

Universidade Federal de Minas Gerais
Escola de Engenharia
Programa de Pós-Graduação em Engenharia de Elétrica

Navegação Autônoma de VANTs Baseada em Imagens Orbitais e Métodos de Otimização

Ramon Santos Corrêa

Orientador: Prof. Dr. Antônio de Pádua Braga

Belo Horizonte, Fevereiro de 2017

DISSERTAÇÃO DE MESTRADO Nº 968

**NAVEGAÇÃO AUTÔNOMA DE VANTS BASEADA EM IMAGENS ORBITAIS E
MÉTODOS DE OTIMIZAÇÃO**

Ramon Santos Corrêa

DATA DA DEFESA: 16/02/2017

Universidade Federal de Minas Gerais

Escola de Engenharia

Programa de Pós-Graduação em Engenharia Elétrica

**NAVEGAÇÃO AUTÔNOMA DE VANTS BASEADA EM IMAGENS
ORBITAIS E MÉTODOS DE OTIMIZAÇÃO**

Ramon Santos Corrêa

Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do Título de Mestre em Engenharia Elétrica.

Orientador: Prof. Antônio de Pádua Braga

Belo Horizonte - MG

Fevereiro de 2017

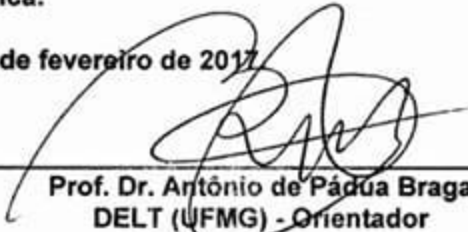
**"Navegação Autônoma de Vants Baseada em Imagens Orbitais
e Métodos de Otimização"**

Ramon Santos Corrêa

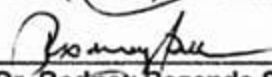
Dissertação de Mestrado submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, como requisito para obtenção do grau de Mestre em Engenharia Elétrica.

Aprovada em 16 de fevereiro de 2017


Por:



Prof. Dr. Antônio de Pádua Braga
DELT (UFMG) - Orientador



Prof. Dr. Rodney Rezende Saldanha
DEE (UFMG)



Prof. Dr. Cristiano Leite de Castro
DEE (UFMG)

Agradecimentos

Agradeço a todos aqueles que, direta ou indiretamente, colaboraram para a realização deste trabalho e, em especial:

Ao LITC, pela oportunidade, apoio e confiança no meu trabalho.

Aos meus pais, Maria da Conceição e Ronaldo, de quem eu sempre me espelhei para me tornar o homem que sou hoje, por tudo que me ensinaram e por toda a dedicação e sacrifício que fizeram para eu ter um futuro melhor.

Ao meu orientador Prof. Antônio de Pádua Braga, pelo apoio em todos os momentos que precisei e pela experiência e conhecimentos que me foram transmitidos durante o desenvolvimento deste trabalho.

Aos meus amigos e colegas de mestrado Tamires Rezende, Ciniro Name-tala e Felipe Mota pelas inúmeras palavras de incentivo e direcionamento nos momentos de dúvidas e de dificuldades.

À UFMG e ao CEFET-MG pela inestimável colaboração em minha formação acadêmica.

Aos meus irmãos e amigos pelo companheirismo e apoio nos momentos difíceis.

A Deus, por todas as realizações que tornou possíveis e por tudo que fez por mim.

Resumo

A navegação de um Veículo Aéreo Não Tripulado (VANT) baseada em imagens pode ser tratada como um problema de otimização. É necessário determinar basicamente quatro parâmetros do VANT: posição latitudinal e longitudinal, rotação e altitude.

A escolha dos valores mais apropriados para estes parâmetros determina o melhor casamento entre as imagens registrada pelo VANT e a georreferenciada do satélite e, conseqüentemente, no menor erro de estimação da sua trajetória.

Atualmente, o principal sistema de navegação utilizado é o GPS, no entanto, há alguns fatores que limitam a utilização desta tecnologia, sendo, então, necessárias outras alternativas para tornar a navegação segura, confiável e autônoma. A abordagem mais comum é utilizar um módulo de visão computacional para auxiliar a navegação do VANT.

Quando a altitude e rotação do VANT são desconhecidas ou muito imprecisas, uma alternativa à técnica geralmente adotada, o *template matching*, é o uso de métodos de otimização.

Amplamente utilizados na área médica, porém ainda pouco explorados na navegação autônoma de VANTS, os métodos de otimização podem ser usados para estimar a posição do VANT com uma medida de dissimilaridade como função objetivo dos métodos para realizar o casamento entre as imagens.

Neste trabalho foram utilizados métodos de otimização determinísticos e estocásticos, medidas de dissimilaridade contínuas baseadas em intensidade e discretas baseadas em extração de características, e imagens reais obtidas de sensores distintos de diferentes tipos de terreno (urbano, rural e litorâneo).

A proposta deste trabalho é avaliar a utilização de métodos de otimização na navegação autônoma de VANTs baseada em imagens em relação à precisão, acurácia e ao tempo de processamento.

A aplicação dos métodos de otimização mostrou-se promissora, principalmente, por permitir estimar variáveis como a rotação e a altitude e pela possibilidade de paralelização dos algoritmos.

Além disso, foi possível identificar os métodos de otimização e as medidas de dissimilaridade mais apropriados para serem utilizados em aplicações práticas.

Abstract

The image-based navigation of an Unmanned Aerial Vehicle (UAV) can be treated as an optimization problem. It's necessary to determine basically four UAV's parameters: latitudinal and longitudinal position, rotation and height.

The choice of the most suitable values for these parameters determines the better matching between UAV's registered images and the georeferenced satellite images and, consequently, the smaller estimation error of its trajectory.

Nowadays, the main navigation system used is GPS, however there are some factors that limit the use of this technology, so other alternatives are necessary to make navigation safe, reliable and autonomous. The most common approach is to use a computer vision module to aid the navigation of the UAV.

When the UAV's rotation and height are unknown or very imprecise, an alternative to the commonly adopted technique, template matching, is the use of optimization methods.

Widely used in the medical field, but still little explored in the UAV's autonomous navigation, optimization methods can be used to estimate the UAV's position with a dissimilarity measure as an objective function of the methods to perform the matching between the images.

In this work, deterministic and stochastic optimization methods were used, continuous dissimilarity measures based on intensity and discrete based on extraction of characteristics, and real images obtained from distinct sensors of different terrain types (urban, rural and coastal).

The purpose of this work is to evaluate the use of optimization methods in the UAV's image-based autonomous navigation in relation to precision, accuracy and processing time.

The application of the optimization methods proved to be promising, mainly because it allows to estimate variables such as rotation and altitude and the possibility of parallelization of the algorithms.

Moreover, it was possible to identify the optimization methods and the dissimilarity measures most appropriate to be used in practical applications.

Sumário

Agradecimentos	i
Resumo	ii
Abstract	iii
Lista de Abreviaturas	vi
Lista de Figuras	viii
Lista de Tabelas	ix
1 Introdução	1
1.1 Motivação	2
1.2 Objetivos	3
1.3 Principais Contribuições	3
1.4 Organização do Texto	4
2 Revisão Bibliográfica	5
2.1 VANTs	5
2.2 Registro de Imagens	6
2.3 Algoritmos de Otimização	8
2.4 Considerações Finais	12
3 Metodologia	13
3.1 VANT Usado Como Referência Nos Experimentos	13
3.2 Imagens de Teste	14
3.2.1 Imagens de satélite georreferenciadas	14
3.2.2 Imagens do voo do VANT	14
3.3 Softwares e Recursos Computacionais	16
3.4 Medidas de Dissimilaridade	16
3.4.1 Dissimilaridades Baseadas em Intensidade	16

3.4.2	Dissimilaridades Baseadas em Extração de Características	20
3.5	Métodos de Otimização	23
3.5.1	Determinísticos	23
3.5.2	Estocásticos	25
3.5.3	Determinação do Tamanho da Imagem Alvo	28
3.5.4	Seleção de Pontos Iniciais	30
3.5.5	Tratamento das Imagens	31
3.5.6	Paralelização dos Métodos de Otimização	31
3.5.7	Otimização	33
4	Resultados e Discussão	37
4.1	Resultados Gerais	39
4.1.1	Métodos de Otimização	39
4.1.2	Medidas de Dissimilaridade	40
4.1.3	Imagens	41
4.2	Resultados das Medidas de Dissimilaridade	41
4.3	Imagens Registradas	48
4.3.1	Com Dissimilaridades Baseadas em Intensidade	48
4.3.2	Com Dissimilaridade Baseadas em Extração de Características	53
4.4	Discussão dos Resultados	56
4.4.1	Métodos de Otimização	56
4.4.2	Medidas de Dissimilaridade	57
4.4.3	Imagens	57
5	Conclusões e Propostas de Continuidade	59
5.1	Conclusões	59
5.2	Propostas de Continuidade	61
	Referências Bibliográficas	62

Lista de Abreviaturas

A	Imagem Alvo
AG	Algoritmos Genéticos
DE	<i>Differential Evolution</i> (Evolução Diferencial)
GC	<i>Gradient Correlation</i> (Correlação de Gradientes)
GD	<i>Gradient Difference</i> (Diferença de Gradientes)
GPS	<i>Global Positioning System</i> (Sistema de Posicionamento Global)
IP	<i>Interior Point</i> (Pontos Interiores)
LM	Levenberg-Marquardt
M	Imagem Registrada
MI	<i>Mutual Information</i> (Informação Mútua)
NCC	<i>Normalized Cross-Correlation</i> (Correlação Cruzada Normalizada)
PSO	<i>Particle Swarm Optimization</i> (Enxame de Partículas)
QN	Quase-Newton BFGS
SA	<i>Simulated Annealing</i> (Recozimento Simulado)
SPLX	Nelder-Mead Simplex
SQP	<i>Sequential Quadratic Programming</i> (Programação Quadrática Sequencial)
SSIM	<i>Structural Similarity Index</i> (Índice de Similaridade Estrutural)
SSD	<i>Sum of Squared Differences</i> (Soma dos Quadrados das Diferenças)
T	Imagem <i>Template</i>
VANT	Veículo Aéreo Não Tripulado

Lista de Figuras

2.1	VANTs de asa fixa (esquerda) e de asa rotativa (direita). Fonte: www.xmrobots.com.br	5
2.2	Exemplo de aplicação do <i>template matching</i> em reconhecimento de caracteres.	7
2.3	Registro de imagens aplicado ao problema de navegação autônoma de VANTs.	8
3.1	VANT Echar 20B da Xmrobots (Fonte: www.xmrobots.com.br)	14
3.2	Classificação das medidas de dissimilaridade baseadas em intensidade (Adaptado de (Chisu, 2005))	17
3.3	Histogramas das imagens individuais e da imagem combinada (Chisu, 2005)	20
3.4	Determinação do tamanho da imagem alvo	29
3.5	Ganho de desempenho obtido com a paralelização através do <i>parfor</i>	32
3.6	Ganho de desempenho obtido com a paralelização através do <i>parfeval</i>	33
3.7	Diagrama do registro de imagens baseado em otimização	36
4.1	Acurácia e precisão	38
4.2	Resultados gerais dos métodos de otimização	40
4.3	Resultados gerais das medidas de dissimilaridade	40
4.4	Resultados gerais das imagens utilizadas	41
4.5	Resultados da medida de dissimilaridade SSD	42
4.6	Resultados da medida de dissimilaridade NCC	42
4.7	Resultados da medida de dissimilaridade GD	43
4.8	Resultados da medida de dissimilaridade GC	43
4.9	Resultados da medida de dissimilaridade SSIM	44
4.10	Resultados da medida de dissimilaridade MI	44
4.11	Resultados da medida de dissimilaridade Jaccard	45
4.12	Resultados da medida de dissimilaridade Sorenson-Dice	45
4.13	Resultados da medida de dissimilaridade Kulczynksi	46
4.14	Resultados da medida de dissimilaridade Relative Matching	46

4.15	Resultados da medida de dissimilaridade Russel & Rao	47
4.16	Resultados da medida de dissimilaridade Yule	47
4.17	Imagem 1 registrada (esquerda) e <i>template</i> (direita) usando SSD	48
4.18	Imagem 2 registrada (esquerda) e <i>template</i> (direita) usando SSD	48
4.19	Imagem 3 registrada (esquerda) e <i>template</i> (direita) usando SSD	49
4.20	Imagem 4 registrada (esquerda) e <i>template</i> (direita) usando SSD	49
4.21	Imagem 5 registrada (esquerda) e <i>template</i> (direita) usando SSD	49
4.22	Imagem 6 registrada (esquerda) e <i>template</i> (direita) usando SSD	50
4.23	Imagem 7 registrada (esquerda) e <i>template</i> (direita) usando SSD	50
4.24	Imagem 8 registrada (esquerda) e <i>template</i> (direita) usando SSD	50
4.25	Localização da imagem registrada 1 na imagem alvo	51
4.26	Localização da imagem registrada 2 na imagem alvo	51
4.27	Localização da imagem registrada 3 na imagem alvo	51
4.28	Localização da imagem registrada 4 na imagem alvo	52
4.29	Localização da imagem registrada 5 na imagem alvo	52
4.30	Localização da imagem registrada 6 na imagem alvo	52
4.31	Localização da imagem registrada 7 na imagem alvo	53
4.32	Localização da imagem registrada 8 na imagem alvo	53
4.33	Imagem 1 registrada (esquerda) e <i>template</i> (direita) usando Jaccard	54
4.34	Imagem 2 registrada (esquerda) e <i>template</i> (direita) usando Jaccard	54
4.35	Imagem 3 registrada (esquerda) e <i>template</i> (direita) usando Jaccard	54
4.36	Imagem 4 registrada (esquerda) e <i>template</i> (direita) usando Jaccard	55
4.37	Imagem 5 registrada (esquerda) e <i>template</i> (direita) usando Jaccard	55
4.38	Imagem 6 registrada (esquerda) e <i>template</i> (direita) usando Jaccard	55
4.39	Imagem 7 registrada (esquerda) e <i>template</i> (direita) usando Jaccard	56
4.40	Imagem 8 registrada (esquerda) e <i>template</i> (direita) usando Jaccard	56

Lista de Tabelas

3.1	Especificações técnicas do VANT usado como referência (Fonte: www.xmrobots.com.br)	13
3.2	Pontos de referência utilizados	15

Capítulo 1

Introdução

Os VANTs (Veículos Aéreos Não Tripulados) são aeronaves projetadas para operar sem piloto a bordo e podem ser usadas em tarefas diversas, tais como monitoramento, reconhecimento tático, vigilância e mapeamento (Jorge & Inamasu, 2014).

A utilização de VANTs tem crescido nos últimos anos, principalmente, devido à ausência de tripulação que esta tecnologia proporciona e ao baixo custo, proporcionado pelos avanços na tecnologia computacional, desenvolvimento de software e de materiais mais leves e a miniaturização dos sensores (Jorge & Inamasu, 2014).

Há diversas alternativas para a navegação de um VANT, entre elas a forma controlada e a autônoma. A navegação autônoma e baseada em imagens orbitais utiliza um módulo de visão computacional que captura as imagens do terreno sobrevoado e faz a correspondência com as imagens georreferenciadas de satélite, de modo que o VANT consiga reconhecer automaticamente o local sobrevoado e seguir um percurso pré-planejado.

Uma grande variedade de técnicas computacionais tem sido aplicadas para que veículos autônomos não necessitem de interação com o ser humano para realizar sua navegação sobre um determinado percurso. Uma das mais simples é o *template matching*, que consiste em buscar a imagem sobrevoada dentro da imagem georreferenciada de satélite e, assim, estimar a posição do VANT. No entanto, pode haver diferenças de rotação e escala entre as imagens, sendo necessário o conhecimento prévio da rotação e altitude da aeronave para que o casamento entre elas seja possível. A rotação e a altitude podem ser obtidas a partir de aparelhos disponíveis no VANT: a rotação por meio de uma bússola e a altitude por um altímetro (Santos *et al.*, 2013).

Além das diferenças de rotação e escala entre as imagens, pode haver outras dificuldades no casamento das imagens, como diferenças temporais, de luminosidade, perspectiva e resposta espectral, visto que as imagens são

registradas de sensores distintos (Silva *et al.*, 2015).

O problema abordado neste trabalho é a navegação autônoma de VANTs baseada em imagens orbitais e métodos de otimização. Nesta abordagem, são utilizadas imagens capturadas pelo VANT do local sobrevoado e imagens georreferenciadas de satélite. Os métodos de otimização são usados para localizar a imagem registrada pelo VANT na imagem de satélite, alterando-se os parâmetros de transformação (translação horizontal, translação vertical e escala) em função de uma medida de dissimilaridade que é utilizada como função objetivo dos métodos. A medida de dissimilaridade, por sua vez, é responsável pelo casamento entre as imagens, fornecendo a informação de quão similar são as imagens comparadas. Como a imagem de satélite é georreferenciada é possível estimar a posição latitudinal e longitudinal do VANT.

A motivação, os objetivos e as principais contribuições deste trabalho serão apresentados nas seções seguintes.

1.1 Motivação

Embora o GPS (do inglês *Global Positioning System*) seja o sistema de navegação mais adotado em escala global, há alguns fatores que limitam sua utilização, entre eles: o sinal GPS pode não estar disponível para todos aqueles que desejam utilizá-lo; pode ser bloqueado por interesses comerciais ou militares; pode apresentar falhas devido a vários fatores, como alterações na ionosfera, interferências e ataques maliciosos (Silva *et al.*, 2015).

Logo, há a necessidade de uma alternativa que torne a navegação dos VANTs mais segura e confiável e também autônoma. Neste caso, uma das alternativas possíveis é a utilização de um módulo de visão computacional para auxiliar ou substituir o GPS na navegação do VANT.

Outra motivação deste trabalho é que o *template matching* necessita do conhecimento prévio da rotação e da altitude do VANT e é preciso percorrer toda a imagem georreferenciada para realizar o casamento entre as imagens. Em contrapartida, os métodos de otimização só precisam utilizar alguns pontos da imagem, podem estimar a rotação e escala das imagens realizando-se transformações nas imagens.

Assim, os métodos de otimização mostram-se bastante úteis, principalmente nos casos em que não haja instrumentos na aeronave que possam fornecer as informações de rotação e altitude ou estes estejam descalibrados ou apresentem muitos erros de medição.

1.2 Objetivos

Este trabalho tem como objetivo principal demonstrar a aplicabilidade de métodos de otimização na navegação autônoma de VANTS baseada em imagens orbitais.

A proposta desse trabalho é avaliar a acurácia, precisão e custo computacional dos algoritmos de otimização e das medidas de dissimilaridade candidatas à função objetivo dos mesmos e identificar os mais apropriados para serem utilizados em aplicações práticas quando são usadas imagens em escala de cinza ou binárias após a aplicação de um extrator de bordas.

Neste trabalho foram aplicados cinco algoritmos de otimização determinísticos - Pontos Interiores (IP), Programação Quadrática Sequencial (SQP), Nelder-Mead Simplex (SPLX), Quase-Newton BFGS (QN) e Levenberg-Marquardt (LM) - e quatro estocásticos - Simulated Annealing (SA), Algoritmos Genéticos (AG), Enxame de Partículas (PSO) e Evolução Diferencial (DE).

Foram usadas, nas imagens em escala de cinza, medidas de dissimilaridade contínuas baseadas em intensidade - Soma dos Quadrados das Diferenças (SSD), Correlação Cruzada Normalizada (NCC), Diferença de Gradientes (GD), Correlação de Gradientes (GC), Índice de Similaridade Estrutural (SSIM) e Informação Mútua Normalizada (MI) - e, nas imagens binárias após extração de características, medidas discretas - Jaccard, Sorenson-Dice, Kulczynski, Relative Matching, Russel & Rao e Yule (Chisu, 2005; Terra *et al.*, 2013; Wang *et al.*, 2004).

Nos experimentos foram utilizadas imagens reais obtidas de sensores distintos de diferentes tipos de terreno (urbano, rural e litorâneo) e as variáveis estimadas foram a posição longitudinal e a latitudinal e o fator de escala das imagens.

1.3 Principais Contribuições

Uma das contribuições deste trabalho é demonstrar a aplicabilidade de métodos de otimização no problema de navegação autônoma de VANTS baseado em imagens orbitais, fornecendo um estudo comparativo entre diversos algoritmos de otimização (determinísticos e estocásticos) e medidas de dissimilaridade (baseadas em intensidade e em extração de características) com relação à acurácia, precisão e custo computacional.

Embora estejam disponíveis na literatura diversos trabalhos aplicados à área médica abordando estes itens, encontra-se muitos poucos similares ou com conteúdo tão abrangente aplicados à tarefa proposta.

A principal contribuição deste trabalho é propor uma abordagem alter-

nativa ao *template matching* para o problema de navegação autônoma de VANTs baseada em imagens, através da utilização de métodos de otimização, que permite: realizar o casamento entre as imagens utilizando somente alguns pontos da imagem alvo e sem precisar das informações de escala e rotação da imagem registrada pelo VANT, incluir mais parâmetros de transformação às imagens e a utilização de paralelização. A abordagem proposta foi publicada no XII Simpósio de Mecânica Computacional (SIMMEC), realizado pela Universidade Federal dos Vales do Jequitinhonha e Mucuri (UFVJM) em maio de 2016 (Corrêa *et al.*, 2016).

1.4 Organização do Texto

Este trabalho está organizado do seguinte modo:

- **Capítulo 2: Revisão Bibliográfica.** Este capítulo apresenta os conceitos necessários para um melhor entendimento do tema e algumas das possíveis soluções encontradas na literatura para resolver o problema em questão.
- **Capítulo 3: Metodologia.** Apresenta a metodologia utilizada neste trabalho, como os métodos de otimização, as medidas de dissimilaridade, as imagens de teste, a seleção de pontos iniciais de busca e o tratamento e as transformações aplicadas às imagens.
- **Capítulo 4: Resultados e Discussão.** Neste capítulo são apresentados e discutidos os resultados obtidos após a implementação e teste dos algoritmos e das medidas de dissimilaridade abordados no capítulo anterior. É realizada uma comparação entre eles em função de sua precisão, acurácia e custo computacional.
- **Capítulo 5: Conclusões e Propostas de Continuidade.** Este capítulo apresenta as conclusões e as propostas de continuidade deste trabalho.

Capítulo 2

Revisão Bibliográfica

Este capítulo é dedicado a apresentar os conceitos necessários para um melhor entendimento do tema do trabalho e algumas das possíveis soluções encontradas na literatura para resolver o problema em questão.

2.1 VANTs

Os VANTs são aeronaves que não necessitam de pilotos embarcados para serem guiadas. Eles podem ser do tipo asa rotativa, tais como helicópteros ou multirotores, ou do tipo asa fixa, como os aviões convencionais, podendo ambos cumprir missões programadas previamente e controladas por piloto automático. A Figura 2.1 apresenta alguns exemplos de VANTs de asa fixa e rotativa.



Figura 2.1: VANTs de asa fixa (esquerda) e de asa rotativa (direita). Fonte: www.xmrobots.com.br

Popularmente conhecidos como drones, embora sejam tecnicamente a

mesma coisa, os VANTs se diferenciam pelo seu propósito de uso, que é puramente comercial ou para fins de pesquisa científica e experimentos. Além disso, precisam de mais uma característica para serem considerados VANTs: uma carga útil embarcada que não seja a necessária para o voo, por exemplo, uma câmera de filmagem ou algum produto (Alencar, 2015).

Há diversas alternativas para a navegação de um VANT, entre elas a forma controlada e a autônoma. Na controlada, a aeronave é controlada remotamente por meio de uma estação de controle. Na autônoma, a navegação é feita de forma automática por meio de um sistema embarcado que replaneja a rota conforme o posicionamento da aeronave é alterado.

A navegação de um VANT envolve basicamente os seguintes parâmetros: posição latitudinal, posição longitudinal, altitude e rotação. Como toda aeronave é capaz de realizar rotações ao redor de três eixos perpendiculares entre si (transversal, longitudinal e vertical), logo a rotação pode ser subdividida, respectivamente, nos ângulos de rotação correspondentes de arfagem, rolamento e guinada.

Na forma autônoma a navegação pode ser realizada através de imagens orbitais, em que o VANT registra as imagens do terreno sobrevoado e faz a correspondência com as imagens georreferenciadas de satélite, a fim de reconhecer automaticamente o local sobrevoado e seguir um percurso pré-planejado.

2.2 Registro de Imagens

Determinar o quão similar duas imagens são é o problema chave no registro de imagens, que consiste em aplicar uma série de transformações em uma imagem alvo a fim de corresponder completamente ou parcialmente o mais próximo possível a uma imagem *template* (Santos *et al.*, 2013).

Um dos métodos mais simples de registro de imagens conhecidos é o *template matching*. Ele aplica somente transformações de translação nas imagens e consiste em realizar uma busca exaustiva para encontrar a posição de uma subimagem (*template*) dentro de uma imagem maior (alvo). No problema tratado, a imagem *template* é a imagem da região sobrevoada pelo VANT e a alvo é a imagem de satélite (Santos *et al.*, 2013).

Um exemplo simples que aborda a utilização do *template matching* está ilustrado na Figura 2.2, em que deseja-se reconhecer um caractere (*template*) numa sequência de caracteres (imagem alvo). Na aplicação do *template matching* considerou-se que a rotação e o fator de escala dos caracteres não são alterados.

As principais abordagens utilizadas no registro de imagens são baseadas em intensidade ou em características.

Os métodos baseados em características utilizam geralmente detectores de bordas, como o Canny e Sobel, para extrair características das imagens, como bordas, linhas, curvas e manchas. Geralmente, estes métodos precisam extrair dados em um espaço de características que é muito específico, podendo ser necessária alguma interação com o usuário e dificultar assim o registro automático das imagens. Uma das vantagens é que eles são geralmente muito rápidos, uma vez que trabalham com um conjunto reduzido de informações (Zitova & Flusser, 2003).



Figura 2.2: Exemplo de aplicação do *template matching* em reconhecimento de caracteres.

Os métodos baseados em intensidade utilizam os valores de intensidades dos pixels das imagens com alguma medida de dissimilaridade para comparar as imagens. As principais desvantagens apresentadas por estes métodos é que possuem elevada complexidade computacional devido à grande quantidade de dados que necessitam ser processados e são geralmente intolerantes a mudanças de iluminação e condições do ambiente. No entanto, não requerem interação com o usuário, permitindo que o registro de imagens seja facilmente automatizado (Zitova & Flusser, 2003).

A correlação cruzada é tipicamente utilizada nos métodos baseados em intensidade, onde uma superfície de correlação é calculada e o ponto de máxima correlação é encontrado e interpretado como o melhor ajuste para o *template*. Contudo, esta técnica é afetada por autosimilaridade na imagem e

é caracterizada por elevada complexidade computacional (Zitova & Flusser, 2003).

Uma alternativa é utilizar técnicas de otimização. As vantagens desta abordagem em relação à correlação cruzada são que é possível aplicar transformações mais complexas ao *template*, sendo mais robusta, e requer menor custo computacional, visto que a superfície de correlação não precisa ser completamente determinada (Machowski & Marwala, 2007). A Figura 2.3 ilustra o registro de imagens aplicado ao problema de navegação autônoma de VANTs.




Figura 2.3: Registro de imagens aplicado ao problema de navegação autônoma de VANTs.

2.3 Algoritmos de Otimização

A navegação de um VANT baseada em imagens pode ser tratada como um problema de otimização, onde é necessário estimar pelo menos quatro parâmetros: posição latitudinal e longitudinal, rotação e altitude. Utilizando uma medida de dissimilaridade apropriada como função objetivo de um algoritmo de otimização e aplicando determinadas transformações geométricas (translação, escala, rotação, etc.) a uma imagem georreferenciada da região do percurso do VANT e comparando-a com a imagem sobrevoada pelo VANT, é possível estimar a sua posição geográfica.

O problema de otimização é multidimensional, onde o número de dimensões corresponde ao número de graus de liberdade das transformações geométricas aplicadas às imagens (Zitova & Flusser, 2003).

Quando o problema se limita a duas dimensões, isto é, quando somente as translações devem ser estimadas, uma forma frequentemente utilizada de

alcançar a solução ótima global é uma busca exaustiva ao longo de toda a imagem (*template matching*) (Zitova & Flusser, 2003).

No caso de transformações com mais graus de liberdade, algoritmos de otimização precisam ser utilizados para localizar a solução ótima global (Zitova & Flusser, 2003).

Os métodos de otimização podem ser classificados em determinísticos e estocásticos. Os determinísticos utilizam a avaliação da função objetivo e a informação dada pelo gradiente desta; em contrapartida, os estocásticos utilizam apenas a avaliação da função objetivo.

Diversos trabalhos têm sido realizados aplicando algoritmos de otimização e medidas de dissimilaridade no registro de imagens. É possível encontrar trabalhos usando algoritmos determinísticos e estocásticos, diferentes tipos de aplicações, como na área médica e navegação autônoma, e com imagens reais obtidas de sensores distintos ou imagens simples de teste.

Uma grande variedade de medidas de dissimilaridade baseadas em intensidade tem sido propostas e avaliadas para diferentes tipos de aplicações. Algumas são baseadas somente na intensidade, outras na informação espacial e também na entropia das imagens. Entre os tipos principais, há dissimilaridades contínuas aplicadas a imagens em escala de cinza e, discretas, aplicadas a imagens binárias. Conforme os estudos têm mostrado, a escolha da medida de dissimilaridade influencia diretamente na acurácia do registro de imagens.

No trabalho de Chisu (2005), encontramos algumas semelhanças com o presente trabalho, como a utilização de medidas de dissimilaridade baseadas somente na intensidade (SSD, NCC, SAD e RIU), na informação espacial (GD, GC, PI, GP, SLNC e VWLNC) e na entropia das imagens (MI e EDI), o problema de otimização também é tridimensional (translações e rotação) e utiliza um algoritmo de otimização estocástico para realizar o casamento das imagens.

Este trabalho se destaca pela grande quantidade de medidas de dissimilaridade contínuas utilizadas e pelo seu foco em acelerar o registro de imagens baseado em intensidade, utilizando unidades de processamento gráfico (GPUs) e computação paralela. Contudo, sua aplicação é na área médica e apenas um algoritmo de otimização simples (abordagem do vizinho mais próximo) é testado (Chisu, 2005).

Nos trabalhos de Machowski (2007) e Machowski & Marwala (2007) também são utilizadas tanto métodos determinísticos (SPLX, QN BFGS, Gradiente Descendente, Gradiente Conjugado e SCG) quanto estocásticos (AG, SA e PSO) e o problema abordado também foi a otimização dos parâmetros de translação horizontal e vertical e escala.

Alguns pontos que merecem destaque foram a adição de um termo de penalização à função objetivo para quando não houver pixels sobrepostos entre

as imagens e a adoção de uma abordagem baseada nos valores de intensidade com maior frequência do histograma do *template* para a escolha de pontos iniciais para contornar o problema de mínimos locais nos algoritmos determinísticos. No entanto, foram utilizadas apenas uma medida de dissimilaridade (SSD) e imagens simples de teste, em que a imagem *template* é um recorte da imagem alvo, corrompida por algum ruído ou após sofrer algum tipo de transformação (Machowski, 2007; Machowski & Marwala, 2007).

Kher (2014) utilizou o método de otimização estocástico PSO e a medida de dissimilaridade contínua MI. Alguns dos pontos altos do trabalho são que a solução proposta é implementada em hardware num processador DSP, são utilizadas imagens reais de satélite e vários parâmetros para avaliar a qualidade do registro das imagens: Raiz da Média dos Erros Quadráticos (RMSE), Relação de Pico Sinal-Ruído (PSNR), Correlação Cruzada e Matriz de Índices de Similaridade Estrutural (SSIM). Contudo, as imagens *templates* utilizadas consistiram em recortes das imagens alvo, apenas um algoritmo de otimização e uma medida de dissimilaridade foram testados e não foi fornecida a informação do tempo computacional gasto pelo algoritmo para saber se uma aplicação prática embarcada é viável (Kher, 2014).

Van der Bom *et al.* (2011) compararam o desempenho de sete algoritmos de otimização, sendo dois estocásticos (Estratégia Evolutiva e Aproximação Estocástica por Perturbação Simultânea) e cinco determinísticos (Gradiente Descendente, Simplex, Powell-Brent, Quase-Newton e Gradiente Conjugado Não Linear). Foram usadas três medidas de dissimilaridade baseadas na informação espacial das imagens (GD, GC e PI). O trabalho foi aplicado à área médica e utilizou imagens reais de raios X e tomografias de pacientes. Os autores utilizaram a acurácia e o tempo computacional gasto pelos algoritmos na comparação.

Sorrentino (2006) usou um algoritmo determinístico baseado no gradiente descendente e duas medidas de dissimilaridade contínuas (NCC e MI). Alguns aspectos interessantes foram que: um filtro de média zero e variância unitária foi aplicado às imagens, que é importante quando o imageamento é feito por meio de sensores diferentes ou sob condições de intensidade de iluminação distintas, caso comum na navegação de um VANT; e foi aplicado um filtro passa baixas nas imagens, que apresentou robustez a mínimos locais, porém, à custa de uma diminuição da acurácia do método.

Contudo, uma comparação de desempenho mais realista, sob condições de ruído e variações de iluminação, não foi realizada e é sugerida a utilização de algumas técnicas com melhores chances de escapar de mínimos locais, conhecidas como técnicas de otimização global, que poderiam ser utilizadas para obter uma melhor acurácia do método proposto (Sorrentino, 2006).

Yang (2009), ao invés de utilizar as imagens em escala de cinza, realizou

um pré-processamento para extrair as bordas das mesmas, obtendo imagens binárias, similar ao que é feito no presente trabalho. Contudo, não foram utilizadas medidas de dissimilaridade para dados binários, mas a dissimilaridade MI. Foram utilizadas nos testes imagens sintéticas e imagens extraídas de sensores distintos, porém não foram utilizados algoritmos de otimização na solução, embora tenha sido sugerido pelos autores para a redução do tempo computacional.

No trabalho de Dame & Marchand (2012) foi proposto um método de otimização determinístico de segunda ordem, que utiliza a MI como dissimilaridade e pode ser aplicado ao registro de imagens em tempo real. A abordagem proposta provou ser robusta, adequada para aplicações de tempo real e fornece uma estimativa precisa de parâmetros de movimento bidimensionais. Também é robusta a mudanças de iluminação, multimodalidade e a oclusões parciais. O menor custo computacional, permitindo utilização em aplicações de tempo real, foi obtido por meio da otimização do cálculo da matriz Hessiana, utilizando-se uma abordagem de otimização específica, baseada na seleção de pixels de referência.

No trabalho de Santos *et al* (2013) foi aplicado o método de *template matching* à navegação de VANTs. Similar ao trabalho de Yang, foi realizada uma extração de bordas por meio do extrator Canny e depois aplicada uma medida de dissimilaridade à imagem binária, porém, neste caso foi utilizada a NCC. Também não foi utilizado um algoritmo de otimização, mas sim uma busca exaustiva ao longo da imagem alvo. As imagens de teste foram imagens reais tiradas de voos de um VANT e de satélite georreferenciadas. Apesar de apresentar o tempo computacional gasto pelo algoritmo, não é fornecida uma métrica que indicasse a acurácia ou precisão do mesmo.

Silva *et al* (2015). também apresenta uma abordagem de casamento de imagens aplicada à estimativa de posição para a navegação autônoma de VANTs e também aplica extratores de bordas às imagens. No entanto, a abordagem emprega Redes Neurais Artificiais (RNA) dos tipos RBF (do inglês *Radial Basis Function*) e MLP (do inglês *MultiLayer Perceptron*) treinadas sob duas metodologias distintas. Os experimentos realizados foram feitos com imagens reais obtidas de voos feitos na região de São Carlos / SP e, assim como o presente trabalho, apresenta diferentes tipos de terreno (floresta, rodovia e zona urbana).

O trabalho de Jaimes *et al* (2016) é aplicado à navegação autônoma de VANTs. Apesar de não abordar métodos de otimização e medidas de dissimilaridade, apresenta uma metodologia importante para realizar a transformação projetiva em imagens capturadas por VANTs quando a posição da câmera não é perpendicular à Terra, que é uma condição muito comum devido ao tipo de câmera acoplada, manobras de virada e perturbações do ambiente.

Logo, a correção da perspectiva é condição fundamental para a estimação de imagens por meio de métodos de *template matching* e poderia ser aplicada ao presente trabalho para obtenção de melhores resultados. Além disso, os resultados mostraram que o método possui baixo custo computacional e pode facilmente ser aplicado em condições reais de voo.

2.4 Considerações Finais

Conforme foi visto nos diversos trabalhos citados, há diversos algoritmos de otimização, determinísticos e estocásticos, e medidas de dissimilaridade sendo utilizadas no problema de registro de imagens.

Estudos mostraram que para uma mesma medida de dissimilaridade são obtidos desempenhos distintos quando métodos de otimização diferentes são usados, o que indica que uma dissimilaridade pode ser uma candidata melhor à função objetivo de um algoritmo de otimização do que outra (Van der Bom *et al.* 2011).

Verifica-se a partir da literatura, pela grande quantidade de trabalhos disponíveis, que, no registro de imagens na área médica, os métodos de otimização possuem ampla e sólida utilização.

Logo, levando-se em consideração as evidências promissoras da sua utilização na solução deste tipo de problema, o presente trabalho pretende comparar o desempenho de alguns dos diversos algoritmos e medidas de dissimilaridade existentes em relação ao custo computacional e desempenho no problema de navegação de um VANT.

No próximo capítulo será apresentada a metodologia utilizada neste trabalho, onde serão abordados algoritmos de otimização determinísticos e estocásticos e as medidas de dissimilaridade que podem ser utilizadas como função objetivo dos algoritmos de otimização neste tipo de problema.

Capítulo 3

Metodologia

Neste capítulo será apresentada a metodologia utilizada neste trabalho, como os métodos de otimização, as medidas de dissimilaridade, as imagens de teste, a seleção de pontos iniciais de busca, o tratamento e as transformações aplicadas às imagens.

3.1 VANT Usado Como Referência Nos Experimentos

Nos experimentos realizados não foi utilizado um VANT real; foram feitas apenas simulações, contudo o VANT Echar 20B da Xrobots foi usado como referência para tornar os testes mais próximos da realidade. A aeronave está apresentada na Figura 3.1 e algumas de suas especificações técnicas na Tabela 3.1.

Tabela 3.1: Especificações técnicas do VANT usado como referência (Fonte: www.xrobots.com.br)

Especificação	Valor
Teto de Voo (Altitude Máxima)	3000 m
Autonomia (1000mASL/30°C/5m/s)	75-90 min
Velocidade de Cruzeiro	75 km/h



Figura 3.1: VANT Echar 20B da Xrobots (Fonte: www.xrobots.com.br)

3.2 Imagens de Teste

3.2.1 Imagens de satélite georreferenciadas

Para a realização dos experimentos foi utilizada uma imagem georreferenciada da cidade do Rio de Janeiro (RJ), obtida da base de mapas do Instituto Brasileiro de Geografia e Estatística (IBGE).

Foi selecionada a folha de número 2745-4-SO do ortomosaico (imagem completa de satélite) que abrange o estado do RJ. A folha foi escolhida por possuir uma grande quantidade de pontos turísticos de referência e apresentar diferentes elementos representativos, como florestas, áreas urbanas e regiões litorâneas (IBGE, 2014).

O ortomosaico, que integra o projeto RJ-25, é formado por um mosaico de fotografias aéreas coloridas e ortorretificadas, registradas a partir de aerolevamento, obtendo-se uma escala final de trabalho de 1:25000 (IBGE, 2014).

A folha utilizada faz parte dos blocos de aerotriangulação de números 24 e 34 do projeto RJ-25, o que significa que as imagens que formam esta folha foram registradas em 2004 e em junho de 2005 (IBGE, 2014).

A imagem georreferenciada possui aproximadamente 85 MB com dimensões de 14100 x 14926 pixels e resolução de 72 DPI (pontos por polegada).

3.2.2 Imagens do voo do VANT

Para simular as imagens registradas pelo VANT foram selecionadas 8 imagens de pontos turísticos da cidade do RJ, situadas a uma distância média

de 2,85 *km* entre uma e outra, afim de traçar uma rota de voo do mesmo.

Foram escolhidos pontos turísticos, pois são, geralmente, mais diferenciáveis no mapa e a utilização dessas imagens exemplifica uma aplicação real de um VANT, que consiste em registrar um *tour* pela ‘cidade maravilhosa’.

As imagens foram obtidas através do *Google Earth* e possuem cerca de 200 KB com dimensões de 720 x 486 pixels (padrão de vídeo digital NTSC) e resolução de 72 DPI.

Na seleção das imagens tomou-se a cautela de redefinir a inclinação e a orientação da bússola para o Norte e de utilizar imagens mais similares às do mapa e com a menor diferença temporal possível. Portanto, foram escolhidas imagens registradas em maio de 2006, representando uma diferença temporal de 1 a 2 anos, pois imagens com menores diferenças temporais possuíam qualidade inferior e influência de fatores climáticos como névoas.

A latitude e a longitude destes pontos também foram obtidas por meio do *Google Earth*.

As imagens foram classificadas em três tipos de zonas (terrenos): urbana, rural e litorânea. A zona rural representa imagens com terrenos não estruturados e com predominância de áreas verdes e montanhas. A zona urbana compreende terrenos estruturados compostos basicamente por prédios, casas, ruas, etc. E, por fim, a zona litorânea consiste em regiões que apresentam faixas de terra junto à costa marítima.

O critério para a classificação de cada imagem se deu pela característica de maior predominância na mesma imagem.

Na Tabela 3.2 estão apresentados o nome, a latitude e a longitude dos pontos turísticos, bem como o tipo de zona que representam.

Tabela 3.2: Pontos de referência utilizados

Nº	Ponto turístico	Latitude	Longitude	Altitude (km)	Tipo de Zona
1	Pão de Açúcar	-22,949259	-43,154576	4,15	Rural
2	UFRJ	-22,954087	-43,175133	1,05	Urbana
3	Praia de Copacabana	-22,971192	-43,182535	1,05	Litorânea
4	Pedra do Arpoador	-22,99015	-43,19129	1,05	Litorânea
5	Cristo Redentor	-22,951916	-43,210487	1,50	Rural
6	Área de Proteção Ambiental Bairro de Santa Teresa	-22,941122	-43,214722	1,38	Rural
7	Sambódromo da Marquês de Sapucaí	-22,911452	-43,196804	1,05	Urbana
8	Estádio Maracanã	-22,912109	-43,230156	1,06	Urbana

Considerando que a distância total do percurso é de 19,70 *km* e que a velocidade do VANT é mantida constante na velocidade de cruzeiro (75 *km/h*), então é necessária uma autonomia mínima de 16 min para que o voo seja realizável. Logo, verifica-se que o Echar 20B possui autonomia suficiente para realizar o voo.

3.3 Softwares e Recursos Computacionais

Os experimentos foram realizados em uma máquina com processador de 4 núcleos Intel(R) Core(TM) i7-3630QM CPU 2.4 GHz com 6 GB RAM, rodando sobre um sistema operacional Windows 10 Home de 64 bits.

Foram utilizados os softwares *Google Earth* e *MATLAB* no desenvolvimento do trabalho. Este foi utilizado para a implementação da metodologia proposta e realização das simulações e aquele para a extração e obtenção das coordenadas geográficas das imagens do voo do VANT.

3.4 Medidas de Dissimilaridade

As medidas de dissimilaridade fornecem uma informação de distância entre as imagens que são comparadas.

Foram utilizadas seis medidas de dissimilaridade baseadas em intensidade e seis baseadas em extração de características como função objetivo dos métodos de otimização.

Algumas delas são, na verdade, de similaridade, portanto suas equações foram alteradas para serem interpretadas como dissimilaridades e possuem valor igual a zero quando houver casamento perfeito entre as imagens (solução ótima global).

3.4.1 Dissimilaridades Baseadas em Intensidade

Baseiam-se somente nos valores de intensidades dos pixels das imagens no seu cálculo, sendo aplicadas a imagens em escala de cinza. Podem ser classificadas como medidas baseadas em: intensidade local, informação espacial e entropia (Chisu, 2005).

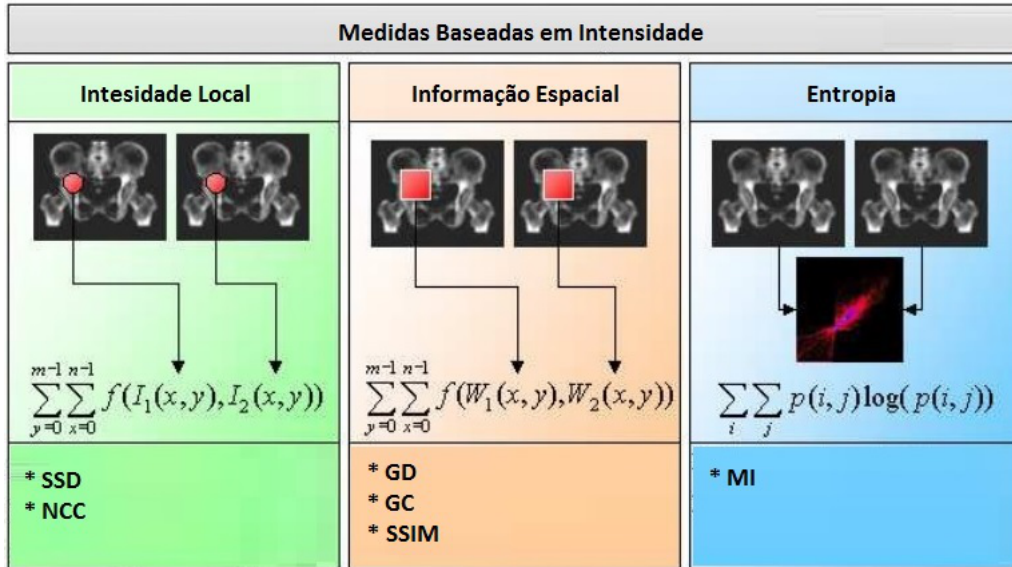


Figura 3.2: Classificação das medidas de dissimilaridade baseadas em intensidade (Adaptado de (Chisu, 2005))

Intensidade Local

É o tipo mais simples, que considera apenas pares de valores de intensidade para as mesmas posições dos pixels nas duas imagens (Chisu, 2005).

- **Soma dos Quadrados das Diferenças (SSD)**

É uma das mais simples de calcular e possui um raio de captura relativamente grande. Contudo, assume que as imagens diferem apenas em ruído gaussiano e é sensível a diferenças de luminosidade entre as imagens (Chisu, 2005). É definida como:

$$f = \frac{1}{N} \sum_{i,j} (T(i,j) - M(i,j))^2 \quad (3.1)$$

onde M é a imagem alvo transformada, T é a imagem *template*, N é o número de pixels sobrepostos entre as imagens e i e j são as coordenadas do pixel na imagem.

- **Correlação Cruzada Normalizada (NCC)**

Esta métrica produz uma função de custo com picos agudos e mínimos bem definidos e é insensível a diferenças de luminosidade entre as imagens.

Contudo, possui um raio de captura relativamente pequeno (Chisu, 2005). É definida como:

$$f = 1 - \frac{\sum_{i,j} T(i, j) \cdot M(i, j)}{\sqrt{\sum_{i,j} T(i, j)^2 \cdot \sum_{i,j} M(i, j)^2}} \quad (3.2)$$

Informação Espacial

Considera também a vizinhança de cada pixel ao calcular a similaridade por pixel (Chisu, 2005).

- **Diferença de Gradientes (GD)**

Esta medida avalia a diferença de magnitude entre os gradientes das duas imagens e seu objetivo é focar o registro nas bordas das estruturas nas imagens. Desta forma, estas exercem maior influência sobre o resultado do registro do que o interior das regiões homogêneas das imagens. Esta medida geralmente é bem robusta à presença de *outliers* (Penney *et al.*, 1998). Seu cálculo se dá através da seguinte equação:

$$f = \sum_{i,j} |\nabla T(i, j) - \nabla M(i, j)| \quad (3.3)$$

- **Correlação de Gradientes (GC)**

Também focada na informação de borda, esta medida aplica a correlação cruzada normalizada usando as magnitudes dos gradientes das imagens. Possui a vantagem de filtrar diferenças de baixas frequências espaciais entre as imagens (Penney *et al.*, 1998). É definida por:

$$f = 1 - \frac{\sum_{i,j} \nabla T(i, j) \cdot \nabla M(i, j)}{\sqrt{\sum_{i,j} (\nabla T(i, j))^2 \cdot \sum_{i,j} (\nabla M(i, j))^2}} \quad (3.4)$$

- **Índice de Similaridade Estrutural (SSIM)**

Esta medida utiliza a similaridade estrutural, comparando padrões locais de intensidade normalizados por luminância e contraste. Baseia-se no princípio de que o sistema visual humano é bom para extrair informações baseadas em estrutura (Wang *et al.*, 2004).

A SSIM é baseada em três medidas de comparação entre as imagens M e T: luminância (l), contraste (c) e estrutura (s). Estas funções são representadas por meio das Equações 3.5 a 3.7 (Wang *et al.*, 2004).

$$l(M, T) = \frac{2 \cdot \bar{M} \cdot \bar{T} + (0.01 \cdot (2^{bpp} - 1))^2}{\bar{M}^2 + \bar{T}^2 + (0.01 \cdot (2^{bpp} - 1))^2} \quad (3.5)$$

$$c(M, T) = \frac{2 \cdot \sigma_M \cdot \sigma_T + (0.03 \cdot (2^{bpp} - 1))^2}{\sigma_M^2 + \sigma_T^2 + (0.03 \cdot (2^{bpp} - 1))^2} \quad (3.6)$$

$$s(M, T) = \frac{\sigma_{MT} \cdot \sigma_T + (0.015 \cdot (2^{bpp} - 1))^2}{\sigma_M \cdot \sigma_T + (0.015 \cdot (2^{bpp} - 1))^2} \quad (3.7)$$

A SSIM é uma combinação ponderada dessas medidas. Utilizando todos os pesos iguais a um, a sua fórmula pode ser reduzida à Equação 3.8 (Wang *et al.*, 2004).

$$f = \left(\frac{(2 \cdot \bar{M} \cdot \bar{T} + (0.01 \cdot (2^{bpp} - 1))^2)(\sigma_{MT} + (0.03 \cdot (2^{bpp} - 1))^2)}{(\bar{M}^2 + \bar{T}^2 + (0.01 \cdot (2^{bpp} - 1))^2)(\sigma_M^2 + \sigma_T^2 + (0.03 \cdot (2^{bpp} - 1))^2)} \right)^{-1} \quad (3.8)$$

onde \bar{M} e \bar{T} são os valores médios das imagens M e T, σ_M e σ_T são os desvios padrão das imagens, σ_{MT} é a covariância entre as imagens M e T e bpp é o número de bits por pixel nas imagens.

Entropia

Utilizam a entropia como medida de informação para minimizar a quantidade de informações presentes em uma combinação das duas imagens (Chisu, 2005).

- **Informação Mútua (MI)**

A ideia desta métrica é calcular as entropias individuais, $H(T)$ e $H(M)$, e conjunta, $H(T, M)$, das duas imagens. Ela não assume um relacionamento linear entre os valores dos pixels das duas imagens; ao invés disso, assume que a co-ocorrência dos valores mais prováveis nas duas imagens é maximizado (Penney *et al.*, 1998). É definida como:

$$f = (H(T) + H(M) - H(T, M))^{-1} = \left(\sum_{i,j} \log \frac{p(i,j)}{p_T(i) \cdot p_M(j)} \right)^{-1} \quad (3.9)$$

onde $p_M(i)$ e $p_T(j)$ são as distribuições de probabilidades nas imagens individuais e $p(i, j)$ é a probabilidade de distribuição conjunta.




Figura 3.3: Histogramas das imagens individuais e da imagem combinada (Chisu, 2005)

3.4.2 Dissimilaridades Baseadas em Extração de Características

Estas medidas de dissimilaridade utilizam um extrator de características para realçar as informações de bordas/arestas das imagens e medidas apropriadas para dados binários.

Além do custo de processamento e armazenamento ser reduzido, uma vez que trabalha-se com imagens binárias (1 bit /pixel) ao invés de em escala de cinza (8 bits/pixel), apresentam robustez a mudanças de luminosidade e de resposta espectral, proporcionada pelo extrator de borda (Silva *et al.*, 2015).

Foi utilizado o extrator de bordas Sobel, pois apresentou melhor desempenho que os demais testados (Canny, Roberts e Prewitt), detectando apenas as bordas fortes da imagem.

Este método detecta bordas usando uma aproximação do gradiente da intensidade dos pixels da imagem, encontrando as bordas onde o seu valor é máximo. A detecção de bordas é obtida pela limiarização da magnitude do gradiente. O Sobel tem a propriedade de realçar linhas verticais e horizontais mais escuras que o fundo, sem realçar pontos isolados (Parker, 1997).

As medidas utilizadas na verdade são de similaridade, portanto foi utilizado o inverso da medida para ela ser interpretada como uma dissimilaridade.

Baseadas Somente na Informação de Borda

Estas baseiam-se somente na informação de borda da imagem, isto é, utilizam somente os pixels que possuem valores iguais a um no seu cálculo.

- **Jaccard**

É uma das mais conhecidas, simples e utilizadas. Também denominada estatística Kappa, ela calcula a fração da área que é comum em ambas as imagens (Terra *et al.*, 2013). É definida como:

$$f = \left(\frac{nnz(T \odot M)}{nnz(T \oplus M)} \right)^{-1} \quad (3.10)$$

onde *nnz* (do inglês, *number of non zeros*) é o número de pixels iguais a um na matriz resultante, \odot e \oplus são as operações bit a bit *AND* e *OR*, respectivamente.

- **Sorenson-Dice**

A diferença entre esta e a Jaccard é basicamente que no seu cálculo ela dobra o peso do que é comum entre as imagens (Terra *et al.*, 2013). É definida como:

$$f = \left(\frac{2 \cdot nnz(T \odot M)}{nnz(T) + nnz(M)} \right)^{-1} \quad (3.11)$$

- **Kulczynski**

É baseada em probabilidade condicional, assumindo que uma característica está presente em um item dado que ela está presente em outro. De acordo com os experimentos de Terra *et al.* (2013), foi a medida que apresentou melhor desempenho, entre as testadas, que consideram apenas bits iguais a um. É definida como:

$$f = \left(\frac{1}{2} \cdot nnz(T \odot M) \cdot \left(\frac{1}{nnz(T)} + \frac{1}{nnz(M)} \right) \right)^{-1} \quad (3.12)$$

Baseadas na Informação de Borda e Não Borda

Estas utilizam tanto a informação da borda (bits iguais a um) como também do que não é borda (bits iguais a zero).

- **Relative Matching**

Considera um conjunto de propriedades de similaridade, como casamento mínimo e máximo. De acordo com os experimentos de Terra *et al.* (2013), foi a medida que apresentou melhor desempenho entre todas as avaliadas. É definida por meio das seguintes equações:

$$ad = nnz(T \odot M) \cdot nnz(T \oplus M) \quad (3.13)$$

$$f = \left(\frac{nnz(T \odot M) + \sqrt{ad}}{N + \sqrt{ad}} \right)^{-1} \quad (3.14)$$

onde nnz é o número de pixels iguais a zero na matriz resultante e a operação $nnz(T \oplus M)$ corresponde a obter os pixels em comum iguais a zero nas imagens.

- **Russel & Rao**

A diferença básica entre esta e a Jaccard é que ela considera a fração da área que é comum em ambas as imagens, considerando tanto os bits iguais a um, como os iguais a zero. Foi a terceira melhor entre as medidas avaliadas nos experimentos de Terra *et al.* (2013). É definida como:

$$f = \left(\frac{nnz(T \odot M)}{N} \right)^{-1} \quad (3.15)$$

- **Yule**

A Yule obteve a quarta colocação entre as medidas avaliadas nos experimentos de Terra *et al.* (2013) em relação ao desempenho. É definida por meio das seguintes equações:

$$ad = nnz(T \odot M) \cdot nnz(T \oplus M) \quad (3.16)$$

$$bc = (nnz(T) - nnz(T \odot M)) \cdot (nnz(M) - nnz(T \odot M)) \quad (3.17)$$

$$f = \left(\frac{1}{2} \left(\frac{ad - bc}{ad + bc} \right) + 1 \right)^{-1} \quad (3.18)$$

3.5 Métodos de Otimização

Os algoritmos usados para a solução de um problema de otimização podem ser, basicamente, determinísticos ou estocásticos (Bastos, 2004).

Foram avaliados cinco métodos de otimização determinísticos e quatro estocásticos, sendo que, em cada um deles, todas as medidas de dissimilaridade foram testadas como função objetivo.

3.5.1 Determinísticos

São métodos que geram uma sequência determinística de possíveis soluções, requerendo o uso da avaliação da função objetivo e de pelo menos a derivada primeira da mesma em relação às variáveis de otimização. Sua maior vantagem em relação aos métodos estocásticos é o tempo de processamento mais baixo (Bastos, 2004).

Para estes métodos foram utilizados o *toolbox* de otimização do MATLAB (Mathworks, 2015).

Como o gradiente de $f(x)$ somente pode ser calculado numericamente, então utilizou-se uma aproximação de diferença central. Um valor mínimo de 2 pixels foi usado para as diferenças, o que significa que as perturbações de translação deslocam a imagem em 2 pixels e as perturbações de escala alteram o tamanho da imagem por 2 pixels.

Pontos Interiores

O método de Pontos Interiores (IP) consiste na obtenção de um ponto viável no interior de um polítopo formado pelas restrições do problema. A partir daí, novos pontos são gerados em uma vizinhança até atingir um critério mínimo para a solução ser considerada ótima (Mehrotra, 1991).

SQP

A Programação Quadrática Sequencial (SQP) consiste na aproximação sequencial do problema de programação não linear por subproblemas de programação quadrática com restrições lineares. Para formar os subproblemas, é utilizada a aproximação da matriz Hessiana da função Lagrangeana através de algum método Quase Newton. Assim, a solução destes subproblemas fornece uma direção de busca para o método de busca linear (Mathworks, 2015).

Simplex

O Simplex (SPLX) de Nelder-Mead baseia-se na comparação entre os valores dos vértices de um simplex - figura geométrica que possui um vértice a mais do que o número de dimensões (Nelder & Mead (1965)).

São utilizadas quatro operações no método: reflexão, contração, expansão e encolhimento. Uma busca por pontos favoráveis é feita usando a reflexão. Outro passo na mesma direção é feito usando a operação de expansão. Se o novo ponto é melhor, então ele é mantido, senão o ponto anterior é usado para a reflexão. Por outro lado, se a reflexão produz um ponto pior, a contração é tentada. Se isso falhar, o tamanho do simplex é reduzido por encolhimento (Nelder & Mead (1965)).

Este método é relativamente robusto quando usado para funções objetivo descontínuas (MATLAB, 2015a).

Quase-Newton BFGS

O método Quase-Newton (QN) é adequado quando a Hessiana somente pode ser calculada numericamente, tal como no registro de imagens. Ele usa a informação das derivadas parciais para atualizar e construir uma matriz Hessiana aproximada que fornece a curvatura da função objetivo (Machowski, 2007).

Este método faz duas aproximações: a expansão de séries de Taylor e a Hessiana. Há duas principais variações para o cálculo da Hessiana aproximada: os algoritmos Davidson-Fletcher-Powell (DFP) e o Broyden-Fletcher-Goldfarb-Shanno (BFGS). Eles diferem entre si na forma como lidam com erros de arredondamento e problemas de convergência. O BFGS é considerado ser o melhor para a maioria dos problemas gerais (Machowski, 2007).

O QN requer mais memória de armazenamento e computação devido à aproximação da Hessiana, que necessita ser calculada a cada iteração acompanhada de uma inversão de matriz (Machowski, 2007).

Levenberg-Marquardt

O método de Levenberg-Marquardt (LM) é uma variação do método de Newton e possui como vantagem não realizar o cálculo a matriz Hessiana, pois utiliza como aproximação desta a matriz Jacobiana (Mathworks, 2015).

Além da aproximação da matriz Hessiana, o LM modifica o método de Newton incluindo um fator μ responsável pelo ajuste do tamanho do incremento realizado pelo algoritmo. Quando o valor de μ se aproxima de zero, o algoritmo se torna o método de Newton utilizando a aproximação da matriz

Hessiana e, quando o valor fica muito grande, ele se torna o método gradiente descendente. Desta forma, ele consegue convergir rapidamente para a solução.

É o método mais adequado para problemas não lineares de mínimos quadrados (Mathworks, 2015).

Foi utilizado para o parâmetro λ o valor igual a 0,005.

3.5.2 Estocásticos

São métodos que usam somente a avaliação da função objetivo na otimização, introduzindo no processo de otimização dados e parâmetros estocásticos. Algumas de suas vantagens em relação aos métodos determinísticos são (Bastos, 2004):

- a função objetivo e as restrições não precisam necessariamente ter uma representação matemática;
- não requerem que a função objetivo seja contínua ou diferenciável;
- trabalham adequadamente, tanto com parâmetros contínuos quanto com discretos, ou ainda com uma combinação deles.

Para estes métodos, foram utilizados algoritmos implementados pelo autor. Em todos os algoritmos, com exceção do SA, foram utilizados 200 indivíduos (partículas).

Simulated Annealing

O *Simulated Annealing* (SA) faz uma analogia aos princípios termodinâmicos ao simular o resfriamento de um conjunto de átomos aquecidos, fenômeno conhecido como recozimento (Kirkpatrick *et al.*, 1983).

Uma característica importante deste método que faz com que ele consiga escapar de mínimos locais é que ele permite que mesmo soluções piores que as anteriores sejam aceitas dentro de uma determinada probabilidade. Esta probabilidade depende da diferença entre as soluções atual e anterior e da temperatura (Kirkpatrick *et al.*, 1983).

A temperatura começa de um valor máximo e são gradativamente reduzidos, ao longo das iterações, o seu valor, por meio de uma razão de resfriamento, e a chance de aceitar uma solução não ótima. O método termina quando a temperatura atinge um valor próximo de zero e nenhuma solução não ótima é aceita, ou seja, o sistema termodinâmico torna-se estável (Kirkpatrick *et al.*, 1983).

No SA foi utilizada uma estratégia de resfriamento geométrica, com razão de resfriamento (α) igual a 0.95, número de iterações para cada valor de temperatura (L) igual a 50 e temperatura final (T_f) igual a 0.1. A temperatura inicial (T_0) foi calculada deterministicamente através da Equação 3.19.

$$T_0 = 0.5 \cdot \max(\text{eig}(\text{cov}(X_0))) \quad (3.19)$$

Então, T_0 é obtida calculando-se a metade do maior autovalor da matriz de covariâncias de X_0 , que consiste num conjunto de 100 pontos amostrados dentro dos limites inferior e superior de x .

Algoritmos Genéticos

O método Algoritmos Genéticos (AG) é inspirado no processo de evolução natural, em que, dada uma população de indivíduos, a pressão do meio ambiente causa uma seleção natural que evolui os indivíduos e seleciona os mais aptos para compor a população final (Goldberg, 1989).

A cada geração do algoritmo, a população é avaliada usando a função de aptidão, são gerados filhos por meio dos operadores genéticos de cruzamento e mutação aplicados sobre a população, os filhos gerados são avaliados e são utilizados os mecanismos de seleção e elitismo para selecionar os indivíduos mais aptos que irão compor a população da próxima geração. O término do algoritmo ocorre quando um critério de parada pré-determinado é alcançado (Goldberg, 1989).

No AG foi utilizada adaptação dinâmica dentro da faixa segundo o comportamento médio da população para determinar as probabilidades de mutação e cruzamento (p_m e p_c). As probabilidades foram determinadas dinamicamente de acordo com as Equações 3.20 e 3.21.

$$p_m = \begin{cases} p_m = p_m \max, & \text{se } md < V_{inf} \\ p_m = p_m \min, & \text{se } md > V_{sup} \\ p_m = p_m \max + \frac{(md - V_{inf}) \cdot (p_m \min - p_m \max)}{V_{sup} - V_{inf}}, & \text{c.c.} \end{cases} \quad (3.20)$$

$$p_c = \begin{cases} p_c = p_c \min, & \text{se } md < V_{inf} \\ p_c = p_c \max, & \text{se } md > V_{sup} \\ p_c = p_c \min + \frac{(md - V_{inf}) \cdot (p_c \max - p_c \min)}{V_{sup} - V_{inf}}, & \text{c.c.} \end{cases} \quad (3.21)$$

$$md = \frac{|x^* - \bar{x}|}{x^*} \quad (3.22)$$

onde md é uma medida da diversidade genética da população, V_{inf} e V_{sup} são os valores inferior e superior da faixa, x^* é a melhor solução encontrada na geração e \bar{x} é a média das soluções nessa geração.

Utilizou-se $p_{min} = 0.05$, $p_{max} = 0.3$, $p_cmin = 0.6$, $p_cmax = 0.95$, $V_{inf} = 0.2$ e $V_{sup} = 0.8$.

Foi utilizado elitismo com taxa de 5 % e os operadores genéticos modificados propostos por Ávila (2002).

Otimização por Enxame de Partículas

O algoritmo de Otimização por Enxame de Partículas (PSO) é baseado no comportamento coletivo de espécies na natureza (bando de pássaros, cardume de peixes, colmeia de abelhas, etc.), em que a busca pela sobrevivência e a cooperação entre elas são modeladas como um mecanismo de otimização (Kennedy & Eberhart, 2001).

O enxame é composto por diversas partículas (soluções do problema) que se movimentam pelo espaço de busca D-dimensional, tendendo a se deslocar para a direção adotada na iteração anterior (inércia), ou para o melhor ponto encontrado na trajetória individual (memória) ou para o melhor ponto encontrado pelo grupo (cooperação) (Kennedy & Eberhart, 2001).

No PSO o peso de inércia (ω) e o coeficiente de contração (K) foram determinados dinamicamente, segundo as Equações 3.23 e 3.24.

$$\omega = \omega_{max} - (1 - md) \cdot (\omega_{max} - \omega_{min}) \quad (3.23)$$

$$K = \frac{(2 \cdot \sigma)}{|2 - (c_1 + c_2) - \sqrt{(c_1 + c_2)^2 - 4 \cdot (c_1 + c_2)}|} \quad (3.24)$$

$$c_1 = c_{1min} - (1 - md) \cdot (c_{1max} - c_{1min}) \quad (3.25)$$

$$c_2 = c_{2min} - (1 - md) \cdot (c_{2max} - c_{2min}) \quad (3.26)$$

onde c_1 e c_2 são fatores de aprendizagem cognitiva e social.

Utilizou-se $\omega_{min} = 0.4$, $\omega_{max} = 0.9$, $c_{1min} = c_{2min} = 2.05$, $c_{1max} = c_{2max} = 4$ e $\sigma = 1$.

Evolução Diferencial

A ideia geral da Evolução Diferencial (DE) é utilizar um vetor de diferenças para perturbar cada indivíduo de uma população. As operações

utilizadas são similares às encontradas em AG: população de pontos e geração de uma nova população através de operações de cruzamento e mutação (Storn & Price, 1997).

No DE foi utilizada uma constante de cruzamento (CR) adaptativa, calculada de acordo com a Equação 3.27.

$$CR = CRmax + (CRmin - CRmax) \cdot md^{k_{CR}} \quad (3.27)$$

Utilizou-se $CRmin = 0.1$, $CRmax = 0.8$ e $k_{CR} = 4$.

A constante de mutação (F) foi determinada aleatoriamente amostrada no intervalo entre zero e um. Foram utilizados o Esquema de Mutação Básico Modificado e o Novo Esquema de Mutação Dirigida. Este foi aplicado quando um número sorteado aleatoriamente é igual ou inferior à medida de diversidade dos indivíduos e aquela quando é superior.

No primeiro esquema, para os indivíduos r_2 e r_3 , usados no cálculo do vetor diferença, são selecionados o melhor e pior indivíduo, respectivamente, e para o indivíduo de referência r_1 é escolhido aleatoriamente um indivíduo diferente destes. No segundo esquema, os indivíduos r_2 e r_3 são selecionados aleatoriamente e o r_1 como o indivíduo mais distante da média da população.

3.5.3 Determinação do Tamanho da Imagem Alvo

Utilizar como imagem alvo (A) a imagem mosaica inteira não só é inviável, como também desnecessária. Além da elevada complexidade para procurar a imagem *template* (T) em A , dependendo da velocidade máxima do VANT e do tempo máximo de processamento do algoritmo para reconhecer uma imagem *template*, é bastante improvável que a aeronave esteja além de um determinado raio de cobertura, se considerarmos que a visada nadir é mantida durante todo o voo.

Considerando os valores limites para a velocidade do VANT (v_{Vmax}) de 20,83 m/s (75 km/h) e para o tempo de processamento do método para reconhecer uma imagem *template* (t_{Mmax}) de 10 s , então, no pior caso, o VANT poderia percorrer uma distância (d_{Vmax}) de no máximo 208,3 m . Utilizando o fator de conversão de distância d_{m2px} de metros para pixels, que é igual a 0.9985, obtemos a distância máxima percorrida pelo VANT igual a 208 px , conforme é demonstrado por meio da Equação 3.28 e pela Figura 3.4.

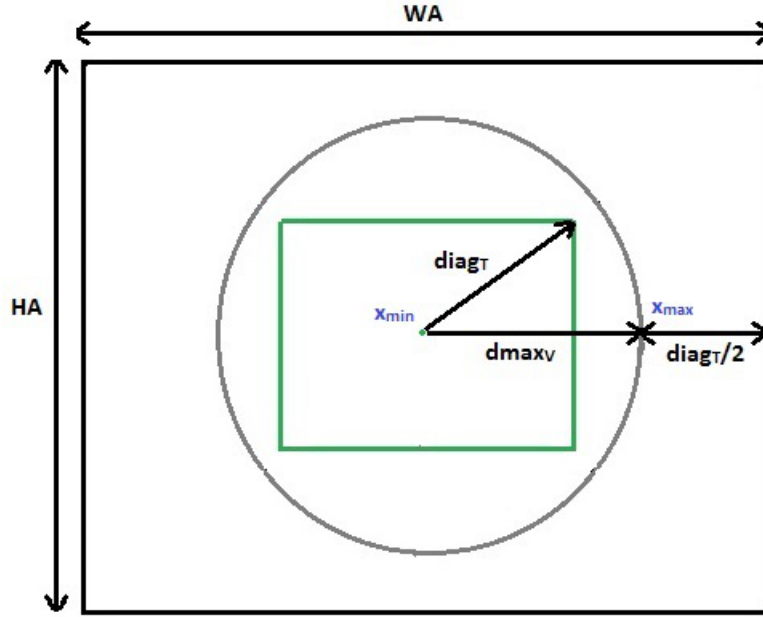


Figura 3.4: Determinação do tamanho da imagem alvo

$$d_{Vmax} = v_{Vmax} \cdot t_{Mmax} \cdot d_{m2px} \quad (3.28)$$

Levando em consideração que o VANT pode ter se movido para qualquer direção, a partir do último ponto registrado (x_{min}), então ele tem que estar dentro do raio de cobertura de $2 \cdot d_{Vmax}$, isto é, de 416,6 m ou 416 px.

Feitas estas considerações, o VANT deve se localizar em algum ponto do interior da circunferência de centro x_{min} e raio d_{Vmax} mostrada na Figura 3.4. Este ponto x_{max} seria o centro da imagem *template* e, como o VANT pode estar em qualquer orientação, então a diagonal do *template* ($diag_T$) deve ser utilizada no cálculo do tamanho da imagem alvo ao invés de sua maior dimensão (largura ou altura). O cálculo de $diag_T$ está apresentado na Equação 3.29. A largura (w_T) e altura (h_T) utilizadas no *template* foram, respectivamente, 720 e 486 px.

$$diag_T = \sqrt{h_T^2 + w_T^2} \quad (3.29)$$

Finalmente, considerando o raio de cobertura de localização do VANT ($2 \cdot d_{Vmax}$) e o tamanho da diagonal do *template*, obtém-se, por meio da Equação 3.30, a largura (w_A) e a altura (h_A) da imagem alvo iguais a 1286 px.

$$w_A = h_A = \text{round}(2 \cdot d_V \text{max} + \text{diag}_T) \quad (3.30)$$

onde *round* é uma função de arredondamento.

É desejável que os métodos de otimização utilizados possuam baixo custo computacional, pois quanto menor for o tempo entre reconhecimentos, menor será a região a ser explorada e mais próximo de um sistema de quase tempo real o sistema de visão computacional ficará.

A escolha do tempo máximo de processamento não é trivial, pois é necessário que o tempo seja suficientemente longo para que os métodos de otimização consigam convergir para a solução ótima global e, simultaneamente, curto para que a região de exploração não seja demasiadamente grande.

3.5.4 Seleção de Pontos Iniciais

Nos métodos de otimização determinísticos a procura pelo ponto ótimo usa o ponto corrente como ponto de partida para a próxima iteração. Logo, a procura é local, pois ocorre na vizinhança do ponto corrente. Assim, quando esses métodos encontram uma solução, há uma grande chance de ser um ótimo local, se a função objetivo for multimodal, o que é problemático para um registro de imagens confiável.

Então, para contornar o problema dos mínimos locais é necessário aplicar alguma técnica para conseguir uma boa exploração da imagem alvo e encontrar regiões mais suscetíveis de conter o *template*.

A técnica empregada consiste em selecionar, a partir de N pontos amostrados aleatoriamente de uma distribuição normal dentro do espaço de busca permitido para os parâmetros, os m pontos mais distantes entre si como pontos iniciais dos algoritmos. O procedimento se resume nos seguintes passos:

1. Gerar $N = 10 \cdot m$ pontos amostrados aleatoriamente de uma distribuição normal;
2. Obter a média dos pontos;
3. Calcular a distância entre os pontos e a média dos mesmos e selecionar o mais distante ao conjunto de pontos iniciais X_0 ;
4. Calcular a menor distância entre cada um dos $N-i+1$ pontos e os $i-1$ pontos escolhidos e selecionar o ponto com a maior das $N-i+1$ distâncias calculadas como o i -ésimo elemento de X_0 ;
5. Normalizar os valores de X_0 para dentro do espaço de busca permitido para os parâmetros.

Nos métodos determinísticos foram utilizados 15 pontos iniciais.

Este método também foi utilizado para gerar os pontos iniciais nos métodos estocásticos AG, PSO e DE, onde o número de pontos usado foi igual ao número de indivíduos (partículas) definido.

3.5.5 Tratamento das Imagens

Antes de aplicar as medidas de dissimilaridade às imagens, as mesmas passaram por um tratamento que consistiu nas seguintes etapas:

- Conversão para escala de cinza;
- Aplicação de um filtro de média zero e variância unitária se a medida de dissimilaridade usada for baseada em intensidade;
- Extração de borda usando o extrator Sobel se a medida de dissimilaridade usada for baseada em extração de características.

É essencial a normalização da intensidade dos pixels na imagens por meio de um filtro de média zero e variância unitária, pois as imagens são oriundas de sensores distintos e podem apresentar diferenças de luminosidade, o que poderia dificultar ou mesmo impedir o casamento das imagens.

A única medida de dissimilaridade baseada em intensidade que não utiliza essa normalização é a MI, pois no cálculo dos histogramas das imagens é necessário que os valores de intensidade sejam inteiros.

3.5.6 Paralelização dos Métodos de Otimização

Para demonstrar a aplicabilidade da paralelização nos métodos de otimização e usufruir melhor dos recursos computacionais foi utilizado o pacote *Parallel Computing Toolbox* do *MATLAB*. Foram usadas as funções *parfor* e *parfeval* com 4 *workers* (processadores).

Parfor

Permite a paralelização síncrona de laços de repetição do tipo *for* cujas iterações sejam independentes entre si e de ordenação. Só é possível obter os resultados após a execução de todas as iterações (MATLAB, 2015b).

Essa função foi utilizada na avaliação da função objetivo dos métodos estocásticos AG, PSO e DE.

A Figura 3.5 mostra o ganho de desempenho obtido com a paralelização à medida que o número de pontos utilizados é aumentado.




Figura 3.5: Ganho de desempenho obtido com a paralelização através do *parfor*

Parfeval

Permite a paralelização assíncrona da avaliação de uma função, fazendo com que ela seja executada em *background* e não seja necessário esperar pelo seu término. Um exemplo típico de sua aplicação é em métodos de otimização, onde é desejável finalizar a sua execução quando a solução obtida é suficientemente boa ou o tempo de execução excede o valor máximo especificado (MATLAB, 2015b).

Essa função foi utilizada em todos os métodos determinísticos e no estocástico SA, onde cada iteração executada corresponde a um ponto inicial distinto.

A Figura 3.6 mostra o ganho de desempenho obtido com a paralelização à medida que o número de pontos utilizados é aumentado. Pode-se observar que, somente a partir de um determinado número de pontos utilizados, há algum ganho de desempenho.

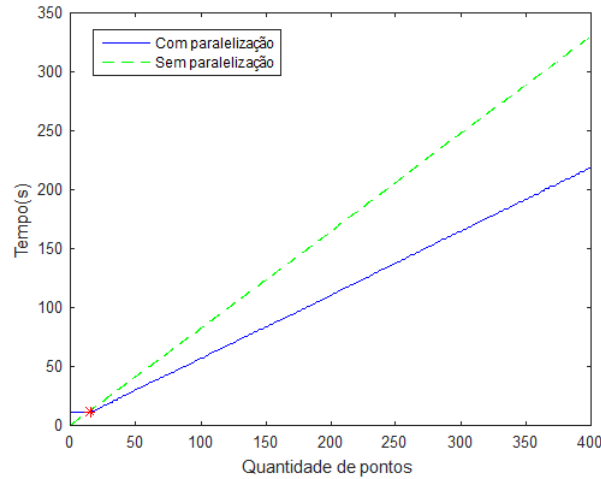


Figura 3.6: Ganho de desempenho obtido com a paralelização através do *parfeval*

3.5.7 Otimização

O problema foi tratado como um problema de otimização restrito e pode ser formulado como:

Encontrar :

$$x^* = \operatorname{argmin}_x f_{obj}(x) \quad (3.31)$$

Sujeito a :

$$x_k \min \leq x_k \leq x_k \max, \quad k = 1, \dots, d$$

onde $f_{obj}(x)$ é a função objetivo, x é o vetor de variáveis de otimização, x^* é a solução ótima global para o problema, $x_k \min$ e $x_k \max$ são os limites inferior e superior das variáveis do espaço de busca e d é o número de variáveis de otimização.

Variáveis de Otimização

O problema abordado possui 3 variáveis de otimização:

- x_1 = posição longitudinal
- x_2 = posição latitudinal
- x_3 = fator de escala

As variáveis x_1 e x_2 indicam a latitude e longitude onde ocorrerá o recorte da imagem alvo A , que corresponde ao ponto central da imagem registrada M . A variável x_3 indica quanto a imagem será ampliada ou reduzida, isto é, se serão utilizados menos ou mais pixels de A a partir do ponto central determinado.

Restrições

As restrições do problema são somente do espaço de busca. Os limites inferior e superior do espaço de busca estão apresentados na Equação 3.32.

$$\begin{aligned}
 x_{1min} &= \frac{w_T/2}{x_{3min}/100} + 1 \\
 x_{1max} &= w_A - \frac{w_T/2}{x_{3min}/100} \\
 x_{2min} &= \frac{h_T/2}{x_{3min}/100} + 1 \\
 x_{2max} &= h_A - \frac{h_T/2}{x_{3min}/100} \\
 x_{3min} &= 75 \\
 x_{3max} &= 125
 \end{aligned} \tag{3.32}$$

onde w_A e w_T são as larguras das imagens alvo A e imagem *template* T e h_A e h_T são as alturas de A e T .

Os valores dos limites inferior e superior de x_1 e x_2 foram escolhidos para que todos os pixels da imagem alvo transformada tenham sobreposição com os pixels da imagem *template* e, os de x_3 , para limitar os valores do fator de escala, de modo que o algoritmo não utilize valores muito elevados, o que poderia requerer uma quantidade excessiva de memória, e nem valores muito baixos, pois, caso T seja dimensionado para um pixel de tamanho por exemplo, então um bom ajuste seria encontrado em qualquer lugar de A .

Função Objetivo

Nos métodos de otimização restritos, a função objetivo é igual ao valor da medida de dissimilaridade utilizada, contudo, nos irrestritos, é necessário adicionar uma função de penalidade (f_{pen}), que contém todas as restrições violadas. Essa abordagem, dos métodos de penalidade, consiste na transformação do problema restrito original em um problema irrestrito equivalente pela associação da função de penalidade (Bastos, 2004).

A função objetivo utilizada está apresentada na Equação 3.33.

$$f_{obj} = f + f_{pen} = f + c \cdot (outPixels + outScale) \quad (3.33)$$

$$outPixels = \begin{cases} (x_{1min} - x_1) \cdot h_T, & \text{se } x_1 < x_{1min} \\ (x_1 - x_{1max}) \cdot h_T, & \text{se } x_1 > x_{1max} \\ (x_{2min} - x_2) \cdot w_T, & \text{se } x_2 < x_{2min} \\ (x_2 - x_{2max}) \cdot w_T, & \text{se } x_2 > x_{2max} \end{cases} \quad (3.34)$$

$$outScale = \begin{cases} |x_3|/x_{3min}, & \text{se } x_3 \leq x_{3min} \text{ e } |x_3| > x_{3min} \\ x_{3min}/|x_3|, & \text{se } x_3 \leq x_{3min} \text{ e } |x_3| \leq x_{3min} \\ |x_3|/x_{3max}, & \text{se } |x_3| > x_{3max} \end{cases} \quad (3.35)$$

onde c é uma constante de penalização, $outPixels$ é o número de pixels sem sobreposição entre as imagens e $outScale$ é um termo que quantifica o quanto o parâmetro de escala está fora dos limites permitidos. Para os métodos restritos $c = 0$ e, para os irrestritos, $c = 100$.

Aplicação do Algoritmo

O algoritmo de otimização inicia encontrando pontos iniciais factíveis. O ponto inicial x_0 é utilizado para aplicar uma transformação geométrica na imagem alvo A . Os pixels sobrepostos entre as imagens M e T são comparados por meio de alguma medida de dissimilaridade f . Essa medida de dissimilaridade é utilizada pelo algoritmo de otimização para a correção dos parâmetros de transformação x_k na próxima iteração k . Então, esse processo se repete até que o parâmetro de transformação desejado x'_k seja encontrado ou alguma condição de parada seja satisfeita. O processo iterativo de registro de imagens por meio de otimização está sintetizado na Figura 3.7.

A transformação geométrica consiste em extrair de A uma imagem maior ($x_3 < 100$) ou menor ($x_3 > 100$) do que o tamanho de T , com ponto central em $[x_1, x_2]$, e depois aplicar uma transformação afim à imagem, alterando apenas o fator de escala da matriz de transformação para que a imagem M fique com o mesmo tamanho de T .

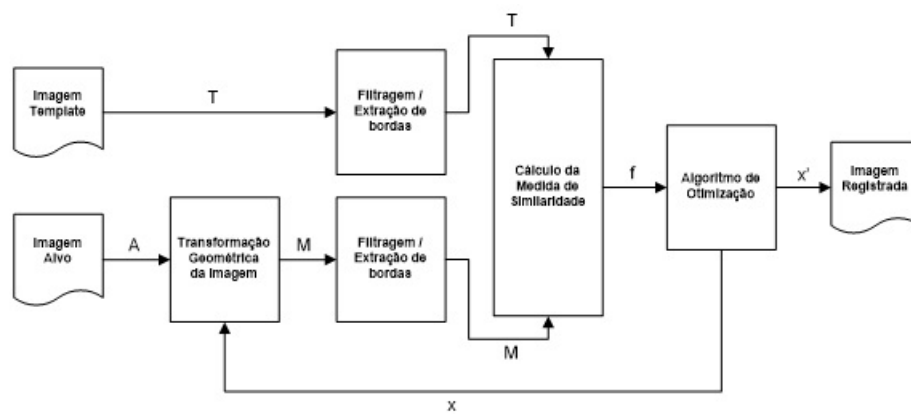


Figura 3.7: Diagrama do registro de imagens baseado em otimização

Capítulo 4

Resultados e Discussão

Cada teste consistiu em avaliar um método de otimização usando uma medida de dissimilaridade e uma imagem de teste. Para avaliar a acurácia, precisão e custo computacional dos testes, cada um foi executado por 20 vezes e a média e desvio padrão dos erros de estimação de posição foram calculados, bem como o tempo médio de execução.

Os critérios de parada utilizados foram:

- Tempo máximo de execução igual a 10 s;
- Valor da função objetivo inferior a 0.1;
- Diversidade das soluções obtidas inferior a 5 % nos métodos estocásticos;
- Número máximo de avaliações da função objetivo superior a 50, para cada ponto inicial, nos métodos determinísticos.

O cálculo da medida de diversidade (md) das soluções está apresentado na Equação 4.1.

$$md = \frac{|x^* - \bar{x}|}{x^*} \quad (4.1)$$

onde x^* é a melhor solução encontrada na iteração e \bar{x} é a média das soluções nessa iteração.

O erro de estimação de posição foi determinado como a distância geográfica entre o ponto real e o ponto encontrado pelo algoritmo. Para calcular essa distância foi utilizada a fórmula de Haversine, que é uma importante equação usada em navegação para calcular a distância geográfica entre dois pontos da Terra a partir de suas longitudes e latitudes. Seu cálculo está apresentado na Equação 4.2 (Sinnott, 1984).

$$d = 2R \arcsin \left(\sqrt{\sin^2 \left(\frac{lat2 - lat1}{2} \right) + \cos(lat1) \cos(lat2) \sin^2 \left(\frac{lon2 - lon1}{2} \right)} \right) \quad (4.2)$$

onde d é a distância entre os dois pontos em m , R é o raio da Terra em m , $lon1$ e $lon2$ são as longitudes dos pontos 1 e 2 e $lat1$ e $lat2$ são as latitudes destes pontos. Foi utilizado o raio equatorial (WGS84) da Terra, que é igual a 6.378.137 m .

É desejável sempre que nos experimentos a acurácia e a precisão sejam maximizadas.

A acurácia determina o quão próximo uma medida se encontra do valor real. É geralmente quantificada como a média de uma série de medidas. Se as medidas forem de erro, quanto menor a média, maior é a acurácia (Thomsen, 1997).

A precisão é uma medida de concordância entre medições repetidas de uma mesma grandeza. É geralmente quantificada como o desvio padrão de uma série de medidas. Se as medidas forem de erro, então quanto menor o desvio padrão, maior é a precisão (Thomsen, 1997).

A acurácia e a precisão estão ilustradas na Figura 4.1.

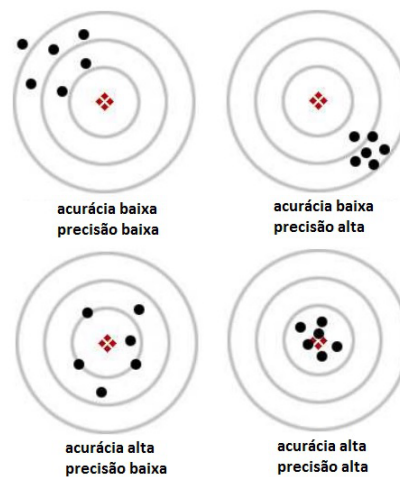


Figura 4.1: Acurácia e precisão

Nos experimentos realizados, espera-se que os métodos determinísticos tenham custo computacional menor que os estocásticos, pois, em geral, necessitam de menos avaliações da função objetivo para alcançar a solução ótima global. No entanto, por dependerem de derivadas numéricas da fun-

ção objetivo e de uma boa estratégia para lidar com o problema de mínimos locais, é esperado que sua precisão e acurácia também sejam menores.

Em relação às medidas de dissimilaridade, as baseadas em extração de características devem apresentar custo computacional mais baixo que as baseadas em intensidade, pois utilizam imagens binárias (1 bit/pixel) enquanto estas imagens em escala de cinza (8 bits/pixel). Elas também devem ser robustas a mudanças de luminosidade e de resposta espectral. Com a utilização do filtro de média zero e variância unitária, as dissimilaridades baseadas em intensidade também devem apresentar esta robustez.

É esperado que as dissimilaridades baseadas em informação espacial e entropia apresentem um ganho de acurácia/precisão em relação às dissimilaridades mais simples, baseadas somente em intensidade. Contudo, nas baseadas em informação espacial, o ganho de desempenho deve resultar num custo computacional mais alto.

Nas dissimilaridades baseadas em extração de características, a utilização de mais informação, isto é, de borda e não borda, deve resultar num ganho de acurácia/precisão. O custo computacional adicional não deve ser significativo.

Por fim, para uma mesma medida de dissimilaridade devem ser obtidos desempenhos distintos quando métodos de otimização diferentes forem usados, o que significa que uma dissimilaridade pode ser uma candidata melhor à função objetivo de um algoritmo de otimização do que outra.

4.1 Resultados Gerais

4.1.1 Métodos de Otimização

Os valores médios dos erros, desvio padrão e tempo de execução, obtidos nos experimentos realizados para os métodos de otimização, estão apresentados na Figura 4.2. A acurácia pode ser inferida por meio da média dos erros; a precisão, pelo desvio padrão dos erros; e o custo computacional, pelo tempo de execução. A média e o desvio padrão dos erros estão apresentados em metros e o tempo de execução em segundos.




Figura 4.2: Resultados gerais dos métodos de otimização

4.1.2 Medidas de Dissimilaridade

A acurácia, a precisão e o custo computacional, obtidos nos experimentos realizados para as medidas de dissimilaridade, estão apresentados na Figura 4.3.

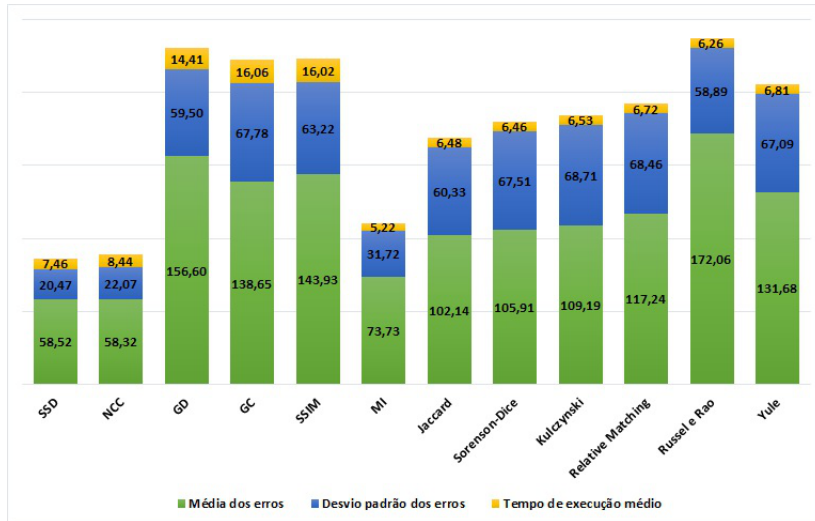


Figura 4.3: Resultados gerais das medidas de dissimilaridade

4.1.3 Imagens

A acurácia, a precisão e o custo computacional, obtidos nos experimentos realizados para as imagens de teste, estão apresentados na Figura 4.4.




Figura 4.4: Resultados gerais das imagens utilizadas

4.2 Resultados das Medidas de Dissimilaridade

As Figuras 4.5 a 4.16 apresentam os resultados obtidos para os métodos de otimização utilizando as medidas de dissimilaridade SSD, NCC, GD, GC, SSIM, MI, Jaccard, Sorenson-Dice, Kulczynski, Russel & Rao e Yule.




Figura 4.5: Resultados da medida de dissimilaridade SSD




Figura 4.6: Resultados da medida de dissimilaridade NCC

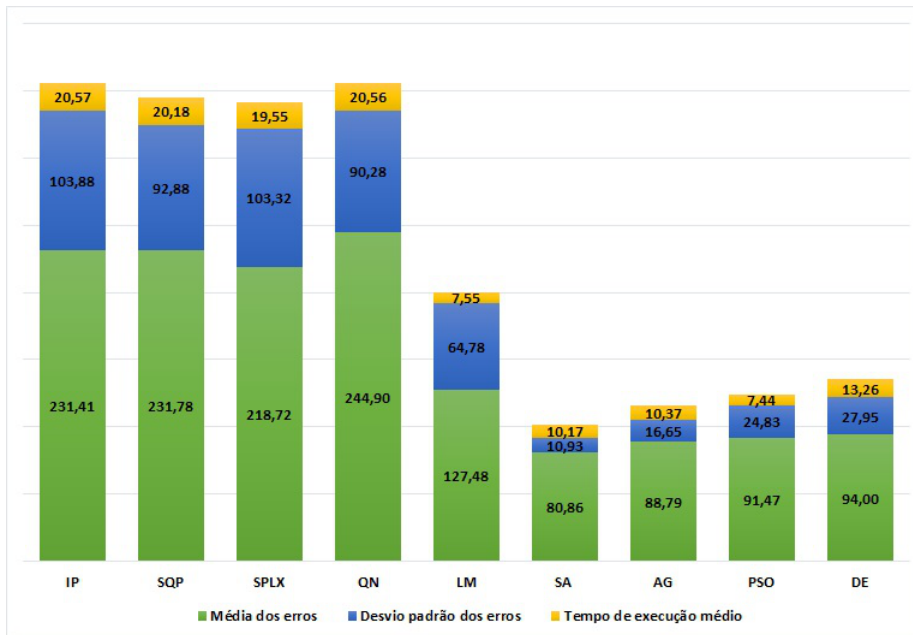


Figura 4.7: Resultados da medida de dissimilaridade GD




Figura 4.8: Resultados da medida de dissimilaridade GC

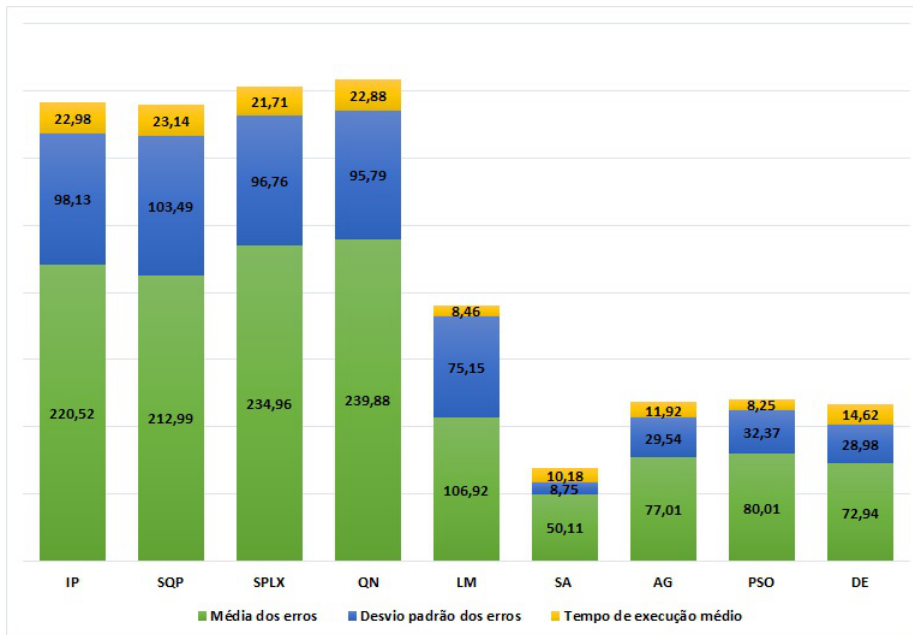


Figura 4.9: Resultados da medida de dissimilaridade SSIM




Figura 4.10: Resultados da medida de dissimilaridade MI




Figura 4.11: Resultados da medida de dissimilaridade Jaccard




Figura 4.12: Resultados da medida de dissimilaridade Sorenson-Dice




Figura 4.13: Resultados da medida de dissimilaridade Kulczynski




Figura 4.14: Resultados da medida de dissimilaridade Relative Matching




Figura 4.15: Resultados da medida de dissimilaridade Russel & Rao




Figura 4.16: Resultados da medida de dissimilaridade Yule

4.3 Imagens Registradas

4.3.1 Com Dissimilaridades Baseadas em Intensidade

As Figuras 4.17 a 4.24 mostram as imagens registradas e *template*, obtidas utilizando o valor médio da solução encontrada pelo algoritmo SA com a dissimilaridade SSD.




Figura 4.17: Imagem 1 registrada (esquerda) e *template* (direita) usando SSD




Figura 4.18: Imagem 2 registrada (esquerda) e *template* (direita) usando SSD




Figura 4.19: Imagem 3 registrada (esquerda) e *template* (direita) usando SSD




Figura 4.20: Imagem 4 registrada (esquerda) e *template* (direita) usando SSD





Figura 4.21: Imagem 5 registrada (esquerda) e *template* (direita) usando SSD

Figura 4.22: Imagem 6 registrada (esquerda) e *template* (direita) usando SSDFigura 4.23: Imagem 7 registrada (esquerda) e *template* (direita) usando SSDFigura 4.24: Imagem 8 registrada (esquerda) e *template* (direita) usando SSD

As Figuras 4.25 a 4.32 exibem a localização da imagem registrada pelo algoritmo SA na imagem alvo usando a dissimilaridade SSD para as imagens de teste.




Figura 4.25: Localização da imagem registrada 1 na imagem alvo



Figura 4.26: Localização da imagem registrada 2 na imagem alvo



Figura 4.27: Localização da imagem registrada 3 na imagem alvo



Figura 4.28: Localização da imagem registrada 4 na imagem alvo




Figura 4.29: Localização da imagem registrada 5 na imagem alvo




Figura 4.30: Localização da imagem registrada 6 na imagem alvo



Figura 4.31: Localização da imagem registrada 7 na imagem alvo



Figura 4.32: Localização da imagem registrada 8 na imagem alvo

4.3.2 Com Dissimilaridade Baseadas em Extração de Características

As Figuras 4.33 a 4.40 mostram as imagens registradas e *template*, obtidas utilizando o valor médio da solução encontrada pelo algoritmo SA com a dissimilaridade Jaccard. A fim de facilitar a visualização destas figuras, as cores das mesmas foram invertidas.




Figura 4.33: Imagem 1 registrada (esquerda) e *template* (direita) usando Jaccard




Figura 4.34: Imagem 2 registrada (esquerda) e *template* (direita) usando Jaccard




Figura 4.35: Imagem 3 registrada (esquerda) e *template* (direita) usando Jaccard




Figura 4.36: Imagem 4 registrada (esquerda) e *template* (direita) usando Jaccard




Figura 4.37: Imagem 5 registrada (esquerda) e *template* (direita) usando Jaccard




Figura 4.38: Imagem 6 registrada (esquerda) e *template* (direita) usando Jaccard



Figura 4.39: Imagem 7 registrada (esquerda) e *template* (direita) usando Jaccard

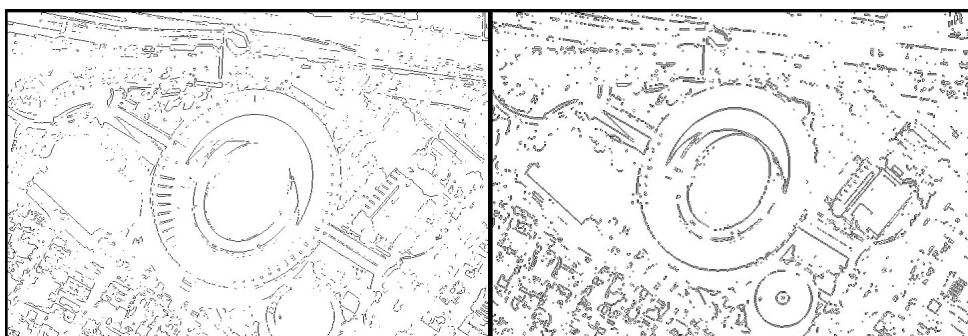


Figura 4.40: Imagem 8 registrada (esquerda) e *template* (direita) usando Jaccard

4.4 Discussão dos Resultados

4.4.1 Métodos de Otimização

Dos métodos determinísticos, o SPLX foi o que obteve as maiores acurácia e precisão e o LM, o menor custo computacional. Em contrapartida, o QN apresentou as menores acurácia e precisão e o IP, o maior custo computacional.

O melhor desempenho obtido pelo SPLX pode estar associado ao fato de ele ser o único método determinístico que não utiliza cálculo de derivadas. O pior desempenho do QN pode estar relacionado com erros numéricos da estimação das derivadas da função objetivo, que não possui derivadas analíticas, que devem ficar ainda maiores quando a Hessiana é calculada.

Dos métodos estocásticos, o SA foi o que apresentou maiores acurácia e precisão e o PSO, o menor custo computacional. Contudo, o PSO apresentou

menores acurácia e precisão e o DE, maior custo computacional.

Acredita-se que o melhor desempenho obtido pelo SA esteja relacionado com a sua capacidade de aceitar soluções de pior custo no início da otimização, considerando que as imagens utilizadas foram obtidas de sensores distintos e apresentam algumas diferenças entre si.

No caso do PSO, a redução do custo computacional acabou resultando na diminuição da sua acurácia e precisão.

Os métodos de otimização determinísticos obtiveram desempenho bem inferior (acurácia e precisão baixas e custo computacional alto) aos obtidos pelos estocásticos. Apenas nos experimentos em que dissimilaridades baseadas em intensidade local foram utilizadas é que ambos apresentaram resultados mais próximos.

4.4.2 Medidas de Dissimilaridade

Das medidas de dissimilaridade baseadas em intensidade, as que apresentaram maiores acurácias e precisão foram as que utilizam intensidade local (SSD e NCC) e menor custo computacional foi a que utiliza entropia (MI).

Em contrapartida, as que utilizam informação espacial (GD, GC e SSIM) apresentaram menores acurácia e maior custo computacional. Conforme pode ser observado na Figura 4.3, o tempo máximo de processamento especificado foi excedido nestas dissimilaridades, o que pode indicar que elas necessitam de maior custo computacional para obter resultados satisfatórios.

Das dissimilaridades baseadas em extração de borda, as que utilizam somente a informação de borda obtiveram maior acurácia do que as que utilizam também a informação de não borda. Destas, a dissimilaridade que se destacou foi a mais simples e comumente utilizada, a Jaccard.

Conforme era esperado, as dissimilaridades baseadas em extração de bordas obtiveram custo computacional mais baixo do que as baseadas em intensidade, porque utilizam menor quantidade de informação no seu cálculo, uma vez que as imagens utilizadas são binárias.

Acredita-se que o desempenho mais baixo obtido pelas dissimilaridades baseadas em extração de borda seja devido às imagens registradas de sensores distintos possuírem diferenças significativas entre si, resultando em informações de bordas menos similares, conforme pode ser observado nas Figuras 4.33 a 4.40.

4.4.3 Imagens

Verificou-se que as imagens do tipo zona urbana (2, 7 e 8), por possuírem terrenos estruturados e características mais robustas, apresentaram maior

acurácia que as dos demais tipos e o custo computacional para realizar o casamento também foi um pouco mais baixo.

Das imagens, a de número 5, do tipo zona rural, foi a que apresentou maiores acurácia e precisão e menor custo computacional; a de número 4, do tipo zona litorânea, apresentou a menor acurácia e o maior custo computacional; e a 7 apresentou a menor precisão.

Acredita-se que o melhor desempenho obtido pela imagem 5 seja devido a ela possuir características bem definidas que permitem distingui-la melhor de outros pontos na imagem alvo. Em contrapartida, a dificuldade no casamento da imagem 4 pode ter sido ocasionada pelo fato de, na imagem satélite utilizada, as regiões marítimas terem sido preenchidas com os mesmos valores de intensidade de pixel.

Capítulo 5

Conclusões e Propostas de Continuidade

5.1 Conclusões

Este trabalho demonstrou a utilização de métodos de otimização no problema de navegação autônoma de VANTs baseado em imagens orbitais.

Foi possível realizar uma comparação entre vários métodos de otimização (determinísticos e estocásticos) e medidas de dissimilaridade (baseadas em intensidade e em extração de características) com relação à acurácia, precisão e custo computacional.

Na comparação foram utilizadas imagens reais obtidas de sensores de imageamento distintos e foram considerados diferentes tipos de terreno (urbano, rural e litorâneo).

Entre os métodos de otimização, os estocásticos apresentaram melhor desempenho que os determinísticos, sendo que o SA se destacou entre eles.

Entre as medidas de dissimilaridade, as baseadas em intensidade obtiveram melhor desempenho do que as baseadas em extração de características, destacando-se as que utilizam intensidade local (SSD e NCC).

Embora as dissimilaridades baseadas em extração de características sejam robustas a variações espectrais e de luminosidade, os resultados obtidos mostraram que, devido às diferenças entre as imagens de satélite e do VANT, as bordas extraídas das imagens apresentaram discrepâncias significativas, prejudicando a acurácia e precisão do casamento das imagens.

Nas dissimilaridades baseadas em intensidade, o problema de diferenças de luminosidade foi contornado com a normalização das imagens usando um filtro de média zero e desvio padrão unitário.

Verificou-se que, para uma mesma medida de dissimilaridade, são obtidos

desempenhos distintos quando métodos de otimização diferentes são usados, o que indica que uma dissimilaridade pode ser uma candidata melhor à função objetivo de um algoritmo de otimização do que outra. Essa conclusão também havia sido verificada por Van der Bom *et al.* (2011) em seus experimentos.

Uma das dificuldades encontradas foi determinar o tempo máximo dos métodos para localizar uma imagem *template*, uma vez que este determina o tamanho da imagem alvo. Se o tempo for muito curto, os métodos de otimização podem não convergir para a solução ótima global e, se for muito longo, a região de exploração pode ficar demasiadamente grande, dificultando que os métodos alcancem essa solução.

Outra dificuldade que pode ser encontrada é para embarcar os métodos de otimização e utilizar a paralelização nos mesmos. Apesar de serem necessários conhecimentos mais específicos na implementação e de um hardware com memória suficiente e *multicore*, com o avanço da tecnologia, atualmente é relativamente barato e fácil obter um hardware com essas especificações, como exemplo a Raspberry Pi 2, que possui 4 núcleos ARM Cortex A7, 1 GB de memória RAM e armazenamento por meio de microSD.

Uma das desvantagens ao se aplicar métodos de otimização na navegação autônoma de VANTs é que os algoritmos dependem de parametrizações e estas parametrizações influenciam diretamente na acurácia e precisão. O custo computacional, por sua vez, é dependente da implementação dos algoritmos, sendo o custo quanto mais baixo quanto mais eficiente for a implementação.

Outra desvantagem é que o custo computacional dos métodos de otimização cresce significativamente com o aumento do número de graus de liberdade das transformações geométricas aplicadas às imagens, uma vez que a região de exploração dos métodos também é aumentada.

Algo que poderia tornar a estimação da posição do VANT mais precisa seria a inclusão da informação a priori oriunda dos sensores inerciais da aeronave à navegação.

É preciso ressaltar que a comparação de desempenho dos métodos de otimização é dependente da implementação realizada dos mesmos, o que significa que um método não seja mais eficiente do que outro, mas sim a implementação utilizada do mesmo. Por outro lado, como as medidas de dissimilaridade possuem uma formulação matemática bem definida, a comparação de desempenho entre elas não apresenta esta dependência.

A aplicação dos métodos de otimização mostrou-se promissora, principalmente, por fornecer uma alternativa ao *template matching*, em que é possível realizar o casamento entre as imagens sem precisar das informações de escala e rotação da imagem registrada pelo VANT, a inclusão de mais parâmetros de transformação às imagens e a paralelização do algoritmo.

5.2 Propostas de Continuidade

Como continuidade deste trabalho, alguns trabalhos futuros são sugeridos:

- Aplicar o método de correção de perspectiva proposto por Jaimes *et al* (2016) e avaliar os impactos na acurácia e precisão;
- Avaliar o ganho de desempenho computacional ao utilizar GPUs (Unidades de Processamento Gráfico) nos algoritmos;
- Implementar e embarcar em um VANT um dos métodos de otimização e uma das medidas de dissimilaridade que obtiveram os melhores desempenhos e realizar testes reais de voo;
- Propor uma implementação mais eficiente de um dos métodos de otimização utilizados, que seja menos dependente possível de parametrizações e possibilite aplicações práticas de quase tempo real;
- Propor uma abordagem para a determinação de uma relação de compromisso ótima entre o tempo máximo dos métodos para localizar uma imagem *template* e o tamanho da imagem alvo.

Referências Bibliográficas

Alencar, Felipe (2015). *Entenda a diferença entre Drone e VANT e suas aplicações práticas*. URL: <http://www.techtudo.com.br/noticias/noticia/2015/05/entenda-diferenca-entre-drone-e-vant-e-suas-aplicacoes-praticas.html>.

Ávila, S.L. (2002). *Algoritmos Genéticos Aplicados na Otimização de Antenas Refletoras*. Dissertação (Mestrado). Universidade Federal de Santa Catarina, Programa de Pós-graduação em Engenharia Elétrica.

Bastos, E.A (2004). *Otimização de Seções Retangulares de Concreto Armado Submetidas à Flexo-Compressão Oblíqua Utilizando Algoritmos Genéticos*. Dissertação de Mestrado em Ciências em Engenharia Civil - COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro.

Chisu, R. (2005). *Technique for Accelerating Intensity-Based Rigid Image Registration*. Master's thesis. Technische Universitat Munchen, Munchen.

Corrêa, R.S., R.R. Saldanha, A.P. Braga (2016). *Navegação Autônoma de VANTs Baseada em Imagens Orbitais e Métodos de Otimização*. XII Simpósio de Mecânica Computacional, UFVJM. Anais do SIMMEC 2016.

Dame, A., E. Marchand (2012). *Second-order optimization of mutual information for real-time image registration*. IEEE Trans. on Image Processing 21(9).

Goldberg, D.E (1989). *Genetic Algorithms in Search Optimization and Machine Learning*. Reading MA: Addison-Wesley.

Google Earth, 2015. *Imagens da Cidade do RJ*. URL: <https://www.google.com/earth>.

IBGE, 2014. *Ortomosaico do Projeto RJ-25*. URL: <ftp://geoftp.ibge.gov.br/>

imagens_do_territorio/imagens_corrigidas/ortomosaicos/rj25.

Jaimes, B.A., F.S. Torres, C.L. Castro (2016). *Correção de Perspectiva em Imagens Aplicada à Navegação Autônoma de VANTs*. XII Simpósio de Mecânica Computacional, UFVJM. Anais do SIMMEC 2016.

Jorge, L.A.C., R.Y. Inamasu (2014). *Uso de Veículos Aéreos Não Tripulados (VANT) em Agricultura de Precisão*. Embrapa Instrumentação. São Carlos, SP.

Kennedy, J., R.C. Eberhart (2001). *Swarm Intelligence*. Morgan Kaufmann, San Francisco, CA.

Kher, H. R. (2014). *Implementation of Image Registration for Satellite Images using Mutual Information and Particle Swarm Optimization Techniques*. International Journal of Computer Applications 97(1), 7-14.

Kirkpatrick, S., D.C. Gellat, M.P. Vecchi (1983). *Optimization by Simulated Annealing*. Science, 220:671680.

Machowski, L.A., T. Marwala (2007). *Evolutionary Optimisation Methods for Template Based Image Registration*. arXiv preprint arXiv: 0705.1674.

Machowski, L.A. (2007). *Insights on using Non-Evolutionary Optimisation Methods for Template Based Image Registration*. Journal: School of Electrical and Information Engineering. University of Witwatersrand, South Africa.

Mehrotra, S. (1991). *On finding a vertex solution using interior point methods*. Linear Algebra and Its Applications, 152 233-253.

Nelder, J.A., R. Mead (1965). A simplex method for function minimization. Computer Journal, 7(4) 308-313.

Mathworks, (2015). *Optimization Toolbox*.

Mathworks, (2015). *Parallel Computing Toolbox*.

Parker, J.R. (1997). *Algorithms for Image Processing and Computer Vision*. New York, John Wiley & Sons, Inc., 23-29.

Penney, G.P., J. Weese, J.A. Little, P. Desmedt, D.L. Hill (1998). *A compa-*

Comparison of similarity measures for use in 2-D-3-D medical image registration. IEEE transactions on medical imaging, 17(4), 586-595.

Santos, A.L., L.C.B. Torres, E.H. Shiguemori, H.F.C. Velho, A.P. Braga (2013). *Controle e navegação de VANTs através de utilização de template matching.* Anais do Computer on the beach 2013, 70-78.

Silva, C.A.O., G.A.M. Goltz, E.H. Shiguemori, C.L. Castro, H.L. Castro, A.P. Braga (2015). *Avaliação da Técnica de Casamento de Imagens para Navegação Autônoma de VANTs.* 12º Congresso Brasileiro de Inteligência Computacional, Curitiba.

Sinnott, R.W. (1984). *Virtues of the Haversine.* Sky and Telescope, 68(2), 159.

Sorrentino, D. (2006). *ELEC 503 - Term Project: Optimization Based Image Registration.*

Storn, R., K. Price (1997). *Differential evolution - A simple and efficient heuristic for global optimization over continuous spaces.* J. Global Optimiz, 11 341359.

Terra, R., J. Brunet, L. Miranda, M.T. Valente, D. Serey, D. Castilho, R. Bigonha (2013). *Measuring the structural similarity between source code entities.*

Thomsen, V. (1997). *Precision and The Terminology of Measurement.* The Physics Teacher 35, 15-17.

Van der Bom, I.M.J., S. Klein, M. Staring, R. Homan, L.W. Bartels, J.P.W. Pluim (2011). *Evaluation of optimization methods for intensity-based 2D-3D registration in x-ray guided interventions.* In SPIE Medical Imaging (pp. 796223-796223). International Society for Optics and Photonics.

Wang, Z., Bovik, A.C., Sheikh, H.R., Simoncelli, E.P. (2004). *Image quality assessment: from error visibility to structural similarity".* IEEE Transactions on Image Processing 13(4) 600612.

Yang, Y. (2009). *Remote sensing image registration via active contour model.* International Journal of Electronics and Communications 65, 227-234.

Zitova, B., J. Flusser (2003). *Image registration methods: a survey*. Elsevier B.V. *Image and Vision Computing* 21, 977-1000.