



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21c/2019/05.25.00.57-TDI

## **SISTEMA DE POSICIONAMENTO DE VANT BASEADO EM IMAGENS**

Rodrigo Augusto Rebouças

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Computação Aplicada, orientada  
pelo Dr. Lamartine Nogueira  
Frutuoso Guimarães, aprovada em  
27 de maio de 2019.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3TC4LNL>>

INPE  
São José dos Campos  
2019

**PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GBDIR)

Serviço de Informação e Documentação (SESID)

CEP 12.227-010

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/7348

E-mail: pubtc@inpe.br

**CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE - CEPPII (PORTARIA Nº 176/2018/SEI-INPE):****Presidente:**

Dra. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CGCPT)

**Membros:**

Dra. Carina Barros Mello - Coordenação de Laboratórios Associados (COCTE)

Dr. Alisson Dal Lago - Coordenação-Geral de Ciências Espaciais e Atmosféricas (CGCEA)

Dr. Evandro Albiach Branco - Centro de Ciência do Sistema Terrestre (COCST)

Dr. Evandro Marconi Rocco - Coordenação-Geral de Engenharia e Tecnologia Espacial (CGETE)

Dr. Hermann Johann Heinrich Kux - Coordenação-Geral de Observação da Terra (CGOBT)

Dra. Ieda Del Arco Sanches - Conselho de Pós-Graduação - (CPG)

Silvia Castro Marcelino - Serviço de Informação e Documentação (SESID)

**BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon

Clayton Martins Pereira - Serviço de Informação e Documentação (SESID)

**REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

Simone Angélica Del Ducca Barbedo - Serviço de Informação e Documentação (SESID)

André Luis Dias Fernandes - Serviço de Informação e Documentação (SESID)

**EDITORAÇÃO ELETRÔNICA:**

Ivone Martins - Serviço de Informação e Documentação (SESID)

Cauê Silva Fróes - Serviço de Informação e Documentação (SESID)



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

sid.inpe.br/mtc-m21c/2019/05.25.00.57-TDI

## **SISTEMA DE POSICIONAMENTO DE VANT BASEADO EM IMAGENS**

Rodrigo Augusto Rebouças

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Computação Aplicada, orientada  
pelo Dr. Lamartine Nogueira  
Frutuoso Guimarães, aprovada em  
27 de maio de 2019.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34R/3TC4LNL>>

INPE  
São José dos Campos  
2019

Dados Internacionais de Catalogação na Publicação (CIP)

---

Rebouças, Rodrigo Augusto.

R242s Sistema de posicionamento de VANT baseado em imagens / Rodrigo Augusto Rebouças. – São José dos Campos : INPE, 2019.

xvi + 106 p. ; (sid.inpe.br/mtc-m21c/2019/05.25.00.57-TDI)

Dissertação (Mestrado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2019.

Orientador : Dr. Lamartine Nogueira Frutuoso Guimarães.

1. VANT. 2. Navegação autônoma. 3. Pontos de interesse. 4. RANSAC. 5. Odometria Visual. I.Título.

CDU 004.455.1:629.014.8

---



Esta obra foi licenciada sob uma Licença [Creative Commons Atribuição-NãoComercial 3.0 Não Adaptada](https://creativecommons.org/licenses/by-nc/3.0/).

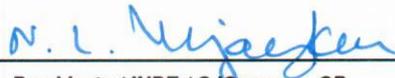
This work is licensed under a [Creative Commons Attribution-NonCommercial 3.0 Unported License](https://creativecommons.org/licenses/by-nc/3.0/).

Aluno (a): **Rodrigo Augusto Rebouças**

Título: "SISTEMA DE POSICIONAMENTO DE VANT BASEADO EM IMAGENS"

Aprovado (a) pela Banca Examinadora  
em cumprimento ao requisito exigido para  
obtenção do Título de **Mestre** em  
**Computação Aplicada**

Dr. Nandamudi Lankalapalli Vijaykumar

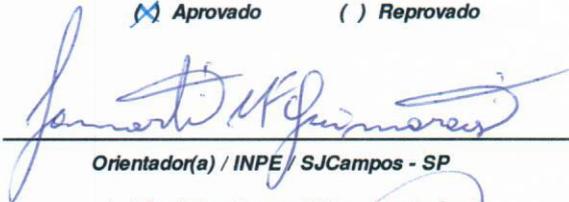


Presidente / INPE / SJCampos - SP

Participação por Vídeo - Conferência

Aprovado  Reprovado

Dr. Lamartine Nogueira Frutuoso  
Guimarães

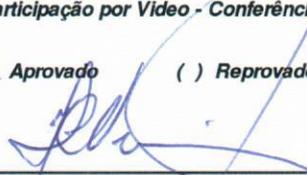


Orientador(a) / INPE / SJCampos - SP

Participação por Vídeo - Conferência

Aprovado  Reprovado

Dr. Haroldo Fraga de Campos Velho



Membro da Banca / INPE / São José dos Campos - SP

Participação por Vídeo - Conferência

Aprovado  Reprovado

Dr. Matheus Habermann



Convidado(a) / IEAv / São José dos Campos - SP

Participação por Vídeo - Conferência

Aprovado  Reprovado

Dr. Elcio Hideiti Shiguemori



Convidado(a) / IEAv / São José dos Campos - SP

Participação por Vídeo - Conferência

Aprovado  Reprovado

Este trabalho foi aprovado por:

maioria simples

unanimidade

São José dos Campos, 27 de maio de 2019



## AGRADECIMENTOS

Primeiramente a Deus, pela força interior para a realização de mais uma etapa em minha vida.

À minha família, pelo incentivo, apoio e compreensão nos momentos de ausência, em especial aos meus pais Vanderlei Frotas Rebouças e Vera Lucia Rebouças, minha esposa Evelyn Iasmin Silva Rebouças e ao meu filho Miguel Rezende Rebouças.

Aos meus orientadores, Dr. Lamartine Nogueira Frutuoso Guimarães, pela ajuda, disponibilidade, paciência, conhecimentos e ensinamentos compartilhados e ao Dr. Elcio Hideiti Shiguemori, que foi além da orientação, um amigo e conselheiro desde a época de graduação e iniciação científica, que me incentivou a realização do mestrado e seguir a área acadêmica.

Aos amigos e colegas do projeto PITER e do IEAv, pelas ideias e ajuda desta dissertação.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelos auxílios financeiros concedidos durante a realização deste mestrado.

Aos membros da banca examinadora da defesa de mestrado, pela participação e orientação.

Por fim, agradeço a todos aqueles que colaboraram para a realização deste trabalho.



## RESUMO

O uso de Veículos Aéreos não Tripulados (VANT) para a captura de imagens tem crescido nos últimos anos, tendo diversas aplicações nas áreas de desmatamento, sistema de vigilância e mosaico de imagens. A navegação autônoma desse tipo de veículo geralmente faz uso de sensores inerciais e GPS, entretanto o GPS possui algumas deficiências, por exemplo: erros de posicionamento; falhas de comunicação; e vulnerabilidade, com isso há uma necessidade de se buscar formas de aprimorar e auxiliar o sistema de navegação da aeronave, buscando uma maior confiabilidade no sistema de posicionamento durante o voo. Neste trabalho faz-se uso de um sistema autoconfigurado, para navegação de VANT baseado por imagens, para auxiliar o GPS. O Trabalho, em uma etapa inicial, faz a comparação de métodos de pontos de interesse binários ORB, BRISK, FREAK, AKAZE e LACH configurados pelo Algoritmo Genético, para detecção de pontos característicos em imagens de diferentes tipos de cobertura de solo, o uso do método RANdom SAmple Consensus (RANSAC) para eliminar falsas correspondências entre os pontos detectados, e a Odometria Visual para estimar a posição do VANT, com uso das correspondências e sensores da aeronave. Para implementação de um sistema autoconfigurado, para cada imagem de entrada do VANT, o sistema identifica através de medidas de texturas, qual parâmetro extraído com o Algoritmo Genético é mais adequado para a imagem, com uso de lógica Fuzzy. O trabalho obteve os seguintes resultados: entre a comparação dos métodos de pontos de interesse, o AKAZE teve a melhor relação de desempenho; entre as medidas de texturas, o contraste e heterogeneidade apresentaram melhor separação entre as coberturas de solo; a lógica nebulosa para configurar automaticamente o parâmetro do AKAZE teve uma melhora na taxa de acerto de 30% em relação aos parâmetros padrões, além de manter o tempo computacional; e o erro da estimação de posição da aeronave é inferior a 10% da distancia percorrida.

Palavras-chave: VANT. Navegação autônoma. pontos de interesse. RANSAC. Odometria Visual. Fuzzy.



# UAV POSITIONING SYSTEM BASED ON IMAGES

## ABSTRACT

The use of Unmanned Aerial Vehicles (UAV) for an image capture has been growing in recent years and has been the target of several applications in the areas of deforestation, surveillance and mosaic of images. The autonomous navigation of this type of vehicle, typically makes use of inherent sensors and GPS, just as the GPS has some deficiencies, for example: positioning errors; communication failures; and vulnerability, with this there is a way to seek advanced and auxiliary forms of aircraft navigation system, seeking a higher speed without a positioning system during flight. When using an autoconfigured system, for the navigation of UAV by images, to assist the GPS. The work, in an initial stage, makes a comparison of methods of binary interest points ORB, BRISK, FREAK, AKAZE and LACH configured by the Genetic Algorithm, for the detection of characteristic points in images of different types of soil cover, the use of the RANdom Consensus SA Method (RANSAC) to eliminate false correspondences between the detected points, and Visual Odometry to estimate the position of the UAV, with the use of aircraft correspondences and sensors. For the implementation of an autoconfigured system, for each input image of the UAV, the system of identification through texture measurements can be used as an additional parameter for the Genetic Algorithm for the image, using Fuzzy logic. The work obtained the following results: in the comparison of the methods of points of interest, the AKAZE had a better relation of performance; considering textures, contrast and heterogeneity, among soil forms; the Fuzzy to automatically configure the AKAZE parameter, had an improvement in the 30 % hit rate compared to paragraph standards, in addition to maintaining computational time; the aircraft position error is less than 10% of the distance traveled.

Keywords: UAV. Autonomous navigation. Interest points. RANSAC. Visual Odometry. Fuzzy.



## LISTA DE FIGURAS

	<u>Pág.</u>
1.1 Sinal do GPS afetado. . . . .	3
3.1 Orientações para obtenção da GLCM. . . . .	11
3.2 Exemplo de Matriz GLCM. . . . .	12
3.3 Detecção de características. . . . .	14
3.4 Diferenças de Gaussianas para diversas oitavas de uma imagem. . . . .	15
3.5 Detecção de extremos no espaço-escala. . . . .	16
3.6 Aproximações de núcleo Gaussiano do SURF. . . . .	17
3.7 Detector de cantos FAST. . . . .	18
3.8 Padrão de amostragem do BRISK. . . . .	19
3.9 Padrão de amostragem do FREAK. . . . .	20
3.10 Comparação entre o espaço de escala gaussiana e Difusão Não-Linear. . . . .	21
3.11 Testes binários dos descritores LDB e M-LDB. . . . .	22
3.12 Visualização do descritor LATCH. . . . .	23
3.13 Processos para odometria visual. . . . .	24
3.14 Esquema do AG. . . . .	25
4.1 Fluxograma do sistema de posicionamento do VANT. . . . .	30
4.2 Efeitos das atitudes da aeronave. . . . .	31
4.3 Casamento de imagens. . . . .	32
4.4 Odometria Visual. . . . .	34
4.5 Fluxograma do Algoritmo Genético para pontos de interesse. . . . .	35
4.6 Fluxograma para geração de Inferência Fuzzy. . . . .	38
5.1 Aeronave e câmera. . . . .	41
5.2 Exemplo de imagens de voos. . . . .	43
5.3 Exemplo de quantidade de <i>inliers</i> . . . . .	44
5.4 <i>Inliers</i> entre as imagens com os parâmetros padrões. . . . .	45
5.5 <i>Inliers</i> que obtiveram a matriz de homografia entre as imagens com os parâmetros padrões. . . . .	47
5.6 Tempo entre as imagens com os parâmetros padrões. . . . .	48
5.7 Tempo entre as imagens que obtiveram a matriz de homografia com os parâmetros padrões. . . . .	49
5.8 <i>Inliers</i> entre as imagens com Algoritmo Genético. . . . .	54
5.9 Erro entre as imagens com os parâmetros padrões. . . . .	56
5.10 Erro entre as imagens com Algoritmo Genético. . . . .	56

5.11	Tempo entre as imagens com Algoritmo Genético em diferentes coberturas de solo. . . . .	59
5.12	Erro entre as imagens com Algoritmo Genético em diferentes coberturas de solo. . . . .	60
5.13	Limiar normalizado dos métodos entre as imagens com Algoritmo Genético em diferentes coberturas de solo. . . . .	60
5.14	Mapa de intensidades das medidas estatísticas e o limiar. . . . .	64
5.15	Lógica Nebulosa do sistema autoconfigurado. . . . .	66
5.16	Conjunto de imagens com região urbana. . . . .	69
5.17	Estimação de posição em imagem de região urbana. . . . .	70
5.18	Conjunto de imagens com região de vegetação rasteira. . . . .	71
5.19	Estimação de posição em imagem de região de vegetação rasteira. . . . .	72
5.20	Conjunto de imagens com região de vegetação densa. . . . .	73
5.21	Estimação de posição em imagem de região de vegetação densa. . . . .	74
5.22	Conjunto de imagens com região de vegetação mista. . . . .	75
5.23	Estimação de posição em imagem de região de vegetação mista. . . . .	76
5.24	Conjunto de imagens com região de vegetação e lago. . . . .	77
5.25	Estimação de posição em imagem de região de vegetação e lago. . . . .	78
5.26	Conjunto de imagens com região de vegetação e urbana. . . . .	79
5.27	Estimação de posição em imagem de região de vegetação e urbana. . . . .	80

## LISTA DE TABELAS

	<u>Pág.</u>
5.1 Combinação dos métodos de pontos de interesse. . . . .	44
5.2 Quantidade de <i>inliers</i> com uso de parâmetro fixo. . . . .	46
5.3 Quantidade de <i>inliers</i> com uso de parâmetro fixo que obtiveram a matriz de homografia. . . . .	47
5.4 Tempo entre as imagens com uso de parâmetro padrão. . . . .	50
5.5 Tempo entre as imagens com uso de parâmetro padrão e obtido com algoritmo genético. . . . .	55
5.6 Comparação do erro da matriz de homografia. . . . .	57
5.7 Comparação de índice de acerto. . . . .	58
5.8 Tempo entre as imagens com Algoritmo Genético em diferentes atitudes da aeronave. . . . .	61
5.9 Erro entre as imagens com Algoritmo Genético em diferentes atitudes da aeronave. . . . .	62
5.10 Limiar normalizado entre as imagens com Algoritmo Genético em diferentes atitudes da aeronave. . . . .	62
5.11 Regras de inferência. . . . .	67
5.12 Comparação do tempo de processamento e taxa de acerto respectivos ao <i>Dataset</i> . . . . .	67
5.13 Comparação quantidade dos pontos de interesse. . . . .	68
5.14 Odometria visual em região urbana. . . . .	69
5.15 Odometria visual em região de vegetação rasteira. . . . .	71
5.16 Odometria visual em região de vegetação densa. . . . .	73
5.17 Odometria visual em região de vegetação mista. . . . .	75
5.18 Odometria visual em região de vegetação e lago. . . . .	77
5.19 Odometria visual em região de vegetação e urbana. . . . .	79
B.1 Quantidade de <i>inliers</i> com os parâmetros padrões. . . . .	93
B.2 Quantidade de <i>inliers</i> com os parâmetros obtidos pelo algoritmo genético. . . . .	94
C.1 Tempo entre as imagens com os parâmetros padrões. . . . .	97
C.2 Tempo entre as imagens com os parâmetros obtidos pelo algoritmo genético. . . . .	98
D.1 Erro entre as imagens com os parâmetros padrões. . . . .	101
D.2 Erro entre as imagens com os parâmetros obtidos pelo algoritmo genético. . . . .	102



## SUMÁRIO

	<u>Pág.</u>
<b>1 INTRODUÇÃO</b> . . . . .	<b>1</b>
1.1 Problemática . . . . .	2
1.2 Motivação . . . . .	4
1.3 Objetivos . . . . .	4
1.4 Contribuições . . . . .	5
1.5 Organização do trabalho . . . . .	6
<b>2 NAVEGAÇÃO AUTÔNOMA</b> . . . . .	<b>7</b>
<b>3 FUNDAMENTAÇÃO TEÓRICA</b> . . . . .	<b>11</b>
3.1 Textura . . . . .	11
3.2 Pontos de interesse . . . . .	14
3.2.1 SIFT . . . . .	14
3.2.2 SURF . . . . .	16
3.2.3 ORB . . . . .	17
3.2.4 BRISK . . . . .	18
3.2.5 FREAK . . . . .	20
3.2.6 KAZE . . . . .	20
3.2.7 AKAZE . . . . .	21
3.2.8 LATCH . . . . .	22
3.3 Odometria Visual . . . . .	23
3.4 Algoritmo Genético (AG) . . . . .	24
3.5 Lógica Fuzzy . . . . .	26
3.5.1 Fuzzificação . . . . .	26
3.5.2 Inferência . . . . .	27
3.5.3 Defuzzificação . . . . .	27
<b>4 METODOLOGIA PROPOSTA PARA A NAVEGAÇÃO AUTÔNOMA POR IMAGENS</b> . . . . .	<b>29</b>
4.1 Aquisição de Imagens . . . . .	30
4.2 Extração de pontos de interesse nas imagens aéreas . . . . .	31
4.3 Correspondência de pontos de interesse . . . . .	32
4.4 Eliminar falsas correspondências . . . . .	33

4.5	Escolher melhor correspondência . . . . .	33
4.6	Estimar deslocamento do VANT . . . . .	34
4.7	Algoritmo Genético (AG) . . . . .	35
4.8	Lógica Fuzzy . . . . .	37
<b>5</b>	<b>EXPERIMENTOS E RESULTADOS . . . . .</b>	<b>41</b>
5.1	Configuração do Algoritmo Genético . . . . .	50
5.2	Comparação dos Métodos de pontos de interesse com Algoritmo Genético	53
5.2.1	Variações de cobertura de solo . . . . .	58
5.2.2	Variações de atitudes e altitudes da aeronave . . . . .	61
5.3	Quantificação da imagem . . . . .	63
5.4	Sistema autoconfigurado . . . . .	65
5.5	Sistema de Odometria Visual . . . . .	68
5.5.1	Região urbana . . . . .	69
5.5.2	Região de vegetação rasteira . . . . .	71
5.5.3	Região de vegetação densa . . . . .	72
5.5.4	Região de vegetação mista . . . . .	74
5.5.5	Região de vegetação e lago . . . . .	76
5.5.6	Região de vegetação e urbana . . . . .	78
<b>6</b>	<b>CONCLUSÕES . . . . .</b>	<b>81</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS . . . . .</b>	<b>83</b>
	<b>ANEXO A - REGIÕES E ATITUDES DA AERONAVE NO CONJUNTO DE IMAGENS DE TESTE . . . . .</b>	<b>91</b>
	<b>ANEXO B - QUANTIDADE DE <i>INLIERS</i> ENTRE AS IMAGENS . . . . .</b>	<b>93</b>
	<b>ANEXO C - TEMPO ENTRE AS IMAGENS . . . . .</b>	<b>97</b>
	<b>ANEXO D - ERRO ENTRE AS IMAGENS . . . . .</b>	<b>101</b>
	<b>ANEXO E - DIFERENÇA ENTRE AS ATITUDES DA AERO- NAVE . . . . .</b>	<b>105</b>

# 1 INTRODUÇÃO

Com o avanço tecnológico e computacional, o uso de imagens aéreas e orbitais tem crescido nos últimos anos, tendo diversas aplicações, entre elas, nas áreas de desmatamento (ZHANG et al., 2017), sistemas de vigilância (NIJIM, 2016), mosaico de imagens (ZHEN et al., 2016), agricultura (OTAKE, 2017) e pecuária (ABADE et al., 2016). Algo que tem ajudado nesse crescimento é a utilização de Veículos Aéreos não Tripulados (VANT) para a captura de imagens.

Os VANTs, também conhecidos como *drones*, são aeronaves projetadas para operar sem piloto a bordo, que possua carga útil embarcada e não ter fim recreativo (FORÇA AÉREA BRASILEIRA, 2015), e podem ser de dois tipos: Aeronave Remotamente Pilotada (RPA do inglês *Remotely-Piloted Aircraft*), quando um piloto controla a aeronave remotamente através de uma interface; e Aeronave Automática ou Autônoma, quando não precisa de intervenção externa durante o voo (FORÇA AÉREA BRASILEIRA, 2015).

Para a realização da navegação de uma aeronave é fundamental determinar os ângulos de atitude e a posição geográfica da aeronave. Atualmente, a navegação é baseada por sensores inerciais Inertial Measurement Unit (IMU) integrados a receptores Global Navigation Satellite System (GNSS), para fornecer o posicionamento da aeronave. Existem vários sistemas GNSS, por exemplo, o GPS dos EUA, o GLONASS da Rússia, o GALILEO da União Europeia e o BEIDOU/COMPASS da China, contudo o Brasil não possui sistema GNSS próprio (MONICO, 2007).

Para a navegação automática e autônoma, uma das maneiras mais utilizadas de estimar o posicionamento é fazer uso de Sistema de Posicionamento Global (GPS do inglês *Global Positioning System*) com o Sistema de Navegação Inercial (INS do inglês *Inertial Navigation System*), entretanto esse sistema apresenta vulnerabilidades, como falhas e ataques da comunicação do sistema, risco de invasão no sinal ou interferência externa (WHITE et al., 1998; BRAGA et al., 2016), com isso há necessidade de se buscar formas de aprimorar e auxiliar o sistema de navegação da aeronave, buscando uma maior confiabilidade no sistema de posicionamento durante o voo.

Uma abordagem para a navegação autônoma é por meio de um sistema de visão computacional (CANHOTO et al., 2009) (SILVA, 2016) (BRAGA, 2019), ou um sistema híbrido com visão computacional, GPS e INS (CHUNHUI et al., 2014). No sistema de visão computacional, pode-se pensar em dois cenários diferentes: quando a aeronave tem um conhecimento prévio da área sobrevoada e faz a navegação através de uma

imagem georreferenciada (JIN et al., 2014) (SILVA, 2016) (GALINDO, 2016) ou baseada em marcos conhecidos (SILVA FILHO, 2016); e quando a aeronave não conhece o local sobrevoado e faz a navegação usando apenas as imagens durante o voo (REN et al., 2015) (LIU et al., 2016) (ROOS, 2018).

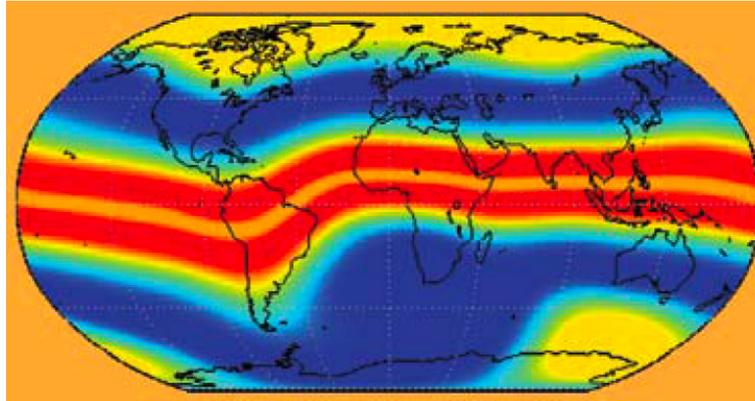
Existem várias técnicas para fazer a navegação autônoma, como o casamento de padrões (SILVA, 2016) (SILVA et al., 2016), SLAM (*Simultaneous Localization and Mapping*) (SUBRAMANYA, 2016), fluxo óptico (HOSEN et al., 2016) e odometria visual (ROOS, 2018) (BRAGA, 2019), dentre essas técnicas uma amplamente usada é a odometria visual (ROOS, 2018) (BRAGA et al., 2019). Onde um dos seus processos é encontrar correspondência entre pares de imagens, uma das maneiras disso ser feito é por meio de detecção de pontos de interesse e extração de características desses pontos entre as imagens, chamado descritores (FRAUNDORFER; SCARAMUZZA, 2012). Com as correspondências entre os pontos é possível fazer o casamento entre as imagens e com os dados de altitude do VANT, é possível realizar a odometria visual, ou seja, estimar a posição da aeronave, onde calcula-se o deslocamento entre os pares de imagem capturadas pelo VANT. Na literatura os principais métodos de pontos de interesse são o SIFT (LOWE, 2004), SURF (BAY et al., 2006), BRIEF (CALONDER et al., 2010), BRISK (LEUTENEGGER et al., 2011), ORB (RUBLEE et al., 2011), FREAK (ALAHY et al., 2012), AKAZE (ALCANTARILLA et al., 2013) e LATCH (LEVI; HASSNER, 2016). No entanto, na maioria das vezes encontra-se pontos casados erroneamente, para eliminar esses erros o método padrão (FRAUNDORFER; SCARAMUZZA, 2012) pode-se fazer uso do método RANSAC (*RANdom SAmple Consensus*) (FISCHLER; BOLLES, 1981).

## 1.1 Problemática

A principal maneira de estimar a posição de uma aeronave, é com uso do Sistema de Navegação Global por Satélite, que inclui o sistema mais utilizado, o GPS, com uso de informações de satélites estima-se o posicionamento geo-espacial. O GPS pode possuir alguns erros de posicionamento, falhas de comunicação e vulnerabilidade (WHITE et al., 1998; BRAGA et al., 2016). O GPS pode sofrer ataques de *jamming*, quando algo impede o sinal, para que o usuário não consiga obter informações de GPS e ataques de *spoofing*, quando algo envia sinais falsos, para que o usuário receba informações inválidas de posicionamento, com tentativas de ganhar o controle do veículo (JAVAID et al., 2017). Além disso existe a cintilação ionosférica, que são variações bruscas que ocorrem no sinal recebido pelos receptores GNSS devido à presença de irregularidades ionosféricas (REZENDE et al., 2007), como as bolhas de

plasma na ionosfera que são geradas com maior frequência na região equatorial que absorvem o sinal de GPS, como ilustrado na Figura 1.1, que tem efeitos na região tropical, com maior incidência sobre o Brasil (MATSUOKA, 2007).

Figura 1.1 - Sinal do GPS afetado.



As cores quentes representam a área mais afetada.

Fonte: Adaptada de Kintner et al. (2009).

Caso o sinal do GPS se torne indisponível ou corrompido, a estimativa da posição pode ser feita com uso de informações do INS, entretanto pode fornecer uma estimativa de posição com um erro acumulado que aumenta ao longo do tempo, o que torna-o inviável dentro de instantes.

Para amenizar esses erros, uma alternativa é empregar um sistema auxiliar de visão computacional, que se baseia por imagens para estimação de posição. Entretanto não há uma técnica única na literatura para fazer a estimação, ou seja, há necessidade de um conjunto de técnicas e métodos para a realização dessa tarefa. Além das imagens obtidas por VANT geralmente apresentam distorções geométricas e podem possuir diferentes cenários de voos com diferentes características, como floresta, vegetação rasteira, área urbana, área rural, rio, árvores, edifícios, ruas pavimentadas e não pavimentadas. A obtenção das imagens pode ser feita com diferentes sensores, como o visível, infravermelho, RADAR (*Radio Detection And Ranging*) e LIDAR (*Light Detection And Ranging*) e também possuir diferentes resoluções de imagens dependendo da câmera utilizada. Com isso há necessidade de se escolher automaticamente algoritmos ou parâmetros mais adequados para cada tipo de imagem dependendo de suas características apresentadas, a fim de resolver esse problema de posicionamento,

esta escolha de ser feita de forma automática e em tempo real.

## 1.2 Motivação

Com o crescimento do uso de VANTs, conseqüentemente aumentam as pesquisas para tentar fazer ataques de *jamming* e *spoofing* a esse tipo de aeronave (FARIA et al., 2016), como em dezembro de 2011, o Irã capturou um VANT de vigilância da Agência Central de Inteligência dos EUA (CIA) através de *spoofing*, onde em uma entrevista, o engenheiro iraniano afirmou que conseguiram falsificar o sinal de GPS do VANT com coordenadas falsas, enganando o sistema, indicando que estava indo para a casa e na verdade estava indo aterrissar no Irã (RAWNSLEY, 2011). Em 2012, uma equipe da Universidade do Texas mostrou a vulnerabilidade de *spoofing* no GPS, onde obteve o controle do VANT de teste durante um curto prazo durante o voo (SHEPARD et al., 2012). Em 2016, no Departamento de Ciência e Tecnologia Aeroespacial - Instituto Tecnológico de Aeronáutica, realizaram diversos testes de segurança e vulnerabilidade, onde até sistemas GPS mais complexos, como receptores aeronáuticos, foram bloqueados e perderam sinais, através de ataque eletromagnético, mostrando-se com uma alta vulnerabilidade (FARIA et al., 2016).

Um sistema de estimação de posição de um VANT com base em imagens obtidas por câmeras embarcadas, apresenta-se como solução para fornecer informações para navegação autônoma quando informações de GPS e/ou inercial são comprometidas.

O trabalho segue uma das linhas de estudo do projeto PITER (Processamento de Imagens em Tempo Real), e projetos de pesquisa desenvolvidos pelo Instituto de Estudos Avançados (IEAv), subordinado ao Departamento de Ciência e Tecnologia Aeroespacial (DCTA) e Instituto Nacional de Pesquisas Espaciais (INPE), que têm como o objetivo desenvolver métodos e técnicas de processamento de imagens e visão computacional para sistemas em tempo real.

## 1.3 Objetivos

O objetivo principal é propor um modelo autoconfigurado de posicionamento de um VANT, para auxiliar na navegação autônoma, baseando-se por imagens aéreas capturadas durante o voo. O intuito é propor algoritmos que de forma automática, escolham-se os parâmetros mais adequados ao cenário sobrevoado, a fim de identificar a posição da aeronave. Para alcançar esse objetivo, o problema pode ser dividido em:

- a) Extrair atributos das imagens obtidas em diferentes cenários de voos, com uso de componentes de textura, para extração de características que usadas como entrada para o sistema autoconfigurado;
- b) Comparar parâmetros e métodos de detecção e descrição de pontos de interesse invariantes a translação, escala e rotação, para a extração de características em imagens com diferentes cenários, configurados por meta-heurística, a fim de encontrar um conjunto de algoritmos e parâmetros sub-ótimos para cada cenário e para cada métodos de pontos de interesse;
- c) Realizar correspondência de pontos de interesse, com uso da distância de *Hamming* e KNN, para selecionar melhor os pontos que são correspondentes entre as imagens da aeronave;
- d) Eliminar falsas correspondências, com uso do RANSAC, para fazer uma filtragem dos pontos correspondentes, com o objetivo de garantir um número mínimo de pontos necessários para a realização da odometria visual;
- e) Criar um sistema autoconfigurado para escolher os melhores parâmetros de acordo com atributos extraídos da imagem, com uso de lógica Fuzzy. Essa técnica foi escolhida para tratar variações dos atributos e criação de regras de inferência através dos atributos e da meta-heurística, para alterar o parâmetro do método de pontos de interesse automaticamente;
- f) Estimar a posição por Odometria Visual, para realizar a navegação autônoma por imagens.

#### 1.4 Contribuições

A contribuição principal é propor um sistema autoconfigurado dos parâmetros dos métodos de pontos de interesse, para a estimação da posição de uma aeronave, através de imagens capturas por uma câmera acoplada em uma aeronave. Comparação dos métodos de pontos de interesse ORB, BRISK, FREAK, AKAZE e LACH configurados pelo algoritmo genético, pois de modo geral é feita com os parâmetros padrões (ALCANTARILLA; STENGER, 2016). O uso do algoritmo genético, neste trabalho, tem o objetivo de encontrar parâmetros dos métodos de pontos de interesse em imagens com diferentes coberturas de solo. Comparação de medidas estatísticas para analisar juntamente com os parâmetros definidos pelo algoritmo genético, a separabilidade de imagens de diferentes tipos de coberturas de solo. Uso de Fuzzy para selecionar automaticamente o parâmetro do método de pontos de interesse, de acordo com as medidas estatísticas e realizar a odometria visual.

## **1.5 Organização do trabalho**

Essa dissertação de mestrado está organizada da seguinte maneira: no Capítulo 1 são apresentados a introdução, problemática, motivação, objetivos, contribuições e a organização desta dissertação de mestrado; no Capítulos 2 é apresentada a revisão bibliográfica; no Capítulos 3 são apresentadas as fundamentações teóricas sobre textura, pontos de interesse, odometria visual, algoritmo genético e lógica fuzzy; no Capítulo 4 é apresentada a metodologia proposta para a navegação autônoma por imagens, através de um modelo autoconfigurado pelo Fuzzy, com uso de métodos de pontos de interesse configurados pelo Algoritmo Genético; o Capítulo 5 apresenta os experimentos e resultados obtidos com a metodologia comparada com um modelo estático; o Capítulo 6 são apresentadas as conclusões e sugestões de possíveis trabalhos futuros.

## 2 NAVEGAÇÃO AUTÔNOMA

Veículo Aéreo não Tripulado (VANT) teve seu estudo no início da primeira guerra mundial, quando a marinha americana investiu no desenvolvimento em um torpedo aéreo, para entregar bombas em um determinado alvo, assim surgiu o torpedo aéreo *Kettering Bug*, que não foi utilizado na primeira guerra, mas foi considerado o primeiro VANT na história, construído por Charles Kettering em 1918 (WYEN, 1969).

Em 1982, ocorreu o primeiro registro de desenvolvimento de um VANT no Brasil, onde teve um projeto de um veículo não tripulado a jato, desenvolvido pelo Centro Técnico Aeroespacial e a Companhia Brasileira de Tratores, infelizmente o projeto acabou sendo encerrado antes do seu primeiro voo. Em seguida surgiu uma necessidade da Marinha, Exército e Aeronáutica para uso dessa tecnologia, onde empresas investiram, principalmente em VANTs como alvos aéreos para treinamento de tiro real de suas unidades antiaéreas (PECHARROMAN; VEIGA, 2016).

Na última década, surgiu no mercado civil o uso de VANT no Brasil, através de empresas criadas por pesquisadores universitários, onde fizeram uso da união de sensores ópticos digitais, eletrônica de controle, sistemas de comunicação e aeromodelos, com aplicações na agropecuária e mineração (PECHARROMAN; VEIGA, 2016).

Atualmente, com o crescimento de novas tecnologias e apoio de investimento, tem surgido muitas aplicações com os VANTs, como em infraestrutura, transporte, seguros, Mídia e entretenimento, telecomunicações, agricultura, segurança, mineração e atividades humanitárias, onde fazem uso principalmente de câmera acoplada no VANT, para análise e extração de informação de imagens capturadas pela aeronave (PECHARROMAN; VEIGA, 2016), além do seu baixo custo para a realização de atividades, como a odometria visual para navegação autônoma de VANT (BRAGA et al., 2019).

Neste trabalho, faz-se uso de imagens aéreas capturadas pelo VANT, para a realização da navegação autônoma por imagens, onde é essencial entender o cenário de voo. Quando a aeronave tem um conhecimento prévio da área sobrevoada, a navegação pode ser feita baseada em marcos conhecidos (SILVA FILHO, 2016) ou através de uma imagem georreferenciada (BRAGA, 2019); e quando a aeronave não conhece o local sobrevoado e faz a navegação usando as imagens durante o voo (ROOS, 2018).

Quando a navegação é baseada em marcos, é necessário conhecer suas coordenadas

para o planejamento da trajetória de voo. Uma das maneiras de fazer esse tipo de navegação, é apresentado por [Silva Filho \(2016\)](#), onde a identificação de marcos é feita durante o voo. Uma das técnicas é com uso dos métodos de pontos de interesse SURF, ORB e AKAZE para extrair características das imagens aéreas e lógica *Fuzzy* para identificar os marcos nas imagens.

Para a utilização de uma imagem georreferenciada para fazer a navegação, uma das maneiras é apresentada por [Zheng et al. \(2014\)](#). Fazem a comparação do método SIFT com o ASIFT ([MOREL; YU, 2009](#)), invariante à transformada afim, ou seja, acrescentou a projeção da imagem, onde o ASIFT obteve melhor desempenho para casamento das imagens de VANT com imagens de satélite. [Silva \(2015\)](#) considera diferentes tipos de cenários, como floresta, rodovia e zona urbana, onde foi avaliado a utilização do operador de *canny* e redes neurais artificiais para extração de bordas, juntamente com cálculo do coeficiente de correlação para a estimação da posição. Além de considerar diferentes tipos de cenários é necessário considerar os diferentes períodos do dia, como é apresentado em [Silva \(2016\)](#), que faz uso de imagens no infravermelho termal durante o período noturno, onde é feito o registro automático entre imagem aérea e de satélite, para realizar isso, também é utilizada rede neural artificial e o cálculo de correlação.

Para a navegação autônoma baseada em imagens, a aquisição de imagens aéreas, pode ser feita de duas principais maneiras, com o sistema de visão monocular, que faz uso de uma câmera e estéreo, que faz uso de duas ou mais câmeras. O sistema de visão estéreo é geralmente usado para fazer SLAM, técnica que faz o mapeamento da área ao mesmo tempo que se localiza, como em [Subramanya \(2016\)](#). Com pares de imagens, é possível calcular, além do deslocamento, a profundidade dos pixels. Entretanto para a navegação autônoma, o uso do SLAM tem um alto custo computacional em relação ao fluxo óptico e pontos de interesse, pois para fazer o mapeamento é necessário detectar locais mapeados previamente, chamado de *loop closing*. Esse tipo de sistema pode ser usado apenas para estimar a posição, uma técnica usada é o uso de pontos de interesse, como em [Ren et al. \(2015\)](#), que fazem uso do SURF e RANSAC com uso de um sistema de visão estéreo, ou seja, para cada par de imagens, é feito o casamento com o próximo par de imagens.

Entretanto para fazer a navegação, pode-se utilizar o sistema monocular, onde faz-se a captura de duas imagens em tempos distintos e calcula-se o deslocamento entre essas imagens, para estimar a odometria visual do VANT ([SCARAMUZZA; FRAUNDORFER, 2011](#)).

Outra maneira de estimar o deslocamento da aeronave, segundo [Hosen et al. \(2016\)](#), é utilizar o fluxo óptico, entretanto técnicas de fluxo óptico clássicas selecionam áreas de interesse dividindo a imagem em uma grade, geralmente sem levar em conta padrões de intensidade de imagem ou qualidade da área de interesse, isso pode dificultar a determinação de correspondências entre as imagens ([VETH, 2011](#)).

Para melhorar a determinação de correspondências entre as imagens, pode-se fazer uso de odometria visual, que faz uso de algoritmos para extração de características em imagens subsequentes para encontrar pontos característicos correspondentes, que são usados para estimar o movimento da câmera, como em [Roos \(2018\)](#) que faz uso do algoritmo AKAZE para extração de características e propõe um método para ajuste automático dos valores de parâmetro do AKAZE durante o voo com uso de Máquinas de Vetores de Suporte (SVM), com o intuito de aumentar a robustez da odometria visual.

Com o objetivo de melhorar o desempenho da odometria visual, pode-se fazer uso de informações do VANT, como apresentado por [Galindo \(2016\)](#), que faz-se a comparação dos métodos SIFT, SURF e ASIFT, invariante à transformada afim, com os métodos ASIFT-V, ASURF-V e faz uso dos sensores inercias do VANT para a estimativa de posição para a navegação autônoma de VANTs.

Outra abordagem utilizada que visa melhorar o resultado é a fusão de técnicas, [Chunhui et al. \(2014\)](#) calculam a odometria visual, com a fusão dos resultados de casamento de pares de imagens de um VANT com os dados de altitude, com o casamento de uma imagem de VANT e uma de referência, onde fez uso do detector FAST e descritor FREAK.

A navegação autônoma pode ser feita com uso de outros sensores de imageamento, como em [Braga \(2019\)](#) que faz uso de imagens *Light Detection And Ranging* (LiDAR) para a fusão de dados, por um Filtro de Partículas Não-Extensível (FPNE) e uso de odometria visual e registro automático de imagens, para estimar a posição da aeronave em regiões cobertas por água e regiões com baixa ou sem luminosidade.



### 3 FUNDAMENTAÇÃO TEÓRICA

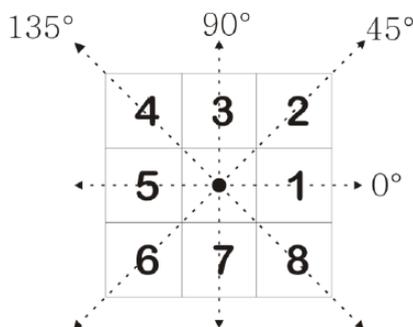
#### 3.1 Textura

Para quantificar a descrição de uma região, uma abordagem utilizada é a textura, pois através dela, obtêm-se medidas de propriedades como suavidade, rugosidade e regularidade, entre outras (GONZALEZ; WOODS, 2009).

Para extração de características de texturas, Haralick et al. (1973) propuseram um método baseado na relação espacial existentes entre os níveis de cinza da imagem, com uso de matrizes de co-ocorrência, onde determinaram 14 características estatísticas, incluindo variância, segundo momento angular, energia, contraste, correlação, homogeneidade, momento inverso da diferença, soma da média, soma da variância, soma da entropia, diferença da variância, diferença da entropia, medida de informação da correlação e coeficiente de correlação máxima. Dentre eles, segundo Baraldi e Parmiggiani (1995) e Hall-Beyer (2017), existem seis com maior relevância: energia; entropia; contraste; variância; correlação; e homogeneidade.

As Matrizes de co-ocorrência de níveis de cinza (GLCM do inglês *Gray Level Co-occurrence Matrices*) é formada pelas ocorrências de transições de níveis de cinza de uma imagem em diferentes direções. De forma geral, a matriz de co-ocorrência  $G$  de tamanho  $k$  é especificada por dois elementos de textura vizinhos, separados por uma distância  $d$  e com uma orientação  $\Theta$ , onde cada elemento na linha  $i$  e coluna  $j$  com valor  $v$  na matriz, indica que houve  $v$  variações do nível de cinza  $i$  para o nível de cinza  $j$  em uma imagem. Esse cálculo é computado usual em 4 orientações,  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ , como mostrado na Figura 3.1

Figura 3.1 - Orientações para obtenção da GLCM.



4 direções no pixel.

Fonte: Haralick et al. (1973).

Com isso, obtêm-se 4 matrizes GLCM, uma para cada orientação, onde cada valor da matriz  $v_{ij}$  é normalizado (Equação 3.1). A partir dessas matrizes, podem-se extrair informações estatísticas que descrevem componentes de textura. As matrizes são sensíveis à rotação da imagem, para minimizar esse efeito, pode-se calcular a média das quatro orientações. Um exemplo de cálculo da matriz GLCM em uma imagem binária, com  $d = 1$  e  $\Theta = 0^\circ$ , pode ser visualizado na Figura 3.2.

$$p_{ij} = \frac{v_{ij}}{\sum_{i=1}^k \sum_{j=1}^k v_{ij}} \quad (3.1)$$

Onde  $p_{ij}$  é a probabilidade do número de vezes que o resultado  $v$  ocorre na linha  $i$  e coluna  $j$ , dividido pelo número total de possíveis resultados.

Figura 3.2 - Exemplo de Matriz GLCM.

0	0	1	1
0	1	0	0
1	1	0	1

(a) Valores de uma imagem.

	0	1
0	2	3
1	2	2

(b) Matriz.

Exemplo de amarelo que ocorrem 2 ocorrências de transições de pixel de valor 0 para 0 (b) na imagem (a).

Fonte: Produção do autor.

Os seis componentes de texturas [Hall-Beyer \(2017\)](#), são descritos como:

- Energia

Também conhecida como Segundo Momento Angular (SMA) ou Uniformidade, a energia mede a uniformidade da textura na imagem, calculada por:

$$ene = \sum_{i=1}^k \sum_{j=1}^k p_{ij}^2 \quad (3.2)$$

- Entropia

A entropia mede a desordem da textura na imagem, calculada por:

$$ent = - \sum_{i=1}^k \sum_{j=1}^k p_{ij} \log p_{ij} \quad (3.3)$$

- Contraste

O contraste mede o espalhamento da textura na imagem, é a diferença de intensidade entre um pixel e seu vizinho na imagem, calculada por:

$$con = \sum_{i=1}^k \sum_{j=1}^k (i - j)^2 p_{ij} \quad (3.4)$$

- Variância

A variância mede a heterogeneidade da textura na imagem, calculada pela Equação 3.9, onde a Equação 3.5 e 3.6 determinam a média da matriz GLCM.

$$\mu_i = \sum_{i=1}^k \sum_{j=1}^k i p_{ij} \quad (3.5)$$

$$\mu_j = \sum_{i=1}^k \sum_{j=1}^k j p_{ij} \quad (3.6)$$

$$\sigma_i^2 = \sum_{i=1}^k \sum_{j=1}^k (i - \mu_i)^2 p_{ij} \quad (3.7)$$

$$\sigma_j^2 = \sum_{i=1}^k \sum_{j=1}^k (j - \mu_j)^2 p_{ij} \quad (3.8)$$

$$\sigma^2 = \frac{\sigma_i^2 + \sigma_j^2}{2} \quad (3.9)$$

- Correlação

A correlação é a dependência linear entre os tons de cinza na imagem, mede o quão relacionado está um pixel com seu vizinho na imagem, calculada por:

$$corr = \sum_{i=1}^k \sum_{j=1}^k \frac{(i - \mu_i)(j - \mu_j)p_{ij}}{\sigma_i \sigma_j} \quad (3.10)$$

- Homogeneidade

A homogeneidade é a correlação inversa com o contraste, calculada pela Equação 3.11.

$$hom = \sum_{i=1}^k \sum_{j=1}^k \frac{p_{ij}}{1 + (i - j)^2} \quad (3.11)$$

### 3.2 Pontos de interesse

A representação de características em imagens tem grande importância nas áreas de visão computacional e processamento de imagem. Existem diferentes métodos de detecção de características representativas em imagens, segundo (LI et al., 2015) pode-se dividir esses métodos em categorias de detecção de bordas, detecção de cantos, pontos de interesse e região de interesse, ilustrados na Figura 3.3. Os métodos de ponto de interesse extraem características locais em imagens e são divididos em 2 partes: o detector, que identifica pontos representativos; e o descritor que descrevem as características desses pontos. Existem diversos métodos de interesse, como o SIFT, SURF, ORB, BRISK, FREAK, KAZE, AKAZE e LATCH, seus usos variam muito de acordo com as propriedades e métodos utilizados, contudo, são amplamente estudados para a reconstrução 3D e reconhecimento de objetos.

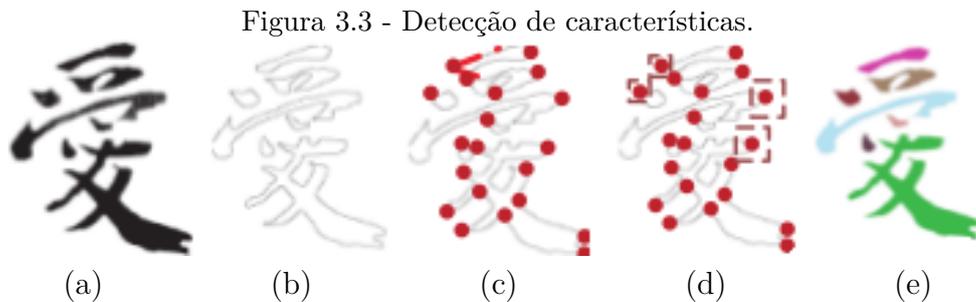


Imagem de exemplo (a) e métodos de detecção de características: Borda (b), Canto (c), pontos de interesse(d) e Região de Interesse(e).

Fonte: Adaptada de Li et al. (2015).

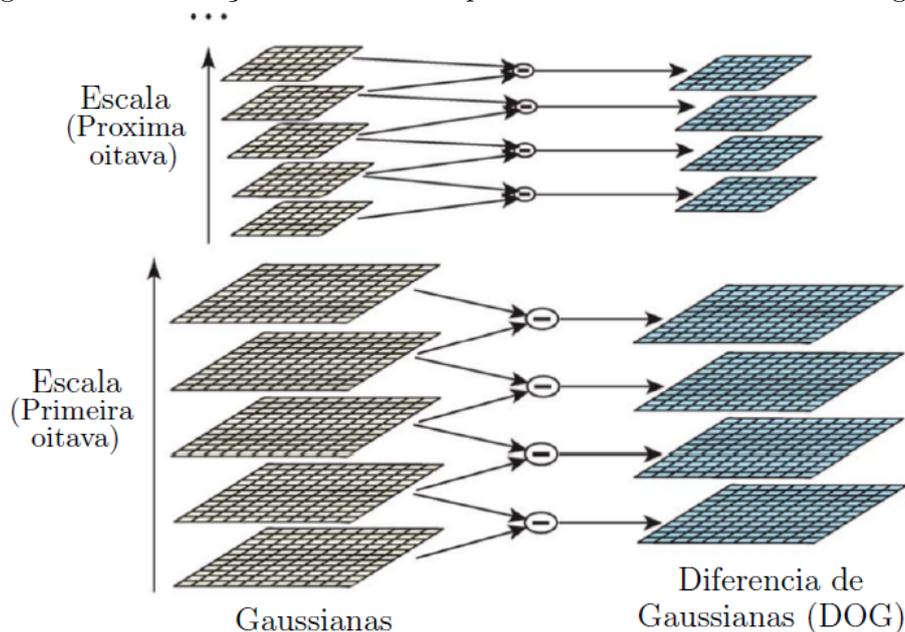
#### 3.2.1 SIFT

O método *Scale Invariant Feature Transform* (SIFT) (LOWE, 2004), extrai pontos de interesse invariantes à escala, translação e rotação, e parcialmente invariantes a

mudança de iluminação, afinidade ou projeção. O detector é baseado em cálculos de diferenças de Gaussianas para detectar pontos extremos no espaço de escalas como ponto e o descritor, faz uso histogramas de gradientes orientados para descrever a vizinhança local dos pontos de interesse.

Para a detecção dos pontos de interesse, a imagem sofre convoluções incrementais com filtros Gaussianos, que faz a suavização da imagem, e nas escalas adjacentes são subtraídas para produzir imagens da Diferença de Gaussianas (DoG), como apresentada na Figura 3.4, esse processo é feito em uma oitava, e para cada oitava é repetido esse processo reduzindo as imagens gaussianas pela metade até chegar em uma imagem oito por oito pixels. Em seguida, são detectados os pontos extremos no espaço de escala para cada oitava, onde compara-se a intensidade de cada ponto com as intensidades de seus oito vizinhos na sua escala, com os nove vizinhos da escala superior e inferior, representados na Figura 3.5. Todos os pontos extremos são candidatos a pontos de interesse, são rejeitados os pontos extremos com baixo contraste e os pontos os quais são mal localizados ao longo de uma borda. Todos os pontos restantes ao final desta etapa são definidos como pontos de interesse.

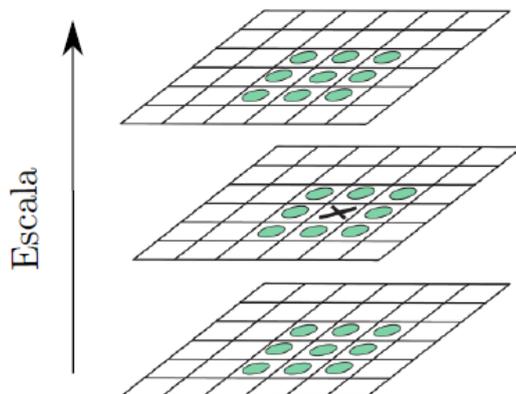
Figura 3.4 - Diferenças de Gaussianas para diversas oitavas de uma imagem.



Lado esquerdo representa os filtros gaussianos, e o lado direito a diferença de gaussianas.

Fonte: Lowe (2004).

Figura 3.5 - Detecção de extremos no espaço-escala.



O  $X$  representa o ponto extremo no espaço de escala.

Fonte: Lowe (2004).

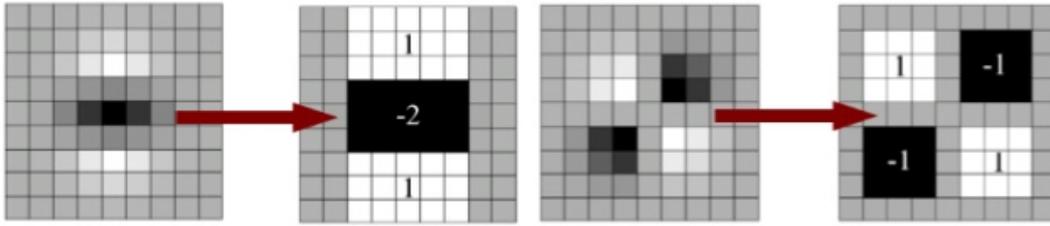
Para descrição dos pontos de interesse, para cada amostragem da imagem na escala, calcula-se a magnitude e orientação do gradiente usando as diferenças de pixels. Em seguida é construído um histograma de orientações da vizinhança do ponto, cobrindo as orientações entre  $0^\circ$  à  $360^\circ$ .

### 3.2.2 SURF

O *Speeded Up Robust Features* (SURF) (BAY et al., 2006) é baseado no SIFT, com algumas mudanças, faz uso de modelo aproximativo do espaço de escala, baseado em imagens integrais, chamado de matriz Hessiana, o que proporciona uma melhoria de eficiência em relação ao SIFT.

Para a realização da aproximação da matriz Hessiana para cada escala diferente, o algoritmo utiliza filtros de caixa correspondentes a núcleos gaussianos de tamanho nove por nove, como ilustrados na Figura 3.6.

Figura 3.6 - Aproximações de núcleo Gaussiano do SURF.



Da esquerda para a direita: Derivadas parciais de segunda ordem na direção  $x$  e  $xy$  e suas aproximações, utilizando núcleos gaussianos. As regiões em cinza correspondem ao valor zero.

Fonte: Bay et al. (2006).

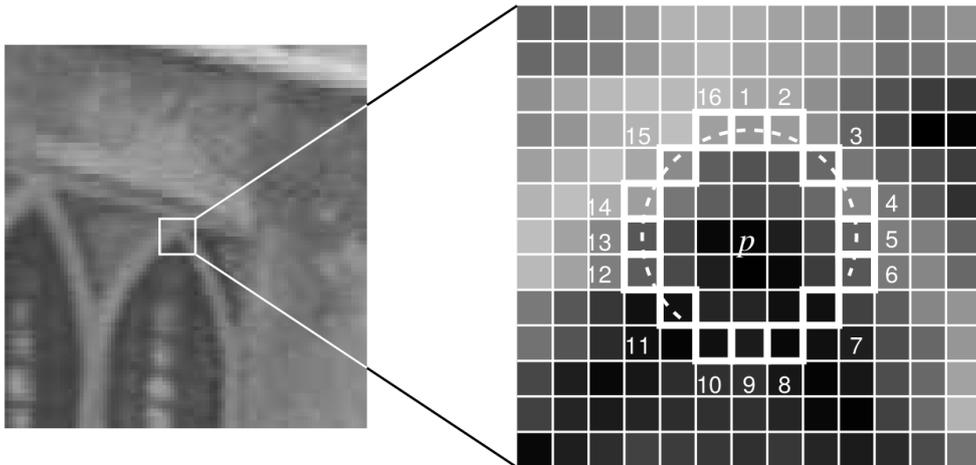
Em seguida, para detecção dos pontos de interesse, cada ponto é comparado com os seus vizinhos de forma semelhante ao SIFT, como mostrado na Figura 3.5. Para descrição dos pontos, faz uso de *Haar-wavelet*, que é uma divisão de uma zona retangular de uma imagem em sub-retângulos, onde cada sub-retângulo é branco ou preto (BAY et al., 2006). O SURF utiliza a soma das repostas *Haar-wavelets* em diferentes orientações, na vizinhança do ponto de interesse, o que possibilita a determinação do valor do gradiente nas direções  $x$  e  $y$ .

### 3.2.3 ORB

O *Oriented FAST and Rotated BRIEF* (ORB) (RUBLEE et al., 2011) é baseado no detector *Features from Accelerated Segment Test* (FAST) (ROSTEN; DRUMMOND, 2006) e no descritor *Binary Robust Independent Elementary Features* (BRIEF) (CALONDER et al., 2010).

O detector FAST (ROSTEN; DRUMMOND, 2006) faz uso de cantos para a detecção de pontos de interesse, onde compara-se a intensidade de 16 pixels contidos em um círculo ao redor de um pixel central para identificar o ponto de interesse, como mostrado na Figura 3.7, onde o pixel central será um canto, se houver 12 pixels contíguos no círculo mais escuro ou mais claro que o pixel central juntamente com um limiar, esse método tem um desempenho superior aos métodos que se baseiam em DoG.

Figura 3.7 - Detector de cantos FAST.



Exemplo de detecção de um ponto de interesse  $p$ .

Fonte: Rosten e Drummond (2006).

O descritor BRIEF (CALONDER et al., 2010) para descrever cada ponto, faz testes aleatoriamente de comparação da intensidade entre os pixels a partir de uma imagem suavizada, com meio do filtro gaussiano, onde é construído uma cadeia binária através do conjunto de comparações entre pares de pontos. O BRIEF é um descritor binário que apresenta ser menor em memória e mais rápido que os descritores SIFT ou SURF, que utilizam pontos flutuantes, entretanto possui a desvantagem de não ser invariante à escala e rotação.

O ORB é um aprimoramento do FAST e BRIEF, pois no FAST faz a inclusão de orientação, com uso do cálculo do centroide da região de canto encontrado, além do detector ser parcialmente invariante à escala, pois faz uso de pirâmide de imagens para extração de pontos de interesse, como no espaço de escala do SIFT. No BRIEF faz a inclusão de ser invariante à rotação, pois faz uso de vetores de orientação adquiridos na etapa de detecção.

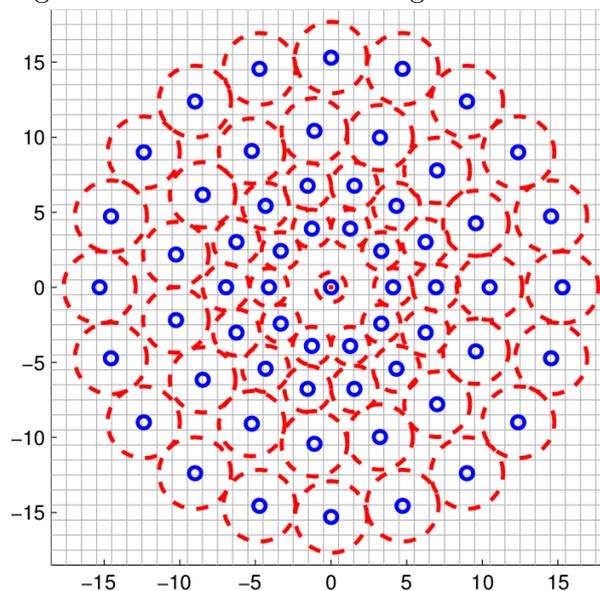
### 3.2.4 BRISK

O *Binary Robust Invariant Scalable Keypoints* (BRISK) (LEUTENEGGER et al., 2011), faz uso do detector *Adaptive and Generic Accelerated Segment Test* (AGAST) e de um descritor semelhante ao BRIEF, entretanto considera a rotação de um ponto a ser descrito.

Para fazer a detecção dos pontos, é feito na imagem o uso do espaço escala para cada oitava semelhante ao SIFT, para adaptar o padrão de amostragem ao máximo no espaço de escala, onde o AGAST faz a detecção de cantos através do FAST, contudo acrescenta um limiar máximo em que um ponto é considerado um canto, onde o ponto deve atingir o valor máximo em relação aos pontos vizinhos da oitava atual e das oitavas superior e inferior. Esses pontos máximos são definidos como pontos de interesse.

Para descrição dos pontos, semelhante ao BRIEF, é uma cadeia binária de um conjunto de comparações de intensidades entre pares de pontos, entretanto seu padrão de amostragem da vizinhança do ponto de interesse não é aleatório, faz uso de um padrão simétrico que possui pontos de amostragem posicionados em círculos concêntricos de tamanhos diferentes, conforme distribuição Gaussiana em torno do ponto de interesse, como ilustrada na Figura 3.8, além de estimar a orientação do ponto e a rotação padrão de amostragem por meio da soma de todos os gradientes locais entre os pares, com isso, torna-o variante à rotação e escala.

Figura 3.8 - Padrão de amostragem do BRISK.



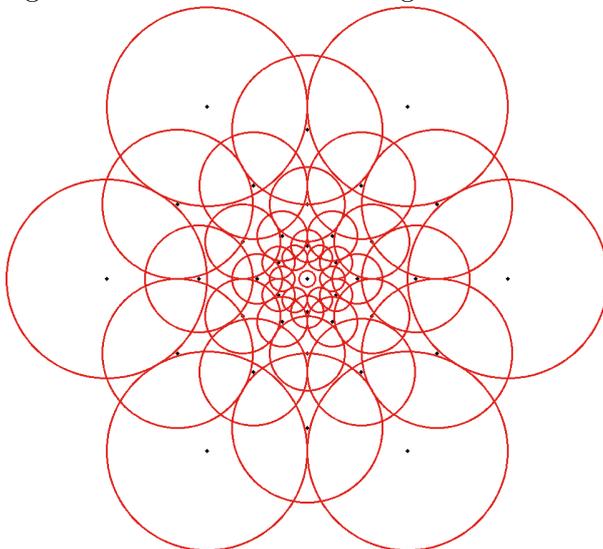
Cada círculo tracejado representa o tamanho do desvio padrão do filtro Gaussiano aplicado a cada ponto de amostragem representado pelos círculos menores.

Fonte: [Leutenegger et al. \(2011\)](#).

### 3.2.5 FREAK

O *Fast Retina Keypoint* (FREAK) (ALAHY et al., 2012) é um descritor baseado na retina do sistema de visão humano, similar ao BRISK, porém sua amostragem não é simétrica, na medida em que se aproxima ao centro do padrão, a densidade de amostragem aumenta, gerando círculos sobrepostos de tamanhos variados, como apresenta na Figura 3.9, esse padrão foi inspirado na retina do olho humano, onde a distribuição das células, responsáveis pela transmissão da informação da luz ao sistema nervoso, aumenta na medida em que se aproxima do centro da retina.

Figura 3.9 - Padrão de amostragem do FREAK.



Cada círculo representa uma suavização da distribuição gaussiana com desvio padrão proporcional ao seu tamanho, onde o centro de cada círculo corresponde a um ponto de amostragem.

Fonte: Adaptada de Alahi et al. (2012).

### 3.2.6 KAZE

O método KAZE (ALCANTARILLA et al., 2012) demonstra melhor eficiência em relação aos SIFT e SURF que fazem uso de espaço de escala gaussiana. O KAZE faz a detecção de descrição de pontos de interesse em um espaço de escala não linear por meio de filtragem de difusão não-linear.

O espaço de escala não linear é construído usando técnicas eficientes de AOS (*Ad-*

*ditive Operator Splitting*) (WEICKERT et al., 1998) e a magnitude do gradiente de imagem para controlar a difusão em cada nível de escala.

O filtro gaussiano usado no SIFT é um método simples para fazer remoção de ruídos, suavizando a imagem e com isso também remove as características de objetos da imagem, como cantos e arestas. O KAZE faz uso de um filtro adaptativo local para reconhecer as características, mantendo os cantos e arestas, que são importantes para detecção de pontos de interesse (ALCANTARILLA et al., 2012), como apresentado na Figura 3.10 a comparação entre esses filtros.

Figura 3.10 - Comparação entre o espaço de escala gaussiana e Difusão Não-Linear.



Na primeira linha apresenta-se as imagens com o espaço de escala gaussiana e a segunda linha apresenta o espaço de escala de Difusão Não-Linear.

Fonte: Alcantarilla et al. (2012).

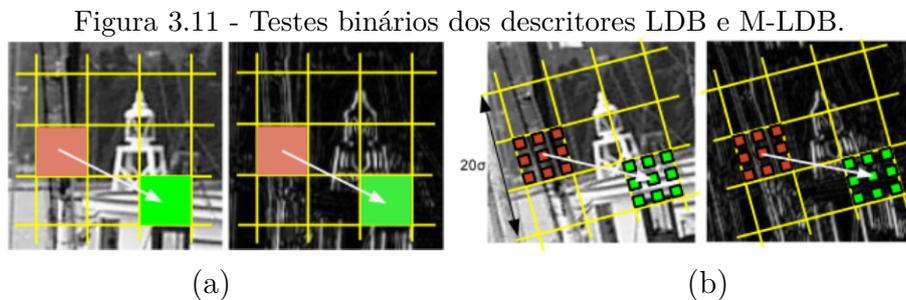
O custo computacional para a criação do espaço de escala não linear é superior ao do SURF para a criação de um modelo aproximado do espaço de escala e inferior ao do SIFT, contudo o KAZE apresenta um desempenho melhor tanto na detecção e descrição dos pontos de interesse (ALCANTARILLA et al., 2012).

### 3.2.7 AKAZE

O *Accelerated-KAZE* (AKAZE) (ALCANTARILLA et al., 2013) é uma versão acelerada do KAZE (ALCANTARILLA et al., 2012), é baseado em gradiente a partir do espaço de escala não linear, onde utiliza uma descrição binária baseada em uma versão modificada do método LDB (Binary Local Difference) (YANG; CHENG, 2012).

O AKAZE faz uso de uma filtragem de difusão não linear, para construção do espaço de escala não linear (ALCANTARILLA et al., 2013), diferente dos descritores

ORB, BRISK e FREAK que utilizam difusão linear, através de um espaço de escala Gaussiano. O detector faz uso de um mecanismo de difusão explícita rápida, que é mais rápido e mais eficiente que o método AOS usado pelo KAZE (ALCANTARILLA et al., 2013). O descritor LDB é semelhante ao BRISK e FREAK, entretanto, não faz a comparação de valores de pixels, faz uso de uma grade de pixels em torno do ponto chave e os testes binários são realizados entre regiões da grade pelo valor médio dos pixels da região. O AKAZE faz uso de um descritor binário de diferenças locais, versão modificada do método LDB, o M-LDB (*Modified-Local Difference Binary*) adiciona invariância a rotação e escala e também faz uso de informação de gradiente do espaço de escala. Os testes binários desses descritores são mostrados na Figura 3.11.



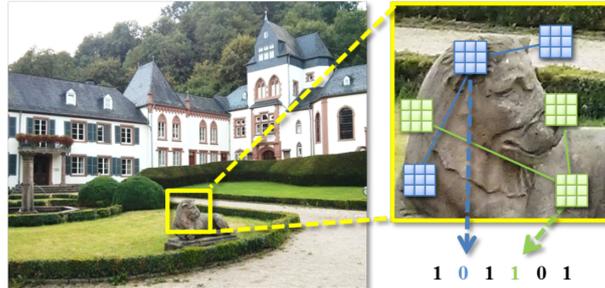
Teste binário do descritor LDB (a) e do descritor M-LDB (b).

Fonte: Alcantarilla et al. (2013).

### 3.2.8 LATCH

O *Learned Arrangements of Three Patch Codes* (LATCH) (LEVI; HASSNER, 2016) faz uso de comparação de sub-regiões (*patches*), ao invés de pixels e faz uso de triplas de pontos de amostragem em vez de pares de pontos de amostragem. Para cada ponto de interesse o LATCH gera um *patch* em torno do ponto, uma janela de tamanho fixo e predeterminado. Para cada Janela, extrai um conjunto de *patches*, onde o descritor elege 3 *patches*, o primeiro chamado de âncora, onde calcula-se a distancia de Frobenius (SCHIMKE et al., 2004) entre a âncora e os outros 2 *patches*. Em seguida, faz a comparação das distancias e seleciona as melhores triplas de patches, para formar cada bit da cadeia binária, como mostrada no exemplo na Figura 3.12.

Figura 3.12 - Visualização do descritor LATCH.



Exemplo de janela, onde as triplas são desenhadas sobre o patch em verde e azul, para gerar os bits da cadeia binária do descritor.

Fonte: Levi e Hassner (2016).

O LATCH é baseado no Local Binary Patterns (LBP), que produz para cada pixel na imagem uma representação de string binária, comparando as intensidades de pares de pixels. Contudo o LATCH faz uso de similaridade de 3 *patches* de pixel, contendo 8 pixels em volta do pixel central, chamado sua variante de *Three-Patch LBP* (TPLBP) e além disso aprende quais *patch* são ideais a partir dos dados de treinamento, em vez de serem feitos a mão, como no TPLBP (LEVI; HASSNER, 2016).

### 3.3 Odometria Visual

Odometria visual é o processo de estimar o movimento de um veículo, robô ou aeronave, com uso de imagens obtidas de um ou múltiplos sensores imageadores fixados a eles (SCARAMUZZA; FRAUNDORFER, 2011). Ela estima a posição e orientação do sensor com base nas cenas capturadas consecutivamente, como o sensor está fixado na aeronave, estima também a movimentação do mesmo.

Quando a odometria visual faz uso de um sensor imageador, chama-se odometria visual monocular. Quando faz uso-se de dois ou mais, tem-se odometria visual estéreo. Entretanto, se a distância entre as cenas for muito maior que a distância dos sensores, a visão estéreo converge para a visão monocular. Por isso, para estimar a posição de uma aeronave, faz-se uso de odometria visual monocular, pois a distância das cenas capturas pela aeronave é maior que a dos sensores (SCARAMUZZA; FRAUNDORFER, 2011).

Segundo Scaramuzza e Fraundorfer (2011), o processo de odometria visual é dividido em 5 partes, como ilustrado na Figura 3.13.

Figura 3.13 - Processos para odometria visual.



Fluxograma para a odometria visual.

Fonte: Adaptado de Scaramuzza e Fraundorfer (2011).

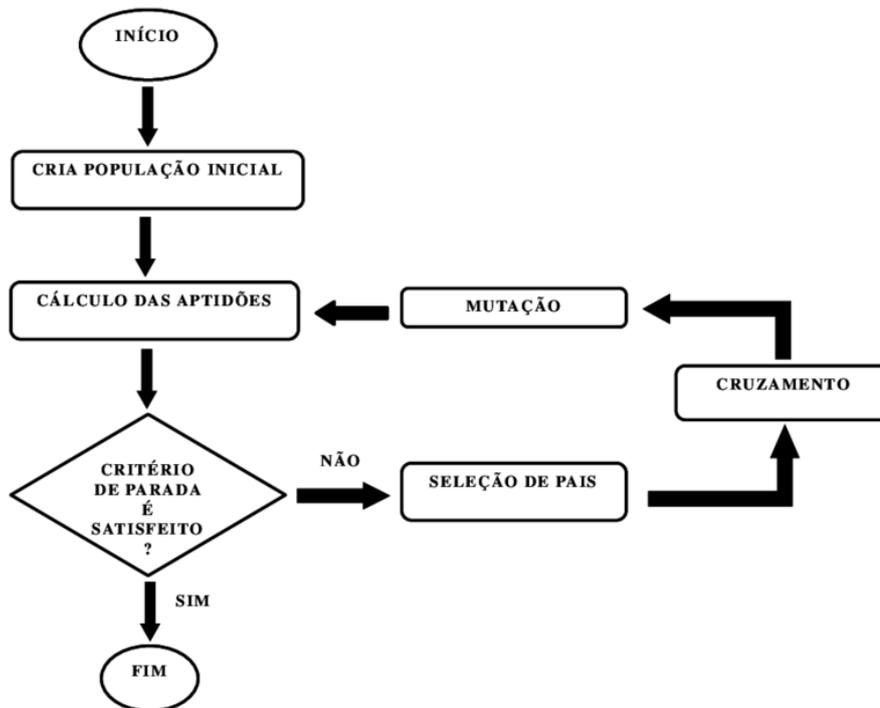
A realização da odometria visual pode ser feita com as características das imagens consecutivas capturadas pela câmera de uma aeronave, onde pode-se fazer a correspondências entre as características em áreas sobrepostas. Contudo, na odometria visual monocular, esse processo pode gerar um erro de deriva, obtido através de erros de estimação de posição que aumenta com a distância da aeronave do seu ponto inicial de partida (SCARAMUZZA; FRAUNDORFER, 2011).

Para amenizar o erro de deriva, pode-se fazer uso de combinações de outros sensores, como o GPS e IMU (SCARAMUZZA; FRAUNDORFER, 2011) ou fazer uso de combinações de outras técnicas para a navegação por imagens, como o reconhecimento de marcos (SILVA FILHO, 2016) e registro de imagens (BRAGA, 2019).

### 3.4 Algoritmo Genético (AG)

Algoritmo Genético (AG) é um método de otimização e busca inspirado no mecanismo de evolução de populações de seres vivos (HOLLAND, 1975). A otimização é a busca da melhor solução para um problema, onde consiste em tentar várias soluções e utilizar a informação obtida neste processo de forma a encontrar soluções cada vez melhores. As etapas do AG são ilustradas na Figura 3.14.

Figura 3.14 - Esquema do AG.



Etapas do AG.

Fonte: Lopes et al. (2013).

A primeira etapa do AG é a criação da população inicial, formada com um conjunto de cromossomos, que são possíveis soluções para um problema. Os cromossomos são compostos por genes, responsáveis pelas características dos seres modificados e melhorados no processo de cruzamento e mutação.

Para cada interação do AG, são calculados as aptidões para cada cromossomo, onde os mais aptos são selecionados para o processo de reprodução e os menos aptos podem ser removidos. A seleção dos cromossomos tem a importância de selecionar quem irá para o processo de cruzamento e mutação, para ser modificado e melhorado, afim de satisfazer o critério de parada. Existem diversos métodos de seleção, os principais são:

- Torneio;
- Seleção Truncada;
- Roleta;

- Seleção por ranking.

O processo de cruzamento é para modificar os cromossomos, cruzando características de dois cromossomos, denominado de pai, para gerar cromossomos melhores. O cruzamento se baseia na vida dos seres vivos, onde o cruzamento de pais mais aptos, irão gerar filhos mais aptos. O próximo passo após a geração dos filhos, pode se fazer uso da mutação.

O processo de mutação também é para modificar os cromossomos, entretanto é uma modificação mais sutil, onde o cromossomo filho sofre alguma alteração, geralmente em uma característica, afim de diversificar a população e chegar a uma solução mais adequada.

Após as operações de seleção, cruzamento e mutação, são calculadas novamente as aptidões da população modificada, o processo se repete até o critério de parada seja satisfeito, para obter as melhores soluções para o problema proposto.

### **3.5 Lógica Fuzzy**

A lógica fuzzy é um método introduzido por Zadeh (1965), que diferente da lógica booleana que aceita apenas valores booleanos, como verdadeiro ou falso e 0 ou 1, a lógica Fuzzy ou lógica difusa, aceita valores que variam entre 0 e 1, ou seja, permite soluções aproximadas. O raciocínio Fuzzy é formado por 3 etapas, a fuzzificação, a inferência e a defuzzificação Zadeh (1965).

#### **3.5.1 Fuzzificação**

Transforma os valores numéricos em termos da linguagem natural. Para isto, são primeiramente determinadas as funções de pertinência para cada entrada do sistema a ser controlado.

As Funções de pertinência, também chamadas de conjuntos Fuzzy, são funções matemáticas que fornecem um significado numérico, conhecido como grau de pertinência, para um conjunto de valores, que recebe um rótulo. As funções mais utilizadas são:

- triangular;
- Trapezoidal;
- Gaussiana;

- Sino;
- Sigmoidal.

### 3.5.2 Inferência

Conhecidas como regras de avaliação, onde aplicam as regras na entrada Fuzzy, geradas pelo processo de fuzzificação. As regras fuzzy são declarações de SE e ENTÃO, ou seja, são ações a serem feitas em resposta a varias entradas Fuzzy, onde as regras descrevem o comportamento do sistema desejado. Por exemplo, em um sistema de ar condicionado:

- SE a temperatura está muito quente, ENTÃO ligue o ar condicionado no alto;
- SE a temperatura está quente, ENTÃO ligue o ar condicionado no médio;
- SE a temperatura está frio, ENTÃO ligue o ar condicionado no baixo.

Existem diversos métodos de inferência na literatura, como o Mamdani, Takagi-Sugeno e Tsukamoto (TUNG; QUEK, 2009), porém o mais usado é o método Mamdani (MARRO et al., 2010).

### 3.5.3 Defuzzificação

Transforma o dado nebuloso, ou seja, o conjunto de saída Fuzzy gerado pela inferência, em dado quantitativo. Existem diferentes maneiras para realizar a defuzzificação, as mais conhecidas são:

- Defuzzificador de Máximo;
- Média dos Máximos;
- Centróide ou centro de gravidade.



## 4 METODOLOGIA PROPOSTA PARA A NAVEGAÇÃO AUTÔNOMA POR IMAGENS

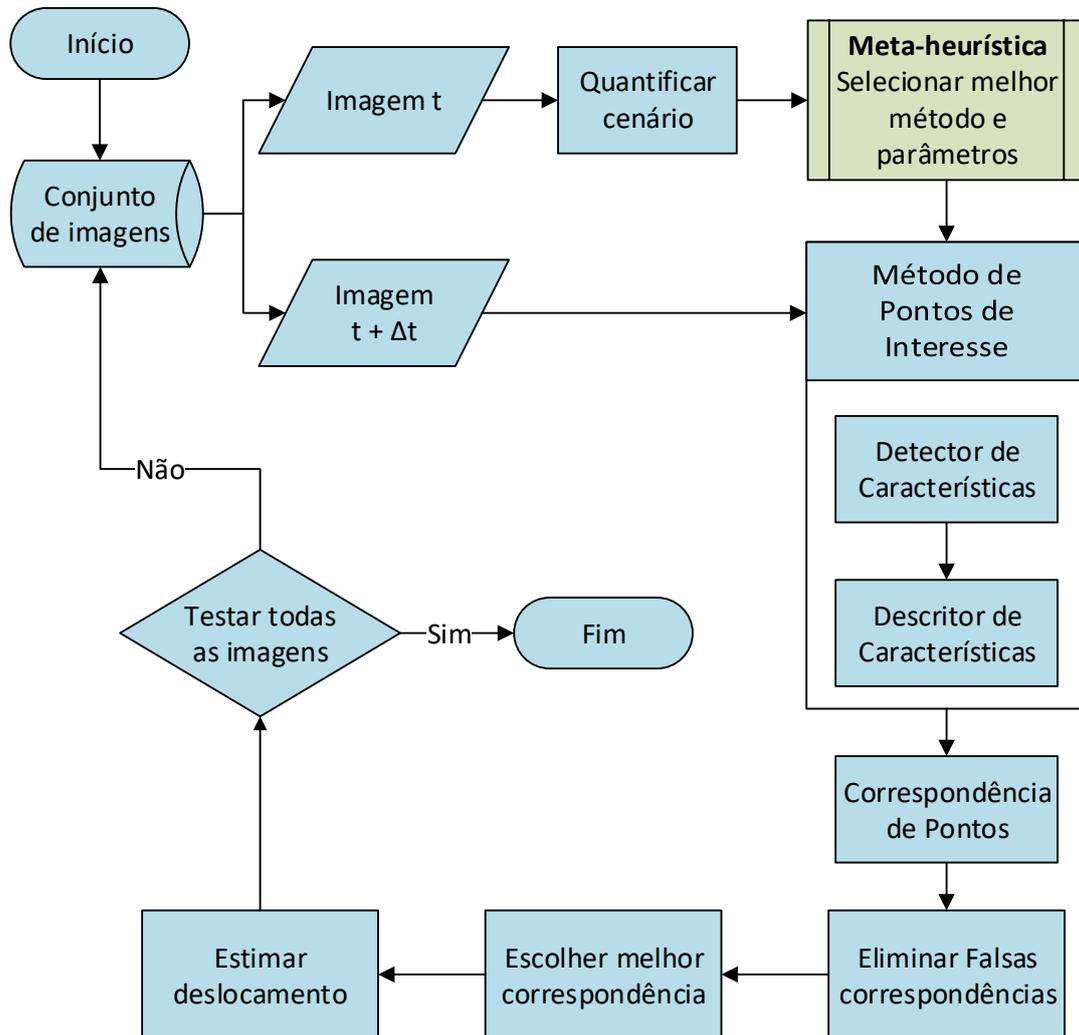
O sistema autoconfigurado para estimação de posição do VANT baseado em imagens, é descrito no fluxograma da Figura 4.1. Para a realização do sistema autoconfigurado, é necessário um passo anterior, onde é feita a comparação de métodos de pontos de interesse BRISK, ORB, FREAK, AKAZE e LATCH. Os parâmetros destes métodos são configurados com uso de um método de otimização, neste trabalho, a meta-heurística: Algoritmo Genético. Após a comparação, aplica-se a melhor técnica em diversas imagens quantificadas, com uso de medidas de textura para criação de regras Fuzzy, que são aplicadas para criação do sistema autoconfigurado.

O primeiro passo é fazer a aquisição de pares de imagens capturadas pelo VANT durante o voo nos tempos  $t$  e  $t + \Delta t$ . Em seguida, é necessário extrair informações das imagens da cobertura do solo sobrevoado. Neste trabalho são extraídas informações de textura, onde é quantificada a imagem no tempo  $t$  com uso de texturas.

Em seguida deve-se estimar quais parâmetros são mais adequados para a imagem. Aplica-se então uma meta-heurística que seleciona automaticamente o parâmetro de acordo com o cenário quantificado, de uma área que a aeronave tem com conhecimento prévio das imagens para configurar os parâmetros da meta-heurística, neste trabalho foi utilizado um sistema fuzzy.

O passo seguinte é aplicado o método de pontos de interesse com o parâmetro escolhido pelo Fuzzy, para detecção e extração de características nas imagens. Em seguida é necessário fazer a correspondência desses pontos, onde faz uso do algoritmo Força Bruta com KNN (*K-Nearest Neighbor*), entretanto, alguns casamentos podem ser identificados erroneamente, para eliminar as falsas correspondências, é aplicado método RANSAC (*RANdom SAmple Consensus*) e para finalizar, é realizada a Odometria Visual com a melhor correspondência, para estimar o deslocamento do ponto e com isso, fazer a estimação da posição do VANT de acordo com as correspondências encontradas.

Figura 4.1 - Fluxograma do sistema de posicionamento do VANT.



Descrição dos processos do sistema de visão computacional.

Fonte: Produção do autor.

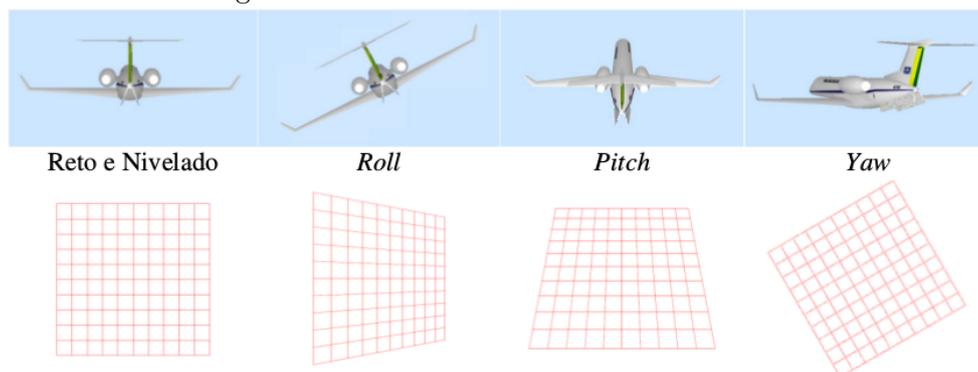
#### 4.1 Aquisição de Imagens

Neste trabalho é necessário possuir o conhecimento do local sobrevoado, para configurar os parâmetros da metodologia. Contudo, após a etapa de configuração, não é necessário conhecer o local sobrevoado, ou seja, faz uso apenas de imagens capturadas durante o voo. Além do conhecimento prévio do local sobrevoado, uma informação essencial para a navegação é a latitude e longitude inicial da aeronave, pois a partir dela são calculados os deslocamentos seguintes. A aquisição de imagens

é realizada com uso de um sistema monocular, ou seja, apenas uma câmera, onde é feita a captura de pares de imagens nos tempos  $t$  e  $t + \Delta t$  do local sobrevoado, onde tendo a informação de posição da imagem no tempo  $t$ , estima-se com a metodologia a posição da imagem no tempo  $t + \Delta t$ , com isso gerar a nova latitude e longitude da aeronave, para fazer a navegação autônoma por imagens.

As atitudes do VANT em torno dos eixos  $x$ ,  $y$  e  $z$ , são chamados de rolamento ou inclinação (*roll*), arfagem (*pitch*) e guinada ou proa (*yaw*), essas atitudes alteram a geometria da imagem capturada pela aeronave, para diminuir esses efeitos, neste trabalho faz-se uso da visada nadir, como ilustrado na Figura 4.2, onde a câmera aponta para baixo e apresenta a geometria da imagem quando a aeronave está reta e nivelada e quando sofre com as atitudes da aeronave de *roll*, *pitch* e *yaw*.

Figura 4.2 - Efeitos das atitudes da aeronave.



Efeitos das atitudes de roll pitch e yaw da aeronave na geometria da imagem.

Fonte: Roberto (2017).

## 4.2 Extração de pontos de interesse nas imagens aéreas

Para fazer a navegação autônoma com uso de casamento de imagens, uma das maneiras é por meio de pontos de interesse entre pares de imagens. Estes pontos podem ser cantos, quinas ou bordas, chamados detectores. Em seguida, são extraídos vetores de características para cada ponto, utilizando seus pixels vizinhos, chamado descritores.

Em seguida cada ponto é correspondido com outro ponto que estiver mais próximo, considerando uma distância entre os vetores. Essas características podem ser binárias ou em ponto flutuante, na literatura os principais detectores e descritores binários

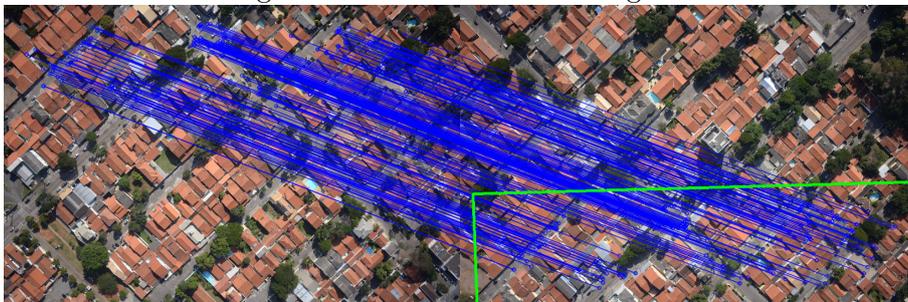
de características são o BRIEF (CALONDER et al., 2010), BRISK (LEUTENEGGER et al., 2011), ORB (RUBLEE et al., 2011), FREAK (ALAHY et al., 2012), AKAZE (ALCANTARILLA et al., 2013) e LATCH (LEVI; HASSNER, 2016), e de ponto flutuante são o SIFT (LOWE, 2004) e SURF (BAY et al., 2006).

Por se tratar de um sistema em tempo real, os métodos binários são mais indicados, pois possuem um custo computacional menor, além disso, serão testados e comparados apenas os mais atuais BRISK, ORB, FREAK, AKAZE e LATCH.

### 4.3 Correspondência de pontos de interesse

Para fazer a correspondência ou casamento dos pares de imagens, como mostrado na Figura 4.3, de modo geral, utiliza o método de busca Força Bruta com KNN, onde para cada ponto busca outros  $k$  pontos mais próximos a ele, utilizando a distância de *Hamming* entre os vetores de cada ponto, encontrados pelo descritor. Além disso, para melhorar a correspondência dos pontos, essa busca é feita em duas direções, ou seja, para cada ponto na imagem no tempo  $t$ , encontra-se os dois melhores pontos correspondentes na imagem no tempo  $t + \Delta t$  e para cada ponto na imagem no tempo  $t + \Delta t$ , encontra-se os dois melhores pontos correspondentes na imagem no tempo  $t$ . Na literatura existem outras estratégias para estimar a quantidade de grupos, mas não são exploradas neste trabalho devido a restrição de tempo de processamento da aplicação considerada. Em seguida, se a distância dos dois melhores pontos forem relativamente próximos, então existe uma possibilidade do segundo melhor casamento ser na verdade o correto, então rejeita-se ambas as correspondências, contudo se essa distância for alta, significa que o melhor casamento, possivelmente é a melhor escolha para aquele ponto.

Figura 4.3 - Casamento de imagens.



Exemplo de casamento de imagens com o método de pontos de interesse ORB, onde as linhas representam as correspondências entre os pontos de interesse.

Fonte: Produção do autor.

Entretanto alguns casamentos infelizmente ainda podem ser falsos, para eliminar esse problema é aplicado o método RANSAC nos casamentos já filtrados.

#### 4.4 Eliminar falsas correspondências

O RANSAC (RANdom SAmple Consensus) é um método iterativo para estimar os parâmetros de um modelo matemático, onde tenta utilizar a menor quantidade de pontos possíveis para estimar um modelo, em seguida verifica os pontos que se ajustam melhor ao modelo e elimina os outros pontos, chamados de *outliers* (FISCHLER; BOLLES, 1981).

Para o casamento de imagens, o RANSAC faz uso das coordenadas dos pontos casados para estimar a matriz de homografia  $H$ , uma matriz 3 por 3 não singular que contem a transformação projetiva do conjunto de pontos  $p = (x, y)$  das imagens no tempo  $t$  que correspondem com o conjunto de pontos  $p' = (x', y')$  das imagens no tempo  $t + \Delta t$ , como mostrado na Equação 4.1.

$$\begin{pmatrix} x' \\ y' \\ 1 \end{pmatrix} = \begin{pmatrix} h_{11} & h_{12} & h_{13} \\ h_{21} & h_{22} & h_{23} \\ h_{31} & h_{32} & h_{33} \end{pmatrix} \begin{pmatrix} x \\ y \\ 1 \end{pmatrix} \quad (4.1)$$

Com isso os pontos que não fazem parte da matriz  $H$ , são eliminados e considerados *outliers*, ou seja, falsos casamentos. Caso o RANSAC não consiga estimar a matriz de homografia, haverá uma falha no sistema, isso pode ocorrer se as imagens tempo  $t$  não tiver sobreposição com a imagem no tempo  $t + \Delta t$  ou se os pontos forem casados erroneamente.

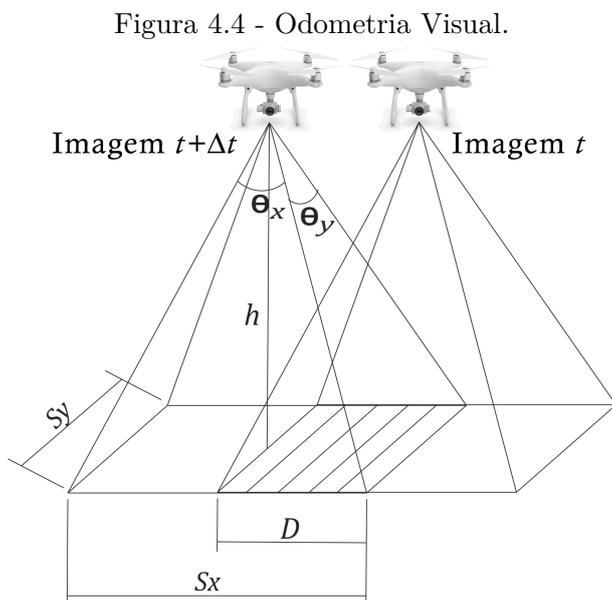
#### 4.5 Escolher melhor correspondência

Com os pontos filtrados pelo RANSAC, o próximo passo é selecionar a melhor correspondência, que será utilizada para estimar o deslocamento do VANT.

Durante a captura da imagem da região sobrevoada, a aeronave não estará com todas as imagens retas e niveladas, como apresentado na Figura 4.2, pois no decorrer do voo, a imagem sofre atitudes da aeronave de *roll*, *pitch* e *yaw*, para amenizar essas atitudes, neste trabalho, faz uso do ponto sempre mais próximo do centro de cada uma das imagens, pois no centro a imagem tem essas influencias menores (ROBERTO, 2017).

#### 4.6 Estimar deslocamento do VANT

Para estimar a posição do VANT por odometria visual, é necessário conhecer a posição inicial da aeronave, para as imagens seguintes. Usa-se a posição inicial como referencia para a próxima imagem. Para calcular a odometria visual são utilizadas as coordenadas obtidas pelo método RANSAC, entre os pares de imagens nos tempos  $t$  e  $t + \Delta t$ , as características da câmera e a altura do VANT, como ilustrado na Figura 4.4.



Cenário de voo para estimar o deslocamento do VANT entre pares de imagens.

Fonte: Produção do autor.

Na Figura 4.4,  $\Theta_x$  e  $\Theta_y$  são os ângulos de abertura do sensor óptico da câmera utilizada no eixo  $x$  e  $y$ . Os  $S_x$  e  $S_y$  são as dimensões real da imagem no instante de tempo  $t + \Delta t$ ,  $h$  é a altura do VANT, obtida com uso de um altímetro e  $D_x$  e  $D_y$  são os deslocamentos em  $x$  e  $y$  do VANT entre os pares de imagem. Com as coordenadas do casamento filtradas pelo RANSAC é possível estimar a área sobrevoada através da Equação 4.2 e 4.3 (TELLIDIS; LEVIN, 2014).

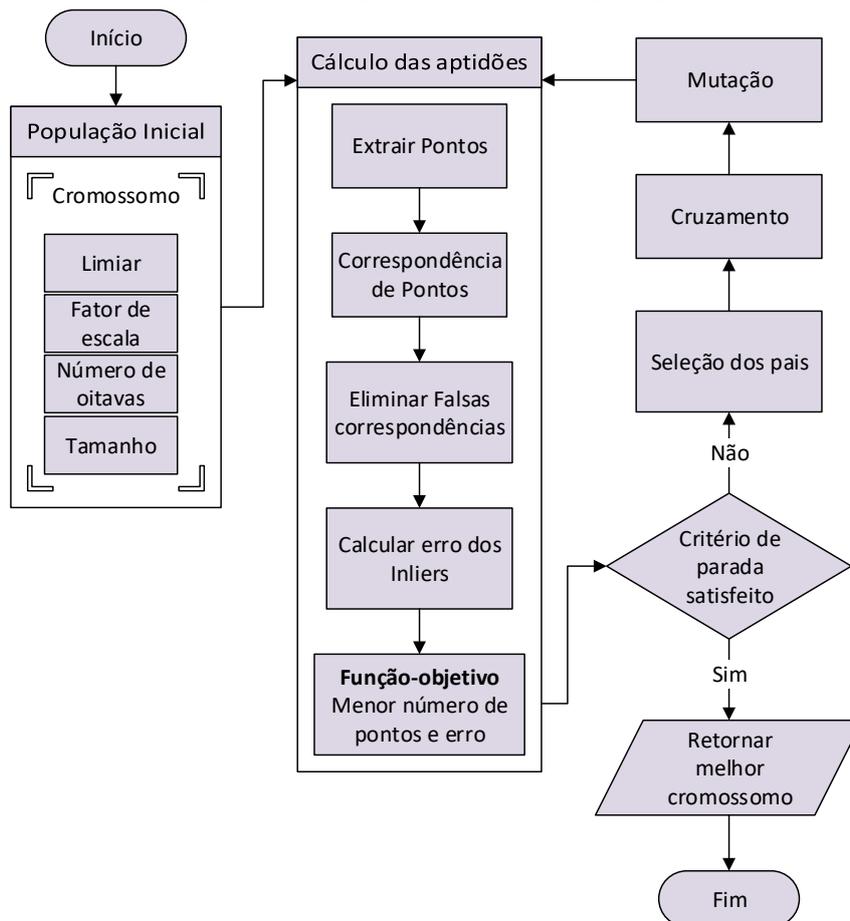
$$D_x = 2h \tan \left( \frac{\Theta_x}{2} \right) \quad (4.2)$$

$$D_y = 2h \tan\left(\frac{\Theta_y}{2}\right) \quad (4.3)$$

#### 4.7 Algoritmo Genético (AG)

Para escolher manualmente os melhores parâmetros do método de Pontos de interesse, é algo trabalhoso e difícil de se conseguir, porém com uso de AG é possível encontrar uma solução subótima, entretanto o AG não garante uma solução ótima. Os procedimentos para o método de otimização são ilustrados na Figura 4.5, que faz uso do AG, para encontrar uma solução subótima, a fim de escolher os melhores parâmetros dos métodos de pontos de interesse para diferentes imagens, serão explicados nesta sessão.

Figura 4.5 - Fluxograma do Algoritmo Genético para pontos de interesse.



Descrição dos processos do Algoritmo Genético para encontrar os parâmetros dos métodos de pontos de interesse BRISK, ORB e FREAK, AKAZE e LATCH.

Fonte: Produção do autor.

O algoritmo começa com a inicialização da população, formada por um conjunto de cromossomos, com os seguintes genes:

- Limiar para detecção do ponto de interesse;
- Número de oitavas, representa o número níveis de escala;
- Fator de escala, representa a relação da vizinhança de um ponto para os níveis de escala;
- Tamanho do descritor.

Os genes escolhidos foram os parâmetros dos métodos de pontos de interesse que têm maior relevância para configurar cada um dos métodos.

Em seguida, realiza-se o cálculo das aptidões de cada cromossomo de acordo com uma função de custo. Caso o critério de parada seja satisfeito, o algoritmo retorna o cromossomo com o menor custo calculado, caso contrário, pode ser realizado a seleção, o cruzamento e a mutação na população, onde esse processo se repete para  $N$  gerações.

Para cada geração do AG, é calculada uma função de aptidão para organizar os cromossomos em relação ao custo e uma função de seleção para eliminar os cromossomos com os maiores custos de acordo com uma probabilidade de seleção.

O cálculo das aptidões neste processo se baseia no método de pontos de interesse, onde são realizados: a extração dos pontos (seção 4.2), com uso de cada método; a correspondência dos pontos extraídos (seção 4.3); a eliminação de falsas correspondências (seção 4.4); o cálculo do erro dos *inliers* em relação a matriz de homografia correta; e a função objetivo função que faz uso do erro, tempo de processamento e a quantidade de *inliers*, que será detalhada na seção 5.1.

Após a seleção dos melhores cromossomos é realizado um torneio entre eles e de acordo com uma taxa de probabilidade de cruzamento é escolhido aleatoriamente 2 cromossomos para fazer um cruzamento e gerar um filho para a população.

Após o cruzamento, de acordo com uma taxa de probabilidade de mutação é realizado a mutação no filho gerado pelo cruzamento.

Após a mutação, é comparado o custo do filho se é menor que o valor de custo do cromossomo pai, caso seja, o filho substitui o pai na população, senão continua a

mesma população.

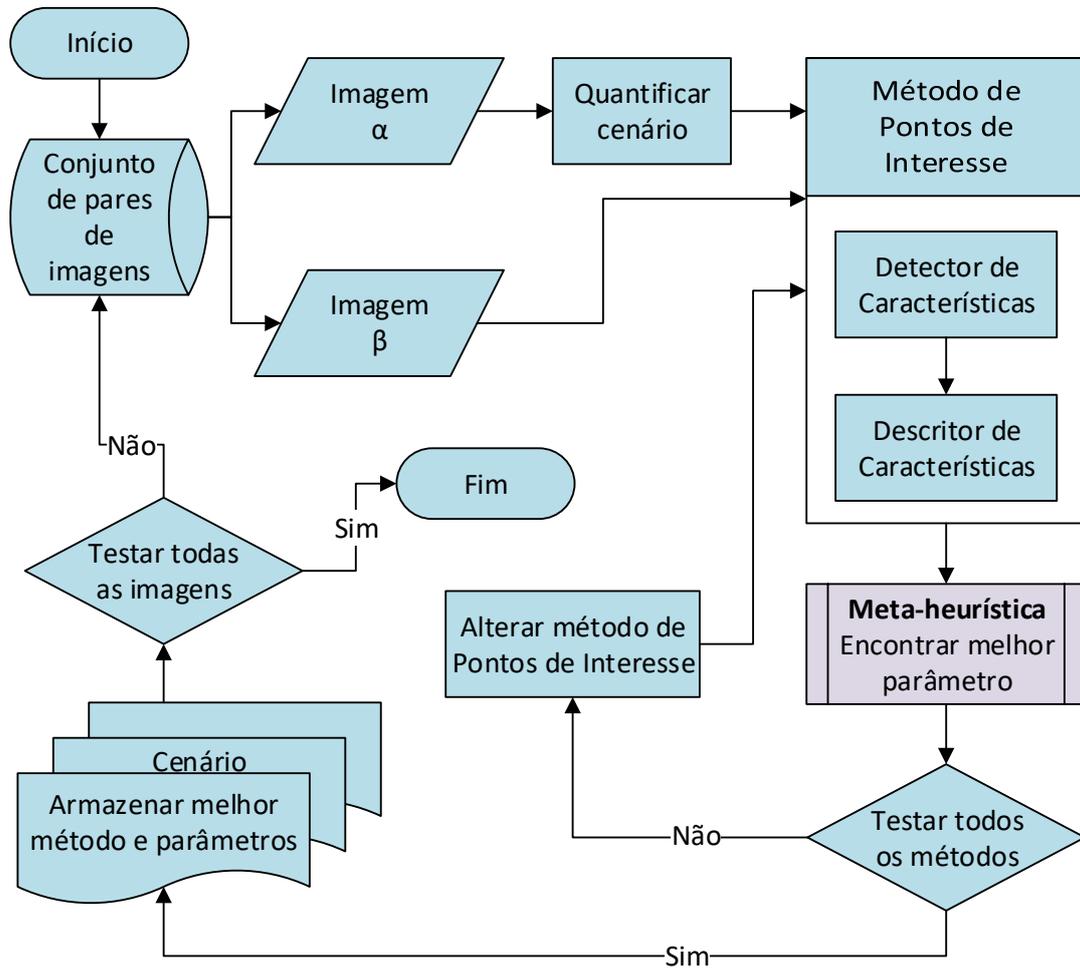
Em seguida inicializa outro torneio até  $N$  e depois inicializa a próxima geração até  $M$ , no final espera ter os melhores parâmetros para o método de pontos de interesse. Para finalizar, o algoritmo escolhe o cromossomo com o menor custo, ou seja, o que tiver o menor erro. Esse procedimento é realizado para cada um dos métodos de pontos de interesse.

#### **4.8 Lógica Fuzzy**

Após a estimação dos melhores parâmetros com uso do Algoritmo Genético, o passo seguinte da metodologia é aplicar essa informação no sistema autoconfigurado. Neste trabalho, faz-se uso de lógica nebulosa com dados dos valores de textura da imagem de entrada, pode-se retornar o valor de parâmetro do método de pontos de interesse para aplicar na imagem. Essas informações podem ser tratadas com lógica multivalorada, como apresentadas no Capítulo 5, onde as variáveis variam entre 0 e 1, pois nos testes práticos, dificilmente pode-se fazer uso de lógica booleana.

Para fazer a transição do dado de entrada para a saída, o Fuzzy faz uso de regras de inferência, para montar as regras, foram armazenados para cada par de imagem de teste, os valores de quantificação e os melhores parâmetros de cada método de pontos de interesse obtido pelo AG. Na Figura 5.15 é apresentado esse processo de armazenagem dos parâmetros, onde o processo é semelhante da Imagem 4.1.

Figura 4.6 - Fluxograma para geração de Inferência Fuzzy.



Descrição dos processos para geração das regras Fuzzy, nas imagens de voo da aeronave, onde a meta-heurística é o AG apresentada na Figura 4.5.

Fonte: Produção do autor.

O fluxograma da Figura 4.6 é iniciado com a aquisição de pares de imagens correspondentes. Em seguida, extrai medidas de texturas para quantificar a imagem. No passo seguinte, aplica-se métodos de pontos de interesse com diferentes detectores e descritores de características, com uso da meta-heurística Algoritmo Genético. Neste processo busca-se por parâmetros subótimos para cada detector e descritor, descrito na seção 4.7. Para finalizar salva-se, os valores de medidas de textura e os parâmetros. Essas informações têm importância para geração das regras de inferência do Fuzzy, pois para aplicação no sistema autoconfigurado, para cada imagem de en-

trada no sistema, escolhe-se automaticamente o melhor parâmetro de acordo com as regras de inferência. Neste trabalho, para o sistema autoconfigurado, não se faz uso de todas as medidas de texturas e de todos os métodos de pontos de interesse, para a simplificação do sistema, a fim de diminuir o custo computacional. A análise das medidas de texturas escolhidas e os melhores detectores, descritores e parâmetros para as imagens são apresentadas no Capítulo 5.



## 5 EXPERIMENTOS E RESULTADOS

Neste Capítulo, são apresentados os experimentos e os resultados da abordagem proposta. Tem-se como objetivo avaliar a importância de um modelo que se configure automaticamente durante o voo, para estimação de posicionamento da aeronave com uso de odometria visual. Para a criação do modelo autoconfigurado, são utilizadas técnicas de visão computacional e inteligência computacional. São discutidas e avaliadas técnicas para quantificação de imagem e métodos de pontos de interesse para extração de características por meio de uma meta heurística, para escolha automática de parâmetro de acordo com uma imagem de entrada. O uso da teoria de conjuntos nebulosos, dos resultados obtidos pela meta-heurística, para a realização da navegação autônoma baseada por imagens em um sistema embarcado em tempo real.

Os experimentos fazem uso de um banco de imagens aéreas concedidas por [Roberto \(2017\)](#), que foram obtidas com uso de uma câmera Nikon Coolpix A embarcada em uma aeronave A-29 Supertucano da Força Aérea Brasileira (FAB), como ilustrada na Figura 5.1. O voo resultou em 868 imagens com resolução de 4928 por 3264 pixel, capturas em diferentes tipos de coberturas de solo com diferentes transformações de projeção, realizado na cidade de São José dos Campos-SP, em altura de 300 e 600 metros. A câmera está com visada nadir, ou seja, apontada para baixo, com o intuito de reduzir distorções da área sobrevoada.

Figura 5.1 - Aeronave e câmera.



(a) Aeronave A-29 Supertucano da FAB.



(b) Câmera Nikon Coolpix A.

Equipamento utilizado para geração das imagens do banco de imagens ([ROBERTO, 2017](#)).

Fonte: [Roberto \(2017\)](#).

Para obter as informações dos sensores da aeronave, faz uso de uma Unidade de Medida Inercial - Inertial Measurement Unit (IMU), para fornecer os ângulos de orientação espacial da aeronave, *yaw*, *pitch*, *roll* e altitude e um receptor GNSS geodésico de dupla frequência com capacidade de pós-processamento diferencial, para fornecer a posição em latitude e longitude da aeronave.

Dentre as imagens do banco de imagens, foram separadas inicialmente 30 pares de imagens com diferentes regiões de coberturas de solo, divididas em: urbana; vegetação rasteira; vegetação densa; lago; vegetação mista (contêm vegetação rasteira e densa); vegetação e lago; vegetação e urbana, definidas visualmente pela predominância da cobertura de solo em cada imagem regiões. Outro fator que pode alterar as características da imagem é a atitude da aeronave, neste banco de imagens, para cada tipo de cobertura de solo, foram selecionas: 1 par de imagem com visada nadir; 1 par com diferença de proa da aeronave; 1 par com diferença de arfagem da aeronave; 1 par com diferença de inclinação da aeronave; 1 par com uma maior altitude da aeronave e alguns pares com mais de uma influência da aeronave; e diferenças de altitude. Os dados são apresentados no Anexo A, que contém 60 imagens, ou seja, 30 casos de pares de imagens, os dados dos sensores inerciais da aeronave de altitude em metros, a proa, a arfagem e a inclinação em graus, que tem a importância de representar a atitude da aeronave e a região sobrevoada da imagem, definido visualmente pela sua predominância na imagem.

Durante o voo de uma aeronave, podem existir variações de características nas imagens capturadas por diversas razões, entre elas, devido à região sobrevoada, com diferentes coberturas de solo (Figura 5.2 (a) e (b)) ou por meio de atitudes da aeronave nos eixos  $x$ ,  $y$  e  $z$ , como a altura (Figura 5.2 (c) e (d)) e *Yaw* (Figura 5.2 (e) e (f)).

Figura 5.2 - Exemplo de imagens de voos.



(a) Região de floresta.



(b) Região de lago.



(c) Aeronave a 300 metros de altura.



(d) Aeronave a 600 metros de altura.



(e) Aeronave sem inclinação do eixo Z.



(f) Aeronave com inclinação do eixo Z.

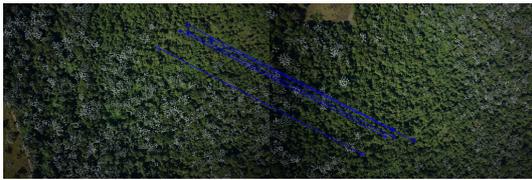
Exemplo de variações que as imagens podem ter durante o voo, através da cobertura do solo ou da atitude da aeronave.

Fonte: Roberto (2017).

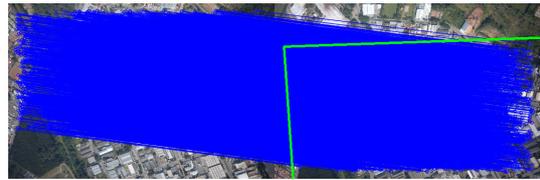
Para realização da Odometria Visual, um dos principais métodos utilizados faz uso de pontos de interesse (FRAUNDORFER; SCARAMUZZA, 2012) (BRAGA, 2019), porém para diferentes imagens, podem ser empregadas diferentes métodos e parâmetros de algoritmos para detecção de pontos de interesse. Entretanto, identificar os parâmetros e métodos mais adequados para cada tipo de imagem não é uma tarefa simples. Além disso, utilizar os parâmetros padrões das bibliotecas de processamento de imagens pode ocasionar falhas para a estimação da posição, por não garantir um número

adequado de pontos para a realização da Odometria Visual (ROOS, 2018). Se forem utilizados poucos pontos não é possível formar a matriz de homografia, sendo necessário no mínimo 8 *inliers*. Se forem utilizados muitos pontos, tem-se um custo computacional alto, prejudicando a eficiência para ter processamento embarcado e tempo real. Na Figura 5.3 (a) é ilustrado um caso em que são identificados poucos *inliers*, enquanto na Figura 5.3 (b), são apresentados casos com muitos *inliers*.

Figura 5.3 - Exemplo de quantidade de *inliers*.



(a) Poucos *inliers*.



(b) Muitos *inliers*.

Exemplo de poucos e muitos *inliers* em relação ao mínimo de 8 *inliers* que são necessários para a formação da matriz de homografia.

Fonte: Produção do autor.

Para detecção e descrição de pontos de interesse, neste trabalho são utilizadas as técnicas BRISK (LEUTENEGGER et al., 2011), ORB (RUBLEE et al., 2011), FREAK (ALAHY et al., 2012), AKAZE (ALCANTARILLA et al., 2013) e LATCH (LEVI; HASSNER, 2016), com suas combinações de detector + descritor, apresentadas na Tabela 5.1.

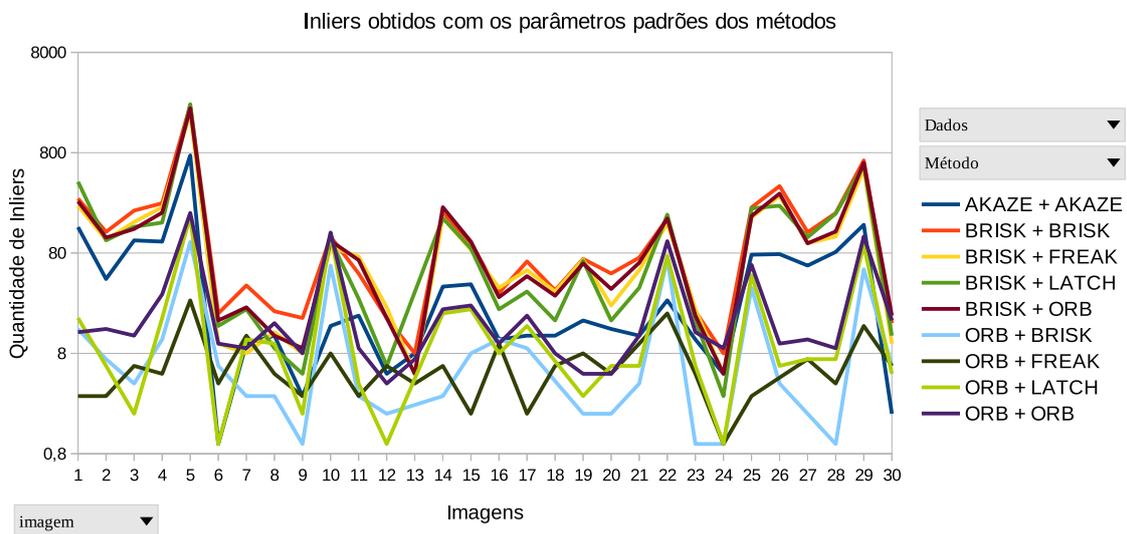
Tabela 5.1 - Combinação dos métodos de pontos de interesse.

Detector	Descritor
AKAZE	AKAZE
BRISK	BRISK
BRISK	FREAK
BRISK	LATCH
BRISK	ORB
ORB	BRISK
ORB	FREAK
ORB	LATCH
ORB	ORB

Nem todos os detectores podem ser combinados com os descritores, como apresentado na Tabela 5.1. O detector AKAZE apenas descreve com ele mesmo, pois não faz uso do espaço escala gaussiano e o FREAK e LATCH são apenas descritores, por isso não estão na lista de detectores.

Na Figura 5.4 e no Anexo B são ilustradas as quantidades de *inliers*, com uso de parâmetros padrões dos métodos de pontos de interesse ORB, BRISK, FREAK, AKAZE e LACH, com suas combinações de detector + descritor em um conjunto de 30 imagens contendo diferentes cenários de voos.

Figura 5.4 - *Inliers* entre as imagens com os parâmetros padrões.



*Inliers* entre as imagens de teste, com uso dos parâmetros padrões dos métodos de pontos de interesse.

Fonte: Produção do autor.

Pode-se observar que em todos os métodos a quantidade de *inliers* varia em cada imagem, isso prejudica a escolha do método a se utilizar. A variação entre a quantidade de *inliers* prejudica a estabilidade do desenvolvimento em um sistema embarcado, pois uma grande quantidade de *inliers* está relacionada ao custo computacional, quanto mais pontos, mais processamento é necessário. Além disso, pode-se observar que em alguns casos os métodos apresentam um número de *inliers* menor que 8, não sendo possível estimar a matriz de homografia para a odometria visual, no Anexo B essa informação é representada pelo campo em branco. Na Tabela 5.2 é apresen-

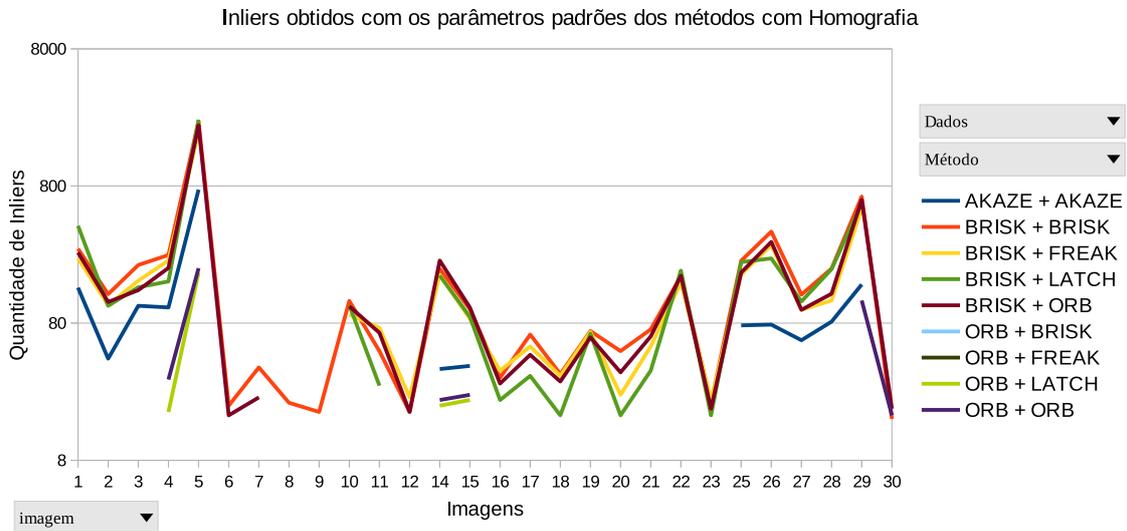
tada a média e o desvio padrão do conjunto de 30 imagens da quantidade de *inliers* apresentada na Figura 5.4.

Tabela 5.2 - Quantidade de *inliers* com uso de parâmetro fixo.

Métodos	<i>Inliers</i>	
	Média	Desvio Padrão
AKAZE + AKAZE	62,5	134,8
BRISK + BRISK	199,0	425,0
BRISK + FREAK	164,6	357,9
BRISK + LATCH	183,6	438,1
BRISK + ORB	179,3	399,2
ORB + BRISK	14,4	24,5
ORB + FREAK	6,3	5,7
ORB + LATCH	23,9	42,0
ORB + ORB	30,6	45,4

Para a odometria visual é importante obter os pontos para a geração da matriz de homografia, entretanto mesmo se forem desconsiderados os *inliers* que não obtiveram a matriz, com uso de um parâmetro fixo, ainda há grande variação de quantidade de pontos, como apresentado na Figura 5.5. Ressalta-se que foi escolhida a quantidade de 8 pontos, por ser o mínimo para formação da matriz de homografia, e com isso garantir que os *inliers* encontrados são verdadeiros se formar a matriz de homografia, para não ocasionar falha na estimação de posicionamento.

Figura 5.5 - *Inliers* que obtiveram a matriz de homografia entre as imagens com os parâmetros padrões.



*Inliers* dos métodos de pontos de interesse, que obtiveram a matriz de homografia entre as imagens de teste, com uso dos parâmetros padrões.

Fonte: Produção do autor.

Pode-se observar na Tabela B1 do Anexo B que os métodos com o detector BRISK apresentaram uma quantidade de pontos maior do que o AKAZE e ORB, contudo com variação maior. Na Tabela 5.3 são apresentados a média e o desvio padrão dos dados da Tabela B1.

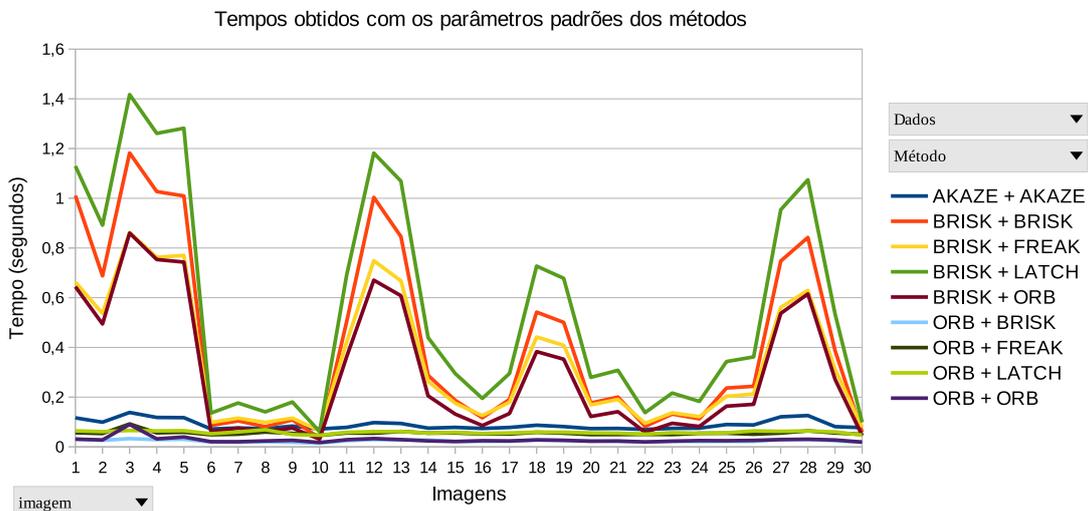
Tabela 5.3 - Quantidade de *inliers* com uso de parâmetro fixo que obtiveram a matriz de homografia.

Métodos	<i>Inliers</i>	
	Média	Desvio Padrão
AKAZE + AKAZE	116,07	174,87
BRISK + BRISK	212,61	436,75
BRISK + FREAK	212,13	396,77
BRISK + LATCH	237,35	487,81
BRISK + ORB	205,65	422,67
ORB + BRISK	64,80	22,07
ORB + FREAK	23,50	3,50
ORB + LATCH	67,67	55,84
ORB + ORB	67,36	58,95

Devido às variações na quantidade de pontos encontrados no conjunto de imagens apresentadas nas Figuras 5.4 e 5.5, emprega-se um conjunto de técnicas para escolher automaticamente o algoritmo mais adequado de acordo com características extraídas da imagem, considerando a necessidade de tempo real e embarcado.

Para embarcar o sistema, o modelo preferencialmente tem que ter um baixo custo computacional e ter tempos de respostas controlados para poder interagir com o tempo do sistema de posicionamento da aeronave. Como apresentado na Figura 5.6 há variações no tempo de processamento dos métodos de pontos de interesse com uso dos parâmetros padrões. Além disso é necessário garantir uma quantidade de pontos para a formação da matriz de homografia, como demonstrando na Figura 5.4. Em alguns casos não é possível garantir o mínimo de pontos necessários para a formação da matriz de homografia. Na Figura 5.7 são apresentados os tempos dos *inliers* que garantiram o mínimo de pontos, formando a matriz de homografia, removendo quem tem menos de 8 pontos. No Anexo C são apresentados os dados do tempo entre as imagens com os parâmetros padrões e os campos em branco, representam os métodos que não atingiram o número mínimo de pontos necessários.

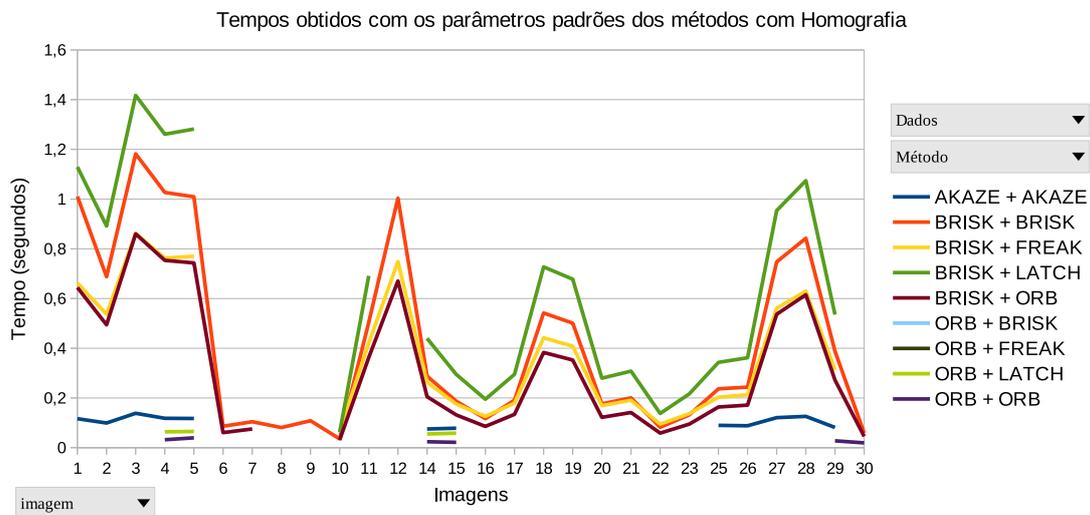
Figura 5.6 - Tempo entre as imagens com os parâmetros padrões.



Tempo de processamento entre as imagens de teste, com uso dos parâmetros padrões dos métodos de pontos de interesse.

Fonte: Produção do autor.

Figura 5.7 - Tempo entre as imagens que obtiveram a matriz de homografia com os parâmetros padrões.



Tempo de processamento dos métodos de pontos de interesse, que obtiveram a matriz de homografia entre as imagens de teste, com uso dos parâmetros padrões.

Fonte: Produção do autor.

Pode-se observar na Figura 5.6 que todos os métodos que têm o detector BRISK, possuem um tempo maior. Na Tabela 5.4 são apresentados a média e o desvio padrão dos tempos. O tempo de processamento do BRISK varia entre 0,3 e 0,6 e os métodos que utilizam o detector AKAZE e ORB, ficam entre 0,02 e 0,1 segundos, mostrando-se mais estáveis. Entretanto como pode-se observar na Figura 5.7, existem lacunas.

Neste trabalho, todos os testes são executados em um Intel Core i7-6500U com 2,5GHz e 8GB de memória RAM. O tempo tem relevância para a geração de trabalhos futuros, para ter medidas de comparação quando for executar em hardware embarcado.

Tabela 5.4 - Tempo entre as imagens com uso de parâmetro padrão.

Métodos	<i>Inliers</i>	
	Média	Desvio Padrão
AKAZE + AKAZE	0,10	0,02
BRISK + BRISK	0,42	0,36
BRISK + FREAK	0,39	0,25
BRISK + LATCH	0,60	0,41
BRISK + ORB	0,32	0,26
ORB + BRISK	0,02	0,01
ORB + FREAK	0,05	0,00
ORB + LATCH	0,06	0,01
ORB + ORB	0,02	0,01

Portanto, pode-se analisar com os resultados que o uso de um modelo estático pode gerar tempos e quantidades de *inliers* variados e tempos longos para cada imagem, em um mesmo voo, com isso não é possível garantir um tempo confiável para embarcar o modelo.

Para o desenvolvimento do modelo autoconfigurado, no primeiro passo, propõe-se empregar uma meta heurística, neste trabalho o Algoritmo Genético é implementado para gerar para cada imagem, de um conjunto de 30 pares de imagens, a escolha de 1 método para uso no modelo autoconfigurado. Neste trabalho faz uso dos principais parâmetros dos métodos de pontos de interesse, o limiar, o fator de escala, o número de oitavas e o tamanho do vetor.

### 5.1 Configuração do Algoritmo Genético

Para comparação dos métodos de pontos de interesse, grande parte dos trabalhos, fazem uso dos parâmetros padrões que vêm nas bibliotecas de processamento de imagens (BRADSKI; KAEHLER, 2008), porém para cada método, diversos parâmetros podem ser modificados para um algoritmo ter um melhor resultado, com isso, existe um desafio em definir quais algoritmos são melhores para cada imagem.

Para tornar a comparação mais justa, pois o uso dos parâmetros padrões em algumas imagens, podem resultar em muitos ou poucos pontos para análise. Logo, pode-se empregar os parâmetros adequados de cada método para uma configuração que tenha um melhor resultado, com isso será comparado os melhores resultados de cada um dos métodos.

A configuração e parametrização do AG teve alterações ao longo do trabalho, a fim de obter uma configuração, com parâmetros subótimos em relação a quantidade de *inliers* de pontos de interesse, um erro e tempo de processamento do algoritmo aceitável para gerar um modelo que consiga estimar a posição, com baixo custo computacional.

Para definir o intervalo dos parâmetros dos métodos, empiricamente configura-se para abrangência de grande parte dos espaços de atributos, onde o limiar varia entre 10 a 100 mais um fator de multiplicação, o fator de escala que varia entre 1,1 a 2,9, o número de oitavas que varia entre 2 a 8 e o tamanho do vetor que varia entre 2, 4, 8, 16, 32, 64.

A parametrização do AG é definida por:

- População: 200;
- Gerações: 50;
- Torneios: 20;
- Taxa de seleção: 99%;
- Taxa de mutação: 40%;
- Taxa de cruzamento: 60%;

Para a formação de uma população mais heterogênea, neste trabalho a inicialização dos 200 cromossomos é distribuída conforme o intervalo de limiar, começando com limiares de valores baixos e aumentando até os valores mais altos. Os atributos de escala, número de oitavas e tamanho do vetor são distribuídos aleatoriamente entre a população.

O cruzamento é realizado com 2 pais, com uso de roleta para escolher quais parâmetros vão ser combinados, gerando 14 combinações possíveis de cruzamento.

A mutação do cromossomo é de 10% em relação ao limiar, com uso de roleta, mais um parâmetro altera para um valor aleatório, caso o parâmetro seja o limiar, a mutação será de 20%.

O Algoritmo Genético, neste trabalho, faz uso de 3 variáveis de entrada: a quantidade de *inliers*, que é necessário no mínimo 8 pontos; o tempo para execução do processo

de detectar, descrever, corresponder e filtrar os pontos de interesse para um par de imagem; e o erro é obtido pela norma de Frobenius:

$$\|erro\|_2 = \left( \sum_{i=0}^m \sum_{j=0}^m |V_{i,j} - H_{i,j}|^2 \right)^{1/2} \quad (5.1)$$

Onde,  $m$  é o tamanho das matrizes de homografia  $H$  e  $V$  que é igual a 3,  $i$  e  $j$  os índices das matrizes.  $H$  representa a matriz de homografia encontrada pelo Algoritmo Genético e  $V$  representa a matriz de homografia desejada, obtida através da mediana das matrizes  $H$  de todos métodos de pontos de interesse testados e configurados com os parâmetros de limiar no mínimo. A matriz  $V$  tem o objetivo de obter o maior número de casamentos corretos, empiricamente quanto menor o limiar do método de pontos de interesse, maior a quantidade de pontos encontradas e o tamanho implica na quantidade de pixels armazenadas no vetor do descritor, entretanto em um sistema embarcado em tempo real, essa configuração geralmente não é esperada, devido ao custo computacional. O erro tende a aumentar com a quantidade de pontos correspondidos incorretamente, onde implica diretamente para encontrar um *inlier* verdadeiro para realização da odometria visual.

Inicialmente (REBOUÇAS et al., 2018), o Algoritmo Genético foi configurado, para gerar uma solução com menor erro e tempo. Onde o número de *inliers* na solução do AG é configurado para aceitar apenas valores entre 16 à 32 pontos, para garantir a correspondência entre as imagens, pois um valor mínimo 8, para gerar a matriz de homografia, pode gerar um erro ou uma certa incerteza, pois como se trata do mínimo, se apenas 1 ponto estiver errado a matriz de homografia pode ter erro. Além disso, como será apresentado na seção , em todos os casos o erro não é igual a 0, ou seja, é necessário abranger um número maior de pontos. Neste trabalho, manteve-se o número de pontos entre 16 e 32, para garantir melhor confiança em encontrar a matriz de homografia e não prejudicar o custo computacional, como será apresentado no decorrer deste capítulo.

Para o AG gerar valores com a quantidade de *inliers* entre 16 à 32 pontos, a função objetivo teve alterações ao longo do trabalho para o cálculo das aptidões. Sua definição final é obtida por:

$$F = \begin{cases} erro \times q, & \text{se } q \leq 32 \\ T + q, & \text{senão} \end{cases} \quad (5.2)$$

Onde,  $F$  é a função objetivo,  $q$  a quantidade de *inliers* e  $T$  o tempo de processamento. A função objetivo foi definida desta maneira, para ter um peso mais forte para os cromossomos com *inliers* inferiores a 32 e como resposta final para a solução do AG, faz uso apenas dos cromossomos com *inliers* entre 16 à 32 pontos.

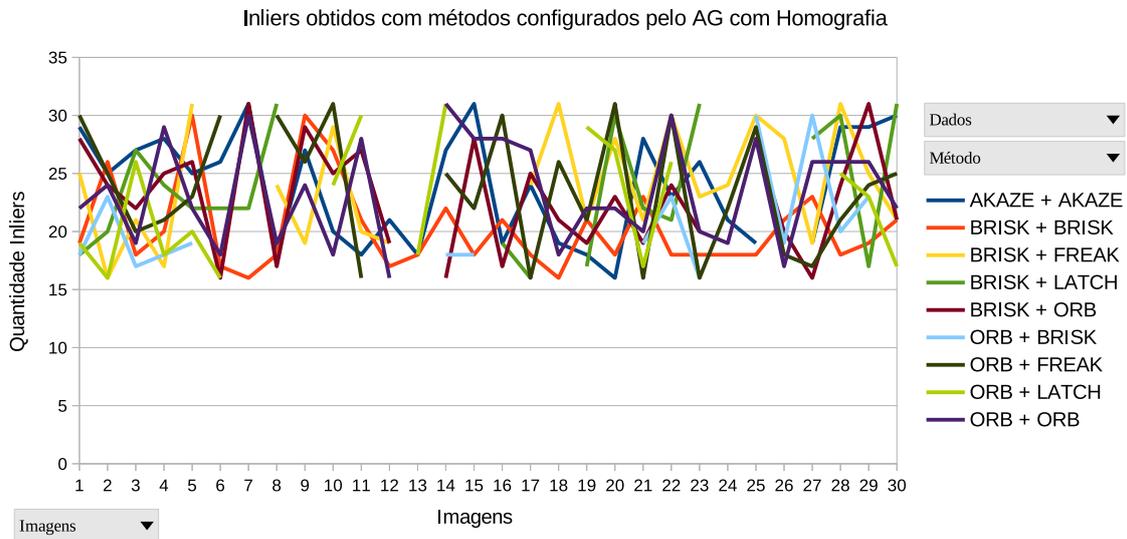
Neste trabalho, o AG é configurado e parametrizado para convergir em poucas gerações, para seu uso ser viável em outros voos, em média a solução é encontrada em 20 gerações.

## 5.2 Comparação dos Métodos de pontos de interesse com Algoritmo Genético

Nessa seção, são apresentadas as comparações dos métodos de pontos de interesse, com uso das técnicas ORB, BRISK, FREAK, AKAZE e LACH (BRADSKI; KAEHLER, 2008), utilizando os parâmetros padrões, com os parâmetros obtidos pelo Algoritmo Genético. São apresentadas apenas as imagens que os métodos de pontos de interesse obtiveram *inliers* suficientes, para encontrar a matriz de homografia.

A quantidade de pontos de interesse, tem influencia direto no custo computacional e desempenho no modelo, pois muitos pontos ocasionam mais processamento e poucos pontos, pode haver falha no modelo. A Figura 5.5 apresenta a quantidade de *inliers*, com uso dos parâmetros padrões, mostrada no início desta seção e na Figura 5.8 apresenta-se os *inliers* obtidos como resposta do Algoritmo Genético.

Figura 5.8 - *Inliers* entre as imagens com Algoritmo Genético.



Inliers entre as imagens de teste, com uso dos parâmetros obtidos através do Algoritmo Genético para os métodos de pontos de interesse.

Fonte: Produção do autor.

Pode-se observar na Figura 5.8 que com uso do Algoritmo Genético, todos os *inliers* variam entre 16 a 32 pontos, mostrados pelo eixo *y* do gráfico, que foram definidos na configuração do AG. Diferente dos parâmetros padrões que variam aproximadamente entre 16 a 2000 (Anexo B), ocasionando um custo computacional mais variado e maior, dificultando a implementação.

O tempo para executar o processo de encontrar os *inliers*, representa a maior parte do custo computacional de todo o modelo, o tempo é importante para avaliação de sistemas embarcados. A Tabela 5.5 apresenta a média e o desvio padrão dos tempos dos métodos de pontos de interesse, com uso de parâmetro padrão (PD) e parâmetro obtido com Algoritmo Genético. No Anexo C apresentam-se os tempos com parâmetros padrões e com o AG.

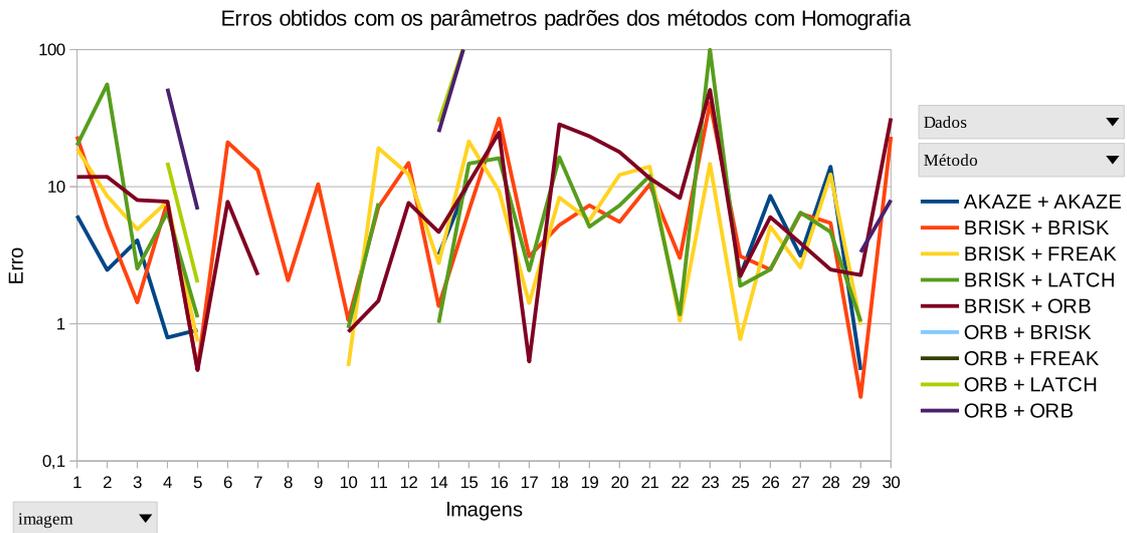
Tabela 5.5 - Tempo entre as imagens com uso de parâmetro padrão e obtido com algoritmo genético.

Método	PD		AG	
	Média	Desvio P.	Média	Desvio P.
AKAZE + AKAZE	0,10	0,02	0,11	0,04
BRISK + BRISK	0,42	0,36	0,17	0,27
BRISK + FREAK	0,39	0,25	0,22	0,19
BRISK + LATCH	0,60	0,41	0,29	0,35
BRISK + ORB	0,32	0,26	0,15	0,17
ORB + BRISK	0,02	0,01	0,28	0,21
ORB + FREAK	0,05	0,00	0,13	0,08
ORB + LATCH	0,06	0,01	0,17	0,23
ORB + ORB	0,02	0,01	0,08	0,12

Pode-se observar na Tabela 5.5 que, com o uso de Algoritmo Genético a média de tempo dos métodos de pontos de interesse ficou entre 0,08 e 0,29 segundos, enquanto com uso do parâmetros padrões, ficou entre 0,02 e 0,60 segundos, pois o tempo tem influência direta com a quantidade de *inliers*. O AG é definido com uso de um intervalo de pontos necessários para a estimação da matriz de homografia, como resultado os tempos dos métodos tem uma diferença menor entre eles. Portanto, para as imagens testadas, o uso de algoritmo genético é adequado para seleção de pontos de interesse. Além disso, na Tabela 5.5 destacado com fundo amarelo, o método ORB + ORB apresenta-se com a média de tempo menor e o AKAZE + AKAZE apresenta-se com o desvio padrão de tempo menor em relação aos outros métodos com uso de AG.

Além de buscar um modelo com tempo de processamento menor, pode-se analisar o quão bem a matriz de homografia obtida pelo algoritmo casa com o modelo verdadeiro. Na Figura 5.9 apresenta-se os erros, com uso dos parâmetros padrões e na Figura 5.10 apresenta-se os erros obtidos como resposta do Algoritmo Genético e no Anexo D apresenta-se os erros com os parâmetros padrões e com o AG.

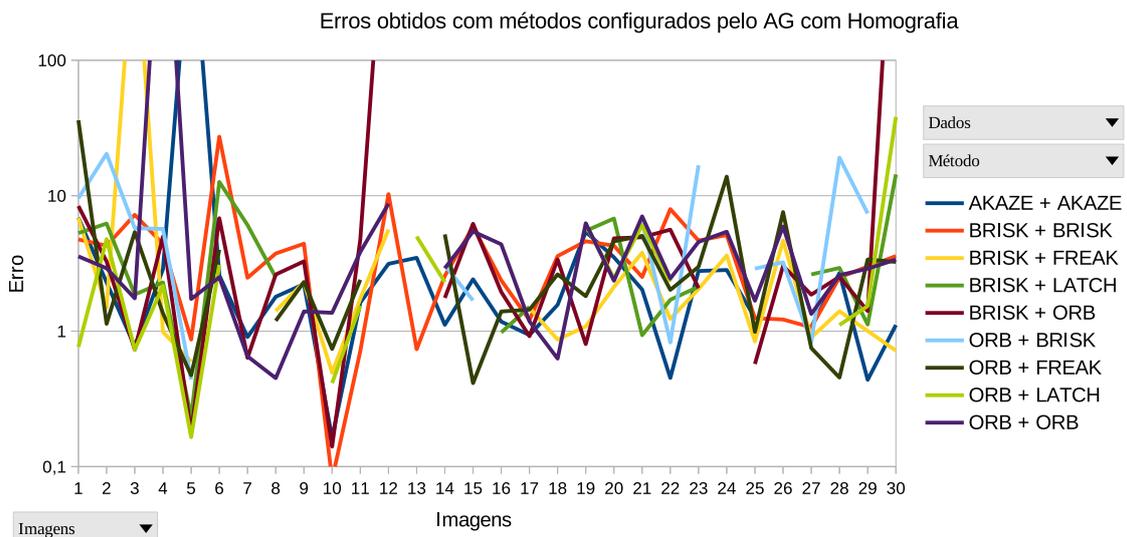
Figura 5.9 - Erro entre as imagens com os parâmetros padrões.



Erro entre as imagens de teste, com uso dos parâmetros padrões dos métodos de pontos de interesse.

Fonte: Produção do autor.

Figura 5.10 - Erro entre as imagens com Algoritmo Genético.



Erro entre as imagens de teste, com uso dos parâmetros obtidos através do Algoritmo Genético para os métodos de pontos de interesse.

Fonte: Produção do autor.

Considera-se que um erro acima ou próximo de 100, tem-se a identificação da matriz de homografia incorreta. Além disso, considera-se que um erro próximo de 10 a matriz de homografia está bem próxima a matriz verdadeira e um erro próximo ou abaixo de 1, seria o ideal, pois pode-se garantir que grande parte dos pontos encontrados são realmente *inliers*.

Pode-se observar na Figura 5.9 que com uso dos parâmetros padrões, muitas imagens não encontraram *inliers* suficientes, pois ficaram lacunas em branco e se observar o eixo  $y$  do gráfico teve menos pontos abaixo de 1 e mais pontos acima de 10 em relação aos parâmetros configurados pelo Algoritmo Genético (Figura 5.10). Além disso na média e o no desvio padrão dos erros, apresentados na Tabela 5.6, observa-se que em todos os casos, com exceção do ORB + FREAK, o uso do AG diminuiu o erro e o desvio padrão em relação ao parâmetros padrões (PD) e na Tabela 5.6 destacado com fundo amarelo, o método AKAZE + AKAZE apresenta-se com o erro menor em relação aos outros métodos com uso de AG.

Tabela 5.6 - Comparação do erro da matriz de homografia.

Método	PD		AG	
	Média	Desvio Padrão	Média	Desvio Padrão
AKAZE + AKAZE	5,82	5,79	4,12	2,13
BRISK + BRISK	9,41	9,85	7,10	8,64
BRISK + FREAK	8,06	6,39	4,56	1,94
BRISK + LATCH	12,65	21,82	4,89	2,27
BRISK + ORB	11,13	11,74	5,84	4,19
ORB + BRISK	17,97	25,16	15,27	16,77
ORB + FREAK	4,00	0,20	7,30	6,89
ORB + LATCH	24,55	40,30	12,93	31,90
ORB + ORB	49,51	81,10	5,95	1,78

A matriz de homografia entre o par de imagens pode ser usada para gerar uma informação sobre os *inliers*, pois representa a transformação geométrica entre as imagens. Quando a matriz não é identificada, não é possível ter a informação se os *inliers* são verdadeiros ou falsos para aplicar a odometria visual. Na Tabela 5.7 apresenta-se o índice de acerto para cada método.

Tabela 5.7 - Comparação de índice de acerto.

Método	Índice de acerto (%)	
	PD	AG
AKAZE + AKAZE	50	97
BRISK + BRISK	93	93
BRISK + FREAK	73	73
BRISK + LATCH	77	77
BRISK + ORB	87	90
ORB + BRISK	17	60
ORB + FREAK	07	77
ORB + LATCH	30	63
ORB + ORB	37	97

Pode-se observar que com uso do Algoritmo Genético, o índice de acerto melhorou na maioria dos casos em relação aos parâmetros padrões, entretanto, onde apenas manteve-se a taxa de acerto, o AG manteve a quantidade de *inliers*, como apresentado no Anexo B, garantindo um sistema mais constante em relação ao tempo, como ilustrado na Figura 5.8. Na Tabela 5.7, destacado com fundo amarelo, os métodos AKAZE + AKAZE, BRISK + BRISK e ORB + ORB apresentam-se com o índice de acerto acima de 90% com uso de AG.

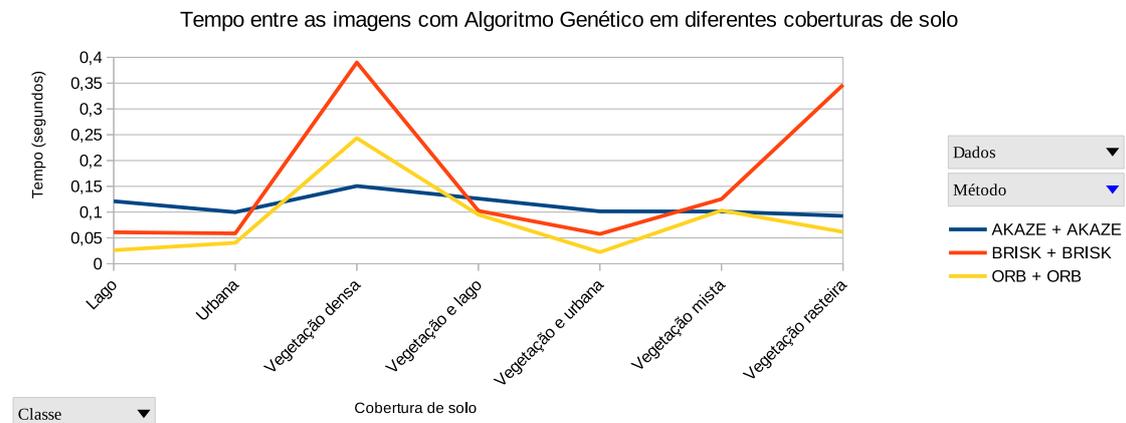
O uso do Algoritmo Genético apresentou resultados melhores em relação aos métodos com parâmetros padrões, considerando o erro e o tempo de execução. O passo seguinte é verificar quais dos métodos com uso de AG é mais adequado para aplicação da metodologia.

Nos testes seguintes, são utilizados os métodos que têm o mesmo detector e descritor, que são o AKAZE + AKAZE, BRISK + BRISK e ORB + ORB, pois foram os que apresentaram um taxa de acerto mais alta com uso de AG.

### 5.2.1 Variações de cobertura de solo

Os testes têm a função de verificar a influência de variações de cobertura pela imagem capturada pela aeronave, sendo neste trabalho, consideradas imagens de região com lago, área urbana, vegetação rasteira, vegetação densa, vegetação e lago, vegetação e urbana, vegetação mista, com vegetação densa e rasteira, com uso do mesmo conjunto de 30 imagens do Roberto (2017). Na Figura 5.11 são apresentados os tempos dos 3 métodos que tiveram as melhores taxas de acerto.

Figura 5.11 - Tempo entre as imagens com Algoritmo Genético em diferentes coberturas de solo.



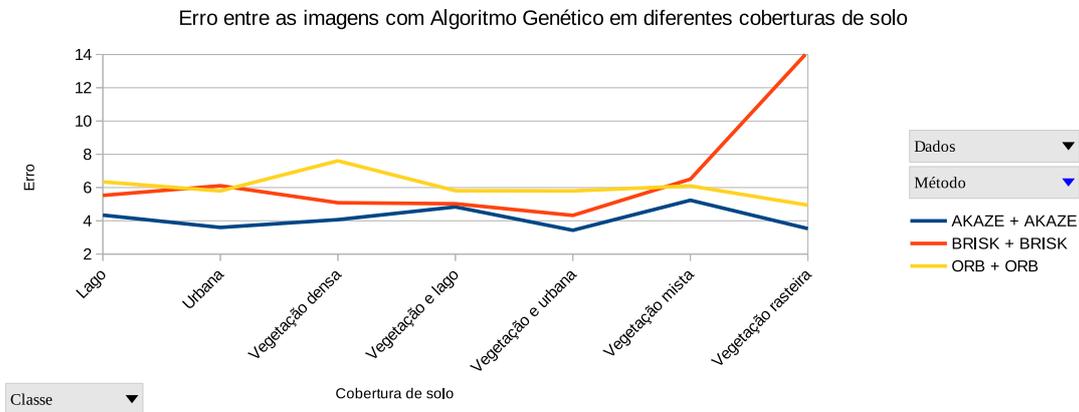
Tempo de processamento entre as imagens de teste, com uso dos parâmetros obtidos através do Algoritmo Genético para os métodos de pontos de interesse em diferentes coberturas de solo.

Fonte: Produção do autor.

Pode-se observar na Figura 5.11 que os métodos BRISK + BRISK e ORB + ORB tiveram variações de tempo maior, com picos acima de 0,2 segundos, em relação ao método AKAZE + AKAZE, que se demonstrou mais constante. Na Tabela 5.5 é indicado que o AKAZE + AKAZE apresenta menor desvio padrão em relação a quantidade de *inliers* comparado com os outros métodos, mostrando-se melhor para uso em sistemas embarcados, onde é necessário ter tempos mais constantes, para sincronia de dados.

Na Figura 5.12 são apresentados os erros dos 3 métodos que tiveram as melhores taxas de acerto. O AKAZE + AKAZE apresenta menores erros em todas as diferentes coberturas de solo.

Figura 5.12 - Erro entre as imagens com Algoritmo Genético em diferentes coberturas de solo.

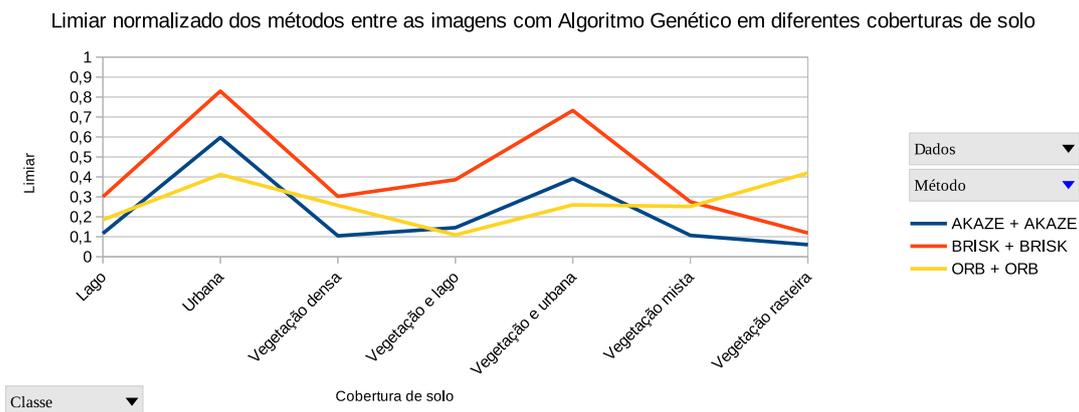


Erro entre as imagens de teste, com uso dos parâmetros obtidos através do Algoritmo Genético para os métodos de pontos de interesse em diferentes coberturas de solo.

Fonte: Produção do autor.

Na Figura 5.13 é apresentado os limiares normalizado entre 0 e 1 dos 3 métodos que tiveram as melhores taxas de acerto, a normalização dos resultados é realizada para melhor visualização, pois estão em escalas distintas.

Figura 5.13 - Limiar normalizado dos métodos entre as imagens com Algoritmo Genético em diferentes coberturas de solo.



Parâmetro de limiar normalizado entre as imagens de teste, com uso dos parâmetros obtidos através do Algoritmo Genético para os métodos de pontos de interesse diferentes coberturas de solo.

Fonte: Produção do autor.

Pode-se observar na Figura 5.13 que o limiar do BRISK + BRISK e do AKAZE + AKAZE tiveram resultados parecidos, alterando, praticamente, só a escala do limiar, ou seja, quando aumenta ou diminui, o outro tem o mesmo comportamento e uma separabilidade melhor das diferentes coberturas de solo do que do ORB + ORB, pois onde contêm regiões de área urbana, ou seja, regiões com características mais alta, o limiar é mais alto do que regiões de área com vegetação, onde as regiões tem características mais baixa, essas características serão abordadas na próxima seção.

### 5.2.2 Variações de atitudes e altitudes da aeronave

Os testes seguintes tem a função de verificar a influência de variações de atitudes da aeronave, com variações de altitude, *yaw*, *roll*, *pitch*. Na Tabela 5.8 são apresentados os tempos dos 3 métodos que tiveram a melhor taxa de acerto, no Anexo A são apresentadas as informações das atitudes da aeronave e no Anexo E as diferenças entre as atitudes para cada par de imagem. As classes de variações de atitudes e altitudes são: altitude de 300 metros; altitude de 600 metros; nadir; *roll*; *yaw*; *yaw* e *roll*. Para considerar que houve diferença entre atitudes, ou que a câmera não esteja em visada nadir, quando a variação ultrapasse 3 graus (ROBERTO, 2017).

Tabela 5.8 - Tempo entre as imagens com Algoritmo Genético em diferentes atitudes da aeronave.

Atitudes	AKAZE + AKAZE	BRISK + BRISK	ORB + ORB
Altitude 300 m.	0,07	0,04	0,02
Altitude 600 m.	0,08	0,04	0,02
Nadir	0,11	0,12	0,07
Roll	0,14	0,31	0,18
Yaw	0,10	0,10	0,06
Yaw e Roll	0,15	0,43	0,10

Pode-se observar na Tabela 5.8 que em relação às atitudes da aeronave, o tempo de processamento diminui. Na maioria dos casos da Tabela 5.6 destacado com fundo amarelo, o ORB + ORB teve um tempo menor. O BRISK + BRISK, para as atitudes com *Roll*, tem um tempo maior que o ORB + ORB e AKAZE + AKAZE.

Na tabela 5.9, são apresentados os erros dos 3 métodos que tiveram as melhores taxas de acerto.

Tabela 5.9 - Erro entre as imagens com Algoritmo Genético em diferentes atitudes da aeronave.

Atitudes	AKAZE + AKAZE	BRISK + BRISK	ORB + ORB
Altitude 300 m.	1,48	6,31	5,90
Altitude 600 m.	0,76	2,76	4,81
Nadir	4,65	12,27	5,20
Roll	4,51	8,24	7,51
Yaw	5,13	6,14	6,38
Yaw e Roll	4,51	4,36	5,40

Pode-se observar na Tabela 5.9, destacado com fundo amarelo, que quando a aeronave está com a altitude maior, 600 metros, o erro diminui, pois a imagem capturada contém mais detalhes. Também destacado com fundo amarelo, o AKAZE + AKAZE foi o método que apresentou o menor erro na maioria dos casos, exceto quando a aeronave tem diferença de *yaw* e *row* o BRIK + BRISK teve um resultado melhor.

O valor de limiar dos métodos são gerados em escalas distintas, para melhor visualização, na Tabela 5.10 é apresentada o limiar normalizado dos 3 métodos que tiveram a melhor taxa de acerto.

Tabela 5.10 - Limiar normalizado entre as imagens com Algoritmo Genético em diferentes atitudes da aeronave.

Atitudes	AKAZE + AKAZE	BRISK + BRISK	ORB + ORB
Altitude 300 m.	0,18	0,66	0,51
Altitude 600 m.	0,56	0,94	0,65
Nadir	0,29	0,77	0,16
Roll	0,24	0,71	0,20
Yaw	0,13	0,65	0,22
Yaw e Roll	0,09	0,52	0,19

Com destaque em amarelo, na Tabela 5.10 pode-se observar que a altitude maior, 600 metros, aumenta o limiar e diminui o erro (Tabela 5.9). Quando existem diferenças entre *yaw* e *row*, tem-se um efeito oposto na maioria dos casos, ou seja, diminui o limiar e aumenta o erro, com isso pode-se ter uma análise prévia que as atitudes da aeronave é um fator que tem relevância quando são aplicados os métodos de pontos

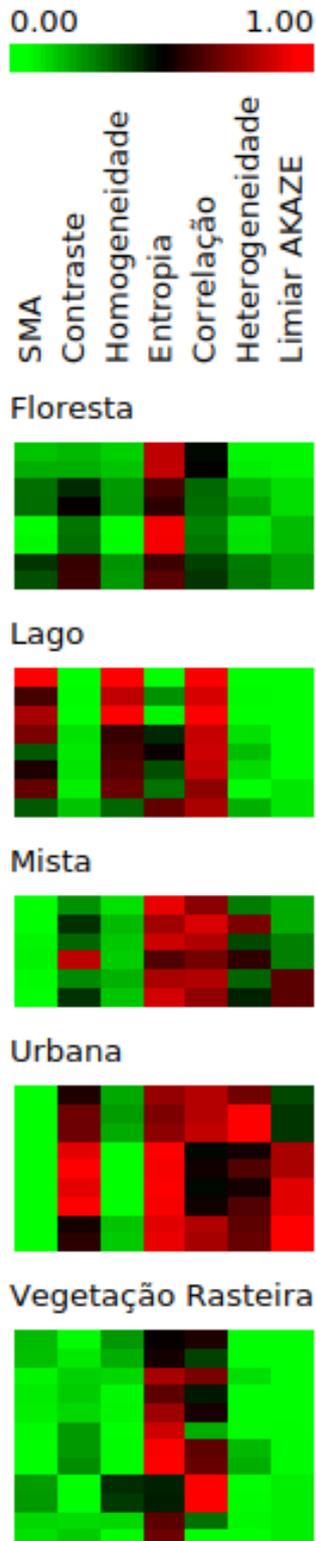
de interesse.

### 5.3 Quantificação da imagem

Com os parâmetros adequados encontrados pelo AG, o passo seguinte é analisar, como o sistema autoconfigurado identifica para cada tipo de informação extraída da imagem qual parâmetro é mais adequado utilizar. Para fazer essa separabilidade dos tipos de informações das imagens, são utilizadas medidas estatísticas, onde é feita uma análise para verificar quais medidas são mais relevantes para conseguir separar as imagens em diferentes tipos de acordo com o parâmetro configurado pelo Algoritmo Genético, com isso tem-se uma tabela, contendo para cada informação extraída da imagem, definida pelas medidas estatísticas, qual parâmetro utilizar, definido pelo Algoritmo Genético.

Para a quantificação e separabilidade das imagens, foram extraídas propriedades estatísticas das imagens, energia, entropia, contraste, variância, correlação e a homogeneidade. Além do parâmetro de limiar do método AKAZE, que se demonstrou mais adequado para aplicação mostrada na seção 5.2, pois comparado com os outros métodos, na média teve uma taxa de acerto maior e um erro menor em diferentes coberturas de solo e nas atitudes da aeronave. Na Figura 5.14 é ilustrado o mapa de intensidades de valores de cada uma das medidas estatísticas e o limiar do AKAZE, separado pelos tipos de cobertura de solo de região de floresta, vegetação rasteira, lago, urbana e mista com rural e urbana. Os valores para o mapa de intensidades foram normalizados entre 0 e 1, onde o 0 é o valor mínimo, representado pela cor verde e 1 é o valor máximo, representado pela cor vermelha, e a cor preta representa o valor médio entre os 2.

Figura 5.14 - Mapa de intensidades das medidas estatísticas e o limiar.



Atributos normalizados entre 0 e 1 e mapa dividido por tipos de cobertura de solo, onde as linhas representam cada resultado da imagem de teste e as colunas os valores de cada atributo.

Fonte: Produção do autor.

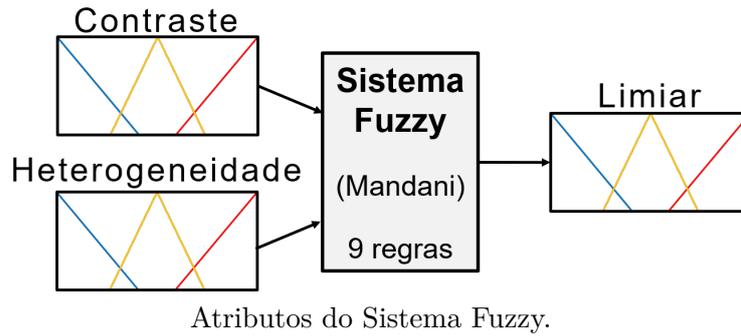
Foram selecionadas empiricamente 2 propriedades estatísticas: o contraste, que indica o espalhamento da textura na imagem; e a heterogeneidade, que indica a variância da textura na imagem. Essas medidas foram escolhidas, pois podem representar as características das imagens e dividi-las em cenários. Por exemplo, na região de vegetação rasteira, a imagens possui menos detalhes quando comparada com a região urbana, por isso o contraste, a heterogeneidade e o limiar no mapa de calor da Figura 5.14 estão com valores baixos, representado pela cor verde, enquanto que na região urbana estão com valores altos, representado pela cor vermelha.

No mapa de calor é possível visualizar a relação entre o limiar e essas 2 medidas estatísticas, se os valores estão baixo, médio ou alto, neste trabalho, essa relação entre medidas estatísticas e parâmetros, emprega-se um algoritmo para selecionar automaticamente os parâmetros adequados de acordo com a imagem de entrada, para isso, neste trabalho faz uso de lógica Fuzzy, pois como é observado na Figura 5.14 não existem apenas 3 cores, verde, preto e vermelho, existem variações entre eles, como o verde claro e verde escuro, pois os valores não são exatos, para se usar lógica booleana, como 0 e 1, é necessário fazer uso de um lógica multivalorada, na qual os valores variam entre 0 e 1. Além disso, com uma pequena quantidade de dados configurados pelo AG é possível montar as regras do Fuzzy para um sistema especialista, usando essa relação entre medidas estatísticas e o parâmetro de limiar do AKAZE.

#### 5.4 Sistema autoconfigurado

Para desenvolvimento do sistema autoconfigurado, pode-se fazer uso da lógica nebulosa, para selecionar automaticamente o parâmetro do método de pontos de interesse de acordo com as medidas de texturas, com uso da biblioteca FuzzyLite. A configuração da lógica nebulosa, é feita com variáveis de entrada e saída, ilustrada na Figura 5.15. As variáveis de entrada são as medidas de textura contraste e heterogeneidade. A variável de saída é o parâmetro de limiar, pois é o atributo do método de Ponto de Interesse de maior relevância (ROOS, 2018). Em seguida é testado o método AKAZE, que demonstrou um desempenho melhor nos teste da seção 5.2, pois comparado com os outros métodos, na média teve uma taxa de acerto maior e um erro menor em diferentes coberturas de solo e nas atitudes da aeronave.

Figura 5.15 - Lógica Nebulosa do sistema autoconfigurado.



Fonte: Produção do autor.

Para a configuração das variáveis de entrada e saída e das regras de inferência, foram feitas empiricamente, onde a configuração das variáveis de entrada foi feita da seguinte maneira:

- Contraste: 40 à 1300;
- Heterogeneidade: 250 à 4700;

A variável de saída, o limiar, é configurada com os parâmetros mais utilizados na literatura (MARRO et al., 2010), onde teve a seguinte configuração:

- Inferência Fuzzy: Mamdani;
- Intervalo: 0,0001 à 0,01;
- Agregação: Soma normalizada;
- Defuzzificação: Centro de área;
- Função de Pertinência: Triangular.

As regras de inferência foram definidas de acordo com uma análise prévia de todo o conjunto de imagens, dividido em termos linguísticos: "baixo"; "médio"; e "alto", apresentados na Tabela 5.11.

Tabela 5.11 - Regras de inferência.

	<b>Se</b>	<b>Então</b>
<b>Contraste</b>	<b>Heterogeneidade</b>	<b>Limiar</b>
Baixo	Baixo	Baixo
Baixo	Médio	Médio
Baixo	Alto	Médio
Médio	Baixo	Baixo
Médio	Médio	Médio
Médio	Alto	Alto
Alto	Baixo	Médio
Alto	Médio	Médio
Alto	Alto	Alto

Os resultados do sistema autoconfigurado, são comparados em 3 cenários de parâmetros configurados no sistema: "Fuzzy" é o sistema autoconfigurado que seleciona o parâmetro de acordo com a textura da imagem; "padrão" é o que o sistema faz uso do parâmetro do AKAZE padrão da biblioteca; e o "manual" é o que o sistema faz uso de um valor baixo de limiar, configurado manualmente, a fim de buscar melhor precisão, pois quanto menor o limiar do AKAZE, maior o número de pontos detectados. Os experimentos seguintes fazem uso de todo o conjunto de imagens, onde o voo resultou em 868 imagens. Na Tabela 5.12, são apresentadas as comparações da média e desvio padrão, em segundos, dos processamentos de execução da metodologia, desconsiderando a parte da aquisição da imagem, e sua respectiva taxa de acerto, que é calculada através da relação entre a quantidade de imagens que o algoritmo encontra a matriz de homografia pela quantidade de imagens totais.

Tabela 5.12 - Comparação do tempo de processamento e taxa de acerto respectivos ao *Dataset*.

<b>Parâmetros</b>	<b>Tempo (s)</b>	<b>Taxa de Acerto (%)</b>
Fuzzy	0,11 ± 0,06	95,4
Padrão	0,10 ± 0,05	68,4
Manual	0,25 ± 0,04	98,5

Pode-se observar na Tabela 5.12 que o uso do Fuzzy para configurar o parâmetro de limiar apresentou melhora na taxa de acerto em aproximadamente 30% em relação aos parâmetros padrões e manteve o tempo computacional. Comparado com um

valor de limiar manual, o Fuzzy foi aproximadamente 2 vezes menos custoso e com uma perda na taxa de acerto de aproximadamente 3%. Para execução da extração de textura da imagem, empregada pelo Fuzzy o tempo de processamento é de  $0,022 \pm 0,003$  segundos. Ressalta-se que o tempo tem relevância para que, em trabalhos futuros, seja executado em hardware embarcado.

Na Tabela 5.13, é apresentada a comparação da quantidade de pontos de interesse, a quantidade de casamentos e a quantidade de *inliers*, essa quantidade tem a importância de ver a relação do número de pontos pelo tempo, apresentada na Tabela 5.12.

Tabela 5.13 - Comparação quantidade dos pontos de interesse.

<b>Método</b>	<b>Qtd. Pontos</b>	<b>Qtd. Casamentos</b>	<b>Qtd. Inliers</b>
Fuzzy	$181 \pm 137$	$27 \pm 25$	$28 \pm 18$
Padrão	$390 \pm 414$	$105 \pm 147$	$95 \pm 138$
Manual	$3199 \pm 432$	$665 \pm 535$	$553 \pm 518$

Pode-se observar na Tabela 5.13, que com uso do Fuzzy, o sistema é mais estável em relação ao parâmetro padrão e ao configurado manualmente, pois a variação de *inliers* é menor. Além disso, a quantidade de *inliers* encontrada com o Fuzzy também é menor.

## 5.5 Sistema de Odometria Visual

Após o sistema autoconfigurado com Fuzzy, gerar os *inliers*, no passo seguinte tem-se calculado a odometria visual, para estimar a posição da aeronave.

A odometria visual pode ser auxiliada com uso de medidas extraídas dos sensores da aeronave, neste trabalho faz uso de informação de altitude e o *Yaw*. Com a informação da altitude, pode-se obter a informação de altura de voo. Com a informação do *Yaw*, tem-se a direção da aeronave. Além das informações dos sensores, faz-se uso de informações da câmera, ângulos de abertura do sensor óptico, que tem a importância para determinar o tamanho do *pixel*.

Para avaliar a odometria visual, o sistema é dividido em com conjunto de 6 imagens sequenciais para cada região, considerando: urbana; vegetação rasteira; vegetação densa; vegetação mista; vegetação e lago; vegetação e urbana.

### 5.5.1 Região urbana

O conjunto de imagens para a região urbana são apresentadas na Figura 5.16.

Figura 5.16 - Conjunto de imagens com região urbana.



Conjunto de imagens sequenciais com região urbana.

Fonte: Roberto (2017).

A partir de uma posição inicial conhecida, neste caso  $-23.246034, -45.880100$ , na Tabela 5.14 são apresentadas as posições seguintes obtidas pelo GPS e as posições estimadas pelo algoritmo, onde calcula-se a distância em metros (m) entre cada posição da imagem, com uso do GPS e a estimada pelo algoritmo e calcula-se o erro em metros (m) da posição estimada em relação ao GPS e a relação (%) do erro da posição estimada pela distância percorrida desde o posição inicial.

Tabela 5.14 - Odometria visual em região urbana.

Posição (latitude, longitude)		Distância (m)		Erro	
GPS	Estimada	GPS	Estimada	(m)	(%)
-23.244864,-45.881180	-23.244964,-45.881184	170	162	11	6
-23.243710,-45.882263	-23.244049,-45.882155	169	142	39	12
-23.242571,-45.883344	-23.243111,-45.883116	168	143	64	13
-23.241447,-45.884419	-23.242204,-45.884079	166	141	91	14
-23.240344,-45.885481	-23.241262,-45.885096	164	148	109	13

Pode-se observar na Tabela 5.14 que o erro da posição é maior que a diferença entre as distâncias do GPS e a estimada, pois a posição leva em consideração o *Yaw* da aeronave, ou seja a rotação da imagem, e não a penas a translação do eixo  $x$  e  $y$ .

Durante o percurso, a aeronave se deslocou 837 metros e teve os erros de deriva entre 6% à 14%, onde pode-se avaliar dependendo da aplicação, como amenizar o erro. Figura 5.17 é apresentada o percurso a partir da posição inicial das posições obtidas pelo GPS e das posições estimadas pelo algoritmo, onde as linhas representam a trajetória e os marcadores em cima da trajetória, representam as posições obtidas para cada imagem, essas representações foram divididas em 2 cores, a amarela o GPS e a vermelha a estimada.

Figura 5.17 - Estimação de posição em imagem de região urbana.



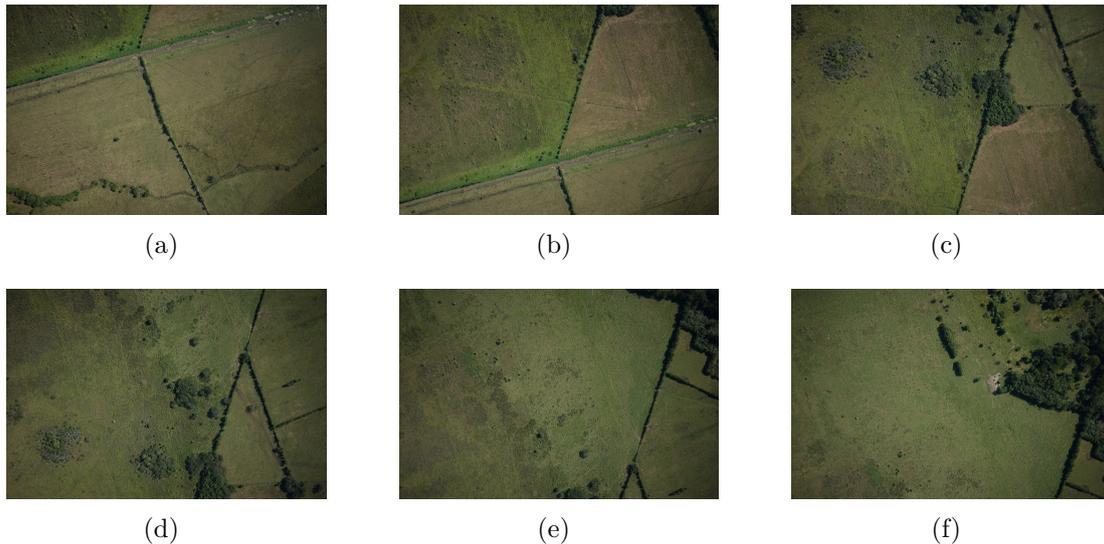
O marcador verde indica a posição inicial do GPS, os marcadores e a linha amarela indicam a posição real do GPS e os marcadores e a linha vermelha indicam a posição estimada do algoritmo.

Fonte: Produção do autor.

### 5.5.2 Região de vegetação rasteira

O conjunto de imagens para a região de vegetação rasteira são apresentadas na Figura 5.18.

Figura 5.18 - Conjunto de imagens com região de vegetação rasteira.



Conjunto de imagens sequenciais com vegetação rasteira.

Fonte: Roberto (2017).

A partir de uma posição inicial  $-23.205518, -45.922863$ , na Tabela 5.15, são apresentadas as posições seguintes obtidas pelo GPS e as posições estimadas.

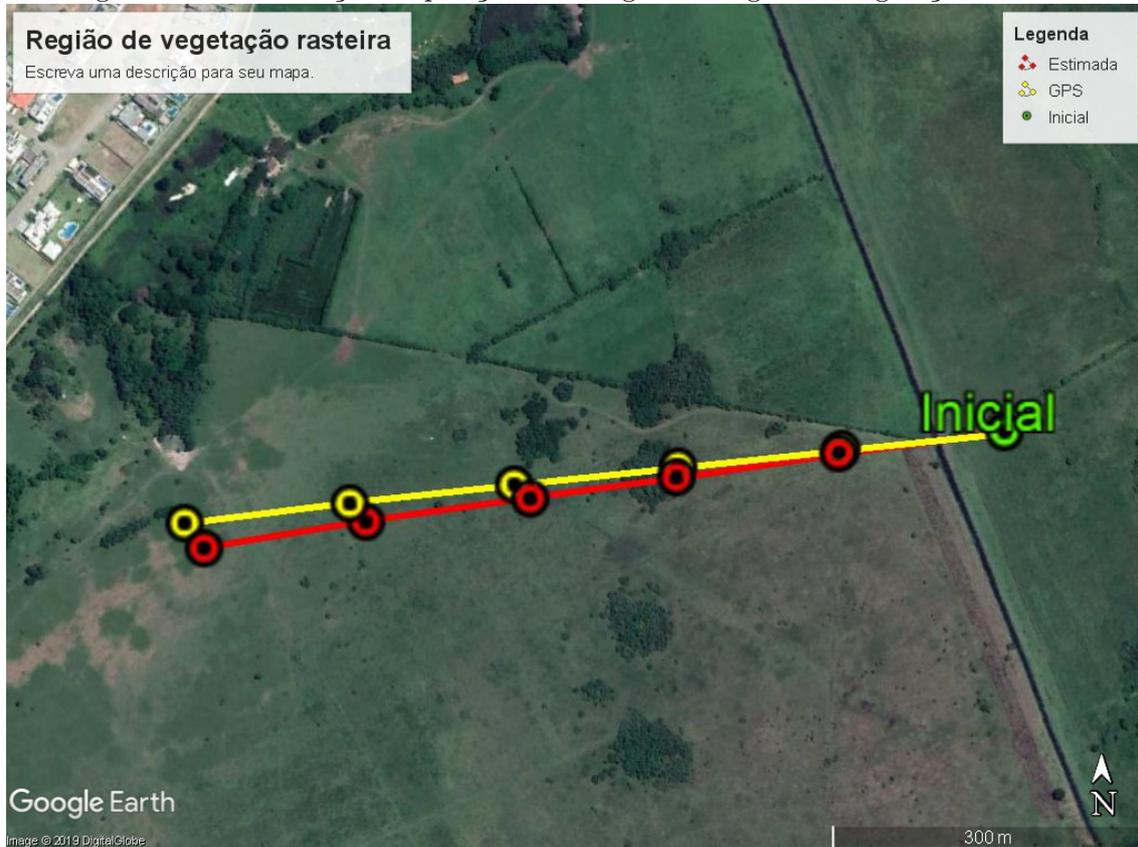
Tabela 5.15 - Odometria visual em região de vegetação rasteira.

Posição (latitude, longitude)		Distância (m)		Erro	
GPS	Estimada	GPS	Estimada	(m)	(%)
-23.205667,-45.924401	-23.205704,-45.924429	157,9	161,2	5,0	3,2
-23.205819,-45.92594	-23.205912,-45.925956	158,1	157,6	10,5	3,3
-23.205976,-45.927482	-23.206098,-45.927332	158,4	142,0	20,4	4,3
-23.20614,-45.929031	-23.206302,-45.928879	159,2	159,6	23,8	3,8
-23.206313,-45.930585	-23.206532,-45.930403	159,9	157,8	30,7	3,9

No percurso apresentado na Figura 5.15, a aeronave se deslocou 793,5 metros e teve

os erros de deriva entre 3,2% e 4,3%. Na Figura 5.19 são apresentadas as comparações dos percursos.

Figura 5.19 - Estimação de posição em imagem de região de vegetação rasteira.



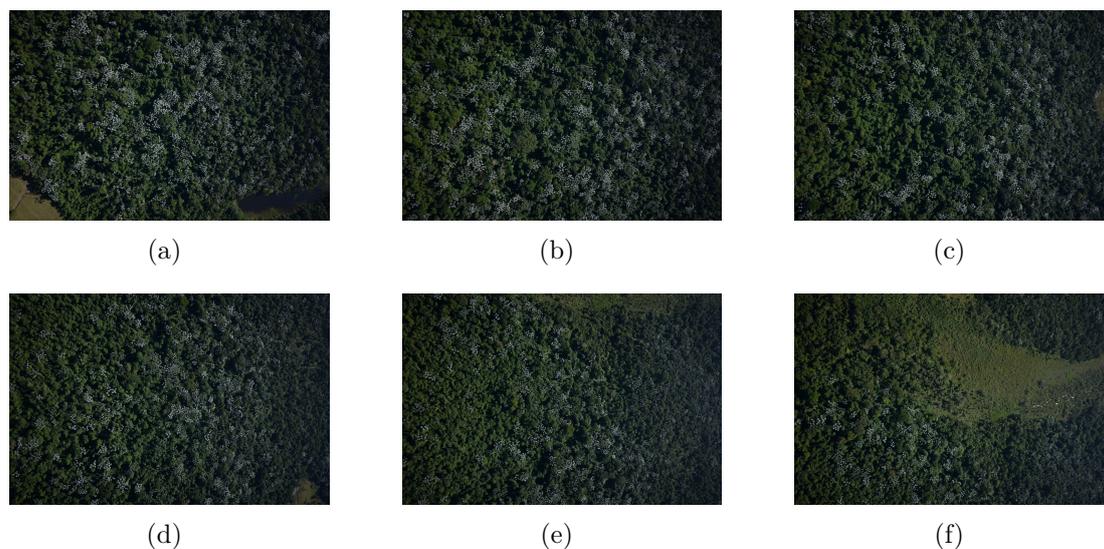
O marcador verde indica a posição inicial do GPS, os marcadores e a linha amarela indicam a posição real do GPS e os marcadores e a linha vermelha indicam a posição estimada do algoritmo.

Fonte: Produção do autor.

### 5.5.3 Região de vegetação densa

O conjunto de imagens para a região de vegetação densa são apresentadas na Figura 5.20.

Figura 5.20 - Conjunto de imagens com região de vegetação densa.



Conjunto de imagens sequenciais com vegetação densa.

Fonte: Roberto (2017).

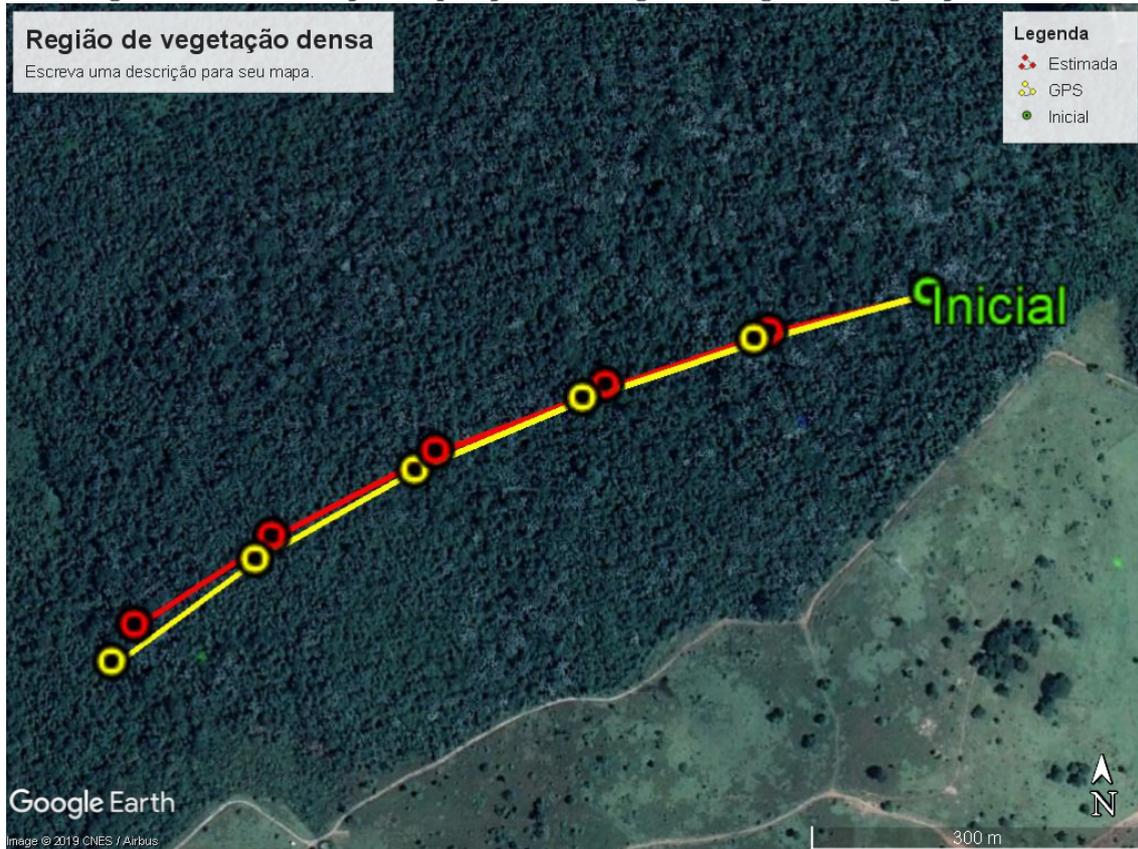
A partir de uma posição inicial -23.210968,-45.971200, na Tabela 5.16, são apresentadas as posições seguintes obtida pelo GPS e as posições estimadas.

Tabela 5.16 - Odometria visual em região de vegetação densa.

Posição (latitude, longitude)		Distância (m)		Erro	
GPS	Estimada	GPS	Estimada	(m)	(%)
-23.211349,-45.972719	-23.211293,-45.972587	160,7	146,1	14,8	9,2
-23.211824,-45.97421	-23.211718,-45.97401	161,2	152,8	23,5	7,3
-23.212405,-45.97566	-23.212252,-45.975483	161,6	161,7	24,8	5,1
-23.213118,-45.977041	-23.212932,-45.976898	161,7	163,0	25,4	3,9
-23.213955,-45.978339	-23.213652,-45.978132	162,0	149,3	39,8	4,9

Na Tabela 5.16 é apresentado o percurso, onde a aeronave se deslocou 807,1 metros e teve os erros de deriva entre 3,9% e 9,2%. Na Figura 5.21 são apresentadas as comparações dos percursos.

Figura 5.21 - Estimação de posição em imagem de região de vegetação densa.



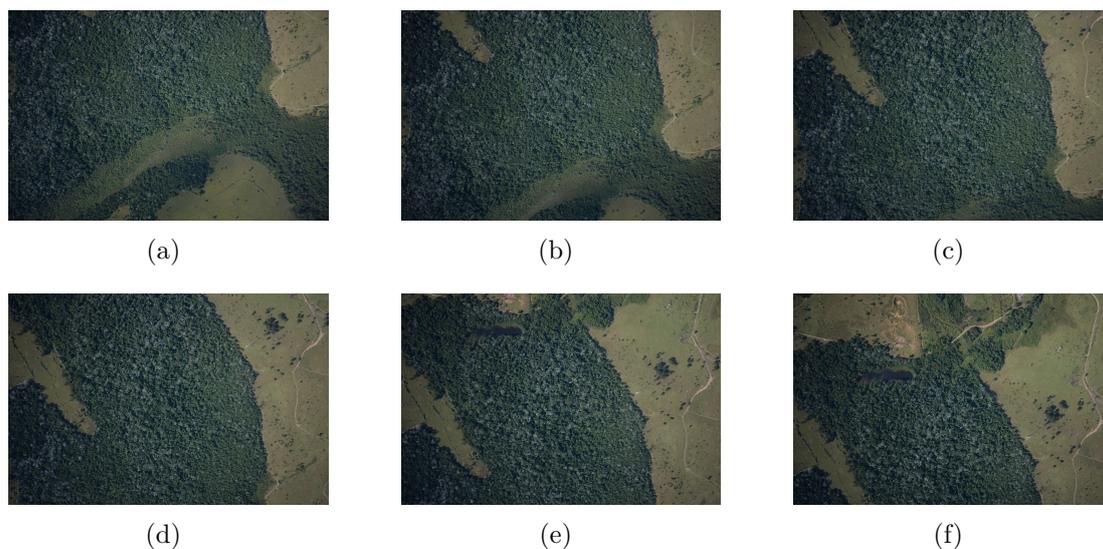
O marcador verde indica a posição inicial do GPS, os marcadores e a linha amarela indicam a posição real do GPS e os marcadores e a linha vermelha indicam a posição estimada do algoritmo.

Fonte: Produção do autor.

#### 5.5.4 Região de vegetação mista

O conjunto de imagens para a região de vegetação mista é formado por regiões que contêm vegetação rasteira e densa, as imagens são apresentadas na Figura 5.22.

Figura 5.22 - Conjunto de imagens com região de vegetação mista.



Conjunto de imagens sequenciais com vegetação mista.

Fonte: Roberto (2017).

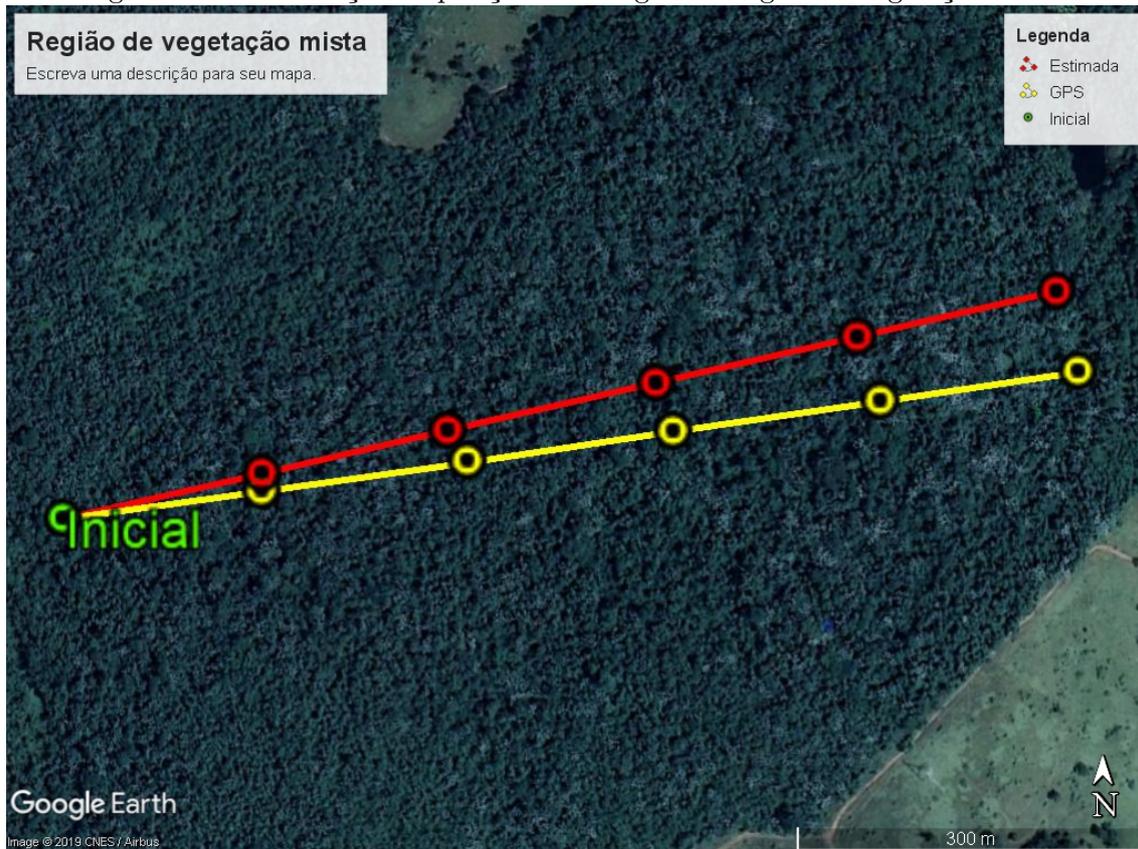
A partir de uma posição inicial -23.211207, -45.978620, na Tabela 5.17, são apresentadas as posições seguintes obtida pelo GPS e as posições estimadas.

Tabela 5.17 - Odometria visual em região de vegetação mista.

Posição (latitude, longitude)		Distância (m)		Erro	
GPS	Estimada	GPS	Estimada	(m)	(%)
-23.210988,-45.976938	-23.210857,-45.976935	173,6	176,5	14,5	8,4
-23.210763,-45.975257	-23.210533,-45.975417	173,4	159,2	30,3	8,7
-23.210538,-45.973577	-23.210175,-45.973718	173,4	178,1	42,8	8,2
-23.21031,-45.971898	-23.20983,-45.972083	173,4	171,3	56,6	8,2
-23.210079,-45.97022	-23.209469,-45.970403	173,3	176,2	70,3	8,1

No percurso apresentado na Tabela 5.17, a aeronave se deslocou 867 metros e teve os erros de deriva entre 8,1% e 8,7%. Na Figura 5.23 são apresentadas as comparações dos percursos.

Figura 5.23 - Estimação de posição em imagem de região de vegetação mista.



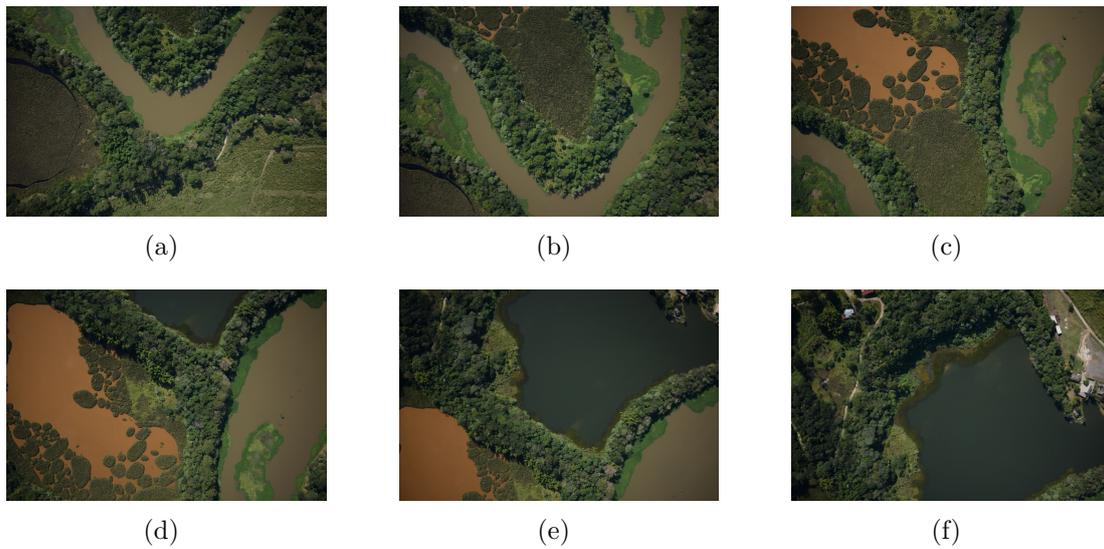
O marcador verde indica a posição inicial do GPS, os marcadores e a linha amarela indicam a posição real do GPS e os marcadores e a linha vermelha indicam a posição estimada do algoritmo.

Fonte: Produção do autor.

### 5.5.5 Região de vegetação e lago

O conjunto de imagens para a região de vegetação e lago são apresentadas na Figura 5.24.

Figura 5.24 - Conjunto de imagens com região de vegetação e lago.



Conjunto de imagens sequenciais com vegetação e lago.

Fonte: Roberto (2017).

A partir de uma posição inicial -23.221312,-45.955552, na Tabela 5.18, são apresentadas as posições seguintes obtida pelo GPS e as posições estimadas.

Tabela 5.18 - Odometria visual em região de vegetação e lago.

Posição (latitude, longitude)		Distância (m)		Erro	
GPS	Estimada	GPS	Estimada	(m)	(%)
-23.219888,-45.955742	-23.219911,-45.95581	159,5	157,9	7,4	4,6
-23.218463,-45.955926	-23.21851,-45.956053	159,5	157,7	14,0	4,4
-23.217036,-45.956105	-23.217232,-45.956269	159,6	143,7	27,4	5,7
-23.215605,-45.956279	-23.215857,-45.956496	160,0	154,6	35,7	5,6
-23.214167,-45.956452	-23.21448,-45.956734	160,8	154,9	45,2	5,6

Assim como no experimento anterior, no percurso apresentado na Tabela 5.18, a aeronave se deslocou 799,2 metros e teve os erros de deriva entre 4,4% e 5,7%. Na Figura 5.25 são apresentadas as comparações dos percursos.

Figura 5.25 - Estimação de posição em imagem de região de vegetação e lago.



O marcador verde indica a posição inicial do GPS, os marcadores e a linha amarela indicam a posição real do GPS e os marcadores e a linha vermelha indicam a posição estimada do algoritmo.

Fonte: Produção do autor.

### 5.5.6 Região de vegetação e urbana

O conjunto de imagens para a região de vegetação e urbana são apresentadas na Figura 5.26.

Figura 5.26 - Conjunto de imagens com região de vegetação e urbana.



Conjunto de imagens sequenciais com vegetação e urbana.

Fonte: Roberto (2017).

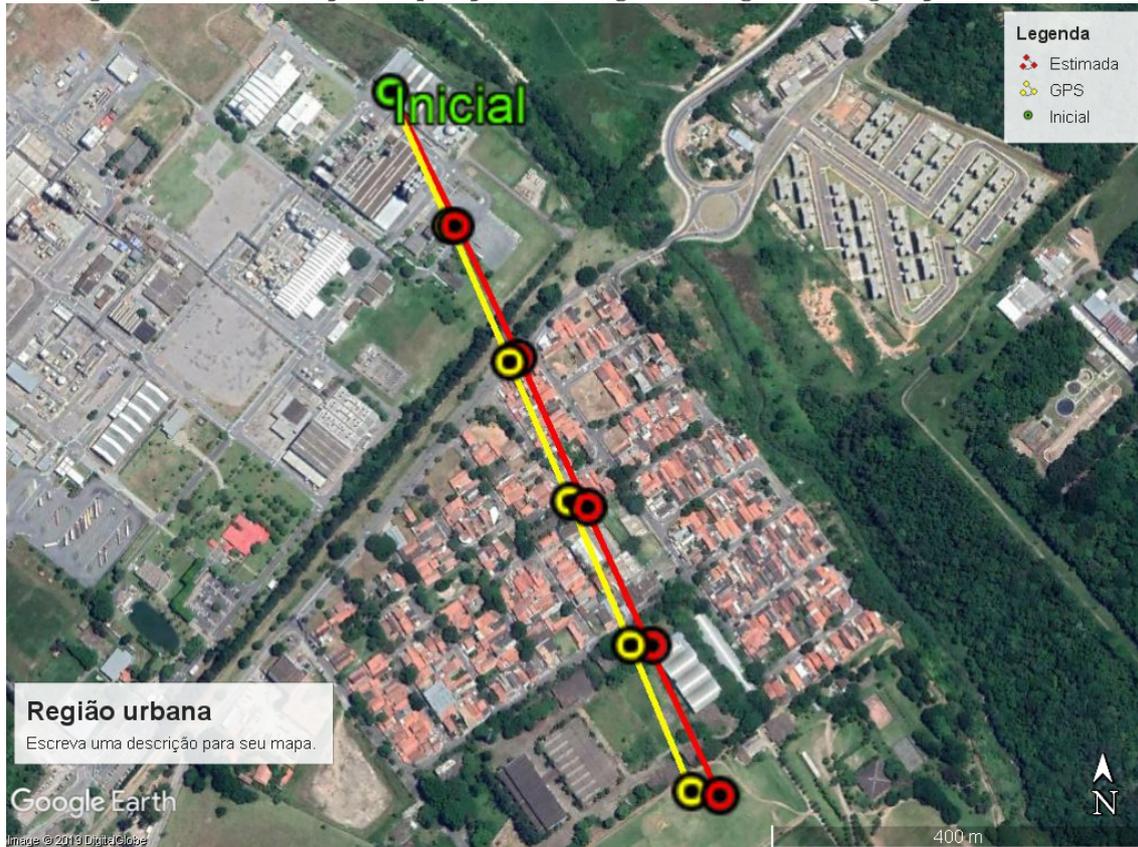
A partir de uma posição inicial  $-23.236562, -45.935421$ , na Tabela 5.19, são apresentadas as posições seguintes obtida pelo GPS e as posições estimadas.

Tabela 5.19 - Odometria visual em região de vegetação e urbana.

Posição (latitude, longitude)		Distância (m)		Erro	
GPS	Estimada	GPS	Estimada	(m)	(%)
-23.237921,-45.934768	-23.237922,-45.934706	165,0	167,8	6,3	3,8
-23.239285,-45.93412	-23.239243,-45.934027	165,4	162,3	10,6	3,2
-23.240657,-45.93348	-23.240714,-45.933285	165,9	180,1	20,8	4,2
-23.242035,-45.932846	-23.24204,-45.932621	166,2	162,2	23,0	3,5
-23.24342,-45.932222	-23.24346,-45.931928	166,6	173,0	30,4	3,7

Na Tabela 5.19 é apresentado o percurso, onde a aeronave se deslocou 829 metros e teve os erros de deriva entre 3,2% e 4,2%. Na Figura 5.27 são apresentadas as comparações dos percursos.

Figura 5.27 - Estimação de posição em imagem de região de vegetação e urbana.



O marcador verde indica a posição inicial do GPS, os marcadores e a linha amarela indicam a posição real do GPS e os marcadores e a linha vermelha indicam a posição estimada do algoritmo.

Fonte: Produção do autor.

## 6 CONCLUSÕES

Neste trabalho, foi apresentada uma abordagem para a navegação aérea autônoma, para auxílio ao INS, com uso de imagens capturas por uma aeronave. As imagens capturadas durante o voo podem sofrer variações frequentes de suas características, afetando o desempenho de algoritmos que possam ser aplicados para a navegação, como na odometria visual.

Nesta dissertação, empregou-se ferramentas de visão computacional e inteligência computacional para a navegação autônoma de VANT por meio de odometria visual, com uso de métodos de pontos de interesse, medidas estatísticas, algoritmo genético e lógica nebulosa, para desenvolvimento de um modelo que se configure automaticamente de acordo com características extraídas de imagens capturadas.

As principais contribuições do trabalho foram o uso do algoritmo genético para selecionar os sub-ótimos parâmetros dos métodos de pontos de interesse ORB, BRISK, FREAK, AKAZE e LACH. Na maioria dos casos, o AKAZE teve uma melhor relação de desempenho. A análise de medidas estatísticas, onde o contraste e heterogeneidade, juntamente com o valor de limiar do AKAZE apresentaram melhor separação. O uso de lógica nebulosa para configurar automaticamente o parâmetro de limiar do AKAZE através do contraste e a heterogeneidade extraídas imagem capturada pela aeronave, teve uma melhora na taxa de acerto em aproximadamente 30% em relação aos parâmetros padrões e manteve o tempo computacional. A estimação de posição da aeronave, através da odometria visual com uso do parâmetro obtido pelo fuzzy aplicada em diversas coberturas de solo como, regiões urbana, lago, vegetação rasteira, densa e mista, onde em praticamente todos os casos o erro da posição é inferior a 10% da distancia percorrida.

Os resultados obtidos mostram-se promissores, com a melhora da correspondência de imagens, quando configurado para se alterar o parâmetro conforme as características da imagem. A quantidade de *inliers* é mais estável quando comparada com o parâmetro padrão ou configurado manualmente e pode-se resultar em 2 ganhos:

- Diminuição do tempo de processamento, pois quando gerado muitos pontos, o tempo pode tornar inviável para processamento em tempo real;
- Diminuição de falhas do algoritmo para a estimação de posição da aeronave, pois uma quantidade de pontos inferior ao mínimo necessário, não é possível executar o algoritmo de odometria

Para continuidade do trabalho realizado, sugere-se outras linhas de pesquisa para trabalhos futuros, apresentadas a seguir:

- Outros tipos de dados da aeronave podem ser considerados para uso na meta-heurística e para o método de otimização, como os dados de altitude, *yaw*, *roll*, *pitch*;
- Outros tipos de sensores de imageamento podem ser testados na metodologia, como imagens em infra-vermelho e LIDAR;
- Outros tipos de meta-heurísticas podem ser aplicados e comparadas com o algoritmo genético, variações do AG, como AG com epidemia, filtro de partículas, algoritmos bio-inspirados e Simulated Annealing;
- Outras configurações do Fuzzy podem ser testadas e comparadas, como o fuzzificador, regras de inferência e defuzzificador;
- Testar meta-heurística para configuração automática das propriedades do Fuzzy, como o algoritmo de colisão de múltiplas partículas;
- Fusão de técnicas para estimar a posição, visando a robustez do algoritmo;
- Estudar e aplicar técnicas de processamento de alto desempenho no algoritmo, visando o processamento em tempo real;
- Embarcar o algoritmo proposto em um VANT, para validação da metodologia em tempo real.

No desenvolvimento do trabalho, gerou-se 3 publicações, um resumo no Conference of Computational Interdisciplinary Science ([REBOUÇAS et al., 2016](#)), um artigo completo no XV Encontro Nacional de Inteligência Artificial e Computacional ([REBOUÇAS et al., 2018](#)) e um artigo completo no XIX Simpósio Brasileiro de Sensoriamento Remoto ([REBOUÇAS et al., 2019](#)).

## REFERÊNCIAS BIBLIOGRÁFICAS

ABADE, A.; CAMPOS, M. D. de; PORTO, L. F.; COELHO, Y. de F.; SOUSA, Y. de M.; NESPOLO, J. P. A construção otimizada de um drone para aplicações na agricultura e pecuária de precisão. In: ANAIS DA ESCOLA REGIONAL DE INFORMÁTICA DA SOCIEDADE BRASILEIRA DE COMPUTAÇÃO, 7., 2016. **Anais...** Mato Grosso, 2016. 1

ALAHY, A.; ORTIZ, R.; VANDERGHEYNST, P. Freak: ast retina keypoint. In: CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR), 2012. **Proceedings...** IEEE, 2012. p. 510–517. 2, 20, 32, 44

ALCANTARILLA, P. F.; BARTOLI, A.; DAVISON, A. J. Kaze features. In: EUROPEAN CONFERENCE ON COMPUTER VISION, 2012. **Proceedings...** Springer, 2012. p. 214–227. 20, 21

ALCANTARILLA, P. F.; NUEVO, J.; BARTOLI, A. Fast explicit diffusion for accelerated features in nonlinear scale spaces. In: BRITISH MACHINE VISION CONFERENCE (BMVC), 2013. **Proceedings...** Bristol, UK, 2013. 2, 21, 22, 32, 44

ALCANTARILLA, P. F.; STENGER, B. How many bits do i need for matching local binary descriptors? In: INTERNATIONAL CONFERENCE ON ROBOTICS AND AUTOMATION (ICRA), 2016. **Proceedings...** IEEE, 2016. p. 2190–2197. 5

BARALDI, A.; PARMIGGIANI, F. An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, n. 2, p. 293–304, 1995. 11

BAY, H.; TUYTELAARS, T.; GOOL, L. V. Surf: speeded up robust features. In: EUROPEAN CONFERENCE ON COMPUTER VISION (ECCV), 2006. **Proceedings...** Springer, 2006. p. 404–417. 2, 16, 17, 32

BRADSKI, G.; KAEHLER, A. **Learning opencv: computer vision with the opencv library**. [S.l.]: "O'Reilly Media", 2008. 50, 53

BRAGA, J. R.; VELHO, H. F.; CONTE, G.; DOHERTY, P.; SHIGUEMORI, É. H. An image matching system for autonomous uav navigation based on neural network. In: INTERNATIONAL CONFERENCE ON CONTROL,

AUTOMATION, ROBOTICS AND VISION (ICARCV), 14., 2016.

**Proceedings...** IEEE, 2016. p. 1–6. 1, 2

BRAGA, J. R. G. **Navegação autônoma de VANT por imagens lidar**. Tese (Doutorado em Computação Aplicada) — Instituto Nacional de Pesquisas Espaciais - INPE, São José dos Campos, 2019. 1, 2, 7, 9, 24, 43

BRAGA, J. R. G.; SHIGUEMORI, E. H.; VELHO, H. F. de C. Odometria visual para a navegação autônoma de vant. **Revista Cereus**, v. 11, n. 1, p. 184–194, 2019. 2, 7

CALONDER, M.; LEPETIT, V.; STRECHA, C.; FUA, P. Brief: binary robust independent elementary features. In: EUROPEAN CONFERENCE ON COMPUTER VISION (ECCV), 2010. **Proceedings...** Springer, 2010. p. 778–792. 2, 17, 18, 32

CANHOTO, A.; SHIGUEMORI, E. H.; DOMICIANO, M. A. P. Image sequence processing applied to autonomous aerial navigation. In: INTERNATIONAL CONFERENCE ON SIGNAL AND IMAGE PROCESSING APPLICATIONS, 2009. **Proceedings...** IEEE, 2009. p. 496–499. 1

CHUNHUI, Z.; RONGZHI, W.; TIANWU, Z.; QUAN, P. Visual odometry and scene matching integrated navigation system in uav. In: INTERNATIONAL CONFERENCE ON INFORMATION FUSION, 17., 2014. **Proceedings...** IEEE, 2014. p. 1–6. 1, 9

FARIA, L. d. A.; SILVESTRE, C. A. d. M.; CORREIA, M. A. F. Gps-dependent systems: vulnerabilities to electromagnetic attacks. **Journal of Aerospace Technology and Management**, v. 8, n. 4, p. 423–430, 2016. 4

FISCHLER, M. A.; BOLLES, R. C. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography. **Communications of the ACM**, v. 24, n. 6, p. 381–395, 1981. 2, 33

FORÇA AÉREA BRASILEIRA. **Saiba mais sobre voo de "drones"**. 2015. Disponível em: <<http://www.fab.mil.br/noticias/mostra/21519/>>. Acesso em: 28 abr. 2017. 1

FRAUNDORFER, F.; SCARAMUZZA, D. Visual odometry: Part ii: matching, robustness, optimization, and applications. **IEEE Robotics & Automation Magazine**, v. 19, n. 2, p. 78–90, 2012. 2, 43

GALINDO, J. C. F. **Estudo de métodos de extração de características aplicados ao problema da estimação da posição de um VANT em navegação autônoma com visão computacional**. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Federal de Minas Gerais, Belo Horizonte, Minas Gerais, 2016. 2, 9

GONZALEZ, R. C.; WOODS, R. C. **Processamento digital de imagens**. [S.l.]: Pearson Educación, 2009. 11

HALL-BEYER, M. Glm texture: a tutorial. 2017. Disponível em: <[https://www.researchgate.net/publication/315776784\\_GLCM\\_Texture\\_A\\_Tutorial\\_v\\_30\\_March\\_2017](https://www.researchgate.net/publication/315776784_GLCM_Texture_A_Tutorial_v_30_March_2017)>. 11, 12

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on systems, man, and cybernetics**, n. 6, p. 610–621, 1973. 11

HOLLAND, J. H. **Adaptation in natural and artificial systems. An introductory analysis with application to biology, control, and artificial intelligence**. Ann Arbor, MI: University of Michigan Press, 1975. 439–444 p. 24

HOSEN, J.; HELGESEN, H. H.; FUSINI, L.; FOSSEN, T. I.; JOHANSEN, T. A vision-aided nonlinear observer for fixed-wing uav navigation. In: AIAA GUIDANCE, NAVIGATION, AND CONTROL CONFERENCE, 2016. **Proceedings...** [S.l.], 2016. p. 2091. 2, 9

JAVAID, A. Y.; JAHAN, F.; SUN, W. Analysis of global positioning system-based attacks and a novel global positioning system spoofing detection/mitigation algorithm for unmanned aerial vehicle simulation. **Simulation**, v. 93, n. 5, p. 427–441, 2017. 2

JIN, Z.; WANG, X.; MORAN, W.; PAN, Q.; ZHAO, C. Efficient scene matching using salient regions under spatial constraints. In: INTERNATIONAL CONFERENCE ON INFORMATION FUSION, 17., 2014. **Proceedings...** IEEE, 2014. p. 1–8. 2

KINTNER, P.; HUMPHREYS, T.; HINKS, J. Gns and ionospheric scintillation. **Inside GNSS**, v. 4, n. 4, p. 22–30, 2009. 3

LEUTENEGGER, S.; CHLI, M.; SIEGWART, R. Y. Brisk: binary robust invariant scalable keypoints. In: INTERNATIONAL CONFERENCE ON COMPUTER VISION (ICCV), 2011. **Proceedings...** IEEE, 2011. p. 2548–2555. 2, 18, 19, 32, 44

- LEVI, G.; HASSNER, T. **LATCH: learned arrangements of three patch codes**. 2016. Disponível em: <<https://talhassner.github.io/home/projects/LATCH/LATCH.pdf>>. 2, 22, 23, 32, 44
- LI, Y.; WANG, S.; TIAN, Q.; DING, X. A survey of recent advances in visual feature detection. **Neurocomputing**, v. 149, p. 736–751, 2015. 14
- LIU, X.; GUO, B.; MENG, C. A method of simultaneous location and mapping based on rgb-d cameras. In: INTERNATIONAL CONFERENCE ON CONTROL, AUTOMATION, ROBOTICS AND VISION (ICARCV), 14., 2016. **Proceedings...** IEEE, 2016. p. 1–5. 2
- LOPES, H. S.; RODRIGUES, L. C. d. A.; STEINER, M. T. A. In: **Meta-heurísticas em pesquisa operacional**. Curitiba: Omnipax, 2013. p. 219–236. 25
- LOWE, D. G. Distinctive image features from scale-invariant keypoints. **International Journal of Computer Vision**, v. 60, n. 2, p. 91–110, 2004. 2, 14, 15, 16, 32
- MARRO, A. A.; SOUZA, A. d. C.; CAVALCANTE, E. d. S.; BEZERRA, G. S.; NUNES, R. O. **Lógica fuzzy: conceitos e aplicações**. Natal: Universidade Federal do Rio Grande do Norte (UFRN), 2010. 27, 66
- MATSUOKA, M. T. **Influência de diferentes condições da ionosfera no posicionamento por ponto com GPS: Avaliação na região brasileira**. Tese (Doutorado em Ciências Cartográficas) — Faculdade de Ciências e Tecnologia da Universidade Estadual Paulista, Presidente Prudente, 2007. 3
- MONICO, J. F. G. **Posicionamento pelo GNSS: descrição, fundamentos e aplicações**. [S.l.]: Editora Unesp, 2007. 1
- MOREL, J.-M.; YU, G. Asift: A new framework for fully affine invariant image comparison. **SIAM journal on imaging sciences**, SIAM, v. 2, n. 2, p. 438–469, 2009. 8
- NIJIM, M. Multitasking intelligent surveillance and first response system. In: SYMPOSIUM ON TECHNOLOGIES FOR HOMELAND SECURITY. **Proceedings...** Kingsville, USA: IEEE, 2016. p. 1–6. 1
- OTAKE, V. S. **Produtos cartográficos gerados a partir de drones e aplicações na agricultura**. Maringá: Unicesumar, 2017. 1

PECHARROMAN, J. M. P.; VEIGA, R. **Estudo sobre a indústria brasileira e europeia de veículos aéreos não tripulados**. 2016. Disponível em: <[http://www.mdic.gov.br/images/publicacao\\_DRONES-20161130-20012017-web.pdf](http://www.mdic.gov.br/images/publicacao_DRONES-20161130-20012017-web.pdf)>. Acesso em: 04 mar. 2019. 7

RAWNSLEY, A. **Iran's alleged drone hack: tough, but possible**. 2011. Disponível em: <<http://www.wired.com/dangerroom/2011/12/iran-drone-hack-gps/>>. Acesso em: 4 maio 2017. 4

REBOUÇAS, R. A.; FORNARI, G.; SHIGUEMORI, É. H.; GUIMARÃES, L. N. F. Sistema adaptativo para registro automático de imagens aéreas com uso do método akaze. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 19., 2019. **Anais...** São José dos Campos: INPE, 2019. 82

REBOUÇAS, R. A.; SHIGUEMORI, E. H.; GUIMARAES, L. N. F. Matching of aerial images obtained by uav and satellite images by using characteristic points and ransac. In: CONFERENCE OF COMPUTATIONAL INTERDISCIPLINARY SCIENCE (CCIS), 4., 2016. **Proceedings...** [S.l.], 2016. 82

REBOUÇAS, R. A.; SHIGUEMORI, É. H.; GUIMARÃES, L. N. F. Parameters configuration for interest points in images obtained by drone. In: CEUR WORKSHOP, 2018. **Proceedings...** [S.l.], 2018. 52, 82

REN, Y.; XIE, X.; HU, J.; LI, Z. A stereo visual odometry based on surf feature and three consecutive frames. In: INTERNATIONAL SMART CITIES CONFERENCE, 2015. **Proceedings...** IEEE, 2015. p. 1–5. 2, 8

REZENDE, L. D.; PAULA, E. D.; KANTOR, I.; KINTNER, P. Mapping and survey of plasma bubbles over brazilian territory. **The Journal of Navigation**, Cambridge University Press, v. 60, n. 1, p. 69–81, 2007. 2

ROBERTO, L. **Acurácia do posicionamento e da orientação espacial de veículos aéreos a partir de imagens de câmeras de pequeno formato embarcadas**. Dissertação (Mestrado em Sensoriamento Remoto — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2017. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m21b/2017/11.03.11.55>>. Acesso em: 25 mar. 2018. 31, 33, 41, 43, 58, 61, 69, 71, 73, 75, 77, 79, 92

ROOS, D. R. **Aprendizado de máquina aplicado à odometria visual para estimação de posição de veículos aéreos não tripulados**. Dissertação

(Mestrado em Ciência da Computação) — Universidade Federal de São Paulo - UNIFESP, São José dos Campos, 2018. 2, 7, 9, 44, 65

ROSTEN, E.; DRUMMOND, T. Machine learning for high-speed corner detection. In: EUROPEAN CONFERENCE ON COMPUTER VISION (ECCV), 2006. **Proceedings...** Springer, 2006. p. 430–443. 17, 18

RUBLEE, E.; RABAUD, V.; KONOLIGE, K.; BRADSKI, G. Orb: an efficient alternative to sift or surf. In: INTERNATIONAL CONFERENCE ON COMPUTER VISION (ICCV), 2011. **Proceedings...** IEEE, 2011. p. 2564–2571. 2, 17, 32, 44

SCARAMUZZA, D.; FRAUNDORFER, F. Visual odometry [tutorial]. **IEEE Robotics & Automation Magazine**, v. 18, n. 4, p. 80–92, 2011. 8, 23, 24

SCHIMKE, S.; VIELHAUER, C.; DITTMANN, J. Using adapted levenshtein distance for on-line signature authentication. In: INTERNATIONAL CONFERENCE ON PATTERN RECOGNITION (ICPR), 17., 2004. **Proceedings...** IEEE, 2004. v. 2, p. 931–934. 22

SHEPARD, D.; BHATTI, J. A.; HUMPHREYS, T. E. **Drone hack: spoofing attack demonstration on a civilian unmanned aerial vehicle**. 2012. Disponível em: <<http://gpsworld.com/drone-hack/>>. Acesso em: 5 maio 2017. 4

SILVA, C.; GOLTZ, G.; SHIGUEMORI, E.; CASTRO, C. D.; VELHO, H. D. C.; BRAGA, A. D. Image matching applied to autonomous navigation of unmanned aerial vehicles. **International Journal of High Performance Systems Architecture**, v. 6, n. 4, p. 205–212, 2016. 2

SILVA, C. A. O. **Avaliação da técnica de casamento de imagens aplicada à localização geográfica de VANTs**. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Federal de Minas Gerais, Belo Horizonte, 2015. 8

SILVA FILHO, P. F. F. **Automatic landmark recognition in aerial images for the autonomous navigation system of unmanned aerial vehicles**. Dissertação (Mestrado em Engenharia Eletrônica) — Instituto Tecnológico de Aeronáutica, São José dos Campos, 2016. 2, 7, 8, 24

SILVA, W. da. **Navegação autônoma de VANT em período noturno com imagens infravermelho termal**. Dissertação (Mestrado em Computação Aplicada) — Instituto Nacional de Pesquisas Espaciais - INPE, São José dos

Campos, 2016. Disponível em: <<http://urlib.net/8JMKD3MGP3W34P/3M8CSN8>>. Acesso em: 13 abr. 2017. 1, 2, 8

SUBRAMANYA, H. Monocular vision based simultaneous localization and mapping (slam) technique for uav platforms in gps-denied environments. **International Journal of Robotics and Mechatronics**, v. 2, n. 1, p. 37–43, 2016. 2, 8

TELLIDIS, I.; LEVIN, E. Photogrammetric image acquisition with small unmanned aerial systems. In: ASPRS ANNUAL CONFERENCE, 2014, Louisville, Kentucky. **Proceedings...** [S.l.], 2014. 34

TUNG, W. L.; QUEK, C. A mamdani-takagi-sugeno based linguistic neural-fuzzy inference system for improved interpretability-accuracy representation. In: INTERNATIONAL CONFERENCE ON FUZZY SYSTEMS, 2009. **Proceedings...** IEEE, 2009. p. 367–372. 27

VETH, M. Navigation using images, a survey of techniques. **Navigation**, v. 58, n. 2, p. 127–139, 2011. 9

WEICKERT, J.; ROMENY, B. M. T. H.; VIERGEVER, M. A. Efficient and reliable schemes for nonlinear diffusion filtering. **IEEE transactions on image processing**, Citeseer, v. 7, n. 3, p. 398–410, 1998. 21

WHITE, N. A.; MAYBECK, P. S.; DEVILBISS, S. L. Detection of interference/jamming and spoofing in a dgps-aided inertial system. **IEEE Transactions on Aerospace and Electronic Systems**, v. 34, n. 4, p. 1208–1217, 1998. 1, 2

WYEN, A. O. V. **Naval Aviation in World War I**. [S.l.]: Chief of Naval Operations, 1969. 7

YANG, X.; CHENG, K.-T. Ldb: an ultra-fast feature for scalable augmented reality on mobile devices. In: INTERNATIONAL SYMPOSIUM ON MIXED AND AUGMENTED REALITY (ISMAR), 2012. **Proceedings...** IEEE, 2012. p. 49–57. 21

ZADEH, L. A. Fuzzy sets. **Information and Control**, v. 8, n. 3, p. 338–353, 1965. 26

ZHANG, Y.; ATKINSON, P. M.; LI, X.; LING, F.; WANG, Q.; DU, Y. Learning-based spatial-temporal superresolution mapping of forest cover with

modis images. **IEEE Transactions on Geoscience and Remote Sensing**, v. 55, n. 1, p. 600–614, 2017. 1

ZHEN, Y.; SUN, Z.; LI, J.; PENG, Y. An airborne remote sensing image mosaic algorithm based on feature points. In: INTERNATIONAL CONFERENCE ON INSTRUMENTATION & MEASUREMENT, COMPUTER, COMMUNICATION AND CONTROL, 6., 2016. **Proceedings...** IEEE, 2016. p. 202–205. 1

ZHENG, M.; WU, C.; CHEN, D.; MENG, Z. Rotation and affine-invariant sift descriptor for matching uav images with satellite images. In: GUIDANCE, NAVIGATION AND CONTROL CONFERENCE (CGNCC), 2014. **Proceedings...** IEEE, 2014. p. 2624–2628. 8

**ANEXO A - REGIÕES E ATITUDES DA AERONAVE NO CON-  
JUNTO DE IMAGENS DE TESTE**

<b>Imagem</b>	<b>Altitude (m)</b>	<b><i>Yaw</i> (graus)</b>	<b><i>Pitch</i> (graus)</b>	<b><i>Roll</i> (graus)</b>	<b>Região</b>
1	911,34	-45,65	-1,95	0,12	Urbana
2	910,69	-43,66	-1,52	-0,15	Urbana
3	914,66	-32,26	-2,19	20,21	Urbana
4	913,52	-26,03	-2,85	10,79	Urbana
5	912,47	-23,73	-1,71	-3,65	Urbana
6	911,79	-23,13	-1,40	-9,81	Urbana
7	904,92	-58,15	0,04	-38,43	Urbana
8	902,79	-70,91	0,54	-37,76	Urbana
9	1541,59	166,87	-2,42	15,44	Urbana
10	1539,96	171,14	-2,63	17,92	Urbana
11	907,03	-99,33	-2,71	-1,83	Vegetação rasteira
12	906,44	-99,13	-2,65	0,05	Vegetação rasteira
13	896,70	-56,26	-2,14	-25,99	Vegetação rasteira
14	895,27	-62,91	-2,07	-28,23	Vegetação rasteira
15	902,50	95,19	-0,86	-34,11	Vegetação rasteira
16	905,45	87,38	-2,93	-18,43	Vegetação rasteira
17	885,72	-169,99	-1,75	3,63	Vegetação rasteira
18	885,43	-167,99	-1,84	-16,05	Vegetação rasteira
19	1550,62	-13,97	-2,66	-0,29	Vegetação rasteira
20	1550,50	-13,78	-2,64	-0,43	Vegetação rasteira
21	915,67	-122,41	-1,71	-24,58	Vegetação densa
22	914,38	-129,56	-2,16	-24,43	Vegetação densa
23	905,22	100,17	-2,11	-2,67	Vegetação densa
24	905,63	98,64	-2,26	-19,09	Vegetação densa
25	877,81	118,71	0,34	-37,63	Vegetação densa
26	878,76	110,39	-4,13	-8,90	Vegetação densa
27	1309,98	-112,25	4,42	8,10	Vegetação densa
28	1325,49	-111,54	4,73	4,80	Vegetação densa
29	905,93	-97,92	-2,38	0,29	Lago
30	906,10	-97,73	-2,84	-0,29	Lago
31	910,25	54,02	-1,56	-18,24	Lago
32	909,99	51,73	-2,07	-4,65	Lago

(Continua)

Tabela A.1 - Continuação

<b>Imagem</b>	<b>Altitude (m)</b>	<b><i>Yaw</i> (graus)</b>	<b><i>Pitch</i> (graus)</b>	<b><i>Roll</i> (graus)</b>	<b>Região</b>
33	910,23	71,75	-0,06	-37,87	Lago
34	910,33	60,91	-1,77	-32,59	Lago
35	904,20	80,44	-1,87	-4,36	Vegetação
36	904,32	79,08	-1,78	-0,20	Vegetação
37	912,28	-99,85	-2,71	-2,27	Vegetação
38	912,55	-101,23	-1,96	-12,70	Vegetação
39	917,52	-151,46	-1,63	-24,97	Vegetação
40	918,11	-160,24	-1,83	-30,67	Vegetação
41	917,43	-175,44	-1,63	-30,89	Vegetação
42	916,52	176,98	-1,37	-29,26	Vegetação
43	1398,32	-110,20	9,93	0,55	Vegetação
44	1435,28	-110,07	9,37	0,07	Vegetação
45	872,47	146,65	-1,87	26,43	Vegetação e lago
46	871,19	155,73	-2,92	26,78	Vegetação e lago
47	908,96	-8,65	-0,32	-43,28	Vegetação e lago
48	908,56	-18,67	-2,60	-13,27	Vegetação e lago
49	901,46	80,90	-3,06	-5,12	Vegetação e lago
50	902,30	78,60	-3,74	-2,23	Vegetação e lago
51	1556,16	76,09	-2,59	-2,39	Vegetação e lago
52	1556,25	75,23	-2,18	-23,09	Vegetação e lago
53	903,19	82,68	-2,99	-0,40	Vegetação e urbana
54	901,55	81,94	-2,65	-0,84	Vegetação e urbana
55	906,53	-13,70	-2,64	-1,92	Vegetação e urbana
56	906,47	-14,58	-2,71	-14,95	Vegetação e urbana
57	1558,73	9,49	-0,16	-48,96	Vegetação e urbana
58	1560,66	-4,89	-0,15	-47,49	Vegetação e urbana
59	955,40	55,36	1,62	39,03	Vegetação e urbana
60	958,56	63,39	1,94	35,51	Vegetação e urbana

Fonte: Roberto (2017).

## ANEXO B - QUANTIDADE DE *INLIERS* ENTRE AS IMAGENS

Os cabeçalhos das tabelas são formados pela identificação de cada par de imagem, representada pelo campo *Img*, e a quantidade de inliers encontrada para cada método separado por detector e descritor (detector + descritor), representadas pelos campos *A+A* (AKAZE + AKAZE), *B+B* (BRISK + BRISK), *B+F* (BRISK + FREAK), *B+L* (BRISK + LATCH), *B+O* (BRISK + ORB), *O+B* (ORB + BRISK), *O+F* (ORB + FREAK), *O+L* (ORB + LATCH) e *O+O* (ORB + ORB).

Tabela B.1 - Quantidade de *inliers* com os parâmetros padrões.

Img	A+A	B+B	B+F	B+L	B+O	O+B	O+F	O+L	O+O
1	145	279	237	410	262			18	
2	44	130	108	107	114				
3	107	212	163	146	139				
4	104	251	229	161	202			18	31
5	752	2364	1992	2434	2217	103	27	187	201
6		20			17				
7		38		22	23				
8		21							16
9		18							
10		116	92	108	106	60		125	128
11	19	50	74	28	68				
12		18	23		18				
13									
14	37	199	180	178	229			20	22
15	39	101	86	89	104			22	24
16		32	36	22	29				
17		66	54	33	47				19
18		34	33	17	30				
19	17	70	69	67	63				
20		50	24	17	35				
21		72	54	36	64				
22	27	176	158	193	177	70	20	75	105
23		21	22	17	19				
24									
25	77	228	181	223	187	36		48	61
26	78	372	296	237	313				

(Continua)

Tabela B.1 - Continuação

Img	A+A	B+B	B+F	B+L	B+O	O+B	O+F	O+L	O+O
27	60	129	100	115	100				
28	82	200	117	198	131				
29	153	670	551	601	634	55		96	117
30		16			19				17

Fonte: Produção do autor.

Tabela B.2 - Quantidade de *inliers* com os parâmetros obtidos pelo algoritmo genético.

Img	A+A	B+B	B+F	B+L	B+O	O+B	O+F	O+L	O+O
1	25	20	25	23	28	18		19	22
2	23	25	19	20	22	26	23	17	24
3	23	18	22	25	25	17	24	22	20
4	25	22	19	21	19	25	19	20	25
5	35	23	26	22	25	21	26	22	25
6	26	30			16			18	20
7	20	20		23	22				27
8	20	20	23	24	19		30	24	21
9	23	31	19				26		26
10	21	30		26	22		24	24	20
11	22	23	20		23	18	22	23	23
12	23	17	19		19				16
13	18	17						17	
14	21	22	21	21	25	22	25	21	22
15	27	17			24	18	24		23
16	25	21		18	18		27		27
17	24	18	24	23	18	19		22	24
18	21	20	19		23		24		24
19	20	17	22	20	19	25	21	27	26
20	21	21	24	27	22		30	27	20
21	23	23	19	24	23	19	17	19	25
22	24	21	27	21	20	25	26	21	29
23	22	19	23	28	22	16	20		19
24	22								19

(Continua)

Tabela B.2 - Continuação

Img	A+A	B+B	B+F	B+L	B+O	O+B	O+F	O+L	O+O
25	26	19	25	24	25	23	25		22
26		22	25		24	19	20	18	21
27	22	22	21	21	23	27	17		26
28	26	23	25	27	24	20	23	24	22
29	28	24	22	21	27	25	24	24	25
30	27				24		22		21

Fonte: Produção do autor.



## ANEXO C - TEMPO ENTRE AS IMAGENS

Os cabeçalhos das tabelas são formados pela identificação de cada par de imagem, representada pelo campo *Img*, e o tempo para cada método separado por detector e descritor (detector + descritor), representadas pelos campos *A+A* (AKAZE + AKAZE), *B+B* (BRISK + BRISK), *B+F* (BRISK + FREAK), *B+L* (BRISK + LATCH), *B+O* (BRISK + ORB), *O+B* (ORB + BRISK), *O+F* (ORB + FREAK), *O+L* (ORB + LATCH) e *O+O* (ORB + ORB).

Tabela C.1 - Tempo entre as imagens com os parâmetros padrões.

Img	A+A	B+B	B+F	B+L	B+O	O+B	O+F	O+L	O+O
1	0,117	1,011	0,662	1,129	0,644			0,064	
2	0,099	0,688	0,537	0,892	0,494				
3	0,138	1,182	0,862	1,417	0,860				
4	0,118	1,027	0,763	1,261	0,753			0,064	0,032
5	0,117	1,009	0,770	1,282	0,743	0,031	0,059	0,065	0,040
6		0,086			0,061				
7		0,104		0,176	0,075				
8		0,081							0,024
9		0,108							
10		0,035	0,065	0,061	0,031	0,015		0,047	0,017
11	0,078	0,504	0,421	0,691	0,363				
12		1,004	0,748		0,670				
13									
14	0,075	0,288	0,263	0,440	0,205			0,055	0,024
15	0,078	0,187	0,175	0,295	0,132			0,058	0,021
16		0,117	0,126	0,195	0,085				
17		0,191	0,179	0,295	0,134				0,024
18		0,542	0,442	0,727	0,383				
19	0,081	0,501	0,408	0,678	0,352				
20		0,176	0,169	0,279	0,122				
21		0,200	0,190	0,308	0,141				
22	0,070	0,082	0,095	0,137	0,059	0,020	0,050	0,051	0,020
23		0,132	0,137	0,216	0,095				
24									
25	0,090	0,237	0,203	0,343	0,164	0,022		0,056	0,025
26	0,088	0,244	0,213	0,362	0,171				

(Continua)

Tabela C.1 - Continuação

Img	A+A	B+B	B+F	B+L	B+O	O+B	O+F	O+L	O+O
27	0,121	0,747	0,561	0,954	0,537				
28	0,126	0,843	0,629	1,074	0,615				
29	0,081	0,388	0,312	0,535	0,272	0,024		0,060	0,028
30		0,059			0,045				0,019

Fonte: Produção do autor.

Tabela C.2 - Tempo entre as imagens com os parâmetros obtidos pelo algoritmo genético.

Img	A+A	B+B	B+F	B+L	B+O	O+B	O+F	O+L	O+O
1	0,077	0,035	0,123	0,086	0,080	0,049		0,036	0,019
2	0,129	0,095	0,139	0,097	0,207	0,476	0,089	0,079	0,047
3	0,132	0,088	0,164	0,383	0,240	0,513	0,258	0,306	0,070
4	0,083	0,035	0,130	0,086	0,119	0,233	0,085	0,062	0,027
5	0,080	0,041	0,056	0,024	0,028	0,021	0,054	0,019	0,040
6	0,081	0,344			0,213			0,304	0,065
7	0,079	0,095		0,185	0,097				0,071
8	0,077	0,243	0,193	0,668	0,187		0,169	0,080	0,031
9	0,156	1,027	0,682				0,307		0,129
10	0,071	0,024		0,023	0,023		0,051	0,016	0,012
11	0,136	0,093	0,202		0,176	0,670	0,086	1,021	0,074
12	0,161	0,238	0,722		0,902				0,632
13	0,233	1,180						0,162	
14	0,073	0,048	0,427	0,096	0,044	0,555	0,087	0,067	0,024
15	0,148	0,042			0,056	0,134	0,077		0,015
16	0,130	0,104		0,291	0,087		0,136		0,041
17	0,085	0,036	0,079	0,256	0,058	0,044		0,081	0,023
18	0,171	0,209	0,457		0,346		0,362		0,274
19	0,088	0,098	0,303	0,216	0,148	0,348	0,210	0,209	0,130
20	0,087	0,182	0,216	1,423	0,153		0,209	0,356	0,052
21	0,088	0,109	0,267	0,419	0,079	0,414	0,096	0,142	0,047
22	0,071	0,028	0,064	0,026	0,027	0,027	0,049	0,019	0,014
23	0,093	0,226	0,235	0,998	0,072	0,291	0,150		0,087
24	0,211								0,255

(Continua)

Tabela C.2 - Continuação

Img	A+A	B+B	B+F	B+L	B+O	O+B	O+F	O+L	O+O
25	0,075	0,030	0,064	0,049	0,029	0,043	0,053		0,014
26		0,051	0,098		0,041	0,242	0,128	0,085	0,024
27	0,083	0,076	0,114	0,183	0,215	0,637	0,072		0,025
28	0,137	0,068	0,125	0,230	0,184	0,228	0,104	0,083	0,023
29	0,073	0,029	0,058	0,029	0,029	0,118	0,052	0,037	0,016
30	0,111				0,251		0,092		0,025

Fonte: Produção do autor.



## ANEXO D - ERRO ENTRE AS IMAGENS

Os cabeçalhos das tabelas são formados pela identificação de cada par de imagem, representada pelo campo *Img*, e o erro para cada método separado por detector e descritor (detector + descritor), representadas pelos campos *A+A* (AKAZE + AKAZE), *B+B* (BRISK + BRISK), *B+F* (BRISK + FREAK), *B+L* (BRISK + LATCH), *B+O* (BRISK + ORB), *O+B* (ORB + BRISK), *O+F* (ORB + FREAK), *O+L* (ORB + LATCH) e *O+O* (ORB + ORB).

Tabela D.1 - Erro entre as imagens com os parâmetros padrões.

Img	A+A	B+B	B+F	B+L	B+O	O+B	O+F	O+L	O+O
1	6,150	23,258	18,837	20,028	11,781			25,616	
2	2,467	5,111	8,557	55,719	11,802				
3	4,065	1,432	4,885	2,527	7,989				
4	0,794	7,765	7,828	6,515	7,787			14,962	51,905
5	0,902	0,465	0,743	1,114	0,459	2,179	4,204	2,000	6,825
6		21,093			7,773				
7		13,171		3,810	2,270				
8		2,073							22,719
9		10,441							
10		1,064	0,493	0,931	0,874	0,925		1,276	1,893
11	6,955	7,097	19,099	7,565	1,471				
12		14,905	12,270		7,624				
13									
14	3,197	1,348	2,769	1,016	4,669			29,734	25,041
15	11,034	6,687	21,385	14,743	10,683			134,928	136,929
16		31,364	9,285	16,141	24,829				
17		3,104	1,415	2,450	0,531				276,599
18		5,246	8,342	16,418	28,492				
19	21,965	7,310	5,687	5,107	23,321				
20		5,532	12,209	7,300	17,907				
21		10,375	14,014	11,995	11,523				
22	1,416	3,020	1,051	1,172	8,275	15,116	3,800	6,779	9,639
23		40,879	14,686	99,727	50,826				
24									
25	2,235	3,115	0,773	1,891	2,227	67,284		4,830	1,698
26	8,586	2,486	5,118	2,490	6,002				

(Continua)

Tabela D.1 - Continuação

Img	A+A	B+B	B+F	B+L	B+O	O+B	O+F	O+L	O+O
27	3,135	6,372	2,571	6,482	3,882				
28	13,983	5,439	12,292	4,679	2,486				
29	0,461	0,293	0,979	1,042	2,266	4,339		0,846	3,332
30		23,114			31,541				7,983

Fonte: Produção do autor.

Tabela D.2 - Erro entre as imagens com os parâmetros obtidos pelo algoritmo genético.

Img	A+A	B+B	B+F	B+L	B+O	O+B	O+F	O+L	O+O
1	7,938	6,243	7,411	5,940	8,394	9,588		6,246	5,290
2	2,921	6,558	6,974	6,234	3,619	29,747	2,354	5,962	6,337
3	1,511	7,231	4,203	5,847	4,600	7,891	7,709	3,441	6,668
4	4,735	7,444	3,800	6,628	7,775	3,887	21,047	5,302	8,371
5	0,893	3,069	1,176	2,014	2,739	2,636	1,279	2,068	2,314
6	5,289	49,931			23,580			8,831	5,178
7	3,373	3,755		9,667	3,875				5,040
8	2,544	4,125	4,960	7,024	4,201		2,899	4,395	3,656
9	5,623	11,884	4,194				2,969		6,693
10	0,812	1,146		0,649	0,480		4,113	5,241	4,127
11	3,894	4,053	1,760		5,730	37,102	4,344	4,195	5,720
12	5,785	10,272	7,641		5,187				9,562
13	5,016	1,339						148,083	
14	1,575	4,683	3,778	3,079	3,459	5,147	9,455	6,950	7,534
15	4,876	6,495			10,419	4,634	1,687		8,071
16	5,090	6,520		3,874	6,323		3,870		8,415
17	3,054	3,570	1,667	3,505	2,907	50,000		3,810	2,539
18	6,442	5,262	6,197		5,213		22,944		3,905
19	6,525	8,406	6,317	7,526	0,802	13,377	4,256	8,016	7,973
20	5,706	5,400	3,679	7,119	7,236		4,738	4,798	5,995
21	6,137	5,527	7,167	4,691	6,209	6,494	13,835	7,548	8,345
22	1,379	7,935	5,461	2,641	8,818	7,129	3,573	5,499	4,275
23	6,547	10,218	3,142	6,965	5,426	59,634	6,944		6,794
24	6,379								5,632

(Continua)

Tabela D.2 - Continuação

Img	A+A	B+B	B+F	B+L	B+O	O+B	O+F	O+L	O+O
25	1,574	2,221	3,284	2,609	3,774	8,357	4,329		4,367
26		2,639	6,647		5,518	3,223	26,431	5,817	6,445
27	1,796	3,462	3,114	6,085	7,982	2,756	1,375		4,383
28	4,545	5,314	5,454	2,926	2,520	18,214	7,082	4,178	6,235
29	0,581	4,194	2,300	2,853	3,910	5,026	5,681	5,323	6,336
30	6,798				6,903		4,914		6,244

Fonte: Produção do autor.



## ANEXO E - DIFERENÇA ENTRE AS ATITUDES DA AERONAVE

<b>Imagem</b>	<b>Altitude</b>	<b>Yaw</b>	<b>Pitch</b>	<b>Roll</b>	<b>Região</b>	<b>Atitude</b>
1	-	-	-	-	Urbana	Nadir
2	0,65	1,99	0,43	0,27	Urbana	Nadir
3	-	-	-	-	Urbana	Yaw e Roll
4	1,14	6,23	0,67	9,42	Urbana	Yaw e Roll
5	-	-	-	-	Urbana	Roll
6	0,68	0,60	0,30	6,17	Urbana	Roll
7	-	-	-	-	Urbana	Yaw
8	2,13	12,76	0,50	0,67	Urbana	Yaw
9	-	-	-	-	Urbana	Altitude Maior
10	1,63	4,28	0,21	2,47	Urbana	Altitude Maior
11	-	-	-	-	Vegetação rasteira	Nadir
12	0,59	0,20	0,06	1,88	Vegetação rasteira	Nadir
13	-	-	-	-	Vegetação rasteira	Yaw
14	1,44	6,65	0,06	2,24	Vegetação rasteira	Yaw
15	-	-	-	-	Vegetação rasteira	Yaw e Roll
16	2,94	7,81	2,07	15,68	Vegetação rasteira	Yaw e Roll
17	-	-	-	-	Vegetação rasteira	Roll
18	0,28	2,00	0,09	19,68	Vegetação rasteira	Roll
19	-	-	-	-	Vegetação rasteira	Altitude Maior
20	0,12	0,19	0,02	0,14	Vegetação rasteira	Altitude Maior
21	-	-	-	-	Vegetação densa	Yaw
22	1,29	7,16	0,45	0,15	Vegetação densa	Yaw
23	-	-	-	-	Vegetação densa	Roll
24	0,41	1,53	0,14	16,42	Vegetação densa	Roll
25	-	-	-	-	Vegetação densa	Yaw e Roll
26	0,95	8,32	4,47	28,73	Vegetação densa	Yaw, Pitch e Roll
27	-	-	-	-	Vegetação densa	Altitude
28	15,51	0,72	0,32	3,30	Vegetação densa	Altitude
29	-	-	-	-	Lago	Nadir
30	0,17	0,19	0,46	0,58	Lago	Nadir
31	-	-	-	-	Lago	Roll
32	0,26	2,29	0,52	13,59	Lago	Roll
33	-	-	-	-	Lago	Yaw
34	0,10	10,84	1,71	5,29	Lago	Yaw

(Continua)

Tabela E.1 - Continuação

<b>Imagem</b>	<b>Altitude</b>	<b>Yaw</b>	<b>Pitch</b>	<b>Roll</b>	<b>Região</b>	<b>Atitude</b>
35	-	-	-	-	Vegetação	Nadir
36	0,11	1,36	0,09	4,16	Vegetação	Nadir
37	-	-	-	-	Vegetação	Yaw
38	0,27	1,38	0,75	10,43	Vegetação	Yaw
39	-	-	-	-	Vegetação	Yaw e Roll
40	0,60	8,78	0,19	5,70	Vegetação	Yaw e Roll
41	-	-	-	-	Vegetação	Yaw
42	0,91	352,41	0,26	1,62	Vegetação	Yaw
43	-	-	-	-	Vegetação	Altitude
44	36,96	0,13	0,56	0,49	Vegetação	Altitude
45	-	-	-	-	Vegetação e lago	Yaw
46	1,28	9,08	1,05	0,35	Vegetação e lago	Yaw
47	-	-	-	-	Vegetação e lago	Yaw e Roll
48	0,40	10,01	2,28	30,01	Vegetação e lago	Yaw e Roll
49	-	-	-	-	Vegetação e lago	Nadir
50	0,84	2,29	0,68	2,89	Vegetação e lago	Nadir
51	-	-	-	-	Vegetação e lago	Altitude Maior
52	0,10	0,86	0,40	20,70	Vegetação e lago	Altitude Maior
53	-	-	-	-	Vegetação e urbana	Nadir
54	1,64	0,73	0,34	0,44	Vegetação e urbana	Nadir
55	-	-	-	-	Vegetação e urbana	Roll
56	0,05	0,88	0,07	13,04	Vegetação e urbana	Roll
57	-	-	-	-	Vegetação e urbana	Altitude Maior
58	1,93	14,38	0,01	1,47	Vegetação e urbana	Altitude Maior
59	-	-	-	-	Vegetação e urbana	Yaw
60	3,16	8,02	0,32	3,52	Vegetação e urbana	Yaw

Fonte: Produção do autor.