

UNIVERSIDADE FEDERAL FLUMINENSE

STEPHENSON DE SOUSA LIMA GALVÃO

**REGISTRO DE IMAGENS TÉRMICAS DA MAMA
ADQUIRIDAS DINAMICAMENTE**

NITERÓI

2015

UNIVERSIDADE FEDERAL FLUMINENSE

STEPHENSON DE SOUSA LIMA GALVÃO

REGISTRO DE IMAGENS TÉRMICAS DA MAMA ADQUIRIDAS DINAMICAMENTE

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Computação da Universidade Federal Fluminense como requisito parcial para a obtenção do Grau de Doutor em Computação. Área de concentração: Computação Visual

Orientador:
Prof.^a D. Sc. Aura Conci

NITERÓI

2015

REGISTRO DE IMAGENS TÉRMICAS DA MAMA ADQUIRIDAS DINAMICAMENTE

Stephenson de Sousa Lima Galvão

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Computação da Universidade Federal Fluminense como requisito parcial para a obtenção do Grau de Doutor em Computação. Área de concentração: Computação Visual

Aprovada em 5 de março de 2015.

BANCA EXAMINADORA

Prof.^a D.Sc. Aura Conci / UFF (Presidente)

Prof. D.Sc. Aristófanês Corrêa Silva / UFMA

Prof.^a D. Sc. Débora Christina Muchaluat Saade / UFF

Prof. D. Sc. Gilson Antonio Giraldi / LNCC

Prof. D. Sc. Leandro Augusto Frata Fernandes / UFF

Niterói

2015

A Deus, meu refúgio, minha fortaleza, defensor sempre alerta nos perigos.

À minha família, em especial meu pai, minha mãe e meus irmãos.

À minha esposa, Luanne Galvão.

A meus mestres e amigos.

Agradecimentos

É bom agradecer a Javé, e tocar teu nome, ó Altíssimo; anunciar pela manhã o teu amor e tua fidelidade pela noite. Até minhas angústias fizestes para me proteger. O teu amor é bom e para sempre.

Agradeço minha família: Madrinha Valda e Padrinho Acideo, pela moradia, quando pequeno; Tia Ana, Tia Edite, Tia Maria e Bisavô Galvão, pela primeira casa da família; Tio Paulo, pelas mensalidades do colégio; Madrinha Socorro, pelos presentes e revistas; Vovô Chiquinha, pelos carinhos e conselhos; Tia Ceíça e Tio Douglas, pelas ajudas. Padrinho Galvão, pelo carinho e viagens; Stanley e Stênio, pelo companheirismo; e Pai e Mãe, por tudo que sou hoje.

Agradeço à minha esposa Luanne, pela compreensão, amor, companheirismo e apoio.

Agradeço à professora Aura, pela paciência, companheirismo e ensinamentos.

Agradeço aos amigos do VisualLab, Lincoln, Roger, Rafael, João Paulo, Tiago Bonini, Giomar, Gabriel e Gilda, pelas colaborações e amizades.

Agradeço aos amigos do IFPI, do convênio UFF/IFPI, Tiago Elias, Francierick, Rittomar, Valéria, Elane, Simone, Rogério e Nádia, pelo apoio e favores.

Aos meus amigos do grupo NumQueOvos pelo apoio e compreensão.

Resumo

O câncer de mama é o segundo tipo de câncer mais frequente no mundo e o que mais acomete mulheres, tanto nos países em desenvolvimento quanto nos países desenvolvidos. Em seu tratamento, quanto mais cedo o câncer for detectado, mais favorável é seu prognóstico e maior é o seu percentual de cura. Uma das ferramentas de detecção precoce é a mamotermografia, que é aquisição de uma cena por câmeras sensíveis à radiação infravermelha, o que permite a confecção de gráficos de distribuição de calor da superfície da mama, denominados de termogramas. A utilização dos termogramas na detecção do câncer de mama muitas vezes é auxiliada por métodos computacionais que a informação final é obtida a partir da combinação de vários termogramas adquiridos durante um intervalo de tempo de alguns minutos em uma mesma posição. Entretanto, durante o tempo de captura, é comum a paciente realizar pequenos movimentos, que acarretam em diferenças entre os termogramas e prejudicam os resultados obtidos no processamento dos dados. Por isso, antes da análise desses termogramas, é necessário realizar um alinhamento entre eles, diminuindo suas diferenças e, assim, facilitando o seu uso por métodos computacionais. Uma das formas de realizar esse trabalho é através das técnicas denominadas de registro de imagens, que são técnicas, orientadas ao contexto, de mapeamentos entre imagens. Com isso, este trabalho tem como objetivo o desenvolvimento de um método de registro de imagens para os termogramas adquiridos pelo protocolo dinâmico armazenados na plataforma DMR (plataforma pública mantida pelo Visual Lab/UFF). O registro simplificará o uso dos termogramas no processamento por ferramentas de auxílio ao diagnóstico, proporcionando a estes melhores resultados. As contribuições desse trabalho será utilização da transformação de Möbius para o mapeamento entre os termogramas, uma função bastante robusta mas pouca explorada nos métodos de registro de imagens; o estudo sobre a movimentação das pacientes durante o exame e quais alterações essa movimentação provoca nos termogramas; e o desenvolvimento de uma nova medida de similaridade entre os termogramas, o qual é formado pela união do coeficiente Dice e da Informação Mútua Normalizada. Por fim, o método elaborado foi testado em um conjunto heterogêneo de 23 pacientes. Neste teste o índice de melhora foi superior a 80% em quase todas as pacientes, em somente duas, esse índice foi inferior a 75%. Entretanto, pela média e desvio padrão dos resultados, houve melhoria em todas as pacientes, para a maioria das avaliações numéricas de desempenho empregadas.

Palavras-chave: Câncer de Mama; Registro de Imagens; Termogramas; Medidas de Similaridade

Abstract

Breast cancer is the second most common cancer worldwide but the most frequent on the female population in undeveloped or developed countries. When earlier treated, more favorable is the prognosis and greater is the cancer cure rate. One of the tools for early detection is the called mammothermography, which consists of the use of an infrared camera for acquisition of a scene and its representation in graphs of temperature distribution. The use of such thermograms for the detection of breast cancer is often assisted by computational methods which uses a combination of several thermograms acquired in a time interval and pattern recognition techniques. However, as for such an examination the patient must still in a same place for minutes, it is common some small movements that represent differences among a series of images of the same examination and these differences affect the final results of computational image analyses. Therefore, approaches for reduction of these differences, named of image registration approaches, must be the first step in computational analyze of these thermograms, improving their use in computational methods. One way to do this is using affine or projective mapping among the series of images of the same examination. The aims of this thesis are the development of an image registration methodology for the dynamic protocol data available in the DMI platform of the Visual Lab/UFF, increasing the efficiency of the computational tools for mammothermography. The developments are preceded by two studies, one to identify the best model for transformation to be used in the mapping and, the other to choose which will be the way to better quantify the resulting images. It was found that the models of transformation that can produce better results are the affine and projective transformations. Concerning the evaluator, after consideration of all possible, a new measure (combining the Dice coefficient and the Normalized Mútual Information) is proposed. Least squares and Gauss-Newton algorithms are used to calculate the transform functions. Linear interpolation is used after the data transformation. The developed method was tested, visually and quantitatively, in a heterogeneous group of 23 patients. In qualitative analysis, 18 patients present more then 80% of improvement, and for only two patients such an improvement was less than 75%. The quantitative, the results are even better with improvement in the average alignment for all patients.

Keywords: Breast Cancer; Image Registration; Thermograms; Similarity Measures

Lista de Figuras

1.1	Termografia: (a) mapa da distribuição de calor e (b) imagem térmica. . . .	3
1.2	Neovascularização da região cancerígena [4].	4
1.3	Posição da paciente na aquisição dos termogramas.	5
1.4	Visões do DMR: (a) dados da paciente, (b) termogramas dinâmicos. . . .	6
1.5	Posicionamento dos mamilos nos termogramas de uma paciente.	8
2.1	Etapas de um método de registro de imagens.	11
2.2	Relação geométrica entre cena contínua e uma imagem discreta.	13
2.3	Organização dos pixels no plano euclidiano.	14
2.4	Representação dos números complexos em coordenadas polares.	15
2.5	Transformações de projeções da Figura 2.2 simulando diferentes visões. . .	21
2.6	Mapeamento entre duas projeções de diferentes perspectivas.	21
2.7	Transformações de Möbius.	22
2.8	Transformação em imagem discreta: (a) forma direta e (b) forma inversa. .	25
2.9	Problema do espaço discreto da imagem na transformação inversa.	26
2.10	Cálculo da função de transformação: (a) direto, (b) iterativo.	27
3.1	Exemplo de imagens do trabalho de Lee <i>et al</i> I: (a) imagem da câmera de baixa frequência e (b) imagem da câmera de frequência mediana.[66]	31
3.2	Resultado do registro de imagens de Lee <i>et al</i> I [66]	31
3.3	Deteção das características no métodos de Lee <i>et al</i> II [65]	32
3.4	Marcas utilizadas na avaliação do método de Lee <i>et al</i> II [65]	33
3.5	Disposição das marcas utilizadas no método de Agostini <i>et al</i> [3].	33
3.6	Triangulação de Delaunay, de Agostini <i>et al</i> [3].	33

3.7	Triângulo de orientação do método de Borchardt <i>et al.</i> [13]	35
3.8	Método de Gazolla: (a) correção do posicionamento e (b) transformação [35].	35
3.9	Método de Santos e Fernandes: (a) eixo medial, junto com os pontos analisados, e (b) segmentos verificando pelo método[99].	36
4.1	Esquema do método de registro desenvolvido.	39
4.2	Etapas realizadas no pré-processamento das imagens.	40
4.3	Histograma da imagem de uma paciente.	41
4.4	Imagem produzida pela limiarização de Otsu.	42
4.5	Algoritmo de varredura do conjunto Ω^1 .	43
4.6	Imagem produzida pelo algoritmo de varredura da Figura 4.5.	44
4.7	Elemento estruturante Δ	44
4.8	Exemplo das operações morfológicas: (a) erosão e (b) dilatação.	45
4.9	Imagens geradas pelas operações de: (a) fechamento e (b) abertura.	46
4.10	Testes realizados: (a) operador de Canny aplicado na imagem suavizada, (b) LoG aplicado na imagem suavizada e (c) operador de Canny e LoG aplicados na imagem limiarizada.	47
4.11	Pontos iniciais escolhidos para serem utilizados como características: (a) termograma e (b) borda da paciente.	48
4.12	Contorno de uma paciente com: (a) mamas pequenas e (b) mastectomizada.	49
4.13	Pontos escolhidos como características do registro.	49
4.14	Deteção dos pontos da classe A.	50
4.15	Identificação das axilas: (a) retas utilizadas e (b) mudança de direção das retas.	51
4.16	Identificação dos pontos da classe C.	52
4.17	Teste do método de identificação de características SIFT.	53
4.18	Pontos identificados pelo método de Shi-Tomasi utilizado na borda da paciente.	53
4.19	Associação entre as características.	54

4.20	Criação do conjunto de características de uma imagem.	54
4.21	Função quadrada gerada pelo método dos mínimos quadrados.	56
4.22	Vizinhança utilizada no cálculo da interpolação.	58
4.23	Execução do método nas imagens de uma paciente.	59
4.24	Método de escolha da imagem de referência.	60
5.1	Planos anatômicos [12].	62
5.2	Inclinação lateral na aquisição das imagens térmicas: (a) paciente inclinada, (b) paciente na posição inicial e (c) sobreposição entre as duas imagens. . .	63
5.3	Inclinação para a trás na aquisição das imagens térmicas: (a) paciente inclinada, (b) paciente na posição normal e (c) sobreposição das bordas. . .	63
5.4	Torção da paciente na aquisição das imagens térmicas: (a) paciente com uma leve torção e (b) paciente com uma torção maior.	63
5.5	Sobreposição das bordas das Figuras 5.4a e 5.4b.	64
5.6	Pontos observados: (a) nas imagens da paciente e (b) nas imagens do ma- nequim.	65
5.7	Quadriláteros das imagens da paciente.	69
5.8	Classes dos quadriláteros das imagens da paciente.	69
5.9	Movimentação observada: (a) imagem 10 da paciente e (b) imagem 1 da paciente.	70
5.10	Quadriláteros das imagens do manequim.	70
5.11	Separações dos quadriláteros das imagens do manequim.	70
5.12	Movimentação com resultados semelhantes entre: (a) paciente e (b) mane- quim.	71
5.13	Comparação em que a transformação afim é melhor que a de projeção. . .	72
5.14	Comparação em que a transformação de projeções é melhor que a afim. . .	73
6.1	Conjuntos: (a) divisão da imagem térmica em dois conjuntos e (b) sobre- posição de conjuntos em duas imagens térmicas.	76

6.2	Método de comparação: (a) criação das imagens transformadas e (b) organização dos pares que serão comparados.	85
6.3	Análise dos pares de uma paciente do conjunto de teste.	86
6.4	Imagens de uma paciente submetida ao protocolo dinâmico.	86
6.5	Processamento para o cálculo das medidas de similaridade: (a) imagem binarizada, (b) bordas da paciente e (c) identificação dos mamilos.	88
6.6	Resumo da comparação das medidas de similaridade.	90
6.7	Resumo da comparação com a Nova Medida.	92
7.1	Diversidade de pacientes da amostra aleatória do DMR.	93
7.2	Exemplo do par 12 da paciente 2, o qual não ocorreu uma melhora após o registro.	101
7.3	Subtração entre pares de imagens semelhantes: (a) antes e (b) após o registro.	102
7.4	Análise visual do par 16 da paciente 15: (a) subtração antes e (b) após o registro.	103
7.5	Exemplo onde o método falha.	104
7.6	Imagem 13 da paciente 21: (a) imagem original e (b) contorno da imagem.	104

Lista de Tabelas

5.1	Distância dos mamilos nas imagens térmicas.	66
5.2	Distância das pregas inframamárias nas imagens térmicas.	67
5.3	Distância dos pontos superiores nas imagens do manequim.	67
5.4	Distância dos pontos inferior nas imagens do manequim.	68
6.1	Resultados da análise visual e quantitativa dos pares da Figura 6.4.	87
6.2	Resumo das medidas de similaridade.	87
6.3	Análise visual e quantitativa dos pares da paciente 1	90
6.4	Análise quantitativa dos casos em que Dice e Jaccard falharam.	91
7.1	Classificação das pacientes da amostra analisada.	94
7.2	Análise quantitativa do par 19 da paciente 6.	94
7.3	Pares de imagens que melhoraram após o registro.	95
7.4	Média e desvio padrão dos pares analisados.	95
7.5	Análise qualitativa dos pares da paciente 6.	97
7.6	Porcentagem de melhora por paciente em cada uma das medidas analisadas.	98
7.7	Média e desvio padrão da análise quantitativa da paciente 6.	98
7.8	Média das medidas de similaridade dos pares de imagens por paciente.	99
7.9	Desvio padrão das medidas de similaridade por paciente.	100
7.10	Análise quantitativa do par 12 da paciente 2 e do par 12 da paciente 1.	102
7.11	Análise quantitativa do par 16 da paciente 15.	103
7.12	Média das medidas de similaridade dos pares de imagens por paciente re- gistrado pelo ITK e pelo método desenvolvido neste trabalho.	106

Lista de Abreviaturas e Siglas

HUAP	:	Hospital Universitário Antônio Pedro;
DMR	:	Database for Mastology Research;
SR	:	Sobreposição da Referência;
FN	:	Falso Negativo;
FP	:	Falso Positivo;
SQD	:	Soma dos Quadrados das Diferenças;
CCN	:	Correlação Cruzada Normalizada;
IM	:	Informação Mútua;
IMN	:	Informação Mútua Normalizada;
DM	:	Distância Média;
DH	:	Distância de Hausdorff;
LoG	:	Laplaciano do Gaussiano;
SIFT	:	Scale-Invariant Feature Transform;
SURF	:	Speeded Up Robust Features;
ASIFT	:	Affine Scale-Invariant Feature Transform;

Lista de Símbolos

(x, y)	: Coordenadas dos pixels em uma imagem discreta;
\tilde{F}	: Função contínua genérica; ;
ξ	: Elemento espacial em um conjunto contínuo; ;
η	: Tempo; ;
Ξ	: Conjunto contínuo limitado ;
F	: Função discreta genérica ;
Ω	: Espaço métrico discreto ;
K	: Conjunto discreto de uma grandeza física ;
ω	: Elemento do conjunto Ω ;
I	: Representação de uma imagem discreta ;
E	: Conjunto de intensidades ;
Γ	: Função que converte valores de K em E ;
\mathbb{R}	: Conjunto dos números reais ;
\mathbb{N}	: Conjunto dos números naturais ;
d	: Função que mede a distância ;
\mathbb{C}	: Conjunto dos números complexos ;
l	: Comprimento de um segmento reta;
α	: Ângulo ;
D	: Conjunto de informações de uma imagem ;
γ	: Função de identificação das características de uma imagem ;
v	: Valor escalar ;
M	: Função de relacionamento entre elementos das imagens ;
Υ	: Função de relacionamento entre pontos das imagens ;
ζ	: Conjunto contínuo, conexo e aberto ;
Φ	: Função de transformação ;
$\tilde{\Omega}$: Conjunto contínuo gerador de ω ;
\tilde{I}	: Representação de uma imagem contínua ;
τ	: Malha infinita discreta ;
W	: Conjunto modelo de transformação de Φ ;

β	: Coeficiente de uma função ;
$\tilde{\omega}$: Elemento do conjunto $\tilde{\omega}$;
(\tilde{x}, \tilde{y})	: Coordenadas dos pixels em uma imagem contínua ;
a	: Elemento de uma matriz ;
O	: Origem de um sistema ;
S^2	: Conjunto de pontos pertencentes a uma esfera de Riemann ;
S_n	: “Polo norte” da esfera de Riemann ;
C	: Função que mede a similaridade ;
Θ	: Função de interpolação ;
T	: União da função de transformação com a interpolação Θ ;
φ	: Função de uma combinação linear ;
N	: Função que recebe um conjunto Ω e informa a quantidade de pixels ;
p	: Função de probabilidade ;
δ	: Amplificação do delta do corpo paralelo ;
L	: Valor de um limiar ;
Δ	: Elemento estruturante ;
ϕ	: Relação funcional desconhecida ;

Sumário

1	Introdução	1
1.1	Mamotermografia	2
1.2	Mamotermografia no diagnóstico do câncer de mama.	3
1.3	Protocolos de aquisição	4
1.4	Protocolo de aquisição utilizado no HUAP	5
1.5	Métodos computacionais de análise dos termogramas	6
1.6	Motivação	7
1.7	Objetivos e contribuições	9
1.8	Estrutura do texto	9
2	Registro de imagens	10
2.1	Pré-processamento	12
2.1.1	Representação das imagens	12
2.2	Identificação das informações das imagens.	15
2.3	Correspondência entre informações	16
2.4	Modelos de transformações	17
2.4.1	Transformações rígidas	18
2.4.2	Transformações afins	19
2.4.3	Transformações de projeções	20
2.4.3.1	Representação no \mathbb{R}^2	20
2.4.3.2	Representação no \mathbb{C}	22
2.4.4	Outros modelos de transformações	23

2.5	Transformações em imagens discretas	24
2.6	Cálculo da transformação e otimização	26
2.7	Medidas de similaridade	28
2.8	Considerações finais sobre registro de imagens	29
3	Trabalhos relacionados	30
3.1	Lee <i>et al</i> I	30
3.2	Lee <i>et al</i> II	31
3.3	Agostini <i>et al</i>	32
3.4	Borchardt <i>et al</i> , Gazolla <i>et al</i> e Santos e Fernandes	34
3.5	Considerações finais dos trabalhos relacionados	36
4	Método desenvolvido	38
4.1	Pré-processamento do método desenvolvido.	39
4.1.1	Limiarização	40
4.1.2	Algoritmo de varredura	43
4.1.3	Fechamento da borda	44
4.1.4	Considerações finais sobre o pré-processamento	47
4.2	Identificação das características no método desenvolvido	47
4.2.1	Definição das características utilizadas	48
4.2.2	Identificação das características da classe A	50
4.2.3	Identificação das características da classe B	51
4.2.4	Identificação das características da classe C	52
4.2.5	Considerações finais sobre a identificação das características	52
4.3	Relacionamento entre as características	54
4.4	Cálculo das funções de transformação	54
4.4.1	Mínimos quadrados	55

4.4.2	Método de <i>Gauss-Newton</i>	57
4.5	Transformação da imagem sensível	58
4.6	Execução sistemática do método.	59
4.6.1	Escolha da referência	60
5	Escolha do modelo de transformações	61
5.1	Análise das imagens do DMR	61
5.2	Hipóteses	64
5.3	Comparação entre paciente e manequim	65
5.3.1	Comparação entre quadriláteros da paciente e manequim.	68
5.4	Considerações finais sobre a escolha do modelo de transformações	71
6	Avaliadores de similaridade	74
6.1	Medidas de similaridade	75
6.1.1	Medidas de sobreposição	75
6.1.1.1	Medidas de concordância	77
6.1.1.2	Medidas de erro	78
6.1.2	Medidas de intensidades	78
6.1.2.1	Soma dos quadrados das diferenças	78
6.1.2.2	Correlação cruzada normalizada	79
6.1.2.3	Informação mútua	80
6.1.3	Medidas de distância	82
6.1.3.1	Distância de Hausdorff	83
6.1.4	Observações sobre os avaliadores	84
6.2	Comparação das medidas de similaridade	85
6.2.1	Avaliação quantitativa realizada	87
6.3	Resultados da comparação das medidas	89

6.4	Considerações finais sobre o estudo das medidas de similaridade	92
7	Resultados	93
7.1	Análise individual	94
7.2	Análise por paciente	96
7.3	Conclusões dos resultados	101
7.3.1	Conclusões dos resultados da análise individual	101
7.3.2	Conclusões da análise por paciente	103
7.4	Comparação do método com outro existente	105
8	Considerações finais	107
8.1	Trabalhos futuros	108
	Referências	109

Capítulo 1

Introdução

O câncer de mama é o segundo tipo de câncer mais frequente no mundo e o que mais acomete mulheres, tanto nos países desenvolvidos quanto nos países em desenvolvimento. A Organização Mundial da Saúde calcula que esse tipo de câncer foi responsável pela morte de aproximadamente 508 mil pessoas em 2011 e 521 mil em 2012 [116]. Para o Brasil, em 2014, foram estimados 57.120 novos casos de câncer de mama, com um risco de 56,09 casos a cada 100 mil mulheres [52].

Uma das estratégias adotadas pela Organização Mundial de Saúde para a diminuição dessa mortalidade é a detecção precoce da doença[116], pois, se identificada em estágios iniciais, quando as lesões são menores de dois centímetros de diâmetro, o câncer de mama apresenta prognóstico mais favorável e elevado percentual de cura[51]. Devido a isso, ações públicas de combate e prevenção ao câncer de mama vêm sendo desenvolvidas no Brasil desde meados dos anos 80, com o lançamento do Programa de Assistência Integral à Saúde da Mulher[16] e do Programa de Oncologia do Instituto Nacional de Câncer [1]. Atualmente, essas ações estão entre os 16 principais objetivos estratégicos do Ministério da Saúde para o período 2011-2015, que prevê a ampliação de acesso, diagnóstico e tratamento em tempo oportuno dos cânceres de mama [52].

Entre as ferramentas de diagnóstico precoce do câncer de mama, a mamografia é o principal exame por imagem realizado atualmente. Neste exame, a paciente tem suas mamas comprimidas pelo mamógrafo e uma radiação ionizante (feixes de raios-x) é incidida sobre elas. Os diferentes tecidos que compõem as mamas absorvem, em vários graus, os raios-x incidentes. Os tecidos densos, como as calcificações, absorvem mais radiação, enquanto que os tecidos menos densos, como as gorduras, permitem uma maior passagem dos raios-x através deles. Como consequência disto, nas imagens de uma mamografia, os tecidos mais densos aparecem com uma intensidade mais alta e os menos densos apare-

cem com uma melhor variação de contrastes. Dessa forma, as possíveis lesões, que são formação mais densa, são identificadas através das áreas de alta intensidade[92].

Apesar da sua grande utilização, a mamografia possui algumas limitações como: a baixa taxa de acerto dos casos positivos, entre as pacientes de mamas densas[118]; o desconforto e o risco de ruptura do encapsulamento de um tumor quando a mama é comprimida[57]; e a exposição à radiação, que pode causar mutações celulares e levar a formações tumorais[92]. Além disso, em um estudo realizado recentemente com 89.835 mulheres de 6 estados canadenses, acompanhadas durante 25 anos, constatou-se que a mamografia anual não teve resultado efetivo na redução das mortes por câncer de mama entre as voluntárias de 40-59 anos[77]. Essas limitações, juntamente com o crescente número de casos de câncer de mama em mulheres jovens, cujas mamas são mais densas, motivam o desenvolvimento de novas metodologias para a detecção precoce da doença, entre elas, a mamotermografia.

1.1 Mamotermografia

A mamotermografia é a confecção de termogramas, que são mapas da distribuição de calor da superfície das mamas [4]. Esses termogramas são fundamentados no princípio de que todo objeto com temperatura acima do zero absoluto (-273°C) emite radiação infravermelha de intensidades e comprimentos de ondas variáveis [82]. A pele humana, por exemplo, emite radiação infravermelha principalmente entre os comprimentos de onda de $2\text{-}20\mu$, sendo que 90% dela está concentrada na faixa de $6\text{-}14\mu$ [11]. Esta radiação é capturada pelo sensor infravermelho da câmera térmica e, juntamente com outros fatores, como a emissividade do corpo, a umidade relativa do ar, a temperatura atmosférica e a distância da paciente para a câmera, é utilizada para calcular a temperatura da pele e formar um mapa da distribuição de calor da mama. Um exemplo desse mapa pode ser visto na matriz da Figura 1.1a, na qual cada célula representa a temperatura de uma determinada região da mama[4].

Nos exames térmicos das mamas, esses mapas são exibidos como imagens térmicas semelhantes à da Figura 1.1b. Nelas, cada temperatura é associada a uma cor que irá preencher as regiões de valores referentes a sua temperatura, possibilitando uma análise direta da distribuição de calor na superfície das mamas.

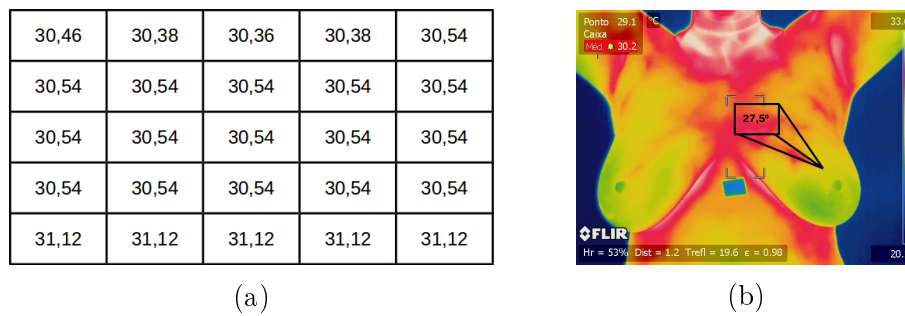


Figura 1.1: Termografia: (a) mapa da distribuição de calor e (b) imagem térmica.

1.2 Mamotermografia no diagnóstico do câncer de mama.

A mamotermografia é um exame fisiológico, sensível às informações do funcionamento normal e anormal do sistema nervoso sensorial e simpático, sistema vascular e processos inflamatórios locais[4]. Essas particularidades tornam-na uma possível ferramenta de identificação do câncer logo no seu estágio pré-tumoral, quando apenas as alterações funcionais são notadas e a quantidade de células cancerígena é tão pequena que é imperceptível aos outros exames.

A detecção precoce pode ocorrer principalmente porque, na etapa de crescimento do tumor, esquematizada pela Figura 1.2, a célula cancerígena libera toxinas presentes nos processos inflamatórios, como a citocina e a quimiocina, capazes de ativar os leucócitos (células imunológicas). Os leucócitos da região são neutralizados pela célula cancerígena, em um processo que produz mais citocina e quimiocina, atraindo mais leucócitos e promovendo um aumento da perfusão de fluidos no local. Esse aumento acaba acarretando em uma neovascularização patológica da região, que proporciona uma elevação do fluxo sanguíneo e, conseqüentemente, incrementa a temperatura e radiação infravermelha do local, o que pode ser detectado pelas câmeras térmicas.

Entretanto, não é somente o crescimento do tumor que provoca alterações de aumento da temperatura da pele. Respostas fisiológicas do organismo às mudanças do ambiente externo, como exposição solar, alterações de temperatura, utilização de loções na pele, entre outras, também motivam reações que podem levar às mudanças na temperatura da pele[4][115]. Além disso, antes de ser captada pelo sensor, a radiação emitida pela pele tende a sofrer atenuações e acentuações ocasionadas pelo ambiente e por outras fontes de calor presentes no cenário[29]. Em decorrência disto, os termogramas das mamas devem ser adquiridos mediante uma rigorosa preparação da paciente e do ambiente, feitas através de protocolos denominados de protocolos de aquisição.




Figura 1.2: Neovascularização da região cancerígena [4].

1.3 Protocolos de aquisição

Vários protocolos de aquisição vêm sendo usados pelos diversos grupos que trabalham com termogramas das mamas [5][56][83]. Em geral, esses protocolos são compostos pelas seguintes partes: preparação da paciente, preparação do ambiente, padronização do sistema de imagens térmicas e aquisições das imagens [82][108]. Na preparação da paciente um conjunto de instruções é repassado antes do exame, instruções como: não fumar e não beber caféina ou álcool no dia do exame. A preparação do ambiente é feita pelo controle de fatores, como a temperatura, fluxo de ar e fontes de calor presentes no cenário. Por fim, na padronização do sistema de imagens e aquisições dos termogramas, o equipamento deve ser padronizado e informações como a distância entre o objeto e sensor, a distância de foco da câmera e os ângulos de captura da paciente (lateral, frontal) são controladas[4][108]. Um desses protocolos é o de Silva *et al*[108], utilizado no Hospital Universitário Antônio Pedro (HUAP), em Niterói, Rio de Janeiro.

1.4 Protocolo de aquisição utilizado no HUAP

No protocolo utilizado no HUAP, o ambiente é controlado da seguinte maneira: a temperatura da sala é mantida entre 20 °C e 22 °C, o local não deve possuir janelas ou aberturas que permitam o fluxo de ar ou entrada de iluminação e somente lâmpadas fluorescentes devem ser utilizadas para a iluminação do local.

Na preparação da paciente, é aconselhado que: pelo menos duas horas antes do exame ela evite álcool, cafeína, exercícios físicos e nicotina; e, no dia do exame, ela não deve aplicar, nas mamas e axilas, qualquer tipo de creme, óleo, loção ou desodorante. Dentro da sala de captura, a paciente é despida das roupas superiores e seu cabelo é preso com uma toca. Após isso, para que seu corpo entre em equilíbrio com a temperatura ambiente, ela é colocada em repouso durante 10 minutos, sentada em uma cadeira com os braços sobre os apoios laterais da mesma. Depois desse tempo, a paciente é posicionada, com as mãos na cabeça, de frente para a câmera, obedecendo às marcações existentes no chão, as quais controlam a distância entre ela e a câmera. O posicionamento da paciente, junto com as marcas de orientação, pode ser vistos na Figura 1.3, que mostra o momento da captura dos termogramas.




Figura 1.3: Posição da paciente na aquisição dos termogramas.

Durante a captura, na parte dinâmica, a paciente é posicionada de frente para a câmera e as áreas do tórax e axilas são resfriadas por um ventilador, até que estas atinjam a temperatura média de 30,5° C. Ao término do resfriamento, uma sequência de 20 termogramas da visão frontal da paciente é adquirida, com um intervalo de 15 segundos entre cada aquisição, demorando aproximadamente 5 minutos para que os 20 termogramas sejam adquiridos.

Por fim, junto com informações fornecidas pela paciente antes do exame, os termogramas adquiridos são armazenados, na forma de imagens (como a da Figura 1.1b), no *Database For Mastology Research* - DMR (Base de Dados para Pesquisas Mastológicas) [102], uma plataforma online mantida e alimentada pelo grupo de pesquisa do laboratório VisualLab (<http://visual.ic.uff.br/>), que serve de auxílio e incentivo para as pesquisas em imagens térmicas. Um exemplo desse armazenamento é exibido na Figura 1.4, na qual, na imagem à esquerda, estão as informações da paciente e, na imagem à direita, estão os termogramas armazenados.

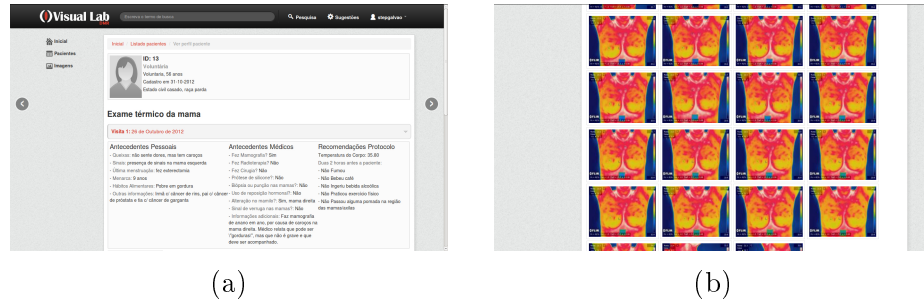


Figura 1.4: Visões do DMR: (a) dados da paciente, (b) termogramas dinâmicos.

1.5 Métodos computacionais de análise dos termogramas

Em alguns estudos de termogramas mastológicos, métodos computacionais de processamento de imagens e sinais são utilizados como instrumentos para a detecção de possíveis indícios da presença ou desenvolvimento do câncer. Por exemplo, utilizando o princípio de que, nos termogramas dinâmicos, a variação da temperatura diverge entre os tecidos normais e tumorais, Gerassionava *et al*[36] estudaram o ritmo de alteração da temperatura de diferentes áreas das mamas, através de séries temporais, criadas por uma sequência de 30000 termogramas da paciente. A mesma variação da temperatura é explorada por Joro *et al*[55] que, utilizando imagens capturadas por três câmeras térmicas de sensibilidades a diferentes comprimentos de onda, constrói séries temporais das temperaturas, as quais são analisadas por relações estatísticas. No trabalho de Silva *et al*[107], as séries temporais são formadas a partir de termogramas da plataforma DMR e analisadas por medidas de complexidade, como complexidade e mobilidade do sinal, entropia e cálculo da dimensão fractal.

Entretanto, em todos os trabalhos discutidos acima, os autores relatam que um dos maiores problemas enfrentados por eles foram as diferenças existentes entre os termogra-

mas dinâmicos de uma mesma paciente. Em grande parte desses casos, essas diferenças são consequência da movimentação da paciente durante a aquisição, alterando o seu posicionamento entre um termograma e outro.

1.6 Motivação

Alterações no posicionamento da paciente no decorrer da sequência de aquisição dificultam a análise das imagens principalmente porque os métodos utilizados baseiam-se na relação entre os valores térmicos de pontos similares, os quais são deslocados junto com a paciente. Por exemplo, em Gerasimova *et al*, a análise multifractal é realizada através da verificação dos valores, ao longo da série de frames, de pontos da região com tumor e de pontos da região saudável, simetricamente posicionada na outra mama. Em Joro *et al* e Silva *et al*, os pontos analisados são gerados a partir da região dos seios, que é dividida em janelas de tamanhos pré-definidos, das quais são extraídos os pontos utilizados para construção das séries temporais. Dessa forma, os diferentes posicionamentos dessas regiões podem provocar relacionamentos imprecisos.

Apesar de todo cuidado no posicionamento da paciente e na preparação realizada pelo protocolo de aquisição, alterações de posicionamentos da paciente também estão presentes nos termogramas dinâmicos do DMR. Uma amostra disto está no estudo exibido pelo gráfico da Figura 1.5, o qual informa as várias localizações dos mamilos na sequência de termogramas de uma paciente. Nesse gráfico, os pontos em azul representam as localizações do centro geométrico do mamilo direito, e os quadrados em vermelho, as do mamilo esquerdo. O cálculo das localizações é feito com base nas coordenadas (x, y) da distribuição dos pixels na imagem, na qual o pixel $(0, 0)$ está localizado no canto esquerdo superior e o pixel $(640, 480)$ está no canto direito inferior. Esses valores estão apresentados através dos eixos das abscissas, com os valores de x , e das ordenadas, com os valores de y . Linhas ligando os pontos das localizações foram adicionadas para enfatizar o sentido dos movimentos.

No gráfico da Figura 1.5, é possível perceber que, para um método de análise que se utiliza de pontos dos mamilos da paciente, é de crucial importância uma etapa que, antes da extração das informações, relacione espacialmente esses termogramas, permitindo que os diferentes posicionamentos desses pontos sejam relacionados o mais corretamente possível. Essa etapa de relacionamento espacial pode ser feita através de técnicas de registro de imagens, as quais, por transformações, criam um mapeamento entre os termogramas




Figura 1.5: Posicionamento dos mamilos nos termogramas de uma paciente.

dinâmicos de uma paciente.

Vários métodos de registro de imagens têm sido desenvolvidos ao longo do tempo [9][74][87]. Entretanto, devido às particularidades existentes em cada imagem e aos diversos objetivos que um registro pode possuir, essa técnica é considerada como um processo orientado ao contexto e, por isso muitos dos trabalhos existentes sobre registro foram criados visando solucionar problemas específicos de mapeamento em uma determinada classe de imagens. Por exemplo, em Lee *et al* [66], os autores desenvolveram um método de registro entre duas imagens da mesma paciente, geradas por câmeras térmicas posicionadas em diferentes ângulos e sensíveis a diferentes espectros de ondas infravermelhas. Em Agostini *et al* [3], foi criado um registro para relacionar cerca de 500 frames de imagens térmicas. Em Borchardt *et al* [13], o alinhamento entre as imagens termica é realizado através da correção do posicionamento da imagem individualmente.

Neste contexto, para uma correta análise dos termogramas dinâmicos do DMR, é necessário um método de registro específico que relacione os termogramas dinâmicos de uma mesma paciente. Esse método servirá como um auxílio para as ferramentas de análise, proporcionando a elas resultados mais corretos. Assim, esse método também contribuirá para o avanço das pesquisas sobre a utilização de imagens térmicas na detecção do câncer de mama.

1.7 Objetivos e contribuições

De acordo com o exposto acima, o objetivo principal desse trabalho é desenvolver um método de registro que relacione os termogramas dinâmicos de uma mesma paciente da plataforma DMR e, assim, auxiliar as pesquisas que necessitem desse relacionamento para a análise dos termogramas. Mais especificamente, este trabalho terá como escopo realizar uma revisão bibliografia dos métodos de registro de imagens médicas existentes na literatura, verificando quais são os mais indicados para as imagens em questão. O produto desse estudo será a criação de um método de registro capaz de realizar o mapeamento entre os 20 termogramas de uma mesma paciente de forma que, através de qualquer termograma da sequência, seja possível ter-se um mapeamento deste com os demais.

Como contribuição será realizado um estudo da movimentação da paciente durante a aquisição dos termogramas, observando os tipos de alterações que essa movimentação pode provocar entre os termogramas. Durante este estudo, hipóteses serão criadas e confirmadas, comparando a movimentação da paciente com a de uma manequim. Para que as alterações sejam corrigidas, o método irá utilizar a função de transformação de Möbius, que é uma transformação robusta, mas de poucas referências entre os trabalhos de registro de imagens, sendo encontrado somente um trabalho de registro com esse tipo de transformação. Além disso, diferentes da maioria dos trabalhos encontrados na literatura, o registro desenvolvido será realizado de forma totalmente automática e sem a colocação de marcas na paciente.

1.8 Estrutura do texto

O restante desse trabalho é organizado da seguinte forma. O capítulo 2 apresenta uma explicação sobre o registro de imagens, exibindo as suas principais etapas e como cada uma delas funciona. No capítulo 3, são comentados alguns dos trabalhos existentes sobre registro em imagens térmicas. No capítulo 6, é feito um estudo sobre os avaliadores de similaridades utilizados em trabalhos de registro de imagens, a verificação do comportamento destes nas imagens térmicas em questão e a escolha do avaliador que será adotado no método desenvolvido. Em seguida, o capítulo 5 considera a movimentação realizada pela paciente durante a aquisição dos termogramas dinâmicos e define qual será o modelo de transformações utilizado para o relacionamento entre os termogramas. Os capítulos finais, 4, 7 e 8, apresentam, respectivamente, o método desenvolvido, os resultados obtidos e as considerações finais do trabalho.

Capítulo 2

Registro de imagens

O registro de imagens tem sido um dos principais desafios na análise de imagens médicas modernas [110]. Uma etapa crucial nos sistemas de processamento de imagens em que a informação final é obtida a partir da combinação de imagens da mesma estrutura, adquirida em tempos diferentes, cenas diferentes ou por sensores diferentes[87].

O registro de imagens pode ser definido como um mapeamento espacial entre duas imagens, uma denominada como imagem de referência e a outra como imagem sensível. O objetivo do método de registro é encontrar uma função de transformação ideal que irá relacionar os pontos da imagem sensível a pontos na imagem de referência e que, ao final, possa gerar uma nova imagem sensível mais “alinhada” à imagem de referência [41].

Devido à diversidade de imagens existentes e os vários tipos de degradações que estas podem sofrer, é impossível existir um método de registro universal, aplicável a todos os problemas. Cada método deve levar em conta não só o tipo de deformação geométrica ou mudança de posicionamentos dos objetos entre as imagens, mas também as deformações provocadas pela fonte de aquisição, os ruídos, a precisão do registro e as particularidades inerentes ao contexto no qual ele será inserido [122].

Apesar da variedade dos métodos de registro de imagens existentes, em alguns estudos, como os de Guo *et al*[41], Zitova e Flusser[122] e Goshtasby[40], os autores apresentam uma sequência de etapas definidas, as quais estão presentes na maioria dos métodos de registro. Estas etapas são: pré-processamento das imagens, identificação das informações, associação das informações identificadas, cálculo da função de transformação, otimização, transformação da imagem sensível, verificação do nível de alinhamento obtido (medição da similaridade).

De uma forma geral, as etapas de um método de registro podem ser esquematizadas

como na Figura 2.1. Inicialmente, as imagens são pré-processadas para facilitar o reconhecimento de informações, como pontos de referência presentes nas duas imagens. Em seguida, essas informações são identificadas e relacionadas entre si. Através dessa relação, é feito o cálculo da função de transformação que irá alterar a imagem sensível, gerando uma nova imagem, mais semelhante à de referência. Após isso, o nível de alinhamento entre as duas imagens é avaliado pelas medidas de similaridades. E, por fim, métodos de otimização podem ser usados para aprimorar a função de transformação, criando imagens ainda mais semelhantes, mas, na maioria das vezes, essa otimização é vista como uma técnica utilizada no cálculo da função de transformação.

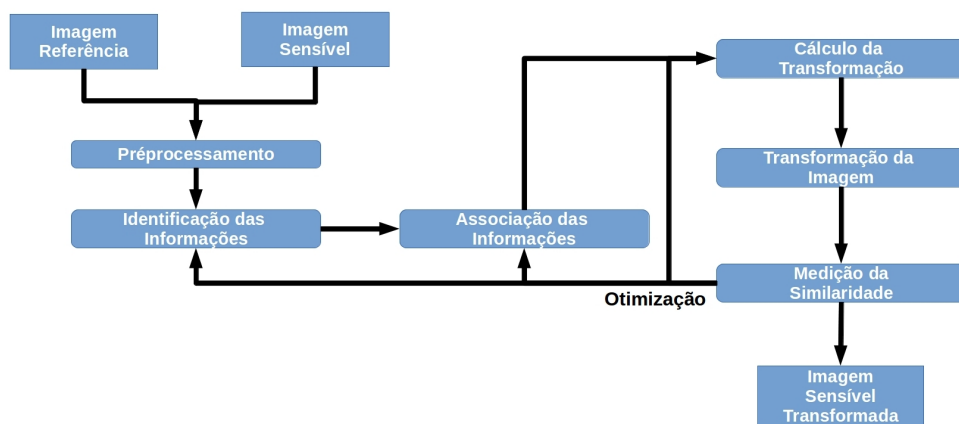


Figura 2.1: Etapas de um método de registro de imagens.

Obedecendo a sequência de etapas de um método de registro de imagens, este capítulo será organizado da seguinte maneira. De início, têm-se as seções de pré-processamento, identificação e associação das informações. Essas consideram o processamento prévio das imagens para o reconhecimento das informações guias, os tipos de informações utilizadas, suas técnicas de identificação e a associação entre elas. Em seguida, estão as seções de modelos de transformações, transformações em imagens discretas e cálculo da função de transformação, nas quais são comentados alguns modelos de transformações relevantes para este estudo, como estes modelos são utilizados em imagens discretas, gerando novas imagens, e como são calculados os seus parâmetros. Por fim, nas seções medidas de similaridade e considerações finais, são apresentados como as medidas de similaridades são utilizadas pelos métodos de registro e algumas observações finais sobre as técnicas de registro de imagens.

2.1 Pré-processamento

A etapa de pré-processamento envolve a preparação das imagens, sensível e de referência, para a identificação de suas informações e o posterior mapeamento entre elas [40]. De forma resumida, essa etapa é formada por métodos de processamento de imagens que procuram diminuir pequenas diferenças entre elas, tornando-as passíveis de manipulação.

Essa etapa ocorre principalmente porque, em alguns casos, as imagens a serem registradas possuem escalas ou tamanhos diferentes, apresentam algum nível de ruído ou apenas áreas das imagens serão relevantes para o método. Nos casos de diferentes escalas ou tamanhos, métodos de ajuste de escala são utilizados como um processamento prévio. Quando ocorrem níveis altos de ruído, filtros de redução de ruídos são aplicados à imagem logo na primeira etapa. Nas imagens em que apenas determinadas áreas contêm informações relevantes para o método, técnicas de segmentação são utilizadas para a identificação dessas áreas de interesse. Por fim, além dos problemas apresentados, outros podem surgir, e, por isso, a forma que ocorre a etapa de pré-processamento e os métodos utilizados por ela variam de acordo com a aplicação.

Exemplos de pré-processamento podem ser observados nos trabalhos de Hopp *et al*[48], Kotsas e Dodd[62] e Mattes *et al*[74]. Em Hopp *et al*, imagens de mamografia e ressonância magnética dos seios são ajustadas por métodos de alteração de escalas e segmentação, antes da realização do registro. No trabalho de Kotsas e Dodd, esse processo prévio é feito através de um filtro de média, que reduz o ruído das imagens, e uma segmentação, que consiste no uso de um algoritmo de crescimento de região, seguido de uma clusterização K-Means [27]. No trabalho de Mattes *et al*, é aplicado um filtro de Gauss[20], para suavização, e, em seguida, um ajuste da resolução entre as imagens a serem registradas.

2.1.1 Representação das imagens

Outro fator importante na manipulação das imagens pelo método de registro é a sua representação digital. Essa digitalização é realizada através da conversão de um campo contínuo para uma forma discreta equivalente, com valores discretos que irão compor toda a imagem[91]. Mais precisamente, sendo $\tilde{F}(\xi, \eta)$ uma função contínua generalizada que representa a luminância, temperatura ou alguma outra propriedade de um sistema físico, no qual ξ é o elemento espacial de um conjunto contínuo limitado e η é uma medida temporal, através da digitalização, um conjunto discreto pode ser obtido de $\tilde{F}(\xi)$ em um instante η_1 e em uma área Ξ , na qual $\xi_i \in \Xi$. Dessa forma, a representação discreta de

$\tilde{F}(\xi_i)$ pode ser vista como $F : \Omega \mapsto K$, onde o domínio Ω é um espaço métrico discreto de elementos ω , e K é um conjunto discreto que expressa os valores da grandeza física digitalizada. Consequentemente, uma imagem pode ser vista como em (2.1), em que Γ é a relação que converte os valores de K em intensidades E , as quais serão relacionadas com os pixels da imagem, organizados pelo conjunto espacial Ω e representados por seus elementos ω . Dessa forma, uma imagem é vista como uma relação $I : \Omega \mapsto E$, em que cada pixel ω tem sua intensidade definida por $I(\omega)$, que será um valor de E [91].

$$I : \Omega \mapsto E \Leftrightarrow I(\omega) = \Gamma \tilde{F}(\omega) \quad (2.1)$$

Para imagens, o processo de discretização pode ser representado pelos elementos da Figura 2.2, que expressa a relação entre a imagem térmica I e o cálculo das temperaturas $\tilde{F}(\xi_i)$, em um determinado instante η_1 , de uma cena orientada pelas coordenadas do plano Euclidiano $(x_O, y_O) \in \mathbb{R}^2$. Na imagem I , o domínio corresponde ao produto cartesiano de números naturais e cada um dos seus valores discretos é chamado pixel, ou seja, $\Omega \subset \mathbb{N}^2$ e $\omega = (x, y)$, com $0 \leq x \leq N_1$ e $0 \leq y \leq N_2$. Na Figura 2.2, (x_O, y_O) representam as coordenadas reais da cena da imagem e (x, y) as respectivas coordenadas nos pixels da imagem, os quais correspondem a valores em uma matriz (ou array bidimensional), onde o valor de cada célula representa uma determinada temperatura.




Figura 2.2: Relação geométrica entre cena contínua e uma imagem discreta.

No trabalho de Silva *et al*[107], os pixels das imagens térmicas são organizados, como na Figura 2.3, sendo o domínio Ω um espaço métrico completo, subconjunto de \mathbb{N}^2 com a métrica $d(\omega_1, \omega_2) = |\omega_2 - \omega_1|$ [64][80]. Seus elementos são representados por $\omega = (x, y)$, com $0 \leq x \leq 639$ e $0 \leq y \leq 479$. Os valores armazenados em cada pixel variam de 0 a 255, ou seja, $E = [0..255]$, sendo que as temperaturas digitalizadas da cena pelo sensor térmico, são convertidas em valores de E pela equação (2.2), na qual $temp$ é a temperatura

calculada e MAX e MIN são as temperaturas máxima e mínima da cena .

$$\Gamma(temp) = \frac{255.temp - MIN}{MAX - MIN} \quad (2.2)$$

Ω	0	1	2	3	4	...	639
0						...	
1						...	
2						...	
3						...	
..
479						...	

Figura 2.3: Organização dos pixels no plano euclidiano.

Outra forma de representação dos pixels na imagem I é através do plano complexo [8][46]. Nela, os pixels são organizados por um espaço métrico completo [64], subconjunto de \mathbb{C} com métrica espacial $d(\omega_1, \omega_2) = |\omega_2 - \omega_1|$, ou seja, $\Omega \subset \mathbb{C}$, no qual $\omega = x + yi$, em que $x \in \mathbb{N}, 0 \leq x \leq N_1$ e $y \in \mathbb{N}, 0 \leq y \leq N_2$, sendo x a parte real do número e y a sua parte imaginária de unidade imaginária i com $i^2 = -1$. No primeiro momento, essa representação pode ser vista de forma semelhante a do trabalho de Silva *et al*, mas implícitas diferenças relacionadas às propriedades dos números complexos diferenciam os dois espaços métricos [8].

Além da sua forma cartesiana descrita acima, um número complexo também pode ser representado em coordenadas polares[22][63]. Nessa representação, Figura 2.4, $\omega = l.(\cos(\alpha) + \sin(\alpha)i)$, sendo α , o ângulo formado entre o eixo das abscissas e a reta que liga a origem ao número ω , e l , o comprimento dessa reta, medido pela distância euclidiana entre ω e a origem, expressa pela fórmula (2.3). O módulo do número complexo pode ser expresso também como $\|\omega\|$:

$$\|\omega\| = |\omega| = l = \sqrt{x^2 + y^2}, l \in \mathbb{R} \quad (2.3)$$

Aplicando coordenadas polares, outra notação possível para ω é através da fórmula de *Euller*, em que $\omega = |\omega|.e^{i\alpha}$, sendo e o número de *Euller*. Assim, fixando $|\omega| = 1$, tem-se um círculo unitário, $\omega = e^{i\alpha}$, formado por todos os números complexos de módulo 1, os quais são utilizados nas transformações de rotações da seção 2.4.




Figura 2.4: Representação dos números complexos em coordenadas polares.

2.2 Identificação das informações das imagens.

Após o pré-processamento, informações das imagens são identificadas e utilizadas como guias para o método de registro. Essas informações podem ser representadas por um conjunto D e serão úteis, tanto no cálculo da função de transformação, como na avaliação do registro realizado.

Na maioria dos trabalhos essas informações são denominadas de características, as quais são derivadas das intensidades dos pixels das imagens. Dessa forma, D pode ser visto como o conjunto das características de uma imagem, definido em (2.4), onde γ é uma função utilizada na identificação das características da imagem I e ω_i são os pixels que as representam. Um exemplo de características são: marcas colocadas durante a aquisição das imagens, padrões presentes nas imagens, bordas, contornos, superfícies e pontos visualmente correspondentes às estruturas anatômicas dos objetos da imagem [41].

$$D = \{\omega_i \mid \omega_i \in \gamma(I)\} \quad (2.4)$$

Na maioria das vezes, as características a serem identificadas podem ser resumidas como abstrações de pontos, linhas ou regiões das imagens [40][122]. Pontos são os tipos mais desejados de características, pois, conhecendo-se as coordenadas de um número de pontos correspondentes, a função de transformação pode ser calculada de maneira mais simples e direta através de diversos métodos [40]. Pontos podem representar centróides de regiões [122], interseções entre linhas [65], padrões (como os cantos) ou qualquer outra estrutura que possa ser resumida em uma coordenada [112]. Goshtasby, em seu livro [40], lista uma variedade de possíveis pontos utilizados como características e seus métodos de identificação. As linhas podem ser representações de limites de tecidos ou estruturas anatômicas alongadas [72]. Normalmente, esse tipo de característica é identificado por técnicas de detecção de bordas e métodos de ajustes de retas e curvas [40]. Por fim, as

estruturas do tipo região são conjuntos fechados e contínuos de pixels de intensidades semelhantes, como os mamilos. Essas estruturas podem ser reconhecidas por métodos de segmentação de regiões, identificação de texturas, ou de detecção de bordas [50].

Outro fator importante sobre a identificação das características é a forma pela qual essas são identificadas, que pode ser manualmente, semiautomática ou automática. Na identificação manual, o usuário seleciona de forma direta as características que serão utilizadas e, por isso, este método é demorado e suscetível à falha humana. Na identificação semiautomática, esse processo é auxiliado pelo computador, que guia e induz o usuário na seleção das possíveis características. Por fim, a identificação automática é feita sem a interação humana, apenas por técnicas de processamento de imagens, por isso, sendo mais rápida, mais repetível e não suscetível à falha humana [122].

Apesar das características serem propriedades inerentes à imagem, possuem várias formas de identificação e existem diversos tipos, em todos os casos, essas informações, preferencialmente, devem satisfazer determinados critérios: serem distintas, esparsas por toda a imagem e facilmente detectáveis. Além disso, espera-se também que elas sejam estáveis, independente das deformações da imagem, da modalidade de captura, da presença de ruídos e das mudanças do ponto, ângulo e direção de visualização da cena. Quanto mais esses critérios acima estiverem presentes nas características, mais chance o registro tem de produzir bons resultados [40].

2.3 Correspondência entre informações

As informações identificadas na etapa anterior necessitam agora ser relacionadas entre si, ou seja, os elementos do conjunto D da imagem I_R são associados a elementos do conjunto D da imagem I_S . Esse relacionamento pode ser visto como uma função que utiliza as características identificadas nas duas imagens, para criar pares de relacionamentos entre elas. Dessa forma, sendo D_R e D_S os conjuntos das características identificadas em I_R e I_S , a associação entre pontos desses conjuntos pode ser vista como em (2.5), em que o conjunto de pares associados (ω_R, ω_S) , com $\omega_R \in D_R$ e $\omega_S \in D_S$, é indicado por uma relação Υ , a qual calcula propriedades específicas de cada ponto, gerando um relacionamento entre eles.

$$M : D \times D \rightarrow (D, D) \Leftrightarrow M = \{(\omega_R, \omega_S) \mid \Upsilon(\omega_R, \omega_S)\} \quad \omega_R \in D_R \quad \omega_S \in D_S \quad (2.5)$$

A relação entre as características dos conjuntos, feita através de Υ , pode ser calculada com base nos valores da vizinhança dessas características, nas suas relações espaciais ou pelos descritores que as individualizam [122]. Nos métodos que se utilizam da vizinhança, são analisados os valores dos pixels mais próximos às características, definidos por uma vizinhança previamente estabelecida. Nas relações espaciais, referências, como a distância entre características e sua posição em relação a pontos da imagem, são utilizadas no cálculo dos valores de associação. Esses métodos geralmente são aplicados quando as características possuem uma vizinhança ambígua ou localmente distorcida. Por fim, nos métodos que se utilizam de descritores, propriedades inerente às características são mensuradas através de coeficiente, como os coeficientes de canto de Harris[43] e Shi-Tomasi[105]. Independente do tipo, em todos os métodos de associação entre as características, os atributos a serem analisados devem ser preferencialmente invariantes, únicos, estáveis e independentes [122].

2.4 Modelos de transformações

Após a correspondência entre as características identificadas em ambas as imagens, é possível calcular uma função que irá mapear os pontos da imagem sensível aos pontos da imagem de referência. Essa função é denominada de transformação. Formalmente, uma transformação pode ser definida como uma relação que mapeia um conjunto sobre ele próprio. Assim, sendo ζ um conjunto contínuo conexo e aberto e sendo $\bar{\zeta}$ o seu fecho na norma euclidiana (formado por ζ junto com seus limites), uma transformação é uma função Φ que realiza mapeamentos de ζ para ele próprio [8].

Como as transformações Φ são realizadas em conjuntos contínuos e as imagens I são representadas por conjuntos discretos Ω , nesta seção, nas explanações sobre transformações, serão utilizadas representações contínuas das imagens. A utilização dessas transformações em imagens discretas será comentada na seção 2.5, junto com as técnicas de interpolação, as quais convertem os valores contínuos, produzidos pelas transformações, em resultados discretos pertencentes ao domínio de representação das imagens. Dessa forma, sendo $I : \Omega \rightarrow E$ uma imagem discreta, a sua representação contínua pode ser vista como $\tilde{I} : \tilde{\Omega} \rightarrow E$, na qual $\tilde{\Omega}$ é um o conjunto contínuo conexo aberto, gerador de Ω , o qual é formado pela uma interseção de $\tilde{\Omega}$ com uma malha infinita discreta τ , como em (2.6) [44]. Por fim, uma transformação Φ em \tilde{I} pode ser definida de acordo com (2.7), como um mapeamento de $\tilde{\Omega}$ para ele mesmo.

$$\Omega = \tau \cap \tilde{\Omega} \quad (2.6)$$

$$\Phi : \tilde{\Omega} \rightarrow \tilde{\Omega} \quad (2.7)$$

Diante do exposto acima, um registro de imagens pode ser definido como uma transformação que, aplicada à imagem \tilde{I}_S , torne esta mais semelhante à imagem de referência, \tilde{I}_R . Assim, sendo \tilde{I}_S^Φ a imagem \tilde{I}_S transformada por uma função Φ , o objetivo do registro é, dentro de um universo W , composto de transformações suaves em $\overline{\Omega}$ (fecho de $\tilde{\Omega}$), encontrar um Φ que torne \tilde{I}_S^Φ similar à \tilde{I}_R , como expressa (2.7) [93] [97].

$$\tilde{I}_S^\Phi \simeq \tilde{I}_R \Leftrightarrow \tilde{I}_S \circ \Phi \simeq \tilde{I}_R, \quad \Phi \in W \quad (2.8)$$

Além de delimitador do universo de soluções do alinhamento entre as duas imagens, o conjunto W também pode ser visto como um classificador ou modelo das transformações possíveis do registro. Ele especifica quais os coeficientes que compõem a função Φ e os tipos de deformações que ela pode realizar na imagem \tilde{I}_S , a fim de torná-la mais similar à \tilde{I}_R [8][112][122]. Dessa forma, em cada método de registro, um conjunto W deve ser definido, caracterizando e delimitando o tipo das transformações realizadas pelo método.

A escolha do modelo de transformação W de um registro é feita levando em consideração, o tipo de deformações que diferenciam as imagens, e o grau das alterações permitidas no contexto do registro. O modelo escolhido deve ser capaz de corrigir as diferenças entre as imagens, satisfazendo o nível das alterações permitidas para o registro. Alguns modelos utilizados em trabalhos anteriores sobre registro de imagens são: transformações rígidas, transformações afins e transformações de projeções. A seguir, cada um deles é explicado.

2.4.1 Transformações rígidas

As transformações rígidas [34] são um dos tipos mais simples de transformação. Elas são caracterizadas por preservarem a distância entre todos os pares de pontos do conjunto $\tilde{\Omega}$, realizando apenas transformações de rotação e a translação na imagem. As transformações rígidas podem ser definidas como em (2.9), uma função de coeficientes β_α e β_t , responsáveis pelas rotações e translações, respectivamente.

$$\Phi(\tilde{\omega}) = \beta_\alpha \tilde{\omega} + \beta_T, \quad \forall \tilde{\omega} \in \tilde{\Omega} \quad (2.9)$$

Sendo $\tilde{\Omega} \subset \mathbb{R}^2$ e $\tilde{\omega} = (\tilde{x}, \tilde{y}) \mid x \in \mathbb{R} \wedge y \in \mathbb{R}$, as transformações rígidas podem ser expressas através da função (2.9), na qual α é a rotação e (t_x, t_y) é vetor de translação, onde $t_x \in \mathbb{R}$ e $t_y \in \mathbb{R}$.

$$\Phi\left(\begin{bmatrix} \tilde{x} \\ \tilde{y} \end{bmatrix}\right) = \begin{bmatrix} \cos(\alpha) & -\sin(\alpha) \\ \sin(\alpha) & \cos(\alpha) \end{bmatrix} * \begin{bmatrix} \tilde{x} \\ \tilde{y} \end{bmatrix} + \begin{bmatrix} t_x \\ t_y \end{bmatrix} \quad (2.10)$$

Por outro lado, nas imagens em que $\tilde{\Omega} \subset \mathbb{C}$ e $\tilde{\omega} = \tilde{x} + \tilde{y}i$, com $\tilde{x} \in \mathbb{R}$ e $\tilde{y} \in \mathbb{R}$, as transformações do tipo rígida podem ser definida através da equação (2.10), na qual α é a rotação, que será realizada de acordo com os elementos do círculo unitário $e^{i\alpha}$ (seção 2.1.1), e t é o vetor de deslocamento, sendo $t \in \mathbb{C}$.

$$\Phi(\tilde{\omega}) = e^{i\alpha} \tilde{\omega} + t \quad (2.11)$$

2.4.2 Transformações afins

As transformações afins[46] são mais genéricas do que as transformações rígidas. Nestas transformações são preservadas as linhas retas do conjunto e o paralelismo existente entre elas. Entretanto, os ângulos entre as linhas e as distâncias entre pontos não são obrigatoriamente mantidos por esse tipo de transformações. As alterações realizadas pelas transformações afins são: translação, escala, rotação, reflexão e cisalhamento. De uma forma genérica, uma transformação afim é expressa como em (2.12), na qual β_A é o coeficiente linear da transformação, responsável pela escala, rotação, reflexão e cisalhamento, e β_T é o coeficiente de translação.

$$\Phi(\tilde{\omega}) = \beta_A \tilde{\omega} + \beta_T, \quad \forall \tilde{\omega} \in \tilde{\Omega} \quad (2.12)$$

Considerando $\tilde{\Omega} \subset \mathbb{R}^2$ e $\tilde{\omega} = (\tilde{x}, \tilde{y})$, com $\tilde{x} \in \mathbb{R}$ e $\tilde{y} \in \mathbb{R}$, a representação de uma transformação afim pode ser feita através de (2.13), na qual os coeficientes a_1 , a_2 , a_3 e a_4 são números reais responsáveis pela parte linear β_A , e t_x e t_y são números reais que compõem o vetor de translação β_T .

$$\Phi\left(\begin{bmatrix} \tilde{x} \\ \tilde{y} \end{bmatrix}\right) = \begin{bmatrix} a_1 & a_2 \\ a_3 & a_4 \end{bmatrix} * \begin{bmatrix} \tilde{x} \\ \tilde{y} \end{bmatrix} + \begin{bmatrix} t_x \\ t_y \end{bmatrix} \quad (2.13)$$

Para $\tilde{\Omega} \subset \mathbb{C}$, a representação das transformações afins é semelhante à expressão (2.12), sendo β_A e β_T seus coeficientes lineares e de translação, com $\beta_A \in \mathbb{C}$ e $\beta_T \in \mathbb{C}$. Nesta representação, estão presentes as seguintes operações em \mathbb{C} [59].

$$\Phi(\tilde{\omega}) = s\tilde{\omega}, s \in \mathbb{R} \quad (2.14)$$

$$\Phi(\tilde{\omega}) = \tilde{\omega} + \mathbf{t}, t \in \mathbb{C} \quad (2.15)$$

$$\Phi(\tilde{\omega}) = e^{i\alpha}\tilde{\omega} \quad (2.16)$$

$$\Phi(\tilde{\omega}) = \bar{\omega} \quad (2.17)$$

$$\Phi(\tilde{\omega}) = \frac{1}{\tilde{\omega}} \quad (2.18)$$

As quais representam respectivamente mudança de escala, translação, rotação, conjugado do número complexo e inversão.

2.4.3 Transformações de projeções

O último tipo de transformação a ser comentada é a transformação de projeção ou homografia. Essa classe de transformações é conhecida por estudar as perspectivas visuais, ou seja, as diferentes aparências de um mesmo objeto observado por diferentes pontos de vista, semelhantes às imagens da Figura 2.5a e 2.5b, que são simulações de diferentes visões de um termograma, feitas através de transformações de projeções.

2.4.3.1 Representação no \mathbb{R}^2

Nas representações em que $\tilde{\Omega} \subset \mathbb{R}^2$, uma transformação de projeção pode ser vista como na Figura 2.6, um mapeamento entre as imagens \tilde{I}_R e \tilde{I}_S , que são projeções centrais[20] da imagem \tilde{I} nos planos $\tilde{\Omega}_R$ e $\tilde{\Omega}_S$, através das origens O_R e O_S , as quais estão linearmente




Figura 2.5: Transformações de projeções da Figura 2.2 simulando diferentes visões.

relacionadas. Os diferentes posicionamentos das origens O_R e O_S podem ser comparados aos diversos posicionamentos de uma câmera, gerando imagens com diferentes visões de um mesmo objeto, como as da Figura 2.5.

Através de espaços \mathbb{R}^3 , com origens em O_R e O_S e orientações conforme a figura 2.6, é possível realizar o mapeamento entre \tilde{I}_S e \tilde{I}_R , criando transformações de $\tilde{\Omega}_S$ para $\tilde{\Omega}_R$, ou vice-versa. Isso pode ser feito mais facilmente se forem usadas, nesses espaços, coordenadas homogêneas[54] entre o plano de \tilde{I} e os planos de projeções $\tilde{\Omega}_R$ e $\tilde{\Omega}_S$. Essas notações podem ser relacionadas pela transformação afim que associa os pontos de origem O_R e O_S , gerando uma transformação como a (2.19), em que $(\tilde{x}_r, \tilde{y}_r)$ e $(\tilde{x}_s, \tilde{y}_s)$ são os pontos de $\tilde{\Omega}_R$ e $\tilde{\Omega}_S$ e a_{ij} são os coeficientes da transformação de projeção, na qual $a_{ij} \in \mathbb{R}$, $i, j = 1 \dots 3$.




Figura 2.6: Mapeamento entre duas projeções de diferentes perspectivas.

$$\Phi\left(\begin{bmatrix} \tilde{x}_r \\ \tilde{y}_r \\ 1 \end{bmatrix}\right) = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix} \begin{bmatrix} \tilde{x}_s \\ \tilde{y}_s \\ 1 \end{bmatrix} \quad (2.19)$$

2.4.3.2 Representação no \mathbb{C}

Para $\tilde{\Omega} \subset \mathbb{C}$, as transformações de projeções podem ser realizadas através da esfera de Riemann: uma esfera $S^2 = \{(u, v, w) \in \mathbb{R}^3 | u^2 + v^2 + w^2 = 1\}$ que é homeomórfica, isto é, tem todos os seus pontos em correspondência com o plano \mathbb{C}_∞ , o qual é formado pela união de \mathbb{C} mais o “infinito”, $\mathbb{C}_\infty = \mathbb{C} \cup \infty$. A função que faz a correspondência entre S^2 e \mathbb{C}_∞ é mostrada na Figura 2.7a, sendo que o “polo sul” da esfera coincide com a origem de \mathbb{C}_∞ e seu “polo norte”, S_N , localizado na outra extremidade da esfera.[59]




Figura 2.7: Transformações de Möbius.

O mapeamento $SC : \mathbb{C} \rightarrow S^2 \setminus S_N$, entre o conjunto dos complexos e os pontos da esfera de Riemann, sem o “polo norte”, pode ser feito através de uma linha CS_N que liga o “polo norte” da esfera a um ponto c em \mathbb{C} e intercepta a esfera em um ponto s . Através desta ilustração, nota-se que, para qualquer $c \in \mathbb{C}$, existe somente uma reta CS_N , sendo que esta intercepta $S^2 \setminus S_N$ em somente um ponto s , associando assim um único s a cada ponto c em \mathbb{C} , tornando, com isso, SC um mapeamento inversível, cujo inverso é SC^{-1} . Além disso, outra propriedade de SC , é que ele é um mapeamento contínuo, no sentido de que, pontos próximos em \mathbb{C} permanecem próximos em $S^2 \setminus S_N$, e, quanto mais afastado o ponto c for da origem, mais próximo ao S_N ele será mapeado[59].

O complemento do alcance de SC para \mathbb{C}_∞ pode ser feito com a inclusão do norte

da esfera, formando um mapeamento $SC : \mathbb{C}_\infty \rightarrow S^2$. Neste novo mapeamento, o ponto ∞ (“infinito”) pode ser visto como um grande círculo infinitamente distante em \mathbb{C} , cuja imagem em SC é o ponto S_N , assim $SC(\infty) = S_N$. Outra forma de ver essa extensão de SC é comentada por Barnsley[8] em seu livro, nela \mathbb{C}_∞ é interpretado como uma regra do mapeamento pela esfera de *Riemann* e não como a união de \mathbb{C} com o “infinito”.

Através do mapeamento $SC : \mathbb{C}_\infty \rightarrow S^2$ e do seu inverso $SC^{-1} : S^2 \rightarrow \mathbb{C}_\infty$, é possível criar uma transformação $\Phi : \mathbb{C}_\infty \rightarrow \mathbb{C}_\infty$, que realize o mapeamento do plano \mathbb{C}_∞ para ele mesmo, como na Figura 2.7b. Nesse tipo de transformação, todo o plano \mathbb{C}_∞ é, inicialmente, mapeado para a esfera de Riemann. Após isso, transformações $SS : S^2 \rightarrow S^2$ são efetuadas dentro da própria esfera através de: rotações sobre o seu eixo; expansão e contração do seu volume; e translação desta no plano \mathbb{C}_∞ . Ao final, utilizando SC^{-1} , os pontos da esfera são mapeados de volta para o plano \mathbb{C}_∞ , finalizando a transformação $\Phi : \mathbb{C}_\infty \rightarrow \mathbb{C}_\infty$, a qual pode ser vista como $\Phi = SP \circ SS \circ SP^{-1}$.

As transformações do tipo $\Phi : \mathbb{C}_\infty \rightarrow \mathbb{C}_\infty$, utilizando a esfera de Riemann, são denominadas de transformações de Möbius, as quais são expressas como em (2.20), onde $\beta_A, \beta_B, \beta_C$ e $\beta_D \in \mathbb{C}$ [8]. As transformações de Möbius são inversíveis, contínuas e mapeiam círculos e linhas para círculos e linhas, preservando os ângulos entre elas, assim como as suas orientações. Além disso, as transformações de Möbius também podem ser vista como a composição de uma transformação afim $\beta_A \tilde{\omega} + \beta_B$ junto com a sua inversa $1/(\beta_C \tilde{\omega} + \beta_D)$. Com isso, nota-se que, para $\beta_C = 0$, a transformação de Möbius é considerada como uma transformação afim, definida em (2.12), sendo $\Phi : (\infty) \rightarrow \infty$. Caso contrário, ou seja, $\beta_C \neq 0$, tem-se que $\Phi(\infty) = \beta_A/\beta_C$ e $\Phi(-\beta_D/\beta_C) = \infty$ [59].

$$\Phi(\omega) = \frac{\beta_A \tilde{\omega} + \beta_B}{\beta_C \tilde{\omega} + \beta_D} \quad (2.20)$$

2.4.4 Outros modelos de transformações

Outros modelos de transformações presentes em trabalhos de registro de imagens são listados em Holden *et al*[47], Sotiras *et al*[110] e Lu *et al*[70]. Diferente dos modelos aqui apresentados, os desses trabalhos, na maioria de vezes, utilizam expansões a partir de funções de base[85] e modelos físicos[113], os quais são usados quando uma quantidade considerável de deformação de segunda ordem é esperada entre as imagens. Entretanto, como será mostrado no capítulo 5, para este trabalho, a paciente pode ser tratada como um corpo rígido, que se movimenta sem deformações anatômicas. Consequentemente, o

aprofundamento dos demais tipos de transformações foge do escopo pretendido.

2.5 Transformações em imagens discretas

As funções de mapeamento Φ , estudadas nas seções anteriores, foram definidas com imagens contínuas $\tilde{I} : \tilde{\Omega} \rightarrow E$, nas quais o mapeamento é realizado entre pontos $\tilde{\omega}$, do conjunto contínuo $\tilde{\Omega}$. Entretanto, ao aplicar essas transformações em imagens discretas do tipo $I : \Omega \rightarrow E$, onde $\Omega \subset \tilde{\Omega}$, tem-se um mapeamento $\Phi : \Omega \rightarrow \tilde{\Omega}$, que relaciona ponto, ω de Ω , com pontos $\tilde{\omega}$, de $\tilde{\Omega}$. Dessa forma, tem-se que a transformação de I_S por Φ é uma imagem contínua \tilde{I}_S^Φ , criada pelo relacionamento $\Phi(\omega_S) = \tilde{\omega}_S$, sendo ω_S pontos de I_S e $\tilde{\omega}_S$ pontos de \tilde{I}_S^Φ [122].

Como nem sempre os pontos $\tilde{\omega}_S$, da imagem contínua \tilde{I}_S^Φ , pertencem ao domínio das imagens discretas Ω , a criação de uma imagem discreta I_S^Φ ou o relacionamento entre $\Phi(\omega_S) = \omega_R$, sendo ω_R ponto de uma imagem discreta I_R , só são possíveis por intermédio de técnicas de interpolação. Através da interpolação os elementos do conjunto imagem de Φ são relacionados com elementos discretos do domínio Ω , criando uma transformação do tipo $T : \Omega \rightarrow \Omega$, formada pela junção de Φ com uma interpolação Θ , como em (2.21).

$$T = \Theta \circ \Phi \quad (2.21)$$

Com esta nova definição, o registro entre duas imagens, I_S e I_R , é feito aplicando a transformação Φ , junto com a interpolação Θ , à imagem I_S , gerando uma nova imagem I_S^T , mais semelhante à I_R . A este processo de criação de I_S^T , Zitova e Flusser [122] denominaram de transformação da imagem, a qual pode ser realizada de forma direta, com a função de transformação Φ , ou de forma inversa, com a função Φ^{-1} .

Na forma direta, cada pixel ω_S , da imagem I_S , é relacionado com um pixel ω_T , da nova imagem I_T , fazendo com que a intensidade de ω_T seja igual à intensidade de ω_S , ou seja, $I_S^T(\omega_T) = I_S(\omega_S)$. Dessa forma, I_S^T é gerada, aplicando a função T , a todos os pontos ω_S e, atribuindo a seus pontos mapeados ω_T , a intensidade $I_S(\omega_S)$, como ilustra a Figura 2.8a. Mais especificamente, a criação de I_S^T pode ser definida como em (2.22), na qual as intensidades dos pixels ω_T de Ω_T são definidas pelo mapeamento T , de I_S para I_S^T .

$$I_S^T = \{\omega_T \rightarrow I_S(\omega_S) \mid \omega_T = T(\omega_S)\} \quad \forall \omega_S \in \Omega_S \quad (2.22)$$




Figura 2.8: Transformação em imagem discreta: (a) forma direta e (b) forma inversa.

Apesar do mapeamento direto parecer intuitivo, essa técnica é de difícil implementação e pode produzir efeitos indesejados na imagem I_S^T , como buracos e sobreposição de pixels [122]. Isso ocorre porque T pode não ser sobrejetora e nem injetora. Dessa forma, é possível que nem todos os pontos ω_T pertencentes à I_S^T , sejam mapeados por T aplicada a Ω_S , ficando esses pontos sem valores de intensidade. Além disso, é possível também que mais de um ponto ω_S , de I_S , seja mapeado para o mesmo ponto ω_T , de I_S^T , causando uma sobreposição de valores de intensidade. Para evitar esses problemas, a construção da imagem transformada, na maioria do caso, é feita de forma inversa.

Na transformação inversa, a criação da nova imagem é feita no sentido contrário ao da transformação direta, utilizando Φ^{-1} . Dessa forma, no lugar do mapeamento ser realizado dos pontos da imagem sensível para os pontos da imagem transformada, ele é feito dos pontos da imagem transformada para os pontos da imagem sensível, como na Figura 2.8b. Mais precisamente, esse mapeamento é realizado entre pontos da imagem transformada e pontos de uma imagem contínua \tilde{I}_S , formada pela interpolação de I_S por Θ , como é exibido em (2.23), criando um mapeamento $\omega_T \rightarrow \tilde{\omega}_S$, na qual $\tilde{\omega}_s$ é um pixel de \tilde{I}_S .

$$\tilde{I}_S = \Theta \circ I_S \quad (2.23)$$

Na transformação inversa, I_S^T pode ser definida como em (2.24), na qual as intensidades dos pixels de ω_T são definidas pela intensidade de seu mapeamento $\Phi^{-1}(\omega_T)$ em I_S . Entretanto, como a imagem de $\Phi^{-1}(\omega_T)$ é contínua e nem sempre seus elementos $\tilde{\omega}_s$ pertencem ao conjunto Ω_S , essas intensidades são calculadas pela interpolação $\Theta(I_S, \Phi^{-1}(\omega_T))$.

$$I_S^T = \{\omega_T \rightarrow v \mid v = \Theta(I_S, \Phi^{-1}(\omega_T))\} \quad \forall \omega_T \in \Omega_T \quad (2.24)$$

Na maioria das vezes, a intensidade de $\tilde{\omega}_s$, calculada por Θ é derivada dos pixels ω_s posicionados em pontos mais próximos de $\tilde{\omega}_s$, representados pelo quadrado vermelho da

Figura 2.9. Esse tipo de interpolação pode ser resumido pela expressão (2.25), na qual ω_i são os pixels de I_S mais próximos de $\tilde{\omega}_s$ e φ é uma função que indica a influência de cada intensidade $I_S(\omega_i)$ no cálculo da intensidade de $\tilde{\omega}_s$ [88].

$$\Theta(I_S, \tilde{\omega}_S) = \sum_i I_S(\omega_i) \varphi(\tilde{\omega}_s, \omega_i) \quad (2.25)$$




Figura 2.9: Problema do espaço discreto da imagem na transformação inversa.

Algumas das técnicas de interpolação inversa utilizadas em imagens médicas são: a do vizinho mais próximo [40], a linear [88] e a cúbica, através da curva B-spline [67]. Um estudo completo sobre as técnicas de interpolação em registro de imagens médicas pode ser visto em Pan *et al*[88] e Lehmann *et al*[67].

2.6 Cálculo da transformação e otimização

O cálculo da função de transformação Φ , utilizada na criação da imagem I_S^T , seja pela transformação direta ou inversa, pode ser visto como um problema de otimização definido em (2.26): uma busca, dentro do universo W , por uma transformação Φ que minimize a função de alinhamento C , a qual é calculada utilizando as imagens I_R e I_S^T , $C(I_R, I_S^T)$. Em outras palavras, esse problema visa, dentro do universo do modelo de transformação, encontrar a função Φ que melhor alinhe a imagem I_S à imagem de I_R de acordo com uma medida C [53][97].

$$\Phi' = \underset{\Phi}{\operatorname{argmin}} C(I_S, I_R; T) \text{ s.t. : } I_S^T \simeq I_R, \Phi \in W \quad (2.26)$$

No cálculo do alinhamento da transformação, a função C pode utilizar as intensidades das imagens ou pontos característicos presentes nas duas imagem. Nesta expressão, ω_R

pertence ao conjunto D_R , formado pelas características da imagem I_R , e ω_T pertence a D_T , conjunto dos pontos característicos da imagem I_S^T . Além disso, ω_T e ω_R são pares de características formadas pela relação M da fórmula (2.5).

$$C : D \times D \rightarrow \mathbb{R} \Leftrightarrow C(\omega_S, \omega_T) = v, \forall (\omega_S, \omega_T) \in M \quad (2.27)$$

A busca da função de transformação Φ é feita através da atribuição de valores β_i aos seus coeficientes β . O tipo e a quantidade dos coeficientes, como visto na seção 2.4, depende de W e do conjunto Ω . Por exemplo, caso $\Omega \subset \mathbb{R}^2$ e W seja o universo das transformações rígidas, os coeficientes das funções $\Phi \in W$ são a rotação α e a translação $t = (t_x, t_y)$, como na fórmula (2.10), sendo $\beta = (\theta, t)$. Assim, ao atribuir os valores $\beta_1 = (\alpha_1, t_1)$ aos coeficientes β , tem-se a função de transformação Φ_{β_1} . O cálculo dos valores de β pode ser feito de forma direta ou iterativa, dependendo do método utilizado.

Os métodos diretos trabalham como na Figura 2.10a. Através de uma função de custo C , um conjunto de valores β_1 é criado e tido como a solução do problema, gerando a transformação Φ_{β_1} , utilizada na criação da nova imagem I_S^T . Na maioria dos trabalhos de registro de imagens, os métodos diretos baseiam-se em técnicas de ajuste de dados, que, de acordo com um modelo definido, visam calcular uma função que diminua as diferenças entre dois conjuntos de dados. Um dos métodos diretos utilizado em registro de imagens é o dos mínimos quadrados [31], usado para estimar transformações não rígidas em Schneider *et al* [101] e para estimar transformações de rígidas em Kim *et al* [58].

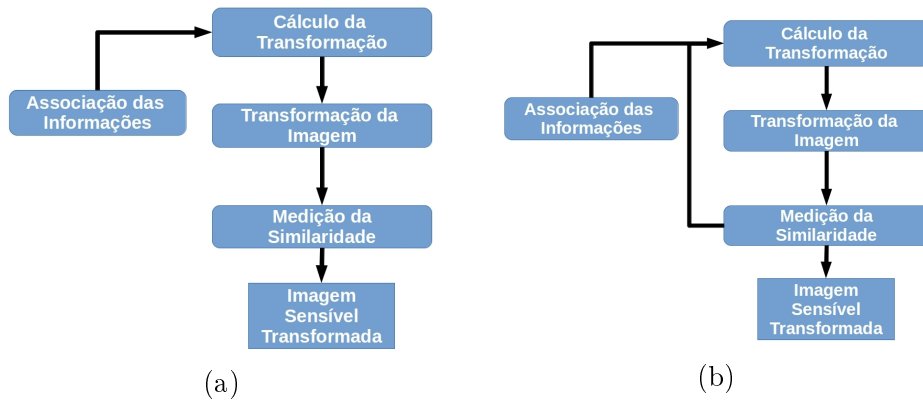


Figura 2.10: Cálculo da função de transformação: (a) direto, (b) iterativo.

Os métodos em que os valores são estimados iterativamente funcionam como na Figura 2.10b. Neles, a cada iteração, um conjunto β_i de valores é sugerido e uma função de transformação Φ_{β_i} é criada, gerando uma imagem I_S^T . Essa imagem é comparada com I_R pela função C . No final das iterações, o conjunto de valores β_i , cuja transformação Φ_{β_i}

gerou a imagem I_S^T mais “alinhada” à I_R , é escolhido como solução do método.

Em registros de imagens baseados em intensidades é comum a utilização de métodos iterativos como os de busca do mínimo local. Exemplos desse tipo de método são os utilizados nos registros de Kotsas *et al*[62], Bozek *et al*[15] e Galvao *et al*[33], nos quais os parâmetros do modelo de mapeamento são estimados através do método de busca local do gradiente descendente[121]. Nos registros de imagens baseados em características é comum o uso tanto dos métodos diretos como dos iterativos. Por exemplo, nos trabalhos de Silva *et al*[107] e Santamaria *et al*[98], que são registros baseados em características, o primeiro calcula a função de transformação de forma direta, pelo mínimos quadrados, e o último por um método iterativo de algoritmos genéticos.

2.7 Medidas de similaridade

As medidas de similaridades são funções que avaliam o grau de alinhamento entre duas imagens através de semelhanças existentes entre elas. As informações das imagens utilizadas no cálculo dessa similaridade variam de acordo com o tipo de medida e o contexto no qual ela é utilizada. Algumas medidas de similaridade analisam a semelhança entre imagens através das intensidades dos pixels das duas imagens, outras utilizam a distância entre características nas duas imagens. Existem também medidas que tratam as imagens como conjuntos binários e calculam a semelhança através da sobreposição de elementos dos mesmos conjuntos [122].

Independente da informação utilizada no cálculo do alinhamento, para o registro de imagens, essas medidas desempenham um papel fundamental, pois elas servem como guia para o cálculo da função de transformação que irá relacionar as duas imagens. Além disso, em muitos trabalhos, essas medidas são utilizadas como um avaliador do método de registro desenvolvido, quantificando e qualificando o nível de alinhamento produzido pelo método. Dessa forma, a escolha de uma medida de similaridade adequada é essencial para a construção de um método de registro preciso.

Entretanto, devido à variedade de medidas e as particularidades de cada registro de imagens, a escolha de uma medida de similaridade adequada não é uma tarefa simples. Para isso, deve-se estudar como cada medida pretendida funciona e analisar como estas se comportam com os tipos de imagens a serem registradas. Ao final, deve-se verificar os resultados e ver se as medidas pretendidas são capaz de avaliar as noções de similaridades desejadas pelo método. Um estudo completo sobre as medidas de similaridades, junto

com os seus comportamentos nas imagens térmicas, é feito no capítulo 6.

2.8 Considerações finais sobre registro de imagens

Resumidamente, o registro de imagens pode ser visto como um processo, no qual o relacionamento entre uma imagem de referência I_R e uma imagem sensível I_S é produzido através das transformações efetuadas em I_S , gerando uma nova imagem I_S^T . Essas transformações, orientadas por Φ , são estabelecidas dentro de um modelo W , do qual Φ faz parte. O cálculo de Φ é realizado com a valorização de seus coeficientes β , determinados pelo modelo W , sendo que a função Φ_{β_i} , gerada pelos valores β_i , deve produzir uma imagem I_S^T semelhante a I_R , semelhança essa calculada pela medida de similaridades C , a qual também serve como guia para a escolha dos valores β_i . Por fim, a criação da imagem I_S^T pela transformação Φ_{β_i} da imagem I_S , só é possível com a utilização de técnicas de interpolação Θ , responsáveis por mapear os resultados de Φ_{β_i} dentro do conjunto discreto de representação dos pixels, Ω .

Devido à capacidade de relacionar imagens desalinhadas, tornando-as mais similares, o registro de imagens tem sido utilizado como um método auxiliar em trabalhos em que a informação final é obtida pela combinação de imagens de uma mesma estrutura. Este problema é muito comum em imagens médicas, nas quais exames são feitos comparando imagens adquiridas em diferentes intervalos de tempos ou por diferentes fontes, especialmente em imagens mastológicas como a mamografia. Nas imagens térmicas das mamas, o registro vem sendo utilizado principalmente em exames dinâmicos, que estudam a variação da temperatura em um curto intervalo de tempo, como nas imagens do DMR. Alguns dos trabalhos de registro em imagens térmicas das mamas desenvolvidos são exibidos no capítulo a seguir.

Capítulo 3

Trabalhos relacionados

Poucos trabalhos sobre registro de imagens térmicas das mamas foram encontrados na revisão bibliográfica. Além disso, em muitos desses trabalhos, mais destaque é dado ao método de análise dos termogramas do que ao método de registro utilizado. Por exemplo, em Arora *et al* [6], para efetuar a análise de uma série de 100 imagens dinâmicas por paciente, os autores apenas relatam que realizam um registro prévio e que esse registro foi guiado por marcas colocadas antes da aquisição das imagens. O mesmo ocorre em Gerasimova *et al*[36], que, com objetivo de reduzir os ruídos causados pelo deslocamento da paciente, os autores executam um registro em um conjunto de 30000 frames de imagens, mas nenhuma informação sobre o método utilizado é comentada. Por fim, uma situação semelhante também é encontrada em Joro *et al*[55], onde é relatado apenas que a análise dos 1700 frames de imagens é precedida por um método de registro de imagens disponíveis na ferramenta Matlab [73].

Entre os trabalhos com maiores informações sobre o método de registro utilizado, pode-se destacar os de Lee *et al* I[66], Lee *et al* II[65], Agostini *et al*[3], Borchardt *et al*[13], Gazolla *et al*[35] e Santos e Fernandes[99] os quais são comentados a seguir.

3.1 Lee *et al* I

No trabalho de Lee *et al* I[66], é realizado um registro entre duas imagens da mesma paciente, geradas por câmeras térmicas posicionadas em diferentes ângulos e sensíveis a diferentes espectros de ondas infravermelhas, uma de baixa frequência e outra de frequência mediana. A diferença entre essas imagens pode ser observada na Figura 3.1, na qual a imagem à esquerda foi capturada pela câmera de baixa frequência e a da direita pela câmera de frequência média.




Figura 3.1: Exemplo de imagens do trabalho de Lee *et al* I: (a) imagem da câmera de baixa frequência e (b) imagem da câmera de frequência mediana.[66]

O registro desenvolvido neste trabalho é feito através de marcas, colocadas previamente na paciente, e visualizadas como pontos vermelhos nas imagens da Figura 3.1. Essas marcas são automaticamente identificadas pelo método de detecção de cantos de Harris[43] e, depois disso, a associação entre elas, formando pares das mesmas marcas em ambas as imagens, é manualmente estabelecida pelo usuário. Através desses pares, uma função de transformação *Thin Plate Splines*[47] é calculada e utilizada para efetuar as alterações na imagem sensível tornando-a mais alinhada à imagem de referência. Ao final, a função de transformação é refinada pelo método simplex de Nelder-Mead[81], provocando um novo alinhamento.

O resultado da aplicação do registro de Lee *et al* II[66] em uma paciente, pode ser visto nas imagens da Figura 3.2, onde a Figura 3.2a é a da câmera de baixa frequência, em tons de cinza, e a Figura 3.2b é a da câmera de frequência mediana, também em tons de cinza. Nesta execução, a imagem de referência é a da Figura 3.2a e a imagem sensível é a da Figura 3.2b. Por fim, a imagem da Figura 3.2b é transformada, gerando uma nova imagem, exibida na Figura 3.2c, mais semelhante à imagem da Figura 3.2a.




Figura 3.2: Resultado do registro de imagens de Lee *et al* I [66]

3.2 Lee *et al* II

O trabalho de Lee *et al* II[65] é semelhante ao trabalho de Lee *et al* I. Entretanto, as imagens manipuladas por ele, são adquiridas em intervalos de tempo maiores do que uma

semana, o que inviabiliza o uso de marcas nas pacientes. Dessa forma, os pontos característicos, que servirão para o cálculo da função de transformação, são gerados a partir de padrões de calor classificados pelo coeficiente de canto de Harris e de ramificações produzidas através dele. Esse processo pode ser visto nas Figuras 3.3a e 3.3b, sendo que, na primeira, estão as ramificações geradas e, na segunda, estão os pontos detectados. Dentre os pontos detectados, os de vermelho são manualmente selecionados como as características guias, utilizadas no cálculo na função de transformação. Assim como em Lee *et al* I, a função de transformação utilizada é a *Thin Plate Splines* e um aprimoramento dessa função é realizado no final do registro, através do método simplex de Nelder-Mead.




Figura 3.3: Detecção das características no métodos de Lee *et al* II [65]

Para avaliar a eficácia do registro, uma paciente foi recrutada e a ela foram aplicadas várias marcas de teste, conforme a Figura 3.4. Em seguida, uma sequência de 10 imagens dessa paciente foi adquirida no mesmo dia, sendo que, durante a aquisição, foi solicitado que a paciente realizasse pequenos movimentos, simulando os deslocamentos que ocorrem em termogramas adquiridos com grandes intervalos de tempos. Através dessas imagens, o registro é realizado tomando a primeira imagem como referência e as demais com as imagens que serão transformadas[65].

Por meio das marcas colocadas, a distância entre os seus posicionamentos, da imagem de referência para as demais, é calculada antes e após a realização do registro. Através desses cálculos foi constatado que, após o registro, a distância média entre as marcas da imagem de referência e as demais foi de 0,68 pixel e que a distância máxima medida foi de 1,5 pixel. Entretanto, nenhuma informação sobre as distâncias entre as marcas, antes do registro, é disponibilizada no trabalho.

3.3 Agostini *et al*

Agostini *et al* [3] realizaram um registro em cerca de 500 frames de imagens térmicas. Antes da aquisição da sequência de imagens, um conjunto de marcadores esféricos de




Figura 3.4: Marcas utilizadas na avaliação do método de Lee *et al* II [65]

madeira, com 5mm de diâmetro, são colocados na pele da paciente, por meio de um gel biocompatível, de forma semelhante à da Figura 3.5. Através desta Figura, é possível perceber que os marcadores são divididos em dois grupos, marcadores brancos e marcadores pretos. Os marcadores brancos são utilizados como características guias no cálculo da função de transformação e os marcadores pretos são utilizados na medida de avaliação do desempenho do método.




Figura 3.5: Disposição das marcas utilizadas no método de Agostini *et al*[3].

O alinhamento do conjunto de frames é feito tomando como referência a primeira imagem da sequência, sendo as demais transformadas em relação a ela. Como o registro é guiado pelas marcas brancas, o método começa com a identificação automática destas. Após isso, cada marca identificada é manualmente rotulada e utilizada na transformação linear por pares, baseada na triangulação de *Delaunay* [39]. O resultado dessa triangulação pode ser visto na Figura 3.6.




Figura 3.6: Triangulação de Delaunay, de Agostini *et al*[3].

A eficácia do método de Agostini *et al* é mensurada através da medida de similaridade S/N , que mede o nível de um sinal com um determinado grau de ruído [2]. Neste caso, o

sinal analisado ao longo da série é formado pelas temperaturas nas posições das marcas pretas no primeiro frame, junto com a temperatura das mesmas posições nas demais imagens. Espera-se que, com as imagens alinhadas, o valor da temperatura no primeiro frame, permaneça igual nas demais imagens, pois as esferas de madeira têm a característica de manter sua temperatura constante. Caso as imagens não estejam alinhadas, os valores das temperaturas observadas na primeira imagem serão diferentes das demais imagens, dado que, com o desalinhamento, na primeira imagem serão observadas as temperaturas das esferas pretas e nas demais serão observadas temperaturas de partes da pele da paciente. Dessa forma, o ruído calculado pela medida é caracterizado com a alteração, ao longo da série, dos valores da temperatura nas localizações observadas, e, quanto maior for esse ruído, menor será a qualidade do sinal (menor S/N) e mais desalinhadas estão as imagens.

Para realizar os testes, foram selecionadas 20 pacientes e, em cada uma delas, o registro foi executado com 18, 12, 9, 7 e 5 marcas brancas (utilizadas como guias para o cálculo da função de transformação). Em todos os casos houve uma melhora, ou seja, um incremento do S/N , após o registro, sendo que no pior caso esse incremento foi de $2dB$. Também foi possível observar que, quanto maior o número de pontos utilizados como guias do registro (marcas brancas), maior é o S/N após o registro. Entretanto, esse incremento é bastante similar nas execuções com 18, 12 e 9 marcas brancas, enquanto que, nas execuções com 7 e 5 marcas brancas, o S/N mostra claramente um registro de menor eficiência.

3.4 Borchartt *et al*, Gazolla *et al* e Santos e Fernades

Os últimos trabalhos comentados neste capítulo são os de Borchartt *et al*[13], Gazolla *et al*[35] e Santos e Fernades[99]. Em Borchartt *et al* , o alinhamento entre as imagens é realizado através da correção do posicionamento da imagem individualmente, sem a necessidade de outra imagem como referência. Esta correção de posicionamento é feita com base nos pontos formados pelas duas axilas, representados por $a1$ e $a2$ na Figura 3.7, os quais são manualmente identificados. Teoricamente, em um correto posicionamento, estas duas marcações sempre devem estar horizontalmente alinhadas. Com base nisto, a alteração que retifica o posicionamento da imagem é realizada através de uma transformação rígida de rotação, calculada através do ângulo α formado pelo triângulo vermelho da Figura 3.7, no qual $a3$ é o ponto horizontalmente alinhado à axila mais baixa, no caso da imagem, o ponto $a2$.

A eficácia desse método é medida através da ferramenta de segmentação de Motta[79],




Figura 3.7: Triângulo de orientação do método de Borchartt *et al.*[13]

na qual o mau posicionamento das pacientes impossibilita a correta segmentação da imagem. Os testes foram realizados em um conjunto de 18 imagens que antes não eram corretamente segmentadas por erros de posicionamento. Como resultado desses testes teve-se que das 18 imagens corrigidas, apenas 6 continuaram com erro de segmentação, gerando uma melhora em 66 % das imagens, de acordo com os autores.

O trabalho de Gazolla *et al*[35] realiza um registro entre duas imagens térmicas de uma mesma paciente. Neste método o registro pode ser dividido em duas etapas, uma correção, semelhante à realizada em Borchartt *et al*, e uma transformação de translação entre as imagens. Estas etapas são calculadas através de 4 pontos, manualmente selecionados em ambas as imagens, sendo eles o lado direito e esquerdo do pescoço e os dois mamilos, como indica os pontos em verde na Figura 3.8a. A correção de posicionamento, realizadas nas duas imagens, é feita por uma rotação, calculada pelo ângulo do triângulo formado pelos pontos do pescoço, conforme a Figura 3.8a. A translação, aplicada na imagem sensível, é medida com base na diferença de posicionamento entre os mamilos das duas imagens, como mostrada Figura 3.8b.




Figura 3.8: Método de Gazolla: (a) correção do posicionamento e (b) transformação [35].

Para avaliar este método, foi utilizada a média da diferença absoluta entre os valores dos pixels de mesma posição nas duas imagens. Quanto menor for o valor dessa medida, mais alinhada as imagens estarão. Os resultados desses cálculos são obtidos antes e após o

registro de 4 pares de imagens de diferentes pacientes e, em todas elas, a média calculada após o registro é menor do que a antes dele.

No trabalho de Santos e Fernades[99] é apresentada uma técnica de verificação da postura das pacientes no processo de captura de imagens térmicas a qual pode auxiliar métodos de extração automática de ROI e métodos de diagnóstico assistido por computador (CAD) na realização de suas tarefas. A base dessa técnica consiste na extração do eixo medial, apresentado na Figura 3.9a. Através desse eixo, os pontos descados de vermelho na Figura 3.9a são identificados e analisado conforme a Figura 3.9b, verificando a localização do segmento BDE, dentre de uma região central pré esbailecida, e a igualdade entre os ângulos do segmento formados pelo segmentos ADE e CDE.




Figura 3.9: Método de Santos e Fernades: (a) eixo medial, junto com os pontos analisados, e (b) segmentos verificandos pelo método[99].

3.5 Considerações finais dos trabalhos relacionados

Em suma, esse capítulo apresentou alguns dos principais trabalhos sobre registro de imagens térmicas das mamas. Durante essa revisão bibliográfica, percebeu-se que, em boa parte dos trabalhos de imagens térmicas, pouca ou nenhuma ênfase é empregada aos métodos de registro utilizados, ficando este em segundo plano. A consequência disso é que registros incorretos podem levar a análises erradas e, por isso uma atenção maior deve ser dedicada aos métodos de registro nos trabalhos de imagens térmicas, o que incentiva o desenvolvimento de trabalhos específicos para registro de imagens térmicas das mamas.

Nota-se também que, em todos os métodos de registros apresentados, o cálculo da função de transformação é guiado por marcas presentes nas imagens, sendo estas colocadas no momento da captura ou adquiridas de forma semiautomática, com a ajuda de métodos de reconhecimento de características, como o coeficiente de canto de Harris. Isso ocorre principalmente porque as características estáveis em todas as imagens, as quais

poderiam servir como guias para o registro, são de difícil identificação nos termogramas, devido à natureza funcional dessas imagens. O resultado dessa interação, antes ou após a capturada, para a criação desses pontos guias, são métodos mais lentos e suscetíveis a erros humanos [41].

Outra observação sobre os trabalhos de registro de imagens térmicas comentados foi que são poucos os métodos de avaliação da eficácia do registro desenvolvido. Na maioria das vezes, essa avaliação é feita de forma simples, apenas pelos valores presentes nos pixels das imagens ou pelo posicionamento de características inseridas, sendo estes dados, apresentados de forma subjetiva.

Ao contrário dos trabalhos de imagens térmicas, em outros tipos de imagens médicas das mamas, como na mamografia, é possível encontrar trabalhos completos sobre os métodos de registro de imagens utilizados. Alguns desses trabalhos podem ser vistos nos *surveys* de Guo *et al*[41], Wyawahare *et al*[120] e Sotiras *et al*[110]. Dessa forma, percebe-se que, para as imagens térmicas das mamas, ainda é necessário mais trabalhos sobre métodos de registro de imagens, o que pode servir de incentivo para o desenvolvimento como o realizado neste trabalho.

Diferente dos trabalhos comentados, o método desenvolvido neste estudo não é guiado por marcas colocadas na paciente antes da aquisição dos termogramas ou por técnicas semiautomáticas. As características que orientam os cálculos da função de transformação são adquiridas de forma automática por técnicas de processamento de imagens. Além disso, para a validação da eficácia do método, várias técnicas de análise de alinhamento entre imagens são utilizadas, validando o método por diferentes grupos de informações. A metodologia completa desse registro junto com os estudos necessários para o seu desenvolvimento são apresentados nos capítulos seguintes.

Capítulo 4

Método desenvolvido

O programa de registro desenvolvido nesse trabalho tem como objetivo diminuir as diferenças provocadas pelos movimentos da paciente durante a aquisição dos termogramas no protocolo dinâmico, facilitando o uso desses por sistemas de auxílio ao diagnóstico. Ele deve corrigir os 20 termogramas de uma mesma paciente, criando uma relação entre eles que possibilite as suas análises. Para isso, inicialmente é desenvolvido um registro entre duas imagens, no qual é produzido um termograma mais semelhante ao escolhido como referência. Em seguida, a execução desse método nos 20 termogramas de uma paciente é feita de forma sistemática, criando um novo conjunto de termogramas, mais semelhantes.

Seguindo as etapas explicadas no capítulo 2, o método de registro foi projetado de acordo com o esquema da Figura 4.1. Inicialmente, as imagens a serem registradas são classificadas em imagem de referência e imagem sensível. Após isso, ambas as imagens são processadas de forma que o contorno do corpo da paciente seja reconhecido. Através do contorno, algumas características das imagens são identificadas. Em seguida, essas características são utilizadas nos cálculos das duas transformações realizadas. Com essas transformações, duas novas imagens são criadas, uma por cada tipo de transformação. Por fim, as imagens geradas são comparadas com a imagem de referência e a imagem que apresentou o melhor resultado é escolhida como saída do método de registro.

As particularidades apresentadas por esse método são: um estudo da movimentação da paciente e suas alterações entre os termogramas, o qual é aplicado para a escolha da função de transformação; a utilização da transformação de Möbius como uma das funções de mapeamento; e o desenvolvimento de um novo avaliador, empregado na seleção da imagem final do registro.

A análise da movimentação da paciente e a criação do novo avaliador são discutidos

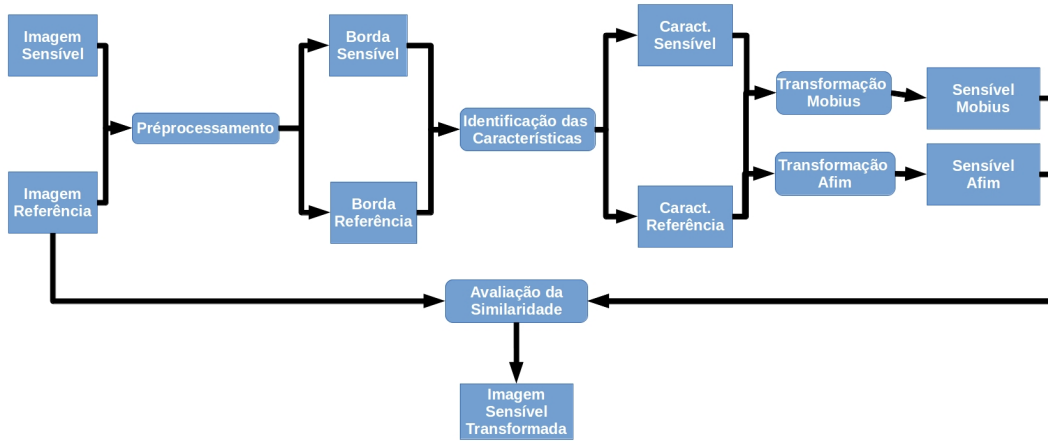


Figura 4.1: Esquema do método de registro desenvolvido.

nos dois capítulos seguintes. Neste capítulo estão presentes nas seções seguintes: as etapas realizadas durante o pré-processamento das imagens; a definição das características das imagens utilizadas pelo registro e os seus métodos de identificação; as técnicas utilizadas no cálculo das funções de transformação; a interpolação empregada na transformação da imagem; e a sistemática de execução do registro no conjunto de 20 imagens de uma paciente.

Durante todo o trabalho, os termogramas serão tratados como um conjunto de relações entre uma posição em Ω e um valor E , $I : \Omega \rightarrow E$. Os valores de E são tons de cinza que irão variar entre 0 e 255. O conjunto de posições Ω será um conjunto métrico, discreto e fechado, no qual $\Omega = \Omega^o \cup \Omega^b$, sendo Ω^o , Ω^b e Ω^c , seu interior, borda e complemento. Assim como em Silva *et al*[108], esse conjunto será subconjunto de \mathbb{N}^2 , com seus valores $\omega = (x, y)$ variando de 0 a 639 em x e de 0 a 479 em y . A métrica que calcula as distâncias entre os elementos de Ω é a distância Euclidiana, e seus valores serão determinados em pixels. Entretanto, para as transformações de projeções, que serão realizadas através da transformação de Möbius, o espaço métrico será visto como um subconjunto de \mathbb{C} , com $\omega = x + yi$ e com x e y possuindo as mesmas variações da representação em \mathbb{N}^2 .

4.1 Pré-processamento do método desenvolvido.

O objetivo principal desta etapa é a detecção do contorno do corpo da paciente para que, posteriormente, características sejam extraídas dele. Dessa forma, é importante que o contorno extraído seja fechado e suave, ou seja, sem buracos e sem *aliasing*[114], os quais podem atrapalhar os subsequentes métodos de identificação dessas características.

Em alguns trabalhos, os contornos de estruturas presentes em imagens médicas têm sido identificados através de técnicas de detecção de bordas, como o operador de Canny[18], a função Gaussiana junto com a Laplaciana[40] e algoritmos de varredura. Em Pan *et al*[87], o contorno do cérebro, em imagens de tomografias computadorizadas, foi reconhecido utilizando o operador de Canny. Schneider *et al*[101] identificam o volume do coração, em imagens de ultrassom 3D, suavizando estas imagens por uma função Gaussiana e, em seguida, realizando a Laplaciana[40]. Este método de identificação é denominado de *Laplacian of Gaussian* (LoG). Mendez *et al*[75] detectaram as bordas das mamas em mamogramas através de um algoritmo de varredura aplicado às imagens limiarizadas. Por fim, Oliveira[84] e Marques[71] também distinguiram o contorno do corpo das pacientes em imagens térmicas com técnicas de limiarização e algoritmos de varredura.

Da mesma maneira que Mendez *et al*, Oliveira e Marques, a detecção do contorno do corpo da paciente neste trabalho é realizada basicamente pela limiarização e por um algoritmo de varredura. As etapas desse processo podem ser vistas na Figura 4.2. De início, a limiarização da imagem ocorre separando o corpo da paciente do fundo da imagem. Depois, na imagem limiarizada, é realizada uma varredura para a detecção da borda. Por fim, a borda identificada é melhorada por operações morfológicas de fechamento e erosão, as quais geram uma borda fechada e mais suave.




Figura 4.2: Etapas realizadas no pré-processamento das imagens.

4.1.1 Limiarização

Na limiarização, os pixels da imagem são separados em dois grupos, os pertencentes ao corpo da paciente e os pertencentes ao fundo da imagem. Isso é possível devido às baixas variações de tonalidades dos pixels pertencentes ao corpo da paciente, como também os pertencentes ao fundo da imagem, dividindo as intensidades da imagem em duas faixas de tonalidades bem definidas, uma que representa o fundo e a outra o corpo da paciente. Essa divisão pode ser observada no histograma da imagem de uma paciente aleatória, exibido na Figura 4.3. Nele, pode-se ver o aparecimento de dois conjuntos distintos, que correspondem às faixas de intensidades do corpo da paciente e do fundo da imagem.

Assim, sendo Ω^0 e Ω^1 os conjuntos dos pixels formados pelo fundo da imagem e pelo corpo da paciente, e sendo L o valor limiar, que divide os dois conjuntos de intensidades, tem-se que Ω^0 e Ω^1 podem ser definidos como em (4.1) e (4.2), um conjunto de pixels de intensidades entre 0(zero) e L e outro de intensidades entre $L + 1$ e 255.




Figura 4.3: Histograma da imagem de uma paciente.

$$\Omega^0 = \{\omega_i \mid I(\omega_i) \in [0 \cdots L]\} \quad (4.1)$$

$$\Omega^1 = \{\omega_i \mid I(\omega_i) \in [L + 1 \cdots 255]\} \quad (4.2)$$

Através das representações acima, percebe-se que, para a correta limiarização da imagem, é necessário a escolha de um limiar L que separe precisamente os dois conjuntos. Essa escolha é feita através do método de Otsu [86], que é caracterizado por realizar uma busca nos valores de intensidades do histograma, visando encontrar um L que maximize a variância entre as duas classes de intensidades, $E_0 = [0..L]$ e $E_1 = [L + 1..255]$. O método de Otsu pode ser definido como em (4.3), um valor de L que maximiza $\sigma^2(L)$, função que mede a variância de E_0 e E_1 .

$$\mathbf{arg\,max}_{L \in [0 \cdots 255]} \sigma^2(L) \quad (4.3)$$

O cálculo da variância $\sigma^2(L)$ é feito de acordo como na fórmula (4.4). Nela, $P(E_0)$ e $P(E_1)$ são as probabilidades acumuladas dos elementos dos conjuntos E_0 e E_1 , e μ_0 e μ_1 são os níveis médios de intensidades destes conjuntos, sendo μ a intensidade média de toda a imagem I . Os valores de $P(E_0)$, $P(E_1)$, μ_0 , μ_1 e μ são obtidos através das expressões (4.5), (4.6), (4.7), (4.8) e (4.9), nas quais e_i é uma intensidade da imagem e $p(e_i)$ é a sua probabilidade de ocorrência, definida em (6.17).

$$\sigma^2(L) = P(E_0).(\mu_0 - \mu)^2 + P(E_1).(\mu_1 - \mu)^2 \quad (4.4)$$

$$p(E_0) = \sum_{i=0}^L p(e_i) \quad (4.5)$$

$$p(E_1) = \sum_{i=L+1}^{255} p(e_i) \quad (4.6)$$

$$\mu_0 = \sum_{i=0}^L e_i.p(e_i) \quad (4.7)$$

$$\mu_1 = \sum_{i=L+1}^{255} e_i.p(e_i) \quad (4.8)$$

$$\mu = \sum_{i=0}^{255} e_i.p(e_i) \quad (4.9)$$

Ao final, para destacar as duas classes de pixels nos termogramas, os valores destes são redefinidos para somente duas intensidades, a branca e a preta. A primeira representando o corpo da paciente e a última o fundo da imagem. As imagens geradas por essa limiarização são semelhantes à Figura 4.4.




Figura 4.4: Imagem produzida pela limiarização de Otsu.

Um detalhe interessante nesta limiarização é que, o quadrado colocado no corpo da paciente é erradamente classificado como fundo da imagem. Isso ocorre, devido a sua semelhança de tonalidade com o fundo da imagem. Por causa dessa particularidade, a identificação do contorno da paciente não pode ser feita de forma direta pelos métodos que trabalham com o gradiente da imagem, como o método *Canny* e LoG, sendo necessário a utilização de um algoritmo de varredura.

4.1.2 Algoritmo de varredura

Sendo I^1 a imagem limiarizada e Ω^1 o seu conjunto de pixels de tonalidades branca, formado por $\Omega^1 = \overset{o}{\Omega}^1 \cup \overset{b}{\Omega}^1$, no qual $\overset{o}{\Omega}^1$, $\overset{i}{\Omega}^1$ e $\overset{b}{\Omega}^1$ são seus complementos, interior e borda, o objetivo do algoritmo de varredura é encontrar os pontos de $\overset{b}{\Omega}^1$ responsáveis pelo contorno da paciente, ou seja, $\overset{b}{\Omega}^1$ sem os pontos de delimitação do quadro interno. Isso pode ser feito percorrendo as linhas e colunas de Ω^1 , identificando os seus limites superiores e inferiores, como é exibido no algoritmo da Figura 4.5, na qual Ω^S será o conjunto responsável pelos pixels do contorno do corpo da paciente.

$\Omega^S \leftarrow \emptyset$

PARA TODO $n \in \{y \mid (x, y) \in \Omega^1\}$ **FAÇA:**

$\text{minimo} \leftarrow \min(\{x \mid (x, n) \in \Omega^1\})$

$\text{maximo} \leftarrow \max(\{x \mid (x, n) \in \Omega^1\})$

$\Omega^S \leftarrow \Omega^S \cup \{(\text{minimo}, n), (\text{maximo}, n)\}$

PARA TODO $n \in \{x \mid (x, y) \in \Omega^1\}$ **FAÇA:**

$\text{minimo} \leftarrow \min(\{y \mid (n, y) \in \Omega^1\})$

$\text{maximo} \leftarrow \max(\{y \mid (n, y) \in \Omega^1\})$

$\Omega^S \leftarrow \Omega^S \cup \{(n, \text{minimo}), (n, \text{maximo})\}$

PARA TODO $n \in \{y \mid (x, y) \in \Omega^1\}$ **FAÇA:**

$\text{minimo} \leftarrow \min(\{x \mid (x, n) \in \Omega^1\})$

$\text{maximo} \leftarrow \max(\{x \mid (x, n) \in \Omega^1\})$

$\Omega^S \leftarrow \Omega^S \cup \{(\text{minimo}, n), (\text{maximo}, n)\}$

PARA TODO $n \in \{x \mid (x, y) \in \Omega^1\}$ **FAÇA:**

$\text{minimo} \leftarrow \min(\{y \mid (n, y) \in \Omega^1\})$

$\text{maximo} \leftarrow \max(\{y \mid (n, y) \in \Omega^1\})$

$\Omega^S \leftarrow \Omega^S \cup \{(n, \text{minimo}), (n, \text{maximo})\}$

Figura 4.5: Algoritmo de varredura do conjunto Ω^1 .

No final da sua execução, o algoritmo descrito gera o conjunto Ω^S apenas com os pontos de valores máximos e mínimos de cada linha e coluna de Ω^1 . O resultado desse processo pode ser visto na Figura 4.6, uma imagem com apenas os pontos de Ω^S destacados de branco. Com essa imagem, é possível observar que Ω^S é formado pela união de quatro conjuntos conexos, Ω^{S_0} , Ω^{S_1} , Ω^{S_2} e Ω^{S_3} . Os dois primeiros são os limites do lado esquerdo e direito da paciente e, os outros dois, os limites dos ombros esquerdo e direito.

Devido a particularidades do algoritmo de varredura, em alguns casos, os conjuntos Ω^{S_i} identificados não são inicialmente conexos. Isto é, a borda destacada por Ω^S não é completamente conectada, existem buracos que podem prejudicar os métodos de identificação de características da fase seguinte. Para resolver esse problema, na imagem da




Figura 4.6: Imagem produzida pela algoritmo de varredura da Figura 4.5.

borda, definida como I^S , são aplicadas as operações de morfologia matemática[103] de fechamento e abertura discutidas a seguir.

4.1.3 Fechamento da borda

As técnicas de abertura e fechamento efetuadas na imagem I^S , para tornar os conjuntos Ω^{S_i} conexos, são derivadas de duas operações morfológicas básicas, erosão e dilatação[103]. Nessas operações, uma imagem binarizada é percorrida por um elemento estruturante Δ , responsável por provocar dilatações ou contrações em um determinado conjunto de pixels da imagem. Esse elemento estruturante possui tamanhos e formatos variados, sendo um de seus componentes escolhido como a origem O do elemento, a qual será utilizada no cálculo das operações em questão.

Em imagens orientadas pelo plano Euclidiano em \mathbb{N}^2 , um exemplo de elemento estruturante pode ser o quadrado de tamanho 3x3, definido em (4.10) e apresentado na Figura 4.7, no qual o ponto $(0,0)$ é sua origem.

$$\Delta = \{(-1, -1), (-1, 0), (-1, 1), (0, -1), (0, 0), (0, 1), (1, -1), (1, 0), (1, 1)\} \quad (4.10)$$

(-1,-1)	(0,-1)	(1,-1)
(-1,0)	(0,0)	(1,0)
(-1,1)	(0,1)	(1,1)

Figura 4.7: Elemento estruturante Δ

Para que as operações sejam realizadas, o elemento estruturante Δ percorre todo o conjunto Ω_S , posicionando a sua origem O em cada um dos pixels de Ω^S . O deslocamento

de Δ no conjunto Ω_S pode ser expresso através da fórmula (4.11), em que Δ_ω é o elemento estruturante Δ deslocado para o pixel ω , ou seja, o elemento estruturante Δ com sua origem O sobreposta a ω . Assim, sendo O_ω a origem do elemento Δ_ω , tem-se que $O_\omega = \omega$.

$$\Delta_\omega = \{(\omega + \omega_\Delta) \mid \omega_\Delta \in \Delta\} \quad (4.11)$$

Através do deslocamento Δ_ω e a sua origem O_ω , a operação de erosão, sobre um conjunto Ω^S de uma imagem I^S , pode ser calculada como em (4.12). Nesta operação, a erosão $\Omega^S \ominus \Delta$ é formada pelas localizações de Δ_ω , quando este é subconjunto de Ω^S . Ou seja, durante a varredura de Δ_ω em Ω^S , quando todos os pixels de Δ_ω estiverem em Ω^S , o pixel da origem O_ω é adicionado ao conjunto de erosão. Um exemplo de erosão pode ser visto na Figura 4.8a, onde o quadrado azul é conjunto Ω^S e o verde é a sua erosão pelo elemento estruturante quadrado de preto com origem no centro.

$$\Omega^S \ominus \Delta = \{O_\omega \mid \Delta_\omega \subseteq \Omega^S\} \quad (4.12)$$




Figura 4.8: Exemplo das operações morfológicas: (a) erosão e (b) dilatação.

A dilatação[109] pode ser vista como uma operação complementar da erosão. Ela é definida como a erosão do complemento de Ω^S . Assim, se $\hat{\Omega}^S$ denota o complemento de Ω^S , a dilatação de Ω^S por Δ é definida como em (4.13). Um exemplo de dilatação pode ser visto na Figura 4.8b, onde o quadrado em azul representa o conjunto Ω^S , o verde, o conjunto Ω^S após a dilatação. O elemento estruturante Δ desse exemplo é o quadrado preto de origem no centro.

$$\Omega^S \oplus \Delta = (\hat{\Omega}^S \ominus \Delta)^c \quad (4.13)$$

O fechamento[109] do conjunto Ω^S por um elemento estruturante Δ é obtido pela equação (4.14): uma dilatação de Ω^S por Δ seguida de uma erosão. Essa operação tem a

característica de remover os pequenos buracos existentes entre os elementos do conjunto operado, tornando-o conexo. Ideal para a remoção dos buracos das bordas de Ω^S [109].

$$\Omega^S \bullet \Delta = (\Omega^S \oplus \Delta) \ominus \Delta \quad (4.14)$$

A abertura[103], expressa em (4.15), é realizada por uma erosão seguida de uma dilatação. Esse tipo de operação é útil para o afinamento de linhas espessas e para a remoção de pequenos elementos desconexos ao conjunto. Uma explicação mais detalhada sobre as operações morfológicas pode ser vista em Serra[103] e Soille[109].

$$\Omega^S \circ \Delta = (\Omega^S \ominus \Delta) \oplus \Delta \quad (4.15)$$

Diante do exposto acima, o problema das descontinuidades dos contornos do corpo da paciente pode ser resolvido aplicando a operação de fechamento no conjunto Ω^S . O resultado dessa operação, efetuada pelo elemento estruturante da Figura 4.7, pode ser visto na Figura 4.9a, uma imagem com bordas fechadas, mas de larga espessura.




Figura 4.9: Imagens geradas pelas operações de: (a) fechamento e (b) abertura.

Entretanto, em alguns casos, o aumento da espessura das bordas, provada pelo fechamento, acarreta no preenchimento total das áreas entre o pescoço e os braços, dificultando a identificação dessas regiões. Isso, torna mais difícil a distinção de pontos importantes nessas áreas, os quais podem ser utilizados como características nas etapas seguintes. Por conta dessas complicações, após o fechamento, a borda espessa produzida é reduzida por uma da operação de abertura, realizada com o mesmo elemento estruturante da operação de fechamento. Ao final, as imagens geradas possuem uma borda mais fina como a da Figura 4.9b.

4.1.4 Considerações finais sobre o pré-processamento

É importante comentar que, antes dos métodos realizados nesse processo, outros foram testados. São eles: o operador de Canny e o LoG. O operador de Canny, aplicado diretamente na imagem suavizada, produziu imagens semelhantes à da Figura 4.10a, na qual a borda lateral aparece com várias falhas e com linhas nas pregas inframamárias, assim como, no quadrado de orientação. O LoG, aplicado na mesma imagem, gerou uma borda lateral bem discreta, junto com a delimitação do quadrado de orientação, como na Figura 4.10b.




Figura 4.10: Testes realizados: (a) operador de Canny aplicado na imagem suavizada, (b) LoG aplicado na imagem suavizada e (c) operador de Canny e LoG aplicados na imagem limiarizada.

Os mesmos métodos também foram aplicados nas imagens limiarizadas, como as da Figura 4.4. Nos dois casos, os resultados foram melhores que os aplicados nas imagens sem limiarização, pois apenas a borda lateral e o quadrado central foram destacados, gerando imagens semelhantes à da Figura 4.10c. Entretanto, com aparecimento do quadrado central, para a separação da borda do corpo da paciente nesta imagem, torna-se necessária também a utilização de algoritmos de varredura, como o exibido anteriormente.

4.2 Identificação das características no método desenvolvido

Com a segmentação da borda da paciente, é possível agora extrair características que servirão como guias para o alinhamento entre as imagens. Para que esse alinhamento seja mais preciso, as características utilizadas devem ser estáveis, de fácil identificação e esparsas por toda a imagem [122].

Em alguns trabalhos sobre registro de imagens médicas com os de Liu *et al*[69] e Bay *et al*[10], as características das imagens foram reconhecidas por algoritmos de detecção

de pontos chaves como o *Scale-Invariant Feature Transform* (SIFT)[69], o *Speeded Up Robust Features* (SURF)[10] e o *Affine Scale-Invariant Feature Transform* (ASIFT)[78]. Em outros, como o de Oliveira[84], as abordagens utilizadas foram o coeficiente de Harris [43] e método de Shi-Tomasi[105].

Neste registro, as características utilizadas são pontos bem específicos, que são identificados individualmente por algoritmos criados durante esta etapa. Devido a isso, a fase de identificação das características será dividida em duas etapas, uma para a definição dos pontos que serão utilizados como características e outra para elaboração dos algoritmos que irão identificar os pontos definidos.

4.2.1 Definição das características utilizadas

Os pontos da borda usados como características devem ser de fácil identificação, estar presentes em todas as imagens de uma série e possuir propriedades constantes, que possam ser utilizadas na sua identificação.

De início, os pontos escolhidos como características foram os definidos na Figura 4.11a, realçados na borda da paciente na Figura 4.11b. De acordo com as imagens, esses pontos podem ser organizados em quatro classes A, B, C e D, as quais representam, respectivamente, as junções do pescoço com o ombro, as axilas, os pontos mais extremos das mamas no contorno do corpo e as uniões das pregas inframamárias com o contorno do corpo.




Figura 4.11: Pontos iniciais escolhidos para serem utilizados como características: (a) termograma e (b) borda da paciente.

Ao analisar a estabilidade dos pontos das Figuras 4.11 ao longo das imagens do DMR, verificou-se que, em algumas pacientes, nem todos os pontos definidos estão presentes. Isso ocorre principalmente com as pacientes de mamas pequenas ou mastectomizadas, as quais possuem os contornos do corpo semelhantes aos da Figura 4.12a e 4.12b, sendo

a primeira de uma paciente com as mamas pequenas e a segunda de uma paciente sem a mama esquerda. Através dessas imagens, nota-se que nestes casos, dificilmente estão presentes todos os pontos da classe C e D.




Figura 4.12: Contorno de uma paciente com: (a) mamas pequenas e (b) mastectomizada.

Outra observação sobre os pontos das Figuras 4.11 é que, ao contrário das classes C e D, os pontos pertencentes às classes A e B mostraram-se estáveis e presentes na maioria das imagens, pois são independentes do volume ou presença das mamas, estando presentes tanto nas pacientes mastectomizadas como nas de mamas pequenas. Por isso, eles são escolhidos como guias do método de registro.

Contudo, como comentado por Lee *et al*[65], no cálculo da função de transformação, uma quantidade maior de pontos pode produzir melhores resultados. Assim, com o intuito de gerar um número maior de características, novos pontos foram derivados a partir dos da classe B. Estes novos pontos são criados pela divisão da linha do contorno formada entre os pontos B e os finais inferiores das bordas. Ao total, 18 novos pontos são criados, 9 do lado direito e 9 do lado esquerdo, gerando uma nova classe, como exhibe a Figura 4.13.




Figura 4.13: Pontos escolhidos como características do registro.

Por fim, os pontos escolhidos como guia do método de registro foram os mostrados na Figura 4.13, divididos em classes A, B e C, sendo a classe A formada pelos pontos das

junções do pescoço com os ombros, a classe B formada pelos pontos das axilas, e a classe C composta por pontos do contorno entre as axilas e os finais inferiores da imagem.

4.2.2 Identificação das características da classe A

A identificação dos pontos da classe A, junções do pescoço com os ombros da paciente, é iniciada como a segmentação das regiões delimitada pelo contorno do pescoço e dos braços da paciente, áreas em azul na Figura 4.14a. Em seguida, com a definição destas áreas, são verificados quais são os pontos mais inferiores de cada uma das regiões, representados pelos pontos em vermelho na Figura 4.14a. Os pontos encontrados nesta busca são ditos como os pontos pertencentes à classe A.




Figura 4.14: Detecção dos pontos da classe A.

A identificação das regiões delimitadas pelo contorno do pescoço e dos braços da paciente é realizada pelo método *Flood Fill* [109], que é capaz de destacar toda uma região fechada formada somente por uma tonalidade. Para que esse método funcione, é preciso inicialmente descobrir um ponto pertencente à região desejada, o qual é denominado de semente. A partir destes pontos, os demais, pertencentes à região, são destacados.

A detecção das sementes das regiões é feita por uma varredura na primeira linha da imagem da borda. Durante essa varredura são identificados seis pontos de alternância de intensidade, cada um referente a uma parte da borda, como exibe os pontos em vermelho da Figura 4.14b. Com isso, são definidos como sementes os pontos médios dos segmentos formados entre 2 e 3 e entre 4 e 5.

Os pontos mais baixos nas duas regiões identificadas podem ser detectados como em (4.16), na qual $\Omega_{A.1}$ e $\Omega_{A.2}$, subconjuntos de Ω , representam as áreas destacadas pelo *Flood Fill*, as quais possuem elementos definidos como (x, y) . Dessa forma, o ponto que tiver o maior x em cada uma das regiões será o ponto em questão.

$$A_i = \{(x, y) \in \Omega_{A_i} \mid x = \max_x \Omega_{A_i}\}, \quad i = [1, 2] \quad (4.16)$$

4.2.3 Identificação das características da classe B

Os pontos da classe B, axilas direta e esquerda, são pontos de mudança de curvatura das bordas laterais. A sua identificação pode ser feita analisando os conjuntos das bordas laterais Ω^{S_0} e Ω^{S_1} como uma curva em função de y , o que é mostrado na Figura 4.15a. Assim, as axilas podem ser caracterizadas por uma grande alteração na direção das curvas Ω^{S_0} e Ω^{S_1} . Esta observação pode ser melhor verificada na Figura 4.15b, na qual as setas são formadas por retas tangentes aos pontos da curva, representando as suas direções. Através dessas retas, pode-se perceber que na localização das axilas ocorre uma leve mudança de direção das setas.




Figura 4.15: Identificação das axilas: (a) retas utilizadas e (b) mudança de direção das retas.

Diante do exposto acima, as axilas podem ser identificadas analisando as derivadas das retas Ω^{S_0} e Ω^{S_1} . Assim, tendo que $\omega_i = (x_i, y_i)$ são os pontos da reta, ordenados de acordo com a sua localização, o ponto que representa uma axila é identificado pelo primeiro ω_i que satisfizer a condição (4.17), na qual $d\Omega^S/dy$ é definido como em (4.18).

$$\frac{d\Omega}{dy}(\omega_{i-1}) \neq \frac{d\Omega}{dy}(\omega_i) \neq \frac{d\Omega}{dy}(\omega_{i+1}) \quad (4.17)$$

$$\frac{d\Omega^S}{dy}(\omega_i) = \frac{x_{i+1} - x_i}{y_{i+1} - y_i} \quad (4.18)$$

4.2.4 Identificação das características da classe C

Os demais pontos, pertencente à classe C , são gerados a partir dos pontos das axilas. No total, mais 9 pontos são gerados em cada borda lateral. A sua criação é feita pela divisão do segmento da borda em partes equidistantes que vão da axila até o final inferior da borda. Por exemplo, na borda Ω^{S_0} , se o ponto da axila for ω_a e o último ponto da borda for ω_b , os demais pontos serão identificados pelo cálculo da proporção que divide os pontos restantes em nove partes, $v = (b - a)/9$. Após isso, cada ponto do conjunto C é identificado por um múltiplo de v , gerando o conjunto $C = [\omega_{a+v}, \omega_{a+2v}, \omega_{a+3v}, \dots, \omega_{a+9v}]$, conforme a Figura 4.16.




Figura 4.16: Identificação dos pontos da classe C.

4.2.5 Considerações finais sobre a identificação das características

Os outros métodos de detecção de características como os SIFT, SURF e ASIFT, utilizados nos trabalhos de Liu *et al*[69], Bay *et al*[10] e Morel e Yu[78], também foram testados. De uma forma geral, em todos esses métodos, foi observado que uma parte das características identificadas por essas técnicas mostraram-se inconstantes ao longo da série, pois estas, ora estavam presentes, e ora estavam ausentes nas imagens da paciente. Entretanto, algumas das características identificadas permaneceram estáveis, mas devido à falta de parâmetros de comparação, a associação automática entre elas tornou-se uma tarefa complicada e sem êxito.

Um exemplo do exposto acima é a Figura 4.17, que destaca as características identificadas pelo método SIFT utilizado em três imagens térmicas diferentes de uma mesma paciente. Nestas imagens, as características estão representadas através de círculos, classificadas automaticamente pelo método de acordo com a sua cor. Através da Figura 4.17a, percebe-se que dois pontos foram destacados nos sentido nordeste do mamilo esquerdo,

os quais são enfatizados pelo quadro ampliado para a melhor observação. Entretanto, nas demais imagens da paciente, esses pontos não estão presentes, o que pode ser observado pelos quadrados das Figuras 4.17b e 4.17c, colocados na mesma área onde os pontos estavam presentes na Figura 4.17a. Além disso, através do mamilo direito na Figura 4.17a, nota-se que este inicialmente foi classificado pelo círculo verde e que, nas demais Figuras, apesar da característica estar presente, ela é classificada pelas cores, marrom e roxo.

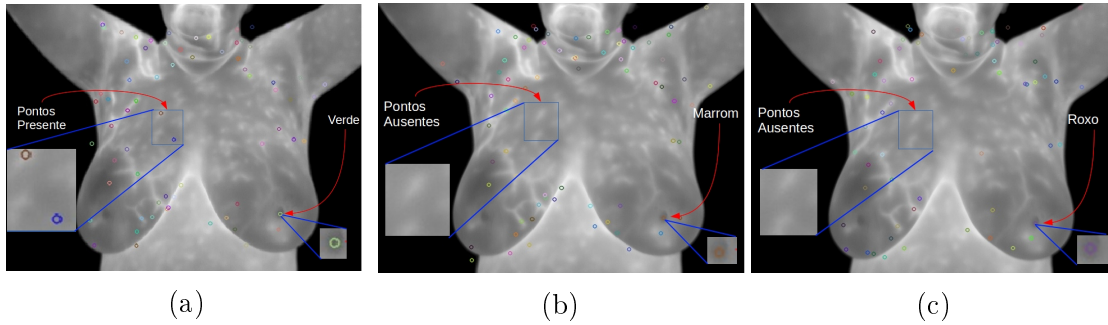


Figura 4.17: Teste do método de identificação de características SIFT.

Outras abordagens testadas nesta etapa foram os coeficientes de cantos de Harris e o método de Shi-Tomasi. Visando a otimização dos seus resultados, esses métodos foram executados em imagens da borda da paciente (como a da Figura 4.9b). Mas, mesmo nestas imagens, os métodos também apresentaram pontos inconstantes, o que pode ser visto na Figura 4.18, onde se tem o resultado da utilização do método de Shi-Tomasi em três imagens da mesma paciente. Do mesmo modo do teste anterior, as características identificadas pelo método são assinaladas por círculos, classificados pela sua cor. Nestas imagens é possível ver que a axila direita da paciente é classificada por um círculo verde na Figura 4.18b e nas demais figuras esse ponto não é mais visto como característica.

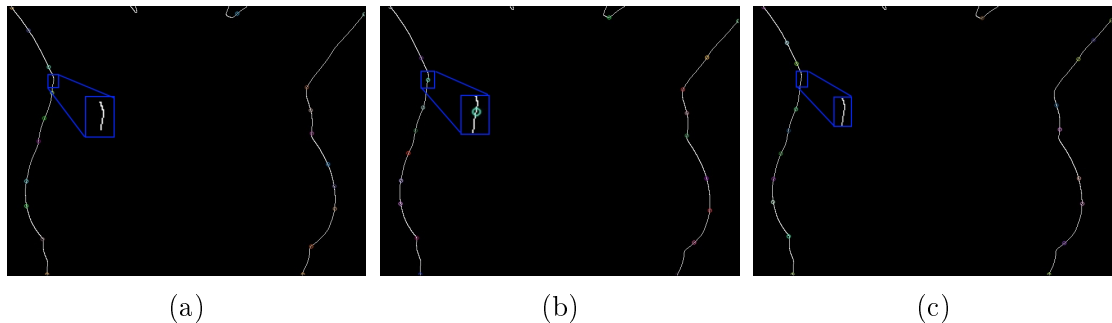


Figura 4.18: Pontos identificados pelo método de Shi-Tomasi utilizado na borda da paciente.

4.3 Relacionamento entre as características

As características escolhidas e identificadas nas etapas anteriores são partes bem definidas da imagem. O relacionamento entre elas pode ser feito de forma direta pela sua classe e número, conforme a Figura 4.19. Com isso, a característica 1 da classe A da imagem de referência é associada à característica 1 da classe A da imagem sensível e assim sucessivamente. Dessa forma, sendo D_S e D_R os conjuntos de características identificadas nas imagens I_S e I_R . Esses conjuntos são formados pelos elementos ω_i , onde i é o índice que classifica as características de cada conjunto, variando de $i = [A.1, \dots, C.2.9]$, como exibido na Figura 4.20. A relação entre esses conjuntos é feita como em (4.19), criando pares entre características de mesmo índice nas duas imagens, os quais serão utilizados no cálculo das funções de mapeamento, como será discutido a seguir.

$$M = \{(\omega_j, \omega_k) \mid j = k, \omega_j \in D_S, \omega_k \in D_R\} \quad (4.19)$$




Figura 4.19: Associação entre as características.




Figura 4.20: Criação do conjunto de características de uma imagem.

4.4 Cálculo das funções de transformação

O objetivo do cálculo da função de transformação é identificar os valores dos coeficientes do modelo de transformações de forma que os pares associados na etapa anterior passem

a ficar mais próximos, após a transformação da imagem sensível. Assim, sendo (ω_s, ω_r) os pares de pontos correspondentes e Φ_β a transformação de um modelo W , através do cálculo da função de transformação, encontram-se os valores dos coeficientes β de Φ_β , de forma que $\Phi_\beta(\omega_s) \sim \omega_r$.

Do mesmo modo que em Caner *et al*[17] e Ashburner *et al*[7], nesse trabalho, o cálculo dos coeficientes da função Φ_β é feito através do método dos mínimos quadrados e do algoritmo de *Gauss-Newton*, sendo o primeiro utilizado no cálculo da transformação afim e o segundo utilizado no cálculo da transformação de Möbius.

4.4.1 Mínimos quadrados

O objetivo do método dos mínimos quadrados [31] consiste em ajustar os parâmetros de uma função modelo para melhor atender um conjunto de dados. Com isso, dado um conjunto M de elementos (ω_s, ω_r) que satisfaçam uma relação funcional desconhecida $\omega_r = \phi(\omega_s)$, o método dos mínimos quadrados pretende encontrar uma combinação linear Φ , definida em (4.20), que seja mais próxima o possível de ϕ . Isto é, calcular os valores dos coeficientes β de Φ_β de modo que ela se torne semelhante a ϕ , para todo (ω_s, ω_r) de M .

$$\Phi(\beta, \omega_s) = \sum_j \beta_j \varphi_j(\omega_s) \quad (4.20)$$

Por exemplo, sendo ω_r e ω_s pontos das imagens I_r e I_s , onde $\omega_r = \phi(\omega_s)$, a finalidade dos mínimos quadrados é encontrar Φ_β tal que $\omega_r \sim \Phi_\beta(\omega_s)$. Fazendo uma analogia como o gráfico da Figura 4.21, sendo ω_r os pontos em vermelho do gráfico e $\Phi_\beta(\omega_s)$ os pontos da curva em azul, os mínimos quadrados tende a encontrar uma curva em que as diferenças entre seus pontos e os de vermelho sejam mínimas. Para isso, os parâmetros β são calculados de forma que a soma dos quadrados dos resíduos c_i , definido como em (4.21), seja mínima. Isso pode ser feito igualando o gradiente de C , em função de β , a zero, como na fórmula (4.22).

$$C = \sum_i (c_i)^2, \quad c_i = \sum_j (\omega_{r_i} - \Phi_\beta(\omega_{s_i})) = \sum_j (\omega_{r_i} - \beta_j \varphi_j(\omega_{s_i})) \quad (4.21)$$

$$\frac{\delta C}{\delta \beta_j} = 2 \sum_i c_i \frac{\delta c_i}{\delta \beta_j} = -2 \sum_i c_i \frac{\delta \Phi(\omega_{s_i}, \beta)}{\delta \beta_j} = 0 \quad (4.22)$$




Figura 4.21: Função quadrada gerada pelo método dos mínimos quadrados.

Através da expressão (4.23), na qual o gradiente de $\Phi(\omega_{s_i}, \beta)$ em β é $\varphi_k(\omega_{s_i})$, pode-se reescrever a fórmula (4.22) como (4.24), que, por sua vez, tendo $U = \varphi_k(\omega_{s_i})\varphi_j(\omega_{s_i})$ e $V = \varphi_k(\omega_{s_i})\omega_{r_i}$, pode ser expressa de forma semelhante à (4.25), uma equação normal em função da matriz de coeficiente β [31].

A resolução da equação (4.25) consiste em encontrar a matriz de coeficientes β de Φ_β , o que pode ser feito pela decomposição (4.26), que, ao ser comparada com (4.24), tem-se que $Q_s = \varphi_j(\omega_s)$, sendo Q_s^T a sua transposta e $Q_r = \omega_{r_i}$. Algebricamente, essa decomposição pode ser solucionada como $\hat{\beta} = (Q_s^T Q_s)^{-1} Q_s^T Q_r$, sendo $(Q_s^T Q_s)^{-1}$ a matriz inversa da multiplicação de Q_s^T e Q_s [31].

$$\frac{\delta \Phi(\omega_{s_i}, \beta)}{\delta \beta_j} = \varphi_k(\omega_{s_i}) \quad (4.23)$$

$$\sum_j \left(\sum_i \varphi_k(\omega_{s_i}) \varphi_j(\omega_{s_i}) \right) \beta_j = \sum_i \varphi_k(\omega_{s_i}) \omega_{r_i} \quad (4.24)$$

$$U\beta = V \quad (4.25)$$

$$(Q_s^T Q_s) \hat{\beta} = Q_s^T Q_r \quad (4.26)$$

Outra forma de resolução do problema dos mínimos quadrados é através da decomposição SVD (*Singular Value Decomposition*) [40]. Nesse método, através da aproximação da equação (4.27), é possível ter-se a expressão (4.28), na qual $\Lambda = \varphi_j(\omega_{s_i})$. Utilizando a rotina de decomposição SVD, a matriz Λ é decomposta em três matrizes, Σ , U e V , sendo a primeira uma matriz diagonal de valores não negativos, conhecidos como valores singulares de Λ . O uso dessa decomposição produz uma expressão semelhante a (4.29), na qual os valores de $\bar{\beta}$ são calculados como em (4.30), sendo σ_J elemento de Λ . Mais

detalhes sobre o problema dos mínimos quadrados e suas resoluções podem ser vistos em Forsythe *et al*[31].

$$\sum_i \beta_j \varphi_j(\omega_{s_i}) \approx \omega_{r_i} \quad (4.27)$$

$$\Lambda \beta \approx Q_r \quad (4.28)$$

$$\Sigma \bar{\beta} \approx \bar{Q}_r \quad (4.29)$$

$$\bar{\beta}_j = \frac{\bar{\omega}_{r_j}}{\sigma_J} \quad (4.30)$$

4.4.2 Método de *Gauss-Newton*

Da mesma forma que os mínimos quadrados da seção anterior, o objetivo de Gauss-Newton também é encontrar os valores dos coeficientes β de Φ , em que soma da diferença quadrada dos resíduos da fórmula (4.21) seja mínima. Entretanto, nesse método, a função modelo Φ_β , que deve relacionar os pontos dos conjuntos, tornando-se o mais próximo possível da relação desconhecida φ , não necessariamente precisa ser uma combinação linear. Devido a isso, esse método também pode ser visto como uma resolução do problema dos mínimos quadrados não lineares.

O cálculo dos valores β_i é feito de forma iterativa, a partir de um conjunto de valores iniciais β_0 . A cada interação, um conjunto de valores β_{n+1} é calculado com base nos valores de β_n , através da fórmula (4.31), na qual J , definida como em (4.32), é matriz Jacobiana de $c_i(\beta_n)$, que é a soma dos resíduos c_i calculados pelos coeficientes de valores β_n [110].

$$\beta_{n+1} = \beta_n - (J_r^T J_r)^{-1} J_r^T c_i(\beta_n) \quad (4.31)$$

$$J_{ij} = \frac{\delta c_i(\beta_n)}{\delta \beta_j} \quad (4.32)$$

4.5 Transformação da imagem sensível

A função de transformação calculada na seção anterior serve para alterar a imagem sensível, tornando-a mais semelhante à de referência. Para isso, é necessária a utilização de técnicas de interpolação que mapeiem os valores contínuos da função de transformação em valores discretos do domínio de representação das imagens. Esse processo será feito de forma inversa (seção 2.5), através do mapeamento Φ_β^{-1} , que irá relacionar os pontos da nova imagem transformada I_S^T aos pontos da imagem sensível I_S .

A função de interpolação utilizada é a interpolação linear [67], escolhida devido a sua simplicidade computacional e seus resultados em trabalhos anteriores descritos em Pan *et al* [88]. Nessa interpolação, a intensidade dos pontos $\tilde{\omega}_s$ em I_S , relacionados por $\tilde{\omega}_s = \Phi_\beta^{-1}(\omega_t)$, sendo ω_t pontos da imagem transformada, é determinada a partir da soma ponderada das intensidades dos quatro pixels mais próximos a ele, como em (4.33). Nesta fórmula, $\Omega_v(\tilde{\omega}_s)$ representa os quatros pixels mais próximos de $\tilde{\omega}_s$ em I_S , e φ é a função que indica a influência de cada intensidade dos pixels ω_i de $\Omega_v(\tilde{\omega}_s)$.

$$\varphi(I_S, \tilde{\omega}_s) = \sum_{\omega_i \in \Omega_v(\tilde{\omega}_s)} \varphi(\omega_i - \tilde{\omega}_s) \cdot I_S(\omega_i) \quad (4.33)$$

No caso em que $\Omega \in \mathbb{N}^2$ e $\omega = (x, y)$, a vizinhança de $\tilde{\omega}_s = (\tilde{x}_s, \tilde{y}_s)$, com $\tilde{\omega}_s \in \mathbb{R}^2$, é definida como (4.34) e ilustrada pela Figura 4.22. Nesta ilustração, (x, y) é o pixel formado pelas partes inteiras de $(\tilde{x}_s, \tilde{y}_s)$ e, os demais são formados pela adição de 1 aos seus valores. Por fim, a função φ , que expressa o peso de cada intensidade, é feita como em (4.35): as distâncias de x_i para \tilde{x}_s e as distâncias de y_i para \tilde{y}_s .




Figura 4.22: Vizinhança utilizada no cálculo da interpolação.

$$\Omega_v(\tilde{\omega}_s) = \{(x + i, y + j) \in \Omega_S \mid (x, y) = (\lfloor \tilde{x}_s \rfloor, \lfloor \tilde{y}_s \rfloor) \wedge i, j = [0, 1]\} \quad (4.34)$$

$$\varphi((x_i, y_i), (\tilde{x}_s, \tilde{y}_s)) = (x_i - \tilde{x}_s)(y_i - \tilde{y}_s) \quad (4.35)$$

4.6 Execução sistemática do método.

O registro apresentado nas seções anteriores deve ser executado de forma que, um relacionamento entre as 20 imagens da paciente seja criado, facilitando a extração de informações ao longo dessa sequência. Essa execução ocorre como na Figura 4.23, na qual o conjunto superior de quadrados I_i , com i variando entre 1 e 20, representa a sequência de imagens de uma paciente antes do registro e o conjunto inferior de quadrados I_i^T representa o novo conjunto de imagens da paciente, gerado após a execução do registro. Inicialmente, uma imagem do conjunto superior é escolhida como a referência do método, no caso da Figura 4.23, a escolhida é a imagem I_1 . Através dessa imagem, os pares são formados por ela junto com as demais, por exemplo I_1 e I_2 , I_1 e I_3 , I_1 e I_4 e assim sucessivamente. No total são formados 19 pares, numerados de acordo com a segunda imagem do par. Neste caso, o par I_1 e I_2 é denominado de “par 2”, o I_1 e I_3 é o “par 3”, não existindo o “par 1”.

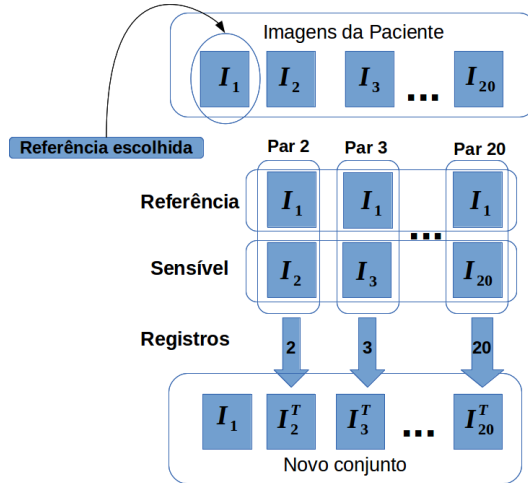


Figura 4.23: Execução do método nas imagens de uma paciente.

O método de registro é executado sobre dos pares formados. Em cada execução, a imagem de referência é a usada para a formação dos pares e a sensível é a outra imagem do par. No caso da Figura 4.23, no registro do “par 2”, a imagem de referência será a I_1 e a sensível será a I_2 . Ao final, a imagem sensível é transformada, originando uma imagem I_i^T , mais “alinhada” a imagem de referência.

Com a criação das imagens transformadas, um novo conjunto de imagens da paciente é formado, sendo ele composto pela imagem de referência, mais as imagens transformadas I_i^T . Na Figura 4.23, esse novo conjunto é constituído da imagem I_1 mais as imagens I_i^T , com i variando de 2 a 20. No novo conjunto gerado, todas as imagens estão alinhadas à de referência, o que intrinsecamente as tornam alinhadas também entre si. O produto final dessa execução sistemática é um conjunto de imagens da paciente alinhadas entre si.

4.6.1 Escolha da referência

Uma etapa importante da execução acima é a escolha da imagem de referência, pois, a partir dela, são formados os pares utilizados na execução do método de registro. Assim, quanto mais similar for a imagem de referência às restantes, mais semelhantes serão os pares e mais chances o registro terá de produzir melhores resultados com menos esforços.

A técnica utilizada para a escolha da imagem de referência ocorre como na Figura 4.24. Nela, cada imagem é testada como se fosse a referência e, em cada teste, a similaridade dos pares formados é medida. A imagem escolhida será a que apresentar pares com a maior similaridade. Esse processo pode ser resumido através da equação (4.36), na qual c é uma função que mede a similaridade entre duas imagens e μ_j é a média das similaridades entre os pares formados pela imagem I_j . Desta forma, para cada imagem I_j da paciente, um μ_j é calculado e a imagem que apresentar o melhor μ_j é escolhida como referência.

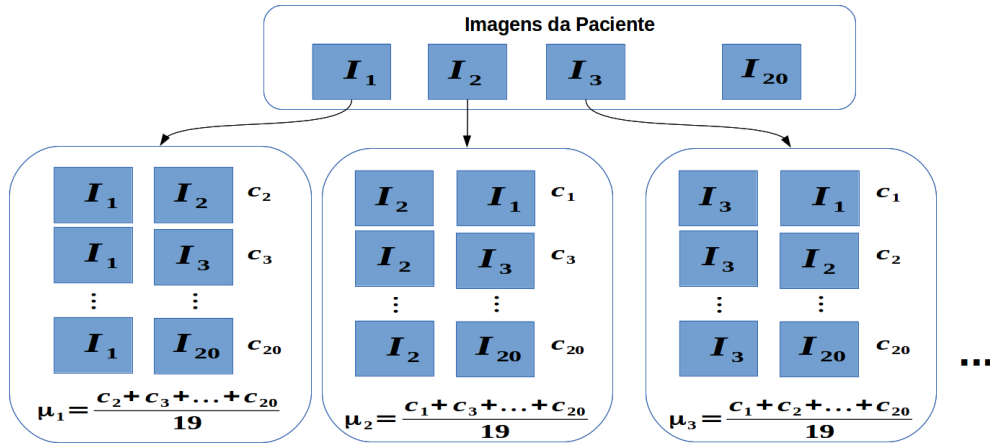


Figura 4.24: Método de escolha da imagem de referência.

$$\mu_j = \frac{1}{19} \sum_i c_i(I_j, I_i), \quad i \in [1 \dots 20] \setminus \{j\} \quad (4.36)$$

A função c , que avalia a similaridade entre os pares, foi desenvolvida nesse trabalho e constatada como a mais recomendada para esse tipo de imagem. A sua criação é feita através de um estudo sobre as medidas existentes na literatura, o qual é apresentado no capítulo 6.

Capítulo 5

Escolha do modelo de transformações

Uma das partes mais importantes do método de registro é a escolha do modelo de transformação, que guia as alterações da imagem sensível tornando-a mais semelhante à imagem de referência. Nesta escolha, deve ser levado em consideração que o modelo selecionado funcionará como delimitador do universo de soluções possíveis. Por isso, ele deve ser capaz de corrigir as alterações que diferenciam as imagens, possibilitando que o registro produza melhores resultados. Dessa forma, para uma boa escolha do modelo de transformação, é necessário antes saber que tipos de alterações diferenciam as imagens e, depois, buscar as transformações que melhor corrijam essas alterações.

Nas imagens térmicas em questão, as diferenças entre elas são provocadas pela movimentação da paciente durante a sua aquisição. Devido a isso, o modelo de transformação utilizado neste registro é selecionado com base em um estudo dos movimentos realizados pelas pacientes durante a captura das imagens. Esse estudo foi efetuado: analisando as imagens armazenadas no DMR; criando hipóteses de movimentações; e confirmando essas hipóteses com imagens geradas experimentalmente por um manequim. A seguir, cada uma dessas etapas é explicada.

5.1 Análise das imagens do DMR

Na análise das imagens do DMR, puderam-se verificar as diferenças existentes entre as imagens de uma mesma paciente e que tipos de movimentos realizados durante a aquisição provocaram essas diferenças. A partir dessa análise, constatou-se que a maioria dos movimentos realizados pelas pacientes podem ser divididos em 3 grupos: leves inclinações laterais, para a esquerda ou para a direita; leves inclinações, para frente ou para atrás; e leves torções ao longo do eixo longitudinal.

Para explicar essa movimentação serão utilizados os planos e eixos anatômicos, ilustrados na Figura 5.1. O plano sagital divide o corpo em lado esquerdo e direito, sendo ele orientado pelos eixos longitudinal e sagital. O plano coronal ou frontal divide o corpo em porções dorsais e ventrais (costas e frente), a sua orientação é dada pelos eixos longitudinal e transversal. E o plano transversal ou axial divide o corpo nas porções cranial e caudal (para cima e para baixo), seus eixos são o transversal e o sagital [12].




Figura 5.1: Planos anatômicos [12].

Nas inclinações laterais, a paciente realiza movimentos sem sair do plano coronal, alterando o ângulo formado entre os eixos longitudinal e transversal. Essa movimentação ocorre tanto para a esquerda, no sentido horário ao eixo sagital, como para a direita, no sentido anti-horário. Um exemplo disto são as imagens da Figura 5.2, em que, na Figura 5.2a, a paciente está com uma leve inclinação para a direita, mantendo-se no seu plano sagital em relação à Figura 5.2b (posição inicial). Essa movimentação é melhor observada através da sobreposição das imagens, exibida na Figura 5.2c, na qual percebe que uma das imagem está mais inclinada para a direita.

As leves inclinações para frente e para trás são realizadas no plano sagital, em torno de um eixo que passa pelos pés, paralelo ao transversal. Essa movimentação ocorre no sentido positivo e negativo desse eixo, gerando imagens como as da Figura 5.3. Na Figura 5.3a, a paciente está em sua posição normal e, na Figura 5.3b, ela está com uma leve inclinação para trás. Essa movimentação é enfatizada na Figura 5.3c, na qual estão as bordas da Figura 5.3a, em azul, e da Figura 5.3b, em branco. Através dessas bordas, a movimentação é caracterizada pela diminuição da borda na região do abdome e pela alteração da posição do quadrado central, que ficou mais baixo.




Figura 5.2: Inclinação lateral na aquisição das imagens térmicas: (a) paciente inclinada, (b) paciente na posição inicial e (c) sobreposição entre as duas imagens.




Figura 5.3: Inclinação para a trás na aquisição das imagens térmicas: (a) paciente inclinada, (b) paciente na posição normal e (c) sobreposição das bordas.

A última classe de movimentos, torções em torno do eixo longitudinal, está representada pelas imagens da Figura 5.4. Na primeira imagem, Figura 5.4a, a paciente está com uma leve torção no sentido horário, em torno do eixo longitudinal. Na imagem seguinte, Figura 5.4b, ela acentua ainda mais essa movimentação. Esse movimento é melhor constatado pelas regiões laterais, abaixo da axila esquerda da paciente, que antes não apareciam na Figura 5.4a e agora podem ser observadas na Figura 5.4b, como a região destacada de vermelho. O mesmo ocorre com as regiões laterais da mama direita, abaixo da axila, que antes eram exibidas na Figura 5.4a e foram cobertas pela mama na Figura 5.4b.




Figura 5.4: Torção da paciente na aquisição das imagens térmicas: (a) paciente com uma leve torção e (b) paciente com uma torção maior.

Além dos tipos de movimentos citados acima, outros não muito frequentes também estão presentes nas imagens do DMR, como por exemplo, a movimentação da cabeça da paciente. Isso pode ser observado nas imagens das Figuras 5.4, em que, na primeira imagem, a paciente está com o queixo apontando para frente e, na segunda imagem, o seu queixo está apontando para a sua direita, simbolizando a movimentação da cabeça para a direita. Essa movimentação é efatizada na sobreposição das bordas das duas imagens, exibidas na Figura 5.5.




Figura 5.5: Sobreposição das bordas das Figuras 5.4a e 5.4b.

5.2 Hipóteses

As movimentações descritas acima podem provocar dois tipos de alterações no cenário de captura das imagens da paciente. Na primeira, todo o corpo é movimentado uniformemente como um corpo rígido, realizando transformações rígidas. Na segunda, a movimentação causa alterações locais no corpo da paciente, provocando pequenas deformações, realizando transformações de segunda ordem. Entretanto, como as diferenças entre as imagens são causadas por movimentos que modificam o corpo da paciente como um todo, acredita-se que as maiores distinções entre as imagens térmicas são provocadas pelo primeiro tipo de alteração e que as deformações locais ocorrem por estarem relacionadas às transformações rígidas realizadas pela paciente.

Estas hipóteses são verificadas, comparando as imagens adquiridos durante o exame de uma paciente com imagens adquiridas por um manequim propositalmente posicionado para simular a movimentação de corpo rígido durante o exame. Assim, se as imagens adquiridas do manequim, que realiza apenas movimentos rígidos, apresentarem resultados semelhante ou piores aos da paciente, é provável que, na paciente, as diferenças sejam, na maior parte, provocadas por movimentos rígidos. Essa comparação é discutida a seguir.

5.3 Comparação entre paciente e manequim

Para uma comparação mais precisa, as imagens do manequim foram adquiridas pela mesma câmera térmica (mesma resolução das imagens térmicas). A única diferença entre as imagens do manequim e da paciente é que as do manequim foram capturadas na frequência visível, e as da paciente foram capturados pela frequência infravermelha.

A análise entre esses dois tipos de imagens é feita através do posicionamento de quatro pontos, manualmente identificados e presentes em todas as imagens na sequência da paciente e do manequim. Nas imagens da paciente, os pontos analisados foram destacados em vermelho na Figura 5.6a, os quais são: os dois mamilos e as junções das pregas inframamárias com o contorno do corpo. No manequim, para simular a assimetria dos mamilos e dos sucos mamários, pontos próximos aos mamilos e as pregas inframamárias foram marcados de azul antes da captura das imagens, como na Figura 5.6b.




Figura 5.6: Pontos observados: (a) nas imagens da paciente e (b) nas imagens do manequim.

Ao ligar os pontos superiores e os inferiores nos dois tipos de imagem, é possível obter dois segmentos de reta quase paralelos, representados pelas linhas azuis nas imagens da Figura 5.6. Com esses segmentos, pseudodeformações, ocorridas na sequência de imagens, são calculadas através da fórmula (5.1), na qual l_1 é o comprimento do segmento de reta na primeira imagem e l_i é o mesmo comprimento na imagem I_i . No cálculo dessas deformações o conjunto discreto fechado Ω , de representação dos pixels das imagens, é um subconjunto de \mathbb{N}^2 , com seus elementos $\omega = (x, y)$, sendo $0 \leq x \leq 639$ e $0 \leq y \leq 479$, semelhante à representação da Figura 2.3.

As observações realizadas nas imagens da paciente são exibidas nas tabelas 5.1 e 5.2. Na primeira, em cada linha, têm-se o número da imagem, a posição dos mamilos, o comprimento do segmento de reta formado por eles e a pseudodeformação. Na segunda as mesmas informações são obtidas com base nas pregas inframamárias.

$$Def_{\cdot i} = \frac{(l_i - l_1)}{l_1} \quad (5.1)$$

Tabela 5.1: Distância dos mamilos nas imagens térmicas.

Img.	Mamilo Direito		Mamilo Esquerdo		l_i	$Def_{\cdot i}$
I_1	119	315	522	318	403.0	
I_2	113	318	521	324	408.0	0.012
I_3	119	315	521	316	402.0	-0.003
I_4	137	313	536	322	399.1	-0.010
I_5	130	321	528	326	398.0	-0.012
I_6	123	313	525	318	402.0	-0.002
I_7	126	300	515	304	389.0	-0.035
I_8	117	315	523	322	406.1	0.008
I_9	88	313	496	310	408.0	0.012
I_{10}	85	333	493	330	408.0	0.012
I_{11}	113	312	520	322	407.1	0.010
I_{12}	123	312	533	321	410.1	0.018
I_{13}	132	306	531	310	399.0	-0.010
I_{14}	142	305	544	307	402.0	-0.002
I_{15}	141	321	549	322	408.0	0.012
I_{16}	137	318	545	322	408.0	0.012
I_{17}	133	325	541	338	408.2	0.013
I_{18}	138	323	548	330	410.1	0.013
I_{19}	142	327	551	334	409.1	0.015
I_{20}	129	326	537	333	408.1	0.013

Nas tabelas 5.1 e 5.2, é possível perceber que, através dos segmentos dos mamilos, a maior “deformação” foi de $-0,035$ na I_7 , indicando que, nesta imagem, o segmento superior diminui 3,5%, em relação ao seu tamanho na I_1 . Nos segmentos formados pelos pontos das pregas inframamárias, a maior deformação foi de $-0,060$ na imagem I_4 , indicando que, nesta imagem, o segmento inferior diminui de 6% em relação à I_1 .

Para verificar se as “deformações” ocorreram na mesma proporção na parte superior e na inferior de uma mesma imagem, os resultados da tabela 5.1 foram confrontados com os da tabela 5.2. Através dessa observação, percebe-se que a maior diferença entre as “deformações” ocorreu na I_{10} , com a parte superior “deformando” em 0,012 e a inferior em $-0,041$, uma diferença de 0.053 entre as duas “deformações” da imagem.

O mesmo estudo realizado nas imagens da paciente é feito nas imagens do manequim. Os resultados obtidos com os pontos superiores do manequim são exibidos na tabela 5.3 e os resultados alcançados com os pontos inferiores são mostrados na tabela 5.4.

Com as duas tabelas anteriores, percebe-se que, como nas imagens da paciente, as

Tabela 5.2: Distância das pregas inframamárias nas imagens térmicas.

Img	Prega Direita		Prega Esquerda		l_i	Def_i
I_1	97	399	500	400	403.0	
I_2	96	401	503	404	407.0	0.010
I_3	108	399	510	399	402.0	-0.002
I_4	125	397	505	404	380.1	-0.060
I_5	120	404	508	408	388.0	-0.039
I_6	122	401	512	402	390.0	-0.033
I_7	123	386	514	385	391.0	-0.031
I_8	111	404	500	405	389.0	-0.036
I_9	103	404	495	396	392.1	-0.028
I_{10}	101	417	488	406	387.2	-0.041
I_{11}	117	400	522	403	405.0	0.005
I_{12}	133	402	523	404	390.0	-0.033
I_{13}	140	398	525	396	385.0	-0.047
I_{14}	145	395	531	393	386.0	-0.044
I_{15}	139	410	530	407	391.0	-0.031
I_{16}	137	408	532	406	395.0	-0.020
I_{17}	138	413	535	417	397.0	-0.015
I_{18}	143	410	531	411	388.0	-0.039
I_{19}	143	413	534	415	391.0	-0.031
I_{20}	135	412	527	414	392.0	-0.028

Tabela 5.3: Distância dos pontos superiores nas imagens do manequim.

Img	Superior Esquerdo		Superior Direito		l_i	Def_i
I_1	224	258	448	253	224,1	
I_2	134	251	346	251	212,4	-0.05
I_3	315	265	523	261	208.0	-0,07
I_4	189	322	443	301	254,9	0.14
I_5	215	301	467	311	252,2	0,13
I_6	317	244	532	256	215,3	-0,04
I_7	108	274	321	238	216,0	-0,04
I_8	182	318	440	333	258,0	0,15

imagens do manequim poderiam estar sofrendo as pseudodeformações tanto na parte superior como na inferior. Além disso, nas imagens do manequim, essas “deformações” foram mais expressivas do que nas da paciente. Na parte superior, a maior “deformação” do manequim medida foi de 0,15 na I_8 , indicando um aumento de 15% do tamanho do segmento, nesta imagem. Na parte inferior, a maior “deformação” também foi de 0,15 na I_8 . Na comparação entre as “deformações” superiores e inferiores da mesma imagem, o manequim também obteve valores semelhantes aos da paciente, sendo o maior deles na imagem I_5 , onde a “deformação” superior foi de 0,13 e a inferior de 0,09, uma diferença de

Tabela 5.4: Distância dos pontos inferior nas imagens do manequim.

Img	Inferior Direito		Inferior Esquerdo		l_i	$Def.i$
I_1	222	325	445	327	223,5	
I_2	154	315	365	328	211,4	-0,05
I_3	303	334	519	332	216,7	-0,03
I_4	197	389	444	380	247,2	0,11
I_5	213	370	456	390	243,8	0,09
I_6	309	313	519	334	211,0	-0,05
I_7	119	344	331	320	213,4	-0,04
I_8	187	384	442	410	256,3	0,15

0,04 entre as duas “deformações”. Por fim, semelhante às imagens térmicas, nas imagens do manequim também foram apresentadas “deformações” negativas e positivas, significando aumentos e diminuições nos tamanhos dos segmentos.

Como o manequim é feito de um material rígido, que realiza apenas transformações rígidas, e as suas pseudodeformações calculadas foram maiores do que as da paciente, a hipótese de representação dos movimentos da paciente como um corpo rígido é uma hipótese válida. Para reforçar isto, uma comparação visual é feita entre quadriláteros formados pelos pontos das imagens. Através desses quadriláteros, as alterações de posições em cada imagem foram verificadas e comparadas visualmente, como comentado a seguir.

5.3.1 Comparação entre quadriláteros da paciente e manequim.

Os quadriláteros desta comparação são formados pelos quatro pontos analisados em uma imagem. As suas arestas ligam: os dois pontos superiores; o ponto superior da esquerda com o inferior da esquerda; os dois pontos inferiores; e os dois pontos da direita. Esta representação pode ser vista no gráfico da Figura 5.7, no qual estão os quadriláteros formados pelas imagens da paciente. Neste gráfico, os eixos das abscissas e ordenadas, representam as coordenadas x e y , em pixel, com o ponto (0,0) no canto superior esquerdo.

Com no gráfico da Figura 5.7, percebe-se que, através das suas semelhanças de formato e posição, os quadriláteros das imagens da paciente podem ser agrupados em 8 classes distintas, exibidas na Figura 5.8. Na primeira classe, estão os quadriláteros das imagens 1, 2 e 3. Na segunda, estão os das imagens 4, 5, 6, 8, 11, 12. Na terceira, quarta e quinta classes, estão os das imagens 7, 9 e 10. Na sexta, estão os das imagens 13 e 14. Na sétima, estão os das imagens 15 e 16. Na última, estão os das imagens 17, 18, 19 e 20.

Na classificação acima, percebe-se visualmente que a maior desigualdade entre os




Figura 5.7: Quadriláteros das imagens da paciente.

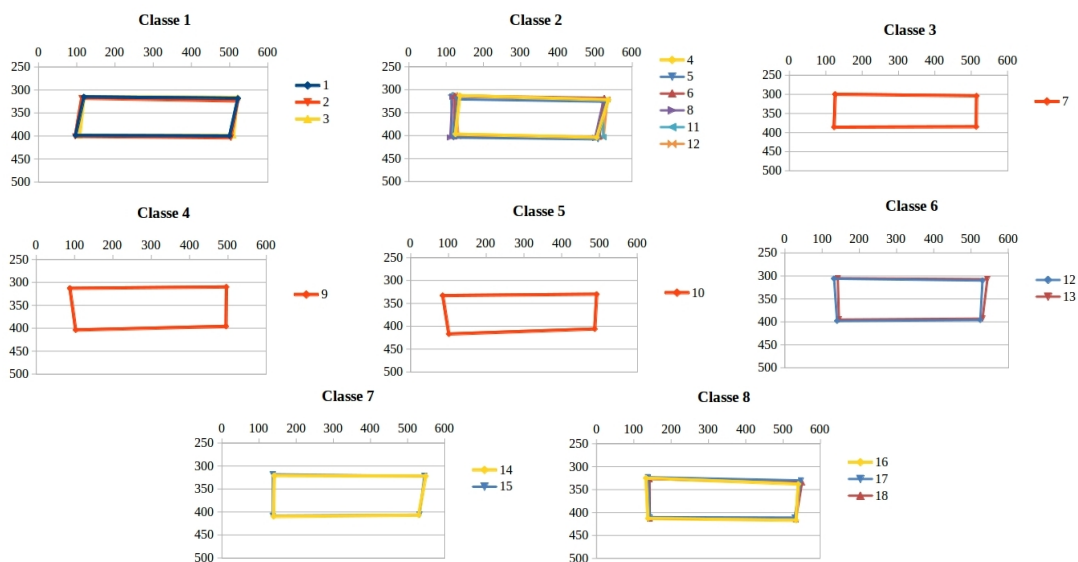


Figura 5.8: Classes dos quadriláteros das imagens da paciente.

quadriláteros ocorreu na imagem 10, representada pela quinta classe de quadriláteros e exibida na Figura 5.9a. Comparando essa imagem com a 1, exibida na Figura 5.9b, nota-se que a paciente realizou uma inclinação para a direita no momento da capturada. Apesar dessa grande movimentação, a “deformação” dessa imagem não foi a maior observada pelas tabelas 5.1 e 5.2, que indica uma “deformação” de 0,012 do segmento de reta superior e $-0,041$ do inferior. Entretanto, na análise das diferenças entre as “deformações” superiores e inferiores, foi esta imagem que teve a maior desigualdade.

Os quadriláteros formados pelos pontos analisados nas imagens do manequim são exibidos no gráfico da Figura 5.10. Através dele, observa-se que, no manequim, os quadriláteros possuem uma diferença maior do que nas imagens da paciente, seguindo a mesma tendência do estudo das “deformações”.




Figura 5.9: Movimentação observada: (a) imagem 10 da paciente e (b) imagem 1 da paciente.




Figura 5.10: Quadriláteros das imagens do manequim.

A separação de cada um dos quadriláteros das imagens do manequim é exibida na Figura 5.11. Através dela, nota-se que parte da movimentação da paciente assemelha-se à movimentação do manequim. Por exemplo, a classe 1 da paciente assemelha-se ao quadrilátero 1 do manequim. O mesmo pode ser dito para a classe 4 e o quadrilátero 2, a classe 5 e o quadrilátero 4, a classe 6 e o quadrilátero 7; e a classe 8 e o quadrilátero 8.




Figura 5.11: Separações dos quadriláteros das imagens do manequim.

Outra fato interessante sobre essa comparação é que, na imagem em que a diferença entre a “deformação” superior e inferior foi maior, tanto paciente como manequim realizaram o mesmo movimento, uma inclinação lateral. Na paciente, isso ocorre na imagem I_{10} e, no manequim, ocorre na I_5 , apresentadas nas figuras 5.12a e 5.12b, nas quais observa-se que a paciente estava inclinado para a direita e o manequim para a esquerda.




Figura 5.12: Movimentação com resultados semelhantes entre: (a) paciente e (b) manequim.

5.4 Considerações finais sobre a escolha do modelo de transformações

Nas seções anteriores, pode-se observar que as pseudodeformações nas imagens do manequim foram maiores que nas da paciente. Além disso, alguns dos movimentos realizados pela paciente puderam ser simulados pelo manequim. Dessa forma, concluiu-se que as deformações que diferenciam as imagens de uma paciente podem ser tratadas como se esta realiza-se uma movimentação de corpo rígido, alterando o seu alinhamento com a câmera e gerando imagens de diferentes visões, semelhantes a da Figura 2.5.

De acordo com Goshtasby[40], imagens de diferentes visões de uma mesma cena podem ser relacionadas através das transformações de projeções e das transformações afins. Quando a câmera está muito distante da cena, como nas imagens de paisagens, é preferencial a utilização de transformações afins e, quando esta se encontra muito próxima, é indicado o uso das transformações de projeções.

No problema em questão, a distância da câmera para o objeto pode ser considerada próxima, em relação ao tamanho da cena. Por isso, esperava-se que as transformações de projeções obtenham melhores resultados do que as transformações afins. Entretanto, durante os testes realizados por um registro previamente criado em Galvão *et al*[32], notou-se que, em alguns casos, as transformações menos genéricas podem produzir melhores

resultados que as com um maior grau de mobilidade. Isso ocorre principalmente porque o relativamente grande número de parâmetros a serem calculados nas transformações mais genéricas pode produzir erros maiores, quando não são necessárias a sua utilização, ou seja, quando as imagens podem ser transformadas por funções de menor mobilidade.

Um exemplo disso são os testes realizados nas imagens de duas pacientes, no qual são comparados os resultados de um registro que utiliza a transformação de projeção com outro que utiliza a transformação afim. Nesta comparação, as 20 imagens da paciente, numeradas de 1 a 20, são organizadas em pares como na seção 4.6 e, em cada um dos pares, os dois registros são realizados. Os resultados produzidos por esses registros são comparados, verificando qual das transformações produziu imagens mais semelhantes à de referência. Para uma comparação mais confiável, os métodos de registro utilizados nessa verificação são orientados pelas mesmas características e suas funções de transformações são calculadas pela mesma técnica. Dessa forma, a única diferença entre os dois registros realizados é somente o modelo de transformação.

As comparações da primeira paciente, entre a imagem de referência e as imagens produzidas por cada registro, podem ser vistas no gráfico da Figura 5.13, no qual os pares analisados estão organizados na horizontal e os valores da medida de similaridade estão dispostos em barras verticais. A primeira barra de cada par, barras em azul, são as comparações entre a imagem de referência e as sensíveis (antes das transformações), as em vermelho são os resultados entre a imagem de referência e as imagens da transformação afim, e as em amarelo são as comparações entre a imagem de referência e as da transformação de projeções. Neste gráfico, quanto maior o valor, maior a similaridade entre as imagens, tendo o par 9º valor máximo por ser a imagem 9 a escolhida como referência.




Figura 5.13: Comparação em que a transformação afim é melhor que a de projeção.

No gráfico anterior, observa-se que, na maioria dos pares, as transformações afins

foram melhores que as de projeções, pois produziram imagens mais semelhantes às de referência, o que ocorre nos pares 3, 4, 5, 6, 7, 8, 10, 13, 15, 16, 17, 18 e 19. As transformações de projeções foram melhores do que as afins somente nos pares 1, 12 e 15. Além disso, é possível ver que, no caso dos pares 3 e 13, nenhuma das transformações conseguiu deixar a imagem sensível mais semelhante à imagem de referência.

Entretanto, realizando os mesmos testes no conjunto de imagens da outra paciente, percebe-se que, para este caso, as transformações de projeções foram melhores do que as transformações afins. Esses resultados são ilustrados pelo gráfico da Figura 5.14, organizado de forma semelhante ao gráfico da Figura 5.13, com barras representando a semelhança entre o par da imagem de referência com a imagem sensível, entre o par da imagem de referência com a da transformação afim e entre a imagem de referência com a da transformação de projeções. Nesta paciente, as transformações de projeções foram melhores na maioria dos pares, exceto no par 20, no qual a transformação afim foi melhor, e nos pares 10 e 19, nos quais nenhuma das transformações conseguiu tornar a imagem sensível mais semelhante à de referência.




Figura 5.14: Comparação em que a transformação de projeções é melhor que a afim.

Devido a essas observações, para o método de registro desenvolvido neste trabalho, tanto a transformação afim como a de projeção serão utilizadas. Entretanto, a saída do método será apenas a imagem da transformação mais semelhante à de referência. Como na escolha da imagem de referência da seção 4.6, essa semelhança entre imagens será analisada por uma medida sugerida nesse trabalho vista como a mais indicada para esse tipo de imagem. Mais detalhes sobre essa medida e os seus testes são exibidos a seguir.

Capítulo 6

Avaliadores de similaridade

A avaliação de um registro de imagens é feito por medidas de similaridade, que se utilizam de informações das imagens para calcular o nível de alinhamento entre elas. De acordo com Zitova e Flusser[122], essa avaliação não é uma tarefa trivial, pois é complicado distinguir entre as diferenças de um registro mal realizado e as diferenças físicas do conteúdo da imagem. Dessa forma, uma avaliação equivocada pode qualificar resultados incorretos ou reprovar resultados satisfatórios. Por isso, dependendo da estratégia utilizada, a criação de um método de registro eficaz está diretamente vinculada à escolha de um avaliador de similaridade adequado ao contexto[19]. O método de registro desenvolvido nesse trabalho utiliza a comparação entre imagens em duas das suas etapas: na escolha da imagem de referência e na escolha da transformação que será apresentada como resultado. Dessa forma, a definição de uma medida de similaridade adequada para as imagens térmicas é de extrema importância para o bom desempenho do método.

Uma maneira de realizar a seleção dessa medida é analisar o desempenho dos possíveis avaliadores no próprio contexto de utilização. Assim, o avaliador que obtiver melhor desempenho será o escolhido. Para que esta comparação seja realizada, é necessário o desenvolvimento de um padrão ideal, com o qual os avaliadores serão confrontados. Em estudos, como os de Ong *et al*[85], Li *et al*[68], Shushariba *et al*[106] e Gholipour *et al*[37], o padrão de comparação é derivado de artefatos com os quais o nível de diferenciação entre as imagens pode ser medido e controlado, como fantasmas, imagens sintéticas, marcas colocadas, antes ou após a aquisição das imagens, e análise visual de um especialista.

Neste trabalho o comportamento de vários índices de similaridade utilizados em estudos anteriores são analisados nas imagens térmicas e comparados com a avaliação de um especialista. Entretanto, durante essa análise, percebeu-se que a junção entre dois tipos de índices produz resultados mais eficazes que os avaliadores analisados. Por isso, essa

junção é utilizada para a criação de um novo avaliador, o qual é escolhido para realizar a comparação entre imagens no método de registro.

Trabalhos semelhantes a este foram previamente realizados em Conci *et al* [21], Gonzalez-Castilho *et al* [38] e Dubuisson *et al* [25]. Nestes trabalhos, as medidas de similaridade são comparadas através de imagens sintéticas ou controladamente modificadas. Em Conci *et al* os autores comparam uma nova medida com outras existentes, através de imagens sintéticas que simulam particularidades presentes no contexto em questão. Gonzalez-Castilho *et al* aplicaram transformação em imagens reais, para estudar o comportamento de várias medidas. Dubuisson *et al* examinaram uma modificação da distância de Hausdorff aplicando ruídos e transformações em imagens reais.

A metodologia utilizada na escolha do avaliador é dividida em três partes: uma revisão bibliográfica dos avaliadores de similaridade; a observação do comportamento desses avaliadores nas imagens térmicas em questão; e as conclusões dos resultados obtidos pelos avaliadores. As quais são exibidas nas seções seguintes.

6.1 Medidas de similaridade

De acordo com as informações da imagem utilizadas, as medidas de similaridade podem ser classificadas em: medidas de sobreposição, que tratam as imagens como conjuntos binários [60]; medidas de intensidades, calculadas através dos valores armazenados nos pixels das imagens [15]; e medidas de distâncias, que utilizam a localização de características das imagens [76]. A seguir, cada um desses conjuntos de medidas é explicado.

6.1.1 Medidas de sobreposição

Para as medidas de sobreposição, os pixels das imagens estão divididos em dois conjuntos: pixels pertencentes às áreas de interesse da imagem e pixels não pertencentes às áreas de interesse. Assim, as imagens verificadas podem ser definidas em apenas dois tipos de intensidades 0 e 1, como é exibido na fórmula (6.1). Com consequência, o conjunto Ω também pode ser dividido em dois conjuntos distintos, Ω^1 e Ω^0 , sendo $\Omega^1 = \{\omega_i \in \Omega \mid I^1(\omega_i) = 1\}$, o conjunto formado pelos pixels pertencentes às áreas de interesse, e $\Omega^0 = \{\omega_i \in \Omega \mid I^1(\omega_i) = 0\}$, o conjunto formado pelos pixels não pertencentes às áreas de interesse.

$$I^1 : \Omega \rightarrow \{0, 1\} \quad (6.1)$$

De acordo com essa definição, nas medidas de sobreposição, as imagens podem ser representadas como na Figura 6.1a, na qual as áreas mais claras representam os pixels do conjunto Ω^1 e as áreas mais escuras representam os pixels do conjunto Ω^0 . Entretanto, durante o cálculo das medidas, apenas o conjunto Ω^1 é analisado, sendo os resultados obtidos pela sobreposição ou não de seus elementos em ambas as imagens.




Figura 6.1: Conjuntos: (a) divisão da imagem térmica em dois conjuntos e (b) sobreposição de conjuntos em duas imagens térmicas.

A sobreposição entre os conjuntos das áreas de interesse é ilustrada na Figura 6.1b. Nela, $\Omega_R^1 \cap \Omega_S^1$ representa as áreas sobrepostas de Ω^1 das imagens I_R^1 e I_S^1 e $\Omega_R^1 \setminus \Omega_S^1$ mais $\Omega_S^1 \setminus \Omega_R^1$ representam as áreas não sobrepostas. Formalmente, sendo Ω um conjunto fechado e conexo, as áreas da Figura 6.1b são expressas como em (6.2), (6.3), (6.4) e (6.5), as quais podem ser medidas em pixels através da função $N : \Omega \rightarrow \mathbb{N}$, que indica a quantidade de pixels de um subconjunto de Ω .

$$\Omega_S^1 \cap \Omega_R^1 = \{\omega_i \in \Omega \mid I_S^1(\omega_i) = 1 \wedge I_R^1(\omega_i) = 1\} \quad (6.2)$$

$$\Omega_S^1 \cup \Omega_R^1 = \{\omega_i \in \Omega \mid I_S^1(\omega_i) = 1 \vee I_R^1(\omega_i) = 1\} \quad (6.3)$$

$$\Omega_S^1 \setminus \Omega_R^1 = \{\omega_i \in \Omega \mid I_S^1(\omega_i) = 1 \wedge I_R^1(\omega_i) \neq 1\} \quad (6.4)$$

$$\Omega_R^1 \setminus \Omega_S^1 = \{\omega_i \in \Omega \mid I_R^1(\omega_i) = 1 \wedge I_S^1(\omega_i) \neq 1\} \quad (6.5)$$

Segundo Klein *et al*[60], as medidas de sobreposição podem ser divididas em dois tipos: medidas de concordância e medidas de erro.

6.1.1.1 Medidas de concordância

As medidas de concordância analisam as áreas de conformidade entre os conjuntos, ou seja, as regiões dos conjuntos Ω_R^1 e Ω_S^1 que se sobrepõem. Entre as medidas de concordância estão o coeficiente de Dice, o coeficiente de Jaccard e a sobreposição da referência.

O **coeficiente de Dice** [61] é definido como em (6.6): duas vezes a área em pixels da interseção das regiões Ω_R^1 e Ω_S^1 , dividida pela soma dos pixels dessas regiões. O valor obtido no coeficiente de Dice representa a porcentagem da região de sobreposição em relação à soma das regiões. Nessa medida, o valor 1 significa a total sobreposição, maior semelhança entre as imagens, enquanto o valor 0(zero) significa que não ocorreu sobreposição.

$$Dice = \frac{2N(\Omega_S^1 \cap \Omega_R^1)}{N(\Omega_S^1) + N(\Omega_R^1)} \quad (6.6)$$

O **coeficiente de Jaccard** [23] é definido como a razão entre as regiões de interseção e a união dos conjuntos Ω_R^1 e Ω_S^1 , como em (6.7). Ele representa a porcentagem de sobreposição desses conjuntos em relação a sua união. Semelhante ao coeficiente de Dice, o valor 1 significa maior semelhança e 0 (zero) sem semelhanças. Os coeficientes de Dice e Jaccard podem ser relacionados através da equação (6.8), na qual se tem que $Dice \geq Jaccard$.

$$Jaccard = \frac{N(\Omega_S^1 \cap \Omega_R^1)}{N(\Omega_S^1 \cup \Omega_R^1)} \quad (6.7)$$

$$Dice = \frac{2Jaccard}{Jaccard + 1} \quad (6.8)$$

A **Sobreposição da Referência (SR)** [60], definida em (6.9), é a área de interseção dividida pela área da região de Ω_R^1 . Essa medida representa a porcentagem de sobreposição em relação à área da região de interesse da imagem I_R . Ela varia entre 0(zero) e 1, sendo 1 o melhor resultado e 0(zero) o pior.

$$SR = \frac{N(\Omega_S^1 \cap \Omega_R^1)}{N(\Omega_R^1)} \quad (6.9)$$

6.1.1.2 Medidas de erro

As medidas de erro analisam as frações de desacordo entre os conjuntos, ou seja, áreas dos conjuntos que não se sobrepuseram, $\Omega_R^1 \setminus \Omega_S^1$ e $\Omega_S^1 \setminus \Omega_R^1$. Entre esse tipo de medidas estão o falso negativo e o falso positivo.

O **Falso Negativo (FN)** [21] é a área da imagem I_R que foi erradamente alinhada à área da imagem I_S . Ela é calculada pela área de Ω_R^1 não sobreposta pela região Ω_S^1 , dividida pela região Ω_R^1 , como é exibido em (6.10). Nessa medida, 0(zero) representa um menor erro e o 1 um maior erro entre as imagens.

$$FN = \frac{N(\Omega_R^1 \setminus \Omega_S^1)}{N(\Omega_R^1)} \quad (6.10)$$

O **Falso Positivo (FP)** [21] é a área da imagem I_S que foi erroneamente alinhada à imagem I_R . Ela é calculada como a área da região Ω_S^1 fora da região Ω_R^1 dividida pela região Ω_S^1 , como em (6.11). Do mesmo modo que a FN , o menor erro dessa medida é 0(zero) e o maior é 1.

$$FP = \frac{N(\Omega_S^1 \setminus \Omega_R^1)}{N(\Omega_S^1)} \quad (6.11)$$

6.1.2 Medidas de intensidades

As medidas baseadas em intensidades quantificam o nível de similaridade através da intensidades dos pixels correspondentes em cada imagem[117]. Comumente, as medidas desse tipo são utilizadas em imagens intramodalidade, imagens de um mesmo exame[41]. Entretanto, em alguns estudos, como [90, 94, 111], elas têm sido utilizadas também em imagens intermodalidade, imagens de exames diferentes. Entre as medidas de intensidades utilizadas em registro de imagens estão: a soma dos quadrados da diferença[24], a correlação cruzada normalizada [91] e a informação mútua[90].

6.1.2.1 Soma dos quadrados das diferenças

A **Soma dos Quadrados das Diferenças (SQD)** calcula a média dos quadrados das diferenças entre regiões das imagens I_R e I_S , como em (6.12). Nessa medida, o valor que representa uma maior similaridade entre as imagens é 0 (zero) e, quanto maior for seu valor, mais diferente as imagens serão.

$$SQD = \frac{1}{N(\Omega)} \sum_{\omega_i \in \Omega} (I_S(\omega_i) - I_R(\omega_i))^2, \quad (6.12)$$

Apesar de a SQD ser mais robusta que uma simples média entre as diferenças das intensidades, a sua utilização é recomendada somente para imagens de mesma modalidade, nas quais as intensidades entre os pixels ω_i das duas imagens possuem poucas variações [24]. Isso porque os seus resultados podem ser facilmente distorcidos por uma minoria de pixels com grandes diferenças de intensidades, por variações globais de intensidades ou pela presença de ruídos nas imagens [30] [44] [69].

Liu e Ribeiro[69] explicam que, para serem mais robustas, as medidas baseadas em intensidades não devem considerar apenas os valores individuais dos pixels analisados. Elas devem utilizar níveis de informações superiores, como a vizinhança. Assim, uma simples extensão da SQD pode ser feita como na fórmula (6.13), em que, no lugar da diferença ser calculada em cima do pixel ω_i , ela é calculada através da sua vizinhança Ω_{v_i} . Dessa forma, para cada pixel ω_i , é feito o somatório das diferenças entre os pixels da sua vizinhança na imagem I_S e os seus correspondentes da imagem I_R . O resultado final é o somatório das diferenças entre as vizinhanças de ω_i da imagem I_S e da imagem I_R .

$$SQD = \sum_{\omega_i} \sum_{\omega_j \in \Omega_v} (I_S(\omega_j) - I_R(\omega_j))^2, \quad \omega_i \in \Omega \quad (6.13)$$

6.1.2.2 Correlação cruzada normalizada

A **Correlação Cruzada Normalizada (CCN)** é mais independente da variação global de intensidade do que a SQD [67]. Ela é empregada na busca de padrões (*templates*), comparando o padrão desejado com partes da imagem [91]. Assim, ao definir I_R como padrão desejado e I_S como a imagem onde a busca é realizada, tem-se uma medida de comparação da similaridade entre as duas imagens [15][69][95].

Para a utilização da CCN, as imagens devem ser tratadas como sinais, com picos e vales. A criação dessa representação é feita utilizando as suas intensidades como os valores do sinal, os quais terão como referência a média das intensidades da imagem, representada por μ e definida em (6.14) como a soma das intensidades dividida pelo número de pixels.

$$\mu(I) = \frac{1}{N(\Omega)} \sum_{\omega_i \in \Omega} I(\omega_i) \quad (6.14)$$

Através da média, a CCN é calculada como em (6.15), em que μ_S e μ_R são médias de intensidades de I_S e I_R . O valor máximo dessa medida é 1, que indica o melhor alinhamento, e o mínimo é 0(zero), que indica uma grande diferença entre as imagens.

$$CCN = \frac{\sum_{\omega_i \in (\Omega_R \cup \Omega_S)} (I_S(\omega_i) - \mu_S)(I_R(\omega_i) - \mu_R)}{\sqrt{(\sum_{\omega_S \in \Omega_S} (I_S(\omega_S) - \mu_S)^2)(\sum_{\omega_R \in \Omega_R} (I_R(\omega_R) - \mu_R)^2)}} \quad (6.15)$$

6.1.2.3 Informação mútua

A **Informação Mútua (IM)** [89] representa uma relação estatística entre dois sistemas. Ela é baseada na entropia de *Shannon*[104], que calcula o nível de incerteza de um sistema através da probabilidade de ocorrência dos seus elementos, como em (6.16), em que p_e é a probabilidade de ocorrência do elemento e dentro de um conjunto E .

$$H(E) = - \sum p_e \log(p_e) \quad (6.16)$$

Conjuntos com elevadas probabilidades, ou seja, repetidas ocorrências de poucos elementos, são previsíveis, pois existe uma grande chance que, na seleção aleatória de um elemento, seja escolhido o de maior ocorrência, provocando um baixo nível de incerteza e entropia. Ao contrário, nos conjuntos de distribuição uniforme, é difícil prever qual deles será escolhido aleatoriamente. Por isso, sistemas desse tipo possuem um alto nível de incerteza e entropia.

Em outra perspectiva, a entropia também pode medir o nível de informação de um conjunto, pois elevadas probabilidades representam sistemas com muitas informações e probabilidades uniformes caracterizam sistemas com poucas informações. Assim, quanto menor a entropia, mais informação o sistema possui.

No processamento de imagens, a entropia é calculada pelas frequências de ocorrência das intensidades E de uma imagem I . Assim, em (6.16), p_e seria a probabilidade de ocorrência da intensidade e , a qual pode ser definida como em (6.17). O conjunto formado pela união das probabilidades dos elementos e de uma imagem é denominado de histograma da imagem, definido como P_I em (6.18).

$$p_e = N(\{\omega_i | I(\omega_i) = e\}) \quad \forall \omega_i \in \Omega \quad (6.17)$$

$$P_I = \bigcup_{e \in E} p_e \quad (6.18)$$

Dentro desse contexto, imagens com distribuições uniformes de intensidades possuem pequenas quantidades de informações e alta entropia. Diferentemente, as imagens com altas frequências em limitadas intensidades possuem um alto nível de informação e uma baixa entropia [90]. Um exemplo disto é o estudo de Woods *et al*[119], o qual observou imagens médicas de diferentes modalidades, e mostrou que, independentes do tipo de imagens, as regiões de tecidos são representadas por uma grande concentração de intensidades similares, provocando uma baixa entropia na imagem.

A consequência da observação de Woods *et al* é que o alinhamento correto entre imagens gera um histograma de união das imagens com grandes quantidades de informações, as quais são produzidas pela sobreposição das regiões semelhantes. Ao contrário disto, os alinhamentos errados, tendem a gerar um histograma de união mais uniforme, nivelando as ocorrências das intensidades. Essa observação foi utilizada por Hill *et al*[45], que verificou a semelhança entre imagens através da entropia da união $H(I_S, I_R)$, calculada com base no histograma de união. Assim, quanto menor for $H(I_S, I_R)$, melhor será o alinhamento entre as imagens I_S e I_R e, quanto maior for $H(I_S, I_R)$, pior será o alinhamento.

A informação mútua aproveita-se do mesmo princípio de Hill *et al*. Ela é definida por (6.19): a soma das entropias das imagens, $H(I_S)$ e $H(I_R)$, subtraída da entropia da união $H(I_S, I_R)$. Como consequência, quanto melhor for o alinhamento, menor será $H(I_S, I_R)$ e maior será a IM, e, quanto pior for o alinhamento, maior será $H(I_S, I_R)$ e menor será a IM. Os valores dessa medida variam de 0(zero) a 1.

$$IM = H(I_S) + H(I_R) - H(I_S, I_R) \quad (6.19)$$

Entretanto, foi demonstrado em Pluim *et al*[90] que a informação mútua é dependente do *overlap* entre as duas imagens, o qual pode sofrer alterações, devido às transformações da imagem sensível. Para remover essa dependência, deve-se normalizar a informação mútua de acordo com o tamanho do *overlap*. Isso é feito através da **Informação Mútua Normalizada (IMN)**, definida por (6.20), na qual soma das entropias das imagens é dividida pela entropia da união. Na informação mútua normalizada, do mesmo modo que na IM, os maiores valores significam melhores alinhamentos e os menores valores representam os piores alinhamentos, sendo que seus valores variam entre 1 e 2.

$$IMN = \frac{H(I_S) + H(I_R)}{H(I_S, I_R)} \quad (6.20)$$

6.1.3 Medidas de distância

A última classe de medidas é baseada nas localizações das características presentes nas duas imagens[41]. Assim, sendo Ω um espaço métrico de norma Euclidiana $\|\omega\|$, no qual Ω^o , Ω^c e Ω^b são, respectivamente, seus interiores, complementos e borda, a distância entre dois pontos ω_S e ω_R , pertencentes a Ω_S e Ω_R , subconjuntos de Ω , é definida como em (6.21).

$$\|\omega_R - \omega_S\| \quad (6.21)$$

Mais precisamente, a distância entre características presentes nas duas imagens pode ser vista como a distância entre elementos de dois conjuntos D , definido em (2.4). Dessa forma, sendo D_R o conjunto de características da imagem I_R e D_S o conjunto de características da imagem I_S , a distância da fórmula (6.21) é calculada com ω_R representando os pontos do conjunto D_R e ω_S representando o mesmo ponto no conjunto D_S .

Zitovar e Flusser[122] observaram que a avaliação do registro, através das distâncias entre características utilizadas no cálculo dos parâmetros da função de transformação, não é uma boa medida de avaliação, pois ela só indica o quanto essas características foram ajustadas pelo método escolhido. Além disso, dependendo do grau de liberdade do modelo de transformação, a distância entre essas características pode ser reduzida a 0(zero), sem necessariamente as imagens estarem alinhadas. Uma melhor avaliação do registro pela distância é realizada utilizando características que não foram usadas no cálculo dos parâmetros da função de transformação, denominadas de pontos de teste.

Uma simples medida de distância que se utiliza dos pontos de teste é a distância média. A **Distância Média (DM)** entre pontos de teste foi adotada em Ehrhardt *et al*[26], no registro entre tomossíntese mamária e mamogramas. Neste registro os pontos de teste utilizados foram manualmente selecionados nas duas imagens. Em Saskia *et al*[100] e Díez *et al*[24], o registro entre mamogramas também é avaliado pela distância média entre pontos de teste, que, neste caso, foram as lesões(calcificações) presentes nas imagens. Em Lee *et al*[65], o registro de termogramas são avaliados por pontos de teste colocados no corpo da paciente antes da aquisição das imagens.

6.1.3.1 Distância de Hausdorff

Outra forma de avaliar o registro pela distância entre pontos é através da **Distância de Hausdorff (DH)**[49]. Nessa medida, sendo D_S e D_R conjuntos de pontos pertencentes à Ω , para calcular a distância de Hausdorff entre eles, inicialmente é calculada a distância do conjunto D_S para D_R e, em seguida, a distância de D_R para D_S . O resultado final será a maior das duas distâncias calculadas. Assim, sendo $d(D_S, D_R)$ a distância de D_S para D_R e $d(D_R, D_S)$ a distância de D_R para D_S a distância de Hausdorff entre D_S e D_R pode ser expressa como em (6.22).

$$DH(D_R, D_S) = \max(d(D_R, D_S), d(D_S, D_R)) \quad (6.22)$$

A distância entre os conjuntos D_R e D_S , é calculada como em (6.23), através da maior das distâncias entre os pontos $\omega_R \in D_R$, para o conjunto D_S , expressas por $d(\omega_R, D_S)$. O cálculo de $d(\omega_R, D_S)$ pode ser feito medindo a distância Euclidiana, entre o ponto ω_R e todos os pontos de D_S , como feito em (6.24), sendo o resultado a menor norma calculada. Resumidamente, a distância entre um ponto e um conjunto é igual à distância entre este ponto e o ponto mais próximo pertencente ao conjunto analisado. Assim, a distância de Hausdorff é a maior distância entre as distâncias de um ponto de D_S para D_R ou entre um ponto de D_R para D_S , tendo que $DH(D_R, D_S) = DH(D_S, D_R)$.

$$d(D_R, D_S) = \max_{\omega_R \in D_R} (d(\omega_R, D_S)) \quad (6.23)$$

$$d(\omega_R, D_S) = \min_{\omega_S \in D_S} (\|\omega_R - \omega_S\|) \quad (6.24)$$

Utilizando a distância de Hausdorff nas imagens térmicas I_S e I_R , o nível de alinhamento entre elas pode ser medido por $DH(\Omega_R^1, \Omega_S^1)$, sendo Ω_R^1 e Ω_S^1 os conjuntos formados pelos pixels da área de interesse, definidos na seção 6.1.1. Esse raciocínio foi utilizado por Klein *et al* [61], para avaliar registro de imagens de entre superfícies.

Outra forma de calcular a distância de Hausdorff é através do corpo paralelo delta (*delta-parallel body*) [28]. O corpo paralelo delta do conjunto Ω^1 , subconjunto de Ω , é formado pelo conjunto de pontos pertencentes à Ω que distam menor ou igual à δ do conjunto Ω^1 , como é expresso em (6.25) [28].

$$\Omega_\delta^1 = \{\omega \in \Omega \mid \|\omega_c - \omega\| \leq \delta, \forall \omega_c \in \Omega^1\} \Leftrightarrow \{\omega \in \Omega \mid d(\omega, \Omega^1) \leq \delta\} \quad (6.25)$$

Utilizando do corpo paralelo delta, o cálculo da distância de Hausdorff entre dois conjuntos fechados Ω_R^1 e Ω_S^1 , subconjuntos de Ω , é definida como em (6.26): o menor δ para o qual o corpo paralelo delta do conjunto Ω_R^1 contém o conjunto Ω_S^1 e vice-versa. Um estudo detalhando sobre a distância de Hausdorff, inclusive com algoritmos de implementação, pode ser visto em Conci *et al*[21], em que os autores afirmam que a distância de Hausdorff é uma medida bastante sensível à discrepância na borda das imagens, podendo gerar valores não muito confiáveis.

$$DH(\Omega_S^1, \Omega_R^1) = \min \{\delta \mid \Omega_S^1 \subset \Omega_\delta^S \wedge \Omega_R^1 \subset \Omega_\delta^R\} \quad (6.26)$$

6.1.4 Observações sobre os avaliadores

Dentre as medidas apresentadas, é possível que nem todas possam funcionar de forma adequada como avaliador do registro. Por exemplo, devido à sequência de imagens de uma paciente ser capturada por protocolos dinâmicos, pequenas variações de temperatura são induzidas inicialmente na paciente, gerando imagens com diferenças de intensidades e, devido a isso, algumas das medidas baseadas nas intensidades podem apresentar resultados insatisfatórios em alguns casos. Nas medidas de sobreposição, problemas podem ocorrer porque as movimentações das pacientes alteram a forma e volume do conjunto Ω^1 , utilizado no cálculo dessas medidas. Por fim, a dificuldade das medidas baseadas em distâncias é a identificação de pontos característicos nas imagens dessa modalidade.

Diante do exposto acima, espera-se que, nas imagens térmicas, as medidas baseadas nas intensidades que são mais independentes das variações nos valores dos pixels, como a CCN e IMN, possam apresentar melhores resultados que a SQD. Da mesma maneira, nas medidas baseadas em sobreposição de conjunto, tem-se a expectativa de que as medidas de concordância apresentem melhores resultados do que as medidas de erro. Por fim, devido à alta sensibilidade, a distância de Hausdorff pode mostrar-se insatisfatória e a distância média entre pontos de teste, devido a sua difícil implementação, torna-se inviável na avaliação do registro.

6.2 Comparação das medidas de similaridade

A comparação das medidas é iniciada com a criação do conjunto de teste, formado por imagens reais de pacientes do DMR, junto com variações destas, criadas por transformações. As imagens desse conjunto são comparadas quantitativamente pelas medidas de similaridade e seus resultados são confrontados com os da avaliação de um especialista, considerada como padrão. Ao final, a medida de similaridade que mais se aproximou da análise do especialista é escolhida como a ideal.

O conjunto de imagens utilizado na comparação é elaborado a partir das imagens de 6 pacientes, tendo cada paciente 39 imagens, 20 imagens originais e 19 imagens transformadas. Na criação das imagens transformadas, uma das 20 imagens é escolhida como referência e as demais são registradas como na seção 4.6, através de um método previamente desenvolvido em Galvao *et al*[33]. Assim, as 39 imagens são divididas em 1 imagem de referência, 19 imagens originais e 19 imagens transformadas, como ilustrado na Figura 6.2a, onde as imagens I_i , com $i = [1 \dots 20]$, são as imagens originais da paciente, sendo a I_1 escolhida como referência, e as imagens I_i^T , com $i = [2 \dots 20]$, são as transformações realizadas nas imagens originais.

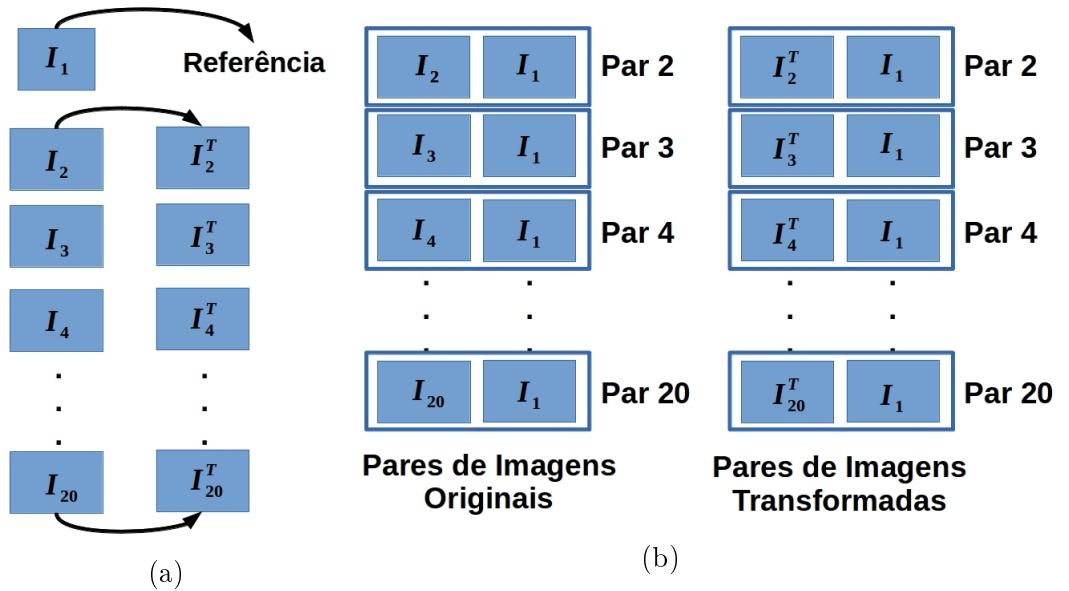


Figura 6.2: Método de comparação: (a) criação das imagens transformadas e (b) organização dos pares que serão comparados.

As 39 imagens da paciente são organizadas em pares conforme a Figura 6.2b, 19 pares de imagens originais e 19 pares de imagens transformadas. Cada par é constituído pela imagem de referência mais uma das imagens originais ou transformadas, sendo o número do par o mesmo da imagem original ou transformada. Assim, para cada par

formado por uma imagem original, existe outro equivalente, formado por uma imagem transformada, gerando uma dupla de pares equivalente. Os pares da dupla são comparados através das medidas de similaridade e cada medida indicará qual deles possui imagens mais semelhantes, como na Figura 6.3. Os resultados obtidos são confrontados com os de um especialista e utilizados na escolha do avaliador de similaridade.

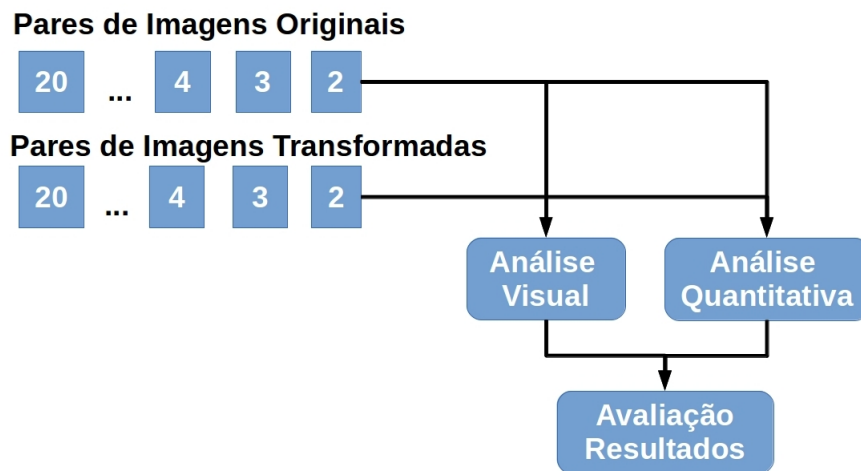


Figura 6.3: Análise dos pares de uma paciente do conjunto de teste.

Um exemplo dessa metodologia pode ser visto através das imagens da Figura 6.4, na qual estão, respectivamente, a imagem de referência, a imagem original e a sua transformada. Com essas imagens, são formados: um par original, composto pela Figura 6.4a e 6.4b; e um par transformado, composto pela Figura 6.4a e 6.4c. Os pares formados são analisados pelo especialista e quantitativamente, gerando tabelas como a 6.1, em que a linha superior representa os resultados do par da imagem original e a inferior os do par da imagem transformada, sendo a primeira coluna a análise do especialista e as demais a análise quantitativa.




Figura 6.4: Imagens de uma paciente submetida ao protocolo dinâmico.

Se para o especialista o par da imagem transformada é mais semelhante que o par da imagem original, as medidas de similaridade também devem apresentar valores melhores

Tabela 6.1: Resultados da análise visual e quantitativa dos pares da Figura 6.4.

Vis.	Jaccard	Dice	SR	FP	FN	SQD	CCN	IMN	DH	DM
-	0.9695	0.9409	0.9820	0.0425	0.0179	630.56	0.8932	1.2513	26	8.56
+	0.9936	0.9872	0.9940	0.0067	0.0059	106.67	0.9111	1.3155	193	11.71

para o par transformado. Ao final, as medidas mais adequadas serão as que possuírem mais resultados em acordo com a análise do especialista.

Na tabela 6.1, os melhores valores de cada análise foram destacados de azul. Dessa forma, para o especialista, o par mais semelhante foi o da imagem transformada. De acordo com essa classificação estão o coeficiente de Dice, o coeficiente de Jaccard, a SR, o FP, o FN, a SQD, a CCN e a IMN. Entretanto, a distância de Hausdorff e a distância média entre pontos de teste informaram o contrário da análise visual. A seção seguinte explica como esses resultados são obtidos.

6.2.1 Avaliação quantitativa realizada

A avaliação quantitativa é realizada através das medidas de similaridade apresentadas anteriormente, resumidas na tabela 6.2, na qual, na primeira linha, tem-se a classe das medidas, na segunda linha, tem-se o nome das medidas e, nas duas últimas, estão os valores das medidas para o melhor caso e pior caso. No entanto, a utilização dessas medidas necessita de um processamento prévio das imagens de cada par. Neste processamento, uma imagem $I : \Omega \rightarrow E$ será representada como um conjunto de pixels organizados pelo espaço métrico igual ao apresentado na seção 2.1.1, com $\Omega \subset \mathbb{N}$, $\omega = (x, y)$ e intensidade que variam em tonalidades de cinza de 0 a 255, sendo 0 a tonalidade mais escura e 255 a tonalidade mais clara.

Tabela 6.2: Resumo das medidas de similaridade.

Classificação	Medida	Melhor	Pior
Sobreposição	Dice	1	0
	Jaccard	1	0
	SR	1	0
	FN	0	1
	FP	0	1
Intensidade	SSD	0	∞
	CCN	1	0
	IMN	1	2
Distância	DM	0	∞
	DH	0	∞

No cálculo das medidas de sobreposição, a identificação dos conjuntos Ω_R^1 e Ω_S^1 é feita

com a limiarização adaptativa de Otsu, explicada na seção 4.1.1, criando imagens como as da Figura 6.5a, que é a imagem da Figura 6.4a na forma binarizada. Assim, através das imagens I_R^1 e I_S^1 , que são as imagens I_R e I_S limiarizadas, as áreas utilizadas nos cálculos das medidas de sobreposição são identificadas conforme as fórmulas da seção 6.1.1, substituindo o valor 1 pela intensidade branca, 255.




Figura 6.5: Processamento para o cálculo das medidas de similaridade: (a) imagem binarizada, (b) bordas da paciente e (c) identificação dos mamilos.

As mesmas imagens de limiarização I_R^1 e I_S^1 são utilizadas como máscaras nos cálculos das medidas de intensidade. Através delas, os pixels ω_i analisados serão somente os pertencentes ao conjunto $\Omega_S^1 \cup \Omega_R^1$. Entretanto, a intensidade utilizada nos cálculos será a da imagem não binarizada, ou seja, $I_S(\omega_i)$ e $I_R(\omega_i)$. Para a SQD, além da utilização da máscara, o seu cálculo é feito conforme a fórmula (6.13), utilizando a vizinhança do pixel.

Na distância de Hausdorff, os conjuntos utilizados no cálculo da medida são formados pelos pontos pertencentes às bordas das áreas Ω_S^1 e Ω_R^1 , os quais são representados por $\Omega_R^{1,b}$ e $\Omega_S^{1,b}$, ilustrados na Figura 6.5b. A criação dessas imagens é feita através de um algoritmo de varredura, comentado na seção 4.1.2. Assim, sendo I_S^b e I_R^b as imagens das bordas de I_S^1 e I_R^1 , pode-se definir $\Omega_R^{1,b}$ e $\Omega_S^{1,b}$ como sendo:

$$\Omega_R^{1,b} = \{\omega_i \in \Omega_R \mid I_R^b(\omega_i) = 255\} \quad (6.27)$$

$$\Omega_S^{1,b} = \{\omega_i \in \Omega_S \mid I_S^b(\omega_i) = 255\} \quad (6.28)$$

Com essa definição, a distância de Hausdorff entre as imagens I_S e I_R é calculada como $DH(\Omega_R^{1,b}; \Omega_S^{1,b})$. Nesse cálculo, as distâncias entre os pontos dos conjuntos são medidas pela norma Euclidiana, expressão (6.29), na qual $\omega_s \in \Omega_S^{1,b}$ e $\omega_R \in \Omega_R^{1,b}$, sendo $\omega_s = (x_s, y_s)$ e $\omega_R = (x_r, y_r)$.

$$\|\omega_s - \omega_r\| = \sqrt{(x_r - x_s)^2 + (y_r - y_s)^2} \quad (6.29)$$

Por fim, para verificar o comportamento dos pontos de teste utilizados nas demais medidas de distâncias, pontos não empregados no cálculo da função de transformação são identificados manualmente nas imagens I_S e I_R . Estes pontos são os mamilos, representados pelos círculos vermelhos da Figura 6.5c. A média entre as suas distâncias é calculada utilizando a norma Euclidiana, exibida em (6.29), sendo agora ω_s e ω_r os mamilos das imagens I_S e I_R . Dessa maneira, as distâncias entre os mamilos, assim como a sua média, são informadas em pixels.

6.3 Resultados da comparação das medidas

Ao aplicar a metodologia acima no conjunto de teste formado pelas 6 pacientes, 114 duplas de pares de imagens originais e transformadas são geradas e analisadas visualmente. Entretanto, em apenas 55 delas foi possível realizar a análise pelo especialista e, devido a isso, a análise quantitativa é realizada somente nessas 55 duplas conclusivas.

Os resultados das duplas de pares da paciente 1 são exibidos na Tabela 6.3. Nela, as linhas estão divididas em duas partes, a superior representando os resultados do par da imagem original e a inferior o da imagem transformada. Os valores das medidas de similaridade estão presentes nas colunas, sendo a primeira a avaliação do especialista, com “+”, para o par mais semelhante, e “−”, para o menos semelhantes.

Através da Tabela 6.3, é possível perceber quais as medidas que apontaram resultados semelhantes aos da análise do especialista e as que mostraram resultados contrários, sendo os resultados semelhantes destacados de azul e os contrários destacados de vermelho. Dessa forma, nota-se que as medidas de Dice, Jaccard, SR, FP, FN, SQD, CCN, IMN, DH e DM tiveram respectivamente 9, 9, 8, 10, 8, 9, 9, 9, 8 e 8 casos de semelhança com o especialistas e 2, 2, 3, 1, 3, 2, 2, 2, 3 e 3, casos de desacordo. Estendendo a mesma contagem para as 55 duplas analisadas, têm-se os números apresentados no gráfico da Figura 6.6, no qual as barras em azul indicam o total de concordância para cada medida e as em vermelho indicam o número de discordâncias.

Verificando os resultados apresentados, percebe-se que, na maioria dos grupo, existem uma ou mais medidas que apresentaram bons resultados. No grupo de intensidades, tanto a SSD como a IMN apresentaram um bom desempenho. No grupo de sobreposição,

Tabela 6.3: Análise visual e quantitativa dos pares da paciente 1

	Vis	Dice	Jaccard	SR	FP	FN	SSD	CCN	IMN	DH	DM
1.1	-	0.9863	0.973	0.989	0.0166	0.0106	214.33	0.9708	1.2546	3	7,64
	+	0.9961	0.992	0.995	0.0032	0.0044	99.399	0.9825	1.2808	1	1,62
1.2	-	0.991	0.982	0.993	0.0113	0.0060	127.76	0.9825	1.2827	3	2,80
	+	0.9971	0.994	0.995	0.0008	0.0048	64.128	0.9764	1.3244	0	2,12
1.3	-	0.9869	0.974	0.989	0.0160	0.0100	185.31	0.9725	1.2844	3	4,95
	+	0.9966	0.993	0.995	0.0025	0.0040	69.856	0.9729	1.3051	1	6,47
1.4	+	0.9936	0.987	0.995	0.0083	0.0042	72.235	0.9895	1.3429	0	2,51
	-	0.9972	0.994	0.996	0.0022	0.0032	73.567	0.9885	1.2953	1	7,07
1.6	-	0.9910	0.982	0.984	0.0028	0.0150	93.455	0.9867	1.3416	0	4,63
	+	0.9963	0.992	0.994	0.0020	0.0052	46.528	0.990	1.3242	174	1,50
1.7	-	0.9943	0.988	0.989	0.0007	0.0105	51.210	0.9932	1.3648	4	4,89
	+	0.9990	0.998	0.998	0.0004	0.0015	8.5709	0.9987	1.4052	0	3,64
1.9	-	0.9972	0.994	0.997	0.0031	0.0023	25.994	0.9962	1.4000	1	4,91
	+	0.9976	0.995	0.997	0.0026	0.0020	27.823	0.9960	1.3952	155	5,70
1.11	-	0.9925	0.985	0.990	0.0055	0.0094	92.130	0.9869	1.3054	3	9,05
	+	0.9968	0.993	0.995	0.0014	0.0049	35.588	0.9883	1.3495	0	6,26
1.14	+	0.9907	0.981	0.986	0.0047	0.0137	167.40	0.9759	1.2817	4	6,03
	-	0.9918	0.983	0.990	0.0067	0.0095	165.84	0.9691	1.2415	142	6,40
1.16	-	0.9903	0.980	0.986	0.0055	0.0137	149.67	0.9792	1.2941	5	6,22
	+	0.9957	0.991	0.995	0.0039	0.0044	50.361	0.9924	1.3131	2	9,07
1.20	-	0.9888	0.977	0.996	0.0187	0.0034	183.30	0.9739	1.2661	1	7,64
	+	0.9925	0.985	0.992	0.0078	0.0070	149.95	0.9750	1.2763	5	1,62




Figura 6.6: Resumo da comparação das medidas de similaridade.

foram Dice e Jaccard. No grupo de distâncias, nenhuma das medidas teve resultados satisfatórios. Entretanto, no geral, foram Dice e Jaccard que apresentaram o melhor desempenho e, por isso, são as mais indicadas como avaliadores de similaridade das imagens em questão.

Porém, ao observar somente os casos em que Dice e Jaccard falharam, exibidos na tabela 6.4, nota-se que, em 100% deles, a SR e FN também falharam, em 80%, a SSD falhou, em 60%, deles a CCN e a DH falharam, em 40%, deles a FP falhou e, em 20%, ou seja, somente 1 caso, a IMN também falhou. Com isso, percebe-se que uma avaliação mais precisa pode ser obtida unido os resultados das medidas de Dice ou de Jaccard aos da IMN, que foi a que melhor analisou os casos em que as primeiras falharam. Essa união também cria um avaliador que trabalha com diferentes informações das imagens,

a sobreposição e as intensidades dos pixels, sendo este avaliador mais confiável que as demais medidas, pois não é direcionado a apenas um determinado tipo de informação.

Tabela 6.4: Análise quantitativa dos casos em que Dice e Jaccard falharam.

	Visual	Dice	Jaccar	SR	FP	FN	SQD	CCN	IMN	DH.
1.4	+	0.9936	0.9874	0.9957	0.0083	0.0042	72.235	0.9895	1.3429	0
	-	0.9972	0.9946	0.9968	0.0022	0.0032	73.567	0.9885	1.2953	1
1.14	+	0.9907	0.9816	0.9862	0.0057	0.0137	167.40	0.9759	1.2817	4
	-	0.9918	0.9838	0.9904	0.0047	0.0095	165.84	0.9691	1.2415	142
3.1	-	0.9871	0.9746	0.9798	0.0054	0.0201	408.90	0.9441	1.2416	4
	+	0.9829	0.9665	0.9715	0.0056	0.0284	504.16	0.8821	1.2515	5
3.2	-	0.9885	0.9774	0.9863	0.0091	0.0136	232.26	0.9591	1.2753	1
	+	0.9847	0.9699	0.9740	0.0044	0.0259	415.36	0.8728	1.2644	5
3.4	-	0.9798	0.9605	0.9737	0.0139	0.0262	444.50	0.9210	1.2338	6
	+	0.9794	0.9596	0.9692	0.0102	0.0307	553.07	0.8207	1.2459	5

Uma provável união dessas medidas é a soma dos resultados de Dice ou Jaccard com os da IMN. Entre as duas medidas de sobreposição, Dice é preferível por produzir valores mais expressivos do que Jaccard, elevando a participação das medidas de sobreposição na união. Assim, o novo avaliador sugerido pode ser calculado como na fórmula (6.30): a soma o resultado da medida de Dice com os da IMN. Essa Nova Medida (NM) gera valores entre 1 e 3, sendo o valor 1 obtido quando Dice é 0 e a IMN é 1, representando uma grande desigualdade, e o valor 3 obtido quando Dice é 1 e a IMN é 2, significando uma grande semelhança entre as imagens analisadas.

$$NM = INM + DICE \quad (6.30)$$

Para averiguar o comportamento da nova medida, a mesma metodologia utilizada nas análises das medidas anteriores é efetuada. O resultado dessa averiguação pode ser visto no gráfico da Figura 6.7, que une os valores do gráfico da Figura 6.6 com os obtidos pelo avaliador sugerido. De forma geral, os resultados do novo avaliador superaram os resultados de todas as medidas anteriores, inclusive as de Jaccard e Dice, medidas que obtiveram os melhores desempenhos anteriores. Com essas observações, é possível notar que, entre as medidas analisadas, a nova medida foi a mais adequada para medir o nível de semelhança entre as imagens, sendo ela a escolhida como avaliador do método de registro.




Figura 6.7: Resumo da comparação com a Nova Medida.

6.4 Considerações finais sobre o estudo das medidas de similaridade

Em síntese, este capítulo apresentou uma revisão das medidas de similaridade utilizadas em registro de imagens e o comportamento destas medidas na avaliação da similaridade entre as imagens térmicas das mamas. Um total de 10 avaliadores de similaridade foram analisados, sendo que, 5 desses avaliadores são baseados na sobreposição de conjuntos, 3 são baseados nas intensidades das imagens e 2 são baseados nas distâncias entre pontos.

Os resultados obtidos, pelas execuções dessas medidas em um conjunto de teste selecionado, foram comparados aos de uma avaliação por um especialista. Ao final, o número de acerto e erros de cada medida foi contabilizado. No grupo das medidas baseadas em intensidades, as com mais acertos foram a IMN junto com SQD e, no grupo das medidas baseadas em sobreposição, as melhores foram as de Dice e Jaccard. As medidas baseadas em distâncias, distância de Hausdorff e distância média entre os mamilos, não apresentaram resultados satisfatórios, mostrando-se inadequadas para as imagens em questão.

Dentre todos os avaliadores analisados, os melhores resultados foram obtidos pelo coeficiente de Dice e Jaccard. Entretanto, através desses resultados, observou-se que, ao unir o coeficiente de Dice com a informação mútua normalizada, é possível criar um avaliador melhor, que utiliza informações do universo das medidas de sobreposição e das intensidades dos pixels. A eficiência desse novo avaliador foi confirmada através da sua comparação com as outras medidas. Esses novos resultados mostraram que o novo avaliador é mais adequado para medir a similaridade das imagens térmicas do que os demais e, por isso foi escolhido como medida de similaridade utilizada pelo método de registro desenvolvido neste trabalho.

Capítulo 7

Resultados

A avaliação da execução do método de registro desenvolvido é feita utilizando as imagens do DMR. Para isso, uma amostra de teste é criada com 23 pacientes aleatoriamente selecionadas. Dentre estas, 8 são saudáveis, 7 são doentes e as 8 restantes não possuem diagnóstico. Além disso, dentro desta amostra, também é possível ver uma grande variedade no formato das mamas e do corpo das pacientes, com pacientes de mamas pouco volumosas, como a da Figura 7.1a, de mamas volumosas, como a da Figura 7.1b, pacientes obesas, como a da Figura 7.1c, e pacientes mastectomizadas, como a da Figura 7.1d.




Figura 7.1: Diversidade de pacientes da amostra aleatória do DMR.

A fim de facilitar a sua identificação nos resultados, as pacientes selecionadas foram numeradas de 1 a 23, sendo as 8 primeiras as saudáveis, as 7 seguintes as doentes e as 8 últimas as sem classificação. Além disso, sobre o formato das mamas e do corpo, percebe-se que as pacientes 1, 7, 12, 15 e 19 são visivelmente obesas, as 3, 8 e 18 possuem as mamas bastante pequenas, as pacientes 2, 6, 10, 13, 17 e 22 possuem mamas muito volumosas e as pacientes 11 e 20 são mastectomizadas. Essas observações são resumidas na Tabela 7.1, na qual cada linha simboliza uma paciente e os índices N, MG, MP, O e M significam, respectivamente, pacientes com mamas normais, pacientes com mamas volumosas, pacientes com mamas pequenas, pacientes obesas e pacientes mastectomizadas.

A realização dos testes sobre a amostra criada é feita por paciente, de acordo com a

Tabela 7.1: Classificação das pacientes da amostra analisada.

Saudáveis								Doentes							Sem Classificação							
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
O	MG	MP	N	N	MG	O	MP	N	MG	M	O	MG	N	O	N	MG	MP	O	M	N	MG	N

execução comentada na seção 4.6. Como a cada execução, pares de imagens são formados e registrados separadamente, os resultados dessa avaliação são analisados de forma individual e de forma coletiva. Nas avaliações individuais, os resultados são dispostos como se os pares fossem conjuntos independentes não pertencentes a nenhuma paciente. Na avaliação coletiva, esses resultados são agrupados por cada paciente. Em cada um desses tipos, a avaliação é feita medindo a similaridade dos pares antes e após o registro. Mais detalhes sobre essas análises são discutidos nas seções seguintes.

7.1 Análise individual

Na análise dos resultados de forma individual são verificados 437 registros de pares de imagens, formados pelos 19 pares de cada uma das 23 pacientes. Esses pares são avaliados, antes e após o registro, pelos medidores de similaridade apresentados no capítulo 6. Por exemplo, para o par 19 da paciente 6 os resultados obtidos são exibidos na Tabela 7.2, na qual, em cada coluna, está uma medida analisada e, nas linhas, estão os valores da comparação do par, antes do registro e após o registro, respectivamente.

Tabela 7.2: Análise quantitativa do par 19 da paciente 6.

	Dice	Jaccard	SR	FP	FN	SQD	CCN	IMN	DH	NM
Antes	0,9410	0,8885	0,9441	0,0621	0,0559	1482,6	0,7542	1,1499	35	2,090
Após	0,9914	0,9829	0,9934	0,0102	0,0066	169,64	0,9124	1,2928	136	2,284

Nesta análise, o cálculo dos valores são realizados de forma semelhante ao do capítulo 6. Nas medidas de sobreposição, as imagens comparadas são vistas como conjuntos de pixels que pertencem ou não ao corpo da paciente, conforme a fórmula (6.1). Na SQD, a diferença é calculada pela média das intensidades da vizinhança do pixel analisado, como em (6.13). Na distância de Hausdorff, os conjuntos dos pontos analisados são os formados pelo contorno do corpo da paciente.

Através dos valores obtidos em uma determinada medida, o registro do par pode ser visto como: satisfatório, se o resultado do par após o registro é melhor do que o resultado antes do registro; e insatisfatório, caso contrário. Na Tabela 7.2, os resultados satisfatórios foram destacados de azul e os insatisfatórios de vermelho. Dessa forma, é possível que,

em uma mesma análise, o par possa obter resultados satisfatórios em algumas medidas e insatisfatório em outras, como no caso acima, em que o registro foi satisfatório em quase todas as medidas, exceto para a distância de Hausdorff.

O resumo dessa análise, em todos os 437 pares de imagens registrados, é exibido na Tabela 7.3, na qual cada coluna expressa, em cada uma das medidas, o número e a porcentagem de pares que apresentaram resultados melhores após o registro. Nesta tabela, pelos coeficientes de Dice e de Jaccard, 404 desses pares apresentaram resultados melhores após o registro. Na SR, esse número foi de 354. No FP, foi de 372. No FN, foi de 354. Na SQD, foram 385 pares. Na CCN, são apenas 247. Na IMN, foram 353 pares melhorados. Na distância de Hausdorff, são 168 pares e, na nova medida, foram 373 pares. Em porcentagem, esses números são de 92%, 92%, 81%, 85%, 81%, 88%, 56%, 81%, 38% e 85% para Dice, Jaccard, SR, FP, FN, SQD, CCN, IMN, DH e a NM, respectivamente.

Tabela 7.3: Pares de imagens que melhoraram após o registro.

	Dice	Jaccard	SR	FP	FN	SQD	CCN	IMN	DH	NM
Quant.	404	404	354	372	354	385	247	353	168	373
Porc.	92%	92%	81%	85%	81%	88%	56%	81%	38%	85%

A avaliação geral dos valores obtidos na análise quantitativa individual pode ser vista através da média e do desvio padrão global dos resultados de cada uma das medidas, antes e após o registro. A média antes do registro é calculada através de todos os valores apresentados por uma determinada medida, nos pares antes do registro. Consequentemente, a média após o registro é feita pelos valores de similaridade dos pares formados após o registro. Da mesma forma, são feitos os cálculos do desvios padrão. Esses resultados são exibidos na Tabela 7.4, em que, na primeira linha, estão as médias de cada medida e, na segunda linha, estão os seus desvios padrão, sendo a parte superior de cada linha responsável pelos valores antes do registro e a inferior pelos valores após o registro. Por fim, as medidas, em que o método obteve melhores valores após o registro foram destacadas de azul e as em que ele não obteve foram destacadas de vermelho.

Tabela 7.4: Média e desvio padrão dos pares analisados.

	Dice	Jaccard	SR	FP	FN	SQD	CCN	IMN	DH	NM
Média	0,988	0,97749	0,988	0,0111	0,011	270,05	0,9643	1,316	6,3464	2,3050
	0,995	0,98864	0,994	0,0054	0,005	163,00	0,9636	1,328	57,010	2,3229
Desvio	0,011	0,02105	0,012	0,0112	0,012	302,03	0,0423	0,172	6,6582	0,1783
	0,005	0,01062	0,007	0,0051	0,007	170,17	0,0399	0,166	66,958	0,1691

Através dos valores apresentados na Tabela 7.4, percebe-se que, pela média, os pares analisados tornaram-se mais semelhantes após o registro para quase todas as medidas,

exceto para distância Hausdorff e a CCN. Esse registro também tornou os pares mais uniformes em relação as suas similaridades, pois ocorreu uma melhora geral no desvio padrão após o registro, a não ser pela distância de Hausdorff.

7.2 Análise por paciente

Na análise por paciente, os pares de imagens de uma mesma paciente são verificados em conjunto, analisando a melhora da semelhança entre eles e, conseqüentemente, o quanto as imagens da paciente tornaram-se mais alinhadas após o registro. Além disso, através dessa análise, é possível constatar para que tipo de pacientes o método é capaz de produzir melhores e piores resultados, proporcionando a verificação de informações que podem servir para que este método seja melhorado em trabalhos futuros.

Análogo à análise individual, a análise por pacientes também é feita através das medidas de similaridade apresentadas no capítulo 6, verificando a semelhanças dos pares de uma paciente antes e após o registro. Nesta análise, para cada paciente, são construídas tabelas semelhantes à 7.5, na qual estão os valores dos pares da paciente 6, sendo as colunas, os valores das medidas de similaridade calculadas e as linhas, o par analisado. Como em cada par os valores são calculados antes e após o registro, as linhas dessas tabelas são bifurcadas para que, na parte superior de cada linha, fiquem os valores das medidas do par antes do registro e, na parte inferior, fiquem os valores do par após o registro. Além disso, em cada linha, os valores em que o par após o registro foi melhor que o antes do registro são destacados de azul; caso o contrário, esses valores são destacados de vermelho.

Ao analisar detalhadamente a Tabela 7.5, percebe-se que, para os coeficientes de Dice e Jaccard, 18 dos 19 pares obtiveram melhores resultados após o registro. Na SR, também são 18. Na FP, foram os 19 pares. Na FN, são 18. Na SQD e CNN, são 18 pares melhorados. Na IMN, esse número é de 17. Na distância de Hausdorff, são 6 e, para a medida nova, são 18 pares melhorados. Em porcentagem, esses números são de 95%, 95%, 95%, 100%, 95%, 95%, 95%, 89%, 32% e 95% para Dice, Jaccard, SR, FP, FN, SQD, CCN, IMN, DH e a nova medida, respectivamente.

A análise anterior é feita em cada uma das pacientes analisadas. Os resultados obtidos são apresentados na Tabela 7.6, na qual as linhas representam cada uma das pacientes e as colunas informam a porcentagem de pares melhorados em cada paciente. Através desses valores, é possível perceber que, para as medidas mais indicadas (Dice, Jaccard, IMN e a Nova Medida), a melhora dos pares foi superior a 80% em grande parte das pacientes.

Tabela 7.5: Análise qualitativa dos pares da paciente 6.

	Dice	Jaccard	SR	FP	FN	SQD	CCN	IMN	DH	NM
1	0,9868	0,9740	0,9897	0,0160	0,0103	245,378	0,9607	1,3139	13,0	2,301
	0,9953	0,9906	0,9957	0,0051	0,0043	98,139	0,9706	1,3258	4,0	2,321
2	0,9890	0,9782	0,9963	0,0182	0,0037	194,219	0,9711	1,3156	2,0	2,305
	0,9963	0,9927	0,9965	0,0039	0,0035	89,827	0,9775	1,3777	112,0	2,374
3	0,9939	0,9879	0,9949	0,0071	0,0051	88,469	0,9855	1,3738	8,0	2,368
	0,9937	0,9874	0,9937	0,0064	0,0063	126,716	0,9820	1,3598	9,0	2,354
4	0,9772	0,9555	0,9683	0,0137	0,0317	495,016	0,9177	1,2211	5,0	2,198
	0,9935	0,9870	0,9935	0,0066	0,0065	126,716	0,9718	1,3598	191,0	2,353
5	0,9834	0,9673	0,9784	0,0116	0,0216	303,784	0,9477	1,2743	7,0	2,258
	0,9961	0,9921	0,9960	0,0037	0,0040	74,511	0,9892	1,3914	43,0	2,388
6	0,9795	0,9599	0,9739	0,0148	0,0261	393,639	0,9336	1,2963	11,0	2,276
	0,9936	0,9874	0,9924	0,0046	0,0076	120,814	0,9785	1,3172	4,0	2,311
7	0,9745	0,9502	0,9631	0,0139	0,0369	560,266	0,9142	1,2397	13,0	2,214
	0,9900	0,9802	0,9872	0,0069	0,0128	223,207	0,9601	1,2573	10,0	2,247
9	0,9730	0,9474	0,9653	0,0192	0,0347	742,091	0,8839	1,1861	8,0	2,159
	0,9904	0,9810	0,9856	0,0040	0,0144	278,589	0,9460	1,2409	12,0	2,231
10	0,9704	0,9425	0,9660	0,0251	0,0340	773,562	0,8792	1,1820	11,0	2,152
	0,9898	0,9799	0,9879	0,0065	0,0121	291,856	0,9358	1,2439	26,0	2,234
11	0,9772	0,9554	0,9826	0,0282	0,0174	508,015	0,9060	1,2598	21,0	2,237
	0,9928	0,9858	0,9931	0,0074	0,0069	244,716	0,9538	1,2494	15,0	2,242
12	0,9642	0,9308	0,9634	0,0351	0,0366	813,498	0,8586	1,2206	24,0	2,185
	0,9912	0,9826	0,9921	0,0097	0,0079	293,023	0,9417	1,2403	147,0	2,232
13	0,9561	0,9159	0,9488	0,0365	0,0512	1062,880	0,8317	1,1932	29,0	2,149
	0,9907	0,9816	0,9908	0,0094	0,0092	289,604	0,9498	1,2398	9,0	2,231
14	0,9462	0,8979	0,9411	0,0487	0,0589	1389,880	0,7811	1,1651	33,0	2,111
	0,9864	0,9732	0,9881	0,0152	0,0119	438,303	0,9244	1,2105	12,0	2,197
15	0,9551	0,9140	0,9599	0,0497	0,0401	1166,410	0,8160	1,1634	31,0	2,119
	0,9896	0,9794	0,9907	0,0115	0,0093	231,340	0,9437	1,2870	158,0	2,277
16	0,9551	0,9140	0,9616	0,0514	0,0384	1114,390	0,8183	1,1731	33,0	2,128
	0,9912	0,9826	0,9920	0,0096	0,0080	204,748	0,9348	1,2710	122,0	2,620
17	0,9468	0,8989	0,9509	0,0573	0,0491	1280,440	0,7783	1,1676	34,0	2,114
	0,9904	0,9810	0,9925	0,0109	0,0075	253,927	0,9006	1,2513	124,0	2,242
18	0,9465	0,8984	0,9478	0,0548	0,0522	1318,090	0,7830	1,1636	33,0	2,110
	0,9903	0,9808	0,9920	0,0108	0,0080	239,324	0,9110	1,2601	122,0	2,250
19	0,9410	0,8885	0,9441	0,0621	0,0559	1482,610	0,7542	1,1499	35,0	2,091
	0,9914	0,9829	0,9934	0,0102	0,0066	169,642	0,9124	1,2928	136,0	2,284
20	0,9586	0,9206	0,9632	0,0459	0,0368	964,496	0,8363	1,1856	29,0	2,144
	0,9938	0,9878	0,9941	0,0064	0,0059	183,524	0,9347	1,2910	143,0	2,285

Também é unânime entre as medidas que a paciente 1 não obteve grandes melhoras em seus pares após o registro.

Outra forma de analisar os resultados por paciente é calculando a média e o desvio padrão, antes e após o registro, verificando assim se ocorreu uma melhora geral no alinhamento entre as suas imagens. Por exemplo, utilizando os valores da análise quantitativa dos pares da paciente 6, apresentados na Tabela 7.5, chega-se aos resultados da Tabela 7.7. Nela, na primeira linha, estão presentes, respectivamente, as médias antes do registro e após o registro, e, na segunda linha, têm-se, na ordem, os desvios padrão antes do registro e após o registro. Nestas duas linhas, os melhores resultados após o registro

Tabela 7.6: Porcentagem de melhora por paciente em cada uma das medidas analisadas.

	Dice	Jaccard	SR	FP	FN	SQD	CCN	IMN	DH	NM
1	0,74	0,74	0,68	0,74	0,68	0,74	0,32	0,79	0,63	0,79
2	0,95	0,95	0,95	0,74	0,95	0,79	0,53	0,68	0,37	0,74
3	0,84	0,84	1,00	0,68	1,00	0,84	0,53	0,84	0,00	0,89
4	1,00	1,00	1,00	0,84	1,00	1,00	0,89	0,74	0,53	0,95
5	1,00	1,00	0,89	0,89	0,89	0,95	0,74	0,89	0,79	0,89
6	0,95	0,95	0,95	1,00	0,95	0,95	0,95	0,89	0,32	0,95
7	1,00	1,00	0,89	0,79	0,89	0,84	0,26	0,84	0,11	0,95
8	0,95	0,95	0,68	0,84	0,68	0,84	0,32	0,74	0,26	0,74
9	0,79	0,79	0,89	0,58	0,89	0,74	0,63	0,74	0,16	0,79
10	0,79	0,79	0,68	0,74	0,68	0,68	0,26	0,63	0,16	0,95
11	1,00	1,00	0,74	1,00	0,74	0,95	0,74	0,89	0,11	0,95
12	0,95	0,95	0,58	0,95	0,58	0,89	0,74	0,89	0,63	0,95
13	1,00	1,00	1,00	0,47	1,00	0,89	0,05	0,63	0,79	0,79
14	1,00	1,00	0,58	1,00	0,58	0,95	0,63	0,89	0,21	0,89
15	0,95	0,95	0,95	0,89	0,95	0,89	0,74	0,89	0,53	0,89
16	0,79	0,79	0,58	0,84	0,58	0,74	0,42	0,68	0,05	0,74
17	0,95	0,95	0,84	1,00	0,84	0,89	0,26	0,95	0,53	0,95
18	1,00	1,00	0,89	0,95	0,89	0,89	0,42	0,79	0,32	0,79
19	1,00	1,00	0,84	1,00	0,84	1,00	1,00	0,74	0,68	0,84
20	1,00	1,00	0,84	1,00	0,84	1,00	1,00	0,74	0,68	0,84
21	1,00	1,00	0,58	1,00	0,58	0,95	0,63	0,89	0,21	0,89
22	0,79	0,79	0,63	0,79	0,63	1,00	0,84	1,00	0,16	1,00
23	0,84	0,84	0,95	0,84	0,95	0,84	0,11	0,79	0,63	0,79

são destacados de azul e os que isso não ocorre são destacados de vermelho.

Tabela 7.7: Média e desvio padrão da análise quantitativa da paciente 6.

	Dice	Jaccard	SR	FP	FN	SQD	CCN	IMN	DH	NM
Média	0,9687	0,9399	0,9680	0,0305	0,0320	744,85	0,8779	1,2622	19,000	2,2309
	0,992	0,985	0,992	0,007	0,008	198,92	0,951	1,323	69,950	2,315
Desvio	0,0175	0,0329	0,0177	0,0191	0,0177	461,90	0,0757	0,1848	12,298	0,2022
	0,003	0,006	0,003	0,003	0,003	100,66	0,028	0,167	66,948	0,169

Os mesmos cálculos feitos para a paciente 6, na Tabela 7.7, são estendidos para as demais pacientes através das tabelas 7.8 e 7.9, nas quais a primeira é responsável pelos valores das médias de cada paciente, antes e após o registro, e a segunda é responsável pelos desvios padrão. Em ambas as tabelas, cada linha representa uma paciente analisada, sendo suas linhas divididas em duas para abrigarem os valores das médias e dos desvios padrão antes e após o registro, de modo que, na parte superior, estão os valores antes do registro e, na parte inferior, estão os valores após o registro. Da mesma forma que nas demais tabelas, os melhores valores após o registro são destacados de azul e os demais são destacados de vermelho.

Através das tabelas anteriores, nota-se que, para todas as pacientes, ocorreu uma melhora tanto na média como no desvio padrão em quase todas as medidas. Isso indica

Tabela 7.8: Média das medidas de similaridade dos pares de imagens por paciente.

	Dice	Jaccard	SR	FP	FN	SQD	CCN	IMN	DH	NM
1	0,9957	0,9914	0,9955	0,0042	0,0045	73,16	0,9916	1,3461	4,40	2,3417
	0,9972	0,9944	0,9967	0,0023	0,0033	36,79	0,9876	1,3692	33,15	2,3664
2	0,9823	0,9654	0,9771	0,0123	0,0229	486,08	0,9026	1,2678	11,90	2,3283
	0,9894	0,9792	0,9874	0,0084	0,0126	344,90	0,9173	1,2868	21,85	2,3217
3	0,9739	0,9495	0,9782	0,0304	0,0218	808,44	0,9084	1,2612	8,10	2,2502
	0,9862	0,9729	0,9947	0,0217	0,0053	448,94	0,9217	1,2856	106,00	2,2763
4	0,9896	0,9795	0,9852	0,0059	0,0148	222,49	0,9740	1,3220	5,30	2,2351
	0,9976	0,9952	0,9971	0,0016	0,0029	84,79	0,9825	1,3465	45,25	2,2718
5	0,9923	0,9847	0,9904	0,0058	0,0096	158,13	0,9831	1,3758	6,20	2,3116
	0,9963	0,9926	0,9949	0,0022	0,0051	83,59	0,9874	1,3991	11,95	2,3441
6	0,9687	0,9399	0,9680	0,0305	0,0320	744,86	0,8779	1,2622	19,00	2,3681
	0,9923	0,9848	0,9924	0,0074	0,0076	198,93	0,9509	1,3233	69,95	2,3954
7	0,9938	0,9877	0,9949	0,0073	0,0051	74,22	0,9905	1,3860	2,45	2,2309
	0,9968	0,9936	0,9976	0,0040	0,0024	42,02	0,9881	1,3913	19,10	2,3157
8	0,9940	0,9882	0,9931	0,0050	0,0069	151,13	0,9885	1,3776	2,60	2,3798
	0,9960	0,9920	0,9938	0,0016	0,0062	113,94	0,9872	1,3948	44,60	2,3880
9	0,9736	0,9492	0,9664	0,0190	0,0336	542,88	0,9204	1,2824	16,75	2,3415
	0,9954	0,9908	0,9952	0,0046	0,0048	115,20	0,9586	1,3243	65,70	2,3291
10	0,9914	0,9829	0,9931	0,0104	0,0069	267,60	0,9692	1,2837	4,30	2,3372
	0,9959	0,9919	0,9961	0,0042	0,0039	142,39	0,9742	1,3207	74,45	2,3434
11	0,9424	0,9349	0,9463	0,0116	0,0037	219,19	0,9228	1,2063	4,80	2,3717
	0,9469	0,9438	0,9486	0,0048	0,0014	94,66	0,9283	1,2850	15,10	2,3908
12	0,9897	0,9797	0,9833	0,0037	0,0167	298,51	0,9604	1,3034	8,25	2,2560
	0,9945	0,9890	0,9930	0,0039	0,0070	181,81	0,9303	1,3054	3,00	2,3022
13	0,9932	0,9866	0,9960	0,0095	0,0040	173,06	0,9780	1,3529	4,30	2,2564
	0,9971	0,9943	0,9975	0,0030	0,0025	74,09	0,9790	1,3787	69,45	2,2672
14	0,9829	0,9667	0,9818	0,0160	0,0182	490,27	0,9269	1,2442	8,65	2,3185
	0,9953	0,9907	0,9944	0,0037	0,0056	98,55	0,9688	1,2930	29,55	2,3197
15	0,9895	0,9794	0,9944	0,0153	0,0056	253,24	0,9695	1,3288	4,75	2,2750
	0,9928	0,9858	0,9954	0,0098	0,0046	184,83	0,9642	1,3373	77,70	2,3166
16	0,9884	0,9772	0,9889	0,0121	0,0111	204,77	0,9783	1,2980	5,70	2,3323
	0,9966	0,9932	0,9953	0,0021	0,0047	68,80	0,9717	1,3494	54,15	2,3279
17	0,9912	0,9826	0,9936	0,0112	0,0064	172,04	0,9810	1,3364	3,90	2,3854
	0,9977	0,9954	0,9983	0,0029	0,0017	54,10	0,9799	1,3553	55,60	2,3826
18	0,9907	0,9817	0,9906	0,0092	0,0094	185,85	0,9815	1,3088	2,85	2,1487
	0,9974	0,9948	0,9972	0,0024	0,0028	70,68	0,9942	1,3394	12,00	2,2319
19	0,9897	0,9796	0,9900	0,0106	0,0100	232,93	0,9687	1,3085	5,45	2,2900
	0,9964	0,9929	0,9969	0,0040	0,0031	93,21	0,9630	1,3401	101,80	2,3054
20	0,9932	0,9866	0,9960	0,0095	0,0040	173,06	0,9780	1,3529	4,30	2,2931
	0,9971	0,9943	0,9975	0,0030	0,0025	74,09	0,9790	1,3787	69,45	2,2998
21	0,9935	0,9871	0,9919	0,0049	0,0081	250,18	0,9530	1,2621	8,55	2,3461
	0,9956	0,9912	0,9954	0,0038	0,0046	164,19	0,9599	1,2869	59,15	2,3758
22	0,9840	0,9687	0,9797	0,0116	0,0203	238,21	0,9685	1,3524	9,50	2,2271
	0,9936	0,9873	0,9930	0,0046	0,0070	97,62	0,9302	1,4134	44,70	2,2884
23	0,9957	0,9914	0,9955	0,0042	0,0045	73,16	0,9916	1,3461	4,40	2,3417
	0,9972	0,9944	0,9967	0,0023	0,0033	36,79	0,9876	1,3692	33,15	2,3664

que, de forma geral, o método de registro desenvolvido conseguiu melhorar o alinhamento em todos os casos propostos, tornando as imagens mais similares e diminuindo o nível de diferença existente entre elas. Isto pode ser visto até mesmo na paciente 1, que obteve resultados insatisfatórios na análise anterior. Além disso, as medidas em que essa melhora

Tabela 7.9: Desvio padrão das medidas de similaridade por paciente.

	Dice	Jaccard	SR	FP	FN	SQD	CCN	IMN	Hausd.	Nova
1	0,0031	0,0061	0,0035	0,0034	0,0035	80,96	0,0094	0,1699	3,56	0,1730
	0,0014	0,0028	0,0019	0,0011	0,0019	25,47	0,0156	0,1589	64,88	0,1599
2	0,0088	0,0171	0,0126	0,0064	0,0126	273,48	0,0582	0,1760	11,93	0,1849
	0,0074	0,0142	0,0111	0,0041	0,0111	278,87	0,0800	0,1702	25,28	0,1738
3	0,0167	0,0313	0,0182	0,0171	0,0182	549,91	0,0605	0,1799	7,22	0,1966
	0,0070	0,0136	0,0045	0,0118	0,0045	237,13	0,0324	0,1719	63,10	0,1763
4	0,0070	0,0137	0,0098	0,0052	0,0098	159,33	0,0185	0,1660	4,18	0,1730
	0,0012	0,0024	0,0016	0,0008	0,0016	50,23	0,0143	0,1656	57,91	0,1665
5	0,0040	0,0079	0,0057	0,0059	0,0057	104,02	0,0108	0,1562	4,05	0,1603
	0,0016	0,0033	0,0034	0,0025	0,0034	48,95	0,0106	0,1469	35,23	0,1480
6	0,0175	0,0329	0,0177	0,0191	0,0177	461,91	0,0757	0,1848	12,30	0,2023
	0,0030	0,0060	0,0034	0,0035	0,0034	100,66	0,0276	0,1675	66,95	0,1699
7	0,0067	0,0131	0,0054	0,0085	0,0054	135,87	0,0175	0,1564	3,43	0,1632
	0,0020	0,0040	0,0017	0,0026	0,0017	42,47	0,0139	0,1530	47,13	0,1542
8	0,0024	0,0048	0,0027	0,0030	0,0027	103,17	0,0071	0,1583	1,82	0,1607
	0,0018	0,0036	0,0028	0,0008	0,0028	81,94	0,0077	0,1489	75,35	0,1501
9	0,0190	0,0358	0,0226	0,0156	0,0226	429,52	0,0623	0,1781	11,47	0,1972
	0,0042	0,0083	0,0056	0,0041	0,0056	104,82	0,0389	0,1641	3,19	0,1673
10	0,0045	0,0088	0,0048	0,0048	0,0048	112,83	0,0179	0,1673	2,31	0,1718
	0,0038	0,0075	0,0038	0,0042	0,0038	105,44	0,0342	0,1723	61,02	0,1746
11	0,0040	0,0080	0,0034	0,0051	0,0034	146,19	0,0165	0,1758	2,83	0,1799
	0,0017	0,0035	0,0022	0,0026	0,0022	82,96	0,0108	0,1698	62,15	0,1711
12	0,2219	0,2202	0,2228	0,0064	0,0044	177,98	0,2183	0,3360	3,82	0,5578
	0,2229	0,2222	0,2233	0,0022	0,0013	74,11	0,2192	0,1728	34,34	0,2935
13	0,0042	0,0082	0,0066	0,0029	0,0066	187,41	0,0245	0,1853	7,43	0,1894
	0,0025	0,0049	0,0028	0,0034	0,0028	135,05	0,0293	0,1710	2,96	0,1728
14	0,0039	0,0077	0,0036	0,0058	0,0036	116,89	0,0141	0,1599	3,76	0,1638
	0,0015	0,0030	0,0019	0,0015	0,0019	40,17	0,0148	0,1522	63,37	0,1530
15	0,0140	0,0267	0,0154	0,0127	0,0154	452,29	0,0662	0,2000	6,18	0,2139
	0,0021	0,0041	0,0033	0,0017	0,0033	50,52	0,0192	0,1700	51,74	0,1713
16	0,0069	0,0134	0,0053	0,0088	0,0053	224,66	0,0264	0,1713	2,99	0,1781
	0,0075	0,0146	0,0074	0,0083	0,0074	201,16	0,0375	0,1680	72,38	0,1719
17	0,0083	0,0161	0,0086	0,0081	0,0086	193,36	0,0202	0,1756	4,05	0,1839
	0,0017	0,0034	0,0025	0,0009	0,0025	53,57	0,0258	0,1643	71,11	0,1655
18	0,0068	0,0133	0,0046	0,0101	0,0046	180,01	0,0199	0,1658	3,21	0,1726
	0,0013	0,0025	0,0011	0,0021	0,0011	45,68	0,0160	0,1597	61,42	0,1605
19	0,0031	0,0061	0,0035	0,0034	0,0035	80,96	0,0094	0,1699	3,56	0,1762
	0,0014	0,0028	0,0019	0,0011	0,0019	25,47	0,0156	0,1589	64,88	0,1604
20	0,0088	0,0171	0,0126	0,0064	0,0126	273,48	0,0582	0,1760	11,93	0,1785
	0,0074	0,0142	0,0111	0,0041	0,0111	278,87	0,0800	0,1702	25,28	0,1644
21	0,0167	0,0313	0,0182	0,0171	0,0182	549,91	0,0605	0,1799	7,22	0,1638
	0,0070	0,0136	0,0045	0,0118	0,0045	237,13	0,0324	0,1719	63,10	0,1530
22	0,0070	0,0137	0,0098	0,0052	0,0098	159,33	0,0185	0,1660	4,18	0,1845
	0,0012	0,0024	0,0016	0,0008	0,0016	50,23	0,0143	0,1656	57,91	0,1782
23	0,0040	0,0079	0,0057	0,0059	0,0057	104,02	0,0108	0,1562	4,05	0,1849
	0,0016	0,0033	0,0034	0,0025	0,0034	48,95	0,0106	0,1469	35,23	0,2065

não foi constatada foram previamente vistas, no capítulo 6, como não ideais para a análise da similaridade nesse tipo de imagem.

7.3 Conclusões dos resultados

Com os resultados exibidos neste capítulo, percebe-se que, de uma forma geral, a execução do método apresentado, obteve bom desempenho. Em todos os tipos de análise realizada, seus valores foram satisfatórios, com taxas de melhora superior a 80% na maioria dos casos. Entretanto, durante a coleta dos resultados observou-se que, em alguns casos específicos, o método pode falhar. Isso ocorre devido às particularidades das imagens, principalmente na borda da paciente, utilizada na identificação das características guias do método. Uma melhor apreciação dos resultados obtidos nas seções anteriores pode ser vista a seguir.

7.3.1 Conclusões dos resultados da análise individual

Através da análise individual, percebe-se que, na maioria dos pares em que a melhora não foi possível, existe uma grande diferença entre a imagem sensível e a de referência, isto é, a paciente realizou uma grande quantidade de movimentos no intervalo de tempo entre as aquisições dessas imagens. Um exemplo disso é a Figura 7.2, na qual estão as imagens do par 12 da paciente 2. Na parte superior desta figura, estão, respectivamente, a imagem de referência, a sensível e a transformação produzida pelo registro. Na parte inferior, estão a subtração, entre a imagem de referência e a sensível, e a subtração entre a imagem de referência e a transformada.




Figura 7.2: Exemplo do par 12 da paciente 2, o qual não ocorreu uma melhora após o registro.

Verificando a imagem de referência e a sensível da Figura 7.2, percebe-se que, entre a captura dessas imagens, a paciente realizou um movimento de torção lateral, junto com o deslocamento do pescoço. Esse deslocamento alterou principalmente a área entre o pescoço e o braço direito da paciente, destacada de vermelho em ambas as imagens. Com a deformação, o ponto de junção entre o pescoço e o ombro, ponto *A.1*, é identificado de forma errada na imagem sensível, pois, de acordo com o algoritmo utilizado, ele será o ponto mais baixo da área em vermelho. A identificação errônea do ponto *A.1* gera a transformação exibida na Figura 7.2c, fazendo com que o par antes do registro seja mais semelhante que o par após o registro. Os resultados obtidos com a análise desse par são exibidos na Tabela 7.10.

Tabela 7.10: Análise quantitativa do par 12 da paciente 2 e do par 12 da paciente 1.

		Dice	Jaccar	SR	FP	FN	SQD	CCN	IMN	DH	NM
2.12	Antes	0,9747	0,95076	0,95538	0,0050	0,044	1015,1	0,826	1,182	2	2,156
	Após	0,9613	0,92548	0,94389	0,0206	0,056	1460,0	0,607	1,164	31	2,125
1.12	Antes	0,9981	0,99637	0,9971	0,0008	0,002	13,455	0,998	1,396	3	2,394
	Após	0,9973	0,99579	0,9953	0,0025	0,004	31,950	0,995	1,355	1	2,352

Em poucos casos de pares de imagens quase idênticas, as medidas também assinaram uma leve piora após o registro. Um exemplo disto é o par 12 da paciente 1, cujas subtrações antes e após o registro são exibidas na Figura 7.3, sendo Figura 7.3a a subtração do par antes do registro e a Figura 7.3b a do par após o registro. Através dessas figuras, pode-se notar uma grande semelhança entre as imagens nos dois pares. Entretanto, as medidas de similaridade desse par, apresentadas na segunda linha da Tabela 7.10, informam que os valores após o registro são levemente piores que os antes do registro.




Figura 7.3: Subtração entre pares de imagens semelhantes: (a) antes e (b) após o registro.

7.3.2 Conclusões da análise por paciente

Um pouco mais completa do que a análise individual foi a análise por paciente. Nesta análise, uma grande quantidade de pares sem melhora em uma paciente indica uma falha do método e numerosas quantidades de pares com melhoras indicam uma boa performance do método naquela paciente. Entre os casos de melhora, tem-se o da paciente 5, que, de acordo com a Tabela 7.6, teve taxa de melhora superior a 80% para a maioria das medidas. Outra paciente com uma expressiva melhora é a 6. Entretanto, diferente da 5, a paciente 6 não se destacou pela melhora na maioria de seus pares, mas pelo significativo aumento da similaridade em alguns pares. Um exemplo disto é par 19, cujos resultados estão na Tabela 7.2, através da qual, é possível perceber que as imagens do par eram bem diferentes antes do registro e tornaram-se bastante similares após ele.

Significativas melhoras também foram observadas na paciente 15, a qual pode ser representada pelo seu par 16, cujas subtrações antes e após o registro estão nas figuras 7.4a e 7.4b, respectivamente. Na subtração antes do registro, as imagens demonstraram-se bastante diferentes e, após o registro, essas diferenças foram quase completamente corrigidas. Os resultados desse par são apresentados na Tabela 7.11, na qual, em quase todas as medidas, a semelhança foi significativamente maior no par após o registro.




Figura 7.4: Análise visual do par 16 da paciente 15: (a) subtração antes e (b) após o registro.

Tabela 7.11: Análise quantitativa do par 16 da paciente 15.

	Dice	Jaccar	SR	FP	FN	SQD	CCN	IMN	DH	NM
Antes	0,9779	0,9568	0,9754	0,019	0,024	578,6	0,91	1,15	12	2,137
Após	0,9949	0,9899	0,9922	0,002	0,007	86,49	0,96	1,26	3	2,262

Um visível caso de falha do método é a paciente 2, que exibiu altas taxas de pares sem melhoras. Essa falha ocorreu principalmente devido a uma movimentação não esperada, realizada pela paciente no momento da aquisição das imagens. Essa movimentação é a

mesma apresentada na Figura 7.2, a qual também é nítida entre as imagens 11 e 12 desta paciente, exibidas nas figuras 7.5a e 7.5b. Entretanto, apesar dessa falha, percebe-se, através das médias e dos desvios padrão, apresentados nas tabelas 7.8 e 7.9, que, de uma forma geral, o método aumentou as semelhanças entre as imagens em todas as pacientes.




Figura 7.5: Exemplo onde o método falha.

Uma observação interessante ocorreu na paciente 14. Nela, durante a captura de seus termogramas, foi apresentado um nível de ruído na área entre o pescoço e o ombro esquerdo da paciente, deixando a imagem bastante borrada nesta região, como mostra a Figura 7.6a. Este efeito gerou contornos semelhantes aos da Figura 7.6b, nos quais a detecção do ponto $A.2$ é totalmente comprometida. Entretanto, devido ao método utilizado de associação entre as características, nos pares formados por essa imagem, o ponto em questão não foi computado no cálculo da função de mapeamento e, dessa forma, os resultados do método não foram prejudicados por essa particularidade.




Figura 7.6: Imagem 13 da paciente 21: (a) imagem original e (b) contorno da imagem.

Por fim, através dos resultados obtidos, percebe-se que o método mostrou-se satisfatório ao analisar os diferentes tipos de pacientes: doentes, saudáveis, com mamas pequenas, obesas, com mamas grandes e mastectomizadas. Entretanto, as principais falhas do método estão relacionadas às grandes movimentações realizadas pela paciente, a qual ocorreu somente em uma paciente da amostra de 23.

7.4 Comparação do método com outro existente

Apesar do registro ser um problema relacionado ao contexto, existem algumas ferramentas que disponibilizam métodos ajustáveis de registro de imagens. Esses métodos, geralmente, utilizam-se das próprias intensidades dos pixels como guias para as transformações, realizando registros baseados em intensidade [42]. Outro aspecto dos métodos disponibilizados por essas ferramentas é a utilização de transformações comuns, como a transformação afim e a BSpline [96]. Exemplos desse tipo de ferramenta são o Insight Segmentation and Registration Toolkit (ITK) [14] e o MATLAB [73].

A fim de comparar o registro desenvolvido neste trabalho, um registro genérico é criado através da ferramenta ITK. Neste registro, a função de transformação escolhida foi a BSpline, a qual foi calculada através do gradiente descendente [39], utilizando Soma do Quadrado da Diferença entre as intensidades dos pixels como função guia do método.

A análise entre os dois métodos é realizada pelas medidas de similaridade do capítulo 6, utilizando o mesmo conjunto de teste de 23 pacientes, comentado no início do capítulo. Como o objetivo desse estudo é saber qual dos métodos apresentou os melhores valores, apenas os resultados após a realização dos dois registros são calculados e comparados. Essa comparação será feita através da média que é calculada agrupando os pares por paciente. Em outras palavras, os pares de uma paciente são registrados pelos dois métodos e a média similaridade dos novos pares gerados é calculada para cada um dos registros.

Os resultados obtidos pelos dois métodos são exibidos na tabela 7.12, na qual cada linha representa uma paciente, sendo os valores da parte superior os do registro geral e os da parte inferior os do registro desenvolvido neste trabalho. Os casos em que os resultados são melhores no registro desenvolvido estão destacados de azul e os que o registro geral são melhores estão destacados de vermelho.

Com os resultados coletados, percebe-se que, de forma geral, o método desenvolvido obteve melhor desempenho do que o de um registro geral, pois, na maioria das pacientes, a sua média entre os pares foi melhor que a do registro geral, na grande parte das medidas. Entretanto, na paciente 2, que é um caso onde o método desenvolvido falha, o registro geral obteve melhores resultados em todas as medidas. Além disso, em algumas paciente, como a 4 e 5, o registro geral conseguiu melhores médias na SQD, o que era esperado, pois está é a função otimizada por ele. Por fim, nota-se também, que existem casos em que os resultados do registrado desenvolvido foi bastante semelhante ao do registro geral, assinalando um desempenho igual dos dois métodos.

Tabela 7.12: Média das medidas de similaridade dos pares de imagens por paciente registrado pelo ITK e pelo método desenvolvido neste trabalho.

	Dice	Jaccard	SR	FP	FN	SQD	CCN	IMN	NM
1	0,9956	0,9914	0,9955	0,0042	0,0045	73,16	0,9916	1,3461	2,3417
	0,9971	0,9944	0,9967	0,0023	0,0033	36,79	0,9876	1,3692	2,3663
2	0,9926	0,9854	0,9971	0,083	0,0119	306,08	0,9026	1,2678	2,2804
	0,9894	0,9792	0,9874	0,0084	0,0126	344,9	0,9173	1,2868	2,2762
3	0,9740	0,9495	0,9782	0,0304	0,0218	408,44	0,9084	1,2612	2,2352
	0,9862	0,9729	0,9947	0,0217	0,0053	448,94	0,9217	1,2856	2,2718
4	0,9963	0,9927	0,9852	0,0059	0,0148	63,49	0,974	1,322	2,3183
	0,9975	0,9952	0,9971	0,0016	0,0029	84,79	0,9825	1,3465	2,3440
5	0,9963	0,9927	0,9937	0,0043	0,0065	74,84	0,9852	1,3812	2,3775
	0,9962	0,9926	0,9949	0,0022	0,0051	83,59	0,9874	1,3991	2,3953
6	0,9915	0,9832	0,9875	0,0069	0,0071	201,35	0,9394	1,3026	2,2941
	0,9923	0,9848	0,9924	0,0074	0,0076	198,93	0,9509	1,3233	2,3156
7	0,9967	0,9935	0,9974	0,0041	0,0025	40,21	0,9925	1,3901	2,3868
	0,9967	0,9936	0,9976	0,004	0,0024	42,02	0,9881	1,3913	2,3880
8	0,9950	0,9901	0,9931	0,006	0,006	100,93	0,9906	1,3813	2,3763
	0,9959	0,992	0,9938	0,0016	0,0062	113,94	0,9872	1,3948	2,3907
9	0,9932	0,9865	0,9907	0,0091	0,0073	187,23	0,9472	1,3075	2,3007
	0,9953	0,9908	0,9952	0,0046	0,0048	115,2	0,9586	1,3243	2,3196
10	0,9949	0,99	0,9957	0,051	0,0053	158,6	0,9725	1,3014	2,2963
	0,9959	0,9919	0,9961	0,0042	0,0039	142,39	0,9742	1,3207	2,3166
11	0,9691	0,9401	0,9472	0,0065	0,0027	108,19	0,9273	1,2691	2,2382
	0,9710	0,9438	0,9486	0,0048	0,0014	94,66	0,9283	1,285	2,2560
12	0,9905	0,9813	0,991	0,0039	0,009	180,51	0,9703	1,3102	2,3007
	0,9944	0,989	0,993	0,0039	0,007	181,81	0,9303	1,3054	2,2998
13	0,9960	0,9922	0,9969	0,006	0,003	73,06	0,989	1,3642	2,3602
	0,9971	0,9943	0,9975	0,003	0,0025	74,09	0,979	1,3787	2,3758
14	0,9944	0,989	0,9912	0,08	0,052	90,63	0,9765	1,275	2,2694
	0,9953	0,9907	0,9944	0,0037	0,0056	98,55	0,9688	1,293	2,2883
15	0,9920	0,9842	0,9955	0,0095	0,0039	180,99	0,9753	1,3356	2,3276
	0,9928	0,9858	0,9954	0,0098	0,0046	184,83	0,9642	1,3373	2,3301
16	0,9910	0,9822	0,9952	0,0025	0,0068	70,83	0,9901	1,3225	2,3135
	0,9965	0,9932	0,9953	0,0021	0,0047	68,8	0,9717	1,3494	2,3459
17	0,9960	0,9921	0,9982	0,002	0,0019	61,03	0,9836	1,3483	2,3443
	0,9976	0,9954	0,9983	0,0029	0,0017	54,1	0,9799	1,3553	2,3529
18	0,9958	0,9918	0,9961	0,0028	0,0031	71,57	0,9913	1,3135	2,3093
	0,9973	0,9948	0,9972	0,0024	0,0028	70,68	0,9942	1,3394	2,3367
19	0,9906	0,9814	0,996	0,006	0,0045	90,34	0,9714	1,3362	2,3268
	0,9964	0,9929	0,9969	0,004	0,0031	93,21	0,963	1,3401	2,3365
20	0,9965	0,9932	0,9967	0,005	0,0031	80,62	0,981	1,3694	2,3659
	0,9971	0,9943	0,9975	0,003	0,0025	74,09	0,979	1,3787	2,3758
21	0,9954	0,991	0,9951	0,0034	0,0053	166,93	0,9632	1,2728	2,2682
	0,9955	0,9912	0,9954	0,0038	0,0046	164,19	0,9599	1,2869	2,2824
22	0,9892	0,9787	0,9873	0,0042	0,009	100,04	0,9354	1,4024	2,3916
	0,9936	0,9873	0,993	0,0046	0,007	97,62	0,9302	1,4134	2,4070
23	0,9973	0,9947	0,9982	0,0021	0,0032	33,95	0,9916	1,3712	2,3685
	0,9971	0,9944	0,9967	0,0023	0,0033	36,79	0,9876	1,3692	2,3663

Capítulo 8

Considerações finais

De forma geral, este trabalho apresentou um método de registro capaz de alinhar as imagens térmicas da plataforma DMR. Este método foi criado utilizando técnicas de registro baseadas em características. O mapeamento entre as imagens foi feito através de transformações afins e de projeções (Möbius) e o método de interpolação para a criação das imagens transformadas foi a interpolação linear. Os pontos guias, utilizados nos cálculos das funções de transformações, foram identificados do contorno da paciente e o relacionamento entre eles é feito de forma direta por classificadores.

Para a execução do método na sequência de imagens de uma paciente, pares são criados a partir da escolha de uma imagem de referência. Em seguida, esses pares são registrados gerando um novo conjunto com imagens mais alinhadas, formado pela imagem de referência mais as imagens transformadas. O teste dessa execução foi realizado em termogramas de 23 pacientes aleatoriamente escolhidas do DMR. No final, os resultados desse teste são avaliados de forma individual e por pacientes.

Tanto na avaliação individuais como na por pacientes, os resultados foram satisfatórios. Entretanto, em alguns casos isolados, é possível perceber que o método não é capaz de melhorar a similaridade entre os pares de imagens da paciente. Isto ocorre principalmente quando, durante a aquisição das imagens, a paciente realiza movimentos bruscos e inesperados, que prejudicam a correta identificação das características. Essa situação ocorreu principalmente nas imagens da paciente 2, que realizou uma movimentação no pescoço, comprometendo a identificação do ponto A.1. É possível também que falhas na qualidade das imagens, como ruídos, possam igualmente atrapalhar o método de registro, porém a paciente que apresentou ruídos em seus termogramas obteve resultados satisfatórios.

8.1 Trabalhos futuros

Vários trabalhos podem surgir a partir deste, que é o primeiro método de registro desenvolvido pelo grupo de pesquisa do VisualLab. Este método foi desenvolvido visando as imagens do DMI, nas quais estão presentes os seios, partes dos braços da paciente, o abdômen, o pescoço e parte da cabeça. Entretanto, a maioria dos trabalhos que se utilizam dessas imagens necessita somente da região dos seios, sendo todo o resto do corpo da paciente visto como excesso que pode atrapalhar o método. Dessa forma, um possível trabalho de registro em imagens térmicas seria o desenvolvimento de um método para a segmentação dessas imagens, deixando somente a região dos seios e retirando todas as outras regiões. Um disso foi o método desenvolvido em Marques [71], que teve como escopo imagens de outro banco e, por isso, não obteve bons resultados em teste realizados com as imagens registradas.

Além do exposto acima, outros trabalhos podem ser realizados alterando parte das etapas do método desenvolvido. A primeira alteração pode ocorrer na fase de identificação das características do registro, a qual, diferente da técnica utilizada neste trabalho, pode ser feita pelos algoritmos genéricos de identificação de pontos característicos, como os comentados na seção 4.2.5. Para que isso ocorra, um maior esforço deve ser empregado nas etapas de identificação e associação das características, pois deve-se identificar, dentre as características sugeridas pelos algoritmos, quais são estáveis e como será feita a associação entre elas. Por fim, o método apresentado também pode ser aperfeiçoado por diferentes grupos de transformações não estudados neste trabalho, como as transformações Thin Plate Spline e os Métodos de Elementos Finitos que podem corrigir possíveis deformações de segunda ordem.

Referências

- [1] ABREU, E. Programa de oncologia(Pro-Onco) 10 anos. *Revista Brasileira de Cancerologia* 43, 4 (1997). disponível em http://www1.inca.gov.br/rbc/n_43/v04/editorial.html acessado em 20 novembro 2014.
- [2] AGOSTINI, V., DELSANTO, S., KNAFLITZ, M., MOLINARI, F. Noise estimation in infrared image sequences: a tool for the quantitative evaluation of the effectiveness of registration algorithms. *IEEE Transactions on Biomedical Engineering* 55, 7 (2008), 1917–1920.
- [3] AGOSTINI, V., KNAFLITZ, M., MOLINARI, F. Motion artifact reduction in breast dynamic infrared imaging. *IEEE Transactions on Biomedical Engineering* 56, 3 (2009), 903–906.
- [4] AMALU, W. C., HOBBS, W. B., HEAD, J. F., ELLIOT, R. L. *Infrared imaging of the breast: an overview*, 3 ed. CRC Press., 2006, cap. 25.
- [5] ANTONINI, S., KOLARIC, D., NOLA, I., HERCEG, Z., RAMLJAK, V., KULIS, T., HOLJEVAC, J., FERENCIC, Z. Thermography surveillance after breast conserving surgery: three cases. In *the Croatian Society Electronics in Marine (ELMAR), 2011 Proceedings* (2011), p. 317–319.
- [6] ARORA, N., MARTINS, D., RUGGERIO, D., TOUSIMIS, E., SWISTEL, A. J., OSBORNE, M. P., SIMMONS, R. M. Effectiveness of a noninvasive digital infrared thermal imaging system in the detection of breast cancer. *The American Journal of Surgery* 196, 4 (2008), 523 – 526.
- [7] ASHBURNER, J., FRISTON, K. J. Diffeomorphic registration using geodesic shooting and gauss-newton optimisation. *NeuroImage* 55, 3 (2011), 954 – 967.
- [8] BARNSLEY, M. F. *Fractals everywhere*, 2 ed. Morgan Kaufmann, 1993.
- [9] BARZIGAR, N., ROOZGARD, A., CHENG, S., VERMA, P. Scobep: Dense image registration using sparse coding and belief propagation. *Journal of Visual Communication and Image Representation* 24, 2 (2013), 137 – 147.
- [10] BAY, H., ESS, A., TUYTELAARS, T., GOOL, L. V. Speeded-up robust features (SURF). *Computer Vision and Image Understanding* 110, 3 (2008), 346 – 359.
- [11] BOQUETE, L., ORTEGA, S., MIGUEL-JIMÉNEZ, J. M., RODRÍGUEZ-ASCARIZ, J. M., BLANCO, R. Automated detection of breast cancer in thermal infrared images, based on independent component analysis. *Journal of medical systems* 36, 1 (2012), 103–111.

- [12] BORBA, A. Planos e eixos do corpo humano, 2011. Disponível em: <http://cienciasmorfologicas.webnode.pt/introdu%C3%A7%C3%A3o%20a%20anatomia/planos-e-eixos-do-corpo-humano/> acessado em 20 de novembro de 2013.
- [13] BORCHARTT, T. B., RESMINI, R., MARQUES, R. D. S., CONCI, A., SILVA, A. C., DE LIMA, R. D. C. F. Registro de imagem para correção da posição corporal em mamotermogramas. In *VII Congresso Nacional de Engenharia Mecânica (CONEM), 2012 Proceedings* (2012), p. 1–7.
- [14] BORRO, D. An ITK-Based Framework for 2D-3D Registration with Multiple Fixed Images. 1–18.
- [15] BOZEK, J., GRGIC, M., SCHNABEL, J. Validation of rigid registration of mammographic images. In *the Croatian Society Electronics in Marine (ELMAR), 2011 Proceedings* (2011), p. 11–16.
- [16] BRASIL. Programa de assistência integral à saúde da mulher. Relatório Técnico, Ministério da Saúde, 1984.
- [17] CANER, G., TEKALP, A. M., SHARMA, G., HEINZELMAN, W. Local image registration by adaptive filtering. *IEEE Transactions on Image Process* 15, 10 (2006), 3053–3065.
- [18] CANNY, J. *Finding edges and lines in images*. Tese de Doutorado, Massachusetts Institute of Technology, Cambridge, MA, 1983.
- [19] CHRISTENSEN, G., GENG, X., KUHL, J., BRUSS, J., GRABOWSKI, T., PIROWANI, I., VANNIER, M., ALLEN, J., DAMASIO, H. Introduction to the non-rigid image registration evaluation project (NIREP). In *Biomedical Image Registration*, vol. 4057 of *Lecture Notes in Computer Science*. Springer, 2006, p. 128–135.
- [20] CONCI, A., AZEVEDO, E., LETA, F. *Computação Gráfica - Teoria e Prática*, 1 ed., vol. 1. CAMPUS, 2007.
- [21] CONCI, A., GALVÃO, S., OLIVERA, G. O. S. A new measure for comparing biomedical regions of interest in segmentation of digital images. in press, 2015.
- [22] CONWAY, J. H., SMITH, D. A. *On quaternions and octonions: their geometry, arithmetic, and symmetry*, 1 ed. Taylor & Francis, 2003.
- [23] CRUM, W., CAMARA, O., HILL, D. Generalized overlap measures for evaluation and validation in medical image analysis. *IEEE Transactions on Medical Imaging* 25, 11 (2006), 1451–1461.
- [24] DíEZ, Y., OLIVER, A., LLADO, X., FREIXENET, J., MARTI, J., VILANOVA, J., MARTI, R. Revisiting intensity-based image registration applied to mammography. *IEEE Transactions on Information Technology in Biomedicine* 15, 5 (2011), 716–725.
- [25] DUBUISSON, M.-P., JAIN, A. A modified Hausdorff distance for object matching. In *International Conference Pattern Recognition (IAPR), 1994 Proceedings* (1994), vol. 1, p. 566–568.

- [26] EHRHARDT, J., KRÜGER, J., BISCHOF, A., BARKHAUSEN, J., HANDELS, H. Automatic correspondence detection in mammogram and breast tomosynthesis images. In *SPIE Medical Imaging, 2012 Proceedings* (2012), vol. 8314, p. 831–839.
- [27] ETEHADTAVAKOL, M., SADRI, S., NG, E. Application of k and fuzzy c-means for color segmentation of thermal infrared breast images. *Journal of Medical Systems* 34, 1 (2010), 35–42.
- [28] FALCONER, K. J. *Fractal geometry: mathematical foundations and applications*, 2 ed. John Wiley & Sons, 1990.
- [29] FLIR. The Ultimate Infrared Handbook for R&D Professionals. Relatório Técnico, FLIR, 2012.
- [30] FLUCK, O., VETTER, C., WEIN, W., KAMEN, A., PREIM, B., WESTERMANN, R. A survey of medical image registration on graphics hardware. *Computer Methods and Programs in Biomedicine* 104, 3 (2011), 45–57.
- [31] FORSYTHE, G., MALCOLM, M., MOLER, C. *Computer methods for mathematical computations*, 1 ed. Prentice Hall, 1977.
- [32] GALVÃO, S., LINCOLN, S., GALVÃO, S., CONCI, A. Registro de imagens afim para o protocolo dinâmico de aquisição de imagens térmicas da mama. In *Encontro Nacional de Engenharia Biomecânica (ENEBI), 2013 Proceedings* (2013).
- [33] GALVÃO, S., MARQUES, R., CONCI, A., SÁNCHEZ, A. A registration method for IR images: Preserving the thermal breast characteristics. In *International Conference on Systems, Signals and Image Processing (IWSSIP), 2013 Proceedings* (2013).
- [34] GARCÍA, H. F. G., VEGA, A. G., AGUIRRE, A. H., ZALETA, J. L. M., COELLO, C. A. C. Robust multiscale affine 2d-image registration through evolutionary strategies. In *International Conference on Parallel Problem Solving from Nature Proceedings (PPSN), 2002 Proceedings* (2002), Springer-Verlag, p. 740–748.
- [35] GAZOLLA, J. A. G. F. M., CONCI, A., BORCHARTT, T. B. A registration method for breast infrared images. In *Encontro Nacional de Engenharia Biomecânica (ENEBI), 2013 Proceedings* (2013).
- [36] GERASIMOVA, E., AUDIT, B., ROUX, S. G., KHALIL, A., ARGOUL, F., NAIMARK, O., ARNEODO, A. Multifractal analysis of dynamic infrared imaging of breast cancer. *Europhysics Letters* 104, 6 (2013), 68001–68007.
- [37] GHOLIPOUR, A., KEHTARNAVAZ, N., BRIGGS, R., DEVOUS, M., GOPINATH, K. Brain functional localization: a survey of image registration techniques. *IEEE Transactions on Medical Imaging* 26, 4 (2007), 427–451.
- [38] GONZALEZ-CASTILLO, J., DUTHIE, K. N., SAAD, Z. S., CHU, C., BANDETTINI, P. A., LUH, W.-M. Effects of image contrast on functional mri image registration. *NeuroImage* 67 (2013), 163–74.
- [39] GOSHTASBY, A. Piecewise linear mapping functions for image registration. *Pattern Recognition* 19, 6 (1986), 459 – 466.

- [40] GOSHTASBY, A. A. *2-D and 3-D Image registration*, 1 ed. John Wiley & Sons, 2005.
- [41] GUO, Y., SIVARAMAKRISHNA, R., LU, C.-C., SURI, J., LAXMINARAYAN, S. Breast image registration techniques: a survey. *Medical and Biological Engineering and Computing* 44, 1-2 (2006), 15–26.
- [42] GUO, Y., SURI, J., SIVARAMAKRISHNA, R. Image registration for breast imaging: a review. In *Engineering in Medicine and Biology Society (EMBS), 2005 Proceedings* (2005), p. 3379–3382.
- [43] HARRIS, C., STEPHENS, M. A combined corner and edge detector. In *Alvey Vision Conference (AVC), 1988 Proceedings* (1988), p. 147–151.
- [44] HILL, D. L., BATCHELOR, P., HOLDEN, M., HAWKES, D. Medical image registration. *Physics in Medicine and Biology* 46, 3 (2001), 1–45.
- [45] HILL, D. L. G., HAWKES, D. J., HARRISON, N. A., RUFF, C. F. A strategy for automated multimodality image registration incorporating anatomical knowledge and imager characteristics. In *International Conference on Information Processing in Medical Imaging (IPMI), 1993 Proceedings* (1993), Springer, p. 182–196.
- [46] HO, J., YANG, M.-H. On affine registration of planar point sets using complex numbers. *Computer Vision and Image Understanding* 115, 1 (2011), 50–58.
- [47] HOLDEN, M. A review of geometric transformations for nonrigid body registration. *IEEE Transactions on Medical Imaging* 27, 1 (2008), 111–28.
- [48] HOPP, T., DIETZEL, M., BALTZER, P. A., KREISEL, P., KAISER, W. A., GEMMEKE, H., RUITER, N. V. Automatic multimodal 2D/3D breast image registration using biomechanical FEM models and intensity-based optimization. *Medical Image Analysis* 17, 2 (2013), 209–218.
- [49] HUTTENLOCHER, D., KLANDERMAN, G., RUCKLIDGE, W. Comparing images using the Hausdorff distance. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 15, 9 (1993), 850–863.
- [50] IKEDO, Y., FUKUOKA, D., HARA, T., FUJITA, H., TAKADA, E., ENDO, T., MORITA, T. Computerized mass detection in whole breast ultrasound images: Reduction of false positives using bilateral subtraction technique. In *SPIE Medical Imaging, 2007 Proceedings* (2007), vol. 6514, p. 65141–65150.
- [51] INCA. Controle do câncer de mama: detecção precoce. Relatório Técnico, Instituto Nacional de Câncer José Alencar Gomes da Silva. Disponível em http://www2.inca.gov.br/wps/wcm/connect/acoes_programas/site/home/nobrasil/programa_controle_cancer_mama/deteccao_precoce acessado em 20 novembro de 2013.
- [52] INCA. Estimativa 2014: incidência de câncer no Brasil. Relatório Técnico, Instituto Nacional de Câncer José Alencar Gomes da Silva, 2014.
- [53] JENKINSON, M., SMITH, S. A global optimisation method for robust affine registration of brain images. *Medical Image Analysis* 5, 2 (2001), 143–156.

- [54] JONES, A. C. *An Introduction to Algebraical Geometry*, 1 ed. Morgan Kaufmann, 1912.
- [55] JORO, R., LÄÄPERI, A.-L., DASTIDAR, P., JÄRVENPÄÄ, R., KUUKASJÄRVI, T., TOIVONEN, T., SAARISTO, R., SOIMAKALLIO, S. A dynamic infrared imaging-based diagnostic process for breast cancer. *Acta Radiologica* 50, 8 (2009), 860–869.
- [56] KAPOOR, P., PRASAD, S. Image processing for early diagnosis of breast cancer using infrared images. In *International Conference on Computer and Automation Engineering (ICCAE), 2010 Proceedings* (2010), vol. 3, p. 564–566.
- [57] KENNEDY, D., LEE, T., SEELY, D. A comparative review of thermography as a breast cancer screening technique. *Integrative Cancer Therapies* 8, 1 (2009), 9–16.
- [58] KIM, M., WU, G., SHEN, D. Hierarchical alignment of breast DCE-MR images by groupwise registration and robust feature matching. *Medical Physics* 39, 1 (2012), 353–366.
- [59] KISIL, V. V. *Geometry of Möbius transformations: elliptic, parabolic and hyperbolic actions of $SL_2(R)$* , 1 ed. Imperial College Press, 2012.
- [60] KLEIN, A., ANDERSSON, J., ARDEKANI, B. A., ASHBURNER, J., AVANTS, B., CHIANG, M.-C., CHRISTENSEN, G. E., COLLINS, D. L., GEE, J., HELLIER, P., SONG, J. H., JENKINSON, M., LEPAGE, C., RUECKERT, D., THOMPSON, P., VERCAUTEREN, T., WOODS, R. P., MANN, J. J., PARSEY, R. V. Evaluation of 14 nonlinear deformation algorithms applied to human brain MRI registration. *NeuroImage* 46, 3 (2009), 786–802.
- [61] KLEIN, A., GHOSH, S. S., AVANTS, B., YEO, B. T. T., FISCHL, B., ARDEKANI, B., GEE, J. C., MANN, J. J., PARSEY, R. V. Evaluation of volume-based and surface-based brain image registration methods. *NeuroImage* 51, 1 (2010), 214–220.
- [62] KOTSAS, P., DODD, T. Rigid registration of medical images using 1D and 2D binary projections. *Journal of Digital Imaging* 24, 5 (2011), 913–925.
- [63] KRAWCZYK, B., SCHAEFER, G. Applied soft computing. *Applied Soft Computing* 14 (2014), 554–562.
- [64] KUBRUSLY, C. S. *The elements of operator theory*, 2 ed. Birkhäuser Basel, 2011.
- [65] LEE, C., CHANG, Z., LEE, W., LEE, S., CHEN, C., CHANG, Y., HUANG, C. Longitudinal registration for breast IR image without markers. In *International Conference on Quantitative InfraRed Thermography (QIRT), 2012 Proceedings* (2012).
- [66] LEE, C., CHUANG, C. C., CHANG, Z. W., LEE, W. J., LEE, C. Y., LEE, S. C., HUANG, C. S., CHANG, Y. C., CHEN, C. M. Quantitative dual-spectrum infrared approach for breast cancer detection. In *International Conference on Quantitative InfraRed Thermography (QIRT), 2010 Proceedings* (2010).
- [67] LEHMANN, T. M., GÖNNER, C., SPITZER, K. Survey: interpolation methods in medical image processing. *IEEE Transactions on Medical Imaging* 18, 11 (1999), 1049–1075.

- [68] LI, X., DAWANT, B. M., WELCH, E. B., CHAKRAVARTHY, A. B., XU, L., MAYER, I., KELLEY, M., MESZOELY, I., MEANS-POWELL, J., GORE, J. C., YANKEELOV, T. E. Validation of an algorithm for the nonrigid registration of longitudinal breast MR images using realistic phantoms. *Medical Physics* 37, 6 (2010), 2541.
- [69] LIU, C., YUEN, J., TORRALBA, A. Sift flow: Dense correspondence across scenes and its applications. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 33, 5 (2011), 978–994.
- [70] LU, X., MA, H., ZHANG, B. A non-rigid medical image registration method based on improved linear elastic model. *Optik - International Journal for Light and Electron Optics* 123, 20 (2012), 1867–1873.
- [71] MARQUES, R. Sgmentação automática das mamas em imagens térmicas. Dissertação de Mestrado, Universidade Federal Fluminense, Niterói, RJ, 2012.
- [72] MARTI, R., ZWIGGELAAR, R., RUBIN, C. M. E., UNIT. Automatic mammographic registration: towards the detection of abnormalities. In *Medical Image Understanding Analysis (MIUA), 2001 Proceedings* (2001).
- [73] MATLAB. *MATLAB version 7.10.0 (R2010a)*. The MathWorks Inc., Natick, Massachusetts, 2010.
- [74] MATTES, D., HAYNOR, D. R., VESSELLE, H., LEWELLEN, T. K., EUBANK, W. Nonrigid multimodality image registration. In *SPIE Medical Imaging, 2001 Proceedings* (2001), vol. 4322, p. 1609–1620.
- [75] MÉNDEZ, A. J., TAHOCES, P. G., LADO, M. J., SOUTO, M., VIDAL, J. J. Computer-aided diagnosis: automatic detection of malignant masses in digitized mammograms. *Medical Physics* 25, 6 (1998), 957–64.
- [76] MERTZANIDOU, T., HIPWELL, J., CARDOSO, M. J., ZHANG, X., TANNER, C., OURSELIN, S., BICK, U., HUISMAN, H., KARSSEMEIJER, N., HAWKES, D. MRI to X-ray mammography registration using a volume-preserving affine transformation. *Medical Image Analysis* 16, 5 (2012), 966–975.
- [77] MILLER, A. B., WALL, C., BAINES, C. J., SUN, P., TO, T., NAROD, S. A. Twenty five year follow-up for breast cancer incidence and mortality of the canadian national breast screening study: randomised screening trial. *British Medical Journal* 348 (2014).
- [78] MOREL, J.-M., YU, G. ASIFT: a new framework for fully affine invariant image comparison. *SIAM Journal on Imaging Sciences* 2, 2 (2009), 438–469.
- [79] MOTTA, L. S. Obtenção automática da região de interesse em termogramas frontais da mama para o auxílio à detecção precoce de doenças. Dissertação de Mestrado, Universidade Federal Fluminense, Niterói, RJ, 2010.
- [80] NAYLOR, A. W., SELL, G. R. *Linear operator theory in engineering and science*, first ed. ed. Ribehart & Winston, 1971.
- [81] NELDER, J. A., MEAD, R. A simplex method for function minimization. *The Computer Journal* 7, 4 (1965), 308–313.

- [82] NG, E.-K. A review of thermography as promising non-invasive detection modality for breast tumor. *International Journal of Thermal Sciences* 48, 5 (2009), 849 – 859.
- [83] NG, E. Y. K., KEE, E. C. Integrative computer-aided diagnostic with breast thermogram. *Journal of Mechanics in Medicine and Biology* 07, 01 (2007), 1–10.
- [84] OLIVEIRA, J. A. P. S. Extração automática da região de interesse em imagens térmicas laterais da mama. Dissertação de Mestrado, Universidade Federal Fluminense, Niterói, RJ, 2012.
- [85] ONG, R., OU, J., MIGA, M. Non-rigid registration of breast surfaces using the laplace and diffusion equations. *BioMedical Engineering OnLine* 9, 1 (2010), 1–8.
- [86] OTSU, N. A threshold selection method from gray-level histograms. *Transactions on Systems, Man and Cybernetics*. 20, 1 (1979), 62–66.
- [87] PAN, M.-S., TANG, J.-T., RONG, Q.-S., ZHANG, F. Medical image registration using modified iterative closest points. *Journal for Numerical Methods in Biomedical Engineering* 27, 8 (2011), 1150–1166.
- [88] PAN, M.-S., YANG, X.-L., TANG, J.-T. Research on interpolation methods in medical image processing. *Journal of Medical Systems* 36, 2 (2012), 777–807.
- [89] PAN, M.-S., ZHANG, F., RONG, Q.-S., ZHOU, H.-C., NIE, F.-Y. Research on robustness of the mutual information similarity metric for registration of medical images. *Biomedical Engineering: Applications, Basis and Communications* 23, 06 (2011), 479–491.
- [90] PLUIM, J., FITZPATRICK, J. Image registration. *IEEE Transactions on Medical Imaging* 22, 11 (2003), 1341–1343.
- [91] PRATT, W. K. *Digital image processing*, 3 ed., vol. 5. John Wiley & Sons, 2001.
- [92] RADIOLOGYINFO. Mammography. Relatório Técnico, RadiologyInfo, 2013. disponível em <http://www.radiologyinfo.org/en/pdf/mammo.pdf> acessado em 10 dezembro de 2014.
- [93] RICHARD, F. J., COHEN, L. D. A new image registration technique with free boundary constraints: application to mammography. *Computer Vision and Image Understanding* 89, 3 (2003), 166–196.
- [94] ROGELJ, P., KOVACIC, S., GEE, J. C. Validation of a nonrigid registration algorithm for multimodal data. In (SPIE): *Medical Imaging, 2002 Proceedings* (2002), vol. 4684, p. 299–307.
- [95] ROOSE, L., MOLLEMANS, W., LOECKX, D., MAES, F., SUETENS, P. Biomechanically based elastic breast registration using mass tensor simulation. In *Medical Image Computing and Computer-Assisted Intervention 2006*, vol. 4191 of *Lecture Notes in Computer Science*. Springer, 2006, p. 718–725.

- [96] RUECKERT, D., SONODA, L., HAYES, C., HILL, D., LEACH, M., HAWKES, D. Nonrigid registration using free-form deformations: application to breast mr images. *IEEE Transactions on Medical Imaging* 18, 8 (Aug 1999), 712–721.
- [97] SANTAMARÍA, J., CORDÓN, O., DAMAS, S. A comparative study of state-of-the-art evolutionary image registration methods for 3D modeling. *Computer Vision and Image Understanding* 115, 9 (2011), 1340–1354.
- [98] SANTAMARÍA, J., DAMAS, S., GARCÍA-TORRES, J. M., CORDÓN, O. Self-adaptive evolutionary image registration using differential evolution and artificial immune systems. *Pattern Recognition Letters* 33, 16 (2012), 2065–2070.
- [99] SANTOS, D. A., FERNANDES, L. A. F. Uma técnica baseada em imagens para correção da postura de pacientes na aquisição de termografias. *Jornal Brasileiro de TeleSaúde* 2, 4 (2013), 138–144.
- [100] SASKIA, V. E., SNOEREN, P., HENDRIKS, J., KARSEMEIJER, N. A comparison of methods for mammogram registration. *IEEE Transactions on Medical Imaging* 22, 11 (2003), 1436–44.
- [101] SCHNEIDER, R. J., PERRIN, D. P., VASILYEV, N. V., MARX, G. R., DEL NIDO, P. J., HOWE, R. D. Real-time image-based rigid registration of three-dimensional ultrasound. *Medical Image Analysis* 16, 2 (2012), 402–414.
- [102] SEQUEIROS, G. O. Desenvolvimento de uma banco de dados de imagens mastológicas acessíveis via web com recuperação baseada no conteúdo. Dissertação de Mestrado, Universidade Federal Fluminense, Niterói, RJ, 2013.
- [103] SERRA, J. *Image Analysis and Mathematical Morphology*, 1 ed. Academic Press, Inc., 1983.
- [104] SHANNON, C. E. A mathematical theory of communication. *SIGMOBILE Mob. Comput. Commun. Rev.* 5, 1 (2001), 3–55.
- [105] SHI, J., TOMASI, C. Good features to track. In *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), 1994 Proceedings* (1994), p. 593–600.
- [106] SHUSHARINA, N., SHARP, G. Analytic regularization for landmark-based image registration. *Physics in Medicine and Biology* 57, 6 (2012), 1477–1498.
- [107] SILVA, L. F., OLIVERA, G. O. S., GALVÃO, S. S. L., SILVA, J. B., SANTOS, A. A. S. M. D., SAADE, D. C. M., A., C. Análise de séries temporais de sinais térmicos da mama para detecção de anomalias. In *CSBC: WIM, 2014 Proceedings* (2014), p. 1818–1827.
- [108] SILVA, L. F., SAADE, D. C. M., SEQUEIROS, G. O., SILVA, A. C., PAIVA, A. C., BRAVO, R. S., CONCI, A. A new database for breast research with infrared image. *Journal of Medical Imaging and Health Informatics* 4, 1 (2014), 92–100.
- [109] SOILLE, P. *Morphological Image Analysis: Principles and Applications*, 2 ed. Springer, 2003.

- [110] SOTIRAS, A., DAVATZIKOS, C., PARAGIOS, N. Deformable medical image registration: a survey. *IEEE Transactions on Medical Imaging* 32, 7 (2013), 1153–90.
- [111] STUDHOLME, C., HILL, D., HAWKES, D. An overlap invariant entropy measure of 3D medical image alignment. *Pattern Recognition* 32, 1 (1999), 71–86.
- [112] SUN, W., ZHOU, W., YANG, M. Non-rigid registration of medical images with scale-space corner detection and thin-plate spline. *Biomedical Signal Processing and Control* 7, 6 (2012), 599–605.
- [113] WANG, Y., STAIB, L. H. Physical model-based non-rigid registration incorporating statistical shape information. *Medical Image Analysis* 4, 1 (2000), 7 – 20.
- [114] WATT, A., POLICARPO, F. *The Computer Image*, 1 ed. Addison Wesley, 1998.
- [115] WEERD, L. D., MERCER, J. B., WEUM, S. Dynamic infrared thermography. *Clinics in Plastic Surgery* 38, 2 (2011), 277–292.
- [116] WHO. World Health Organization, Cancer. Relatório Técnico, World Health Organization, 2014. disponível em <http://www.who.int/mediacentre/factsheets/fs297/en/> acessado em 21 de novembro de 2014.
- [117] WIRTH, M. A., NARHAN, J., GRAY, D. W. S. Nonrigid mammogram registration using mutual information. In *SPIE Medical Imaging, 2002 Proceedings* (2002), vol. 4684, p. 562–573.
- [118] WISHART, G. C., CAMPISI, M., BOSWELL, M., CHAPMAN, D., SHACKLETON, V., IDDLIS, S., HALLETT, A., BRITTON, P. D. The accuracy of digital infrared imaging for breast cancer detection in women undergoing breast biopsy. *European Journal of Surgical Oncology* 36, 6 (2010), 535–540.
- [119] WOODS, R. P., CHERRY, S. R., C., M. J. Rapid automated algorithm for aligning and reslicing pet images. *Computer Assisted Tomography* 16, 4 (1992), 620–633.
- [120] WYAWAHARE, M. V., ABHYANKAR, H. K. Image Registration Techniques: An overview. *International Journal of Signal Processing, Image Processing and Pattern Recognition* 2, 3 (2009), 11–28.
- [121] ZHOU, B., GAO, L., DAI, Y.-H. Gradient methods with adaptive step-sizes. *Computational Optimization and Applications* 35, 1 (2006), 69–86.
- [122] ZITOVÁ, B., FLUSSER, J. Image registration methods: a survey. *Image and Vision Computing* 21, 11 (2003), 977–1000.