



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

sid.inpe.br/mtc-m21b/2016/08.08.20.34-TDI

## NAVEGAÇÃO AUTÔNOMA DE VANT EM PERÍODO NOTURNO COM IMAGENS INFRAVERMELHO TERMAL

Wanessa da Silva

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Computação Aplicada, orientada  
pelos Drs. Nandamudi Lankalapalli  
Vijaykumar, e Elcio Hideiti  
Shiguemori, aprovada em 22  
de agosto de 2016.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3M8CSN8>>

INPE  
São José dos Campos  
2016

## **PUBLICADO POR:**

Instituto Nacional de Pesquisas Espaciais - INPE

Gabinete do Diretor (GB)

Serviço de Informação e Documentação (SID)

Caixa Postal 515 - CEP 12.245-970

São José dos Campos - SP - Brasil

Tel.:(012) 3208-6923/6921

Fax: (012) 3208-6919

E-mail: pubtc@inpe.br

## **COMISSÃO DO CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELECTUAL DO INPE (DE/DIR-544):**

### **Presidente:**

Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação (CPG)

### **Membros:**

Dr. Plínio Carlos Alvalá - Centro de Ciência do Sistema Terrestre (CST)

Dr. André de Castro Milone - Coordenação de Ciências Espaciais e Atmosféricas (CEA)

Dra. Carina de Barros Melo - Coordenação de Laboratórios Associados (CTE)

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

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

Dr. Marley Cavalcante de Lima Moscati - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

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

### **BIBLIOTECA DIGITAL:**

Dr. Gerald Jean Francis Banon

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

### **REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:**

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

Yolanda Ribeiro da Silva Souza - Serviço de Informação e Documentação (SID)

### **EDITORAÇÃO ELETRÔNICA:**

Marcelo de Castro Pazos - Serviço de Informação e Documentação (SID)

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



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

sid.inpe.br/mtc-m21b/2016/08.08.20.34-TDI

## NAVEGAÇÃO AUTÔNOMA DE VANT EM PERÍODO NOTURNO COM IMAGENS INFRAVERMELHO TERMAL

Wanessa da Silva

Dissertação de Mestrado do  
Curso de Pós-Graduação em  
Computação Aplicada, orientada  
pelos Drs. Nandamudi Lankalapalli  
Vijaykumar, e Elcio Hideiti  
Shiguemori, aprovada em 22  
de agosto de 2016.

URL do documento original:

<<http://urlib.net/8JMKD3MGP3W34P/3M8CSN8>>

INPE  
São José dos Campos  
2016

Dados Internacionais de Catalogação na Publicação (CIP)

---

Silva, Wanessa da.

Si38n Navegação autônoma de VANT em período noturno com imagens infravermelho termal / Wanessa da Silva. – São José dos Campos : INPE, 2016.

xxii + 104 p. ; (sid.inpe.br/mtc-m21b/2016/08.08.20.34-TDI)

Dissertação (Mestrado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2016.

Orientadores : Drs. Nandamudi Lankalapalli Vijaykumar, e Elcio Hideiti Shiguemori.

1. Veículo aéreo não tripulado. 2. Imagem infravermelho termal. 3. rede neural artificial. 4. Algoritmo de colisão de múltiplas partículas. I.Título.

CDU 629.014.8:004.032.26

---



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): **Wanessa da Silva**

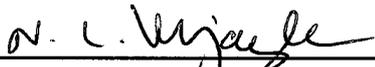
Título: " NAVEGAÇÃO AUTÔNOMA DE VANT EM PERÍODO NOTURNO COM IMAGENS INFRAVERMELHO TERMAL".

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

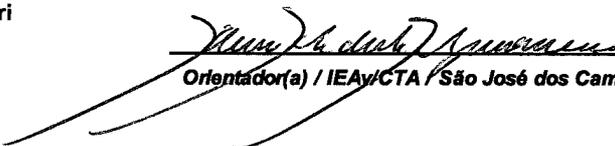
Dr. Haroldo Fraga de Campos Velho

  
\_\_\_\_\_  
Presidente / INPE / São José dos Campos - SP

Dr. Nandamudi Lankalapalli Vijaykumar

  
\_\_\_\_\_  
Orientador(a) / INPE / SJC Campos - SP

Dr. Elcio Hideiti Shiguemori

  
\_\_\_\_\_  
Orientador(a) / IEAvCTA / São José dos Campos - SP

Dr. Sergio Rosim

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

Dr. Alexandre Carlos Brandão Ramos

  
\_\_\_\_\_  
Convidado(a) / UNIFEI / Itajubá - MG

**Este trabalho foi aprovado por:**

maioria simples

unanimidade

São José dos Campos, 22 de Agosto de 2016



*A meus pais, Beatrix e Pedro, pelo seu amor e incentivo, pelos ensinamentos e principalmente pelo exemplo de vida.*

*A meu namorado José Renato por todo apoio, amor e companheirismo.*



## AGRADECIMENTOS

Primeiramente a Deus por mais uma etapa vencida e por sempre me dar força interior para superar as dificuldades e seguir em frente.

A meus orientadores, Dr. Elcio Hideiti Shiguemori e Dr. Nandamudi Lankalapalli Vijaykumar, e igualmente ao professor Dr. Haroldo Fraga de Campos Velho pela amizade, por contribuírem para o meu crescimento profissional, pela confiança, pela atenção concedida a todas as minhas dúvidas, pelas revisões e sugestões fatores fundamentais para a conclusão deste trabalho.

Aos membros da banca pela disposição em analisar este trabalho.

Agradeço à CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior) pela concessão da bolsa durante todo o período de realização deste mestrado.

A meus familiares em especial a minha mãe Beatriz Maria Silva e a meu pai Pedro Afonso da Silva, pelo seu amor, por todo apoio, compreensão, incentivo e por estarem sempre a meu lado nos momentos mais difíceis e por acreditarem e torcerem por mim.

A minha querida avó Vicentina Maria da Silva que sempre rezou por mim e sempre me disse que tudo daria certo.

A meu namorado José Renato Garcia Braga, pelo amor e pelo companheirismo, por ter estado sempre a meu lado me auxiliando, tirando minhas dúvidas e por ter me apoiado e me dado força para concluir mais essa etapa da minha vida.

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



## RESUMO

Atualmente o emprego de Veículos Aéreos Não Tripulados tem aumentado consideravelmente e se tornado indispensável para diversas aplicações onde a intervenção humana é impossível, exaustiva, arriscada ou cara, como por exemplo monitoramento de tráfego, operação de busca e resgate, vigilância de fronteiras, entre outras. Com esse aumento no emprego de Veículos Aéreos Não Tripulados, a navegação autônoma tem sido tema de diversas pesquisas. Para dar solução a esta navegação autônoma vários sistemas têm sido utilizados, um deles é com uso de processamento de imagens, que é uma alternativa ao sistema mais empregado que utiliza o Sistema de Posicionamento Global, que pode apresentar falhas ou bloqueio do sinal. Apesar do emprego em diversas aplicações de Veículos Aéreos Não Tripulados equipados por um sistema de navegação autônoma baseada em imagens, há um desafio em dotá-los com a capacidade de voo noturno. Neste contexto, esta dissertação de mestrado apresenta um método capaz de estimar a posição geográfica do Veículo Aéreo Não Tripulado durante um voo noturno com uso de imagens aéreas no espectro do infravermelho termal capturadas pela aeronave, buscando a região sobrevoada em uma imagem de satélite georreferenciada no espectro do visível. Para fazer o registro automático entre imagem aérea e de satélite, são utilizadas informações de bordas extraídas por Redes Neurais Artificiais e cálculo do coeficiente de correlação para fazer a estimação da posição da aeronave, pois são empregadas com sucesso em trabalhos relacionados. No sentido de se fazer a configuração automática da Redes Neurais Artificiais, o Algoritmo de Colisão de Múltiplas Partículas é empregado. Os resultados obtidos com as técnicas empregadas mostram-se promissores para emprego na navegação autônoma de Veículo aéreo não tripulado em período noturno.

Palavras-chave: Veículo Aéreo Não Tripulado. Imagem Infravermelho Termal. Rede Neural Artificial. Algoritmo de Colisão de Múltiplas Partículas.



# NIGHT UAV AUTONOMOUS NAVIGATION BY IMAGE PROCESSING OF THERMAL INFRARED IMAGES

## ABSTRACT

Unmanned Aerial Vehicles (UAVs) have been increasing for being employed for several applications where human intervention is impossible, exhaustive, risky or expensive, such as monitoring traffic, search and rescue, border vigilance, among others. This increase in its use has led to investigate approaches for autonomous navigation. One of such approaches is employing image processing instead of Global Positioning System as the latter may fail or its signal blocked. In spite of being employed in several applications, it is still a challenge for flying UAVs during night periods. Therefore, this Master's dissertation proposes and develops a method that is able to estimate the geographic position of a UAV during nights based on thermal infrared images captured by it as well as the satellite image of the region from the visible band. In order to automatically register correctly the aerial and satellite images, information on extracted borders by means of Artificial Neural Networks (ANNs) and correlation index will be used to estimate UAV's position as many of the published literature were successful in employing such techniques. The automatic configuration of ANN has been conducted by employing Multiple Particle Collision Algorithm (MPCA). The results obtained with these techniques show promise for use in autonomous navigation of UAV at nighttime.

Keywords: Unmanned Aerial Vehicles. Thermal Infrared Images. Artificial Neural Networks. Multiple Particle Collision Algorithm.



## LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Exemplos de categorias de VANTs. . . . .	10
2.2 Espectro Eletromagnético, com destaque para a radiação infravermelha. . . . .	12
2.3 Diferença entre imagens no comprimento de onda do visível e do infravermelho termal. . . . .	13
2.4 Etapas da passagem do filtro da Mediana. . . . .	16
2.5 Aplicação do filtro da Mediana. . . . .	17
2.6 Etapas da passagem do filtro Gaussiano de duas dimensões. . . . .	17
2.7 Aplicação do filtro Gaussiano. . . . .	18
3.1 Aplicação do extrator de bordas Sobel. . . . .	20
3.2 Processo de detecção de bordas pelo Canny. . . . .	21
3.3 Aplicação do extrator de bordas Canny. . . . .	22
3.4 Representação de um neurônio artificial. . . . .	24
3.5 Funções de ativação. . . . .	25
3.6 Arquitetura de uma rede neural artificial MLP. . . . .	27
3.7 Detecção de bordas por rede neural artificial MLP. . . . .	28
3.8 Arquitetura de uma rede neural artificial RBF. . . . .	29
3.9 Detecção de bordas por rede neural artificial RBF. . . . .	30
3.10 Navegação Autônoma de VANT: processamento de imagem + INS. . . . .	35
4.1 Métodos desta dissertação de mestrado. . . . .	38
4.2 Padrões de bordas e de não-bordas utilizados para treinamento da rede neural MLP e da rede neural RBF. . . . .	41
4.3 Novos Padrões de bordas e de não-bordas utilizados para treinamento da rede neural MLP e da rede neural RBF. . . . .	42
4.4 Processo de transformação da uma matriz de um padrão em vetor. . . . .	42
4.5 Processo de ativação das RNAs. . . . .	43
4.6 Processo de convolução de imagens. . . . .	45
4.7 Processo de convolução de imagens. . . . .	45
4.8 Câmera acoplada ao helicóptero. . . . .	47
4.9 Região selecionada para a produção dos resultados. . . . .	48
4.10 VANT utilizado para a captura das imagens infravermelho termal. . . . .	49
4.11 Sensor infravermelho termal utilizado para a captura das imagens aéreas. . . . .	50
4.12 Imagens utilizadas para geração dos resultados em uma única região. . . . .	51
4.13 Rota pré-definida na imagem de satélite, composta de 15 regiões. . . . .	52
4.14 Imagens de satélite utilizadas para a geração dos resultados. . . . .	53

4.15	Imagens do VANT de todas as 15 regiões que compõe a rota. . . . .	54
5.1	Imagens aérea de de satélite utilizadas no processo de extração de bordas.	60
5.2	Resultados da extração de bordas pela rede neural MLP de arquitetura determinada pelo MPCA. . . . .	60
5.3	Resultado da estimação da posição do VANT pela correlação entre a imagem aérea e a de satélite. . . . .	62
5.4	Resultado da estimação da posição do VANT pela correlação entre a imagem aérea e a de satélite. . . . .	62
5.5	Imagens aérea de de satélite utilizadas no processo de extração de bordas.	63
5.6	Resultados da extração de bordas pela rede neural MLP de arquitetura determinada pelo MPCA. . . . .	64
5.7	Resultado da estimação da posição do VANT pela correlação entre a imagem aérea e a de satélite. . . . .	65
5.8	Resultado da estimação da posição do VANT pela correlação entre a imagem aérea e a de satélite. . . . .	66
5.9	Combinação das técnicas para a produção de resultados. . . . .	67
5.10	Imagens utilizadas na geração de resultados do processo de extração de bordas. . . . .	68
5.11	Resultados da extração de bordas em imagem de Satélite. . . . .	69
5.12	Resultados da extração de bordas em imagem do VANT. . . . .	70
5.13	Estimação da posição do VANT na rota. . . . .	72
5.14	Erro dos métodos utilizados x Região da rota. . . . .	73
5.15	Estimação da posição do VANT na rota. . . . .	74
5.16	Erro dos métodos utilizados x Região da rota. . . . .	75
5.17	Estimação da posição do VANT na rota. . . . .	76
5.18	Erro dos métodos utilizados x Região da rota. . . . .	77
5.19	Estimação da posição do VANT na rota. . . . .	78
5.20	Erro dos métodos utilizados x Região da rota. . . . .	79
5.21	Estimação da posição do VANT na rota. . . . .	80
5.22	Erro dos métodos utilizados x Região da rota. . . . .	81
5.23	Estimação da posição do VANT na rota. . . . .	82
5.24	Extratores de bordas: Com aplicação do filtro Gaussiano e RNAs treinadas com o conjunto de 26 padrões. . . . .	83
5.25	Comparação entre as melhores técnicas de estimação da posição do VANT para cada região da rota. . . . .	84
5.26	Quantidade de bordas nas imagens capturada pelo VANT em função das técnica aplicadas para extração de borda. . . . .	85

5.27	Quantidade de bordas nas imagens capturada por satélite em função das técnicas aplicadas para extração de borda. . . . .	85
5.28	Extrator de bordas Canny sem filtro aplicado. . . . .	86
5.29	Extrator de bordas rede neural MLP (MPCA) com Filtro Gaussiano e conjunto de treinamento gerado pelos 26 padrões. . . . .	87
A.1	Extrator de bordas Sobel sem filtro aplicado. . . . .	97
A.2	Extrator de bordas Sobel com Filtro da Mediana. . . . .	97
A.3	Extrator de bordas Sobel com Filtro Gaussiano. . . . .	98
A.4	Extrator de bordas Canny com Filtro da Mediana. . . . .	98
A.5	Extrator de bordas rede neural RBF sem filtro aplicado e conjunto de treinamento gerado pelos 10 padrões. . . . .	99
A.6	Extrator de bordas rede neural RBF sem filtro aplicado e conjunto de treinamento gerado pelos 26 padrões. . . . .	99
A.7	Extrator de bordas rede neural RBF com Filtro da Mediana e conjunto de treinamento gerado pelos 10 padrões. . . . .	100
A.8	Extrator de bordas rede neural RBF com Filtro da Mediana e conjunto de treinamento gerado pelos 26 padrões. . . . .	100
A.9	Extrator de bordas rede neural MLP (MPCA) com Filtro Gaussiano e conjunto de treinamento gerado pelos 10 padrões. . . . .	101
A.10	Extrator de bordas rede neural RBF com Filtro Gaussiano e conjunto de treinamento gerado pelos 26 padrões. . . . .	101
A.11	Extrator de bordas rede neural MLP (MPCA) sem filtro aplicado e conjunto de treinamento gerado pelos 10 padrões. . . . .	102
A.12	Extrator de bordas rede neural MLP (MPCA) sem filtro aplicado e conjunto de treinamento gerado pelos 26 padrões. . . . .	102
A.13	Extrator de bordas rede neural MLP (MPCA) com Filtro da Mediana e conjunto de treinamento gerado pelos 10 padrões. . . . .	103
A.14	Extrator de bordas rede neural MLP (MPCA) com Filtro da Mediana e conjunto de treinamento gerado pelos 26 padrões. . . . .	103
A.15	Extrator de bordas rede neural MLP (MPCA) com Filtro Gaussiano e conjunto de treinamento gerado pelos 10 padrões. . . . .	104



## LISTA DE TABELAS

	<u>Pág.</u>
4.1 Resoluções do satélite <i>Quickbird</i> . . . . .	46
4.2 Principais características do sensor utilizado. . . . .	49
5.1 Arquitetura da rede neural RBF obtida durante o treinamento . . . . .	57
5.2 Arquitetura da rede neural MLP determinada empiricamente e da rede neural MLP de arquitetura determinada pelo algoritmo MPCA . . . . .	58
5.3 Arquitetura da rede neural RBF obtida durante o treinamento . . . . .	59
5.4 Arquitetura da rede neural MLP determinada pelo algoritmo MPCA . . . . .	59
5.5 Erro da estimação da posição do VANT . . . . .	61
5.6 Erro da estimação da posição do VANT . . . . .	65



## LISTA DE ABREVIATURAS E SIGLAS

ANAC	–	Agência Nacional da Aviação Civil
ARP	–	Aeronave Remotamente Pilotada
CNN	–	Cellular Neural Network
DCTA	–	Departamento de Ciências e Tecnologia Aeroespacial
EQM	–	Erro Médio Quadrático
FLIR	–	Forward Looking Infrared
FPGA	–	Field Programmable Gate Array
GNSS	–	Global Navigation Satellite System
GPS	–	Global Positioning System
IEAv	–	Institutos de Estudos Avançados
INS	–	Inertial Navigation System
IRLS	–	Infrared Linescanner
MLP	–	Multilayer Perceptron
MPCA	–	Multiple Particle Collision Algorithm
NASA	–	National Aeronautics and Space Administration
PCA	–	Particle Collision Algorithm
RBF	–	Radial Basis Function
REM	–	Radiação Eletromagnética
RNA	–	Rede Neural Artificial
SAMA	–	South Atlantic Magnetic Anomaly
SAR	–	Synthetic Aperture Radar
SURF	–	Speeded Up Robust Features
SVM	–	Support Vector Machines
VANT	–	Veículo Aéreo Não Tripulado
VANTs	–	Veículos Aéreos Não Tripulados



## SUMÁRIO

	<u>Pág.</u>
<b>1 INTRODUÇÃO</b> . . . . .	<b>1</b>
1.1 Motivação . . . . .	4
1.2 Objetivo e Estrutura da Dissertação . . . . .	5
<b>2 VANT E AQUISIÇÃO DE IMAGEM</b> . . . . .	<b>9</b>
2.1 Veículo Aéreo Não Tripulado . . . . .	9
2.2 Sensor e Imagem Infravermelho Termal . . . . .	11
2.3 Transformação para tons de cinza e Binarização da imagem . . . . .	14
2.4 Filtragem da imagem . . . . .	15
2.4.1 Filtro da Mediana . . . . .	16
2.4.2 Filtro Gaussiano . . . . .	17
<b>3 POSICIONAMENTO POR PROCESSAMENTO DE IMAGENS</b> <b>19</b>	
3.1 Métodos Tradicionais de Detecção de Bordas . . . . .	19
3.1.1 Extrator de Bordas Sobel . . . . .	19
3.1.2 Extrator de Bordas Canny . . . . .	21
3.2 Redes Neurais Artificiais na Detecção de Bordas . . . . .	23
3.2.1 Redes Neurais Artificiais . . . . .	23
3.2.2 Rede Neural Artificial com Perceptrons em Múltiplas Camadas . . . . .	26
3.2.3 Rede Neural Artificial com Funções de Base Radial . . . . .	28
3.2.4 Configuração Automática de Redes Neurais Artificiais . . . . .	31
3.2.4.1 Algoritmo de Colisão de Múltiplas Partículas . . . . .	31
3.3 Estimação da Posição Geográfica do VANT . . . . .	33
<b>4 NAVEGAÇÃO AUTÔNOMA BASEADA EM IMAGEM NO IN- FRAVERMELHO TERMAL</b> . . . . .	<b>37</b>
4.1 Métodos . . . . .	37
4.1.1 Extração de bordas pelas RNAs . . . . .	40
4.1.2 Estimação da Posição do VANT por casamento de padrões . . . . .	43
4.2 Características das imagens utilizadas . . . . .	46
4.2.1 Imagem do VANT capturada por sensor na banda do visível . . . . .	47
4.2.2 Imagens do VANT capturada por sensor na banda do infravermelho termal . . . . .	48

4.2.2.1	Imagens utilizadas para geração de resultado em uma única região . . . . .	50
4.2.2.2	Imagens utilizadas para geração de resultados em uma rota . . . . .	51
<b>5</b>	<b>RESULTADOS: DISCUSSÃO E ANÁLISE . . . . .</b>	<b>55</b>
5.1	Arquitetura das RNAs para extração de bordas . . . . .	56
5.1.1	Treinamento com o conjunto de 10 padrões . . . . .	57
5.1.2	Treinamento com o conjunto de 26 padrões . . . . .	58
5.2	Resultados de capacitação com o problema . . . . .	59
5.3	Resultados preliminares para uma única região e imagens óptica e termal . . . . .	63
5.4	Resultados para uma rota . . . . .	66
<b>6</b>	<b>CONSIDERAÇÕES FINAIS E SUGESTÕES . . . . .</b>	<b>89</b>
	<b>REFERÊNCIAS BIBLIOGRÁFICAS . . . . .</b>	<b>91</b>
	<b>APÊNDICE A - GRÁFICOS DO DESVIO DO ERRO . . . . .</b>	<b>97</b>

## 1 INTRODUÇÃO

O desenvolvimento científico e tecnológico possibilita, cada vez mais, o uso de sistemas onde se tenha um maior desempenho e menor participação humana em processos onde a sua presença não seja essencial. Segundo [Crestani \(2001\)](#) um sistema autônomo pode ser definido como um sistema provido de estratégias que regulam seu comportamento no ambiente. Neste contexto, um sistema autônomo caracteriza-se pela capacidade que possui de executar a tarefa para a qual foi projetado sem a interferência de qualquer mecanismo de controle externo ([FABRO, 1996](#)).

A navegação autônoma é estudada e desenvolvida em veículos aquáticos, terrestres e aéreos. Em veículos aéreos particularmente, a navegação autônoma tem sido realizada por diferentes técnicas, com uso de sistemas inerciais associados ao GPS e mais recentemente com uso de imagens.

Um exemplo de sistema aquático pode ser encontrado em [Takai et al. \(1997\)](#) onde é desenvolvido um sistema para fazer a localização autônoma de um veículo aquático, no qual um cabo guia é utilizado. Neste sistema captura-se uma imagem e passa-se um filtro gaussiano, para reduzir possíveis ruídos, e por fim é utilizada a técnica de Transformada de Hough para determinar a posição do cabo na imagem. Para a posição com relação a profundidade um sonar é utilizado.

Em [Nistér et al. \(2006\)](#), é desenvolvido um sistema baseado em visão computacional para a navegação autônoma de veículo terrestre, através da localização e desvio de objetos, usando para isto visão estéreo. Tal sistema opera em tempo real, com baixo atraso e faz a localização dos obstáculos utilizando o algoritmo de Harris Corner. Neste algoritmo os cantos dos obstáculos são detectados, fazendo com que o veículo desvie.

Os Veículos Aéreos Não Tripulados (VANTs) são qualquer tipo de aeronave que não necessitam de piloto embarcado para serem guiados. No Brasil, este tipo de aeronave tem sido denominada Aeronave Remotamente Pilotada (ARP). Segundo a Agência Nacional de Aviação Civil (ANAC) ARPs são aeronaves em que o piloto não está a bordo, constituem uma subcategoria dos VANTs e excluem as aeronaves não tripuladas totalmente autônomas. Desta forma, neste trabalho o termo empregado será VANT.

O emprego de VANTs tem sido uma solução viável para muitas aplicações nos setores científicos, civis e militares. Existem diferentes categorias de VANT, por exemplo,

asa fixa e rotativa. Com o uso de câmeras a bordo, esta tecnologia pode fornecer informações importantes para aplicações em diferentes cenários, por exemplo, de baixa altitude e alta resolução, como monitoramento de incêndios florestais (DANTAS, 2014), busca e resgate (CHAVES, 2013), monitoramento ambiental (LONGHITANO, 2010), vigilância de fronteiras (ANDRADE, 2013), entre outras. Apesar de voos autônomos de VANTs não estarem autorizados no Brasil, segundo o Código Brasileiro da Aeronáutica (Lei n° 7.565/89), vários métodos são propostos para realizar a navegação de VANTs em trabalhos acadêmicos e de pesquisa, ou em operações em outros países. Os três principais são:

- Uso de uma estação de solo com rádio-controle para pilotagem, realizada por um piloto (LONGHITANO, 2010).
- Com a associação de um Sistema Inercial de Navegação (INS, do inglês, *Inertial Navigation System*) e um GNSS (*Global Navigation Satellite System*). O GNSS totalmente operacional em escala mundial é o Sistema de Posicionamento Global (GPS), um sistema dos Estados Unidos da América (MITISHITA et al., 2014).
- Emprego de visão computacional com a aquisição de informações através de processamento de imagens (CONTE; DOHERTY, 2008; GOLTZ, 2011; SJANIC, 2011).

As Redes Neurais Artificiais são técnicas computacionais também utilizadas para auxiliar a navegação autônoma de VANTs. Na pesquisa de Kim e Calise (1997), foi desenvolvido um sistema baseado em redes neurais para o controle da trajetória da aeronave. Tal sistema é formado por um INS que fornece os dados de entrada para que a rede neural produza, em sua saída, a correção necessária que o INS deverá realizar para manter a aeronave na trajetória.

Em Shiguemori et al. (2007), redes neurais são utilizadas para o processamento das imagens capturadas da região sobrevoada pelo VANT. Um filtro de Gabor é utilizado para extrair a textura da imagem e a rede neural para fazer o reconhecimento da região sobrevoada entre os marcos, oriundos de uma imagem de satélite, utilizados para a navegação da aeronave.

Em Goltz (2011), redes neurais são utilizadas para extrair bordas de imagens de VANT e de satélite. A partir das imagens de bordas, das imagens capturadas pelo VANT e de satélite referente a mesma região sobrevoada pela aeronave, o Cálculo

do Coeficiente de Correlação é empregado para estimar a posição do VANT. No trabalho de Goltz (2011) foram utilizados um conjunto de 10 padrões de treinamento para a rede neural e o filtro da Mediana. Além disso, a rede neural foi configurada empiricamente. As imagens utilizadas, tanto as capturadas por satélite quanto imagens aéreas, foram capturadas por sensores na banda do visível. E todos os testes foram realizados para uma única região.

Grande parte dos trabalhos relacionados à navegação autônoma, com base em visão computacional e utilização de sensores passivos, estão voltados à navegação em ambiente com luz do dia e fazem uso de dados provenientes do espectro eletromagnético visível (LENSKIY; LEE, 2010). Desse modo há o interesse pelo desenvolvimento de sistemas de navegação autônoma que tenha a capacidade de operar em período noturno e utilizar dados provenientes do espectro eletromagnético infravermelho. Há a produção de alguns trabalhos científicos nesta área.

Lenskiy e Lee (2010) propõem um sistema de navegação autônoma para veículos terrestres, tanto para navegação noturna quanto diurna. Neste sistema são extraídas as características da imagem utilizando o algoritmo *Speeded Up Robust Features* (SURF) e determinada a verossimilhança dos elementos que compõe a imagem, para realizar a segmentação, utilizando uma Máquina de Vetores de Suporte (SVM, do inglês, *Support Vector Machines*).

Em Valasek et al. (2005), é proposto um sistema de navegação composto por GPS e INS combinados com visão computacional, que utiliza sensor infravermelho para realizar o reabastecimento de VANTs em voo. A visão computacional foi utilizada para aumentar a acurácia do sistema de navegação, pois, segundo os autores, é necessária uma precisão de 2 cm para o engate do aparelho de reabastecimento de combustível no VANT.

No trabalho de Rathinam et al. (2007), um VANT de asa fixa é utilizado para realizar o sobrevoo ao longo de um rio. Esta tarefa é executada por um sistema de visão computacional que extrai características de textura e histograma da imagem capturada em tempo real de voo, para percorrer um rio. Neste, os experimentos foram realizados tanto com imagens no infravermelho quanto no comprimento de onda do visível.

Os trabalhos citados em Lenskiy e Lee (2010), Valasek et al. (2005) e Rathinam et al. (2007) abordam a navegação autônoma de veículos em período noturno. No entanto, nenhum se concentra na navegação autônoma de um VANT em período

noturno com uso de visão computacional e sem a utilização de GPS ou de um piloto em estação terrestre. Neste sentido, nesta dissertação de mestrado sugere-se o desenvolvimento de técnicas para identificação do local sobrevoado, para realizar a navegação autônoma de um VANT no período noturno. Para esta tarefa técnicas de processamento de imagens são utilizadas para a localização do VANT com a identificação de marcos fixos presentes no terreno sobrevoado. O sistema usa um processo de Cálculo do Coeficiente de Correlação entre uma imagem de satélite georreferenciada com uma imagem no infravermelho, capturada em tempo real de voo da aeronave. Antes do processo do Cálculo do Coeficiente de Correlação, as imagens do VANT e de satélite terão suas bordas extraídas (*segmentação*) tanto por extratores tradicionais como Canny e Sobel, quanto por Redes Neurais Artificiais (RNA).

Para se fazer a configuração da rede neural de forma automática, o Algoritmo de Colisão de Múltiplas Partículas (MPCA, do inglês, *Multiple Particle Collision Algorithm*), pode ser empregado. Tal algoritmo foi utilizado, obtendo bons resultados, na pesquisa desenvolvida por Braga et al. (2015) que usa o MPCA para determinar arquitetura ótima da Rede Neural Artificial com Perceptrons em Múltiplas Camadas (MLP, do inglês, *Multilayer Perceptron*), que realizam o processo de mineração de dados de imagens hiperespectrais, e na rede neural artificial MLP que fazem a classificação destes dados.

## 1.1 Motivação

Atualmente com o aumento no emprego de VANTs para as mais diversas aplicações tanto civis, comerciais quanto militares, as pesquisas relacionadas a eles também têm aumentado. Devido principalmente ao menor custo de produção e operação destes quando comparados as aeronaves tripuladas.

Apesar de existirem VANTs dotados com a capacidade de voo noturno, a maioria faz uso de sensores INS e GNSS para auxiliar nessa navegação. A utilização de GNSS pelo VANT, como o GPS, pode deixá-lo suscetível a, por exemplo, bloqueios no sinal por interesses militares e falhas como interferência no sinal, o que ocorre principalmente no Brasil onde a Anomalia Magnética do Atlântico Sul (SAMA, do inglês, *South Atlantic Magnetic Anomaly*) (HARTMANN, 2006) está presente.

Dessa forma, um desafio é possibilitar voos autônomos baseados em imagens, em especial, voos noturnos ou com baixa luminosidade. Quando existem atividades que também podem ou devem ser executadas no período noturno como, por exemplo, a

atividade de vigiar fronteiras, pois é nesse período que as fronteiras precisam estar mais garantidas e essa atividade se executada por aeronave tripulada custa caro, é perigosa e exaustiva para o ser humano. Neste sentido, destaca-se a importância do desenvolvimento de um método que possa ser embarcado em um VANT e permita a sua navegação de forma autônoma sem utilização de GPS e em período noturno, através de uma rota pré-definida.

## 1.2 Objetivo e Estrutura da Dissertação

Essa pesquisa de mestrado tem como objetivo estudar e implementar um método capaz de estimar a posição geográfica de um VANT, sem a utilização de GPS. Essa estimativa é baseada no uso de imagens aéreas no infravermelho termal capturadas pela aeronave no período noturno, buscando essa região sobrevoada em uma imagem de satélite georreferenciada e na banda do visível. Para isso foram levantadas algumas hipóteses:

- é possível realizar a navegação autônoma por imagens termais, o que propicia uma navegação noturna;
- é possível empregar técnicas de processamento de imagens para estimar a posição sobrevoada com uso de imagens ópticas e termais (2 sensores diferentes);
- o emprego de uma rede neural para extração de bordas em imagens termais e ópticas pode ter desempenho igual ou superior às técnicas tradicionais. E que existe uma rede neural mais adequada para este problema;
- uma rede neural auto-configurada para extração de bordas apresenta resultados melhores que os apresentados por uma rede neural configurada empiricamente;
- um conjunto de treinamento da rede neural com mais detalhes (padrões) apresenta resultados melhores na extração de bordas em imagens termais e ópticas;
- o filtro Gaussiano pode ser mais adequado ao problema que o Filtro da Mediana;
- as técnicas de extração de bordas extraídas por uma rede neural e Cálculo de Coeficiente de Correlação são adequados para estimar a posição de um VANT em diferentes cenários existentes em uma rota.

Para o cumprimento deste objetivo, este trabalho baseou-se na técnica utilizada em Conte e Doherty (2008), Goltz (2011) e Sjanic (2011), onde realizou-se o registro automático entre as imagens obtidas pelo VANT e do satélite, utilizando para isso as informações de borda das imagens. Nestes trabalhos, as principais diferenças estão nos tipos de imagens utilizadas e do operador de extração de bordas aplicado. Em Conte e Doherty (2008) e Goltz (2011) tanto para as imagens capturadas pelo VANT quanto para as de satélite, foram utilizadas imagens na banda do visível. Enquanto que em Sjanic (2011) foram utilizados dois diferentes sensores um com imagem de satélite na banda do visível e outro com imagem aérea de Radar de Abertura Sintética (SAR, do inglês, *Synthetic Aperture Radar*). Com relação ao operador de extração de bordas aplicado, em Conte e Doherty (2008) e Sjanic (2011) foram utilizados métodos convencionais de detecção de bordas, sendo o Sobel e Canny respectivamente. Em Goltz (2011) foram utilizadas três RNAs, para realizar a extração de bordas em imagens, a Rede Neural Artificial com Perceptrons em Múltiplas Camadas (MLP, do inglês, *Multilayer Perceptron*), a Rede Neural Artificial com Função de Base Radial (RBF, do inglês, *Radial Basis Function*) e a Rede Neural Artificial Celular (CNN, do inglês, *Cellular Neural Network*).

Nesta dissertação as redes neurais artificiais MLP e a RBF assim como os operadores Canny e Sobel são utilizados para a obtenção das informações de borda, mas a fim de possibilitar a navegação do VANT no período noturno as imagens capturadas pelo VANT deverão estar na banda do infravermelho termal. Enquanto as imagens georreferenciadas de satélite ainda serão utilizadas na banda do visível. A vantagem da utilização de imagem de satélite georreferenciadas na banda do visível é a de se ter uma grande quantidade de imagens disponíveis. O que não seria possível caso se fizesse a utilização de imagens georreferenciadas de satélite na banda do infravermelho.

Essa dissertação de mestrado está organizada da seguinte maneira: no Capítulo 1 são apresentados a introdução, motivação, objetivos e a estrutura desta dissertação de mestrado; nos Capítulos 2 e 3 é apresentada a fundamentação teórica necessária para o desenvolvimento dessa dissertação; no Capítulo 4 são apresentados os materiais e a metodologia utilizados; o Capítulo 5 apresenta os resultados obtidos com o emprego da metodologia, numa primeira fase sendo utilizada para geração de resultados de capacitação com o problema, com uso de imagem de VANT capturadas por sensor na banda do visível. E numa segunda fase a mesma metodologia é utilizada para uma geração de resultados com uso de imagens capturadas por sensor na banda do infravermelho termal, para possibilitar voo noturnos; o Capítulo 6 apresenta as

considerações finais desse estudo realizado e sugestões de possíveis trabalhos futuros.



## 2 VANT E AQUISIÇÃO DE IMAGEM

A navegação autônoma tem aplicação em diferentes sistemas, sejam aquáticos, terrestres e aéreos. Várias estratégias são propostas para dar uma solução à navegação autônoma de VANTs, como em Tchernykh et al. (2006), Caballero et al. (2009), Amidi et al. (1999), Corke et al. (2001) e Saripally e Sukhatme (2003). Uma forma de se implementar tal sistema autônomo é a utilização associada de um INS com dados do GPS, que é o mais utilizado sistema GNSS em escala mundial totalmente operacional. Contudo, existe o risco desta tecnologia não estar disponível, ou seja, o sinal GPS pode, por exemplo, ser bloqueado devido a interesses militares, falhar devido a uma interferência, entre outros. Neste caso, uma ação possível é a captura de imagens em tempo real do terreno sobrevoado e o processamento de tais imagens com o intuito de reconhecer automaticamente o local sobrevoado e corrigir uma rota pré-planejada (CONTE; DOHERTY, 2008).

Neste capítulo são apresentados alguns conceitos: na **Seção 2.1** são apresentados os conceitos sobre VANTs. Na **Seção 2.2** são apresentados os conceitos sobre imagem, em especial obtidas com uso do sensor na banda do infravermelho termal. Na **Seção 2.3** é apresentado o processo de transformação em tons de cinza e binarização das imagens. Na **Seção 2.4** são descritos os filtros Gaussiano e de Mediana.

### 2.1 Veículo Aéreo Não Tripulado

O VANT também chamado de Aeronave Remotamente Pilotada (ARP) ou Drone (zangão em português), é qualquer tipo de aeronave que não necessita de piloto a bordo para ser guiada, sendo controlada a distância por meios eletrônicos e computacionais, supervisionada e controlada por humanos, ou sem a sua intervenção. Neste último caso, a navegação será realizada de forma autônoma.

Existem diferentes categorias de VANTs, por exemplo, de asa fixa, rotativa e atualmente veículos aéreos utilizados para voos orbitais. Este último, trata-se da categoria de VANT mais recentemente desenvolvida. O VANT X-37B é um projeto realizado em parceria da NASA (do inglês, *National Aeronautics and Space Administration*) com o programa X-37B da Força Aérea dos Estados Unidos. O X-37B possui 8,9 m de comprimento, 2,9 m de altura, 4,5 m de envergadura de asa, é alimentado por baterias e células solares, possui velocidade de 27.353 Km/h e utiliza o foguete Atlas V para ser lançado. Este projeto está sendo utilizado em testes de voo orbital (opera em órbita baixa da Terra, entre 110 a 500Km acima da Terra), reentrada, aterrissagem automática, experimentos e em missões secretas (KILLIAN, 2014). Outro

projeto da NASA é o chamado Global Hawks, esse VANT é capaz de permanecer em voo por mais de 30 horas, atinge altitudes superiores a 19 *Km* além de ser completamente autônomo, tendo a sua rota programada antes do seu lançamento. Este VANT está sendo utilizado para recolher dados atmosféricos e climáticos e no estudo de fenômenos como aquecimento global e o buraco na camada de ozônio (SAUSER, 2010).

As Figuras 2.1 (A), (B), (C) e (D) apresentam cada um dos tipos de VANTs citados anteriormente.

Figura 2.1 - Exemplos de categorias de VANTs.



(A)



(B)



(C)



(D)

Em (A) é ilustrado um VANT de asa fixa, em (B) de asa rotativa e VANTs para voos orbitais em (C) e (D), sendo o Global Hawks e o X-37B, respectivamente.

Fonte: (A) e (B)Guimaraes (2012), (C)Sauser (2010), (D)Killian (2014).

Segundo Guimaraes (2012) as categorias de VANTs de asa fixa Figura 2.1 (A) e asa rotativa Figura 2.1 (B) possuem as seguintes características:

- Asa fixa: Utilizam-se asas fixas em relação à estrutura da aeronave para se sustentar no ar. Geralmente, ou necessitam de uma catapulta para serem lançados ao ar ou de uma pista tanto para decolagem quanto para pouso e voam a altas velocidades cobrindo grandes distâncias.
- Asa rotativa: Se destacam pela capacidade de decolagem e pouso vertical. Possuem alta manobrabilidade quando comparadas às aeronaves de asas fixas, além de possuírem a capacidade de pairar.

## 2.2 Sensor e Imagem Infravermelho Termal

Em muitas aplicações é desejado obter informações de uma cena com características específicas. Dessa forma, é comum o emprego de sensores para a captura desses dados, em especial dos sensores aerotransportados, assim denominados pelo fato de serem embarcados em algum tipo de aeronave, como por exemplo um VANT.

Os sensores têm a finalidade de captar a radiação eletromagnética (REM) proveniente da superfície terrestre. A REM é a radiação emitida por toda matéria a uma temperatura superior a zero absoluto ( $0^{\circ}K$  ou  $-237^{\circ}C$ ), como resultado de suas oscilações atômicas e moleculares. Essa radiação ao incidir sobre a superfície de outra matéria pode ser refletida, absorvida ou transmitida. Quando absorvida, a energia é geralmente reemitida, em diferentes comprimentos de onda. Esses processos de absorção, emissão, reflexão e transmissão ocorrem simultaneamente e suas intensidades relativas caracterizam a matéria em investigação. Dependendo de suas características químicas e físicas, os quatro processos ocorrem com intensidades diferentes em diferentes regiões do espectro (FLORENZANO, 2011). Na Figura 2.2 essas regiões do espectro são apresentadas nos diferentes comprimentos de onda.

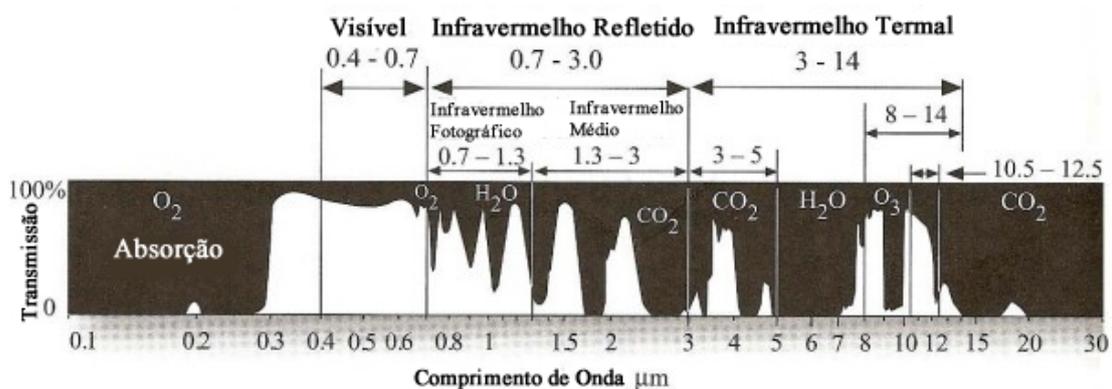
Depois de os sensores capturarem essa REM, transformam a energia conduzida pela onda eletromagnética em pulso eletrônico ou valor digital proporcional à intensidade desta energia. Segundo a fonte da onda eletromagnética os sensores são:

- Ativos: Estes utilizam REM artificial produzidas por radares instalados na aeronave. Estas ondas atingem a superfície terrestre onde interagem com os alvos, sendo refletidas de volta a aeronave;
- Passivos: Medem a REM natural refletida ou emitida pelos objetos, a partir da superfície terrestre.

Os sensores aerotransportados passivos operam em uma ou mais porções das faixas espectrais que se estendem do visível até as microondas. Nestes a principal fonte de energia é o Sol. A energia recebida pelo sensor é causada pela reflexão da energia solar no alvo ou por espalhamento na atmosfera ou proveniente do próprio alvo. Na faixa do visível, a energia emitida pelos alvos é causada pela reflexão da energia solar. Enquanto que na faixa do infravermelho termal, a energia emitida pelos alvos é função de sua temperatura, seja ela resultante da absorção da energia solar ou de fonte interna própria como a combustão (FLORENZANO, 2011).

Para cada cena focalizada pelo sensor, em uma faixa de frequência bem definida do espectro eletromagnético, há a geração de um tipo imagem. Imagens visíveis são capturadas por sensores na banda do visível, que cobre uma faixa de comprimento de onda que varia de  $0.4 - 0.7\mu m$ , como apresentado na Figura 2.2. Enquanto as imagens infravermelho termal são capturadas por sensores que atuam na região do infravermelho termal onde a radiação eletromagnética cobre uma faixa de comprimento de onda que varia de  $3 - 14\mu m$ , como apresentado na Figura 2.2, sendo totalmente diferente da radiação do visível. As faixas espectrais do infravermelho termal mais importantes para sensores aerotransportados vão da região  $3 - 5\mu m$  que é especialmente útil para o monitoramento de alvos quentes como, por exemplo, incêndios florestais, até a região  $8 - 14\mu m$  os quais vegetação, solo e rocha são bem melhor monitorados (JENSEN, 2009).

Figura 2.2 - Espectro Eletromagnético, com destaque para a radiação infravermelha.

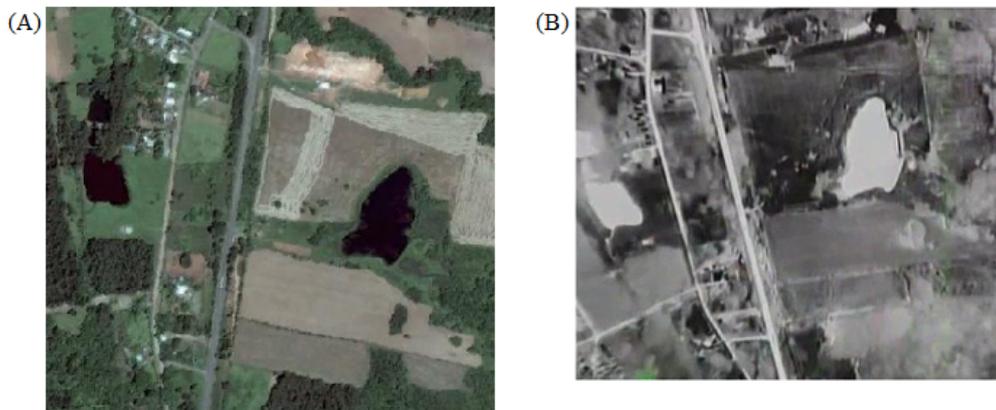


Fonte: Jensen (2009).

Numa imagem do espectro infravermelho termal, por convenção, tons claros representam áreas frias e tons escuros áreas quentes. Em geral, a escala de cores mais empregada para esse tipo de imagem é a escala que vai do branco ao preto, onde os vários tons de cinza, entre o preto e o branco, representam as temperaturas de brilho (radiométricas) dos objetos observados. Nesta escala objetos em tom de branco representam a superfície mais fria e em preto a mais quente. Podem ainda ser utilizadas outras tabelas de cores, nas quais um limite representa as temperaturas de brilho mais frias e o outro limite as temperaturas de brilho mais quentes ou ainda uma tabelas de cores em que se pretenda fazer sobressair determinadas gamas de temperatura de brilho.

Nas imagens do espectro visível, sendo estas imagens o resultado da reflexão da radiação solar pela superfície da Terra, o brilho é uma indicação da porcentagem da radiação solar refletida pelos alvos. Dessa forma, tons claros representam área de alta reflexão e tons mais escuros representam áreas de baixa reflexão (JENSEN, 2009). A Figura 2.3 apresenta um exemplo de cada tipo dessas imagens.

Figura 2.3 - Diferença entre imagens no comprimento de onda do visível e do infravermelho termal.



Em (A) é apresentada uma imagem visível e em (B) uma imagem infravermelho termal, correspondente a mesma região de (A).

Fonte: Produção do autor.

Um sensor aerotransportado infravermelho termal é um dispositivo capaz de coletar, detectar e transduzir a radiação infravermelha termal emitida pelos alvos, sob a aeronave ao qual está instalado, e gerar uma imagem correspondente. Esses imagea-

dores termais dividem-se, basicamente, em dois grupos: os imageadores de varredura de linha (IRLS, do inglês, *Infrared Linescanner*) e os de visada frontal (FLIR, do inglês, *Forward Looking Infrared*) (LUCCA; BASTOS, 2001).

### 2.3 Transformação para tons de cinza e Binarização da imagem

O processo de transformação em tons de cinza é frequentemente aplicado anteriormente aos processos de filtragem e extração de bordas. Esse processo de transformação consiste em converter uma imagem com diversas bandas em uma com apenas uma banda.

Um dos métodos para se transformar uma imagem colorida em tons de cinza, segue os seguintes passos: primeiro obtém-se o valor do pixel na banda do vermelho, verde e azul (da escala RGB). Então adicionam-se 30% do vermelho mais 59% do verde e mais 11% do azul, essas porcentagens relacionam-se a sensibilidade visual do olho humano para as cores primárias (HUGHES et al., 2013). Chegando com isso a Equação:

$$Escala\_Cinza = 0,2989 * R + 0,5870 * G + 0,1140 * B . \quad (2.1)$$

Esse cálculo é realizado para cada pixel da imagem. A Equação 2.1 converte os valores de RGB para valores em escala de cinza, formando uma soma ponderada dos componentes R, G e B.

A binarização da imagem é o processo pelo qual se atribui apenas um entre dois valores possíveis para cada pixel, preto ou branco. Para se realizar esse processo de binarização deve-se primeiro converter a imagem para tons de cinza, para então aplicar um método de binarização. A conversão de uma imagem com níveis de cinza para uma com representação binária (dois tons) é importante para uma série de objetivos, como por exemplo, para identificar objetos e separá-los do fundo da imagem. Também é importante que a intensidade de seus pixels estejam bem definidas na hora de se analisar a forma da imagem (LIU; WANG, 2009).

Existem diversas maneiras de binarizar uma imagem. Todos os métodos de binarização de imagem consistem em achar um limiar (threshold), que denota o valor de pixel que minimiza a variância entre os tons de cinza, sendo este o valor que definirá a qual classe (preto ou branco) pertence cada pixel. Esse limiar pode ser fixo ou pode variar conforme a imagem. O método mais tradicional para encontrar um limiar adaptativo, aquele que varia conforme o valor de tom de cinza de cada imagem, é o método de Otsu (OTSU, 1979). O método de Otsu é dividido em duas

etapas:

- 1 - Consiste na construção do histograma da imagem;
- 2 - A partir do histograma da imagem o algoritmo seleciona o valor que minimiza a variância entre os tons de cinza da imagem, o qual será usado como limiar. Desta forma valores abaixo do limiar serão 0 (preto) e acima serão 1 (branco).

## 2.4 Filtragem da imagem

A filtragem da imagem é uma das técnicas de processamento, muito utilizada para melhorar a qualidade de uma imagem digital. Esta permite diminuir efeitos indesejáveis, seja por causa do método de aquisição ou das condições nas quais a imagem foi capturada, que podem ter ressaltado algum ruído na imagem.

Existem dois tipos de filtragem. A filtragem no domínio da frequência e a filtragem em domínio espacial, a primeira opera sobre a transformada de Fourier e a segunda, no caso de imagens, opera diretamente sobre os pixels (GONZALEZ; WOODS, 2011).

As técnicas de filtragem espacial são transformações da imagem pixel a pixel, que não dependem apenas da intensidade de um determinado pixel, mas também do valor da intensidade dos pixels vizinhos. O processo de filtragem é realizado com uso de matrizes denominadas máscaras, as quais são aplicadas sobre a imagem, esse processo também é conhecido como convolução (GONZALEZ; WOODS, 2011).

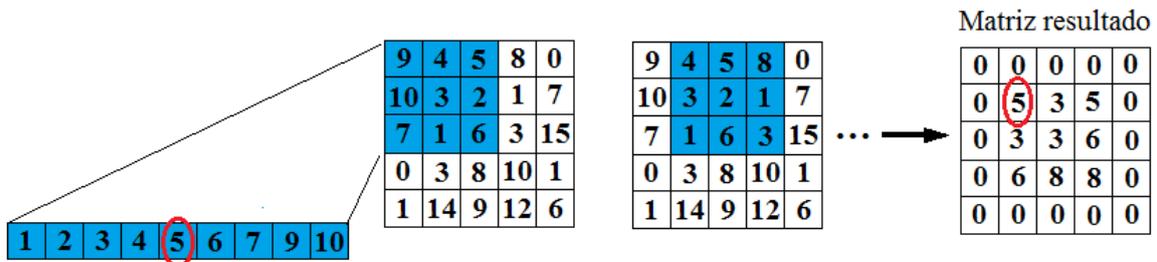
Os filtros espaciais podem ser classificados em passa-baixa e passa-alta. A filtragem passa-alta realça detalhes da imagem, isto é, as transições entre regiões diferentes tornam-se mais nítidas. Dessa forma esse filtro pode ser usado para realçar certas características como bordas, linhas curvas ou manchas, mas possuem a desvantagem de enfatizarem o ruído existente na imagem. Já o filtro passa-baixa suaviza a imagem atenuando as altas frequências, com isso tende a minimizar ruídos e apresenta o efeito de suavização da imagem. Segundo Conte e Doherty (2008) o filtro passa-baixa tem a propriedade de fazer a remoção de pequenos detalhes na imagem, enquanto preserva a definição das bordas. Exemplos do filtro passa-baixa são o Filtro da Mediana e o Filtro Gaussiano.

### 2.4.1 Filtro da Mediana

O filtro da Mediana é um filtro passa-baixa, não linear no domínio espacial. Sua principal característica é de suavizar a imagem, porém, minimizando o efeito de borramento. O tamanho da máscara utilizada, do filtro da Mediana, tem influência direta no efeito de suavização da imagem, ou seja, quanto maior a dimensão da máscara, maior será o efeito de suavização (XIE et al., 2014). Por esse motivo, caso seja requerida uma menor suavização normalmente é utilizada uma máscara de dimensão  $3 \times 3$ .

O processo do filtro da Mediana consiste em, para cada janela de dimensão  $3 \times 3$ , ordenar os pixels em ordem crescente e escolher como saída o valor que está no centro da sequência. Após esse processo, a posição central dessa janela  $3 \times 3$  receberá esse valor da mediana para geração da imagem filtrada. Este filtro é ideal para o tratamento de ruídos do tipo sal e pimenta, no qual, pontos brancos representam o sal e os pretos a pimenta (GONZALEZ; WOODS, 2011). Na Figura 2.4 é exibida a passagem do filtro de Mediana utilizando uma máscara de dimensão  $3 \times 3$  e a matriz resultante desse processo.

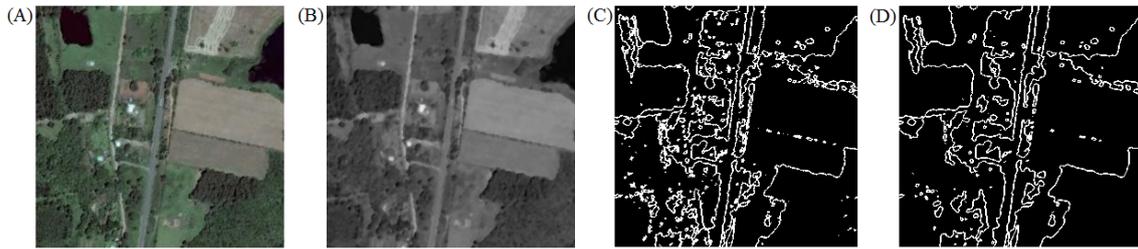
Figura 2.4 - Etapas da passagem do filtro da Mediana.



Fonte: Produção do autor.

Nas Figuras 2.5 (A) e (B), são apresentados exemplos de uma imagem sem e outra com a aplicação do filtro da Mediana, respectivamente. E para uma melhor visualização dos efeitos da aplicação do filtro, essas mesmas imagens são apresentadas com suas bordas extraídas nas Figuras 2.5 (C) e (D).

Figura 2.5 - Aplicação do filtro da Mediana.



Em (A) a imagem original, em (B) a imagem filtrada, em (C) a imagem segmentada sem filtro e em (D) a imagem segmentada e com aplicação do filtro da Mediana.

Fonte: Produção do autor.

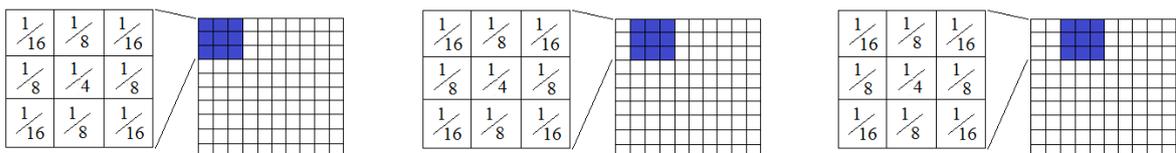
### 2.4.2 Filtro Gaussiano

O filtro Gaussiano é um filtro muito utilizado em processamento de imagens pela sua capacidade de suavização e remoção de ruídos na imagem (GONZALEZ; WOODS, 2011). O filtro Gaussiano tem sua máscara construída utilizando a função Gaussiana em duas dimensões. A função Gaussiana é apresentada na Equação:

$$G(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} e^{-\frac{x^2}{2\sigma_x^2} - \frac{y^2}{2\sigma_y^2}} \quad (2.2)$$

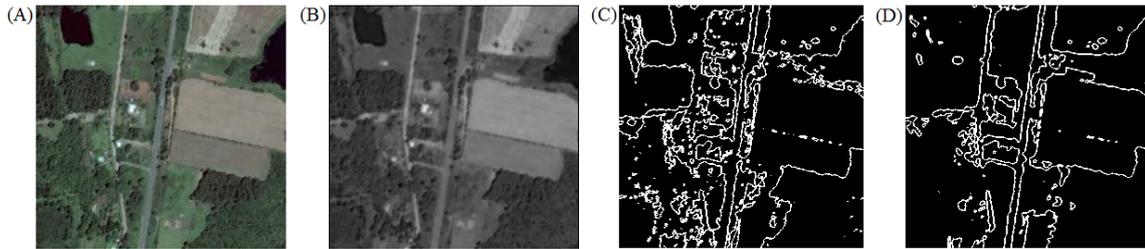
Na função Gaussiana  $\sigma$  é o desvio padrão. Um exemplo de máscara gaussiana para uma janela de dimensão  $3 \times 3$  é mostrada na Figura 2.6. Os valores foram obtidos com  $\sigma^2 = 2/\pi$ .

Figura 2.6 - Etapas da passagem do filtro Gaussiano de duas dimensões.



Nas Figuras 2.7 (A) e (B) são apresentados um exemplo de uma imagem sem e outra com a aplicação do filtro Gaussiano, respectivamente. E para uma melhor visualização dos efeitos da aplicação do filtro, essas mesmas imagens são apresentadas com suas bordas extraídas nas Figuras 2.7 (C) e (D).

Figura 2.7 - Aplicação do filtro Gaussiano.



Em (A) a imagem original, em (B) a imagem filtrada, em (C) a imagem segmentada sem filtro e em (D) a imagem segmentada e com aplicação do filtro.

Fonte: Produção do autor.

### 3 POSICIONAMENTO POR PROCESSAMENTO DE IMAGENS

O tema da tese é posicionamento de um VANT por processamento de imagens. O processo envolve várias etapas: pré-processamento, segmentação (detecção de bordas) de imagens, convolução de imagens segmentadas entre imagem georreferenciada e imagem do VANT.

Nesse capítulo são apresentados alguns conceitos teóricos necessários para o desenvolvimento dessa dissertação de mestrado. Na **Seção 3.1** são revisados métodos conhecidos de segmentação. Na **Seção 3.2** são apresentados os conceitos sobre RNAs, sua aplicação na detecção de bordas e o Algoritmo de Colisão de Múltiplas Partículas, que realiza a configuração automática da rede neural artificial MLP. Na **Seção 3.3** são apresentados os conceitos sobre Cálculo do Coeficiente de Correlação e seu emprego na estimação da posição do VANT.

#### 3.1 Métodos Tradicionais de Detecção de Bordas

A detecção de bordas é uma técnica de processamento de imagem e visão computacional bastante empregada no processo de extração de características das imagens. Pois sua utilização reduz significativamente a quantidade de dados a serem processados e descarta informações que são consideradas menos relevantes, ainda que preservando informações essenciais sobre as formas dos objetos na cena. A detecção pode ser prejudicada por bordas falsas criadas por ruídos na imagem provenientes, por exemplo, do processo de captura da imagem. Para se amenizar esses ruídos podem ser utilizadas, antes do processo de detecção de bordas, técnicas de redução de ruídos, como os filtros (MUTHUKRISHNAN; RADHA, 2011).

O método de detecção de bordas é utilizado no processo de localização e realce dos pixels de borda, aumentando o contraste entre a borda e o fundo. Dentre os métodos tradicionais de detecção de bordas destacam-se os operadores Sobel e Canny, amplamente aplicados pela comunidade científica no processo de extração de bordas.

##### 3.1.1 Extrator de Bordas Sobel

O algoritmo de detecção de bordas Sobel está baseado no cálculo do gradiente de um pixel em relação aos seus vizinhos, quando este valor de gradiente for acima de um limiar então é detectada a presença de borda (GONZALEZ; WOODS, 2011). Sobre a imagem em tons de cinza são aplicadas em convolução as máscaras apresentadas

na Equação:

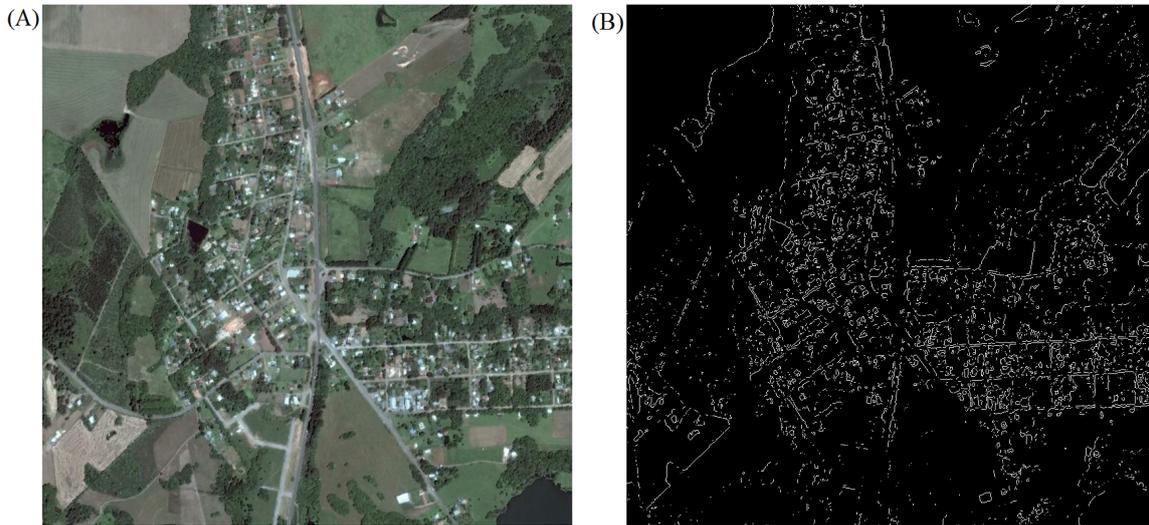
$$Mg_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad Mg_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \quad (3.1)$$

A  $Mg_x$  calcula os gradientes na direção horizontal e a  $Mg_y$  calcula os gradientes na direção vertical. Como resultado da aplicação dessas duas máscaras são obtidas duas matrizes  $Ig_x$  e  $Ig_y$ . O passo final do algoritmo é o cálculo da magnitude do gradiente, que pode ser obtida pela Equação:

$$|Ig| = \sqrt{Ig_x^2 + Ig_y^2} . \quad (3.2)$$

A Figura 3.1 apresenta um exemplo da aplicação do algoritmo de detecção de bordas Sobel.

Figura 3.1 - Aplicação do extrator de bordas Sobel.



Em (A) a imagem original e em (B) a imagem com aplicação do algoritmo Sobel.

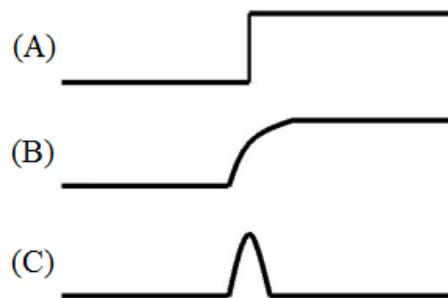
Fonte: Produção do autor.

### 3.1.2 Extrator de Bordas Canny

Canny é um algoritmo multi-passos para a detecção de bordas. Este algoritmo realiza uma convolução sobre a imagem suavizando os ruídos presentes e localizando as bordas, por meio da primeira derivada, para isto utiliza um operador diferencial com um filtro Gaussiano.

Na Figura 3.2 em (A) é mostrada a representação de uma borda em uma dimensão, em (B) o resultado da operação do filtro Gaussiano sobre a borda e em (C) o resultado do cálculo da primeira derivada onde o ponto de máximo representa a presença de borda.

Figura 3.2 - Processo de detecção de bordas pelo Canny.



Fonte: Produção do autor.

Em uma imagem que é representada por uma matriz, após a operação com filtro Gaussiano e o cálculo da primeira derivada nas duas dimensões os pontos de máximo serão as bordas da imagem. Segundo [Gonzalez e Woods \(2011\)](#) o algoritmo Canny possui as etapas descritas abaixo.

#### Etapas do algoritmo Canny:

- 1 - Redução de ruído: Começa-se com a convolução da imagem com uma máscara Gaussiana, isto conseqüentemente reduz o efeito de pixels ruidosos na imagem. O filtro Gaussiano foi apresentado na **Seção 2.4.2**;
- 2 - Cálculo dos gradientes da intensidade da imagem: São utilizadas as máscaras do filtro de Sobel para o cálculo do valor dos gradientes da imagem. O

algoritmo de detecção de bordas do Sobel foi apresentado na **Seção 3.1.1**;

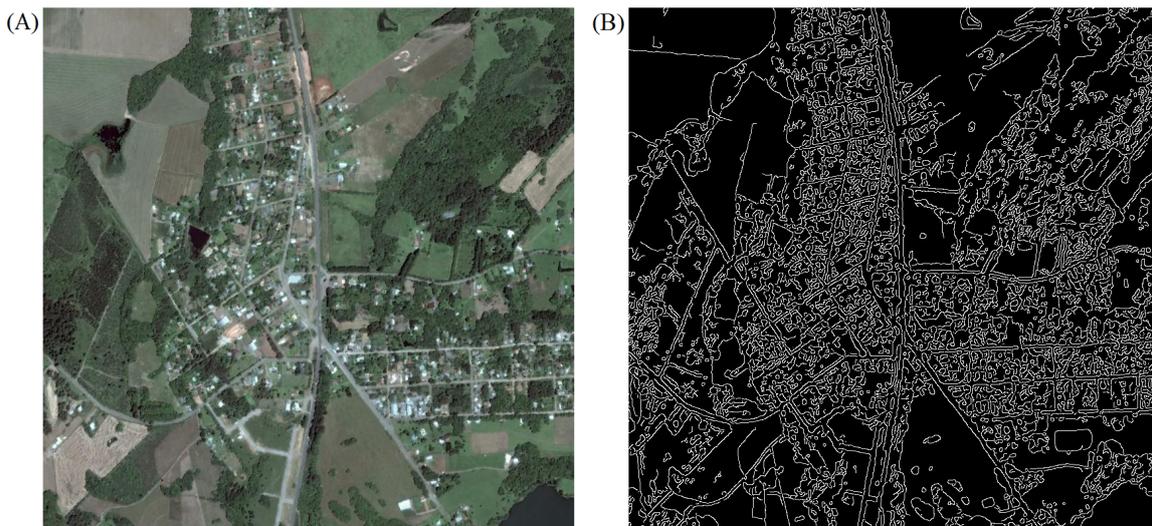
- 3 - Cálculo da direção do ângulo do gradiente: O cálculo da direção é realizado pela Equação 3.3. E realiza-se a aproximação de  $\theta$  para  $135^\circ$ ,  $90^\circ$ ,  $45^\circ$  e  $0^\circ$ ;

$$\theta = \arctan \left( \frac{|I_{g_y}|}{|I_{g_x}|} \right) \quad (3.3)$$

- 4 - Detecção das bordas da imagem: Os resultados da convolução da imagem original com cada uma destas máscaras são armazenados. Para cada pixel, marca-se então o maior resultado do gradiente nesse pixel e o sentido da máscara que produziu essa borda. Da imagem original, criam-se dois mapas de gradientes da intensidade em cada ponto na imagem, e o do sentido do gradiente no ponto. Os gradientes de intensidade mais elevada são mais prováveis de serem bordas.

Na Figura 3.3, é apresentado um exemplo da aplicação do algoritmo de detecção de bordas Canny.

Figura 3.3 - Aplicação do extrator de bordas Canny.



Em (A) a imagem original e em (B) a imagem com aplicação do algoritmo Canny.

Fonte: Produção do autor.

## 3.2 Redes Neurais Artificiais na Detecção de Bordas

As RNAs podem ser utilizadas como filtro para detecção de borda, pois as RNAs são naturalmente um filtro não linear devido: a não linearidade da função de ativação dos neurônios e dos pesos sinápticos da rede (TERRY; VU, 1993).

As redes neurais possuem maior acurácia na detecção de bordas, pois não realizam mudanças nos valores de tons de cinza das imagens durante o processo de convolução da máscara, diferentemente dos algoritmos tradicionais de detecção de bordas (LI et al., 2008).

Na **Seção 3.2.1** são apresentados alguns conceitos gerais sobre RNAs. Nas **seções 3.2.2 e 3.2.3** são apresentadas as descrições das RNAs empregadas nesta dissertação. E na **Seção 3.2.4** é descrito o algoritmo MPCA, que faz a configuração automática da rede neural artificial MLP.

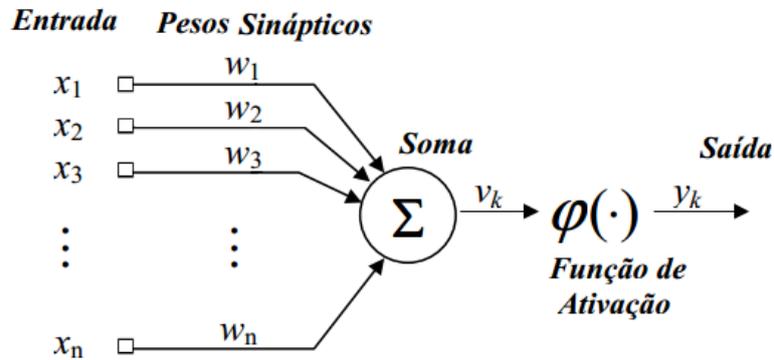
### 3.2.1 Redes Neurais Artificiais

De forma geral, uma RNA é um modelo matemático projetado para modelar a maneira como o cérebro humano realiza uma tarefa particular ou função de interesse. A RNA é normalmente implementada utilizando-se componentes eletrônicos ou programação em software (HAYKIN, 2007). A RNA se assemelha ao cérebro por possuir as seguintes características:

- Possui uma unidade básica de funcionamento que é o neurônio;
- Forças de conexões entre os neurônios, as sinapses (pesos sinápticos), armazenam o conhecimento adquirido; e
- O conhecimento é adquirido a partir do ambiente, por meio de um processo de aprendizagem.

Da mesma forma como as RNAs se assemelham ao cérebro humano, os neurônios artificiais são baseados nos neurônios biológicos. Enquanto os neurônios biológicos são células nervosas que recebem e transformam estímulos em outros estímulos, os neurônios artificiais transformam várias entradas em uma única saída (HAYKIN, 2007). Na Figura 3.4 é apresentada a representação esquemática de um neurônio artificial.

Figura 3.4 - Representação de um neurônio artificial.



Fonte: Adaptada de Haykin (2007).

No neurônio artificial, a soma ponderada das entradas é efetuada pela Equação 3.4 e a saída do neurônio é dada pela Equação 3.5:

$$v_k = \sum_{j=1}^n w_{kj} \times x_j . \quad (3.4)$$

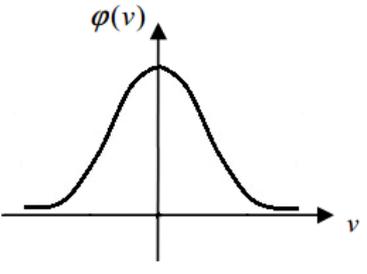
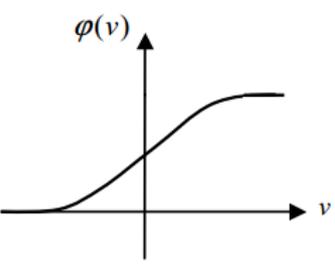
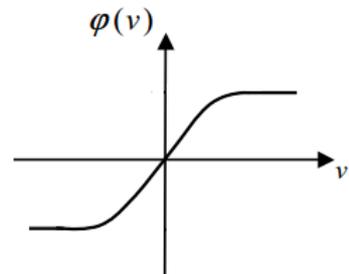
Na Equação 3.4,  $v_k$  é o resultado do combinador linear do neurônio produzido pelo somatório de todos os componentes do vetor de entrada  $x_j$ , para  $j = 1, 2, \dots, n$ , multiplicada por seu respectivo peso sináptico  $w_{kj}$ .

$$y_k = \varphi(v_k) \quad (3.5)$$

onde  $\varphi$  é uma função de ativação aplicada ao termo  $v_k$  produzindo a saída  $y_k$  do neurônio artificial.

A função de ativação é a responsável pela geração do sinal de saída do neurônio artificial. Existem diversas funções matemáticas que podem ser utilizadas para esta finalidade. A Figura 3.5 ilustra três funções de ativação mais comumente utilizadas.

Figura 3.5 - Funções de ativação.

Função Gaussiana	Função Logística Sigmoidal	Função Tangente Hiperbólica
		
$\varphi(v) = e^{-a^2}$	$\varphi(v) = \frac{1}{1 + e^{-av}}$	$\varphi(v) = \frac{1 - e^{-av}}{1 + e^{-av}}$

Fonte: Adaptada de Braga et al. (2007).

A principal propriedade de uma RNA é conseguir aprender e assim melhorar seu desempenho. A RNA aprende por meio de um processo chamado treinamento, onde há o ajuste dos pesos sinápticos, até que a RNA apresente uma solução generalizada para uma classe de problemas (HAYKIN, 2007).

O processo de aprendizagem, também conhecido como treinamento, consiste no processo de adaptação dos pesos sinápticos das conexões dos neurônios em resposta às entradas. A ativação consiste no processo de receber uma entrada e produzir uma saída de acordo com a arquitetura da RNA (HAYKIN, 2007).

O treinamento de uma RNA, marcado pela modificação dos valores dos pesos, é realizado por um conjunto de regras bem definido denominado de algoritmo de treinamento. O treinamento de uma RNA pode ser realizado de duas formas:

- Supervisionado: Neste a entrada e saída desejada são fornecidas anteriormente para a RNA. Então a cada padrão de entrada submetido à rede, compara-se a resposta desejada com a obtida pela RNA e ajustam-se os pesos das conexões para minimizar o erro;

- Não-supervisionado: Neste a RNA recebe um conjunto de entradas sem a respectiva saída desejada e busca encontrar propriedades no conjunto de dados. A partir destas propriedades que o aprendizado é constituído.

Existem muitos tipos de algoritmos de treinamento específicos para determinados modelos de RNA, como por exemplo, o algoritmo de Retropropagação do Erro e o de Seleção de Centros Auto-Organizados, o primeiro para a rede neural MLP e o segundo para a rede neural RBF. Estes algoritmos diferem entre si pelo modo como os pesos são modificados.

### 3.2.2 Rede Neural Artificial com Perceptrons em Múltiplas Camadas

A rede neural artificial MLP tem sido empregada com sucesso em diversas áreas do conhecimento como aproximação de funções (HAYKIN, 2007), classificação de padrões (DUDA et al., 2000), controle de navegação de VANTs (KIM; CALISE, 1997), entre outros.

Uma rede neural artificial MLP é constituída por três camadas, a primeira de entrada composta por neurônios não-computacionais sensitivos, esses recebem estímulos do ambiente para a sua ativação. Uma segunda, formada por uma ou mais camadas ocultas, constituídas por neurônios computacionais, são esses neurônios que capacitam a rede neural MLP na resolução de problemas complexos, ao extrair as características mais significativas dos padrões a ela apresentados. E a terceira e última, formada por uma camada de saída com neurônios computacionais.

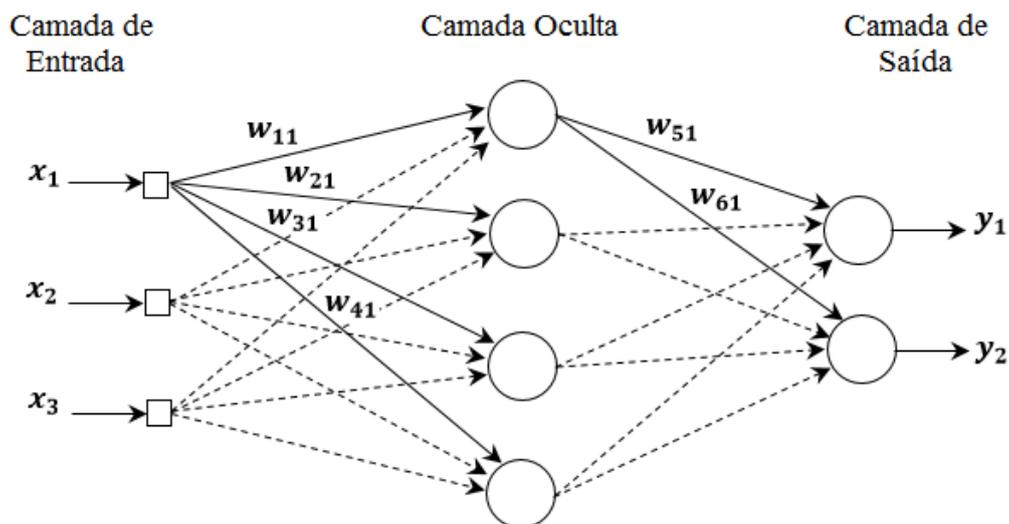
A rede neural artificial MLP tem sido aplicada para resolver problemas difíceis, sendo treinada de forma supervisionada com um algoritmo, conhecido como retropropagação do erro (do inglês, *error back-propagation*) (HAYKIN, 2007). Este algoritmo fundamenta-se no ajustamento dos pesos para minimizar a diferença entre a resposta desejada e a saída da rede. O algoritmo de retropropagação de erro consiste de dois passos (HAYKIN, 2007):

- Propagação: nesta fase do algoritmo os pesos sinápticos (parâmetros livres) da rede neural MLP são todos mantidos fixos. Uma saída é produzida pela rede e seu valor é subtraído da saída desejada, produzindo um sinal de erro.

- Retropropagação: nesta fase do algoritmo o erro calculado na fase de propagação é retro-propagado pela rede neural MLP, camada após camada, para realizar a correção dos pesos sinápticos da rede neural MLP segundo uma regra de correção. Os pesos sinápticos são ajustados para fazer com que a resposta da rede neural MLP se aproxime da resposta desejada.

A Figura 3.6 ilustra um exemplo de arquitetura de uma rede neural MLP, constituída de uma camada de entrada, uma oculta e uma de saída.

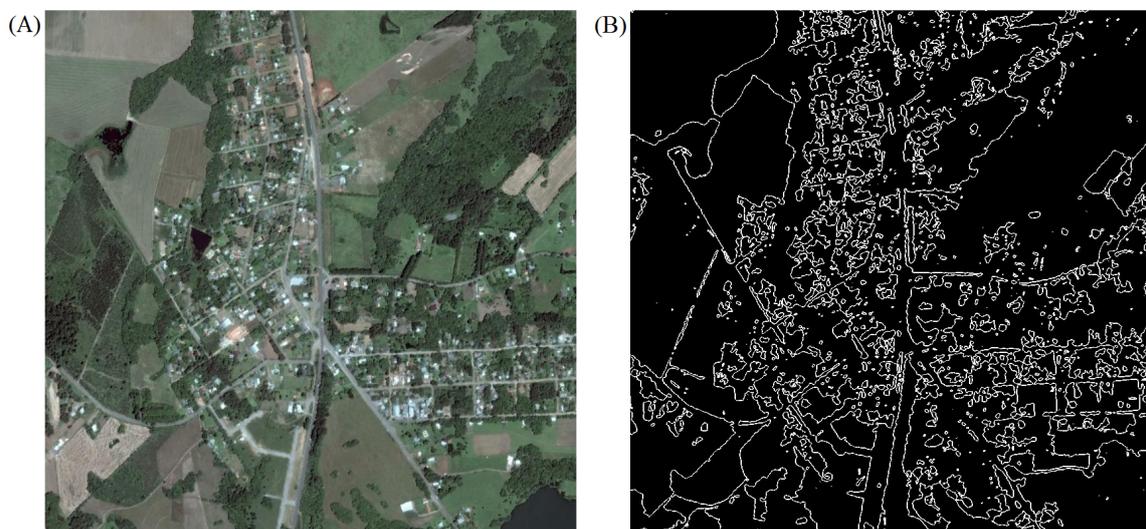
Figura 3.6 - Arquitetura de uma rede neural artificial MLP.



Fonte: Adaptada de Haykin (2007).

Uma abordagem para usar redes neurais na detecção de bordas consiste em treinar as redes neurais a reconhecer elementos de bordas (padrões) na imagem. Depois de treinada, a rede neural MLP é ativada para a detecção de bordas. A rede recebe como entrada a janela da imagem onde pretende-se extrair bordas. Os parâmetros para o funcionamento da rede são aqueles obtidos durante o treinamento. A Figura 3.7 ilustra a extração de bordas realizada pela rede neural MLP.

Figura 3.7 - Detecção de bordas por rede neural artificial MLP.



Em (A) a imagem original e em (B) a extração feita pela rede neural MLP.

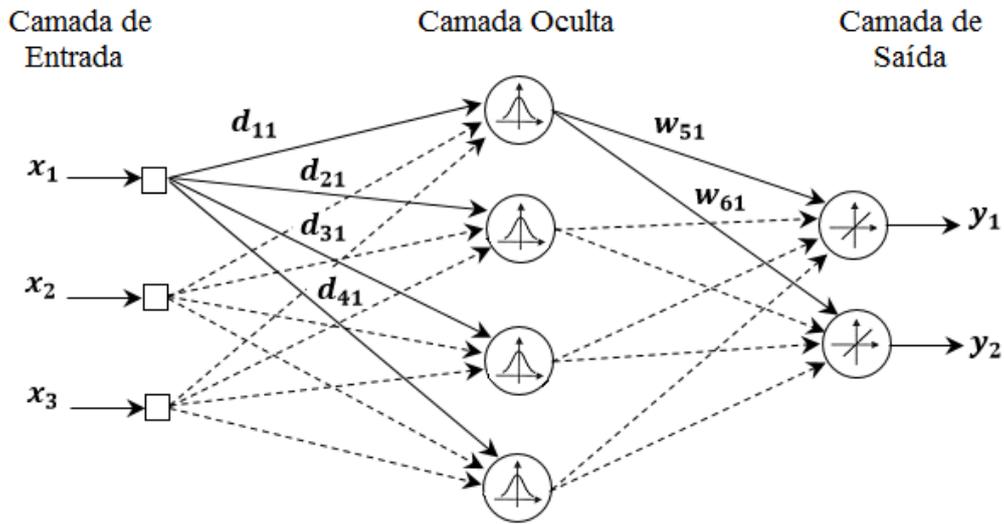
Fonte: Produção do autor.

### 3.2.3 Rede Neural Artificial com Funções de Base Radial

Uma rede neural artificial RBF tem sua arquitetura formada por três camadas, sendo a primeira a de entrada composta por neurônios não-computacionais sensitivos, esses neurônios recebem estímulos do ambiente para sua ativação. A segunda é a camada oculta, formada por neurônios computacionais, cuja função de ativação é uma função de base radial, que aplica uma transformação não-linear sobre os dados de entrada. A terceira e última é a camada de saída, também formada por neurônios computacionais, que possuem uma função de ativação linear, que aplicam uma transformação linear sobre os dados vindos da camada oculta (HAYKIN, 2007).

A Figura 3.8 ilustra um exemplo de arquitetura de uma rede neural RBF, constituída de uma camada de entrada, uma camada oculta e uma camada de saída.

Figura 3.8 - Arquitetura de uma rede neural artificial RBF.



Fonte: Adaptada de Haykin (2007).

As funções de base radial são uma classe de função cujo valor cresce ou decresce em relação à distância de um ponto central. Uma das muitas funções que satisfazem a definição de função de base radial é a função gaussiana que é a mais comumente utilizada (HAYKIN, 2007):

$$\varphi(x) = \exp\left(-\frac{v^2}{2 \times \sigma^2}\right) \quad (3.6)$$

onde  $v = \|x - \mu\|$  é a distância euclidiana entre  $\mu$  e  $x$ ,  $\mu$  representa o centro da função radial. O valor da largura  $\sigma_j$  da função gaussiana 3.6, do *centróide* $_j$ , é calculado por:

$$\sigma_j = \frac{\sum_{i=1}^{i=n} \|\mu_j - \mu_i\|^2}{n} \quad (3.7)$$

onde  $n$  é a quantidade de centros.

O treinamento de uma rede neural artificial RBF consiste da determinação dos parâmetros  $\mu$  (centro) e  $\sigma$  (largura ou desvio padrão desejado) da função radial e, também, da determinação dos pesos (valores das conexões) entre a camada oculta e a camada de saída. Após o treinamento, a RNA já treinada é empregada na etapa de ativação.

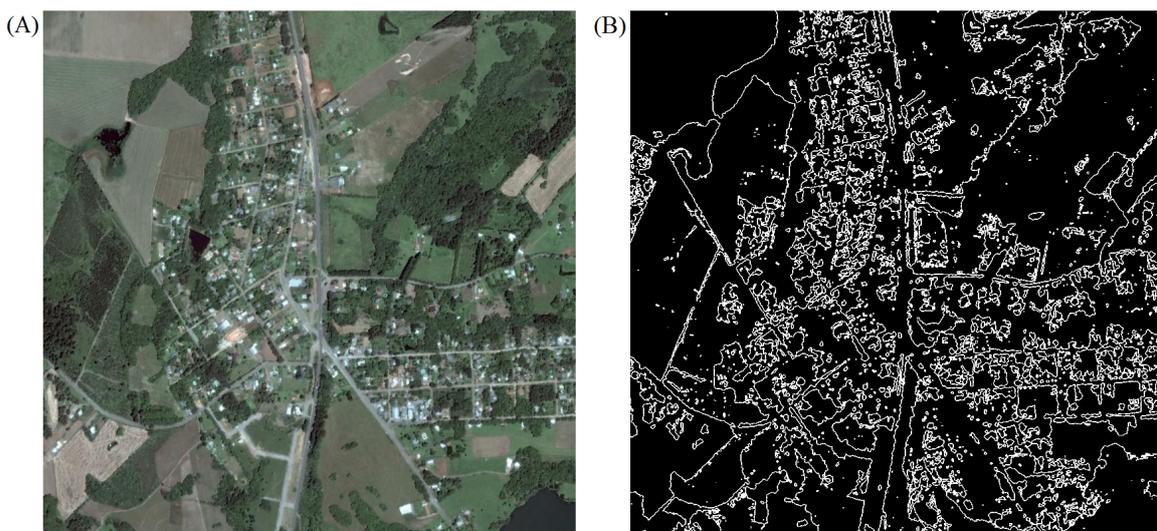
Há várias estratégias de treinamento para uma rede neural RBF que determinam

de forma diferente os parâmetros citados (HAYKIN, 2007). Uma dessas estratégias e que será empregada nesta proposta é a *Seleção de Centros Auto-Organizadas* que é composta por dois passos:

- Passo 1 - seleção de forma não-supervisionada dos centróides a partir dos padrões de treinamento, por meio de um algoritmo de agrupamento, por exemplo, o  $k$ -médias.
- Passo 2 - determinação dos valores dos pesos das conexões entre a camada oculta e a camada de saída utilizando um algoritmo de aprendizagem supervisionada.

Uma metodologia que pode ser adotada para utilizar a rede neural RBF na tarefa de detecção de bordas consiste em treinar as redes neurais a reconhecer elementos de bordas (padrões) na imagem. Depois de treinada, a rede neural MLP é ativada para a detecção de bordas. A rede recebe como entrada a imagem que se pretende extrair bordas. Os parâmetros utilizados na rede são aqueles mesmos obtidos durante o treinamento. A Figura 3.9 ilustra a extração de bordas realizada pela rede neural artificial RBF.

Figura 3.9 - Detecção de bordas por rede neural artificial RBF.



Em (A) a imagem original e em (B) a extração feita pela rede neural artificial RBF.

Fonte: Produção do autor.

### 3.2.4 Configuração Automática de Redes Neurais Artificiais

As RNAs têm sido aplicadas com sucesso em diversas áreas do conhecimento, mas ainda é um desafio a determinação de uma arquitetura ótima da RNA para a resolução do problema proposto (HAYKIN, 2007) (LUZ, 2012) (ANOCHI, 2015). Geralmente essa determinação é feita de forma empírica baseada na seguinte sequência:

- a) Escolha dos parâmetros livres da RNA: número de camadas escondidas, número de neurônios em cada camada, taxa de aprendizado e momento e tipo de função de ativação;
- b) Treinamento da RNA na configuração adotada;
- c) Teste de generalização da RNA;
- d) Avaliação dos resultados produzidos pelas diversas arquiteturas e seleção da melhor.

Este processo empírico não garante que a arquitetura selecionada seja a melhor para a resolução do problema. A escolha de uma arquitetura adequada é essencial, pois se uma RNA é configurada com uma quantidade pequena de neurônios pode não ser capaz de aprender os padrões apresentados, todavia, uma grande quantidade de neurônios pode causar dificuldades na generalização (HAYKIN, 2007).

Uma maneira de encontrar uma arquitetura ótima para uma RNA é a utilização do Algoritmo de Colisão de Múltiplas Partículas, que encontra de forma automática os parâmetros para a determinação da arquitetura ótima da rede. Esse algoritmo foi comparado com outros algoritmos para determinação da arquitetura ótima da RNA e apresentou melhores resultados (ANOCHI, 2015).

#### 3.2.4.1 Algoritmo de Colisão de Múltiplas Partículas

O MPCA é uma meta-heurística introduzida por Luz (2012), que realiza a busca pela configuração ótima de uma função objetiva. O MPCA é uma extensão do Algoritmo de Colisão de Partículas (PCA, do inglês, *Particle Collision Algorithm*) proposto por Sacco et al. (2009), que foi inspirado nos fenômenos que ocorrem em um reator nuclear, principalmente, nas reações de espalhamento e absorção. As principais etapas do PCA são:

- a) O usuário fornece ao algoritmo uma configuração inicial dos parâmetros da função objetiva: *ConfiguraçãoAbsorvida* ;

- b) O algoritmo cria uma nova configuração para essa função objetivo: *Configuração Gerada*;
- c) O algoritmo compara as respostas obtidas por essas configurações, e seleciona (**Absorve**) a configuração de melhor resposta: *Configuração Absorvida*;
- d) O algoritmo descarta (**Espalha**), a partir de uma probabilidade calculada, a configuração de pior resposta da função objetivo, *Configuração Gerada = vazio*;
- e) Retorna ao passo (b) ou termina a execução caso tenha atingido um limite pré-determinado.

No MPCA, proposto por Luz (2012), realiza-se a busca pela configuração ótima de uma função objetiva de forma semelhante ao PCA, mas no MPCA introduz-se o conceito de exploração múltipla e simultânea ao invés de uma única exploração, ou seja, diferente do PCA onde todo o processo ocorre em uma única partícula, no MPCA esse processo ocorrerá em inúmeras partículas simultaneamente. Para coordenar esta busca multi-explorativa é empregada uma função de comunicação entre processos: *QuadroNegro*. Desta forma, é inserido mais um passo no algoritmo descrito anteriormente:

- (f) Na função *QuadroNegro*, seleciona-se, entre todas as configurações geradas por cada partícula a que gera uma resposta melhor, do que a configuração armazenada em *Configuração Absorvida*.

Cada partícula (configuração candidata) pode seguir uma *história independente*, que é compartilhada via função *QuadroNegro*. Nos trabalhos de Carvalho (2011) e Anochi (2015) foi empregada uma função objetiva que determina a configuração ótima de uma RNA:

$$f_{obj} = penalty \times \left( \frac{\rho_1 \times E_{train} + \rho_2 \times E_{gen}}{\rho_1 + \rho_2} \right) \quad (3.8)$$

onde  $\rho_1$  e  $\rho_2$  são fatores de ajustes que modificam a relevância atribuídas aos  $E_{train}$  (erro de treinamento) e  $E_{gen}$  (erro de generalização) respectivamente, e o termo

*penalty* (penalidade) é utilizado para evitar arquiteturas complexas (número alto de neurônios). Para os fatores de ajuste Carvalho (2011) propõe  $\rho_1 = 1$  e  $\rho_2 = 0, 1$ .

O erro de treinamento é obtido por:

$$E_{train} = \frac{1}{N_t} \sum_{k=1}^{N_t} (d_k - \hat{y}_k)^2 . \quad (3.9)$$

O erro de generalização é obtido por:

$$E_{gen} = \frac{1}{N_g} \sum_{k=1}^{N_g} (y_k - \hat{y}_k)^2 \quad (3.10)$$

onde  $N_t$  é o número de padrões apresentados à RNA no treinamento e  $N_g$  na generalização,  $d_k$  é a saída desejada apresentada durante o treinamento,  $\hat{y}_k$  é a saída da RNA e  $y_k$  é a resposta desejada no teste de generalização.

Dessa forma, a otimização da arquitetura de uma RNA é a aquisição de arquiteturas que apresentam um desempenho tão próximo quanto possível de um ótimo global, em outras palavras, é a busca de arquiteturas com baixos erros de treinamento e generalização.

### 3.3 Estimação da Posição Geográfica do VANT

Uma das formas mais empregadas para se estimar a posição do VANT é com o uso de GPS combinado com INS (YOO; AHN, 2003). Contudo existe o risco dessa tecnologia não estar disponível ou apresentar falhas, pois o GPS apesar de ser um sistema preciso é uma tecnologia controlada por nação estrangeira, está suscetível a perda de sinal (LIMA, 2005) e pode apresentar falhas devido a influência da SAMA (HARTMANN, 1996). Enquanto que o INS apesar de não depender de sinal emitido por fonte externa e sim do bom funcionamento dos sensores inerciais acoplados à aeronave, necessita de correções, pois possui um erro de posicionamento calculado por ele que cresce ao longo do tempo (LIMA, 2005).

Uma alternativa de se fazer essa estimação da posição geográfica do VANT, que não faz uso de GPS para correção do INS é a aplicação de técnicas de processamento de imagens para realizar a correção do INS. Nesta abordagem existem duas principais metodologias. A primeira delas é através de marcos presentes no terreno, nesta metodologia a partir de uma imagem de satélite georreferenciada da rota pré-definida, são estabelecidos marcos fixos no terreno onde o VANT irá sobrevoar. Nessa imagem da rota são usadas técnicas de processamento de imagens como extração de caracte-

rísticas de textura, aplicação de filtro de Gabor, identificação de formas geométricas, entre outras. Durante o voo, para identificar os marcos nas imagens capturadas pela aeronave, são utilizadas nestas a mesma tecnologia aplicada à imagem da rota. Após a identificação é utilizada a localização destes marcos, na imagem georreferenciada, para fazer a estimação da posição da aeronave e correção do INS.

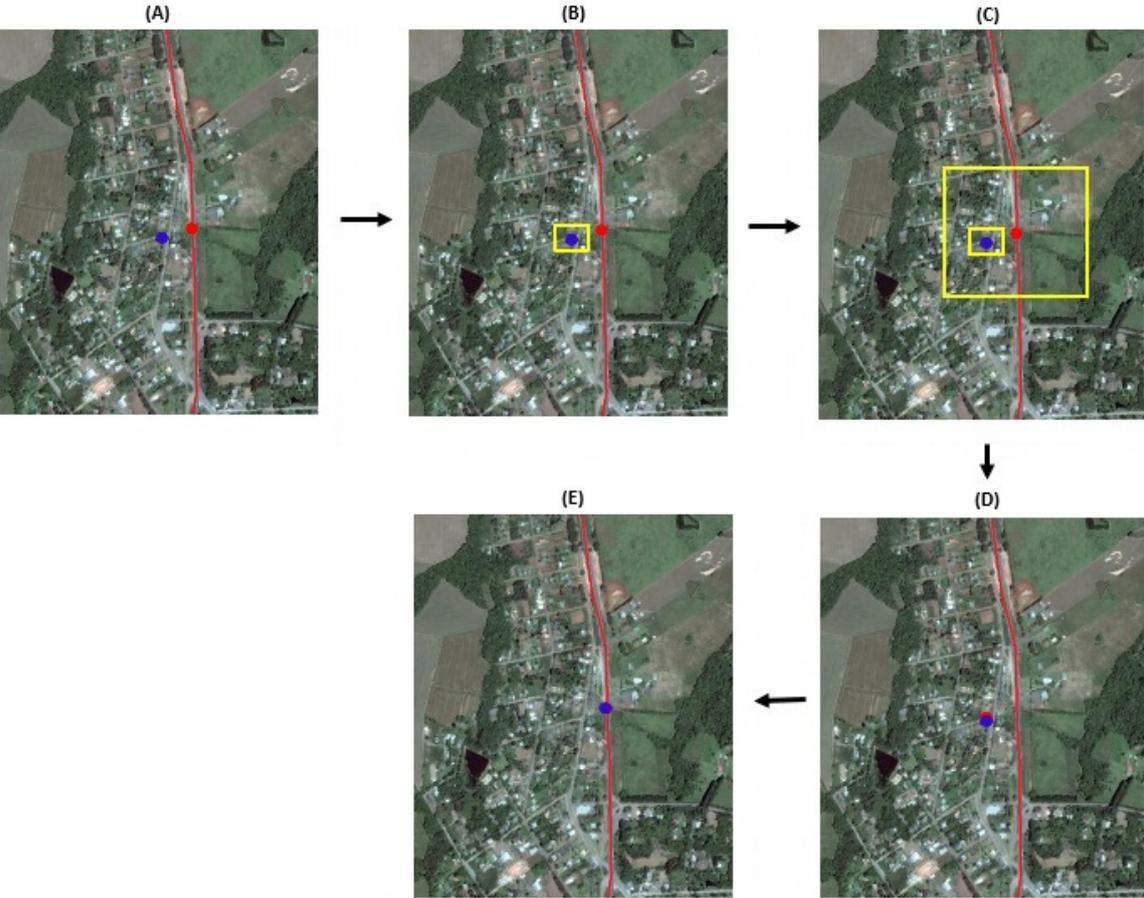
A outra metodologia que pode ser aplicada para estimar a posição do VANT, utilizando a combinação de INS e processamento de imagens é realizada através da correlação entre uma imagem aérea capturada pelo VANT em tempo de voo e uma de satélite georreferenciada, onde são conhecidas as coordenadas em cada ponto da imagem. Nesta abordagem não é necessário um marco específico. Para identificar a área correspondente da imagem do VANT na imagem de satélite, é realizada a correlação de tais imagens com o intuito de reconhecer automaticamente o local sobrevoado e corrigir uma rota pré-planejada (CONTE; DOHERTY, 2008).

A Figura 3.10 mostra o processo de navegação autônoma de VANT, com a estimação da posição da aeronave realizada por meio de processamento de imagens combinado com informações do INS e com uma abordagem que não faz uso de marcos específicos.

Esse processo de navegação autônoma do VANT é realizado da seguinte forma:

- (A) - A linha vermelha na imagem representa a rota pré-definida, o ponto vermelho a posição dada pelo INS ao VANT. O ponto azul representa a posição real do VANT naquele determinado momento;
- (B) - O VANT captura uma imagem da região por ele sobrevoada, essa região está representada na imagem por um retângulo amarelo;
- (C) - A imagem da região sobrevoada pelo VANT é buscada em uma imagem de satélite georreferenciada, representada pelo retângulo amarelo maior;
- (D) - Realiza-se a convolução entre as imagens. O resultado da convolução é uma matriz cujo o ponto de maior valor representa a localização do VANT na imagem de satélite georreferenciada. Com essa localização é possível determinar a posição geográfica do VANT e corrigir a posição do INS;
- (E) - Utilizando um sistema de controle ou piloto automático embarcado, o VANT é conduzido para a rota.

Figura 3.10 - Navegação Autônoma de VANT: processamento de imagem + INS.



Fonte: Produção do autor.



## 4 NAVEGAÇÃO AUTÔNOMA BASEADA EM IMAGEM NO INFRATERMELHO TERMAL

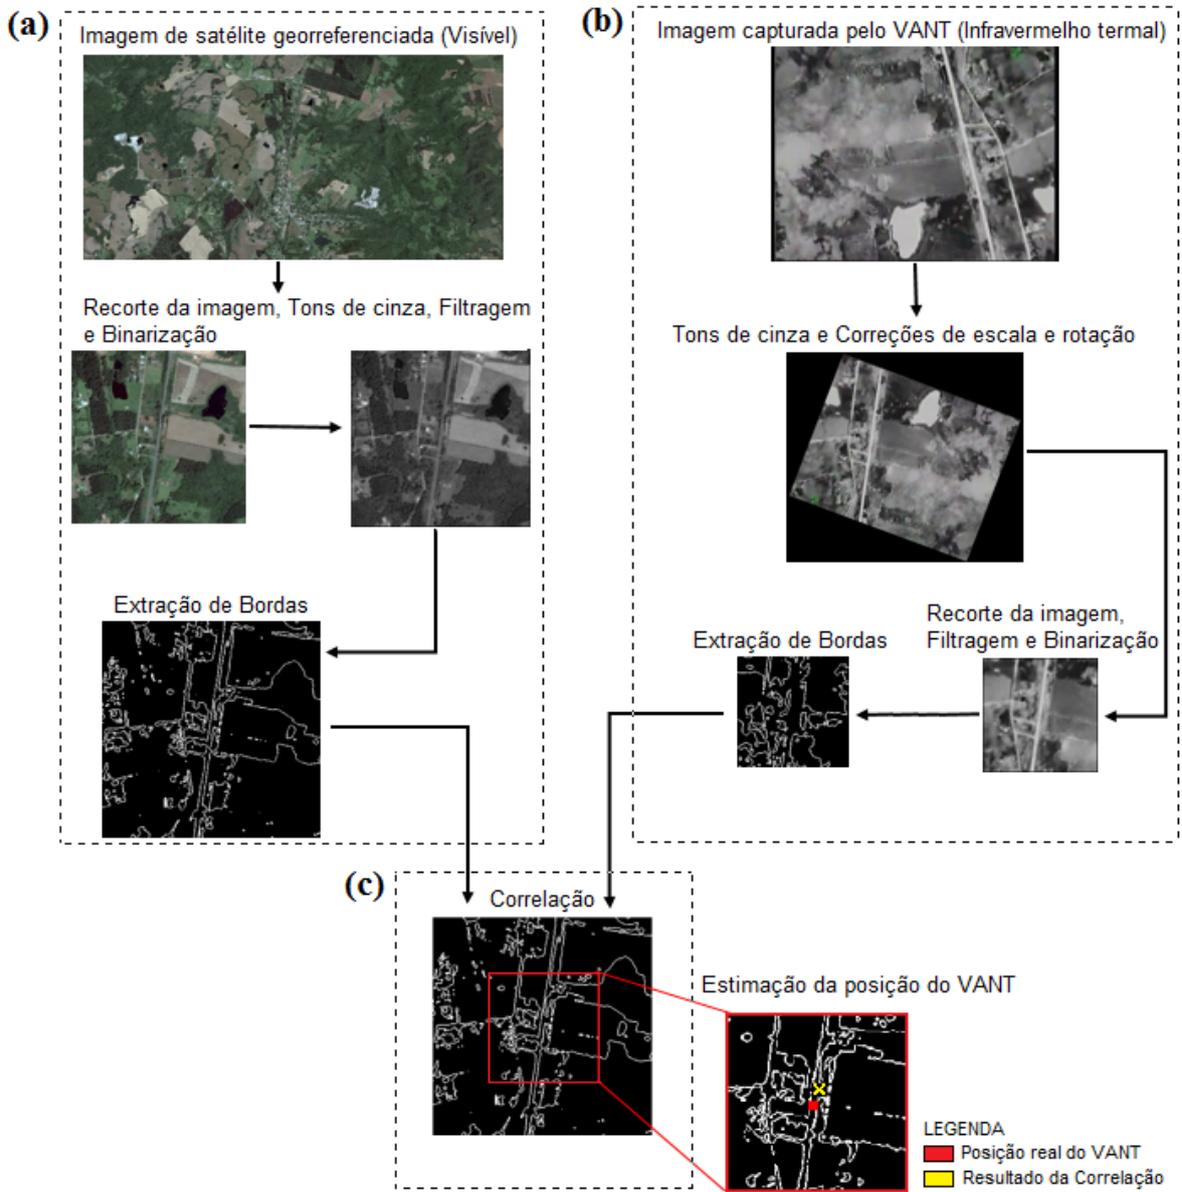
Neste capítulo são apresentados os métodos e os materiais utilizados no desenvolvimento desta dissertação de mestrado. Na **Seção 4.1** são apresentados os métodos, utilizados nesta dissertação de mestrado, que fazem uso de imagens do VANT capturadas por um sensor infravermelho termal. E que possibilita, desta forma, a estimação da posição do VANT no período noturno. Na **Seção 4.2** são apresentadas as características dos sensores, tanto na banda do visível quanto na do infravermelho termal, utilizados para a captura das imagens. Nesta seção são também apresentadas as imagens capturadas por um sensor infravermelho termal, utilizadas para geração dos resultados em rota pré-definida. Além disso, esta seção também apresenta as imagens utilizadas para geração dos resultados preliminares, onde a estimação da posição é feita para uma única região, utilizando os sensores na banda do visível e do infravermelho termal. Na **Seção 4.2.1** são apresentadas as imagens utilizadas e as características do sensor na banda do visível do VANT, que capturou tais imagens. Na **Seção 4.2.2** são apresentadas as imagens utilizadas e as características do sensor na banda do infravermelho termal do VANT, que capturou tais imagens.

### 4.1 Métodos

Os métodos empregados nesta dissertação de mestrado estão baseados nas pesquisas desenvolvidas em [Goltz \(2011\)](#), [Conte e Doherty \(2008\)](#) e em [Sjanic \(2011\)](#) que descrevem técnicas para a orientação da trajetória de VANTs por meio de processamento de imagens e sem a utilização de GPS. Neste presente trabalho é empregada a abordagem de estimação de posição a partir de imagens embarcadas no VANT e casamento de padrões. As três pesquisas citadas anteriormente estão fundamentadas no processo de extração de bordas e posterior Cálculo do Coeficiente de Correlação entre a imagem capturada pela câmera do VANT e uma imagem de satélite georreferenciada. Nos trabalhos de [Goltz \(2011\)](#) e [Conte e Doherty \(2008\)](#) ambas as imagens, tanto a do VANT quanto a de satélite, são capturadas por um sensor óptico passivo e na banda do visível, enquanto no trabalho de [Sjanic \(2011\)](#) a imagem de satélite foi capturada por um sensor na banda do visível e a do VANT é uma imagem SAR.

Na [Figura 4.1](#) são apresentados os métodos dessa dissertação de mestrado, que consistem na aplicação de técnicas de processamento de imagens para serem embarcadas em um VANT, a fim de estimar a posição sobrevoada no período noturno. Para tanto, são empregadas imagens aéreas no infravermelho termal, possibilitando assim o voo noturno.

Figura 4.1 - Métodos desta dissertação de mestrado.



Fonte: Produção do autor.

Os métodos apresentados na Figura 4.1 estão divididos em duas partes: o processamento da imagem de satélite georreferenciada, identificada pelas linhas pontilhadas e a letra (a), e o processamento da imagem aérea capturada pelo VANT, identificado pelas linhas pontilhadas e pela letra (b).

Para o processamento da imagem de satélite georreferenciada, tem-se:

- Obtenção da imagem de satélite georreferenciada (sensor na banda do visível), que podem ser obtidas por satélites ou voos prévios. Neste trabalho é empregada a estratégia de uso de um sistema inercial para restringir a região de busca. Isso é possível devido à existência destes sensores na maioria dos VANTs (XMOBOTS, 2016). Com isso, são utilizadas informações de posicionamento do INS para realizar um corte na imagem de satélite, com o objetivo de restringir a região de busca;
- Transformação da imagem de satélite em tons de cinza. Esse processo é necessário anteriormente ao processo de filtragem e binarização, pois o algoritmo de binarização Otsu, utilizado nesta dissertação, trabalha com imagens em tons de cinza. Como apresentado na literatura Gonzalez e Woods (2011), na conversão de uma imagem RGB para tons de cinza não há perda significativa para esse tipo de aplicação;
- Filtragem da imagem: Filtro de Mediana e Filtro Gaussiano. Esse processo é utilizado para eliminar ruídos e características indesejáveis (CONTE; DOHERTY, 2008). Pois as imagens de VANT e as de satélite, além de serem de sensores diferentes, foram também capturadas em períodos de tempo diferentes;
- Binarização da imagem (Somente no caso de o extrator de bordas utilizado ser uma RNA). As RNAs são técnicas eficientes na classificação de padrões binarizados de bordas (LI et al., 2008) (TERRY; VU, 1993) (HE; SIYAL, 1998). Dessa forma, o processo de binarização de imagem é utilizado nesta pesquisa;
- Extração das bordas da imagem: Canny, Sobel, rede neural RBF e rede neural MLP (MPCA). Esse processo é utilizado porque as imagens são oriundas de sensores diferentes e é desejável manter apenas as características principais para o processo de correlação.

Para o processamento da imagem aérea capturada pelo VANT, tem-se:

- Obtenção da imagem aérea capturada em tempo real pelo VANT, por meio de um sensor infravermelho termal;

- Correção de escala e rotação, com utilização de informações de altímetro e bússola do VANT respectivamente, estas informações são obtidas pelos sensores embarcados. Esse procedimento é realizado para se diminuir o erro do processo de identificação do local sobrevoado. Neste trabalho é utilizado o Cálculo do Coeficiente de Correlação. A variação de ângulo de visada não é considerada, pois a câmera pode ficar com visada NADIR com uso de Torretas (do inglês, *Gimbal*);
- Transformação da imagem do VANT em tons de cinza. Assim como na imagem georreferenciada, na imagem capturada pelo VANT também é feita essa transformação;
- Recorte da imagem capturada pelo VANT, para eliminar regiões da imagem sem informação, geradas após a correção da rotação;
- Filtragem da imagem: Filtro de Mediana e Filtro Gaussiano. Assim como realizado na imagem de satélite georreferenciada;
- Binarização da imagem (Somente no caso de o extrator de bordas utilizado ser uma RNA);
- Extração das bordas da imagem: Canny, Sobel, rede neural RBF e rede neural MLP (MPCA).

Após o processamento das duas imagens é realizado o Cálculo do Coeficiente de Correlação, ilustrado na linha tracejada (c), entre a imagem de satélite georreferenciada processada e a imagem aérea capturada pelo VANT e processada a fim de ser feita a estimativa da posição do VANT.

#### 4.1.1 Extração de bordas pelas RNAs

Um passo importante do processo de navegação autônoma por imagens é a extração de bordas presentes nas imagens georreferenciadas e obtidas pelo VANT, pois esta informação tende a estar presente em ambas as imagens, mesmo com variação de iluminação, tipos de sensores ou condição climática.

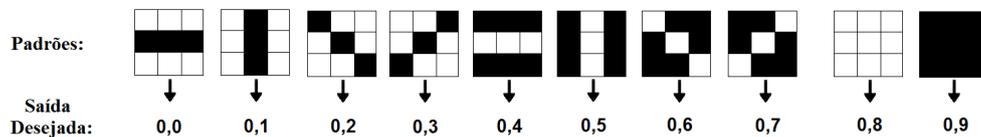
As redes neurais são empregadas com sucesso no processo de extração de bordas, principalmente devido à capacidade de generalização, tolerância a variações nas imagens e a ruídos, desde que devidamente treinadas.

Nesta dissertação são utilizadas diferentes RNAs, com aprendizagem supervisionada. Com isso, o treinamento e ativação para o processo de extração de bordas são realizados da seguinte forma:

Para o processo de treinamento das RNAs foram utilizados dois conjuntos de padrões: Um conjunto de 10 padrões, sendo 8 padrões de borda e 2 de não-borda; e outro conjunto contendo 26 padrões, sendo 24 padrões de borda e 2 de não-borda. O conjunto de 10 padrões utilizados nessa dissertação foram os mesmos apresentados em Goltz (2011) e o conjunto de 26 os mesmos descritos em Braga et al. (2016) . Este teste foi importante para analisar a hipótese se um conjunto de treinamento da RNA com mais detalhes (padrões) apresenta melhores resultados.

Ambos os conjuntos de padrões são descritos por uma matriz binária com dimensão  $3 \times 3$ . A Figura 4.2 e a Figura 4.3 ilustram esses padrões utilizados e a suas respectivas saídas desejadas.

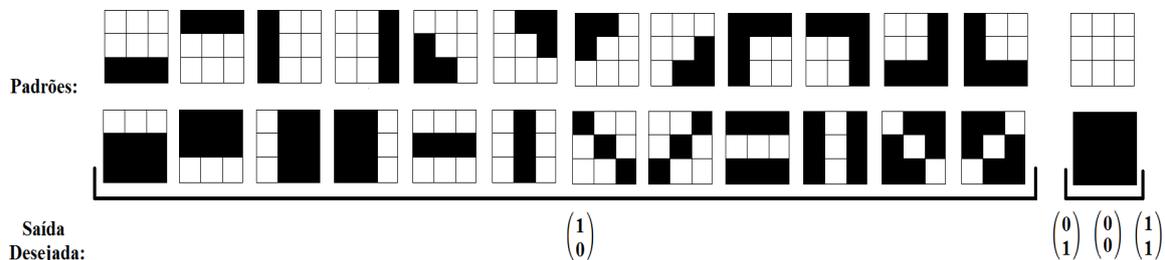
Figura 4.2 - Padrões de bordas e de não-bordas utilizados para treinamento da rede neural MLP e da rede neural RBF.



Fonte: Goltz (2011).

A camada de saída das RNAs, treinadas com os 10 padrões, é formada por um único neurônio computacional, onde valor menor que 0,8 corresponde a um valor de borda e valor igual ou maior que 0,8 corresponde a um valor de não-borda.

Figura 4.3 - Novos Padrões de bordas e de não-bordas utilizados para treinamento da rede neural MLP e da rede neural RBF.

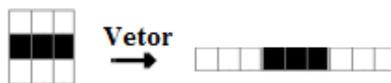


Fonte: Braga et al. (2016).

A camada de saída das RNAs treinadas com os 26 padrões é formada por dois neurônios computacionais que produzem como resposta um vetor, onde o vetor  $\begin{pmatrix} 1 \\ 0 \end{pmatrix}$  representa a um valor de borda e os vetores  $\begin{pmatrix} 0 \\ 1 \end{pmatrix}$ ,  $\begin{pmatrix} 0 \\ 0 \end{pmatrix}$  e  $\begin{pmatrix} 1 \\ 1 \end{pmatrix}$  correspondem a um valor de não-borda.

A camada de entrada das RNAs é composta de nove neurônios sensitivos (não-computacionais), que recebe para treinamento um vetor de dimensões  $1 \times 9$ , correspondente a uma matriz de dimensão  $3 \times 3$  com valores binários que representam cada um dos padrões de treinamento. A Figura 4.4 ilustra um exemplo da transformação da matriz de um padrão de entrada em vetor.

Figura 4.4 - Processo de transformação da uma matriz de um padrão em vetor.

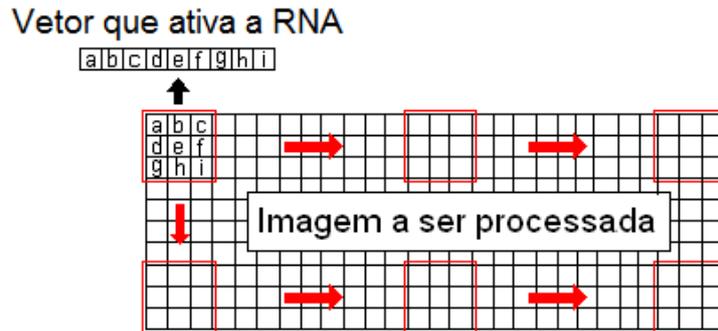


Fonte: Produção do autor.

A ativação da RNA é feita por meio de uma janela de  $3 \times 3$  pixels, que percorre uma matriz binarizada da esquerda para a direita, de pixel em pixel, formando o vetor de entrada com dimensão  $1 \times 9$ ; ao chegar ao final da linha a janela decai

um pixel, iniciando a nova operação à esquerda da imagem. A Figura 4.5 ilustra este processo. O limiar para realizar a binarização da imagem foi determinado pelo método de Otsu. Este método foi escolhido, pois este é um método que se adapta a luminosidade da imagem (OTSU, 1979).

Figura 4.5 - Processo de ativação das RNAs.



Fonte: Goltz (2011).

A saída da RNA, que foi treinada com o conjunto de 10 padrões apresentados na Figura 4.2, é um escalar. Se esse valor for menor que 0,8 corresponderá a um padrão de borda e o ponto central da janela receberá o valor 1. Caso esse valor seja igual ou maior que 0,8 o ponto central da janela não representará uma borda e receberá o valor 0.

A saída da RNA, que foi treinada com o conjunto de 26 padrões apresentados na Figura 4.3, é um vetor. Se o vetor for  $\begin{pmatrix} 1 \\ 0 \end{pmatrix}$  o valor assumido pelo ponto central da janela será 1 e corresponderá a um padrão de borda. Caso o vetor seja  $\begin{pmatrix} 0 \\ 1 \end{pmatrix}$ ,  $\begin{pmatrix} 0 \\ 0 \end{pmatrix}$  ou  $\begin{pmatrix} 1 \\ 1 \end{pmatrix}$  o ponto central da janela receberá o valor 0 e não representará uma borda.

#### 4.1.2 Estimação da Posição do VANT por casamento de padrões

Existem diferentes abordagens para se realizar a estimação da posição de um VANT através da correlação entre duas imagens, entre elas podem ser citados: quadrado da diferença entre as matrizes da imagem; Cálculo do Coeficiente de Correlação entre as matrizes da duas imagens; e Cálculo do Coeficiente de Correlação das matrizes das duas imagens. Este último método foi escolhido, pois apresentou resultados promissores em Goltz (2011) e Conte e Doherty (2008).

Para fazer a estimação da posição do VANT, é possível realizar o Cálculo do Coeficiente de Correlação entre as imagens das bordas das imagens aéreas capturadas pelo VANT e de satélite georreferenciada. Esse cálculo resulta em uma matriz cujo o seu maior valor representa a posição do VANT na imagem de satélite. O Cálculo do Coeficiente de Correlação é determinado por:

$$c(s, t) = \sum_x \sum_y (f(x, y) \times w(x - s, y - t)) \quad (4.1)$$

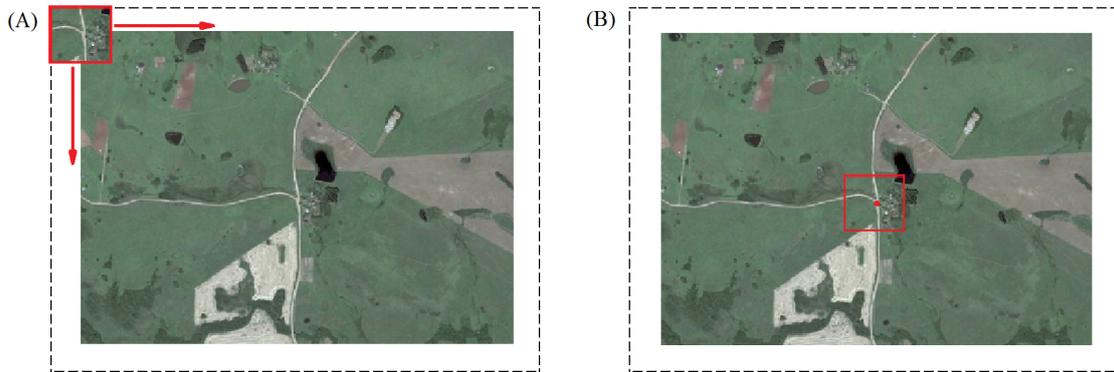
onde  $c(s, t)$  é a matriz de correlação  $c$  de índices  $s$  e  $t$  com  $s = 0, 1, \dots, M$  e  $t = 0, 1, \dots, N$ ,  $M$  e  $N$  são as dimensões da matriz  $f$  que contém as bordas da imagem de satélite, e a matriz  $w$  com dimensões  $J \times K$ , com  $J \leq M$  e  $K \leq N$  que contém as bordas da imagem aérea.

Para identificar a área correspondente da imagem do VANT  $w$  na imagem de satélite  $f$ , realiza-se a sua correlação com a imagem de satélite, pelo processo de convolução.

Por convolução entende-se a movimentação da imagem do VANT pixel a pixel (da esquerda para a direita e de cima para baixo), assim como apresentado na Figura 4.7 (A), nesta a imagem menor corresponde a imagem do VANT  $w$ , a maior corresponde a imagem de satélite  $f$  e a região tracejada corresponde a matriz de correlação  $c$ .

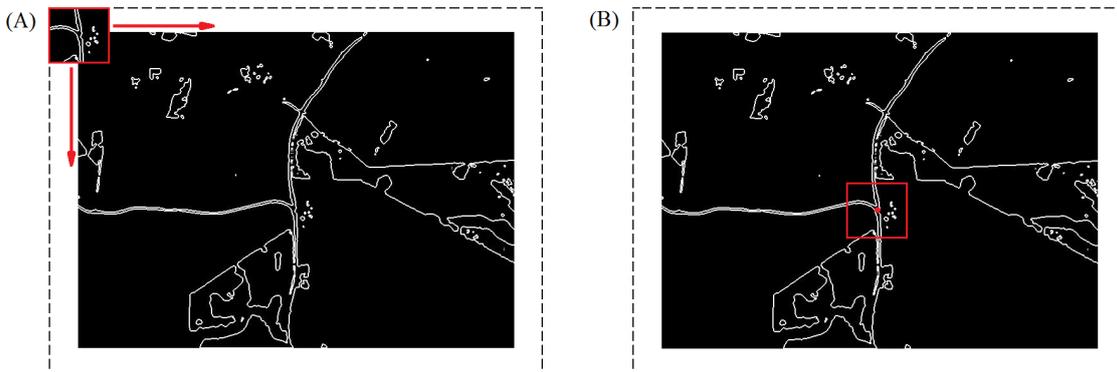
A cada posição percorrida na imagem o valor da Coeficiente de Correlação é calculado. O maior valor na matriz  $c$  (o maior valor da correlação) corresponde ao ponto central da imagem do VANT (esse ponto central é a posição da aeronave na imagem do VANT). Como a imagem de satélite é georreferenciada, as coordenadas do ponto de maior Coeficiente de Correlação podem ser obtidas usando-se as coordenadas do ponto em  $f$  que coincide com o ponto central de  $w$ . Dessa forma o processo de correlação e estimação da posição do VANT estará completo, o resultado desse processo é apresentado na Figura 4.7 (B). Na Figura 4.6 (A) e (B) é apresentado o processo de convolução, descrito anteriormente, nas imagens originais sem a aplicação do operador de extração de bordas.

Figura 4.6 - Processo de convolução de imagens.



Fonte: Produção do autor.

Figura 4.7 - Processo de convolução de imagens.



Fonte: Produção do autor.

Com esta informação é possível corrigir a informação do INS. Para o processo de correção da trajetória, apresentado na Figura 3.10, são utilizadas as coordenadas da posição do VANT estimada pelo processo de correlação e as coordenadas da posição pré-definida para a rota no planejamento. A condução pela rota planejada cabe ao piloto automático do VANT.

## 4.2 Características das imagens utilizadas

Nessa seção são apresentadas as características dos sensores e de todas as imagens utilizadas nessa dissertação de mestrado. São apresentadas as imagens utilizadas para geração dos resultados em uma rota pré-definida, sendo estas, capturadas por sensor embarcado no VANT na banda do infravermelho termal. São apresentadas também as imagens utilizadas para geração dos resultados iniciais de capacitação com o problema, na qual os métodos são aplicados a uma única região: para uma imagem capturada por um sensor embarcado no VANT na banda do visível e também para uma imagem capturada por um sensor embarcado no VANT na banda do infravermelho termal. Além disso, são apresentadas as imagens de satélite utilizadas, adquiridas por um sensor na banda do visível.

Nesta dissertação, as imagens de satélite empregadas como referência foram adquiridas por um sensor na banda do visível, esta escolha foi feita devido a maior disponibilidade deste tipo de imagem em comparação com imagens termais. O satélite que capturou essas imagens é o *Quickbird*. Na Tabela 4.1 são apresentadas as resoluções espaciais, espectrais e radiométricas deste satélite.

Tabela 4.1 - Resoluções do satélite *Quickbird*

Resolução Espacial	Pancromática: 0,60m Multiespectral: 2,80m
Resolução Espectral	Pancromática : 0,45 – 0,90 $\mu$ m Banda 1 - Azul: 0,45 – 0,52 $\mu$ m Banda 2 - Verde: 0,52 – 0,60 $\mu$ m Banda 3 - Vermelho: 0,63 – 0,69 $\mu$ m
Resolução Radiométrica	11 bits - 2048 níveis de cinza

Fonte: Globalgeo (2016).

A resolução espacial refere-se ao tamanho que um pixel da imagem representa na realidade. A espectral tem a ver com o número de bandas que os sensores existentes no satélite conseguem discretizar. A combinação das Bandas 1 (azul), 2 (verde) e 3 (vermelho) utilizam apenas as bandas da porção do visível eletromagnético, pois, é a que mais se aproxima das cores reais. No caso, as tonalidades de azul representam água, enquanto áreas urbanas aparecem em tonalidades de marrom claro, e a vege-

tação, em tons de verde. E por fim a resolução radiométrica que é o limite de tons de cinza que o sensor consegue detectar e armazenar, medidos em bits. O nível de cinza representa a intensidade de energia eletromagnética (refletida/emitida) média medida pelo sensor para a área da superfície da terra correspondente ao tamanho do pixel (MENESES; ALMEIDA, 2012).

#### 4.2.1 Imagem do VANT capturada por sensor na banda do visível

Os métodos aplicados nesta dissertação foram testados, em uma primeira fase, com imagens obtidas por sensores na banda do visível. A imagem empregada foi obtida de experimentos realizados pelo Instituto de Estudos Avançados (IEAv), subordinado ao Departamento de Ciências e Tecnologia Aeroespacial (DCTA). Nestes experimentos foram realizados voos sobre a cidade de São José dos Campos a uma altitude constante e em visada NADIR. Esse voo foi realizado no ano de 2006, por um helicóptero com suporte para câmeras, ilustrado na Figura 4.8.

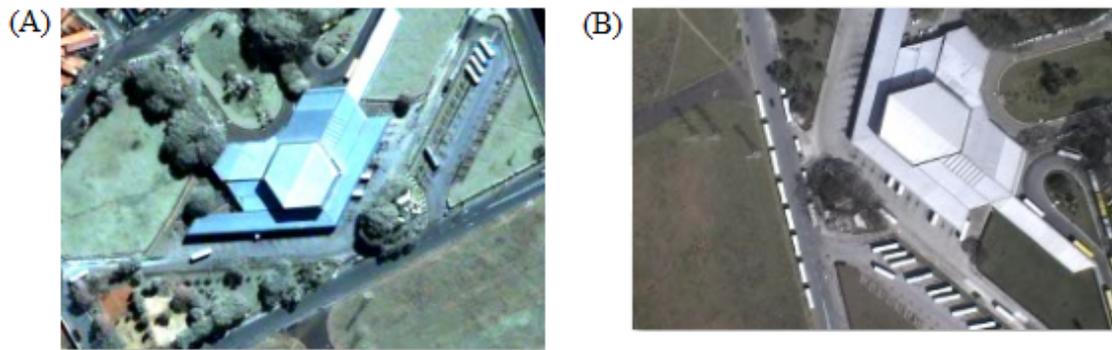
Figura 4.8 - Câmera acoplada ao helicóptero.



Fonte: Laboratório PITER (2016).

A Figura 4.9 ilustra a região utilizada para a obtenção de resultados. Esta região foi escolhida por ter sido empregada na dissertação de mestrado de Goltz (2011).

Figura 4.9 - Região selecionada para a produção dos resultados.



Em (A) é apresentada a imagem de satélite e em (B) a imagem aérea referente a mesma região da primeira, e ambas são imagens capturadas por sensor na banda do visível.

Fonte: Goltz (2011).

A imagem de satélite, da Figura 4.9, foi obtida com uso do sensor pancromático do satélite *Quickbird*, com resolução espacial de 0,6m. O imageamento é referente a maio de 2004 sobre a cidade de São José dos Campos, SP. Na Tabela 4.1 são apresentados as resoluções espacial, espectral e radiométrica deste satélite.

A imagem da Figura 4.9, foi obtida da videografia dos voos realizados pelo IEAv em 2006 a uma altitude constante e em visada nadir, também sobre a região de São José dos Campos, SP.

A dimensão da imagem de satélite é de  $480 \times 340$  pixels e a dimensão da imagem aérea é de  $191 \times 191$  pixels. Estas dimensões foram utilizadas por compreender a região de voo, dos experimentos do IEAv, do qual as imagens foram obtidas.

#### **4.2.2 Imagens do VANT capturada por sensor na banda do infravermelho termal**

Numa segunda fase desta dissertação foram usadas as imagens obtidas com uso de sensor no infravermelho termal, visando possibilitar a estimação da posição, inclusive em voos noturnos. Para prova de conceitos, foram empregadas imagens infravermelho termal obtidas de uma videografia aérea realizada em novembro de 2014, em período diurno, a uma altitude constante, sobre a cidade de Santa Maria-RS e cedida pelo IEAv/DCTA em parceria com o Esquadrão Hórus da Força Aérea (1°/12° GAV). O VANT *RQ - 450* utilizado para a captura das imagens infravermelho termal é

ilustrado na Figura 4.10.

Figura 4.10 - VANT utilizado para a captura das imagens infravermelho termal.



Fonte: Defesa Aérea (2016).

Para a captura dessas imagens foi usado um sensor infravermelho termal acoplado ao VANT. O sensor infravermelho termal empregado foi um FLIR, mas este foi adaptado para ser utilizado na visada NADIR. Na Tabela 4.2, são apresentadas as principais características desse sensor e a Figura 4.11 ilustra o sensor infravermelho termal utilizado.

Tabela 4.2 - Principais características do sensor utilizado.

Variação do Espectro	$3,4 - 4,8\mu m$
Material	InSb
Tamanho da Imagem	640 x 512
Taxa de geração de frames	25Hz

Fonte: Laboratório PITER (2016).

Figura 4.11 - Sensor infravermelho termal utilizado para a captura das imagens aéreas.



Fonte: Laboratório PITER (2016).

As imagens de satélite, empregadas nessa fase, referem-se à mesma região imageada pelo VANT e foram capturadas em agosto de 2014. Essas imagens foram obtidas com uso do sensor pancromático do satélite *Quickbird*, com resolução espacial de 0,6 m, conforme Tabela 4.1.

#### 4.2.2.1 Imagens utilizadas para geração de resultado em uma única região

Para a primeira fase foram empregadas imagens de um único ponto capturadas por sensor visível. Estes experimentos foram importantes para verificar as hipóteses de que a RNA configurada automaticamente e o uso do filtro Gaussiano comparado ao da Mediana melhorariam os resultados. Na segunda fase foram empregadas imagens infravermelho termal, para testar a hipótese: que é possível estimar a posição com uso do sensor termal e visível, possibilitando assim o voo noturno. Essa segunda fase foi dividida em dois experimentos, um primeiro usando imagens em uma única região e um segundo de uma rota. No experimento da rota o interesse era em se testar a hipótese: que os métodos são adequados para diferentes cenários.

Para o experimento de uma única região foi utilizada a imagem apresentada na Figura 4.12. Essa região foi escolhida pois é a posição inicial da gravação onde as

informações de posição e altitude do VANT são conhecidas (SILVA et al., 2015).

Figura 4.12 - Imagens utilizadas para geração dos resultados em uma única região.



Em (B) a imagem aérea infravermelha termal e em (A) a imagem de satélite, capturada por sensor na banda do visível, referente a mesma região da primeira

Fonte: Produção do autor.

A dimensão da imagem de satélite utilizada foi 500 x 800 pixels e a dimensão da imagem aérea foi de 116,4 x 116,4 pixels. Estas dimensões foram utilizadas por compreender a região de voo, do qual as imagens foram obtidas.

#### 4.2.2.2 Imagens utilizadas para geração de resultados em uma rota

Um teste importante das técnicas desenvolvidas nesta dissertação é a avaliação da identificação do local sobrevoado considerando uma rota de voo. Esse teste é importante para avaliar se a hipótese de que os métodos empregados são adequados para diferentes cenários. Para isso foi selecionada, dentre as imagens do voo realizado pelo VANT, uma rota de voo considerando diferentes pontos de referência, por exemplo, rodovias, região rural, região urbana, plantações e lagos. A rota pré-definida é ilustrada, na imagem de satélite, na Figura 4.13. A rota de voo começa na parte superior da Figura 4.13. Para compor esta rota foram definidas 15 regiões, o ponto central destas regiões é destacado na imagem por pontos vermelhos. A imagem de satélite utilizada tem dimensão total de  $2148 \times 3761$  pixels e a rota tem comprimento de 2951 metros.

Figura 4.13 - Rota pré-definida na imagem de satélite, composta de 15 regiões.



Fonte: Produção do autor.

Na Figura 4.14 são apresentadas as imagens de satélite utilizadas para a geração de resultados na rota. A dimensão da janela dessas imagens é de  $260 \times 260$  pixels ou  $156,4 \times 156,4$  metros. Esse tamanho de janela foi definido levando-se em consideração o erro do INS no momento da falha do GPS, como no momento da falha do GPS o INS possui o mesmo erro do GPS e esse erro é de até 20 metros, dependendo da posição do globo onde o GPS estiver (GRIMES, 2008). Esse erro do GPS foi usado como a incerteza da posição da aeronave, dessa forma, a dimensão da janela de satélite e a dimensão da janela do VANT  $116,4 \times 116,4$  m são somadas com essa incerteza de 20 m em cada lado da imagem totalizando  $156,4 \times 156,4$  metros.

E na Figura 4.15 são apresentadas as imagens de VANT das 15 regiões que compõem a rota pré-definida. A dimensão da imagem do VANT utilizada é de  $194 \times 194$  pixels ou  $116,4 \times 116,4$  metros.

Figura 4.14 - Imagens de satélite utilizadas para a geração dos resultados.



Figura 4.15 - Imagens do VANT de todas as 15 regiões que compõe a rota.



Fonte: Produção do autor.

## 5 RESULTADOS: DISCUSSÃO E ANÁLISE

Para análise dos resultados obtidos com os métodos empregados, são considerados diferentes experimentos para testar as hipóteses consideradas neste trabalho. O desenvolvimento dessa dissertação teve duas principais fases: capacitação para solução do problema e desenvolvimento do tema. Já na primeira fase foram consideradas hipóteses para melhorias em relação aos trabalhos já desenvolvidos. Na segunda fase foram consideradas duas situações: avaliação de uma única região e avaliação de uma rota de voo. Ressalta-se que os métodos aplicados ao trabalho podem operar de duas formas: embarcados no VANT ou por um processamento na estação de solo.

Dessa forma, com a finalidade de capacitação com os conceitos teóricos e métodos necessários para o desenvolvimento dessa dissertação de mestrado, na primeira fase, os métodos aplicados na dissertação de Goltz (2011) foram implementados e testados. Porém, um problema observado em seu trabalho foi o uso de uma RNA, cuja arquitetura foi definida de forma empírica, o que não garante a escolha da melhor arquitetura da RNA. Foi levantada a hipótese de que uma RNA auto-configurada apresentaria resultados melhores que uma RNA configurada empiricamente. A fim de reduzir a quantidade de configurações durante o treinamento da rede neural e obter uma melhora nos resultados, a hipótese da RNA auto-configurável foi testada e a configuração da rede neural MLP foi determinada de forma automática com uso do MPCA. Ainda nesta primeira fase, foi testada a hipótese de que uma filtragem mais adequada ao problema poderia melhorar os resultados. Com isso, foi testado outro tipo de filtro, além do Filtro de Mediana aplicado no trabalho de Goltz (2011), o Filtro Gaussiano. E o resultado da aplicação de ambos os filtros foram comparados (esses resultados são exibidos na **Seção 5.2**).

Na segunda fase foram empregadas imagens de VANT capturadas por sensor infravermelho termal, visando testar a hipótese do uso de diferentes sensores que possibilitassem também voos noturnos. Nessa fase foram consideradas duas situações a primeira foi a aplicação dos métodos a uma única região e a segunda em uma rota pré-definida, para testar a hipótese de que os métodos funcionam também em diferentes cenários.

A primeira situação foi importante para a avaliação dos resultados da aplicação dos métodos em imagens capturadas por diferentes sensores, uma na banda do visível capturada por um satélite e outro na banda do infravermelho termal capturada por um VANT (esses resultados são exibidos na **Seção 5.3**).

O problema de se aplicar os métodos a um único ponto, como realizado em Goltz (2011) e no experimento realizado nesta dissertação para uma única região usando imagem infravermelho termal, está no fato de que o resultado será diferente dependendo da região escolhida e do tipo de elementos presentes, dessa forma, os resultados obtidos em regiões controladas podem não representar os resultados que seriam obtidos em um voo real do VANT em diferentes cenários. Por esses motivos, a hipótese de que os métodos funcionam também em diferentes cenários foi considerada na aplicação dos métodos em uma rota pré-definida. A rota foi definida considerando-se diferentes regiões de voo, como região urbana, rural, rodovias, lagos e plantações. Nessa segunda situação, foi testada a hipótese de uso de mais padrões de treinamento de RNA visando melhorar os resultados obtidos (esses novos padrões utilizados são apresentados na **Seção 4.1.1**).

Na **Seção 5.1** são apresentadas as configurações das RNAs, utilizadas no processo de extração de bordas de todas as imagens, tanto para as redes neurais que utilizaram 10 padrões para seu treinamento, quanto para as que utilizaram 26 padrões. Esses padrões de treinamento são apresentados na Figura 4.2 e 4.3, respectivamente.

### 5.1 Arquitetura das RNAs para extração de bordas

Para a realização dos testes, foram consideradas diferentes redes neurais, a RBF e a MLP, com diferentes arquiteturas variando a quantidade de neurônios na camada escondida e número de centros, para o caso da rede neural RBF, para testar a hipótese de que existe uma RNA mais adequada ao problema considerado. E para o caso da rede neural MLP foram consideradas duas diferentes arquiteturas, uma determinada empiricamente e outra pelo algoritmo MPCA, variando a quantidade de neurônios na camada escondida, quantidade de camadas escondidas, função de ativação, taxa de aprendizado e constante de momento.

Durante o treinamento da rede neural MLP variou-se a quantidade de neurônios na camada escondida, função de ativação, taxa de aprendizado e a constante de momento. Foram utilizados dois diferentes critérios de parada para a rede neural MLP. O treinamento da rede neural MLP determinada empiricamente foi obtido quando o erro mínimo requerido foi atingido, ou seja, quando atingiu-se o critério de parada dessa rede neural. Para o caso da rede neural MLP determinada pelo MPCA o critério de parada utilizado foi o número de épocas de treinamento da rede neural MLP determinada empiricamente. No treinamento da rede neural RBF foi variado somente o número de centros e o critério de parada utilizado, para esta rede neural, foi o erro mínimo.

O treinamento das redes neurais foi realizado com dois diferentes conjuntos de padrões de treinamento, um com 10 e outro com 26 padrões (esses são apresentados na Figura 4.2 e Figura 4.3, respectivamente). O conjunto de 10 padrões foi utilizado como base para a elaboração de um conjunto maior. Esses novos padrões, resultado da variação do conjunto de 10 padrões, foram divididos e utilizados no treinamento e teste de generalização da rede neural. Dessa forma, no teste de generalização são apresentados padrões, que não estão no grupo de treinamento, para avaliar se a rede neural responde corretamente. O mesmo processo descrito anteriormente ocorre para o conjunto de 26 padrões.

O novo conjunto gerado a partir da variação do conjunto de 10 padrões contém ao todo 28 padrões, sendo 18 destes variações do conjunto de 10. Esse novo conjunto gerado foi dividido e utilizado para treinamento e generalização da rede neural. O mesmo aconteceu com o conjunto de 26 padrões, que gerou 46 padrões de variação, totalizando 72 padrões utilizados entre treinamento e generalização da RNA.

### 5.1.1 Treinamento com o conjunto de 10 padrões

A melhor arquitetura da rede neural RBF obtida empiricamente durante o treinamento tem sua configuração exibida na Tabela 5.1. Essa arquitetura que foi obtida variando-se a quantidade de neurônios na camada escondida e utilizando o conjunto de treinamento gerado a partir do conjunto de 10 padrões.

Tabela 5.1 - Arquitetura da rede neural RBF obtida durante o treinamento

Nº de neurônios na camada de entrada	9
Nº de neurônios na camada escondida	16
Nº de neurônios na camada de saída	1
Nº de centros	16
Função de ativação de base radial (camada oculta)	Função Gaussiana, Equação 3.6
Função de ativação da da camada de saída	Função Linear
Largura da rede neural RBF ( $\sigma$ )	Equação 3.7
Erro mínimo	$10^{-31}$

Uma outra RNA testada para a hipótese de que uma RNA pode apresentar melhores resultados que outra configurada empiricamente, foi a RNA auto-configurada. Na Tabela 5.2 são apresentadas as arquiteturas obtidas durante o treinamento da rede neural MLP, determinada tanto de forma empírica quanto encontrada auto-

maticamente pelo MPCA. Essas arquiteturas foram obtidas variando-se o número de neurônios da camada escondida, a função de ativação, a taxa de aprendizado, a constante de momento e o número de épocas de treinamento. E utilizando o conjunto de treinamento gerado a partir do conjunto de 10 padrões.

Tabela 5.2 - Arquitetura da rede neural MLP determinada empiricamente e da rede neural MLP de arquitetura determinada pelo algoritmo MPCA

	Empiricamente	MPCA
Nº de neurônios na camada de entrada	9	9
Nº de neurônios na camada escondida	16	18
Nº de neurônios na camada de saída	1	1
Função de ativação	Sigmoide	Tangente Hiperbólica
Taxa de aprendizado ( $\eta$ )	0,8	0,35
Constante de momento ( $\alpha$ )	0,5	0,82
Número de épocas de treinamento	15000	15000
Erro mínimo	$10^{-4}$	$10^{-6}$

### 5.1.2 Treinamento com o conjunto de 26 padrões

Nesta dissertação é apresentada a hipótese de que o uso de um conjunto com mais tipos de bordas podem melhorar os resultados da aplicação. A mesmas RNAs foram empregadas e o conjunto de treinamento foi gerado de forma semelhante ao experimento anterior. Dessa forma, o conjunto gerado pelos 26 padrões foi empregado no treinamento das RNAs.

A arquitetura da rede neural RBF obtida empiricamente durante o treinamento tem sua configuração exibida na Tabela 5.3. Essa arquitetura que foi obtida variando-se a quantidade de neurônios na camada escondida e utilizando o conjunto de treinamento gerado a partir do conjunto de 26 padrões.

Tabela 5.3 - Arquitetura da rede neural RBF obtida durante o treinamento

Nº de neurônios na camada de entrada	9
Nº de neurônios na camada escondida	31
Nº de neurônios na camada de saída	2
Nº de centros	31
Função de ativação de base radial (camada oculta)	Função Gaussiana, Equação 3.6
Função de ativação da camada de saída	Função Linear
Largura da rede neural RBF ( $\sigma$ )	Equação 3.7
Erro mínimo	$10^{-8}$

Como nos experimentos anteriores a rede neural MLP definida automaticamente apresentou melhores resultados do que a RNA empírica. Neste experimento foi usada somente a RNA auto-configurada. Na Tabela 5.4 é apresentada a arquitetura obtida durante o treinamento da rede neural MLP, determinada automaticamente pelo MPCA. Essa arquitetura foi obtida variando-se o número de neurônios da camada escondida, a função de ativação, a taxa de aprendizado, a constante de momento e o número de épocas de treinamento. Utilizou-se o conjunto de treinamento que foi gerado a partir do conjunto de 26 padrões.

Tabela 5.4 - Arquitetura da rede neural MLP determinada pelo algoritmo MPCA

Nº de neurônios na camada de entrada	9
Nº de neurônios na camada escondida	18
Nº de neurônios na camada de saída	2
Função de ativação	Tangente Hiperbólica
Taxa de aprendizado ( $\eta$ )	0,73
Constante de momento ( $\alpha$ )	0,85
Número de épocas de treinamento	15000
Erro mínimo	$10^{-8}$

## 5.2 Resultados de capacitação com o problema

Nesta seção são apresentados os resultados de capacitação com o problema, obtidos com o emprego dos métodos em uma única região e usando a imagem obtida pelo VANT capturada por um sensor na banda do visível, assim como realizado no trabalho de Goltz (2011). Além disso, são gerados novos resultados com o acréscimo da configuração automática da rede neural MLP pelo algoritmo MPCA e da com-

paração entre o filtro aplicado em Goltz (2011), a Mediana, com o filtro Gaussiano.

Na Figura 5.2 é apresentado o resultado obtido pelo processo de extração de bordas, utilizando RNA, em uma mesma região de uma imagem de satélite e de uma imagem aérea, apresentadas na Figura 5.1.

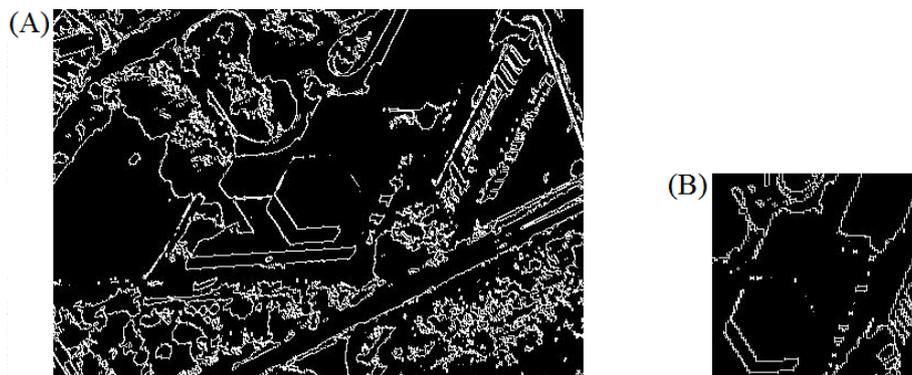
Figura 5.1 - Imagens aérea de de satélite utilizadas no processo de extração de bordas.



Em (A) é apresentada a imagem de satélite em (B) a imagem aérea.

Fonte:

Figura 5.2 - Resultados da extração de bordas pela rede neural MLP de arquitetura determinada pelo MPCA.



Em (A) é apresentado o resultado sobre a imagem de satélite em (B) o resultado sobre a imagem aérea.

Fonte: Produção do autor.

A correlação entre as imagens de bordas de satélite e aérea foi feita com uso da Equação 4.1. Como a posição do VANT na imagem de satélite foi determinada por Goltz (2011) é possível calcular o erro em metros, utilizando a distância Euclidiana entre a posição do VANT e a posição estimada pelo Cálculo do Coeficiente de Correlação. O resultado desse cálculo é um valor em pixels que deve ser multiplicado pela resolução espacial da banda pancromática do satélite *Quickbird* 0,6m, para que seja obtido o valor dessa distância, entre a posição do VANT e a calculada, em metros.

Para comparação do desempenho da estimação da posição com uso dos métodos propostos foi feita a comparação das técnicas. O emprego do detector de bordas Canny resultou em um erro de estimação de 0,60m. Na Tabela 5.5 apresenta-se o resultado do cálculo do erro (em metros) para cada filtro aplicado e por extrator de bordas.

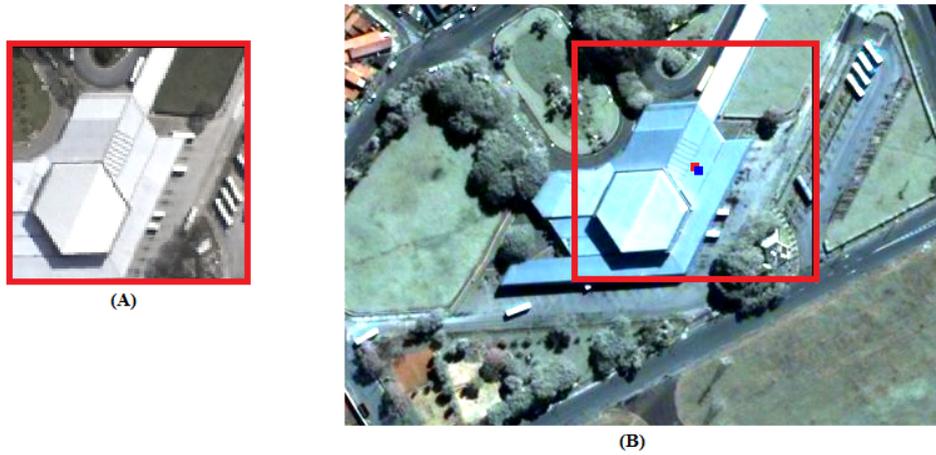
Tabela 5.5 - Erro da estimação da posição do VANT

Filtro	MLP	RBF	MLP (MPCA)
Mediana	1,89	1,34	0,84
Gaussiano	0,84	1,20	0,60

A análise dos resultados obtidos sobre a região da Figura 5.1 evidencia que a aplicação da rede neural MLP (MPCA) em conjunto com o filtro Gaussiano produziu resultados iguais ao operador Canny, como apresentado na Tabela 5.5.

A Figura 5.4 ilustra a posição do VANT estimada pelo emprego dos métodos. O resultado apresentado foi obtido com uso do rede neural MLP (MPCA). Na Figura 5.3 ilustra-se a posição estimada pelos métodos nas imagens originais.

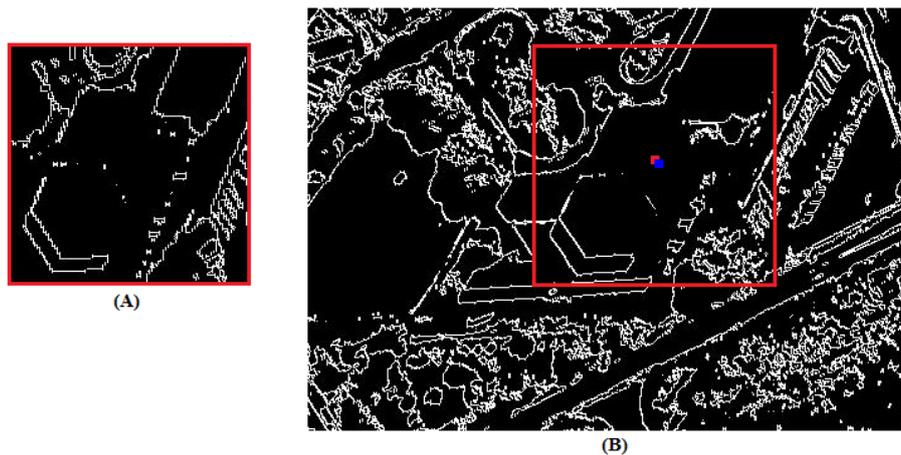
Figura 5.3 - Resultado da estimação da posição do VANT pela correlação entre a imagem aérea e a de satélite.



Em (A) é apresentada a imagem aérea e em (B) a imagem de satélite com a região da imagem aérea delimitada em vermelho. A posição real do VANT é apresentada em vermelho e a posição estimada pela correlação em azul.

Fonte: Produção do autor.

Figura 5.4 - Resultado da estimação da posição do VANT pela correlação entre a imagem aérea e a de satélite.



Em (A) é apresentada a imagem aérea e em (B) a imagem de satélite com a região da imagem aérea delimitada em vermelho. A posição real do VANT é apresentada em vermelho e a posição estimada pela correlação em azul.

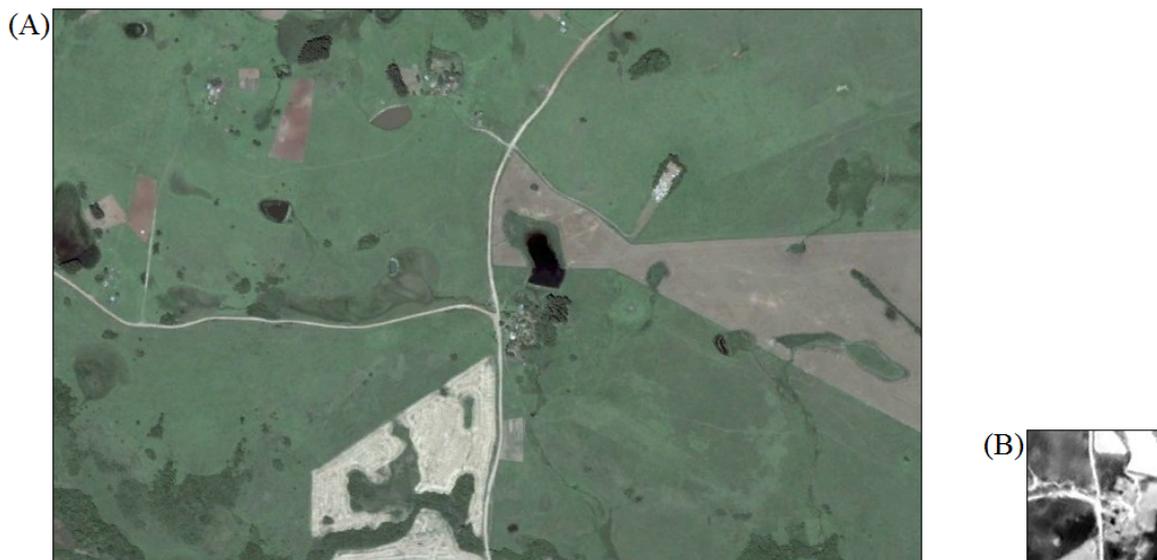
Fonte: Produção do autor.

### 5.3 Resultados preliminares para uma única região e imagens óptica e termal

Nesta seção são apresentados os resultados preliminares obtidos com o uso de imagem capturada, por sensor infravermelho termal embarcado em um VANT e imagem de satélite óptica com sensor na banda do visível, com configuração automática da rede neural MLP pelo MPCA e comparação entre o filtro da Mediana, aplicado em Goltz (2011), e o Gaussiano.

A Figura 5.6 ilustra o resultado do processo de extração de bordas em uma mesma região de uma imagem de satélite e de uma imagem aérea, apresentadas na Figura 5.5.

Figura 5.5 - Imagens aérea de de satélite utilizadas no processo de extração de bordas.



Em (A) é apresentada a imagem de satélite em (B) a imagem aérea.

Fonte: Produção do autor.

Figura 5.6 - Resultados da extração de bordas pela rede neural MLP de arquitetura determinada pelo MPCA.



Em (A) é apresentado o resultado sobre a imagem de satélite em (B) o resultado sobre a imagem aérea.

Fonte: Produção do autor.

A correlação entre as imagens de bordas de satélite e aérea também foi obtida com uso da Equação 4.1. Para o cálculo do erro de estimação da posição de um VANT é necessário ter conhecimento de sua posição real. Essa informação pode ser fornecida por sensores embarcados no VANT ou sensores externos. No entanto, essas informações não foram fornecidas com as imagens obtidas pelo VANT. Logo, neste trabalho a posição real do VANT foi estimada com registro manual das imagens, usando-se como base uma imagem georreferenciada. Com isso, foi possível realizar o cálculo do erro em metros, utilizando a distância Euclidiana entre o ponto dito como verdade e o ponto estimado pelo Cálculo do Coeficiente de Correlação. O resultado desse cálculo é um valor em pixels que deve ser multiplicado pela resolução espacial da banda pancromática do satélite *Quickbird* 0,6m.

Para comparação do desempenho da estimação da posição com uso dos métodos propostos foi feita a comparação das técnicas. O emprego do detector de bordas Canny resultou em um erro de estimação de 2,47m. Na Tabela 5.6 apresenta-se o resultado do cálculo do erro (em metros) para cada filtro aplicado e por extrator de bordas.

Tabela 5.6 - Erro da estimação da posição do VANT

Filtro	MLP	RBF	MLP (MPCA)
Mediana	3,06	3,00	2,47
Gaussiano	2,40	1,89	1,89

A análise dos resultados obtidos, do erro de estimação da posição do VANT na Tabela 5.6, evidenciam que as RNAs juntamente com aplicação do filtro Gaussiano produziram os melhores resultados em comparação com as outras técnicas.

A Figura 5.8 ilustra o resultado do processo de correlação e a estimação da posição do VANT. O resultado apresentado foi obtido com uso da rede neural MLP (MPCA). Na Figura 5.7 ilustra-se a posição estimada pelos métodos nas imagens originais.

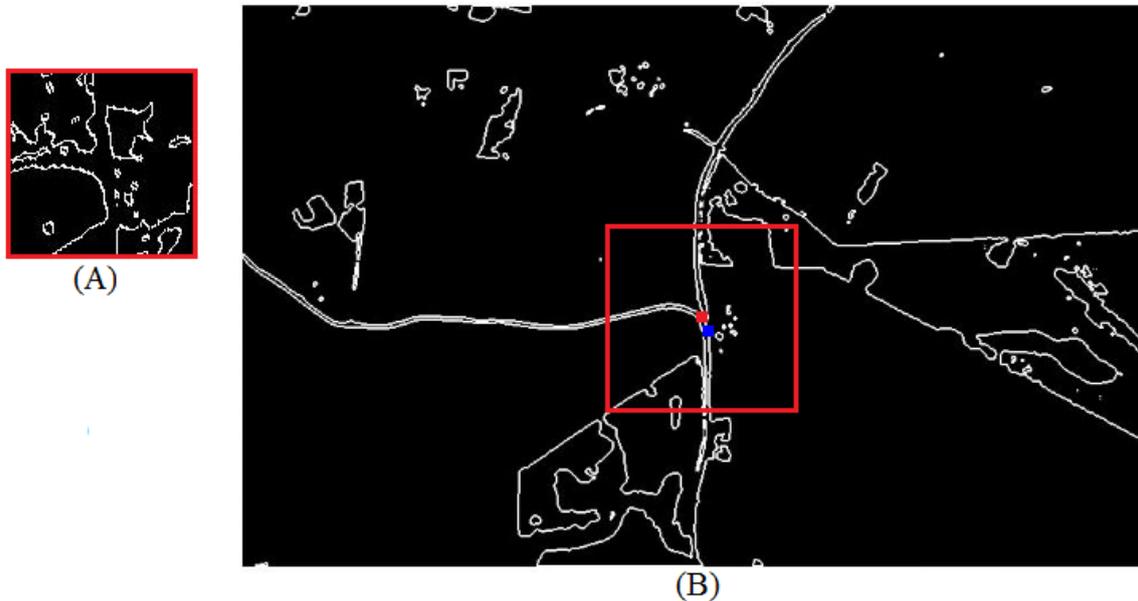
Figura 5.7 - Resultado da estimação da posição do VANT pela correlação entre a imagem aérea e a de satélite.



Em (A) é apresentada a imagem aérea na banda do infravermelho termal e em (B) a imagem de satélite com a região da imagem aérea delimitada em vermelho. A posição real do VANT é apresentada em vermelho e a posição estimada pela correlação em azul.

Fonte: Produção do autor.

Figura 5.8 - Resultado da estimação da posição do VANT pela correlação entre a imagem aérea e a de satélite.



Em (A) é apresentada a imagem aérea na banda do infravermelho termal e em (B) a imagem de satélite com a região da imagem aérea delimitada em vermelho. A posição real do VANT é apresentada em vermelho e a posição estimada pela correlação em azul.

Fonte: Produção do autor.

#### 5.4 Resultados para uma rota

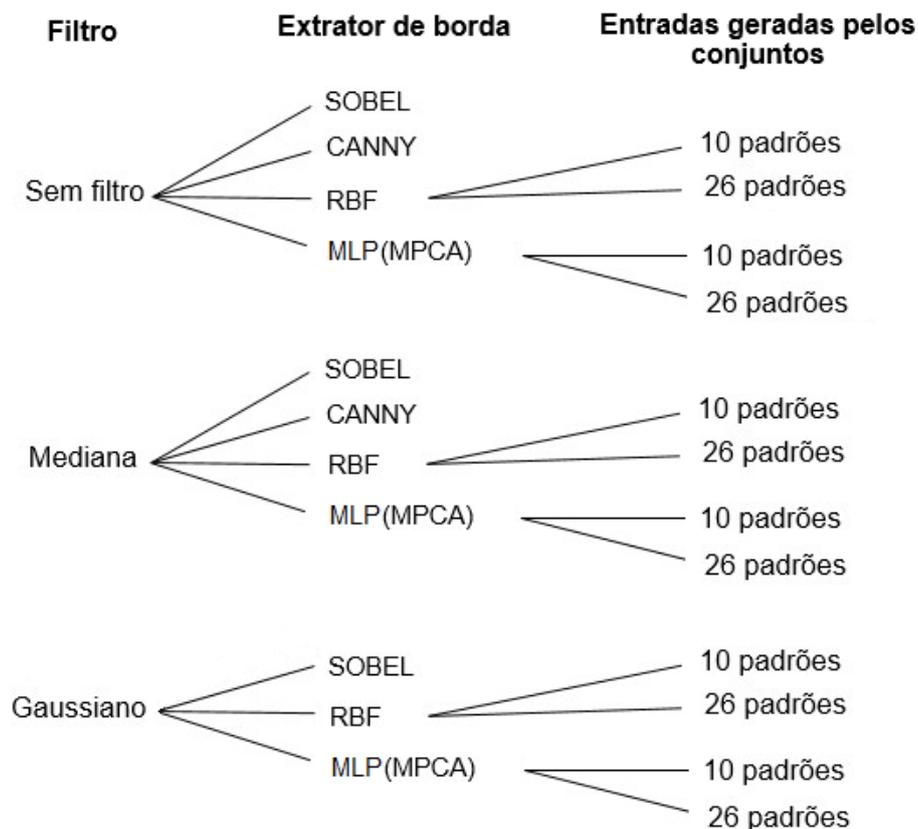
Como foi observado nas seções anteriores é possível realizar a identificação automática de um local sobrevoado pelo VANT com uso de imagens obtidas por sensores ópticos e termais. No entanto, para avaliar o desempenho das técnicas em diferentes cenários de voo, foi planejada uma rota considerando voos sobre diferentes regiões. Para este teste foram empregadas imagens obtidas por VANTs da FAB em operação em Santa Maria (RS). Nessa seção são apresentados os resultados obtidos para uma rota pré-definida (exibida na Figura 4.13). Ressalta-se que os testes não consideram correções de trajetória, pois foram utilizadas imagens armazenadas durante um único voo. Os métodos empregados para a geração desses resultados são apresentados na Figura 4.1.

Com o intuito de avaliar a hipótese previamente apresentada, no processo de estimação da posição do VANT, alguns experimentos foram realizados:

- utilização de dois conjuntos dos diferentes padrões para o treinamento das RNAs. Um conjunto gerado pelo conjunto de 10 padrões e outro gerado pelo conjunto de 26 padrões, esses são descritos na **Seção 4.1.1**;
- geração de resultados sem a aplicação de filtro, com a aplicação do Filtro de Mediana e com a aplicação do Filtro Gaussiano;
- geração de resultados com a aplicação de diferentes extratores de bordas: Sobel, Canny, rede neural RBF e a rede neural MLP (MPCA).

Na Figura 5.9 são apresentadas as combinações realizadas para a produção de resultados no processo de estimação da posição do VANT, para posterior análise. Para estas combinações foi adicionado também o extrator de bordas sobel, por ter sido empregado anteriormente no trabalho de [Conte e Doherty \(2008\)](#). Lembrando que, o Filtro Gaussiano não é aplicado ao extrator de bordas Canny, pois o Canny já faz uso deste filtro em seu algoritmo.

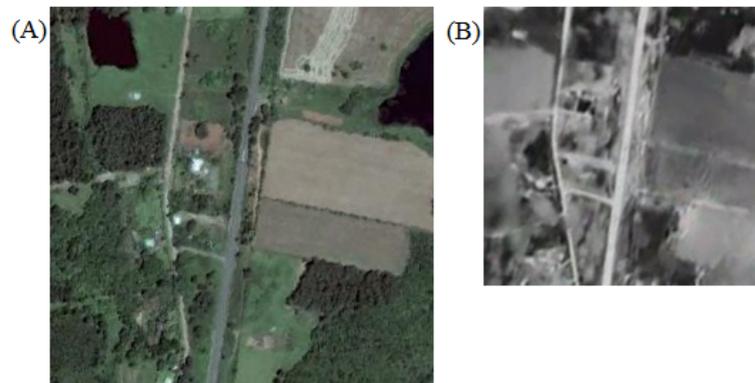
Figura 5.9 - Combinação das técnicas para a produção de resultados.



Fonte: Produção do autor.

Para ilustrar alguns exemplos de resultados do processo de extração de bordas em uma mesma região em imagens de satélite e de VANT. São apresentados os resultados para os filtros aplicados e para os conjuntos de treinamento utilizados para treinar as RNAs (conforme a combinação das técnicas ilustrada na Figura 5.9). As imagens obtidas pelo VANT e obtidas pelo satélite utilizadas na geração dos exemplos são apresentadas na Figura 5.10. As bordas obtidas pelas combinações com uso da imagem de satélite são apresentadas na Figura 5.11. Enquanto as bordas obtidas nas imagens capturadas pelo VANT são apresentadas na Figura 5.12.

Figura 5.10 - Imagens utilizadas na geração de resultados do processo de extração de bordas.



Em (A) imagem de satélite na banda do visível e em (B) imagem de VANT na banda do infravermelho termal.

Figura 5.11 - Resultados da extração de bordas em imagem de Satélite.

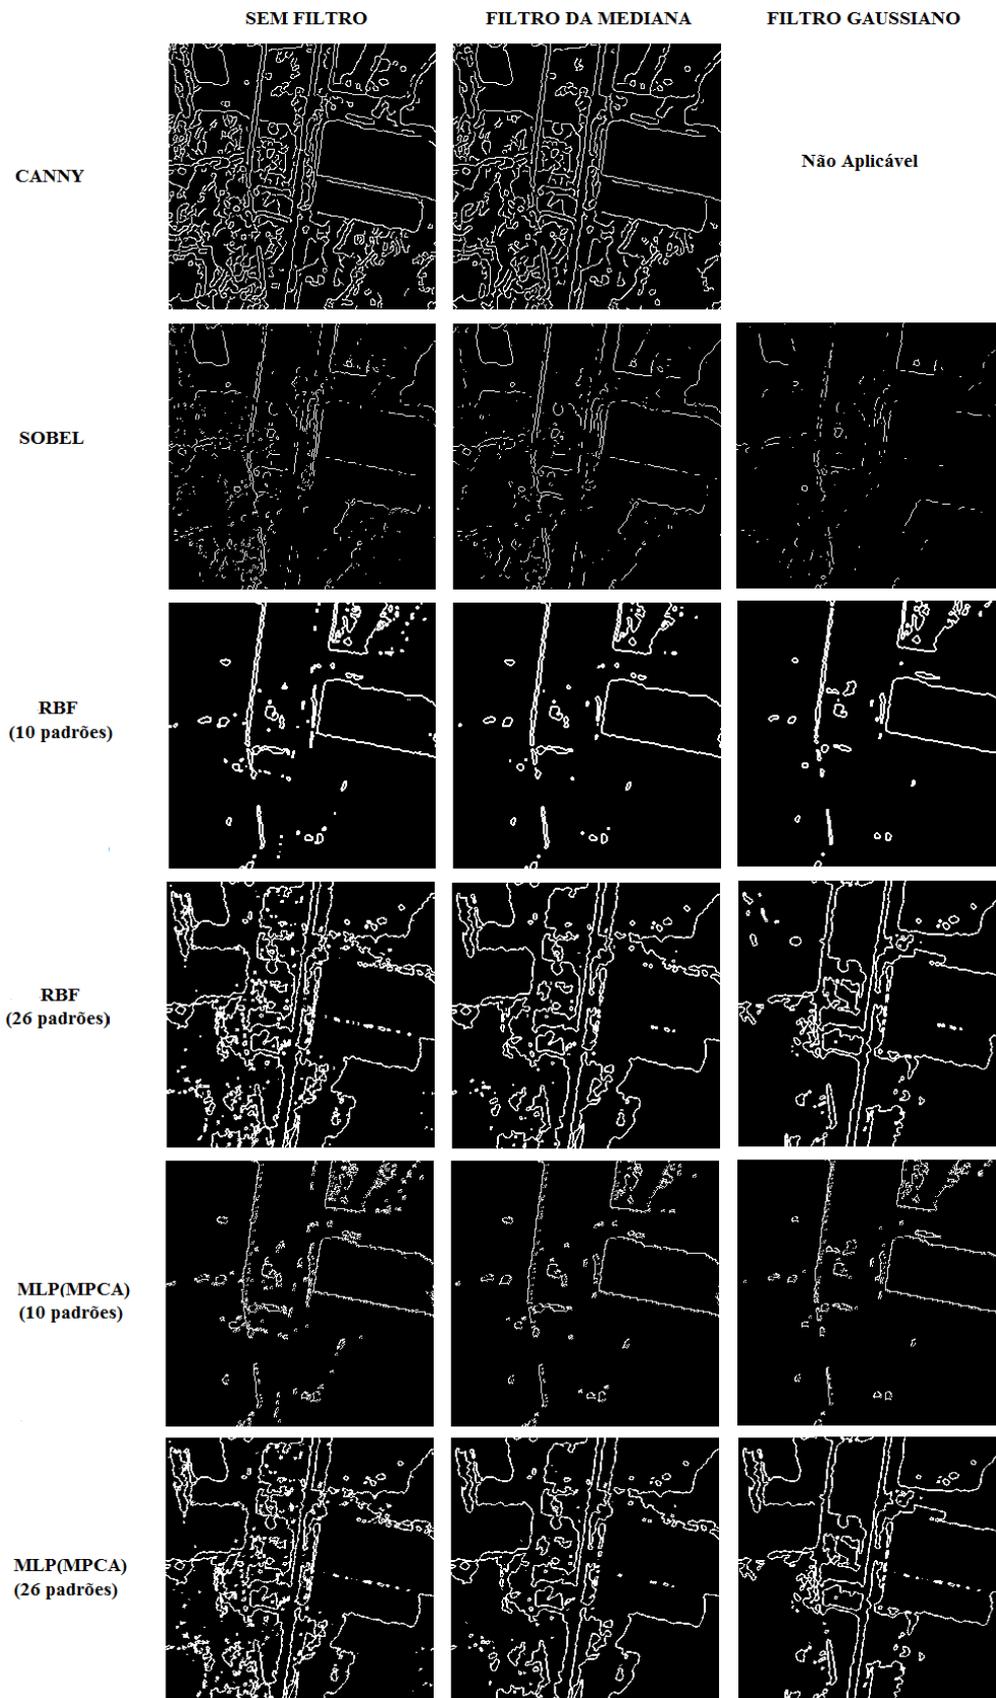
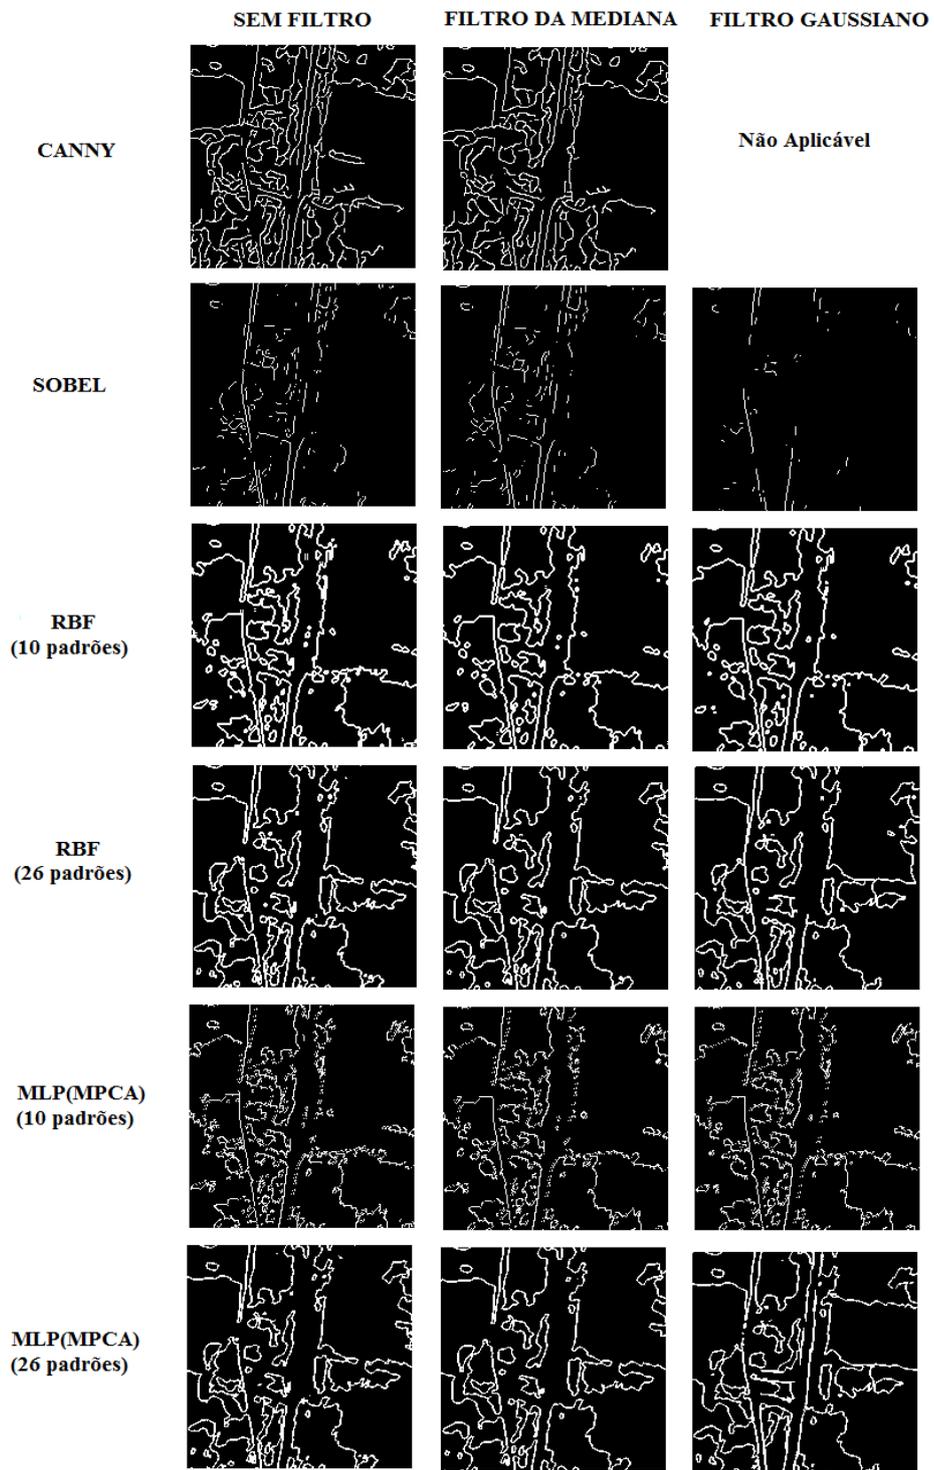


Figura 5.12 - Resultados da extração de bordas em imagem do VANT.



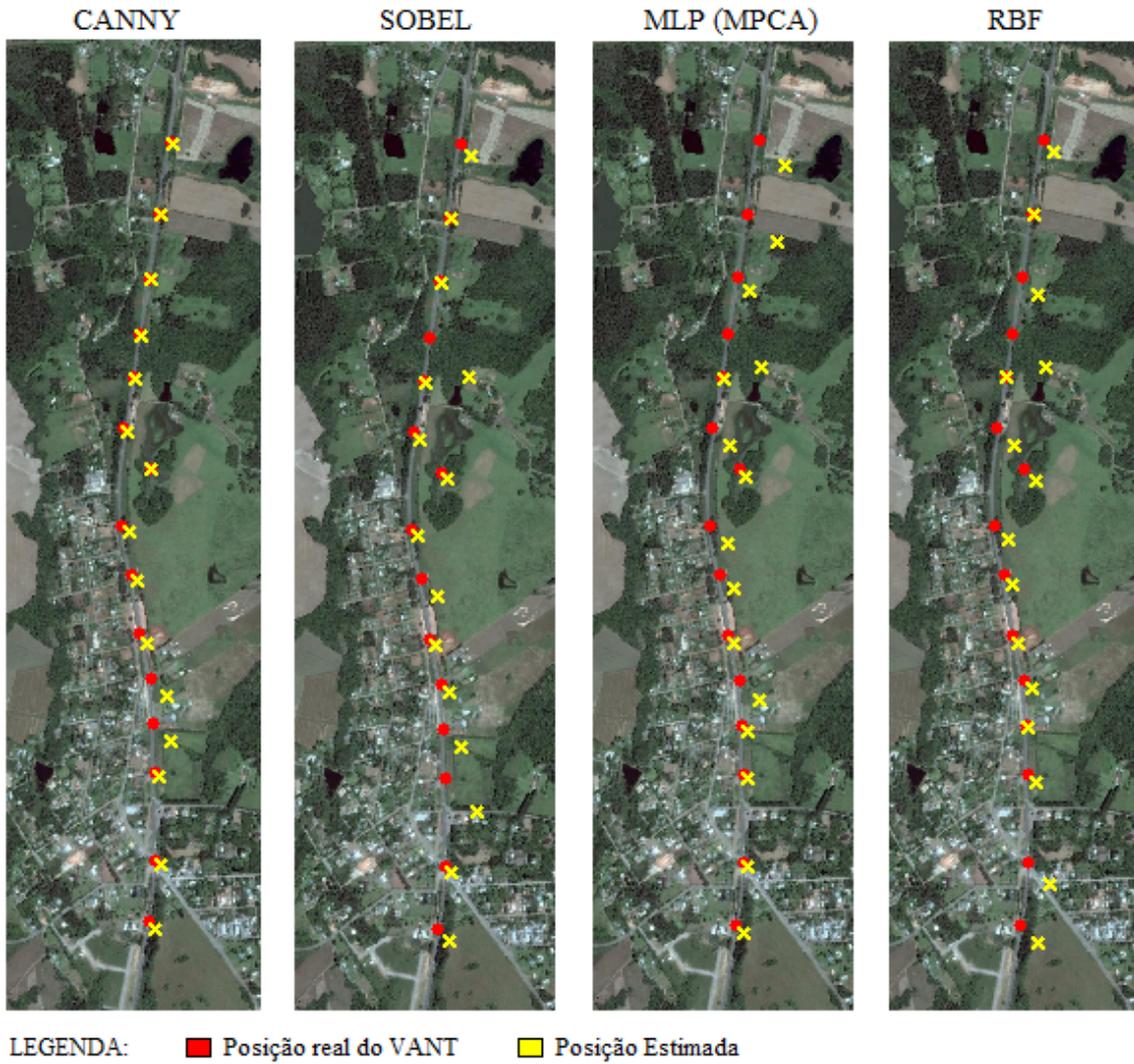
A correlação entre as imagens de bordas de satélite e aérea foi feita com uso da Equação 4.1. Assim como para o cálculo do erro na estimação da posição de um

único ponto, neste teste de voo em uma rota, a posição real do VANT foi estimada com registro manual e uso de imagem georreferenciada, pois não foram fornecidas informações dos sensores embarcados no VANT. Com isso, é possível o cálculo do erro em metros utilizando a distância Euclidiana entre a posição do VANT e a posição estimada pelo Cálculo do Coeficiente de Correlação. O resultado desse cálculo é um valor em pixels que deve ser multiplicado pela resolução espacial da banda pancromática do satélite *Quickbird* 0,6 m, para que seja obtido o valor em metros dessa distância. A seguir são apresentados os resultados da estimação da posição do VANT para a rota, bem como os gráficos de comparação do erro em cada um dos métodos aplicados (detectores de bordas, filtros e conjunto de padrão de treinamento utilizado na RNA), para cada uma das regiões da imagem de satélite que compõe a rota.

Para avaliação dos resultados, foi utilizado um limiar. Esse limiar leva em consideração o erro que o INS pode apresentar no momento da falha do GPS, como no momento da falha o INS possui o mesmo erro do GPS o erro utilizado é o do GPS. Como o erro do GPS comercial gira em torno de 20 metros, dependendo da posição do globo onde o GPS estiver (GRIMES, 2008), o valor do limiar adotado foi de 20 metros. Esse limiar significa que, valores maiores que 20 metros não representam uma posição aceitável para a estimação da posição do VANT, portanto esses valores não são considerados.

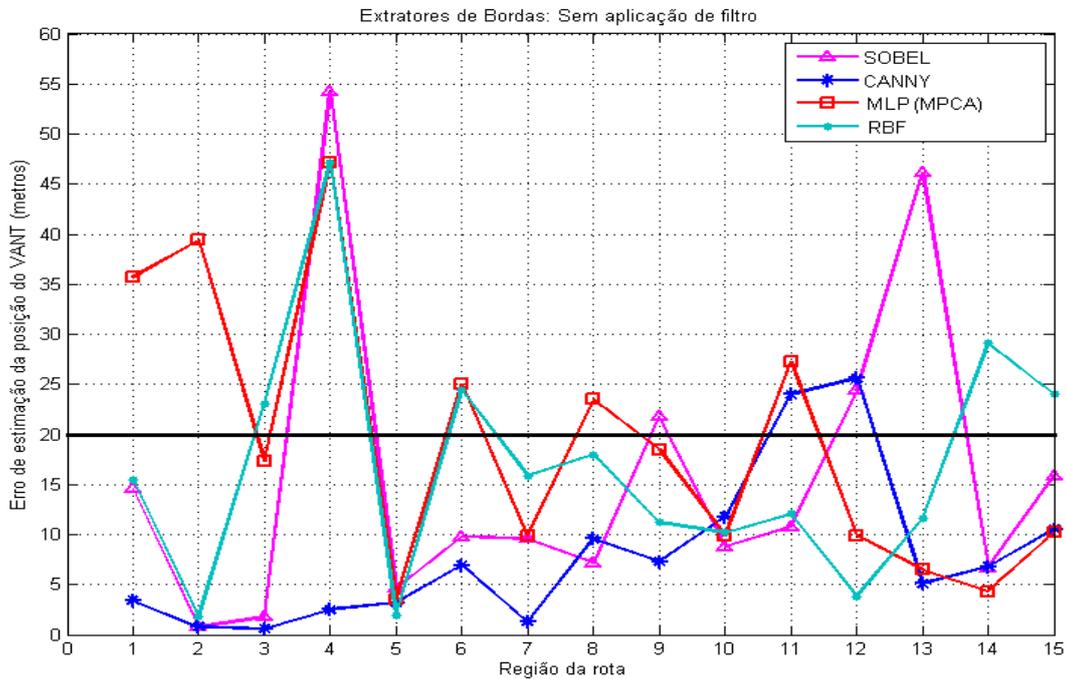
Para avaliar a importância do uso de filtros nos diferentes pontos da rota, inicialmente foram realizados testes sem aplicação de filtros nas diferentes técnicas de extração de bordas. Nas Figuras 5.13 e 5.14 são apresentadas a estimação da posição do VANT na rota e o gráfico dos erros, respectivamente. Para a obtenção destes resultados não foi aplicado filtro nas imagens e foram utilizadas as RNAs treinadas com o conjunto gerado pelos 10 padrões de entrada. Lembrando que o Canny, neste resultado, é o único no qual o filtro Gaussiano não está aplicado, pois este já possui tal filtro em seu algoritmo. Pode-se observar, analisando as Figuras 5.13 e 5.14, que o operador Canny apresentou os melhores resultados, comparados aos outros extractores de bordas, nos quais o filtro Gaussiano não foram aplicados. Neste, as redes neurais tiveram praticamente o mesmo desempenho do operador Sobel.

Figura 5.13 - Estimação da posição do VANT na rota.



Sem aplicação de filtro nas imagens e RNAs treinadas com 10 padrões de entrada.

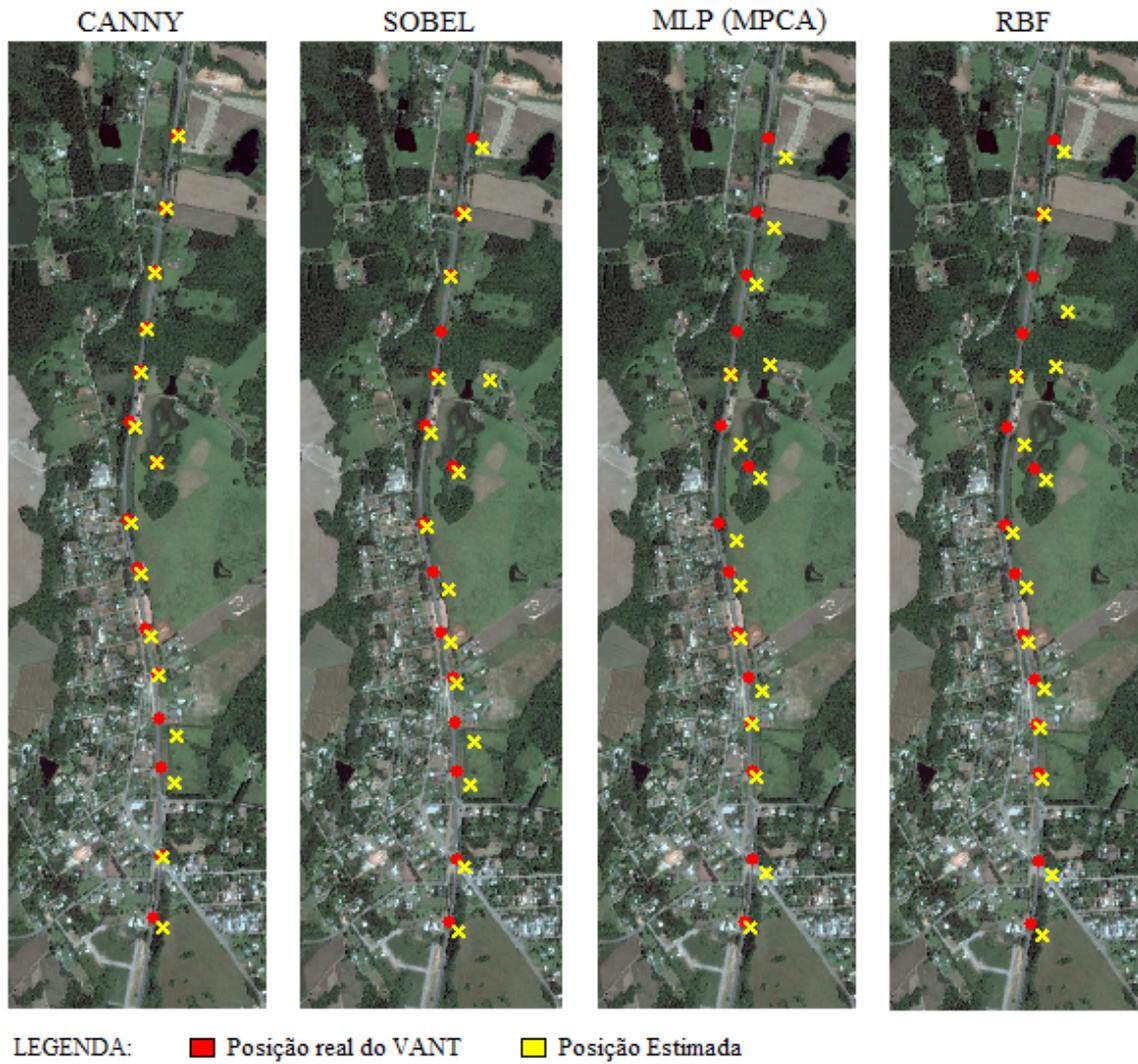
Figura 5.14 - Erro dos métodos utilizados x Região da rota.



A linha horizontal preta que corta o gráfico é o limiar.

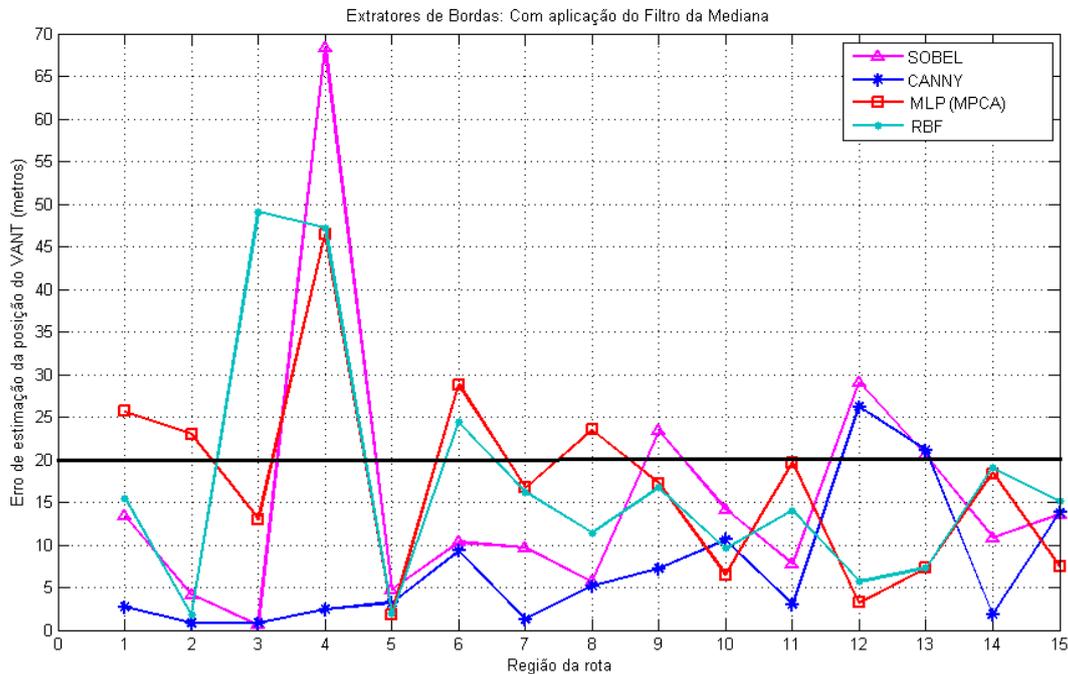
Para testar as técnicas empregadas no trabalho de Goltz (2011) para um único ponto e imagem capturada por sensor visível, aplicou-se essas mesmas técnicas para a rota e em imagens capturadas pelo VANT na banda do infravermelho termal. Nas Figuras 5.15 e 5.16 são apresentados a estimação da posição do VANT na rota e o gráfico dos erros, respectivamente. Para a obtenção destes resultados foi aplicado o filtro da Mediana nas imagens e foram utilizadas as RNAs treinadas com o conjunto gerados pelos 10 padrões de entrada. Nesse caso o Filtro da Mediana foi aplicado ao Canny. Com a aplicação do filtro da Mediana não foram notadas melhoras nas RNAs e nem do operador Canny em relação aos resultados sem a aplicação de filtro, apresentados nas Figuras 5.13 e 5.14. Mas, no caso do operador Sobel, houve uma certa melhora com a aplicação deste filtro.

Figura 5.15 - Estimação da posição do VANT na rota.



Com aplicação do filtro da Mediana nas imagens e RNAs treinadas com o conjunto gerado pelos 10 padrões de entrada.

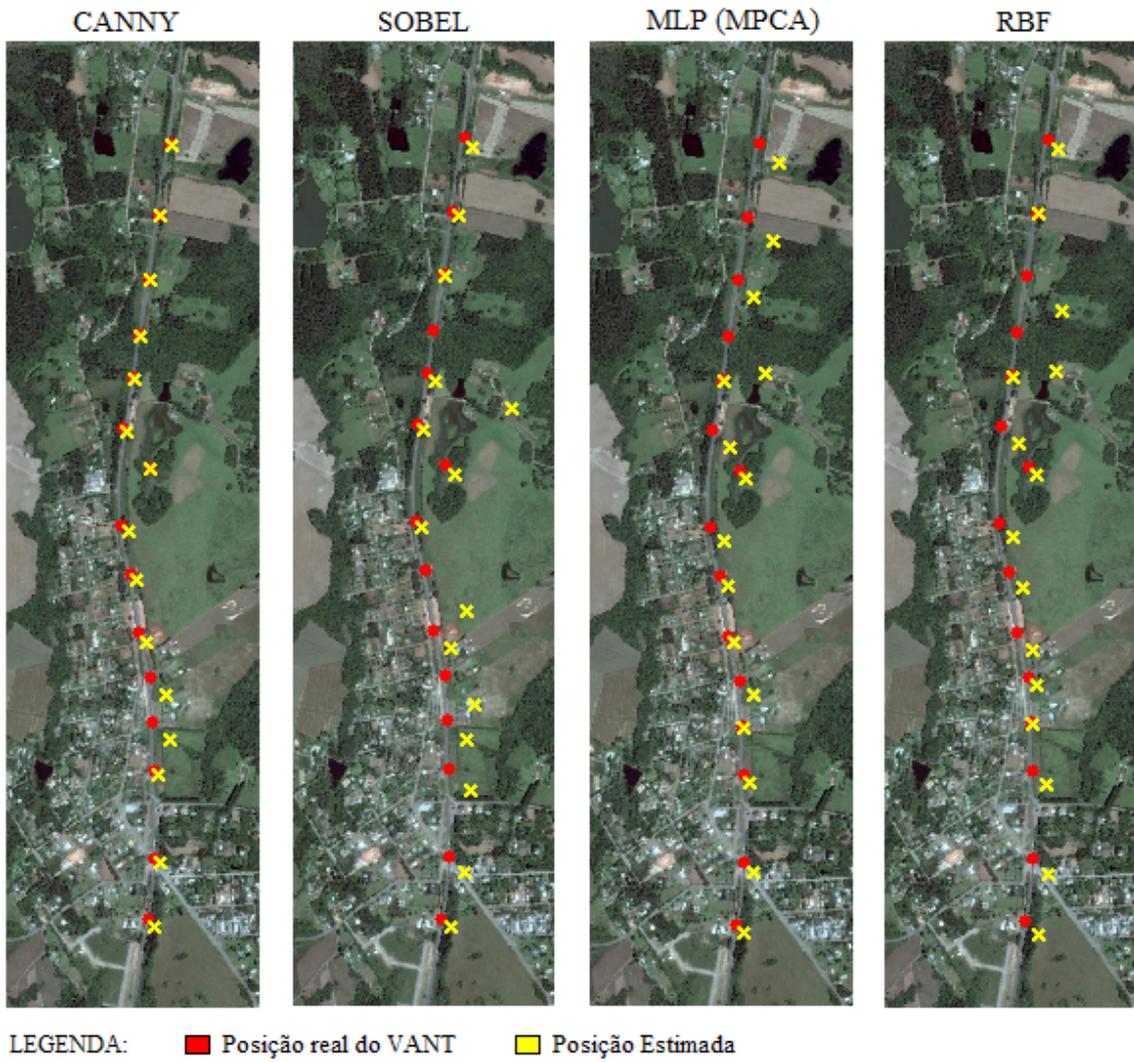
Figura 5.16 - Erro dos métodos utilizados x Região da rota.



A linha horizontal preta que corta o gráfico é o limiar.

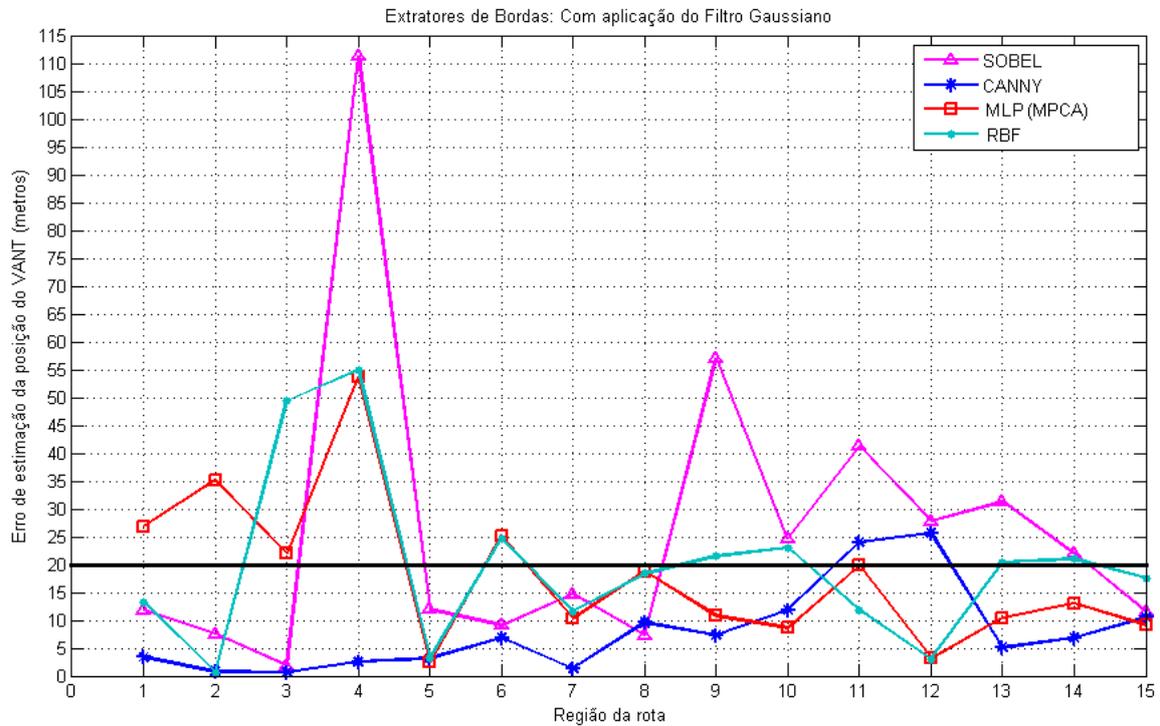
Para avaliar a hipótese de que uma filtragem mais adequada ao problema poderia melhorar os resultados, o filtro Gaussiano foi testado. Nas Figuras 5.17 e 5.18 são apresentados a estimação da posição do VANT na rota e o gráfico dos erros, respectivamente. Para a obtenção destes resultados foi aplicado o filtro Gaussiano nas imagens e foram utilizadas as RNAs treinadas com o conjunto gerado pelos 10 padrões de entrada. Como o Canny já possui o filtro Gaussiano em seu algoritmo, esse filtro não foi aplicado. Com base nas Figuras 5.17 e 5.18 é possível verificar que, com a aplicação do filtro Gaussiano, as RNAs melhoraram os seus resultados. As RNAs tiveram alguns resultados iguais ou melhores que o operador Canny. Enquanto o operador Sobel, com a aplicação deste filtro, piorou os seus resultados em comparação aos resultados com a aplicação do filtro da Mediana, apresentados nas Figuras 5.15 e 5.16.

Figura 5.17 - Estimação da posição do VANT na rota.



Com aplicação do filtro Gaussiano nas imagens e RNAs treinadas com o conjunto gerado pelos 10 padrões de entrada.

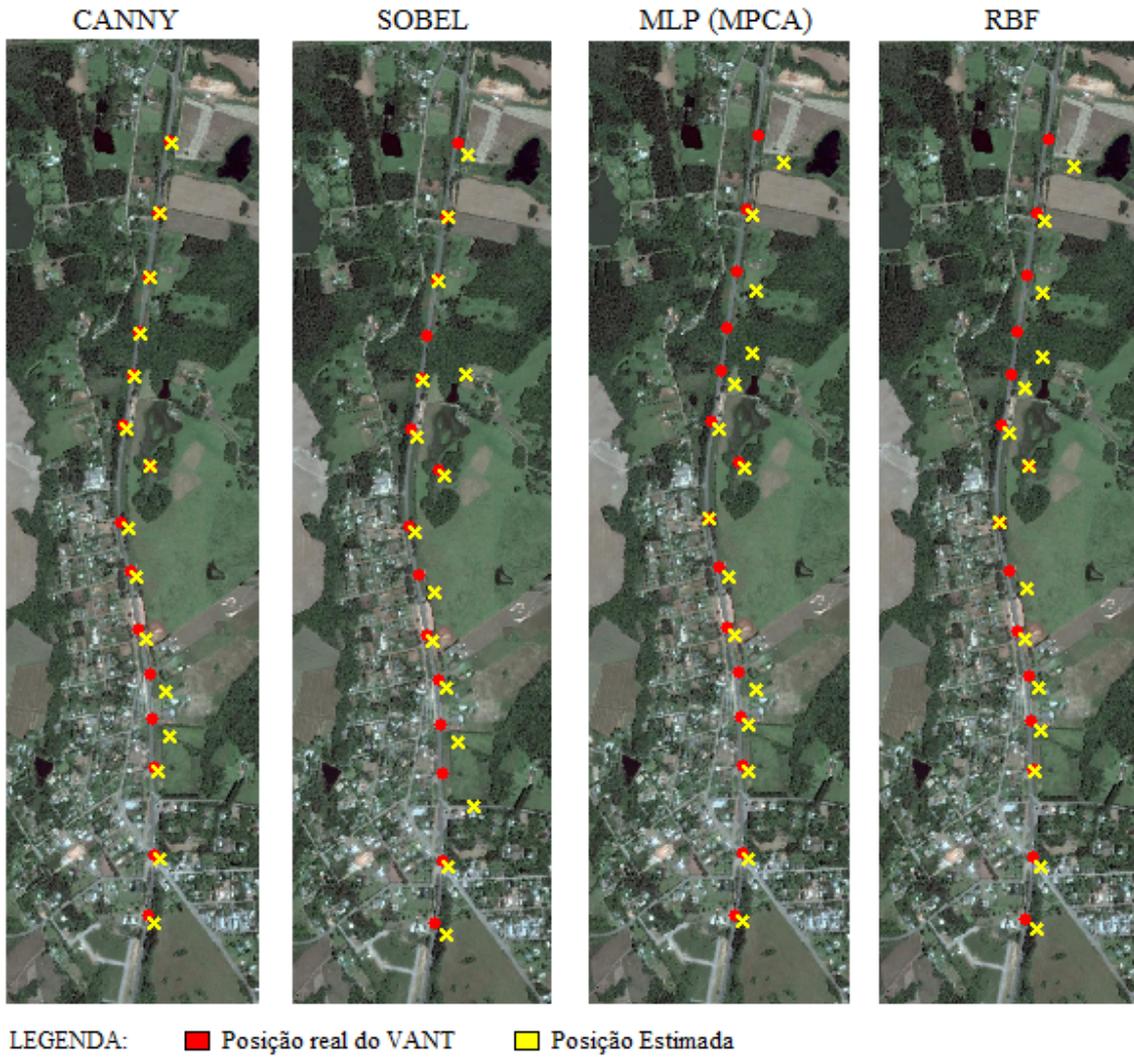
Figura 5.18 - Erro dos métodos utilizados x Região da rota.



A linha horizontal preta que corta o gráfico é o limiar.

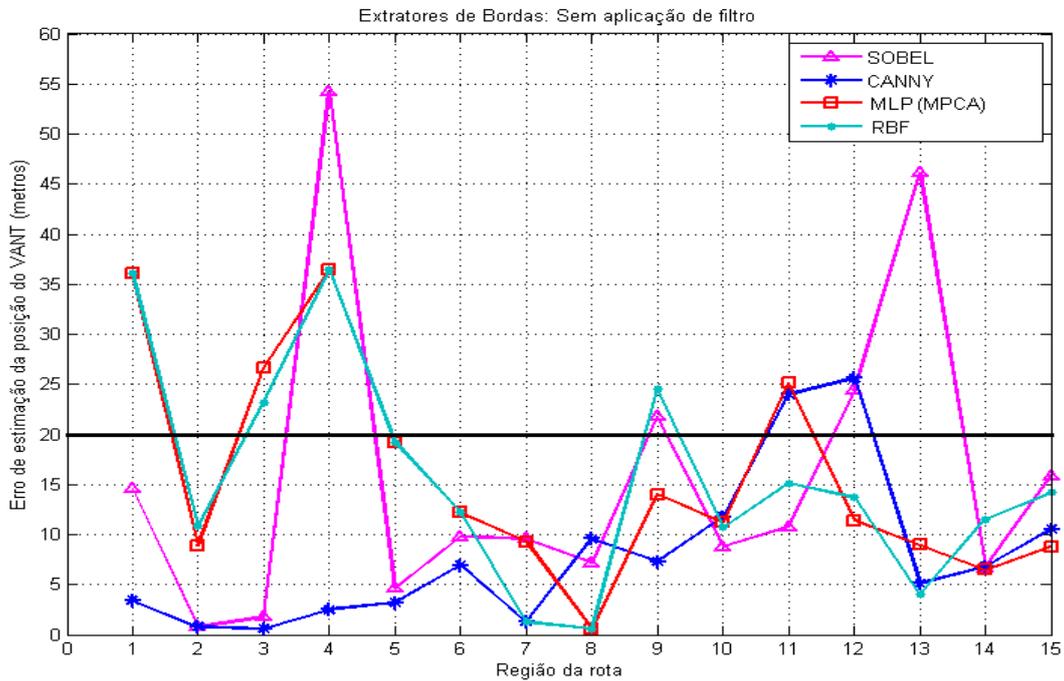
Este experimento teve por objetivo avaliar a hipótese de que usar mais padrões, no treinamento das redes, podem melhorar os resultados. Nas Figuras 5.19 e 5.20 são apresentados a estimação da posição do VANT na rota e o gráfico dos erros, respectivamente. Para a obtenção destes resultados não foi aplicado filtro nas imagens e foram utilizadas as RNAs treinadas com o conjunto gerado pelos 26 padrões de entrada. Analisando os resultados pode-se observar que, com a utilização do conjunto gerado pelos 26 padrões de treinamento, as RNAs apresentaram melhores resultados se comparados aos resultados que também não utiliza filtro e tem as RNAs treinadas com o conjunto gerado pelos 10 padrões, cujo os resultados são apresentados nas Figuras 5.13 e 5.14.

Figura 5.19 - Estimação da posição do VANT na rota.



Sem aplicação de filtro nas imagens e RNAs treinadas com o conjunto gerado pelos 26 padrões de entrada.

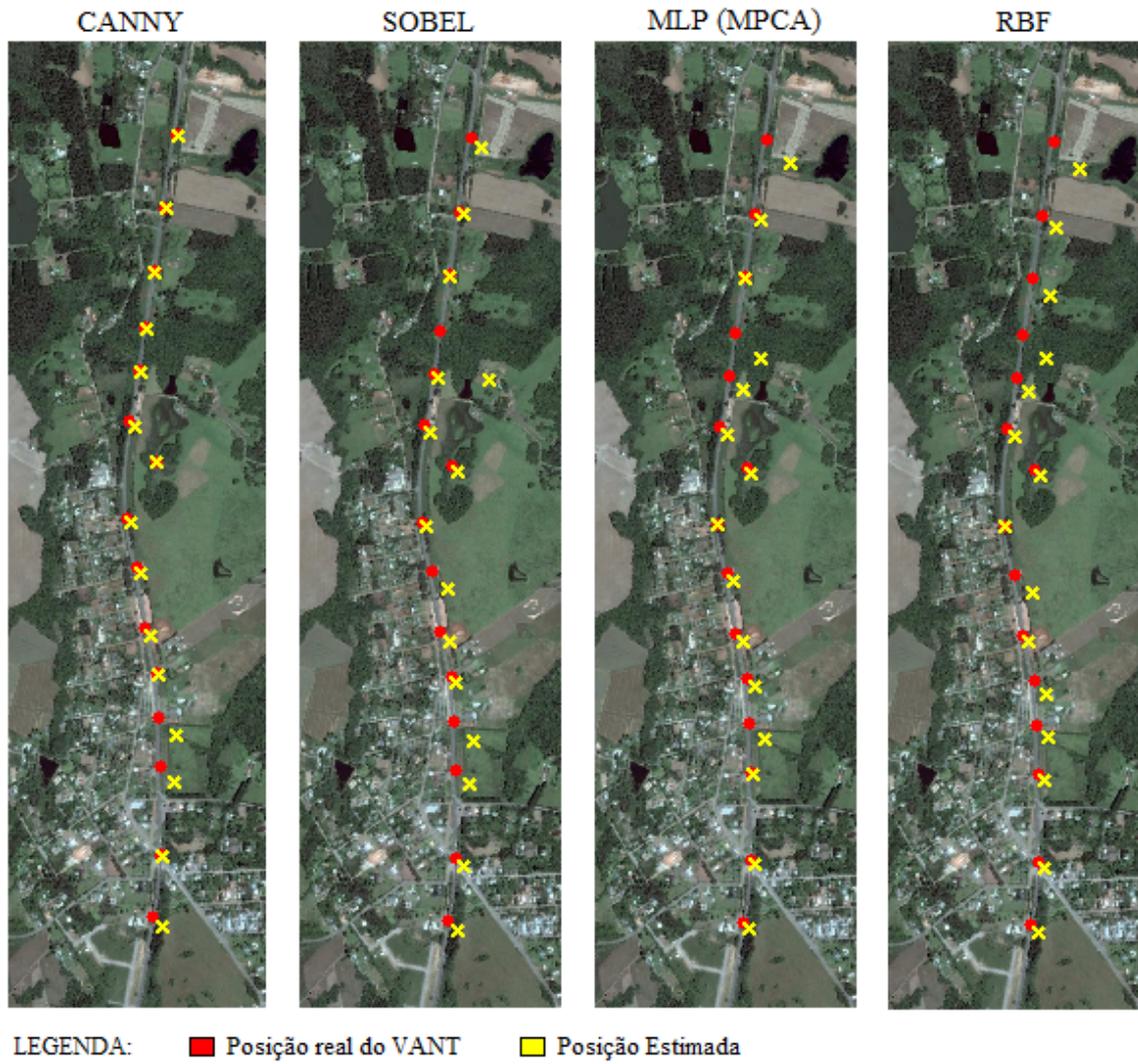
Figura 5.20 - Erro dos métodos utilizados x Região da rota.



A linha horizontal preta que corta o gráfico é o limiar.

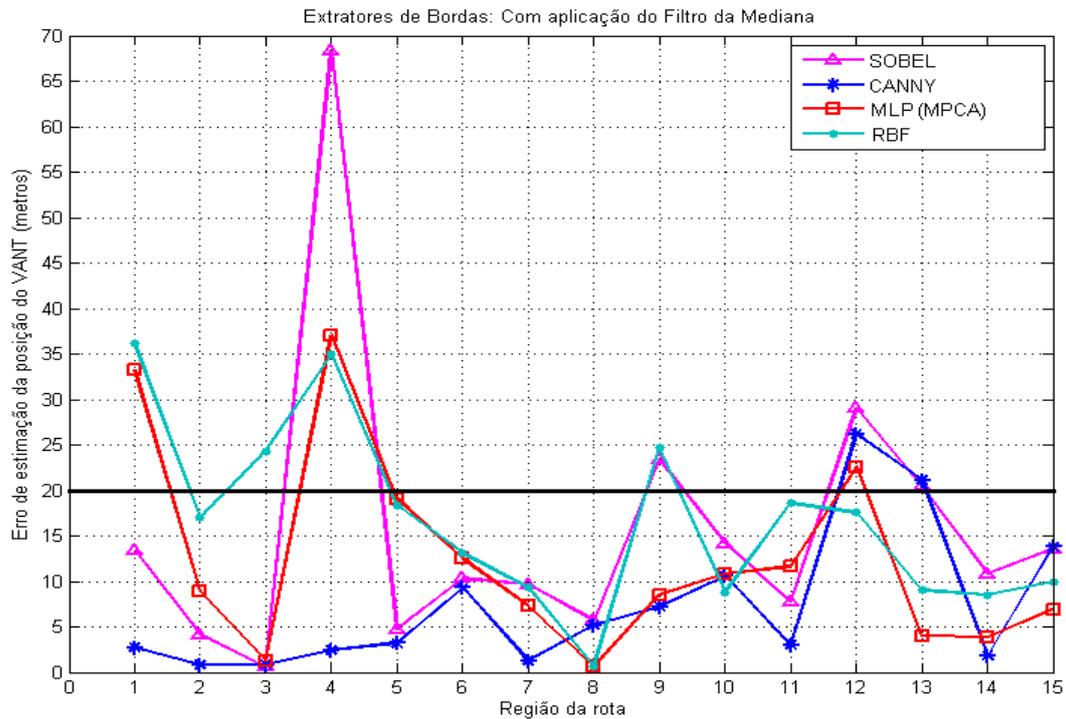
Neste experimento, buscou-se testar os métodos com uso do conjunto de treinamento para as redes neurais gerado pelos 26 padrões. Nas Figuras 5.21 e 5.22 são apresentados a estimação da posição do VANT na rota e o gráfico dos erros, respectivamente. Para a obtenção destes resultados foi aplicado o filtro da Mediana nas imagens e foram utilizadas as RNAs treinadas com 26 padrões de entrada. Nesse caso o Filtro da Mediana foi aplicado ao Canny. Pode-se notar, com a análise dos resultados das Figuras 5.21 e 5.22, que os resultados das RNAs melhoraram se comparados com os resultados no qual foi aplicado o conjunto gerado pelos 10 padrões de treinamento e o mesmo filtro, apresentados nas Figuras 5.15 e 5.16.

Figura 5.21 - Estimação da posição do VANT na rota.



Com aplicação do filtro da Mediana nas imagens e RNAs treinadas com o conjunto gerado pelos 26 padrões de entrada.

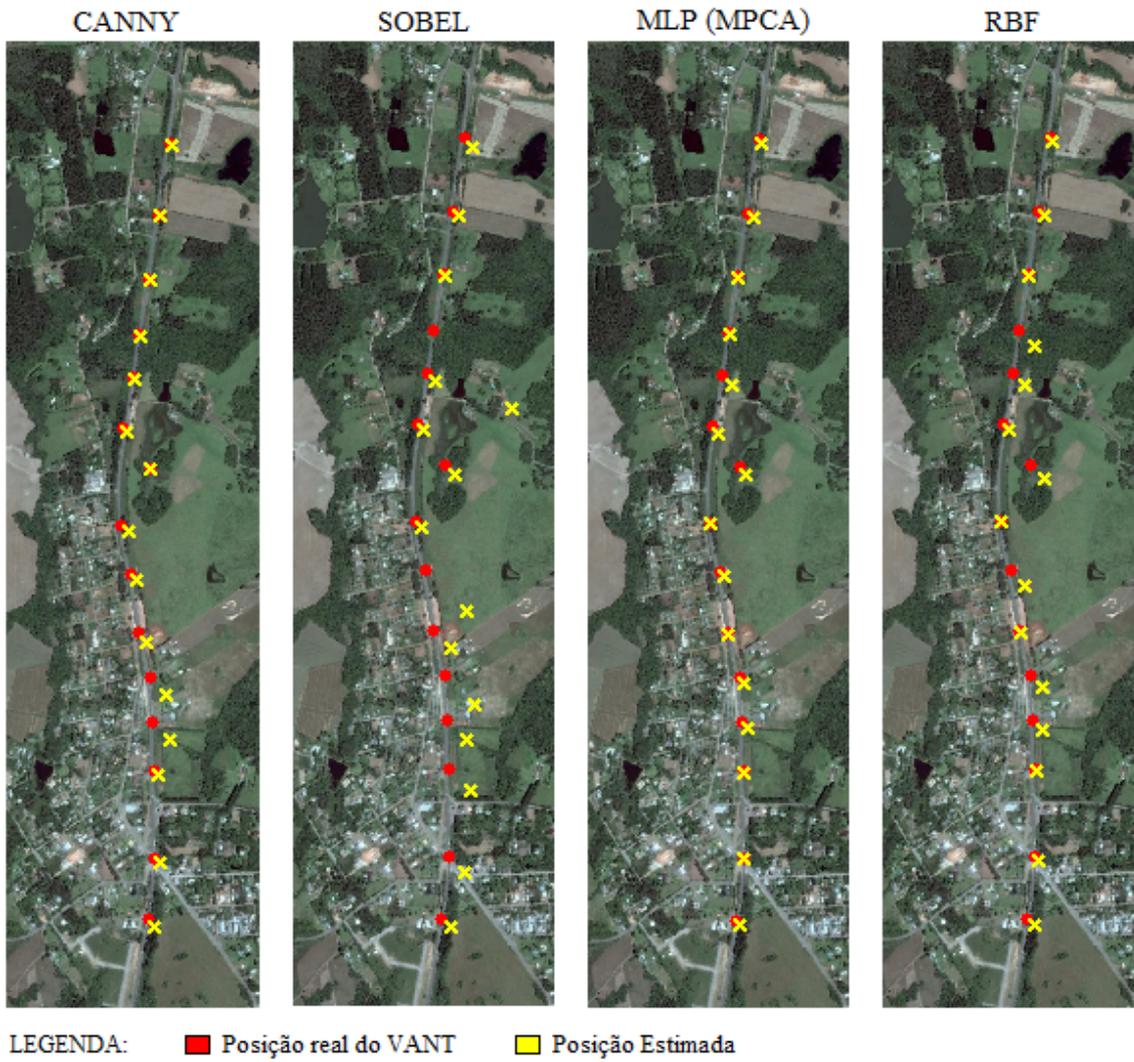
Figura 5.22 - Erro dos métodos utilizados x Região da rota.



A linha horizontal preta que corta o gráfico é o limiar.

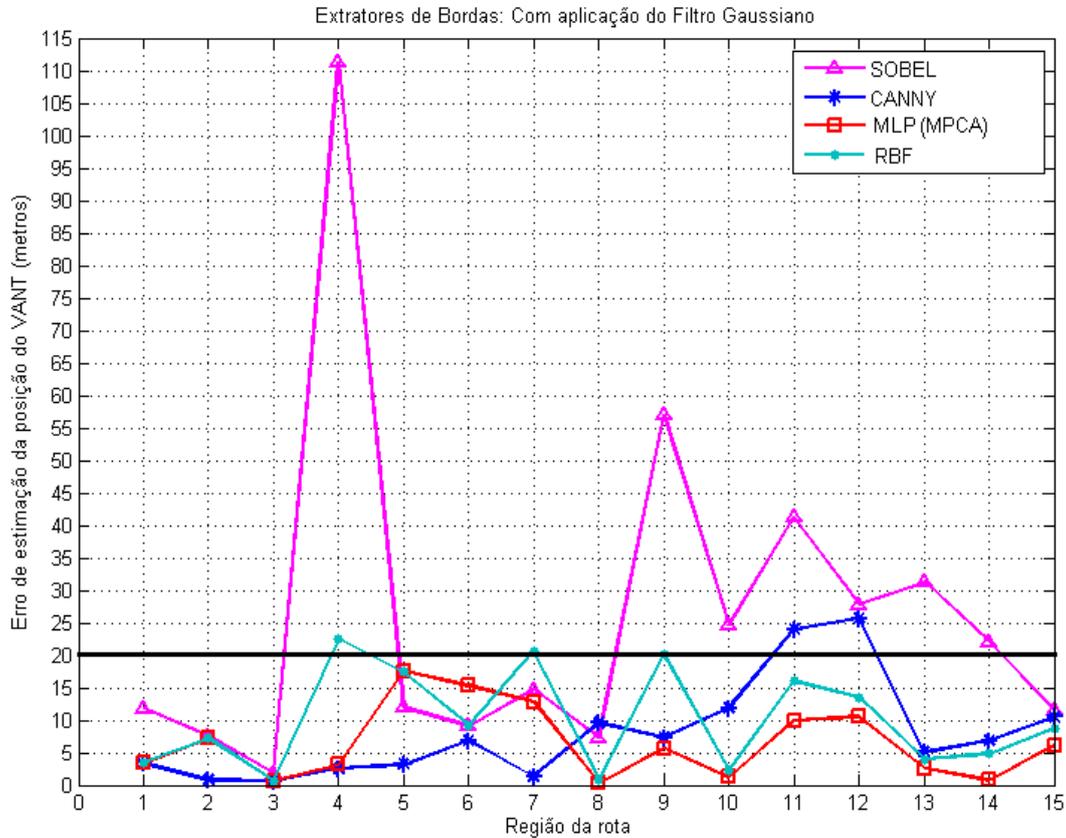
Para testar as hipóteses dessa dissertação de mestrado, neste experimento são empregados o conjunto gerado com 26 padrões e o filtro Gaussiano. Nas Figuras 5.23 e 5.24 são apresentadas a estimação da posição do VANT na rota e o gráfico dos erros, respectivamente. Para a obtenção destes resultados foi aplicado o filtro Gaussiano nas imagens e foram utilizadas as RNAs treinadas com o conjunto gerado pelos 26 padrões de entrada. Como o Canny já possui o filtro Gaussiano em seu algoritmo, esse filtro não foi aplicado. Pode-se observar que as RNAs, obtidas com a utilização do conjunto gerado pelos 26 padrões para seu treinamento, apresentaram excelentes resultados se comparadas aos resultados obtidos pelas RNAs treinadas com o conjunto gerado pelos 10 padrões e com a aplicação do mesmo filtro, apresentados nas Figuras 5.17 e 5.18. Pode-se observar ainda que as RNAs, com a aplicação do filtro Gaussiano e utilização do conjunto gerado pelos 26 padrões de treinamento, obtiveram melhores resultados que os operadores Sobel e Canny.

Figura 5.23 - Estimação da posição do VANT na rota.



Com aplicação do filtro Gaussiano nas imagens e RNAs treinadas com o conjunto gerado pelos 26 padrões de entrada.

Figura 5.24 - Extratores de bordas: Com aplicação do filtro Gaussiano e RNAs treinadas com o conjunto de 26 padrões.



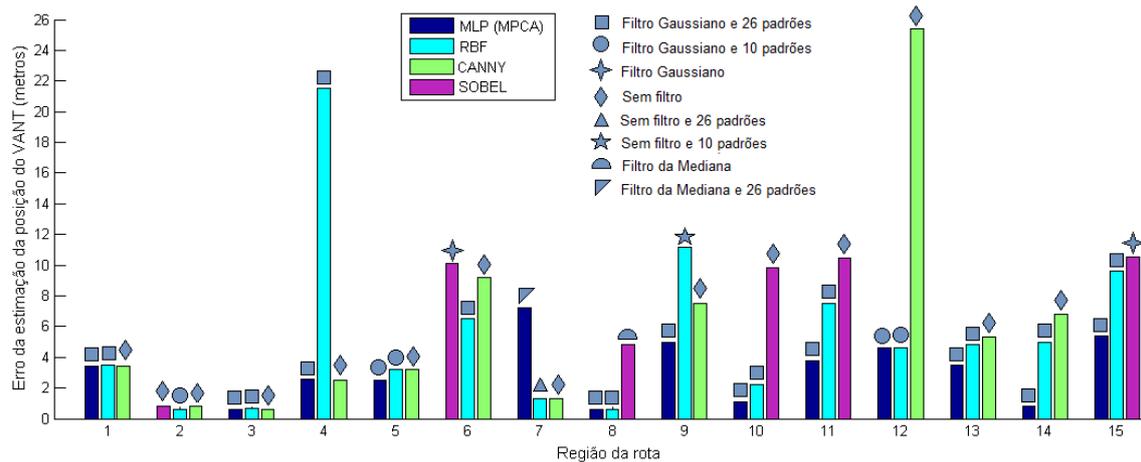
A linha horizontal preta que corta o gráfico é o limiar.

Os resultados obtidos, com todos os experimentos realizados com a rota, mostram que houve uma melhora significativa nos resultados quando o filtro Gaussiano era aplicado nas imagens, antes destas terem suas bordas extraídas. Os extratores de bordas que mais se beneficiaram disso foram as RNAs e o Canny, que já possui tal filtro aplicado em seu algoritmo. O operador Sobel apresentou melhores resultados com a aplicação do filtro da Mediana. Pode-se observar ainda, que as RNAs treinadas com o conjunto gerado pelos 26 padrões de treinamento obtiveram melhores resultados comparadas as treinadas com o conjunto gerado pelos 10 padrões. Além disso é possível se observar que a combinação de métodos como o tipo de filtro aplicado e conjunto de padrões de treinamento, apresentados nas Figuras 5.23 e 5.24, foi o que mais beneficiou as RNAs. Fazendo com que as RNAs tivessem melhores resultados do que os operadores tradicionais de bordas, colocando todos os seus resultados abaixo do limiar. Analisando mais detalhadamente as Figuras 5.23 e 5.24,

observa-se que a rede neural MLP obteve melhores resultados que a rede neural RBF e ainda que a rede neural MLP se saiu melhor que o operador Canny nas porções da imagem na qual o terreno é urbano e o Canny obteve os seus melhores resultados na porção mais rural do terreno.

Visando avaliar a melhor combinação das técnicas utilizadas e fazer a comparação do resultado da estimação da posição do VANT para cada região da rota, com uso dessas técnicas, foi gerado o gráfico da Figura 5.25. Este gráfico faz a comparação das melhores técnicas para a estimação da posição do VANT, para avaliar o melhor algoritmo de extração de bordas. No gráfico são comparados as três melhores técnicas de estimação da posição do VANT em cada região da rota.

Figura 5.25 - Comparação entre as melhores técnicas de estimação da posição do VANT para cada região da rota.



Analisando o gráfico da Figura 5.25 observa-se que o extrator de bordas Canny teve 20% dos melhores resultados, sendo estes obtidos exclusivamente na primeira metade da rota. Enquanto as RNAs obtiveram 66% dos melhores resultados e os 14% dos casos restantes tanto as RNAs quanto o Canny obtiveram resultados iguais. Sendo que na maioria dos casos, onde as RNAs obtiveram os melhores resultados, a rede neural MLP (MPCA) apresentou o menor erro de estimação da posição do VANT do que a rede neural RBF. Esses resultados obtidos podem estar relacionados a quantidade de bordas encontradas pelos extratores de bordas dependendo da região da rota.

Para analisar a relação entre a quantidade de bordas extraídas pelos algoritmos e o resultado da estimação da posição do VANT, os gráficos nas Figuras 5.27 e 5.26 são apresentados.

Figura 5.26 - Quantidade de bordas nas imagens capturada pelo VANT em função das técnica aplicadas para extração de borda.

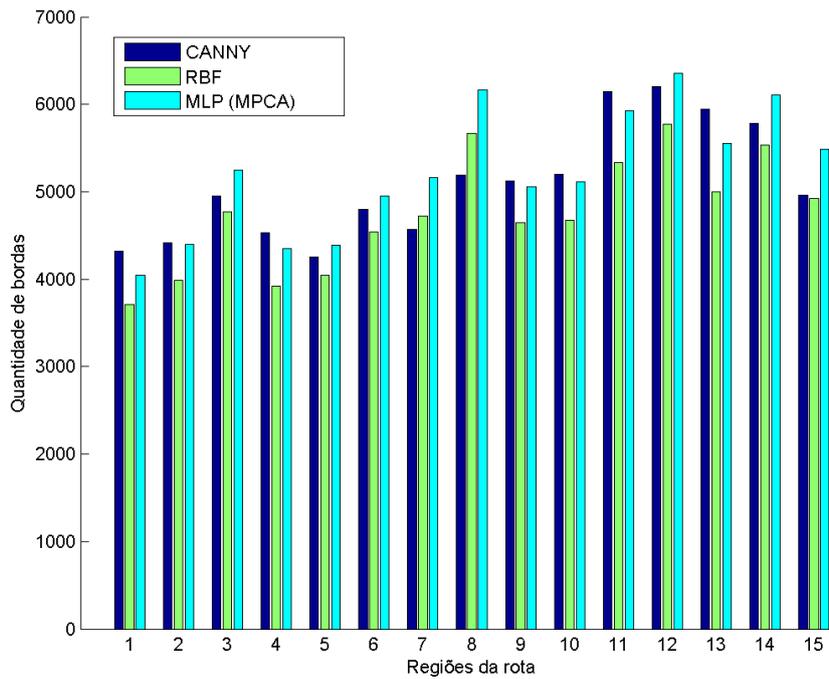
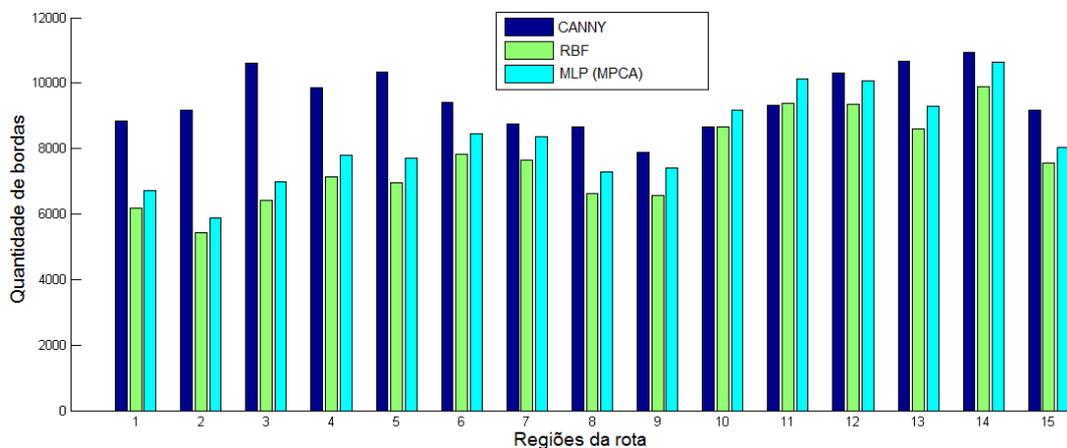


Figura 5.27 - Quantidade de bordas nas imagens capturada por satélite em função das técnica aplicadas para extração de borda.



Observa-se que na Figura 5.26, que apresenta a quantidade de bordas nas imagens capturadas pelo VANT, que a quantidade de bordas é semelhante entre as técnicas de extração de bordas em todas as regiões da rota. Na Figura 5.27, que apresenta a quantidade de bordas nas imagens capturadas por satélite na rota, observa-se que na primeira metade da trajetória o algoritmo Canny encontra uma quantidade maior de bordas do que as RNAs e na segunda metade as RNAs encontram quantidades iguais ou maiores que o algoritmo Canny. Os resultados obtidos, com os gráficos das Figuras 5.26 e 5.27 e levando em consideração os resultados apresentados pelo gráfico da Figura 5.25, mostram que quando o algoritmo de extração de bordas Canny encontra mais bordas que as RNAs ele apresenta também os menores erros de estimação da posição do VANT. E quando as RNAs e o Canny encontram quantidades semelhantes de bordas as RNAs apresentam os melhores resultados.

Para avaliar o melhor técnica de estimação da posição do VANT, utilizando diferentes algoritmos de extração de borda, diferentes conjuntos de treinamento e diferentes filtro, as Figuras 5.28 e 5.29 apresentam os gráficos do desvio do erro medido para cada ponto da trajetória dos dois melhores resultados obtidos e no **APÊNDICE A** são apresentados os outros gráficos gerados.

Figura 5.28 - Extrator de bordas Canny sem filtro aplicado.

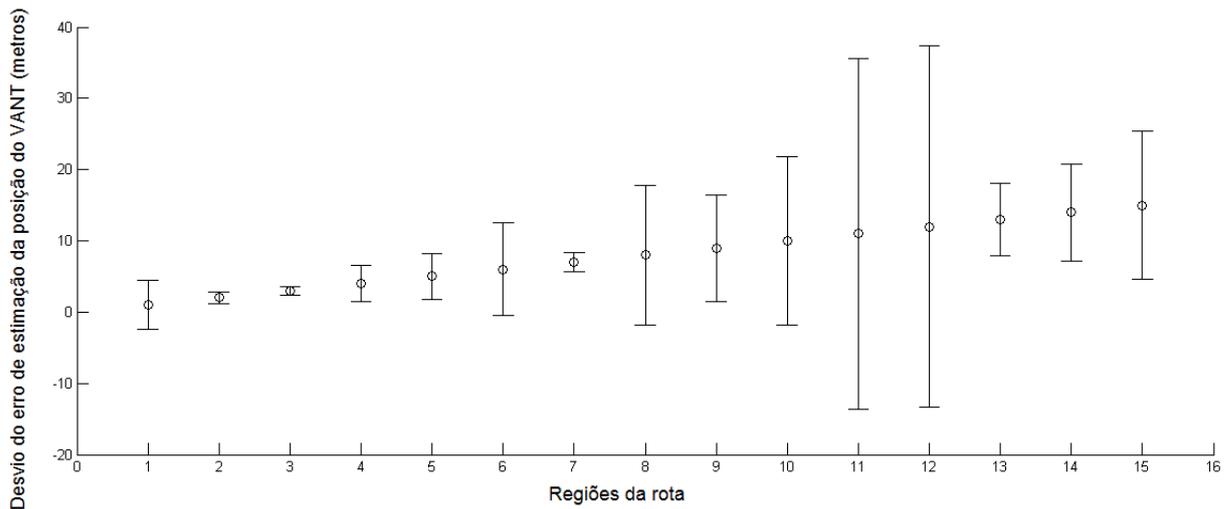
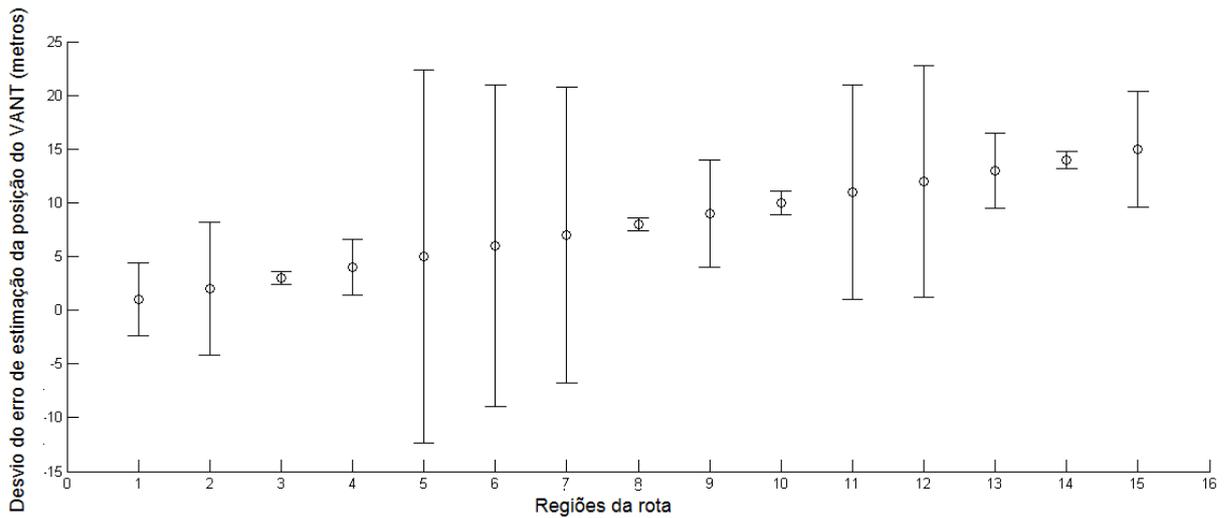


Figura 5.29 - Extrator de bordas rede neural MLP (MPCA) com Filtro Gaussiano e conjunto de treinamento gerado pelos 26 padrões.



Analisando dos gráficos das Figuras 5.28 e 5.29 é possível se observar que o resultado da técnica onde foi aplicado o algoritmo Canny em comparação à técnica onde o extrator de bordas utilizado foi a rede neural MLP (MPCA), apresenta menor erro e portanto melhores resultados na primeira metade da trajetória, ou seja, na região mais rural da rota. Enquanto a técnica onde o extrator de bordas utilizado foi a rede neural MLP (MPCA) apresenta a maioria dos seus melhores resultados na segunda metade da rota, onde a região é urbana. Mas fazendo uma análise geral do erro obtido pelos métodos verifica-se que a rede neural MLP (MPCA) possui melhor resultado.



## 6 CONSIDERAÇÕES FINAIS E SUGESTÕES

Neste trabalho foi apresentado que é possível estimar a posição sobrevoada por um VANT com uso de imagens termais e ópticas indicando que é possível realizar a navegação autônoma com essas imagens, o que propicia uma navegação noturna. São apresentados resultados de pesquisa e experimentações da estimação da posição do VANT em período noturno, utilizando RNAs no processo de detecção de bordas e com uso de imagens obtidas por dois diferentes sensores. Os estudos foram realizados utilizando quatro diferentes detectores de bordas, os tradicionais como o operador Canny e o Sobel, e as RNAs empregadas na tarefa de detecção de bordas. As RNAs aplicadas foram a rede neural RBF e a rede neural MLP. O emprego de RNA para a extração de bordas mostrou-se mais eficiente que as técnicas tradicionais em alguns cenários e a rede neural MLP apresentou resultados melhores que a rede neural RBF.

Para análise dos métodos propostos foram considerados diferentes experimentos. Esses experimentos foram divididos em duas principais fases: uma de capacitação com os conceitos e métodos necessários para o desenvolvimento do tema, com a aplicação dos métodos a uma única região e utilizando imagens adquiridas por sensores na banda do visível. Na segunda fase foram utilizadas imagens capturadas por diferentes sensores e foram consideradas duas situações: avaliação de uma única região e avaliação de uma rota de voo, com regiões urbanas, rural, de lagos e estradas.

Também foi apresentado que uma RNA autoconfigurada para a extração de bordas nas imagens termais e ópticas apresenta resultados melhores que uma RNA configurada empiricamente. No trabalho foram utilizados dois conjuntos de padrões um gerado com 10 e outro com 26 padrões de treinamento. Notou-se que o uso do conjunto de padrões com mais detalhes influencia no desempenho da detecção de bordas. As RNAs treinadas com o conjunto gerado pelos 26 padrões apresentou resultados melhores do que as treinadas com o conjunto gerado pelos 10 padrões. Foram comparados resultados do uso de padrões com os do filtro Gaussiano e da Mediana, o filtro Gaussiano apresentou resultados melhores comparados com o filtro da Mediana. Além disso, foram considerados diferentes cenários para a estimação da posição do VANT.

Os resultados encontrados mostram-se promissores, com a melhora nos resultados da RNA configurada pelo MPCA, com as RNAs apresentando resultados iguais os melhores em relação aos extratores tradicionais de bordas, com o excelente resultado da aplicação do conjunto de 26 padrões de treinamento das RNAs e com o bom resultado das imagens filtradas pelo filtro Gaussiano. Com base nesses resultados conclui-se que a utilização de diferentes sensores não interferem no processo de estimação da posição do VANT, que as RNAs podem ser efetivamente usadas como ferramentas para extração de bordas em imagens termais, que a configuração com o MPCA melhora os resultados e que os

elementos que compõem o conjunto de treinamento da RNA influencia no desempenho da estimação da posição do VANT. Os resultados obtidos evidenciam o potencial da aplicação dos métodos para a realização da navegação autônoma de VANT em período noturno, por exemplo, em razão de falha do GNSS ou em substituição a este.

As principais contribuições apresentadas nessa dissertação são:

- Desenvolvimento de um método para possibilitar a navegação autônoma noturna por meio de imagens e que não necessita de marcos fixos no terreno;
- Utilização de imagens capturadas por dois diferentes sensores, uma de satélite na banda do visível e outro de VANT, na banda do infravermelho termal;
- Aplicação do filtro Gaussiano nas imagens, antes destas terem suas bordas extraídas; e
- Utilização do MPCA, para configuração automática da rede neural MLP que faz a extração de bordas nas imagens.

A principal vantagem da utilização dos métodos em detrimento do uso da combinação do sistema GNSS e INS é que essa não depende de sinal externo. Outra vantagem é a possibilidade de utilização de dois sensores diferentes, para se fazer a estimação da posição do VANT, um de satélite na banda do visível e outro do VANT na banda do infravermelho termal.

Como continuidade das pesquisas realizadas até o presente momento, algumas possibilidades de trabalhos são:

- Implementação dos métodos desenvolvidos em hardware de baixo custo e consumo, por exemplo, Raspberry, computadores PC-104 ou FPGA (*Field Programmable Gate Array*), de modo que estes possam ser embarcados em VANTs; e
- Teste de sensor infravermelho termal em diferente faixa espectral, do que a utilizada nesta dissertação. O sensor utilizado se enquadra na região  $3 - 5\mu m$ , que segundo Jensen (2009) é especialmente útil para o monitoramento de alvos quentes como, por exemplo, incêndios florestais.

## REFERÊNCIAS BIBLIOGRÁFICAS

AMIDI, O.; KANADE, T.; FUJITA, K. A visual odometer for autonomous helicopter flight. In: BERNS, K.; GINI, M.; OTA, J. (Ed.). **Robotics and Autonomous System**. Elsevier, 1999. v. 28, p. 185–193. Disponível em:

<<http://www.sciencedirect.com/science/article/pii/S0921889099000160>>.

Acesso em: 06 mar. 2015. 9

ANDRADE, R. O. O voo do falcão. **Pesquisa FAPESP**, v. 211, p. 64–69, 2013. 2

ANOCHI, J. A. **Previsão climática de precipitação por redes neurais autoconfiguradas**. 2015. 159 p. Tese (Doutorado em Computação Aplicada) —

Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2015.

Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m21b/2015/09.16.22.02>>.

Acesso em: 02 ago. 2016. 31, 32

BRAGA, A. P.; CARVALHO, A.; LUDERMIR, T. **Redes neurais artificiais: teoria e aplicações**. 2. ed. Rio de Janeiro, RJ: LTC Editora, 2007. 25

BRAGA, J. R. G.; CONTE, G.; DOHERTY, P.; VELHO, H. F. C.; SHIGUEMORI, E. H. An image matching system for autonomous uav navigation based on neural network. In: XIV INTERNATIONAL CONFERENCE ON CONTROL, AUTOMATION, ROBOTICS AND VISION, 14., 2016, Pucket, Tailândia.

**Proceedings...** Pucket: IEEE, 2016. p. 1–6. 41, 42

BRAGA, J. R. G.; GOMES, V. C.; SHIGUEMORI, E. H.; VELHO, H. F. C.; PLAZA, A.; PLAZA, J. Nonlinear method of reduction of dimensionality based on artificial neural network and hardware implementation: theoretical and computational advances. In: CONSTANDA, C.; KIRSCH, A. (Ed.). **Integral methods in science and engineering**. Cham, Suíça: Birkhäuser Basel, 2015. p. 69–80. 4

CABALLERO, F.; MERINO, L.; FERRUZ, J.; OLLERO, A. Vision-based odometry and slam for medium and high altitude flying uavs. **Journal of Intelligent and Robotic Systems**, v. 1, p. 1–9, 2009. 9

CARVALHO, A. **Uso de redes neurais otimizadas para recuperação do perfil de concentração de gases traços atmosféricos a partir de dados de satélites**. 2011. 208 p. Tese (Doutorado em Computação Aplicada) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2011. Disponível em:

<<http://urlib.net/sid.inpe.br/mtc-m19/2011/06.06.12.20>>. Acesso em: 15 fev.

2015. 32, 33

- CHAVES, A. N. **Proposta de modelo de veículos aéreos não tripulados (VANTs) cooperativos aplicados à operação de busca**. 2013. 149 p. Dissertação (Mestrado em Ciências) — Universidade de São Paulo (USP), São Paulo, 2013. 2
- CONTE, D.; DOHERTY, P. An integrated uav navigation system based on aerial image matching. In: AEROSPACE CONFERENCE, 2008, Montana, USA. **Proceedings...** California, USA: IEEE, 2008. p. 1–10. 2, 6, 9, 15, 34, 37, 39, 43, 67
- CORKE, P. I.; SIKKA, P.; ROBERTS, J. M. Height estimation for an autonomous helicopter. In: RUS, D.; SINGH, S. (Ed.). **Experimental Robotics VII**. Berlin, Heidelberg: Springer, 2001. v. 271, p. 101–110. Disponível em: <<https://pdfs.semanticscholar.org/0022/e420526915064d0e84daac7e83ab0277f088.pdf>>. Acesso em: 02 mar. 2015. 9
- CRESTANI, P. R. J. **Sistemas inteligentes de navegação autônoma: uma abordagem modular e hierárquica com novos mecanismos de memória e aprendizagem**. 2001. 214 p. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Estadual de Campinas (UNICAMP), Campinas, 2001. 1
- DANTAS, G. F. S. M. **Enxame de VANTs para a detecção de incêndios florestais**. 2014. 66 p. Dissertação (Mestrado em Engenharia da Computação) — Escola Politécnica de Pernambuco (POLI), Recife, 2014. 2
- DEFESA AÉREA. **Esquadrão hórus**. 2016. Disponível em: <<http://www.defesaaereanaval.com.br/tag/esquadrao-horus/>>. Acesso em: 01 junho 2016. 49
- DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern classification**. 2. ed. New York, NY: Wiley, 2000. 26
- FABRO, J. A. **Grupos neurais e sistemas nebulosos: aplicação à navegação autônoma**. 1996. 75 p. Dissertação (Mestrado em Engenharia Elétrica) — Universidade Estadual de Campinas (UNICAMP), Campinas, 1996. 1
- FLORENZANO, T. **Iniciação em sensoriamento remoto**. 3. ed. São Paulo: Oficina de Textos, 2011. 11, 12
- GLOBALGEO. **Quickbird**. [s.n.], 2016. Disponível em: <<http://www.globalgeo.com.br/satelite/quickbird/>>. Acesso em: 10 fevereiro 2016. 46
- GOLTZ, G. A. M. **Redes neurais artificiais em imagens para estimação da posição de um VANT**. 2011. 116 p. Dissertação (Mestrado em Computação Aplicada) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2011. Disponível em: <<http://mtc-m16d.sid.inpe.br/col/sid.inpe.br/mtc-m19/2011/>>

04.01.13.25/doc/publicacao.pdf>. Acesso em: 10 jan. 2015. 2, 3, 6, 37, 41, 43, 47, 48, 55, 56, 59, 60, 61, 63, 73

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. 3. ed. São Paulo, SP: Blucher, 2011. 15, 16, 17, 19, 21, 39

GRIMES, J. G. **Global positioning system standard positioning service performance standard**. [s.n.], 2008. Disponível em:  
<<http://www.gps.gov/technical/ps/2008-SPS-performance-standard.pdf>>.  
Acesso em: 16 fevereiro 2016. 52, 71

GUIMARAES, J. P. F. **Controle de atitude para um veículo aéreo não tripulado do tipo quadricóptero**. 2012. 69 p. Tese (Doutorado em Engenharia Elétrica e de Computação) — Universidade Federal do Rio Grande do Norte (UFRN), Rio Grande do Norte, 2012. Disponível em:  
<<http://repositorio.ufrn.br:8080/jspui/handle/123456789/15212>>. Acesso em: 10 jan. 2015. 10

HARTMANN, G. A. **Anomalia magnética do atlântico sul: causas e efeito**. 2005. 151 p. Dissertação (Mestrado em Ciências Geofísicas) — Universidade de São Paulo (USP), São Paulo, 1996. 33

HARTMANN, G. A. A anomalia magnético atlântico sul: causas e efeitos. **Revista Brasileira de Geofísica**, v. 24, p. 445 – 445, 2006. 4

HAYKIN, S. **Redes neurais princípios e práticas**. 2. ed. Porto Alegre: Bookman, 2007. 23, 24, 25, 26, 27, 28, 29, 30, 31

HE, Z.; SIYAL, M. Edge detection with bp neural networks. In: INTERNATIONAL CONFERENCE ON SIGNAL PROCESSING PROCEEDINGS (ICSP), 4., 1998, Beijing, China. **Proceedings...** Beijing: IEEE, 1998. p. 1382–1384. 39

HUGHES, J.; DAM, A.; MCGUIRE, M.; SKLAR, D.; FOLEY, J.; FEINER, S.; AKELEY, K. **Computer graphics: principles and practice**. 3. ed. Boston, MA, USA: Addison-Wesley Professional, 2013. 14

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. 1. ed. São José dos Campos, SP: Parêntese, 2009. 12, 13, 90

KILLIAN, M. **Air force's secretive X-37B orbital test vehicle returns after nearly two years in orbit**. [s.n.], 2014. Disponível em:  
<<http://www.americaspace.com/?p=69210>>. Acesso em: 05 abril 2016. 9, 10

KIM, B. S.; CALISE, J. A. Nonlinear flight control using neural networks. **Journal of guidance, control, and dynamics**, v. 20, p. 18, 1997. 2, 26

LABORATÓRIO PITER. **Repositório de imagens do IEAv/DCTA**. São José dos Campos: Divisão de Geointeligência (EGI), 2016. 3 imagens. 47, 49, 50

LENSKIY, A. A.; LEE, J. S. Terrain images segmentation in infra-red spectrum for autonomous robot navigation. In: INTERNATIONAL FORUM ON STRATEGIC TECHNOLOGY (IFOST), 2010, Ulsan, Korea. **Proceedings...** [S.l.]: IEEE, 2010. p. 33–38. 3

LI, W.; WANG, C.; WANG, Q.; CHEN, G. An edge detection method based on optimized bp neural network. In: INTERNATIONAL SYMPOSIUM ON INFORMATION SCIENCE AND ENGINEERING, 2., 2008, Shangai, China. **Proceedings...** [S.l.]: IEEE, 2008. p. 40–44. 23, 39

LIMA, S. R. S. **Integração GPS-INS utilizando sensores inerciais baseados em sistemas microeletromecânicos (MEMS)**. 2005. 158 p. Tese (Doutorado em Ciências Geodésicas) — Universidade Federal do Paraná (UFPR), Curitiba, 2005. Disponível em: <[http://acervodigital.ufpr.br/bitstream/handle/1884/2351/Tese\\_Sandro\\_Lima.pdf?sequence=1](http://acervodigital.ufpr.br/bitstream/handle/1884/2351/Tese_Sandro_Lima.pdf?sequence=1)>. Acesso em: 06 ago. 2015. 33

LIU, J.; WANG, C. An algorithm for image binarization based on adaptive threshold. In: CHINESE CONTROL AND DECISION CONFERENCE (CCDC), 21., 2009, Guilin, China. **Proceedings...** [S.l.]: IEEE, 2009. p. 3958–3962. 14

LONGHITANO, G. A. **VANTs para sensoramento remoto: aplicabilidade na avaliação e monitoramento de impactos ambientais causados por acidentes com carga perigosa**. 2010. 163 p. Dissertação (Mestrado em Engenharia de Transportes) — Universidade de São Paulo (USP), São Paulo, 2010. 2

LUCCA, E. V. D.; BASTOS, A. F. Sistemas imagiadores infravermelho termal: características, descrição e resultados. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO (SBSR), 10., 2001, Foz do Iguaçu. **Anais...** São José dos Campos: INPE, 2001. p. 1433–1440. ISBN 85-17-00016-1. 14

LUZ, E. F. P. **Meta-heurísticas paralelas na solução de problemas inversos**. 2012. 155 p. Tese (Doutorado em Computação Aplicada) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2012. Disponível em: <<http://urlib.net/sid.inpe.br/mtc-m19/2012/02.22.17.13>>. Acesso em: 17 fev. 2015. 31, 32

MENESES, P.; ALMEIDA, T. **Introdução ao processamento de imagens de sensoramento remoto**. 1. ed. Brasília: CNPq, 2012. Disponível em: <<http://cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>>. 47

MITISHITA, E.; EDUARDO, J.; GRAÇA, N.; CENTENO, J.; MACHADO, A. O uso de veículos aéreos não tripulados (vants) em aplicações de mapeamento aerofotogramétrico.

In: CONGRESSO BRASILEIRO DE CARTOGRAFIA, 26., 2014, Gramado, Rio Grande do Sul. **Anais...** Rio Grande do Sul: UFRGS, 2014. p. 1–10. 2

MUTHUKRISHNAN, R.; RADHA, M. Edge detection techniques for image segmentation. **International Journal of Computer Science Information Technology (IJCSIT)**, v. 3, p. 259–267, 2011. 19

NISTÉR, D.; NARODITSKY, O.; BERGEN, J. Visual odometry for ground vehicle applications. **Journal of Field Robotics**, v. 23, p. 320, 2006. 1

OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, v. 9, p. 62–66, 1979. 14, 43

RATHINAM, S.; ALMEIDA, P.; KIM, Z. W.; JACKSON, S.; TINKA, A.; GROSSMAN, W.; SENGUPTA, R. Autonomous searching and tracking of a river using an uav. In: AMERICAN CONTROL CONFERENCE, 2007, New York City, USA. **Proceedings...** USA: IEEE, 2007. p. 359–364. 3

SACCO, W. F.; KNUPP, D. C.; LUZ, E. F. P.; SILVA, A. J. N. Algoritmo de colisão de partículas (particle collision algorithm): aplicação em problemas inversos em transferência radiativa. In: SILVA, A. J. N.; BECCENERI, J. O. (Ed.). **Técnicas de inteligência computacional inspiradas na natureza**. São Carlos, SP: SBMAC, 2009. p. 79–90. 31

SARIPALLY, S.; SUKHATME, G. Landing on a moving target using an autonomous helicopter. In: INTERNATIONAL CONFERENCE ON FIELD AND SERVICE ROBOTICS (FSR), 4., 2003, Mt Fuji, Japan. **Proceedings...** [S.l.]: Springer, 2003. p. 1–7. 9

SAUSER, B. **Robotic planes chase after climate data**. [s.n.], 2010. Disponível em: <<https://www.technologyreview.com/s/418226/robotic-planes-chase-after-climate-data/>>. Acesso em: 05 abril 2016. 10

SHIGUEMORI, E. H.; MONTEIRO, M. V. T.; MARTINS, M. P. Landmarks recognition for autonomous aerial navigation by neural networks and gabor transform. In: ANNUAL SYMPOSIUM ELECTRONIC IMAGING SCIENCE AND TECHNOLOGY, 19., 2007, San Jose, California, EUA. **Proceedings...** San Jose, California, EUA: SPIE, 2007. p. 1–6. 2

SILVA, W.; SHIGUEMORI, E. H.; VIJAYKUMAR, N. L.; VELHO, H. F. C. Estimation of uav position with use of thermal infrared images. In: INTERNATIONAL CONFERENCE ON SENSING TECHNOLOGY (ICST), 9., 2015, Auckland, New Zealand. **Proceedings...** New Zealand: IEEE, 2015. p. 828–833. 51

SJANIC, Z. **Navigation and SAR auto-focusing in a sensor fusion framework**. 2011. 261 p. Tese (Doutorado em Eletrical Engineering) — Linköping University (LIU), Linköping, Sweden, 2011. Disponível em:

<<http://users.isy.liu.se/en/rt/zoran/Publ/thesis1533.pdf>>. Acesso em: 02 mar. 2015. 2, 6, 37

TAKAI, M.; LAM, W.; URA, T. Vision based autonomous underwater vehicle navigation: underwater cable tracking. In: MTS/IEEE CONFERENCE PROCEEDINGS OCEANS '97, 2., 1997, Nova Scotia, Canada. **Proceedings...** [S.l.]: IEEE, 1997. p. 1418–1424. 1

TCHERNYKH, V.; BECK, M.; JANSCHKE, K. Optical flow navigation for an outdoor uav using a wide angle mono camera and dem matching. In: SYMPOSIUM ON MECHATRONIC SYSTEM (IFAC), 4., 2006, Heidelberg, Germany. **Proceedings...** [S.l.]: Elsevier, 2006. p. 1–6. 9

TERRY, P. J.; VU, D. Edge detection using neural networks. In: CONFERENCE ON SIGNALS, SYSTEMS AND COMPUTERS, 27., 1993. **Proceedings...** [S.l.]: IEEE, 1993. p. 391–395. 23, 39

VALASEK, J.; GUNNAM, K.; KIMMETT, J.; TANDALE, M. D.; JUNKINS, J. L. Vision-based sensor and navigation system for autonomous air refueling. **Journal of Guidance, Control and Dynamics**, v. 28, p. 979–989, 2005. 3

XIE, Y.; ZHU, Z.; ZHANG, X.; WANG, Q. An adaptive median filter using local texture information in images. In: INTERNATIONAL CONFERENCE ON COMPUTER AND INFORMATION SCIENCE (ICIS), 13., 2014, Taiyuan, China. **Proceedings...** [S.l.]: IEEE/ACIS, 2014. p. 177–180. 16

XMOBOTS. **VANTS echar 20B**. [s.n.], 2016. Disponível em: <<http://www.xmrobots.com/>>. Acesso em: 17 junho 2016. 39

YOO, C. S.; AHN, I. K. Low cost gps/ins sensor fusion system for uav navigation. In: DIGITAL AVIONICS SYSTEMS CONFERENCE (DASC), 22., 2003, Indianapolis, IN. **Proceedings...** [S.l.]: IEEE, 2003. p. 1–9. 33

## APÊNDICE A - GRÁFICOS DO DESVIO DO ERRO

Para avaliar o melhor método de estimação da posição do VANT, utilizando diferentes algoritmos de extração de borda; diferentes conjuntos de treinamento, quando o algoritmo de extração de bordas aplicado é uma RNA; e a aplicação de filtro, neste apêndice encontram-se todos os gráficos do desvio do erro medido para cada ponto da trajetória.

Figura A.1 - Extrator de bordas Sobel sem filtro aplicado.

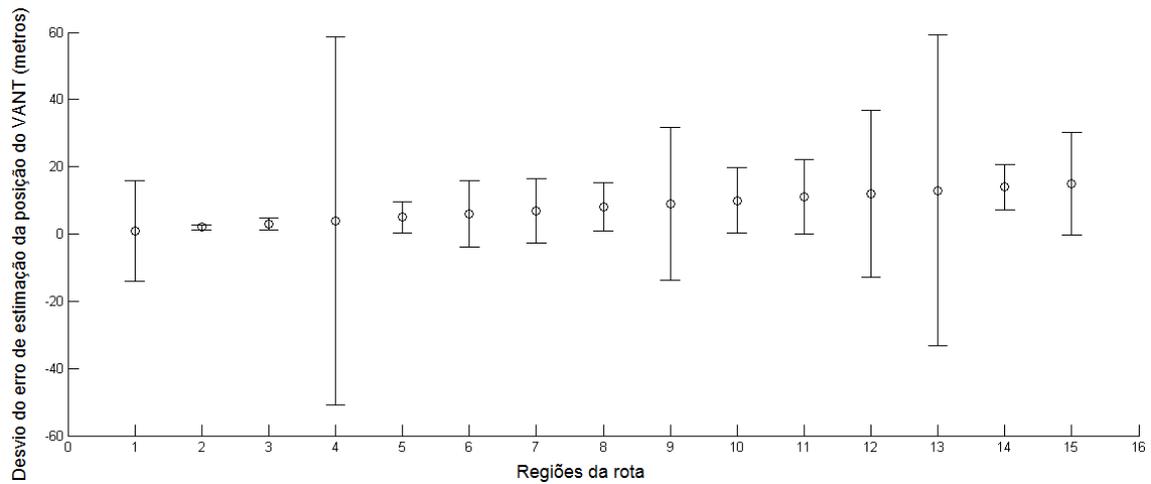


Figura A.2 - Extrator de bordas Sobel com Filtro da Mediana.

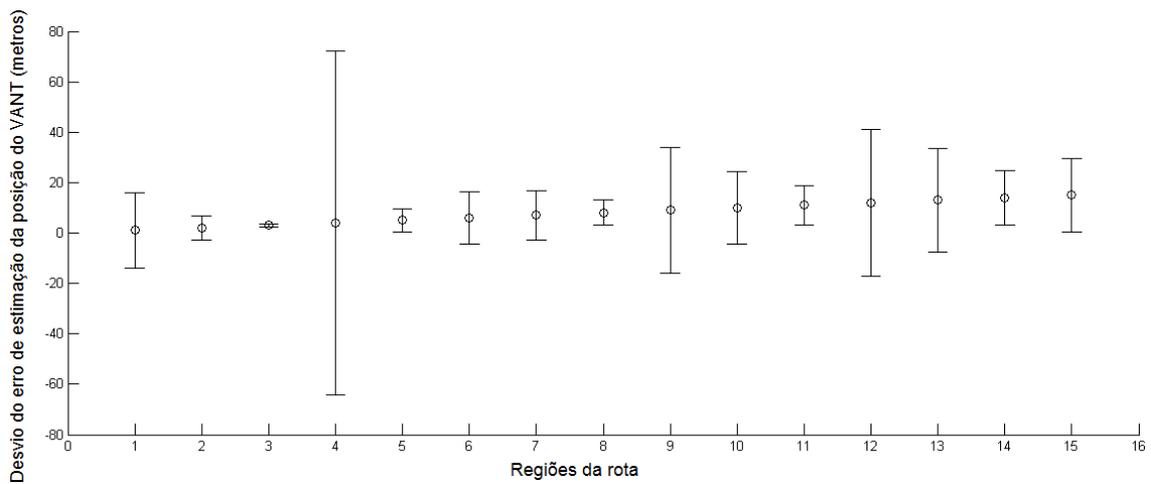


Figura A.3 - Extrator de bordas Sobel com Filtro Gaussiano.

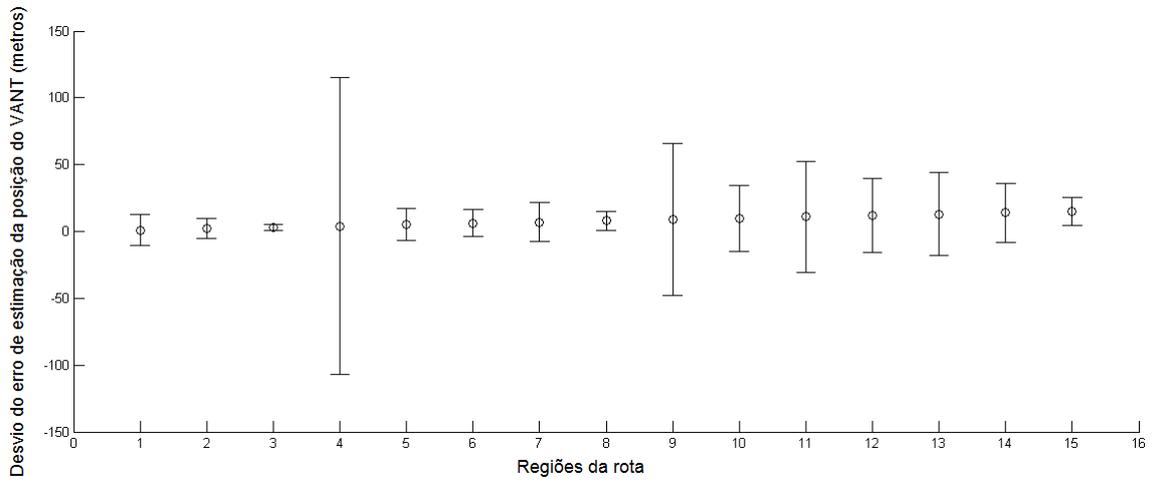


Figura A.4 - Extrator de bordas Canny com Filtro da Mediana.

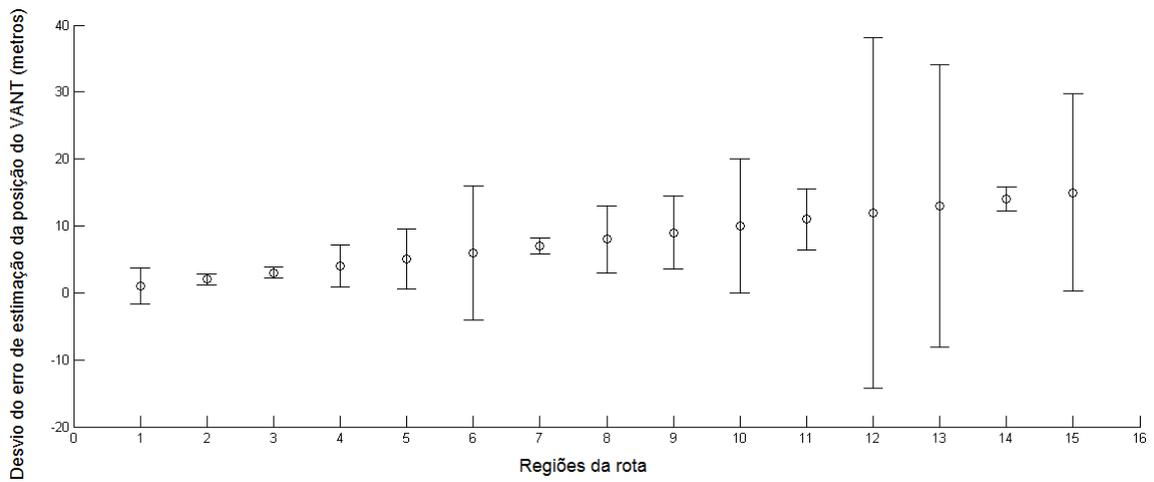


Figura A.5 - Extrator de bordas rede neural RBF sem filtro aplicado e conjunto de treinamento gerado pelos 10 padrões.

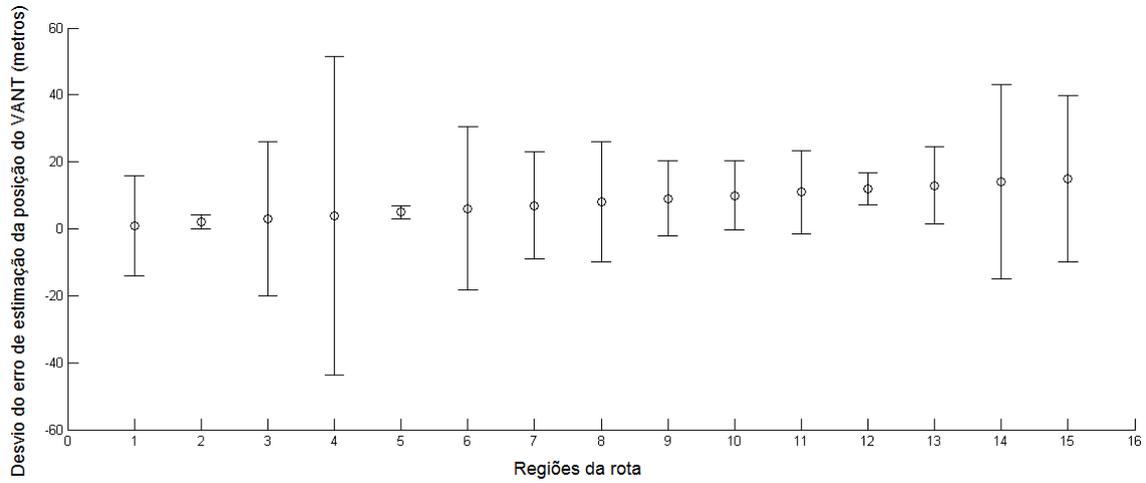


Figura A.6 - Extrator de bordas rede neural RBF sem filtro aplicado e conjunto de treinamento gerado pelos 26 padrões.

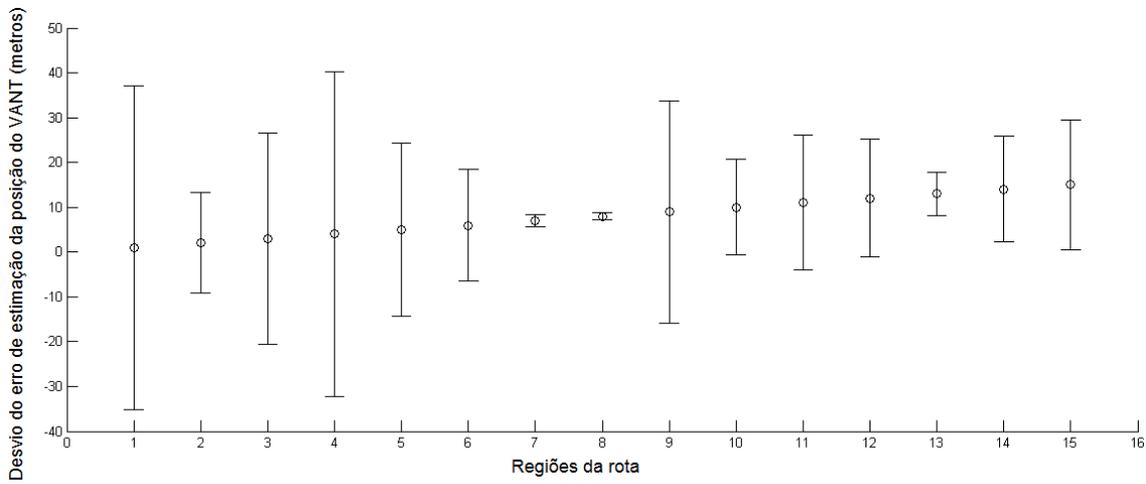


Figura A.7 - Extrator de bordas rede neural RBF com Filtro da Mediana e conjunto de treinamento gerado pelos 10 padrões.

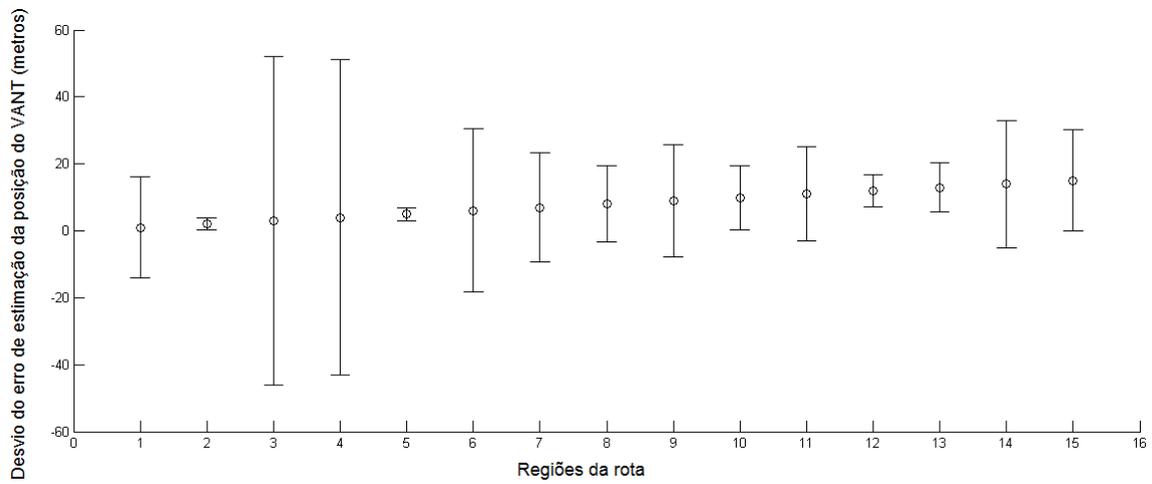


Figura A.8 - Extrator de bordas rede neural RBF com Filtro da Mediana e conjunto de treinamento gerado pelos 26 padrões.

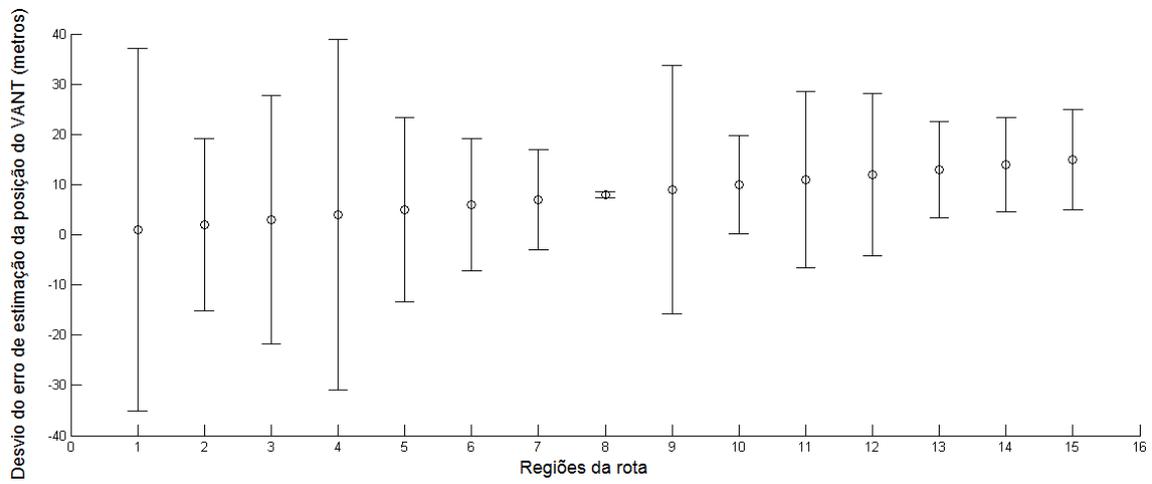


Figura A.9 - Extrator de bordas rede neural MLP (MPCA) com Filtro Gaussiano e conjunto de treinamento gerado pelos 10 padrões.

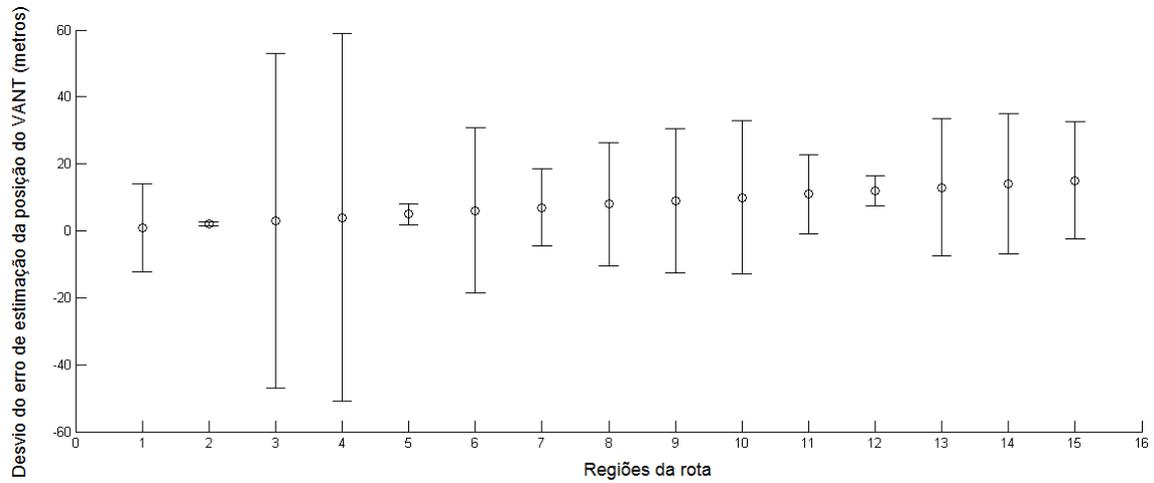


Figura A.10 - Extrator de bordas rede neural RBF com Filtro Gaussiano e conjunto de treinamento gerado pelos 26 padrões.

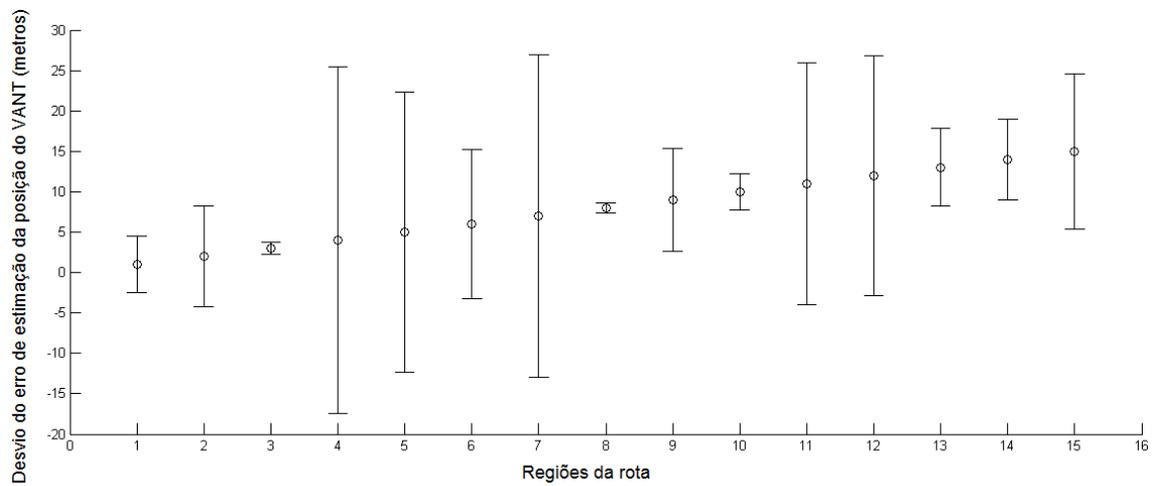


Figura A.11 - Extrator de bordas rede neural MLP (MPCA) sem filtro aplicado e conjunto de treinamento gerado pelos 10 padrões.

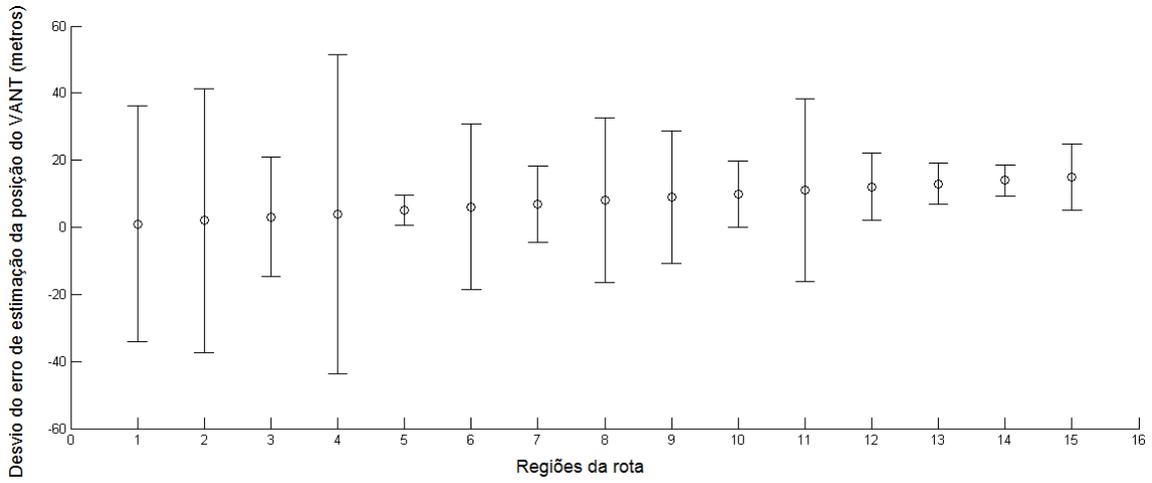


Figura A.12 - Extrator de bordas rede neural MLP (MPCA) sem filtro aplicado e conjunto de treinamento gerado pelos 26 padrões.

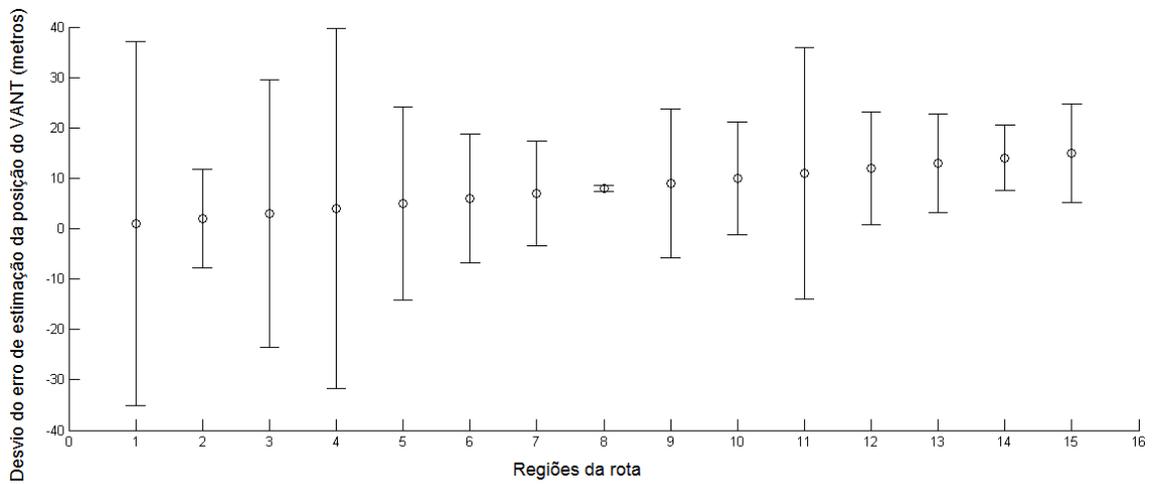


Figura A.13 - Extrator de bordas rede neural MLP (MPCA) com Filtro da Mediana e conjunto de treinamento gerado pelos 10 padrões.

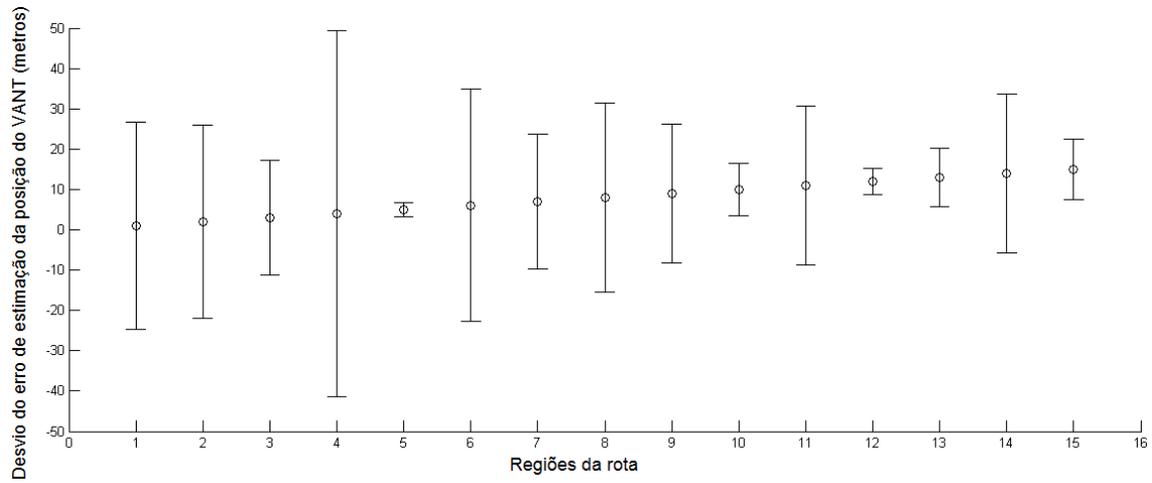


Figura A.14 - Extrator de bordas rede neural MLP (MPCA) com Filtro da Mediana e conjunto de treinamento gerado pelos 26 padrões.

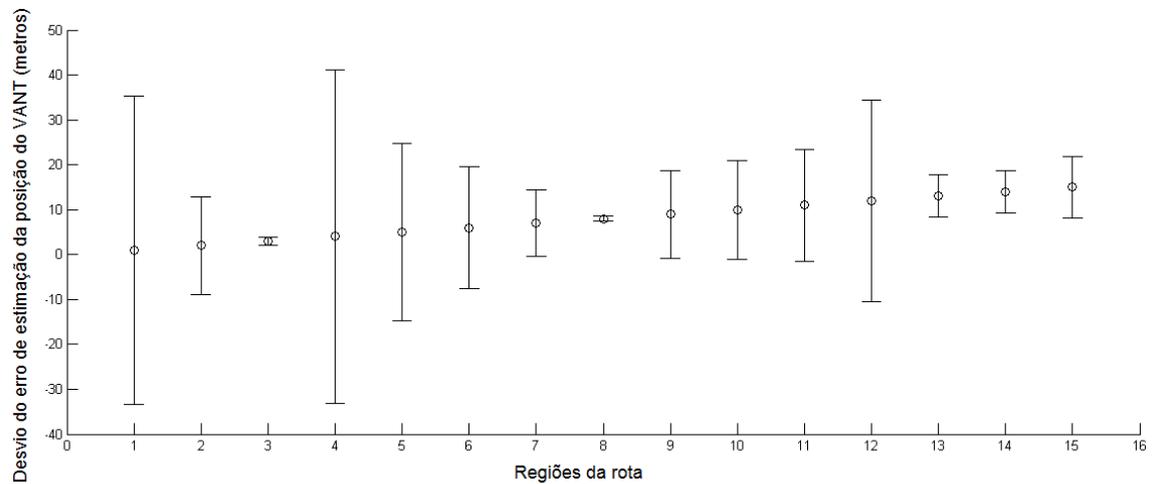


Figura A.15 - Extrator de bordas rede neural MLP (MPCA) com Filtro Gaussiano e conjunto de treinamento gerado pelos 10 padrões.

