



Ministério da
Ciência e Tecnologia



sid.inpe.br/mtc-m19/2011/04.01.13.25-TDI

REDES NEURAIS ARTIFICIAIS EM IMAGENS PARA ESTIMAÇÃO DA POSIÇÃO DE UM VANT

Gustavo Augusto Mascarenhas Goltz

Dissertação de Mestrado do Curso de Pós-Graduação em Computação Aplicada,
orientada pelos Drs. Haroldo Fraga de Campos Velho, e Elcio Hideiti Shiguemori,
aprovada em 06 de maio de 2011.

URL do documento original:

<<http://urlib.net/8JMKD3MGP7W/39EBJ7S>>

INPE
São José dos Campos
2011

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@sid.inpe.br

CONSELHO DE EDITORAÇÃO E PRESERVAÇÃO DA PRODUÇÃO INTELLECTUAL DO INPE (RE/DIR-204):**Presidente:**

Dr. Gerald Jean Francis Banon - Coordenação Observação da Terra (OBT)

Membros:

Dr^a Inez Staciarini Batista - Coordenação Ciências Espaciais e Atmosféricas (CEA)

Dr^a Maria do Carmo de Andrade Nono - Conselho de Pós-Graduação

Dr^a Regina Célia dos Santos Alvalá - Centro de Ciência do Sistema Terrestre (CST)

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Dr. Ralf Gielow - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

Dr. Wilson Yamaguti - Coordenação Engenharia e Tecnologia Espacial (ETE)

Dr. Horácio Hideki Yanasse - Centro de Tecnologias Especiais (CTE)

BIBLIOTECA DIGITAL:

Dr. Gerald Jean Francis Banon - Coordenação de Observação da Terra (OBT)

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

Deicy Farabello - Centro de Previsão de Tempo e Estudos Climáticos (CPT)

REVISÃO E NORMALIZAÇÃO DOCUMENTÁRIA:

Marciana Leite Ribeiro - Serviço de Informação e Documentação (SID)

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

EDITORAÇÃO ELETRÔNICA:

Vivéca Sant´Ana Lemos - Serviço de Informação e Documentação (SID)



Ministério da
Ciência e Tecnologia



sid.inpe.br/mtc-m19/2011/04.01.13.25-TDI

REDES NEURAIS ARTIFICIAIS EM IMAGENS PARA ESTIMAÇÃO DA POSIÇÃO DE UM VANT

Gustavo Augusto Mascarenhas Goltz

Dissertação de Mestrado do Curso de Pós-Graduação em Computação Aplicada,
orientada pelos Drs. Haroldo Fraga de Campos Velho, e Elcio Hideiti Shiguemori,
aprovada em 06 de maio de 2011.

URL do documento original:

<<http://urlib.net/8JMKD3MGP7W/39EBJ7S>>

INPE
São José dos Campos
2011

Dados Internacionais de Catalogação na Publicação (CIP)

Goltz, Gustavo Augusto Mascarenhas.
G583r Redes neurais artificiais em imagens para estimação da posição
de um VANT / Gustavo Augusto Mascarenhas Goltz. – São José
dos Campos : INPE, 2011.
xxvi+90 p. ; (sid.inpe.br/mtc-m19/2011/04.01.13.25-TDI)

Dissertação (Mestrado em Computação Aplicada) – Instituto
Nacional de Pesquisas Espaciais, São José dos Campos, 2011.

Orientadores : Drs. Haroldo Fraga de Campos Velho, e Elcio
Hideiti Shiguemori.

1. Redes neurais artificiais. 2. Reconhecimento de padrões em
imagens. 3. Navegação aérea autônoma. 4. Processamento de ima-
gens. I. Título.

CDU 004.032.26

Copyright © 2011 do MCT/INPE. Nenhuma parte desta publicação pode ser reproduzida, armazenada em um sistema de recuperação, ou transmitida sob qualquer forma ou por qualquer meio, eletrônico, mecânico, fotográfico, reprográfico, de microfilmagem ou outros, sem a permissão escrita do INPE, com exceção de qualquer material fornecido especificamente com o propósito de ser entrado e executado num sistema computacional, para o uso exclusivo do leitor da obra.

Copyright © 2011 by MCT/INPE. No part of this publication may be reproduced, stored in a retrieval system, or transmitted in any form or by any means, electronic, mechanical, photocopying, recording, microfilming, or otherwise, without written permission from INPE, with the exception of any material supplied specifically for the purpose of being entered and executed on a computer system, for exclusive use of the reader of the work.

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

Dra. Sandra Aparecida Sandri



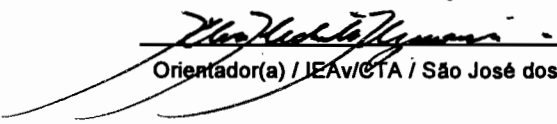
Presidente / INPE / SJCampos - SP

Dr. Haroldo Fraga de Campos Velho



Orientador(a) / INPE / São José dos Campos - SP

Dr. Elcio Hideiti Shiguemori



Orientador(a) / IEAv/CTA / São José dos Campos - SP

Dra. Leila Maria Garcia Fonseca




Membro da Banca / INPE / SJCampos - SP

Dr. Luciano Vieira Dutra



Membro da Banca / INPE / SJCampos - SP

Dr. Antonio de Pádua Braga



Convidado(a) / UFMG / Belo Horizonte - MG

Este trabalho foi aprovado por:

- maioria simples
- unanimidade

Aluno (a): Gustavo Augusto Mascarenhas Goltz

São José dos Campos, 06 de maio de 2011

“O Brasil espera que cada um cumpra o seu dever!”

ALMIRANTE BARROSO
“Batalha Naval do Riachuelo”, 11 de junho 1865

A Deus e a meus pais ...

AGRADECIMENTOS

Agradeço a Deus e a meus pais pela dádiva da vida e por terem me guiado e me guardado sempre.

Agradeço aos meus orientadores, Dr. Haroldo e Dr. Elcio, pelos conhecimentos passados, pela paciência, pela amizade, pela ajuda que sempre pude contar durante todo o mestrado e pelas idéias que nortearam minha dissertação.

Agradeço aos colegas e professores do INPE e do IEAv pela amizade e companheirismo. Sempre estiveram disponíveis para me ajudar e ensinar. Agradeço a Deus a oportunidade de ter conhecido todos vocês, espero sempre poder revê-los de tempos em tempos, visitando o INPE e o IEAv quando possível. Foi uma satisfação poder contar com todos durante este período. Muito obrigado.

Agradeço ao INPE pela oportunidade de estudo, ao IEAv pelo auxílio financeiro e disponibilidade de dados, e ao CNPq pelo auxílio financeiro.

RESUMO

A aplicação de Veículos Aéreos Não Tripulados (VANTs) intensificou-se nos últimos tempos devido ao baixo custo operacional e de fabricação comparados às aeronaves convencionais, ausência de tripulação (aplicações em tarefas tediosas, cansativas ou que envolvem risco à tripulação), maior autonomia, entre outros fatores. A navegação aérea por imagens, capturadas em tempo real da região sobrevoada pelo VANT, é uma alternativa para a navegação autônoma destas aeronaves. As Redes Neurais Artificiais (RNAs) são ferramentas usadas com sucesso em diversas aplicações que envolvem processamento de imagens devido ao seu baixo custo computacional, tolerância a falhas e robustez ao ruído. A navegação aérea autônoma por imagens é uma aplicação com potencial para o emprego de RNAs por necessitar de processamento rápido, embarcado e tolerante a falhas. Neste contexto foram usadas três RNAs com treinamento supervisionado e de diferentes arquiteturas (rede com funções de base radial, rede perceptron de múltiplas camadas e rede neural celular) aplicadas na extração de bordas em imagens aéreas e de satélite, para posterior cálculo da correlação no domínio espacial entre as bordas dessas imagens, a fim de simular a estimação da posição geográfica de um VANT. A informação de borda neste caso é interessante por ser invariável ao tipo de sensor de imageamento (satélite e imagens aéreas). Para a aplicação, as redes neurais foram comparadas com os operadores Sobel e Canny.

ARTIFICIAL NEURAL NETWORKS ON IMAGES FOR UAV POSITION ESTIMATION

ABSTRACT

The application of Unmanned Aerial Vehicles (UAVs) has intensified in recent years due to low operating cost and manufacturing compared to conventional aircraft, no crew (applications on tedious tasks, tiring, or that involve risk to the crew), more autonomy, among other factors. The navigation based on images, captured in real time of the area overflown by the UAV, is an alternative for autonomous navigation of such aircraft. Artificial Neural Networks (ANNs) are powerful tools used in various applications involving image processing due to its low computational cost, fault tolerance and robustness to noise. The autonomous navigation of images is an application for employment potential of ANNs because need fast processing, embedded code, and fault tolerance. In this context, three ANNs were approached with supervised training and different architectures (neural network radial basis function, multilayer perceptron and cellular neural network) applied in edge detection on aerial and satellite images, for later calculation of the correlation in spatial domain between these images to simulate the estimation of the geographical position of a vehicle autonomous unmanned air. For the application, these ANNs were compared with the Sobel operator and Canny algorithm.

LISTA DE FIGURAS

	<u>Pág.</u>
1.1 VANT com a imagem terrestre capturada em tempo real (B) correspondendo-se à imagem de satélite (A).	6
2.1 No sentido horário: <i>Aerosonde</i> ¹ , <i>Heron</i> ² e <i>Global Hawk</i> ³	11
2.2 VANT usado nos experimentos de Conte e Doherty (2008).	14
3.1 Máscaras g_1 (esquerda) e g_2 (direita) detectoras de bordas de Roberts, usadas na detecção das bordas da Figura 3.2.	18
3.2 Uma imagem aérea em tons de cinza (255 bits) e suas bordas extraídas pelo operador de Roberts.	18
3.3 (a) máscara detectora de bordas em x e (b) em y de Sobel, usadas para detectar as bordas da Figura 3.4.	19
3.4 Uma imagem aérea em tons de cinza (255 bits) e suas bordas extraídas pelo operador Sobel.	20
3.5 Máscara de convolução do operador Laplaciano, usada para detectar as bordas da Figura 3.6.	20
3.6 Uma imagem aérea e suas bordas extraídas pelo operador Laplaciano.	21
3.7 Uma imagem aérea e suas bordas extraídas pelo operador Canny sem histerese.	23
4.1 Conexões do neurônio central de uma RNC.	28
5.1 Padrões de treinamento da RBF e da RPMC. À direita os dois padrões sem borda.	29
5.2 Fluxograma de ativação da rede RBF e da RPMC e formação da imagem de saída contendo as bordas.	30
5.3 Padrões de treinamento da RNC. À direita os dois padrões sem borda.	32
5.4 Fluxograma de ativação da RNC e formação da imagem de saída contendo as bordas.	33
5.5 Passos do processo de casamento.	35
6.1 Imagem aérea (a) corrigida corretamente em relação à imagem de satélite (c) e imagem aérea (b) com inserção de ruído em +10% na escala e +10% na rotação. Em vermelho a região na imagem de satélite (c) correspondente às imagens aéreas (a) e (b).	44

6.2	Ponto estimado (vermelho) com o uso da RNC e ponto correto (amarelo). A imagem menor corresponde-se à imagem aérea e a maior à imagem de satélite.	47
6.3	Estimação da posição do VANT com a RNC. Erro de 1,8974 metros. Em amarelo o ponto correto e em vermelho o ponto estimado. Ruído de +10% em escala e -5% em rotação. A imagem menor corresponde-se à imagem aérea e a maior à imagem de satélite.	50
A.1	Região 1: direita imagem aérea e esquerda de satélite.	65
A.2	Região 2: direita imagem aérea e esquerda de satélite.	65
A.3	Região 3: direita imagem aérea e esquerda de satélite.	66
A.4	Região 4: direita imagem aérea e esquerda de satélite.	66
A.5	Região 5: direita imagem aérea e esquerda de satélite.	66
A.6	Região 6: direita imagem aérea e esquerda de satélite.	67
B.1	Região 1: direita imagem aérea e esquerda de satélite.	69
B.2	Região 2: direita imagem aérea e esquerda de satélite.	69
B.3	Região 3: direita imagem aérea e esquerda de satélite.	70
B.4	Região 4: direita imagem aérea e esquerda de satélite.	70
B.5	Região 5: direita imagem aérea e esquerda de satélite.	70
B.6	Região 6: direita imagem aérea e esquerda de satélite.	71
C.1	Região 1: direita imagem aérea e esquerda de satélite.	73
C.2	Região 2: direita imagem aérea e esquerda de satélite.	73
C.3	Região 3: direita imagem aérea e esquerda de satélite.	74
C.4	Região 4: direita imagem aérea e esquerda de satélite.	74
C.5	Região 5: direita imagem aérea e esquerda de satélite.	74
C.6	Região 6: direita imagem aérea e esquerda de satélite.	75
D.1	Região 1: direita imagem aérea e esquerda de satélite.	77
D.2	Região 2: direita imagem aérea e esquerda de satélite.	77
D.3	Região 3: direita imagem aérea e esquerda de satélite.	78
D.4	Região 4: direita imagem aérea e esquerda de satélite.	78
D.5	Região 5: direita imagem aérea e esquerda de satélite.	78
D.6	Região 6: direita imagem aérea e esquerda de satélite.	79
E.1	Região 1: direita imagem aérea e esquerda de satélite.	81
E.2	Região 2: direita imagem aérea e esquerda de satélite.	81
E.3	Região 3: direita imagem aérea e esquerda de satélite.	82
E.4	Região 4: direita imagem aérea e esquerda de satélite.	82

E.5	Região 5: direita imagem aérea e esquerda de satélite.	82
E.6	Região 6: direita imagem aérea e esquerda de satélite.	83
F.1	Resumo publicado nos Anais do 32 ^o CNMAC: Congresso Nacional de Matemática Aplicada e Computacional (Ano: 2009).	86
F.2	Resumo publicado nos Anais do IX WAI: <i>Workshop</i> Anual de Pesquisa e Desenvolvimento do IEAv (Ano: 2009).	87
F.3	Artigo publicado nos Anais do IX SIGE: Simpósio de Aplicações Operacionais em Áreas de Defesa (Ano: 2009).	90

LISTA DE TABELAS

	<u>Pág.</u>
5.1 Resoluções do Satélite <i>Quickbird</i>	36
6.1 Valores de parâmetros testados durante o desenvolvimento da RBF. Na terceira coluna, os valores escolhidos.	40
6.2 Valores de parâmetros testados durante o desenvolvimento da RPMC. Na terceira coluna, os valores escolhidos.	40
6.3 Valores de parâmetros testados durante o desenvolvimento da RNC. Na terceira coluna, os valores escolhidos.	41
6.4 Porcentagem de pontos de borda e EQM para as imagens aéreas.	42
6.5 Porcentagem de pontos de borda e EQM para as imagens de satélite.	42
6.6 Erro médio em metros para cada situação definida de ruído em escala e rotação nas imagens normalizadas.	45
6.7 Erro médio em metros para cada situação definida de ruído em escala e rotação com a RNC.	45
6.8 Erro médio em metros para cada situação definida de ruído em escala e rotação com o operador Sobel.	46
6.9 Erro médio em metros para cada situação definida de ruído em escala e rotação com a RPMC.	46
6.10 Erro médio em metros para cada situação definida de ruído em escala e rotação com a RBF.	46
6.11 Erro médio em metros para cada situação definida de ruído em escala e rotação com o algoritmo Canny.	46
6.12 Quantidade de amostras com erro menor ou igual a 10 metros para a RNC.	47
6.13 Quantidade de amostras com erro menor ou igual a 10 metros para o operador Sobel.	48
6.14 Quantidade de amostras com erro menor ou igual a 10 metros para a RPMC.	48
6.15 Quantidade de amostras com erro menor ou igual a 10 metros para a RBF.	48
6.16 Quantidade de amostras com erro menor ou igual a 10 metros para o algoritmo Canny.	48
6.17 Soma dos erros médios, em metros, e soma das amostras com erro menor ou igual a 10 metros para cada operador estudado.	49

6.18 Tempo de processamento, em segundos, de cada operador para os recortes das imagens aéreas e de satélite.	49
---	----

LISTA DE ABREVIATURAS E SIGLAS

CTEx	–	Centro Tecnológico do Exército
DCTA	–	Departamento de Ciência e Tecnologia Aeroespacial
DEM	–	<i>Digital Elevation Map</i>
EQM	–	Erro Quadrático Médio
GNSS	–	<i>Global Navigation Satellite System</i>
GPS	–	<i>Global Positioning System</i>
IEAv	–	Instituto de Estudos Avançados
INS	–	<i>Inertial Navigation System</i>
IPqM	–	Instituto de Pesquisas da Marinha
PITER -	–	Processamento de Imagens em Tempo Real
RBF	–	<i>Radial Basis Function</i>
RNA	–	Rede Neural Artificial
RNC	–	Rede Neural Celular
RPMC	–	Rede Perceptron de Múltiplas Camadas
SAR	–	<i>Synthetic Aperture Radar</i>
SIFT	–	<i>Scale Invariant Feature Transform</i>
SOM	–	<i>Self – Organizing Map</i>
SURF	–	<i>Speeded Up Robust Features</i>
UAV	–	<i>Unmanned Aerial Vehicle</i>
UFMG	–	Universidade Federal de Minas Gerais
Unicamp	–	Universidade Estadual de Campinas
USP	–	Universidade de São Paulo
VANT	–	Veículo Aéreo Não Tripulado

LISTA DE SÍMBOLOS

m	– metro
Km	– quilômetro: 10^3 metros
μm	– micrômetro: 10^{-6} metros
GHz	– giga-hertz: 10^9 hertz
GB	– gigabyte: 2^{30} bytes
α	– constante de momento
η	– taxa de aprendizagem
σ	– desvio-padrão
e	– constante neperiana
∂	– derivada parcial
∂^2	– derivada parcial de segunda ordem
∇^2	– laplaciano
Σ	– somatório
$*$	– convolução
R	– conjunto dos números reais

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
2 NAVEGAÇÃO AUTÔNOMA DE VEÍCULOS AÉREOS NÃO TRIPULADOS	9
2.1 Sistema de Navegação Global via Satélite e Sistema de Navegação Inercial	9
2.2 Mapa Digital de Elevação Associado com Imagens do Terreno Sobrevoado	10
2.3 Correspondência Automática entre Imagens da Região Sobrevoada e Imagens Georeferenciadas	12
3 MÉTODOS CONVENCIONAIS DE DETECÇÃO DE BORDAS	17
3.1 Detector de Bordas de Roberts	17
3.2 Detector de Bordas de Sobel	19
3.3 Detector de Bordas Laplaciano	20
3.4 Detector de Bordas de Canny	21
3.5 Considerações Finais	23
4 REDES NEURAS ARTIFICIAIS NA DETECÇÃO DE BORDAS	25
4.1 Rede Neural com Funções de Base Radial (RBF)	26
4.2 Rede Perceptron de Múltiplas Camadas (RPMC)	27
4.3 Rede Neural Celular (RNC)	27
5 TREINAMENTO E ATIVAÇÃO DAS RNAS E ESTIMAÇÃO DA POSIÇÃO GEOGRÁFICA DE UM VANT	29
5.1 Rede com Funções de Base Radial	29
5.1.1 Treinamento da Rede RBF	29
5.1.2 Ativação da Rede RBF	30
5.2 Rede Perceptron de Múltiplas Camadas	31
5.2.1 Treinamento da RPMC	31
5.2.2 Ativação da RPMC	31
5.3 Rede Neural Celular	31
5.3.1 Treinamento da RNC	31
5.3.2 Ativação da RNC	32

5.4	Estimação da Posição Geográfica de um VANT	33
5.5	Obtenção do Casamento entre as Imagens Aéreas e de Satélite	34
5.6	Materiais Utilizados e Metodologia	36
6	RESULTADOS	39
6.1	Resultados das RNAs na Detecção de Bordas	39
6.2	Resultados do Uso de Bordas no Casamento entre Imagens Aéreas e de Satélite	43
7	DISCUSSÃO E CONCLUSÕES	53
	REFERÊNCIAS BIBLIOGRÁFICAS	57
	ANEXO A - IMAGENS AÉREAS E DE SATÉLITE UTILIZADAS	65
	ANEXO B - IMAGENS AÉREAS E DE SATÉLITE COM BORDAS EXTRAÍDAS PELO OPERADOR CANNY	69
	ANEXO C - IMAGENS AÉREAS E DE SATÉLITE COM BORDAS EXTRAÍDAS PELA REDE COM FUNÇÕES DE BASE RADIAL	73
	ANEXO D - IMAGENS AÉREAS E DE SATÉLITE COM BOR- DAS EXTRAÍDAS PELA REDE PERCEPTRON DE MÚLTIPLAS CAMADAS	77
	ANEXO E - IMAGENS AÉREAS E DE SATÉLITE COM BORDAS EXTRAÍDAS PELA REDE NEURAL CELULAR	81
	ANEXO F - PUBLICAÇÕES REFERENTES AOS ESTUDOS DE- SENVOLVIDOS NO CAPÍTULO 5	85

1 INTRODUÇÃO

A navegação autônoma é um grande desafio científico e tecnológico. A robótica é uma das áreas em que tais desafios têm grande impacto e significado. Os exemplos não se fixam somente na robótica, mas também na navegação de automóveis, onde várias soluções são propostas (JUNG et al., 2005), desde da construção de *estradas inteligentes* até um sistema de sensores e processamento em que o veículo deverá permanecer ou em uma estrada, ou seguir uma rota pré-determinada.

A navegação autônoma é desenvolvida em diversas formas de veículos (terrestres, aéreos e aquáticos). Castro (2003) desenvolveu o controle de um veículo autônomo terrestre capaz de identificar as faixas laterais de uma pista através da detecção de bordas, por redes neurais artificiais (RNAs), na imagem da pista. A informação é enviada ao controle do veículo que, através de regras *fuzzy* e de RNAs, toma decisões sobre a mudança ou não da trajetória do veículo, a fim desde permanecer dentro da pista. Outro exemplo encontra-se em (MATOS; CRUZ, 2005), onde a navegação autônoma de um veículo subaquático é orientada por uma rede de bóias que emitem energia acústica que é capturada pelo veículo. A disposição das bóias na área de atuação do veículo autônomo possibilita sua localização sob a água, percorrendo uma rota desejada.

Várias estratégias são propostas para dar uma solução à navegação de um veículo aéreo não tripulado (VANT). Uma delas é usar rádio-controle, porém esta é uma solução que depende da interação com um piloto. Uma maneira de implementar um sistema autônomo de navegação é associar um sistema inercial de navegação (*Inertial Navigation System* (INS)) com dados de um sistema de posicionamento (*Global Navigation Satellite System* (GNSS)). O único sistema totalmente operacional em escala mundial é o sistema americano *Global Positioning System* (GPS)(GIBBONS MEDIA & RESEARCH LLC, 2009). Esta forma de navegação está em operação em diversos VANTs e em outros veículos autônomos (KEARFOTT, 2009). Yoo e Ahn (2003) propuseram um sistema de navegação de baixo custo para VANTs, integrando GPS e INS. Contudo, existe o risco desta tecnologia não estar disponível a todos, ou seja, o sinal GPS pode ser bloqueado por interesses comerciais ou militares, assim como podem receber interferência e conter erro (SOUZA et al., 2006). Neste caso, uma ação possível é a captura de imagens em tempo real do terreno sobrevoado e processamento de tais imagens com o intuito de reconhecer automaticamente o local sobrevoado e corrigir uma rota pré-planejada (CONTE; DOHERTY, 2008). Os dados

processados alimentam um sistema de controle que atua na correção da trajetória do VANT.

O uso de técnicas de processamento de imagens, visão computacional e reconhecimento de padrões aplicadas em navegação autônoma de VANTs têm sido tema de pesquisa em diversos trabalhos nos últimos anos em todo o mundo. Isso pode ser visto em alguns trabalhos como em (ZHANG; LIU, 2003), onde a posição do VANT é estimada com imagens capturadas do terreno sobrevoado e através do seu modelo digital de elevação. Conte e Doherty (2008) utilizaram a informação de borda extraída das imagens capturadas em vôo pelo VANT para a identificação da posição geográfica da aeronave em uma imagem de satélite georeferenciada (possui informação latitude e longitude de cada pixel). Em (LEE et al., 2008), apesar da navegação ser auxiliada por sinal GPS, a aproximação de pouso de um pequeno helicóptero é realizada com visão estéreo para estimar a distância entre a aeronave e a base de pouso, assim como a posição da base de pouso. O sistema de imageamento foi construído *sem fio* a fim de reduzir o *hardware*. Em (NEMRA; AOUF, 2009), um VANT é auxiliado com um mapa visual das construções do ambiente de vôo. Este mapa é construído com as imagens capturadas pelo VANT. É feita a correspondência destas imagens entre si através do algoritmo *Scale Invariant Feature Transform* (SIFT) adaptado para a aplicação. A complexa manobra de pouso de um VANT também pode ser realizada de forma autônoma com o uso de imagens, isto pode ser visto em (DAQUAN; HONGYUE, 2007), onde um algoritmo baseado em visão de máquina foi desenvolvido, capaz de estimar a atitude da aeronave, a cabeceira da pista de pouso e a posição do VANT em relação à pista. Em (XU et al., 2009), imagens capturadas no intervalo de onda do infra-vermelho são utilizadas para que o VANT reconheça uma plataforma de pouso instalada no convés de um navio. O ângulo de guinada do VANT também é calculado.

Diversos trabalhos aplicam RNAs no sistema de navegação de VANTs. Martin et al. (2006) modelaram a dinâmica do sistema de controle de um VANT com uma rede neural com funções de base radial (*Radial Basis Function* (RBF)) e uma rede perceptron de múltiplas camadas (RPMC), as quais também foram comparadas. Em (DONGLI et al., 2007), uma RBF foi desenvolvida para tratar da fusão de informações adquiridas de diversos sensores utilizados pelo sistema de controle da aeronave. Em (SAMAL et al., 2009), uma RNA modela a dinâmica de vôo de um pequeno helicóptero. Puttige (2009) utilizou redes neurais adaptativas para o sistema de controle de um

VANT, implementado em uma plataforma de baixo custo. Nestes trabalhos como em muitos outros, as RNAs são utilizadas no controle do sistema de navegação da aeronave. Uma pesquisa realizada por (CHAO et al., 2007) mostra esta realidade. Em (CHAO et al., 2007), não são citados trabalhos que utilizam RNAs no processamento de imagens e/ou no reconhecimento de padrões em imagens, a fim de auxiliar a navegação de VANTs. Porém o uso de RNAs para este fim pode ser visto em alguns trabalhos como em (FITZGERALD, 2007), onde uma RNA classifica a superfície de regiões candidatas a um pouso forçado de um VANT após a segmentação da imagem do terreno sobrevoado. A região de pouso é eleita com o uso de regras *fuzzy* que também utilizam dados da inclinação do terreno disponíveis em bases de dados da área sobrevoada. Shiguemori et al. (2007) também desenvolveram um trabalho onde RNAs são utilizadas no processamento das imagens capturadas da região sobrevoada pelo VANT. Inicialmente a textura da imagem é extraída por um filtro Gabor e uma RNA busca a região sobrevoada entre alguns marcos utilizados para a navegação do VANT, oriundos de uma imagem de satélite. A RPMC e o mapa auto-organizável de Kohonen (*Self Organizing Map* (SOM)) são desenvolvidos para este propósito e comparados.

A aplicação de RNAs em processamento de imagens tem sido tema de inúmeros trabalhos científicos, porém a aplicação destes conhecimentos na área de navegação aérea autônoma por imagens tem sido pequena comparada a aplicação de RNAs no sistema de controle de VANTs. Ao listar algumas tarefas realizadas por algoritmos convencionais das áreas de processamento de imagens, visão computacional e reconhecimento de padrões em imagens nos trabalhos comentados no 4º parágrafo, pode-se visualizar que muitas delas possuem RNAs desenvolvidas para a mesma tarefa, a saber:

- a) Detecção de Bordas;
- b) Visão Estéreo;
- c) Correspondência de Imagens;
- d) Segmentação;
- e) Extração de Textura; e
- f) Classificação em Imagens.

Alguns exemplos com emprego de RNAs para cada tarefa listada acima e outras de interesse para a navegação autônoma de VANTs por imagens são: separação de textura em imagens, em tempo real, em (SHIMONOMURA; YAGI, 2008), um sistema anti-colisão baseado em imagens em (OKUNO; YAGI, 2008), percepção de movimento em (TORRES-HUITZIL et al., 2005), redes Hopfield para correspondências em visão estéreo em (NASRABADI; CHOO, 1992), detecção de bordas em (CASTRO, 2003) e (CORRÊA, 2004) e segmentação em (SCHULTZ et al., 1998).

Nas últimas décadas RNAs de diferentes arquiteturas foram desenvolvidas para a detecção de bordas em imagens. Como as redes neurais celulares (RNCs) em (AIZENBERG; AIZENBERG, 1994), (SCHULTZ et al., 1998), (AIZENBERG et al., 1998) e (CORRÊA, 2004). Em (CASTRO, 2003) tem-se diversas arquiteturas para esta tarefa, a saber: RPMC, RBF, Memória Associativa Bidirecional, Teoria da Ressonância Adaptativa, Aprendizagem por Quantização Vetorial, Maxnet e Memória Associativa Nebulosa. Redes baseadas no cortex visual primário em (URSINO; CARA, 2004) e redes neurais adaptativas baseadas em padrões de borda em (KUBOTA, 2004).

Nota-se a grande demanda de RNAs como ferramentas que podem ser aplicadas em navegação aérea autônoma de VANTs por imagens, ou pelo menos de estudos comparativos entre estas ferramentas e os algoritmos clássicos de processamento de imagens, visão computacional e reconhecimento de padrões em imagens para a aplicação em questão. Isto porque a navegação aérea autônoma de VANTs exige baixo custo computacional, processamento em tempo real e embarcado, implementação em hardware, tolerância a falhas, entre outros requisitos, que são implementáveis em RNAs.

Pode-se observar na literatura citada nas seções anteriores que estudos aplicados em VANTs têm sido realizados em todo o mundo. No Brasil existem várias instituições (militares e civis públicas e privadas) que possuem grupos de pesquisa na área de VANTs, como por exemplo (NETO, 2008): UFMG, Unicamp, USP de São Carlos-SP, *Avibrás*, *Gyron*, DCTA, IPqM, CTEx, entre outras. Em (NETO, 2008) há um levantamento sobre estas instituições e seus trabalhos, como também é realizado um estudo sobre o problema da geração de trajetórias para veículos aéreos autônomos não-tripulados. Na sequência é dada atenção ao trabalho desenvolvido pelo projeto de Processamento de Imagens em Tempo Real (PITER) pertencente ao Instituto de Estudos Avançados (IEAv), subordinado ao Departamento de Ciência e Tecnologia Aeroespacial (DCTA).

No projeto PITER, a utilização de imagens para auxílio à navegação aérea autônoma está em estudo através de quatro técnicas de visão computacional diferentes:

- a) Rastreamento de Alvos: (SHIGUEMORI et al., 2007);
- b) Visão Estéreo: (CANHOTO et al., 2009);
- c) Visada Oblíqua: (JOSÉ; SHIGUEMORI, 2010); e
- d) Visada Nadir¹:(GOLTZ; SHIGUEMORI, 2007).

A abordagem por rastreamento de alvos visa identificar alvos fixos no solo que possuem latitude e longitude conhecidas. O movimento relativo do VANT a estes alvos pode ser mensurado, extraíndo desta forma a localização do VANT. A visão estereo, num ambiente em três dimensões, possibilita extrair a profundidade destes objetos em relação à câmera. A visada oblíqua extrai do terreno sobrevoado suas elevações que podem ser correlacionadas com um mapa digital de elevação da região sobrevoada. Este tipo de visada também identifica obstáculos do VANT. Uma câmera a bordo de um VANT com visada nadir gera imagens semelhantes ao imageamento por satélite. Desta forma, pode-se buscar pontos ou objetos correspondentes entre a imagem capturada pela câmera com uma imagem de satélite georeferenciada da mesma região sobrevoada, identificando assim a posição do VANT. Esta abordagem se resume na [Figura 1.1](#), onde se tem a mesma região terrestre em duas imagens: na imagem aérea gerada em tempo real pelo sistema imageador do VANT e na imagem de satélite embarcada no VANT.

O objetivo desta dissertação de mestrado é implementar um método capaz de estimar a posição geográfica de um VANT através de imagens aéreas capturadas pela aeronave, buscando a região sobrevoada em uma imagem de satélite georeferenciada. Para isto, este trabalho baseou-se na técnica utilizada em (CONTE; DOHERTY, 2008), onde o registro automático entre a imagem aérea e de satélite é feito com a informação de borda, extraída pelo operador Sobel. Nesta dissertação o operador Sobel também é testado, assim como o operador Canny e as RNAs inicialmente desenvolvidas para extração de bordas. Em (FEDOROV, 2002), existe um levantamento de várias técnicas de registro de imagens, bem como o desenvolvimento de uma técnica

¹O nadir é oposto ao zênite. Neste caso, é a visada de uma câmera voltada à superfície terrestre, com o eixo focal ortogonal à superfície terrestre.




Figura 1.1 - VANT com a imagem terrestre capturada em tempo real (B) correspondendo-se à imagem de satélite (A).

semi-automática de registro e mosaico de imagens de sensoriamento remoto. Aqui foi escolhida a técnica do cálculo da correlação, visto que esta técnica é simples de ser implementada e é automática, o que é exigido pela aplicação abordada.

Foram utilizadas imagens aéreas provenientes de uma videografia aérea para simular o imageamento feito por um VANT. A videografia foi realizada com um vôo sobre a cidade de São José dos Campos, sendo esta mesma região contida na imagem de satélite, proveniente do satélite *Quickbird*. A análise dos resultados - com a aplicação de cada extrator de borda: Sobel, Canny e as RNAs (RPMC, RBF e RNC) foi feita com o cálculo do erro entre os pontos geográficos da localização do VANT estimados pelo método e os pontos geográficos correspondentes à localização correta do VANT num dado momento. Em um VANT pode-se ter um sensor inercial embarcado, com isso a região de busca da imagem aérea na imagem de satélite foi realizada em torno da localização do VANT estimada pelo sensor inercial, a fim de diminuir a região de busca. A imagem aérea utilizada foi corrigida em escala (informação do altímetro) e rotação (informação da bússola) em relação à região da imagem de satélite. Durante

estas correções, foram inseridos ruídos de até 10% nos valores de escala e rotação e avaliou-se o extrator de borda com melhor resultado.

Esta dissertação de mestrado está organizada da seguinte maneira: O [Capítulo 2](#) apresenta algumas formas de navegação autônoma de VANTs, dando maior atenção à navegação aérea autônoma por imagens. O [Capítulo 3](#) aborda um estudo dos métodos convencionais de detecção de bordas, visto que esta operação é de extrema importância para o posterior cálculo da correlação entre as bordas das imagens utilizadas na navegação do VANT. Com o objetivo de obter operadores que detectam bordas baseados em padrões de borda, faz-se no [Capítulo 4](#) o desenvolvimento de três RNAs detectoras de bordas treinadas com padrões de borda. No [Capítulo 5](#) são apresentadas as formas de treinamento e ativação das RNAs do [Capítulo 4](#) e a metodologia para simulação da busca das regiões sobrevoadas por um VANT em uma imagem de satélite georeferenciada. As RNAs desenvolvidas no [Capítulo 4](#) são aplicadas na detecção de bordas em imagens aéreas e de satélite. As bordas destas imagens são utilizadas no cálculo da correlação para estimação da posição do VANT, sendo que as RNAs são comparadas entre si como também com os operadores Sobel e Canny. O [Capítulo 6](#) mostra os resultados alcançados com os experimentos obtidos com as metodologias descritas nos capítulos anteriores e o [Capítulo 7](#) apresenta uma discussão sobre os resultados, as conclusões desta dissertação, suas contribuições e indica trabalhos futuros.

2 NAVEGAÇÃO AUTÔNOMA DE VEÍCULOS AÉREOS NÃO TRI-PULADOS

Os VANTs têm substituído as aeronaves convencionais em diversas tarefas. São empregados em sensoriamento remoto, com sensores óticos (NIETHAMMER et al., 2010) ou SAR embarcados (ACEVO-HERRERA et al., 2010), a fim de monitorar cidades, atividades humanas ou áreas de risco, como algumas atividades aéreas em zonas de conflito (MATHEWSON, 2009) ou o levantamento aéreo de catástrofes naturais e áreas de difícil acesso (NIETHAMMER et al., 2010). O crescente emprego de VANTs deve-se a fatores como seus baixos custos de fabricação e manutenção, ausência de tripulação, maior autonomia, entre outros (MATHEWSON, 2009).

VANTs dotados de navegação autônoma utilizam-se de sensores que enviam informações a um sistema de controle que as processam, de forma a gerar ou não comandos aos atuadores do VANT. Algumas destas informações são: velocidade do VANT e do vento, direção do VANT e do vento, altitude, posição geográfica, ângulos de arfagem, rolagem e guinada em relação aos eixos tridimensionais, entre outras. Dada uma rota de vôo pré-planejada, a informação da posição geográfica do VANT durante o vôo é essencial para que o sistema de controle tome atitudes caso o VANT encontre-se fora de sua rota. Algumas soluções desenvolvidas para estimar a posição geográfica de um VANT de forma autônoma são descritas a seguir.

2.1 Sistema de Navegação Global via Satélite e Sistema de Navegação Inercial

Como visto na Introdução, o Sistema de Posicionamento Global, em inglês *Global Positioning System* (GPS), é o único Sistema de Navegação Global via Satélite, em inglês *Global Navigation Satellite System* (GNSS), totalmente operacional em escala mundial. O GPS utiliza informações de uma constelação de 24 satélites divididos em 6 órbitas planares com 4 satélites cada (KAPLAN; HEGARTY, 2006) para estimar sua posição geográfica. Baseados na observação de sinais eletromagnéticos enviados pelos satélites que orbitam a Terra, os receptores GPS efetuam medições que permitem a determinação de pontos com coordenadas geocêntricas (LIMA, 2005). O Sistema de Navegação Inercial, em inglês *Inertial Navigation System* (INS), é um sistema que utiliza informações de um conjunto de sensores inerciais: acelerômetros e giroscópios (no mínimo um para cada eixo das três dimensões) para estimação de posição. Os acelerômetros fornecem a força específica sofrida pelo conjunto em cada

direção e os giroscópios fornecem o movimento de rotação sofrido pelo conjunto em cada eixo (LIMA, 2005). Ambas as informações são dadas em relação a um ponto de origem (conhecido) do movimento do conjunto de sensores.

O GPS é um sistema bastante preciso (SOUZA et al., 2006), porém pode receber interferência em seu sinal (SOUZA et al., 2006), ou ficar inoperante num dado intervalo de tempo até que seja possível receber, de um número mínimo de satélites, os sinais necessários para o cálculo de sua posição (SOUZA et al., 2006). O INS não necessita de sinais externos para seu funcionamento, ou seja, é um sistema autocontido (LIMA, 2005), porém seu erro de deriva cresce ao longo do tempo, sendo necessário sua correção periódica (LIMA, 2005). Devido a estas características do GPS e do INS, é possível a associação de ambos, onde o GPS corrige de tempos em tempos o INS. Essa correção é realizada toda vez que se torna possível a recepção dos sinais dos satélites pelo GPS. Enquanto a recepção está inoperante, o VANT utiliza a informação de posição do INS para sua navegação (LIMA, 2005).

O uso do GPS com INS é bastante comum em vários sistemas de navegação não autônomos, não só em sistemas aéreos (YOO; AHN, 2003) como também em terrestres (SPAGNOL et al., 2005) e aquáticos (BACHMANN et al., 1996). Sistemas de navegação que associam o GPS ao INS são bastante comuns entre os VANTs autônomos no mercado (KEARFOTT, 2009). Yoo e Ahn (2003) associaram GPS e INS a baixo custo para emprego em VANTs. Na Figura 2.1 tem-se alguns VANTs em operação no mundo que utilizam a associação do sinal GPS com INS no auxílio à navegação (autônoma e não-autônoma).

A navegação autônoma que utiliza o sinal GPS é utilizável sem restrições somente aos possuidores desta tecnologia, que dominam os sinais dos satélites necessários ao cálculo do posicionamento geográfico do VANT. Este tipo de navegação também fica sujeita às interferências intencionais ou não (SOUZA et al., 2006) dos sinais de satélite. A seguir são descritas outras formas de navegação autônoma de VANTs que são independentes de GPS.

2.2 Mapa Digital de Elevação Associado com Imagens do Terreno Sobrevoado

Mapas digitais de elevação, em inglês *Digital Elevation Map* (DEM), georeferenciados podem ser correlacionados com informações capturadas da região sobrevoada



Figura 2.1 - No sentido horário: *Aerosonde*¹, *Heron*² e *Global Hawk*³.

(1) http://www.ctie.monash.edu.au/hargrave/duigan_hamilton.html – Novembro/2010

(2) <http://www.israeli-weapons.com/weapons/aircraft/uav/heron/Heron.html> - Novembro/2010

(3) <http://www.spacedaily.com/news/milspace-02o.html> - Novembro/2010

pelo VANT. Zhang e Liu (2003) desenvolveram uma abordagem para estimar a posição de uma aeronave através de duas etapas: na primeira, o movimento 3D do plano é estimado a partir dos quadros de imagem atual e anterior para produzir uma primeira estimativa da posição da aeronave. Na segunda etapa, o erro na estimativa de posição inicial é corrigido usando uma imagem de teste gerada a partir de um mapa de elevação digital da área de vôo e do quadro anterior.

O uso do mapa digital de elevação tem a vantagem de poder ser usado em regiões não urbanas, como áreas rurais, montanhas e florestas. Estes locais possuem poucos objetos em suas imagens, porém o relevo se destaca. Com base nesta vantagem, Woo et al. (2007) desenvolveram a estimação da posição de um VANT com o uso de informações de um DEM de uma área montanhosa. A imagem do horizonte é capturada no comprimento de onda infra-vermelho (a fim do VANT poder operar tanto de dia quanto à noite), os picos de montanhas são identificados nestas imagens e são buscados no DEM georeferenciado. Uma vez identificados no DEM, a posição

do VANT é conhecida.

Samadzadegan et al. (2007) implementaram uma plataforma para estimação da posição de um VANT usando sinal GPS/INS e DEM. Com o objetivo de eliminar os problemas de ambos os sensores descritos na sessão anterior (inoperância momentânea do GPS e erro de deriva do INS), o sistema também é alimentado por informações 2D e 3D do terreno correlacionadas com o DEM georeferenciado do terreno sobrevoado.

2.3 Correspondência Automática entre Imagens da Região Sobrevoada e Imagens Georeferenciadas

A posição geográfica de um VANT pode ser estimada com o reconhecimento da região sobrevoada em uma imagem de satélite georeferenciada. Para um VANT autônomo, esta correspondência entre imagens deve ser feita de forma automática. Para isso, alguns algoritmos usados para construção de vetores de características (GONZALEZ; WOODS, 2000) são mostrados adiante, porém não apresentaram resultados satisfatórios em testes com imagens da aplicação desta dissertação. A correspondência também pode ser feita pela correlação entre alguma informação presente nas imagens. São mostrados adiante a correlação de textura e de bordas, que apresentaram resultados satisfatórios nos trabalhos referenciados.

A busca automática por pontos correspondentes entre duas imagens que representam a mesma cena tem grande utilidade em visão estéreo, navegação autônoma e restreio de alvos (BELO, 2006), assim como calibração de câmeras, reconstrução 3D e reconhecimento de objetos (BAY et al., 2006). Na literatura existem alguns algoritmos que constroem, de forma automática, vetores de características de pontos de controle para a correspondência de imagens. Dentre eles destacam-se o *Scale Invariant Feature Transform* (SIFT) e o *Speeded Up Robust Features* (SURF).

O algoritmo SIFT, proposto por Lowe (2004), constrói vetores de características locais de uma dada imagem, sendo estes vetores relativamente invariantes a transformações de escala, rotação, iluminação e baixa variação de perspectiva. O SIFT foi testado por Goltz e Shiguemori (2007) em aplicações de correspondência entre imagens aéreas que simulam o imageamento de um VANT. O algoritmo alcançou índices de acerto próximos ou iguais a 100% nos pares de imagens dos testes, porém ao aplicá-lo na correspondência entre essas imagens com a mesma região contida em

uma imagem de satélite de alta resolução espacial ($0,6m$), este algoritmo alcançou índices de acerto inferiores a 50%.

O algoritmo SURF, desenvolvido por Bay et al. (2006), constrói vetores de características baseados na distribuição Haar-wavelet da vizinhança do pixel escolhido como ponto de controle. Esta escolha ocorre de semelhante maneira a do algoritmo SIFT, onde os pontos de controle são escolhidos como os mais constantes durante sucessivas filtragens (Diferença de Gaussianas no caso do SIFT e Matriz Hessiana no caso do SURF). O algoritmo SURF, assim como o SIFT, é relativamente invariante a transformações de escala, rotação, iluminação e baixa variação de perspectiva. O SURF e o SIFT foram testados por Santos e Shiguemori (2009) em imagens de diferentes sensores (imagens aéreas e de satélite) contendo a mesma cena. Ambos os algoritmos obtiveram 100% de acerto com as correspondências feitas entre imagens do mesmo sensor. Para as correspondências feitas entre imagens de sensores diferentes, o SIFT acertou 44,12% e o SURF, 33,33%. Nota-se que o emprego destes algoritmos em aplicações que envolvem o mesmo sensor de imageamento é interessante (visão estéreo e rastreamento de alvos, por exemplo), porém são ineficazes para aplicações que exigem imagens de diferentes sensores, como é o caso da estimação da posição do VANT com o uso de imagens de satélite georeferenciadas e imagens aéreas da região sobrevoada pelo VANT.

São abordadas a seguir duas formas de estimação da posição de um VANT através da correlação de informações extraídas das imagens aéreas e de satélite. A primeira delas leva em conta a possibilidade do VANT reconhecer nas imagens da região sobrevoada (capturadas durante o vôo) alguns marcos de controle com latitude e longitude conhecidas. Esta abordagem foi desenvolvida por Shiguemori et al. (2007) da seguinte forma: Dada uma rota pré-planejada de um VANT, identificam-se possíveis marcos que o VANT deve sobrevoar. As cenas contendo estes marcos são representadas em imagens de satélite que vão embarcadas no VANT. As imagens capturadas pelo VANT são comparadas com os marcos pré-estabelecidos, e quando encontrados, a posição do VANT é estimada. Estes marcos são feições do terreno com características bastante singulares, como por exemplo, entroncamento de rodovias, uma ponte, um lago ou um campo de futebol. A comparação entre as imagens dos marcos e as imagens capturadas durante o vôo é feita com o uso da textura de ambas as imagens, extraídas com o filtro Gabor. Após a extração da textura, uma RNA busca no banco de marcos de controle a imagem da região sobrevoada. Para

realizar esta busca, [Shiguemori et al. \(2007\)](#) utilizaram duas RNAs: RPMC e SOM. Os resultados de ambas as RNAs foram comparados posteriormente. A desvantagem desta abordagem é a necessidade de se prever todos os caminhos possíveis que o VANT pode sobrevoar. Esta estratégia não leva em conta o caso do VANT não sobrevoar as regiões contidas no banco de marcos, o que pode acarretar a perda da localização do VANT.

[Conte e Doherty \(2008\)](#) desenvolveram uma plataforma completa de navegação para VANTs baseada em imagens, além de ser testada experimentalmente. Esta plataforma funciona da seguinte forma: através das bordas extraídas da imagem aérea capturada em tempo real pelo VANT, faz-se o registro desta em uma imagem de satélite georeferenciada, de forma a identificar a posição geográfica do VANT. [Conte e Doherty \(2008\)](#) utilizaram o operador Sobel para extração das bordas. O registro das imagens também possibilita a realização de odometria digital e ambas as informações são passadas para o sistema de controle do VANT. O sistema de estimação da posição do VANT por imagens corrige um sensor inercial a bordo. A fim de evitar *falsos positivos*, um histórico do desvio-padrão do erro do inercial em relação ao ponto estimado pelo imageamento é guardado, para uma dada janela de tempo. Quando o desvio-padrão é maior que a média dos desvios-padrões dentro desta janela de tempo, a posição estimada pelo imageamento é descartada pela premissa de ser um *falso positivo*. Na [Figura 2.2](#) tem-se o VANT utilizado nos experimentos.



Figura 2.2 - VANT usado nos experimentos de [Conte e Doherty \(2008\)](#).

Em (CONTE; DOHERTY, 2008), nota-se o sucesso da localização do VANT com uso de informação de borda para a busca da correspondência entre as imagens aéreas (capturadas em tempo real pelo VANT) e de satélite (contendo informações de latitude e longitude). Nos dois Capítulos a seguir, a detecção de bordas é estudada. No Capítulo 3, alguns algoritmos clássicos detectores de borda são mostrados e no Capítulo 4 são desenvolvidas três RNAs detectoras de bordas. Com isso, a correspondência entre imagens é realizada no Capítulo 5 com o emprego das RNAs do Capítulo 4 e com dois algoritmos vistos no Capítulo 3, a fim de compará-los na estimação da posição do VANT.

3 MÉTODOS CONVENCIONAIS DE DETECÇÃO DE BORDAS

A detecção de bordas é utilizada neste trabalho para que seja possível realizar o cálculo da correlação entre os contornos dos objetos das imagens aéreas e de satélite, acreditando-se na premissa de que as mesmas bordas são encontradas nos dois tipos de imagens. Com isso, nota-se a importância das bordas para o sucesso da estimação da posição geográfica do VANT (visto com maiores detalhes no [Capítulo 5](#)).

De acordo com [Gonzalez e Woods \(2000\)](#), os algoritmos de detecção de bordas são, em geral, baseados em umas das seguintes propriedades básicas de valores de níveis de cinza: descontinuidade e similaridade. Na primeira categoria, a abordagem consiste em particionar a imagem baseando-se em mudanças bruscas nos níveis de cinza. As principais áreas de interesse nessa categoria são a detecção de pontos isolados e detecção de linhas e bordas na imagem. As principais abordagens da segunda categoria baseiam-se em limiarização, crescimento de regiões e divisão e fusão de regiões.

Os detectores de bordas discutidos adiante restringem-se à classe de algoritmos baseados na descontinuidade brusca entre os níveis de cinza de pixels adjacentes. Para encontrar bordas, estes algoritmos utilizam a operação de convolução entre duas funções bidimensionais discretas $f(x, y)$ e $g(x, y)$, denotada por $f(x, y) * g(x, y)$. A [Equação 3.1](#) define a operação de convolução entre f e g que resulta em $h(x, y)$, sendo: f a imagem a ser processada, g uma máscara de convolução e h a imagem resultante da convolução, contendo as bordas da imagem f .

$$h(x, y) = f(x, y) * g(x, y) = \sum_{b=-\infty}^{\infty} \sum_{a=-\infty}^{\infty} f(a, b) \times g(x - a, y - b). \quad (3.1)$$

3.1 Detector de Bordas de Roberts

O detector de Roberts ([RICHARDS; JIA, 2006](#)) é um diferenciador de 1ª ordem por utilizar a informação da derivada de 1ª ordem da descontinuidade dos níveis de cinza para a detecção de borda. O método consiste nos seguintes passos:

- a) Dada a imagem f a ser processada, calcula-se $h' = f * g_1$, conforme [Equação 3.1](#), sendo g_1 a matriz representada na [Figura 3.1](#);

- b) Dada a imagem f a ser processada, calcula-se $h'' = f * g_2$, conforme Equação 3.1, sendo g_2 a matriz representada na Figura 3.1; e
- c) Calcula-se a magnitude $m_{i,j}$ conforme Equação 3.2, sendo i, j os índices de um elemento das matrizes m, h' e h'' . A matriz m é a imagem com as bordas da imagem f .

$$m_{i,j} = \sqrt{h'_{i,j}{}^2 + h''_{i,j}{}^2}. \quad (3.2)$$

1	0	0	1
0	-1	-1	0

Figura 3.1 - Máscaras g_1 (esquerda) e g_2 (direita) detetoras de bordas de Roberts, usadas na detecção das bordas da Figura 3.2.

Na Figura 3.2 tem-se um exemplo de aplicação do operador de Roberts. Na sequência, esta mesma imagem aérea é utilizada nos próximos detetores de bordas apresentados.




Figura 3.2 - Uma imagem aérea em tons de cinza (255 bits) e suas bordas extraídas pelo operador de Roberts.

3.2 Detector de Bordas de Sobel

O operador Sobel (RICHARDS; JIA, 2006) também é um diferenciador de 1ª ordem. Dada uma sequência de pixels, pode-se fazer uma analogia desta sequência com pontos de uma função. Analisando um intervalo desta função, a sua derivada indica um ponto de mínimo ou de máximo que, no caso de uma sequência de pixel, seria uma borda. Em uma imagem, as bordas ocorrem em todas as possíveis direções, porém o método de Sobel, através de duas máscaras de convolução, detecta bordas nas direções x e y da imagem. Cada máscara está associada às derivadas parciais em x e em y da imagem. A Figura 3.3 representa as duas máscaras de convolução de Sobel, sendo a Figura 3.3(a) na direção x e Figura 3.3(b) na direção y . Este algoritmo funciona da seguinte maneira:

- a) Dada a imagem f a ser processada, calcula-se $h' = f * a$, conforme Equação 3.1, sendo a a matriz representada na Figura 3.3(a);
- b) Dada a imagem f a ser processada, calcula-se $h'' = f * b$, conforme Equação 3.1, sendo b a matriz representada na Figura 3.3(b); e
- c) Calcula-se a magnitude $m_{i,j}$ conforme Equação 3.2, sendo i, j os índices de um elemento das matrizes m , h' e h'' . A matriz m é a imagem com as bordas da imagem f .

1	0	-1
2	0	-2
1	0	-1

(a)

1	2	1
0	0	0
-1	-2	-1

(b)

Figura 3.3 - (a) máscara detectora de bordas em x e (b) em y de Sobel, usadas para detectar as bordas da Figura 3.4.

Na Figura 3.4 pode-se observar as bordas extraídas pelo operador Sobel de uma imagem aérea.




Figura 3.4 - Uma imagem aérea em tons de cinza (255 bits) e suas bordas extraídas pelo operador Sobel.

3.3 Detector de Bordas Laplaciano

O detector de bordas Laplaciano é um diferenciador de 2ª ordem (GONZALEZ; WOODS, 2000). Através da convolução da imagem com a máscara da Figura 3.5, a segunda derivada da imagem é calculada em suas componentes nas direções x e y , que correspondem ao cálculo de uma derivada de segunda ordem como é dado pela Equação 3.3, sendo f a imagem a ser processada.

$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2}. \quad (3.3)$$

O detector de bordas Laplaciano segue o seguinte algoritmo:

- a) Dada a imagem f a ser processada, calcula-se $h = f * g$, conforme Equação 3.1, sendo g a matriz representada na Figura 3.5; e
- b) A matriz h é a imagem que contém as bordas da imagem f .

0	-1	0
-1	4	-1
0	-1	0

Figura 3.5 - Máscara de convolução do operador Laplaciano, usada para detectar as bordas da Figura 3.6.

Na [Figura 3.6](#) tem-se o resultado da detecção de bordas pelo operador Laplaciano na imagem aérea. Os operadores diferenciais são sensíveis ao ruído. Em ([GONZALEZ; WOODS, 2000](#)) tem-se uma forma de associar uma função gaussiana ao operador Laplaciano, com o objetivo de suavizar o ruído e aumentar a robustez deste operador. A seguir tem-se o detector de bordas Canny, que segue o mesmo raciocínio de suavização, além de outras operações a fim de uma detecção de bordas mais precisa.




Figura 3.6 - Uma imagem aérea e suas bordas extraídas pelo operador Laplaciano.

3.4 Detector de Bordas de Canny

O processo de detecção de bordas de Canny baseia-se em um conjunto de critérios de detecção e de localização. [Canny \(1986\)](#) definiu três critérios que um filtro de detecção de bordas deve atender, sendo o primeiro a taxa de erro: o detector de bordas deve detectar e encontrar somente bordas, consistindo na maximização da razão sinal/ruído. O segundo critério é seguido pela localização, na qual a distância entre os pixels de borda encontrados pelo detector deve ser a menor possível, com os pontos de bordas bem localizados. O terceiro critério é evitar que o detector de bordas identifique múltiplos pixels de borda onde somente exista um único pixel.

O detector de Canny é um filtro de convolução resistente ao ruído. Este método baseia-se em procurar por máximos no gradiente da imagem que se pretende analisar, cujo gradiente é obtido a partir da derivada de um filtro Gaussiano.

Os passos do algoritmo de Canny são os seguintes:

- a) Obtém-se uma matriz f que representa a imagem a ser processada;

- b) Cria-se uma máscara de Gauss unidimensional G para convoluir com a imagem f . O desvio-padrão σ da função Gaussiana é um parâmetro para o detector de bordas;
- c) Cria-se uma máscara unidimensional para a primeira derivada da função Gaussiana nas direções x e y , chamando-as de G_x e G_y , respectivamente. O mesmo valor σ é usado;
- d) Dada uma matriz f que representa uma imagem a ser processada, faz-se a convolução da imagem f com G , percorrendo as linhas na direção x , resultando a matriz f_x ;
- e) Dada uma matriz f que representa uma imagem a ser processada, faz-se a convolução da imagem f com G , percorrendo as colunas na direção y , resultando f_y ;
- f) Faz-se a convolução de f_x com G_x , resultando em h' e faz-se a convolução de f_y com G_y , resultando em h'' ; e
- g) A magnitude m do resultado é computada para cada pixel i, j conforme Equação 3.2, usando h' e h'' .

A dimensão das máscaras utilizadas está em função do valor de σ definido pelo usuário. A seguir tem-se a definição dos operadores matemáticos utilizados no algoritmo descrito. Dado $u \in R$, e a constante neperiana e σ o desvio-padrão desejado para a função gaussiana G , tem-se:

$$G(u) = e^{-u^2/2\sigma^2} \quad (3.4)$$

e a primeira derivada de G :

$$G'(u) = (-u/2\sigma^2)e^{-u^2/2\sigma^2}. \quad (3.5)$$

Após o cálculo da magnitude m , faz-se a operação de histerese (CASTRO, 2003) com o objetivo de eliminar bordas duplas. Esta operação utiliza uma faixa de limiares onde os pixels abaixo do limiar mínimo recebem zero e os pixels acima do limiar máximo são considerados borda.



Figura 3.7 - Uma imagem aérea e suas bordas extraídas pelo operador Canny sem histerese.

Na [Figura 3.7](#), observam-se as bordas extraídas de uma imagem pelo operador Canny. Notam-se as bordas duplas que ocorrem após o cálculo da magnitude sem aplicar a operação de histerese. No [Anexo B](#) pode-se observar algumas bordas extraídas pelo operador Canny com o uso de histerese.

3.5 Considerações Finais

Para o processo de segmentação, os resultados da detecção de bordas necessitam passar por um processo de limiarização. Muitas vezes este limiar é encontrado de forma analítica, sendo aplicado de forma global ou local. O próximo capítulo trata de redes neurais artificiais que extraem bordas de imagens com uma saída binária, eliminando o processo de limiarização.

Os operadores estudados neste capítulo são sensíveis ao ruído, exceto o operador Canny, que possui uma maior robustez ao ruído comparado aos outros métodos, porém possui um algoritmo não muito simples de ser implementado e mais complexo computacionalmente em relação aos outros métodos. Com o uso das redes neurais artificiais propõem-se uma maneira de tratar o ruído com certa robustez de forma mais simples de implementação e com uma menor complexidade computacional que o operador Canny.

4 REDES NEURAIS ARTIFICIAIS NA DETECÇÃO DE BORDAS

Buscando utilizar as RNAs para a detecção de bordas em imagens, este Capítulo trata do desenvolvimento de três RNAs: RBF, RPMC, e RNC. Após a apresentação das RNAs desenvolvidas, são apresentados no [Capítulo 5](#) o treinamento e a ativação destas RNAs e a aplicação destas.

O uso de RNAs em detecção de bordas foi comentado na Introdução desta dissertação. Dentre os trabalhos citados, dois deles foram de fundamental importância para o desenvolvimento das RNAs deste Capítulo, os quais estão comentados abaixo:

- a) Em ([CASTRO, 2003](#)), as seguintes arquiteturas de redes neurais foram desenvolvidas para extração de bordas: RPMC, RBF, Memória Associativa Bidirecional, Teoria da Ressonância Adaptativa, Aprendizagem por Quantização Vetorial, *Maxnet* e Memória Associativa Nebulosa. Estas RNAs foram treinadas de forma supervisionada com o uso de alguns padrões de borda pré-definidos em janelas 3×3 . Apesar da aplicação final do trabalho estar voltada a navegação de um veículo autônomo terrestre, estas RNAs também foram testadas em diversas imagens e comparadas com o operador Canny. A idéia básica do uso de padrões de borda para o treinamento de [Castro \(2003\)](#) foi utilizada para o treinamento da RBF e da RPMC desta dissertação;
- b) Em ([CORRÊA, 2004](#)), um estudo sobre as RNCs e formas de implementar memória associativa em RNCs foi realizado. Para isso foram estudadas as seguintes formas de aprendizagem supervisionada: método baseado em matriz pseudo-inversa, método baseado em decomposição por valor singular, método baseado em aprendizado Hebbiano, método baseado em aprendizagem por perceptron e método baseado em inequações matriciais lineares. [Corrêa \(2004\)](#) testou estas RNCs na tarefa de suavização de imagens, detecção de bordas em imagens e reconhecimento de caracteres. O método baseado em perceptron foi utilizado para o desenvolvimento da RNC desta dissertação, assim como a abordagem de usar padrões de caracteres ruidosos no treinamento, os quais foram substituídos por padrões de borda ruidosos nesta dissertação.

A seguir são abordados o desenvolvimento das três RNAs deste Capítulo.

4.1 Rede Neural com Funções de Base Radial (RBF)

Uma RBF em sua forma mais simples, segundo Haykin (2001), é uma rede composta de três camadas em que: a primeira camada faz a conexão da rede com o ambiente externo, a segunda (única camada oculta) aplica uma transformação não linear nos dados utilizando as funções de base radial e a terceira camada (saída) aplica uma transformação linear na saída da segunda camada.

Em Haykin (2001) são apresentadas quatro formas diferentes de aprendizagem para obter os parâmetros livres da RBF, a saber:

- a) *Centros Fixos Seleccionados ao Acaso*: é a forma mais simples de aprendizado, onde algumas amostras do conjunto de treinamento são escolhidas aleatoriamente como centros para as funções de base radial. Os pesos da camada de saída são estimados pelo método da pseudo-inversa;
- b) *Seleção Auto-Organizada de Centros*: é composta por dois passos: o primeiro seleciona de forma auto-organizada os centros a partir das amostras de treinamento, utilizando um algoritmo de agrupamento (k -médias (DUDA; HART, 1973), por exemplo). No segundo passo os pesos para a saída da rede são estimados com um algoritmo de aprendizagem supervisionada;
- c) *Seleção Supervisionada de Centros*: aqui é utilizado um algoritmo de aprendizagem supervisionada para estimar todos os parâmetros da rede, através de três passos principais: atualização dos pesos lineares da camada de saída; cálculo das posições dos centros; e espalhamento dos centros de acordo com o sinal de erro da unidade de saída; e
- d) *Interpolação Estrita com Regularização*: esta abordagem utiliza teoria de regularização combinada com a teoria da estimação de regressão de núcleo.

Neste trabalho aplicou-se o método da seleção auto-organizada de centros para a definição dos vetores característicos que representam os pesos entre a camada de entrada e a camada oculta de funções de base radial, definidas como sendo gaussianas conforme Equação 4.1, onde \vec{r} é o vetor de coordenadas do centro de um neurônio da camada oculta, e a constante neperiana, \vec{x} o vetor de entrada da ativação da RBF e σ o desvio-padrão desejado para a função gaussiana.

$$G(\vec{r}, \vec{x}) = e^{-\frac{\|\vec{x}-\vec{r}\|}{2\sigma^2}}. \quad (4.1)$$

4.2 Rede Perceptron de Múltiplas Camadas (RPMC)

A RPMC é uma rede baseada no funcionamento do perceptron de Rosenblatt (HAYKIN, 2001), possuindo uma ou mais camadas ocultas e um ou mais neurônios por camada. A RPMC é uma rede do tipo *alimentada a diante*, onde o sinal de entrada se propaga da seguinte forma: uma camada de nós sensoriais recebem do meio externo o sinal de entrada, o qual é transmitido às camadas ocultas de forma ponderada de acordo com os pesos das ligações sinápticas. A entrada de cada nó oculto é a soma dos sinais ponderados que chegam em cada um destes nós. Cada nó oculto possui uma função de ativação que recebe esta soma e envia adiante na rede o novo sinal gerado. A última camada é chamada de camada de saída, e o sinal propagado por esta é a saída da rede.

As funções de ativação comumente utilizadas nas RPMCs são a degrau, rampa, sigmóide e tangente hiperbólica, todas detalhadas em (HAYKIN, 2001).

Os nós das camadas ocultas e da camada de saída podem possuir uma entrada extra chamada de viés. A razão de seu uso é que o viés representa um termo independente das entradas da rede e é utilizado para definir, junto com os pesos sinápticos, os hiperplanos que separam as classes de padrões aprendidos pela rede. As RPMCs podem utilizar o algoritmo de retropropagação de erro (BRYSON; HO, 1969) para o aprendizado, ou seja, para a definição dos seus viés e dos seus pesos sinápticos.

4.3 Rede Neural Celular (RNC)

As RNCs foram propostas por (CHUA; YANG, 1988) e emulam o funcionamento das células nervosas de forma local, ou seja, são neurônios localmente ligados.

A Figura 4.1 mostra uma RNC de dimensões 5×5 , onde cada neurônio se conecta com seus vizinhos adjacentes. Nesta Figura têm-se representadas as conexões do neurônio central.

A vizinhança de um neurônio pode ser representada pela Equação 4.2, onde $V(i, j)$ representa o conjunto de células vizinhas c de índices k, l da célula de índice i, j , onde r é o raio da vizinhança, sendo $1 \leq k, i \leq N$ e $1 \leq l, j \leq M$, N e M as




Figura 4.1 - Conexões do neurônio central de uma RNC.

dimensões da rede. No exemplo da Figura 4.1 tem-se $r = 1$ e $N = M = 5$.

$$V(i, j) = c(k, l) : \max(|k - i|, |l - j|) \leq r. \quad (4.2)$$

Matematicamente, uma RNC funciona de acordo com a Equação 4.3 e pela regra da Equação 4.4, sendo \dot{x} a saída da rede, x a entrada da rede, T a matriz esparsa que contém os pesos das conexões entre os neurônios, B o vetor de vies, $sat(x_{i,j})$ a equação de saturação do neurônio i, j da rede e $x_{i,j}$ a entrada x correspondente ao neurônio i, j .

$$\dot{x} = sat(x + Tx + B). \quad (4.3)$$

$$sat(x_{i,j}) = \begin{cases} -1, & \text{se } x_{i,j} < -1 \\ x_{i,j}, & \text{se } -1 \leq x_{i,j} \leq 1 \\ 1, & \text{se } x_{i,j} > 1 \end{cases} \quad (4.4)$$

Durante a ativação da rede, a Equação 4.3 é realimentada com sua própria saída até que x fique estável, ou seja, até que $\dot{x} \approx x$.

5 TREINAMENTO E ATIVAÇÃO DAS RNAs E ESTIMAÇÃO DA POSIÇÃO GEOGRÁFICA DE UM VANT

Inicialmente é mostrado neste Capítulo a metodologia para treinar e ativar as RNAs abordadas no Capítulo 4. Na sequência é mostrado o método utilizado para estimar a posição geográfica de um VANT, empregando as RNAs no passo de extração de bordas em imagens deste método.

5.1 Rede com Funções de Base Radial

A arquitetura da rede RBF possui nove entradas, que correspondem a cada elemento de uma janela 3×3 que se movimenta na imagem ao passo de um pixel, tanto na vertical quanto na horizontal. A camada oculta possui um número variável de neurônios que se corresponde ao número de centros encontrados no processo de agrupamento dos centros. A camada de saída possui um único neurônio com a informação da borda estimada. Na camada de saída, utilizou-se a função tangente hiperbólica. O treinamento, a ativação e a saída da RBF são abordados a seguir.

5.1.1 Treinamento da Rede RBF

Em (CASTRO, 2003) gerou-se um conjunto de padrões de borda para o treinamento das RNAs. Estes padrões foram descritos em uma janela 3×3 com valores binários. Neste trabalho dois padrões extras foram propostos para treinar as redes a identificar a ausência de elementos de borda. A Figura 5.1 mostra os padrões de borda definidos para o treinamento, bem como a saída desejada de cada um.




Figura 5.1 - Padrões de treinamento da RBF e da RPMC. À direita os dois padrões sem borda.

Inicialmente os centros foram estimados através do algoritmo k -médias (DUDA; HART, 1973) utilizando o conjunto de padrões de treinamento descrito. Em seguida os pesos da camada de saída foram estimados pelo algoritmo da Regra Delta (HAY-

KIN, 2001).

5.1.2 Ativação da Rede RBF

Após o treinamento, a rede RBF é ativada com um vetor de dimensões 1×9 originário de uma janela de dimensões 3×3 que se movimenta na imagem da seguinte forma: esta janela desliza na imagem ao passo de um pixel, da esquerda para direita. Ao fim da linha, a janela decai um pixel e percorre novamente a imagem, com início na esquerda em direção à direita. Em cada posição desta janela, a rede é ativada com um vetor 1×9 formado pelos elementos desta janela. O vetor é normalizado.

A saída da rede (um escalar) é comparada com todas as saídas que se correspondem a cada padrão de borda, sendo atribuída à imagem de saída como o valor central do padrão que está mais associado a esta saída. Este valor central da janela 3×3 pode ser 0 ou 1, dependendo do padrão. Todos os passos descritos estão resumidos na Figura 5.2.

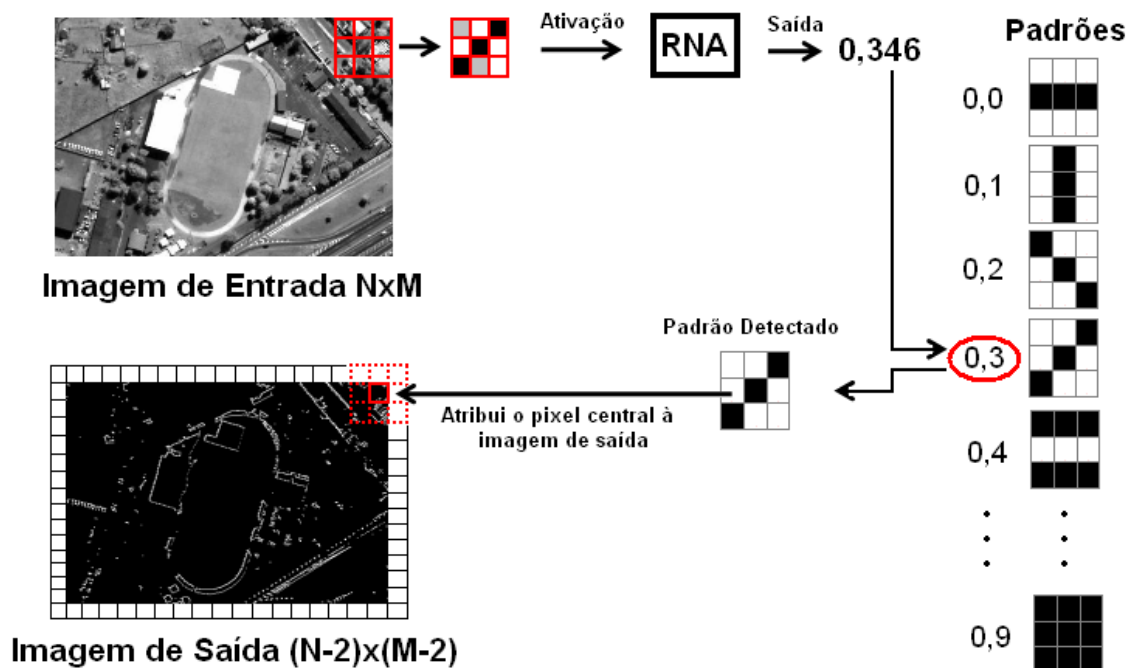


Figura 5.2 - Fluxograma de ativação da rede RBF e da RPMC e formação da imagem de saída contendo as bordas.

5.2 Rede Perceptron de Múltiplas Camadas

A RPMC desenvolvida possui nove neurônios na camada de entrada, que correspondem a cada elemento de uma matriz 3×3 , funcionando de forma semelhante à rede RBF para sua ativação, conforme a [Figura 5.2](#). Para todos os neurônios foi utilizada a função tangente hiperbólica para ativação.

5.2.1 Treinamento da RPMC

Foi utilizado o algoritmo de retropropagação de erro ([BRYSON; HO, 1969](#)) para obter os pesos sinápticos e viés. O conjunto de entrada do treinamento foram os mesmos padrões utilizados para a RBF, assim como a saída desejada para cada padrão.

5.2.2 Ativação da RPMC

A RPMC foi ativada da mesma forma que a rede RBF, como pode ser visto na [Figura 5.2](#)), ou seja, extrai-se uma janela 3×3 da imagem e avalia a saída da rede, um escalar, que é comparado com a saída correspondente à [Figura 5.1](#). O pixel central do padrão que mais se associa à saída da rede é atribuído à imagem de saída.

5.3 Rede Neural Celular

A RNC construída neste trabalho possui dimensões 3×3 , com vizinhança entre as células com raio r ([Equação 4.2](#)) igual a 1. Seu treinamento e ativação são abordados adiante.

5.3.1 Treinamento da RNC

Foram utilizados trinta e dois padrões de borda e dois padrões com ausência de borda para o treinamento, representados na [Figura 5.3](#). Os padrões possuem valores polares -1 e 1 . Estes padrões foram associados à saída desejada da rede e para a entrada de treinamento inseriu-se um ruído gaussiano de 20% nestes padrões.

[Corrêa \(2004\)](#) reproduziu e comparou cinco formas diferentes de treinamento de RNCs, dentre elas um método baseado em perceptrons, desenvolvido por [Liu e Lu \(1997\)](#), o qual foi usado nesta dissertação. Chamando de T a matriz esparsa contendo as conexões entre os neurônios e B o vetor de viés, define-se:




Figura 5.3 - Padrões de treinamento da RNC. À direita os dois padrões sem borda.

$$W^i = [w_1^i, w_2^i, \dots, w_i^i + \mu, \dots, w_n^i, B_i] \text{ e } \bar{y}^p = [y^p, 1]. \quad (5.1)$$

onde: $w_{j,i} = T_{i,j}$ caso a j -ésima célula pertencente à vizinhança da i -ésima célula e $w_{j,i} = 0$, caso contrário, e y^p o p -ésimo padrão. De acordo com Liu e Lu (1997) utilizando a constante $\mu > 1$, e y_i^p o i -ésimo elemento do p -ésimo padrão, tem-se:

$$\begin{cases} W^i \bar{y}^p \geq 0, & \text{se } y^p = 1 \\ W^i \bar{y}^p < 0, & \text{se } y^p = -1 \end{cases} \quad (5.2)$$

Os pesos W^i da Equação 5.2 são encontrados através do algoritmo de treinamento do perceptron, disponível em (HAYKIN, 2001). O treinamento da RNC consiste em obter T e B a partir do treinamento do perceptron e avaliar a estabilidade de x na Equação 4.3. Caso x não se estabilize, obtêm-se novamente T e B utilizando x como entrada no treinamento do perceptron, e assim por diante até que x esteja estável, alcançando um erro mínimo entre os valores consecutivos de x .

5.3.2 Ativação da RNC

Uma janela 3×3 extraída da imagem da mesma forma que nas outras redes é transformada num vetor 1×9 , normalizado entre -1 e 1, que inicia a Equação 4.3. A saída da Equação 4.3 é utilizada como entrada de ativação na nova iteração até que x fique estável. O valor central do vetor x estável é atribuído à imagem de saída. A

ativação da RNC com a imagem e a formação da imagem contendo as bordas são representas na [Figura 5.4](#).

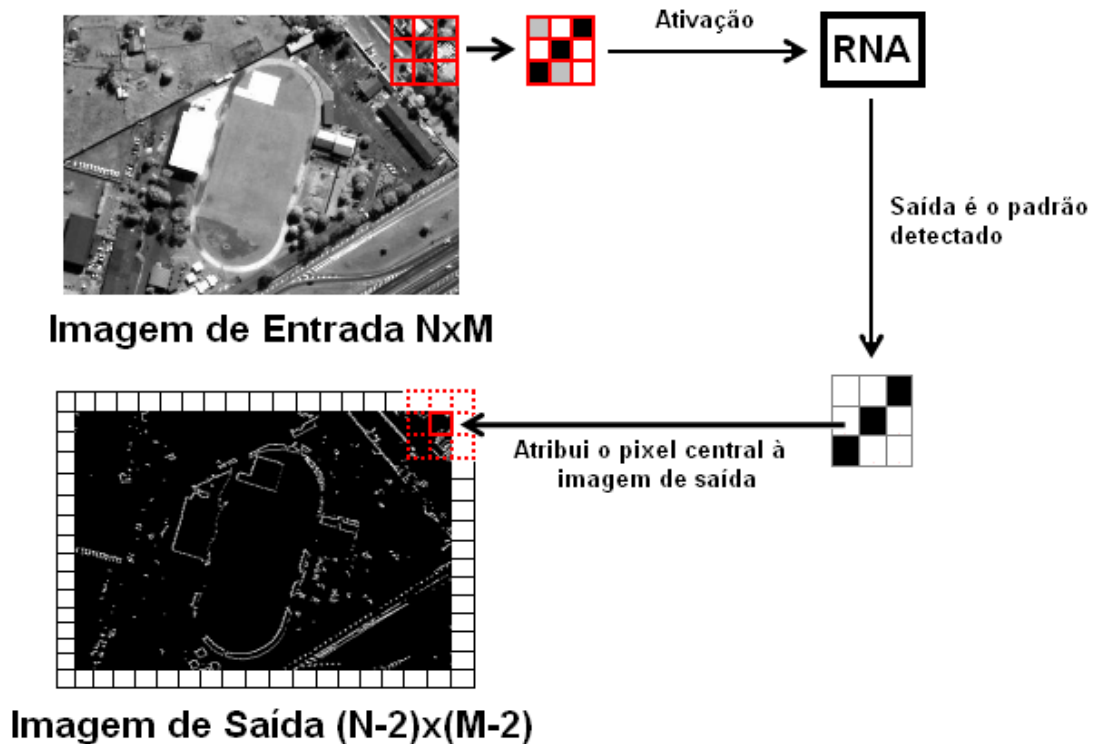


Figura 5.4 - Fluxograma de ativação da RNC e formação da imagem de saída contendo as bordas.

A seguir é mostrado o método para estimar a posição geográfica de um VANT. Um dos passos deste método consiste em extrair bordas das imagens aéreas capturadas pelo VANT e das imagens de satélite. Neste passo, as RNAs mostradas anteriormente são aplicadas.

5.4 Estimação da Posição Geográfica de um VANT

O casamento entre imagens aéreas e de satélite não é trivial pois a escala, rotação, diferença de luminosidade e diferença na resposta espectral da cena capturada entre os dois sistemas (câmera de imageamento do VANT e sistema de imageamento do satélite) fazem com que uma mesma cena seja representada de forma diferente na imagem capturada em tempo real pelo VANT e na imagem de satélite utilizada. Isto pode ser visto na [Figura 1.1](#).

Existe um alto custo computacional para encontrar uma pequena região sobrevoada em uma imagem de satélite contendo toda a região do plano de vôo. Este custo pode ser reduzido concentrando-se a busca da região sobrevoada em torno de um ponto estimado pelo sensor inercial do VANT, o qual é corrigido pelo próprio casamento entre as imagens periodicamente.

Algumas informações podem ser utilizadas para auxiliar a estimação da posição do VANT com o uso do imageamento do terreno sobrevoado e da imagem de satélite. Uma característica comum entre as imagens aéreas capturadas pelo VANT e a imagem de satélite é que ambas podem ser capturadas em visada nadir, eliminando efeitos de perspectiva. A diferença de rotação entre estas imagens pode ser corrigida através da informação da bússola do VANT. A diferença de escala entre as imagens pode ser estimada pela informação do altímetro do VANT. Detalhes do terreno em ambas as imagens podem ser eliminados ao aplicar nestas imagens um filtro passa-baixa. Isso faz com que sejam mantidos nas imagens apenas os objetos e feições do terreno mais relevantes. Fatores ligados às diferenças de luminosidade e de resposta espectral são eliminados utilizando-se somente as bordas extraídas das imagens.

5.5 Obtenção do Casamento entre as Imagens Aéreas e de Satélite

Inicialmente a imagem capturada em tempo real pelo VANT é corrigida em escala e rotação, em relação à região da imagem de satélite embarcada. Esta região pode ser delimitada em torno do ponto onde o sensor inercial estima ser a posição geográfica do VANT. Um filtro da mediana (GONZALEZ; WOODS, 2000) com uma máscara de convolução de dimensões 3×3 é aplicado nas duas imagens, com o intuito de eliminar pequenos detalhes nas imagens. Em seguida as bordas são extraídas. Neste trabalho utilizaram-se os operadores Sobel e Canny, bem como as RNAs desenvolvidas no Capítulo 4 para este fim. Com as bordas das duas imagens, o casamento é feito com o cálculo da correlação (GONZALEZ; WOODS, 2000) no domínio espacial (Equação 5.3):

$$c(s, t) = \sum_x \sum_y f(x, y)w(x - s, y - t) \quad (5.3)$$

sendo $c(s, t)$ a correlação c de índices s, t , com $s = 0, 1, \dots, M - 1$ e $t = 0, 1, \dots, N - 1$, onde 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 $K \leq N$, contendo as

bordas da imagem aérea.

Dada a maior correlação c encontrada entre as matrizes f e w , o ponto na imagem de satélite f que coincide com o ponto central da imagem aérea w corresponde à localização do VANT no momento em que este sobrevoou tal região imageada. Assumindo-se que este ponto é conhecido, suas coordenadas corrigem o sensor inercial e o processo de casamento entre as imagens recomeça. O diagrama da Figura 5.5 resume o processo de casamento descrito. Para acelerar o cálculo da correlação, a imagem aérea também tem sua área reduzida em torno do seu ponto central, após as correções de escala e rotação.

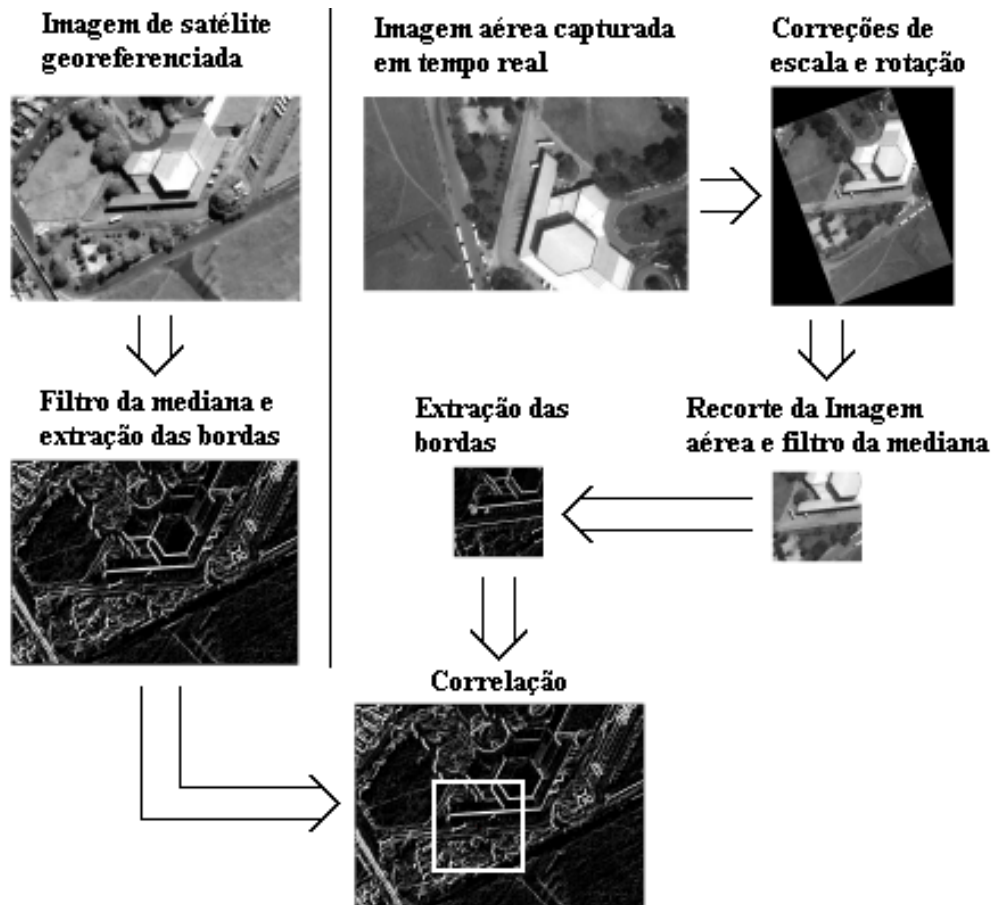


Figura 5.5 - Passos do processo de casamento.

5.6 Materiais Utilizados e Metodologia

Para simular as imagens capturadas em tempo real por um VANT, foram utilizadas imagens de uma videografia aérea cedida pelo IEAv e realizada em 2006 a uma altitude constante e em visada nadir, sobre a cidade de São José dos Campos, SP. Exemplos destas imagens encontram-se no [Anexo A](#).

A imagem de satélite utilizada possui alta resolução espacial de $0,6m$ a fim de facilitar o casamento com a imagem aérea. Para isto escolheu-se uma imagem pancromática do sensor do satélite *Quickbird* da região de São José dos Campos, SP, referente a maio de 2004. Esta imagem cobre uma região de aproximadamente $66Km^2$. A [Tabela 5.1](#) mostra as resoluções espacial, espectral e radiométrica das imagens produzidas pelo *Quickbird*. No [Anexo A](#) encontram-se alguns exemplos de recortes desta imagem utilizadas neste trabalho.

Tabela 5.1 - Resoluções do Satélite *Quickbird*

Resolução Espacial	Pancromática: $0,61m$ Multiespectral: $2,44m$
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: $0,63 - 0,69\mu m$ Banda 4 - Infravermelho: $0,76 - 0,90\mu m$
Resolução Radiométrica	11 bits - 2048 níveis de cinza

Fonte: <http://www.digitalglobe.com/index.php/48/Products> - Abril/2009.

O cálculo da correlação foi realizado em 10 pares de imagens (uma imagem aérea e uma de satélite) que simulam 10 regiões diferentes sobrevoadas por um VANT, sendo que cada imagem de satélite contém a região da imagem aérea correspondente. As dimensões das imagens utilizadas no cálculo da correlação foram: 480×340 pixels para a imagem de satélite e 191×191 pixels para a imagem aérea. A imagem aérea tem dimensões ímpares para que haja um pixel central. O ponto na imagem de satélite que coincide com este pixel central é a posição geográfica do VANT calculada. A fim de calcular o erro de estimação da posição do VANT, para cada par de imagens, foi estimado visualmente o ponto central que coincide a imagem aérea na imagem de satélite, representando o ponto geográfico onde o VANT se encontra naquele momento. Este ponto assumiu-se como verdade para o cálculo do erro. A

escala e rotação necessárias para corrigir a imagem aérea em relação à de satélite também foram estimadas visualmente. A fim de verificar a robustez do método de estimação da posição do VANT em relação aos valores de escala e rotação, foram inseridos ruídos de $\pm 5\%$ e $\pm 10\%$ nos valores de escala e rotação estimados e aplicou-se o método descrito para a estimação da localização do VANT, usando cada um dos operadores: Sobel, Canny, RBF, RPMC e RNC para extração das bordas das imagens. Com a inserção de ruído em escala e rotação para cada operador citado, também foi possível verificar qual operador deixa o método mais robusto para cada situação de ruído em escala e rotação.

O operador Canny foi escolhido para ser comparado às RNAs por ser um extrator de bordas robusto ao ruído, como visto no [Capítulo 3](#), destacando-se entre os algoritmos convencionais de extração de bordas, por ser um extrator de bordas padrão (CASTRO, 2003) e por ter apresentado menor EQM nos testes com imagens-verdade, conforme pode ser visto no primeiro artigo do [Anexo F](#). Neste artigo, as RNAs abordadas nesta dissertação foram comparadas com o operador Canny na detecção de bordas em imagens aéreas, de satélite e imagens-verdade. O operador Sobel foi escolhido por ter sido usado em (CONTE; DOHERTY, 2008) na mesma aplicação desta dissertação, o qual apresentou excelentes resultados como pode ser visto em (CONTE; DOHERTY, 2008).

As RNAs foram implementadas em código C++ com o uso da biblioteca *OpenCV* para leitura e escrita das imagens e para a estrutura de dados utilizada para representar as imagens. Os algoritmos Canny, Sobel e a correlação entre as bordas das imagens foram implementados na ferramenta *Matlab*. Todos os testes foram realizados num microcomputador modelo *Acer Aspire 5520-5912*, com dois processadores *AMD Turion 64 bits* de *1,9GHz*, memória RAM de *2GB* e com sistema operacional *Windows XP 32 bits*.

6 RESULTADOS

Este Capítulo apresenta os resultados das técnicas descritas no [Capítulo 5](#), conforme descritos abaixo:

- Na Sessão 6.1 os resultados são referentes a aplicação das RNAs na detecção de bordas em seis imagens aéreas em tons de cinza e seis imagens pancromáticas do sensor do satélite *Quickbird* das mesmas regiões das imagens aéreas. Estas imagens encontram-se no [Anexo A](#). As bordas detectadas foram comparadas com os resultados do operador Canny. Isso foi necessário, num primeiro momento, para avaliar as RNAs na tarefa de detecção de bordas, comparando-as com este operador, um extrator de bordas padrão ([CASTRO, 2003](#)). As bordas extraídas das imagens do [Anexo A](#) pelo operador Canny encontram-se no [Anexo B](#), pela RBF no [Anexo C](#), pela RPMC no [Anexo D](#) e pela RNC no [Anexo E](#).
- Na Sessão 6.2 os resultados são referentes a aplicação das RNAs na detecção de bordas dentro do processo de estimação da posição geográfica de um VANT. Neste segundo momento, o foco foi avaliar as RNAs na aplicação. Nestes testes, as RNAs foram comparadas com os operadores Canny e Sobel.

6.1 Resultados das RNAs na Detecção de Bordas

Para o treinamento da RBF foram usados os seguintes valores para os respectivos parâmetros: desvio-padrão σ da [Equação 4.1](#) igual a 0,3354; taxa de aprendizagem $\eta = 0,05$; e constante de momento $\alpha = 0,5$. Os dois últimos parâmetros citados são usados no algoritmo da Regra Delta utilizado no treinamento dos pesos da camada de saída. Como critério de parada deste algoritmo foram utilizados um erro mínimo da saída da rede igual a 10^{-6} em relação à saída desejada e número máximo de épocas de 50000. O valor de σ usado está em função da distância máxima d_{max} entre os centros ([HAYKIN, 2001](#)) dada como parâmetro no algoritmo k -médias ([DUDA; HART, 1973](#)), segundo a [Equação 6.1](#). Com isso, o valor de σ usado foi originário do uso da distância entre os centros igual a 1,5.

$$\sigma = \frac{d_{max}}{\sqrt{2 \times n^2 \text{ de centros}}}. \quad (6.1)$$

Os valores testados para cada parâmetro da RBF podem ser vistos na segunda coluna da [Tabela 6.1](#). Os parâmetros escolhidos, que apresentaram o menor erro quadrático médio de treinamento ($9,9995 \times 10^{-6}$ com 2837 épocas) dentre os valores testados, encontram-se na terceira coluna da [Tabela 6.1](#).

Tabela 6.1 - Valores de parâmetros testados durante o desenvolvimento da RBF. Na terceira coluna, os valores escolhidos.

N° de padrões	10 e 34	10
N° máximo de centros	10 e 34	10
Distância entre os centros	1; 1,5; 2; 2,5 e 3	1,5
η	0,001; 0,002; 0,003; 0,004; 0,005; 0,006; 0,007; 0,008; 0,009; 0,01; 0,02; 0,03; 0,04; 0,05; 0,06; 0,07; 0,08; 0,09; 0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 0,7; 0,8 e 0,9	0,05
α	0,01; 0,02; 0,03; 0,04; 0,05; 0,06; 0,07; 0,08; 0,09; 0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 0,7; 0,8 e 0,9	0,5
N° máximo de épocas	1000; 5000; 10000; 20000; 30000; 40000; 50000 e 60000	50000
Erro mínimo de treinamento	10^{-4} ; 10^{-5} e 10^{-6}	10^{-6}

Os parâmetros de treinamento utilizados para a RPMC foram $\eta = 0,05$, $\alpha = 0,5$, para critério de parada das iterações utilizaram-se erro mínimo de 10^{-4} e número máximo de épocas igual a 50000.

Os valores testados para cada parâmetro da RPMC podem ser vistos na segunda coluna da [Tabela 6.2](#). Os parâmetros escolhidos, que apresentaram o menor erro quadrático médio de treinamento (10^{-4} com 13393 épocas) dentre os valores testados, podem ser vistos na terceira coluna da [Tabela 6.2](#).

Tabela 6.2 - Valores de parâmetros testados durante o desenvolvimento da RPMC. Na terceira coluna, os valores escolhidos.

N° de padrões	10 e 34	10
η	0,001; 0,002; 0,003; 0,004; 0,005; 0,006; 0,007; 0,008; 0,009; 0,01; 0,02; 0,03; 0,04; 0,05; 0,06; 0,07; 0,08; 0,09; 0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 0,7; 0,8 e 0,9	0,05
α	0,01; 0,02; 0,03; 0,04; 0,05; 0,06; 0,07; 0,08; 0,09; 0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 0,7; 0,8 e 0,9	0,5
N° máximo de épocas	1000; 5000; 10000; 20000; 30000; 40000; 50000 e 60000	50000
Erro mínimo de treinamento	10^{-4} ; 10^{-5} e 10^{-6}	10^{-4}

Para a RNC, o perceptron foi treinado com $\eta = 0,03$ e número máximo de épocas igual a 100. No treinamento da RNC, para avaliação da estabilidade, considerou-se x estável quando o erro entre dois valores consecutivo de x alcançasse valor menor ou igual a 0,01 e um limite de iterações para estabilidade igual a 1000. Na ativação da RNC, o erro mínimo para a estabilidade de x da [Equação 4.3](#) usado foi de 0,02 e utilizou-se um limite máximo de iterações da [Equação 4.3](#) igual a 50.

Os valores testados para cada parâmetro da RNC podem ser vistos na segunda coluna da [Tabela 6.3](#). Os parâmetros escolhidos, que apresentaram a menor diferença entre os valores consecutivos de x ($9,0032 \times 10^{-3}$) dentre os valores testados, podem ser vistos na terceira coluna da [Tabela 6.3](#).

Tabela 6.3 - Valores de parâmetros testados durante o desenvolvimento da RNC. Na terceira coluna, os valores escolhidos.

N° de padrões	10 e 34	34
η	0,001; 0,002; 0,003; 0,004; 0,005; 0,006; 0,007; 0,008; 0,009; 0,01; 0,02; 0,03; 0,04; 0,05; 0,06; 0,07; 0,08; 0,09; 0,1; 0,2; 0,3; 0,4; 0,5; 0,6; 0,7; 0,8 e 0,9	0,03
N° máximo de épocas	50; 100; 200 e 500	100
N° máximo de iterações para estabilidade de x	20; 50; 100; 200; 500; 1000; 1500 e 2000	1000 (treinamento) 50 (ativação)
Estabilidade de x	0,001; 0,005; 0,01; 0,02; 0,03; 0,04; 0,05; 0,06; 0,07; 0,08; 0,09 e 0,1	0,01 (treinamento) 0,02 (ativação)

Utilizou-se a função *edge()* ([MATHWORKS, 2006](#)) com seus parâmetros-padrão contida no software *MatLab* ([MATHWORKS, 2006](#)) para gerar as bordas com o operador de Canny. As bordas extraídas por este operador das imagens escolhidas deste trabalho encontram-se no [Anexo B](#). As bordas extraídas pela RBF encontram-se no [Anexo C](#), pela RPMC encontram-se no [Anexo D](#) e pela RNC no [Anexo E](#).

A análise quantitativa foi realizada com base no trabalho de [Castro \(2003\)](#), com dois índices: (1) através do erro quadrático médio (EQM) das imagens de bordas geradas pelas RNAs em relação às geradas pelo Canny, conforme [Equação 6.2](#), onde n e m são a quantidade de linhas e colunas da imagem, respectivamente, c é a imagem das bordas gerada pelo Canny e r a imagem das bordas gerada pela rede neural; e (2) através da porcentagem de bordas encontradas em relação ao total de pixels da imagem, conforme [Equação 6.3](#).

$$EQM = \frac{1}{n \times m} \sum_{x=1}^n \sum_{y=1}^m (c(x, y) - r(x, y))^2. \quad (6.2)$$

$$\% \text{ pixels de borda} = \frac{\text{pixels de borda}}{\text{número de pixels da imagem}} \times 100. \quad (6.3)$$

Os valores encontrados para estes dois índices para as imagens aéreas encontram-se na [Tabela 6.4](#), a para as imagens de satélite encontram-se na [Tabela 6.5](#).

Tabela 6.4 - Porcentagem de pontos de borda e EQM para as imagens aéreas.

Região	Canny	RBF		RPMC		RNC	
	% borda	EQM	% borda	EQM	% borda	EQM	% borda
1	10,3586	0,1867	14,6901	0,1590	9,5707	0,1474	6,3551
2	6,9003	0,1022	6,7951	0,0917	4,1713	0,0782	1,5664
3	7,4422	0,1294	9,0229	0,1324	8,6890	0,0953	3,6101
4	8,2907	0,1974	17,7008	0,1603	11,4588	0,1029	3,1168
5	8,8711	0,1603	13,3375	0,1707	12,8958	0,1126	3,4053
6	11,6179	0,1569	8,9626	0,1632	9,1301	0,1452	4,2872

Tabela 6.5 - Porcentagem de pontos de borda e EQM para as imagens de satélite.

Região	Canny	RBF		RPMC		RNC	
	% borda	EQM	% borda	EQM	% borda	EQM	% borda
1	12,0398	0,2454	24,0282	0,2176	14,5614	0,1375	2,1936
2	9,4452	0,2085	19,8609	0,1786	12,7677	0,1182	3,1480
3	10,2319	0,1479	12,2756	0,1712	12,2602	0,1260	3,4995
4	10,1570	0,2105	20,468	0,1848	13,1688	0,1256	3,4971
5	11,3763	0,1899	14,8152	0,2138	15,2843	0,1451	4,0776
6	14,0539	0,2072	17,5119	0,2327	17,8239	0,2019	7,8916

No [Anexo F](#) encontra-se um estudo comparativo entre as RNAs e o operador Canny na detecção de bordas em imagens-verdade¹ disponíveis em um catálogo de imagens para este fim em ([BERKELEY, 2009](#)).

Entre as redes neurais, a RNC obteve os menores erros em comparação ao Canny

¹Termo em inglês: *Ground-truth*.

e apresentou ser mais robusta a regiões com textura, porém detectou menos pontos de borda em relação às outras RNAs e apresentou ser mais lenta que as outras redes em função da sua ativação recorrente.

Durante a implementação das três RNAs, foram testados dois conjuntos de treinamento: um contendo dez padrões (Figura 5.1) e outro contendo trinta e quatro padrões (Figura 5.3). Em testes preliminares, a RPMC e a RBF obtiveram resultado qualitativo semelhante com ambos os conjuntos, com isso optou-se por treiná-las com dez padrões. A RNC apresentou nestes testes preliminares um melhor resultado qualitativo ao ser treinada com os trinta e quatro padrões ao invés de dez, com isso optou-se por treiná-la com trinta e quatro padrões. Das três RNAs implementadas, a RBF extraiu mais bordas em relação às outras RNAs, porém errou mais em relação ao Canny. A RPMC apresentou resultado semelhante à RBF, com erro e detecção de bordas um pouco menores comparados à RBF. Uma vantagem da RPMC aos outros operadores estudados é que esta não possui parâmetros iniciais para ativação.

6.2 Resultados do Uso de Bordas no Casamento entre Imagens Aéreas e de Satélite

O casamento entre as imagens aéreas e de satélite foi realizado através do cálculo da correlação (Equação 5.3) conforme visto no Capítulo 5. Esta foi calculada entre 10 pares de imagens (10 imagens aéreas e 10 imagens de satélite) para cada situação de ruído em escala e rotação. Inserindo-se ruídos nestes parâmetros, avaliou-se a robustez do método para a estimação da posição do VANT. O erro médio, em metros, foi calculado para cada situação de ruído estabelecida, bem como para cada extrator de borda utilizado. O erro em metros foi obtido pela distância euclidiana entre o ponto estimado pela correlação e o ponto considerado como verdade, multiplicando esta distância em pixels por 0,6, que corresponde à resolução espacial em metros de cada pixel.

As seguintes situações com ocorrência de ruído em escala e rotação foram estabelecidas:

- Escala com 0% de ruído e rotação com 0% de ruído.
- Escala com 0% de ruído e rotação com $\pm 5\%$ de ruído.
- Escala com 0% de ruído e rotação com $\pm 10\%$ de ruído.

- Escala com $\pm 5\%$ de ruído e rotação com 0% de ruído.
- Escala com $\pm 5\%$ de ruído e rotação com $\pm 5\%$ de ruído.
- Escala com $\pm 5\%$ de ruído e rotação com $\pm 10\%$ de ruído.
- Escala com $\pm 10\%$ de ruído e rotação com 0% de ruído.
- Escala com $\pm 10\%$ de ruído e rotação com $\pm 5\%$ de ruído.
- Escala com $\pm 10\%$ de ruído e rotação com $\pm 10\%$ de ruído.

A fim de possibilitar uma comparação visual entre uma situação sem inserção de ruído na escala e rotação e outra com inserção de ruído na fase de correção da imagem aérea em relação à imagem de satélite, tem-se na [Figura 6.1](#) um exemplo de cada situação citada.




Figura 6.1 - Imagem aérea (a) corrigida corretamente em relação à imagem de satélite (c) e imagem aérea (b) com inserção de ruído em $+10\%$ na escala e $+10\%$ na rotação. Em vermelho a região na imagem de satélite (c) correspondente às imagens aéreas (a) e (b).

O erro médio em metros para cada situação de ruído em escala e rotação, usando a RNC, pode ser visualizado na [Tabela 6.7](#). Na [Tabela 6.8](#) tem-se o mesmo para o operador Sobel, na [Tabela 6.9](#) para a RPMC, na [Tabela 6.10](#) para a RBF e para o operador Canny na [Tabela 6.11](#). Testes com a correlação entre as imagens aéreas e de

satélite normalizadas foram realizados a fim de verificar se desta forma a correlação apresentava uma melhor estimaco da posico geogrfica do VANT em relato ao uso de bordas. O resultado destes testes esto na [Tabela 6.6](#).

Tabela 6.6 - Erro mdio em metros para cada situao definida de rudo em escala e rotao nas imagens normalizadas.

Rudo de Escala	Rudo em Rotao				
	0%	+5%	-5%	+10%	-10%
0%	67,9697	68,7531	60,1390	69,1059	59,2316
+5%	67,1682	66,9639	59,8962	66,8403	60,0454
-5%	70,2552	72,1566	64,3482	68,9983	63,4965
+10%	65,3588	65,5395	61,4699	65,2426	58,2723
-10%	65,5063	66,4848	66,2190	71,7826	66,7151

Tabela 6.7 - Erro mdio em metros para cada situao definida de rudo em escala e rotao com a RNC.

Rudo de Escala	Rudo em Rotao				
	0%	+5%	-5%	+10%	-10%
0%	7,8576	9,2947	10,6999	16,4235	11,8659
+5%	19,9380	17,5677	18,5463	20,7806	19,4015
-5%	14,4574	17,4527	13,8857	32,5664	14,4809
+10%	13,8365	17,9255	19,5072	17,5487	19,8421
-10%	23,5740	43,3915	22,5993	38,4582	23,9200

Considerando como *acerto* um ponto estimado pelo mtodo com erro menor ou igual a 10 metros, pode-se avaliar o desempenho dos diferentes extratores de borda considerando a quantidade de acertos para cada situao de rudo de escala e rotao. Considerando-se que o erro mximo possvel de ocorrer na estimaco da posico do VANT  de aproximadamente 200 metros, um erro em torno de 10 metros equivale a 5% do erro mximo. Como exemplo ilustrativo de erro prximo a 10 metros, tem-se na [Figura 6.2](#) a estimaco realizada com o uso da RNC, com rudo de $-5%$ em escala e rotao, atingindo um erro de estimaco da posico do VANT de 9,6747 metros.

Os acertos alcanados com o uso da RNC para a extrao das bordas encontram-se na [Tabela 6.12](#), seguida da [Tabela 6.13](#) com os acertos com o uso do operador Sobel. A [Tabela 6.14](#) refere-se  RPMC, a [Tabela 6.15](#)  RBF e a [Tabela 6.16](#) ao operador

Tabela 6.8 - Erro médio em metros para cada situação definida de ruído em escala e rotação com o operador Sobel.

Ruído de Escala	Ruído em Rotação				
	0%	+5%	-5%	+10%	-10%
0%	17,5691	26,0526	23,9107	37,0409	22,4340
+5%	27,4574	25,8143	21,7140	33,6119	22,0860
-5%	18,7518	22,4229	14,5507	29,2616	14,4072
+10%	32,1567	37,7637	27,7461	52,7081	34,1553
-10%	33,0129	41,3799	25,8231	47,4098	26,3929

Tabela 6.9 - Erro médio em metros para cada situação definida de ruído em escala e rotação com a RPMC.

Ruído de Escala	Ruído em Rotação				
	0%	+5%	-5%	+10%	-10%
0%	35,5602	21,6710	29,1947	31,7831	27,9897
+5%	33,1237	27,8070	26,6501	41,2326	23,5940
-5%	27,0336	40,8017	30,8544	46,9750	25,2514
+10%	28,6022	37,6232	37,9550	30,1881	31,8395
-10%	33,9359	33,4824	26,0865	41,8216	32,9589

Tabela 6.10 - Erro médio em metros para cada situação definida de ruído em escala e rotação com a RBF.

Ruído de Escala	Ruído em Rotação				
	0%	+5%	-5%	+10%	-10%
0%	11,0080	29,4197	38,7029	50,8025	47,8432
+5%	30,2243	41,5390	29,0521	51,5052	36,4028
-5%	45,0886	57,4982	39,3576	47,8896	51,5520
+10%	49,7000	48,9144	32,5715	49,7793	50,6496
-10%	55,4028	36,4382	54,7588	46,1977	63,1675

Tabela 6.11 - Erro médio em metros para cada situação definida de ruído em escala e rotação com o algoritmo Canny.

Ruído de Escala	Ruído em Rotação				
	0%	+5%	-5%	+10%	-10%
0%	44,0584	73,3576	45,5240	63,5402	54,5495
+5%	66,1305	62,0739	55,0899	74,6144	56,3574
-5%	44,4771	61,6806	49,5212	68,9480	54,9179
+10%	70,8078	68,5371	57,9415	72,0219	66,3969
-10%	51,2727	59,9341	53,7592	76,2841	52,6852




Figura 6.2 - Ponto estimado (vermelho) com o uso da RNC e ponto correto (amarelo). A imagem menor corresponde-se à imagem aérea e a maior à imagem de satélite.

Canny.

Tabela 6.12 - Quantidade de amostras com erro menor ou igual a 10 metros para a RNC.

Ruído em Escala	Ruído em Rotação				
	0%	+5%	-5%	+10%	-10%
0%	8	7	8	4	8
+5%	5	6	5	3	6
-5%	8	6	9	4	9
+10%	5	4	4	3	5
-10%	7	4	8	3	8

Na Tabela 6.17 tem-se a soma dos erros médios apresentados com o uso de cada operador de borda utilizado, como também a soma dos acertos para cada operador, ou seja, a soma das amostras que apresentaram erro de estimação da posição do VANT igual ou menor a 10 metros. Levando-se em consideração as dimensões das imagens aéreas e de satélite utilizadas nos testes, o maior erro possível de ocorrer para a estimação da posição do VANT é de 197,4985 metros, com isso, a soma máxima de erro é de 49374,6250 metros. Sabendo-se que os testes possuem 10 amostras, e que existem 25 situações de ruído em escala e rotação, a soma máxima de acertos é de 250.

Tabela 6.13 - Quantidade de amostras com erro menor ou igual a 10 metros para o operador Sobel.

Ruído em Escala	Ruído em Rotação				
	0%	+5%	-5%	+10%	-10%
0%	8	5	7	3	8
+5%	5	5	7	4	6
-5%	7	5	8	4	9
+10%	4	3	7	1	3
-10%	6	3	6	3	7

Tabela 6.14 - Quantidade de amostras com erro menor ou igual a 10 metros para a RPMC.

Ruído em Escala	Ruído em Rotação				
	0%	+5%	-5%	+10%	-10%
0%	7	7	6	5	6
+5%	4	4	6	2	5
-5%	5	4	4	3	6
+10%	3	3	4	3	5
-10%	4	4	5	4	4

Tabela 6.15 - Quantidade de amostras com erro menor ou igual a 10 metros para a RBF.

Ruído em Escala	Ruído em Rotação				
	0%	+5%	-5%	+10%	-10%
0%	9	5	4	2	2
+5%	4	2	4	2	3
-5%	4	2	5	2	3
+10%	2	2	4	1	2
-10%	2	4	2	2	2

Tabela 6.16 - Quantidade de amostras com erro menor ou igual a 10 metros para o algoritmo Canny.

Ruído em Escala	Ruído em Rotação				
	0%	+5%	-5%	+10%	-10%
0%	5	1	3	1	2
+5%	2	2	2	0	2
-5%	3	1	3	1	3
+10%	1	1	1	0	0
-10%	3	2	2	0	2

Tabela 6.17 - Soma dos erros médios, em metros, e soma das amostras com erro menor ou igual a 10 metros para cada operador estudado.

Operador	Soma dos Erros Médios(m)	Soma dos Acertos ($\leq 10m$)
RNC	485,8218	147
Sobel	715,6336	136
RPMC	804,0155	113
RBF	1095,4655	76
Canny	1504,4811	43

Na Tabela 6.18 encontram-se os tempos de processamento, em segundos, para a operação de extração de bordas realizada pelos operadores estudados, tanto para a imagem aérea quanto para a imagem de satélite.

Tabela 6.18 - Tempo de processamento, em segundos, de cada operador para os recortes das imagens aéreas e de satélite.

Operador	Imagem Aérea	Imagem de Satélite
RNC	2	13
Sobel	<1	<1
RPMC	0,5	2
RBF	2	10
Canny	<1	<1

Somente o emprego da normalização das imagens para posterior cálculo da correlação mostrou-se insuficiente para estimar a posição geográfica de um VANT. Isso pode ser visto ao comparar os resultados contidos na Tabela 6.6 com os resultados contidos nas Tabelas 6.7 a 6.11.

A RNC obteve resultados superiores em comparação com os outros operadores utilizados, tanto em erro médio (Tabela 6.7) quanto em acertos (Tabela 6.12). O segundo melhor extrator de borda estudado para a aplicação foi o operador Sobel. Os outros operadores estudados não demonstraram resultados satisfatórios para a aplicação levando-se em conta a inserção de ruído, sendo do operador Canny os resultados menos expressivos. Estas considerações podem ser vistas na Tabela 6.11 e na Tabela 6.16.

Na Figura 6.3 tem-se um exemplo de um dos melhores resultados da estimação da

posição do VANT com uso da RNC, com erro de 1,8974 metros em relação à posição correta, inserindo-se um ruído de +10% no valor de escala e -5% no valor de rotação.




Figura 6.3 - Estimação da posição do VANT com a RNC. Erro de 1,8974 metros. Em amarelo o ponto correto e em vermelho o ponto estimado. Ruído de +10% em escala e -5% em rotação. A imagem menor corresponde-se à imagem aérea e a maior à imagem de satélite.

Ao analisar os testes sem inserção de ruído em escala e rotação, nota-se que a RBF obteve o melhor resultado em número de acertos (9 acertos em 10 amostras) seguida da RNC e Sobel empatados (8 acertos em 10 amostras). Levando-se em conta o erro médio de estimação da posição do VANT para esta mesma situação, a RNC errou menos (erro médio de 7,8576 metros) seguida da RBF (11,0080 metros) e do operador Sobel (17,5691 metros).

Considerando-se os tempos de processamento que os operadores estudados gastam para processar a imagem de satélite, nota-se que a RNC apresenta um tempo de processamento superior aos outros operadores, apesar desta apresentar os melhores resultados para a aplicação. O tempo de processamento da imagem de satélite para esta aplicação não é relevante, pois esta pode ser processada a priori (antes do vôo do VANT) porque já é conhecida. Somente a imagem aérea requer o processamento em tempo real, e neste caso, os tempos de processamento entre os operadores estudados são mais próximos entre si comparados com os tempos de processamento da imagem de satélite (Tabela 6.18). Os tempos de processamento dos operadores Sobel e Canny

na ferramenta *Matlab* ficaram próximos dos tempos de processamento em C++, isso porque as rotinas dessa ferramenta são otimizadas.

Este trabalho limitou-se a avaliar o erro de estimação da posição do VANT com o uso da correlação entre as imagens, não demonstrando uma forma de eliminar *falsos positivos*, ou seja, correlações erradas consideradas como corretas. Uma forma de eliminar estas correlações pode ser feita de semelhante forma à utilizada em (CONTE; DOHERTY, 2008), onde um histórico do desvio-padrão entre a posição estimada pelo sensor inercial e pelo sistema de imageamento é guardado, para um dado intervalo de tempo. Caso o sistema de imageamento estime uma posição do VANT que produza um desvio-padrão maior que o desvio-padrão médio (levando-se em conta um limiar), esta posição é rejeitada.

O cálculo da correlação no domínio da frequência (GONZALEZ; WOODS, 2000) é uma alternativa caso haja interesse em aumentar a velocidade de computação do casamento entre as imagens aéreas e de satélite.

7 DISCUSSÃO E CONCLUSÕES

A navegação aérea autônoma sem o uso de informação do tipo GNSS ainda é um desafio, tendo em vista as barreiras tecnológicas que potenciais usuários desta tecnologia enfrentam, muitas vezes devido ao fim militar ou comercial desde conhecimento. A navegação aérea autônoma auxiliada por imagens capturadas do terreno sobrevoado por um VANT tem sido uma saída para substituir sistemas que utilizam sinal GPS para auxílio à navegação, como visto no [Capítulo 2](#). Este nicho de pesquisa exige a utilização, e quando necessário o aprimoramento, de técnicas de processamento de imagens e reconhecimento de padrões em imagens. O desenvolvimento de novas ferramentas em processamento de imagens voltados a esta aplicação podem ser feitos empregando-se RNAs, como visto em ([FITZGERALD, 2007](#)), ([SHIGUEMORI et al., 2007](#)) e nesta dissertação.

As RNAs testadas para a extração de bordas inicialmente foram comparadas com o algoritmo Canny, o qual obteve o melhor resultado (entre ele e as RNAs) para a detecção de bordas em imagens-verdade, como visto no primeiro artigo do [Anexo F](#). Nos testes realizados para este fim, também observou-se que a RBF e a RPMC obtiveram resultados muito próximos ao Canny. Isto também ocorreu ao utilizar estes operadores para extrair bordas em imagens aéreas e de satélite, as quais pertencem à aplicação final do trabalho, com o objetivo de estimar a posição de um VANT reconhecendo o local sobrevoado, contido em imagens aéreas capturadas em tempo real, em uma imagem de satélite georeferenciada da mesma região sobrevoada pelo VANT.

Para o aprendizado das RNAs deste trabalho foi utilizada a abordagem de [Castro \(2003\)](#) de aprendizagem de padrões de borda com valores binários. Porém o treinamento e ativação destas RNAs se faz de forma diferente de [Castro \(2003\)](#) - na RBF e na RPMC, associa-se a saída da rede a um número escalar que representa o padrão de borda detectado. Na ativação da RNC, o padrão de borda é alcançado por uma operação recorrente, como em ([CORRÊA, 2004](#)). O treinamento é feito com base na aprendizagem do perceptron, com o uso de padrões de borda polares ruidosos associados com os mesmos padrões sem ruído. O conjunto dos padrões de treinamento utilizados nas três RNAs foram diferentes dos padrões usados em ([CASTRO, 2003](#)) e ([CORRÊA, 2004](#)), principalmente no fato de ter sido usado padrões sem borda nesta dissertação, com o objetivo das RNAs identificarem regiões sem borda nas imagens. Esta forma de ativação (das três RNAs) também elimina o processo de limiarização

necessário para deixar as imagens binárias.

Em (CONTE; DOHERTY, 2008) o operador Sobel é empregado com sucesso para o registro de imagens aéreas (capturadas em tempo real pelo VANT) em uma imagem de satélite georeferenciada. Além disso, o sistema faz odometria digital e é validado com um voo real. Esta abordagem foi seguida no [Capítulo 5](#), contendo 10 imagens aéreas a serem detectadas numa imagem de satélite georeferenciada. Nesta dissertação o operador Sobel é superado por uma das RNAs desenvolvidas no [Capítulo 4](#), a RNC, a qual detecta com maior precisão um ponto sobrevoado pelo VANT, utilizando o cálculo da correlação no domínio espacial entre as imagens aéreas e a imagem de satélite.

A RNC apresentou os piores resultados quando comparada ao operador Canny e com a RBF e a RPMC nos testes de detecção de bordas em imagens-verdade¹. Porém, ao empregar os mesmos operadores para a extração de bordas em imagens de diferentes sensores para posterior cálculo da correlação, a RNC superou os outros operadores, mostrando que duas aplicações diferentes (detecção de bordas em imagens-verdade e detecção de bordas em imagens de diferentes sensores seguida do cálculo da correlação) não necessariamente possuem o mesmo extrator de bordas com melhor desempenho em ambas as aplicações.

Apesar da RBF e da RPMC não apresentarem bons resultados para a aplicação da estimação da posição do VANT (assim como o algoritmo Canny), elas se mostraram bastante eficientes ao serem comparadas com o algoritmo Canny. Isso faz com que estas RNAs sejam ferramentas com potencial emprego em aplicações que utilizam este algoritmo, o que deve ser verificado em pesquisas posteriores.

Esta dissertação possui as seguintes contribuições:

- Uma abordagem diferente de associação de padrões e saída desejada durante o treinamento da RBF e RPMC, como também para a ativação destas RNAs;
- Imagem de saída das RNAs sem necessidade de processo de limiarização, já inserido na fase de busca do padrão detectado, durante a ativação;
- Uso de padrões sem borda no conjunto de treinamento das RNAs;

¹Ver 1^a publicação do Anexo F

- Desenvolvimento e aplicação de três RNAs detectoras de bordas para auxílio à navegação aérea autônoma por imagens;
- Aplicação com êxito da RBF e da RPMC para a extração de bordas em imagens-verdade, com resultados próximos ao operador Canny;
- Aplicação com êxito das bordas extraídas pela RNC na estimação da posição geográfica de um VANT através do cálculo da correlação no domínio espacial;
- Comparação de cinco detectores de borda diferentes (Sobel, Canny e as três RNAs estudadas) num método baseado em imagens para estimação da posição geográfica de um VANT; e
- Um método para avaliar a robustez, em relação aos parâmetros de escala e rotação, da estimação da posição geográfica de um VANT com o uso de correlação entre bordas.

Alguns trabalhos futuros são:

- Modificações nas RNAs para atender aplicações que exijam comportamento diferenciado das RNAs, como por exemplo: detecção de mais ou menos bordas, tipo de bordas, detecção de bordas em regiões de alto ou baixo contraste, etc;
- Buscar o emprego de outras formas de se utilizar informações do imageamento da região sobrevoada pelo VANT a fim de estimar seu posicionamento geográfico;
- Dados os pontos estimados pela correlação, pode-se desenvolver a odometria digital no sistema, sendo mais uma fonte de informação para auxílio à navegação por imagens;
- Implementação da metodologia em dispositivos de alta velocidade de processamento para atender a aplicações que exijam resposta em tempo real;
- Testar o uso de regras *fuzzy* na comparação da saída da RPMC e da RBF com as saídas desejadas que se correspondem a cada padrão de treinamento, a fim de identificar o padrão reconhecido pela RNA; e

- Testar a Rede de Funções de Base Radial Não Extensiva (SHIGUEMORI, 2007), assim como outras arquiteturas de RNAs, na aplicação.

REFERÊNCIAS BIBLIOGRÁFICAS

- ACEVO-HERRERA, R.; AGUASCA, A.; BOSCH-LLUIS, X.; CAMPS, A.; MARTÍNEZ-FERNÁNDEZ, J.; SÁNCHEZ-MARTÍN, N.; PÉREZ-GUTIÉRREZ, C. Design and first results of an uav-borne l-band radiometer for multiple monitoring purposes. **Remote Sensing**, v. 2, n. 7, p. 1662–1679, 2010. ISSN 2072-4292. Disponível em: <<http://www.mdpi.com/2072-4292/2/7/1662/>>. 9
- AIZENBERG, I. N.; AIZENBERG, N. N.; VANDEWALLE, J. Precise edge detection: representation by boolean functions, implementation on the cnn. In: IEEE INTERNATIONAL WORKSHOP ON CELLULAR NEURAL NETWORKS AND THEIR APPLICATIONS, 5. **Proceedings ...** Londres, Reino Unido: IEEE, 1998. p. 301–306. 4
- AIZENBERG, N. N.; AIZENBERG, I. N. Cnn-like networks based on multi-valued and universal binary neurons: learning and application to image processing. In: IEEE INTERNATIONAL WORKSHOP ON CELLULAR NEURAL NETWORKS AND THEIR APPLICATIONS, 3. **Proceedings ...** Roma, Itália: IEEE, 1994. p. 153–158. 4
- BACHMANN, E. R.; MCGHEE, R. B.; WHALEN, R. H.; STEVEN, R.; WALKER, R. G.; CLYNCH, J. R.; HEALEY, A. J.; YUN, X. P. Evaluation of an integrated gps/ins system for shallow-water auv navigation (sans). **Autonomous Underwater Vehicle Technology**, p. 268–275, 1996. 10
- BAY, H.; TUYTELAARS, T.; GOOL, L. V. Surf: speeded up robust features. In: EUROPEAN CONFERENCE ON COMPUTER VISION, 9., 2006, Graz, Austria. **Proceedings ...** Graz, Austria: LNCS, 2006. v. 3951, p. 404–417. 12, 13
- BELO, F. A. W. **Desenvolvimento de algoritmos de exploração e mapeamento visual para robôs móveis de baixo custo**. Dissertação (Mestrado) — Unicamp, Campinas, Brasil, 2006. 12
- BERKELEY. **Segmentation dataset**: images. Maio 2009. Disponível em: <<http://www.eecs.berkeley.edu/Research/Projects/CS/vision/grouping/segbench/BSDS300/html/dataset/images.html>>. 42
- BRYSON, A. E.; HO, Y. C. **Applied Optimal Control**. 1. ed. Washington, DC, EUA: Blaisdell, 1969. 27, 31

CANHOTO, A.; SHIGUEMORI, E. H.; DOMICIANO, M. A. P. Image sequence processing applied to autonomous aerial navigation. In: SIGNAL AND IMAGE PROCESSING APPLICATIONS, 2009. **Proceedings ...** Kuala Lumpur, Malásia: IEEE, 2009. p. 496–499. 5

CANNY, J. A computational approach to edge detection. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 8, n. 6, p. 679–698, 1986. 21

CASTRO, A. P. A. de. **Detecção de bordas e navegação autônoma utilizando redes neurais artificiais**. Dissertação (Mestrado) — INPE, São José dos Campos, Brasil, 2003. 1, 4, 22, 25, 29, 37, 39, 41, 53

CHAO, H.; CAO, Y.; CHEN, Y. Autopilots for small fixed-wing unmanned air vehicles: A survey. In: INTERNATIONAL CONFERENCE ON MECHATRONICS AND AUTOMATION. **Proceedings ...** Harbin, China: IEEE, 2007. p. 3144–3149. 3

CHUA, L. O.; YANG, L. Cellular neural networks: theory. **IEEE Transactions on Systems and Circuits**, v. 35, n. 10, p. 1257–1272, Outubro 1988. 27

CONTE, G.; DOHERTY, P. An integrated uav navigation system based on aerial image matching. In: AEROSPACE CONFERENCE. **Proceedings ...** IEEE, 2008. p. 1–10. Disponível em: <<http://dx.doi.org/10.1109/AERO.2008.4526556>>. xv, 1, 2, 5, 14, 15, 37, 51, 54

CORRÊA, L. G. **Memória associativa em redes neurais realimentadas**. Dissertação (Mestrado) — USP, São Carlos, Brasil, 2004. 4, 25, 31, 53

DAQUAN, T.; HONGYUE, Z. Vision based navigation algorithm for autonomic landing of uav without heading & attitude sensors. In: INTERNATIONAL IEEE CONFERENCE ON SIGNAL-IMAGE TECHNOLOGIES AND INTERNET-BASED SYSTEM, 30. **Proceedings ...** Shanghai, China: IEEE, 2007. p. 972–978. 2

DONGLI, Y.; JIANGUO, Y.; XINMIN, W.; QINGBIAO, X. A study of information fusion for uav based on rbf neural network. **International Conference on Control and Automation**, p. 2839–2842, Junho 2007. 2

DUDA, R. O.; HART, P. E. **Pattern Classification and Scene Analysis**. 1. ed. Nova Iorque, EUA: Wiley, 1973. 26, 29, 39

- FEDOROV, D. **Sistema semi-automático de registro e mosaico de imagens**. Dissertação (Mestrado) — INPE, São José dos Campos, Brasil, 2002. 5
- FITZGERALD, D. L. **Landing site selection for UAV forced landings using machine vision**. Tese (Doutorado) — Queensland University of Technology, Brisbane, Austrália, 2007. 3, 53
- GIBBONS MEDIA & RESEARCH LLC. **Inside GNSS**. Oregon, EUA, 2009. Disponível em: <<http://www.insidegnss.com/gps>>. 1
- GOLTZ, G. A. M.; SHIGUEMORI, E. H. Aplicação do algoritmo sift em imagens de navegação autônoma. **Atividades de Pesquisa e Desenvolvimento do IEAv**, 2007. 5, 12
- GONZALEZ, R. C.; WOODS, R. E. **Processamento de Imagens Digitais**. 1. ed. São Paulo, Brasil: Edgard Blucher, 2000. 12, 17, 20, 21, 34, 51
- HAYKIN, S. **Redes Neurais, Princípios e Prática**. 1. ed. Porto Alegre, Brasil: Bookman, 2001. 26, 27, 30, 32, 39
- JOSÉ, C. G.; SHIGUEMORI, E. H. Processamento de imagens obtidas com diferentes ângulos de visada para aplicação na navegação autônoma. In: SEMINARIO ANUAL DE INICIACAO CIENTIFICA E POS-GRADUACAO DO IEAV, 4. **Anais ...** São José dos Campos, Brasil: IEAv, 2010. v. 1, p. 61–62. 5
- JUNG, C. R.; OSÓRIO, F. S.; KELBER, C. R.; HEINEN, F. J. Computação embarcada: projeto e implementação de veículos autônomos inteligentes. **XXV Congresso da Sociedade Brasileira de Computação**, 2005. 1
- KAPLAN, E. D.; HEGARTY, C. J. **Understanding GPS: principles and applications**. 2. ed. Norwood, EUA: Artech House Inc, 2006. 9
- KEARFOTT. **UAV INS/GPS systems**. Maio 2009. Disponível em: <<http://www.kearfott.com/content/view/147/130/>>. 1, 10
- KUBOTA, T. Massively parallel networks for edge localization and contour integration: adaptable relaxation approach. **Neural Networks**, p. 411–425, 2004. 4
- LEE, S.; YOON, S.; KIM, H. J.; KIM, Y. Wireless stereo vision system development for rotary-wing uav guidance and control. In: INTERNATIONAL

CONFERENCE ON SENSING TECHNOLOGY, 3. **Proceedings ...** Tainan, Taiwan: ICST, 2008. p. 168–173. 2

LIMA, S. R. S. de. **Integração GPS-INS utilizando sensores inerciais baseados em sistemas microeletromecânicos**. Tese (Doutorado) — Universidade Federal do Paraná, Curitiba, Brasil, 2005. 9, 10

LIU, D.; LU, Z. A new synthesis approach for feedback neural networks based on the perceptron training algorithm. **IEEE transactions on Neural Networks**, v. 8, n. 6, p. 1468–1492, Novembro 1997. 31, 32

LOWE, D. G. Distinctive image features from scale-invariant keypoints. **International Journal of Computer Vision**, v. 60, p. 91–110, 2004. Disponível em: <<http://www.springerlink.com/content/h4102691327px768>>. 12

MARTIN, R. S.; BARRIENTOS, A.; GUTIERREZ, P.; CERRO, J. del. Unmanned aerial vehicle (uav) modelling based on supervised neural networks. **International Conference on Robotics and Automation**, p. 2497–2502, 2006. 2

MATHEWSON, E. **Unmanned aircraft systems flight plan 2009-2047**. Washington DC, Maio 2009. Disponível em: <www.fas.org/irp/program/collect/uas_2009.pdf>. 9

MATHWORKS, I. T. **Matlab R2006a**. Janeiro 2006. Versão 7.2.0.232. 41

MATOS, A.; CRUZ, N. Auv navigation and guidance in a moving acoustic network. **Oceans 2005 - Europe**, v. 1, p. 680–685, 2005. 1

NASRABADI, N. M.; CHOO, C. Y. Hopfield network for stereo vision correspondence. **IEEE Transactions on Neural Networks**, v. 3, n. 1, p. 5–13, Janeiro 1992. 4

NEMRA, A.; AOUF, N. Robust feature extraction and correspondence for uav map building. In: **MEDITERRANEAN CONFERENCE ON CONTROL AND AUTOMATION. Proceedings ...** Los Alamitos, EUA: IEEE Computer Society, 2009. v. 0, p. 922–927. ISBN 978-1-4244-4684-1. 2

NETO, A. A. **Geração de trajetórias para veículos aéreos autônomos não-tripulados**. Dissertação (Mestrado) — UFMG, Belo Horizonte, Brasil, 2008. 4

NIETHAMMER, U.; ROTHMUND, S.; JAMES, M. R.; TRAVELLETTI, J.; JOSWIG, M. Uav-based remote sensing of landslides. In: INTERNATIONAL ARCHIVES OF PHOTOGRAMMETRY, REMOTE SENSING AND SPATIAL INFORMATION SCIENCES, COMMISSION V SYMPOSIUM. **Proceedings ...** Newcastle Upon Tyne, Reino Unido: ISPRS, 2010. v. 38 Parte 5, p. 496–501. 9

OKUNO, H.; YAGI, T. A visually guided collision warning system with a neuromorphic architecture. **Neural Networks**, v. 21, n. 10, p. 1431 – 1438, 2008. ISSN 0893-6080. ICONIP 2007. Disponível em:

<<http://www.sciencedirect.com/science/article/B6T08-4TTMJR9-1/2/ad8cadf31172cc48477af600f2bf4988>>. 4

PUTTIGE, V. R. **Neural network based adaptive control for autonomous flight of fixed wing unmanned aerial vehicles**. Tese (Doutorado) — University of New South Wales - Australian Defence Force Academy. Engineering & Information Technology, New South Wales, Austrália, 2009. Disponível em: <<http://handle.unsw.edu.au/1959.4/43736>>. 2

RICHARDS, J. A.; JIA, X. **Remote Sensing Digital Image Analysis: An introduction**. 4. ed. Verlag Berlin Heidelberg, Alemanha: Springer, 2006. 17, 19

SAMADZADEGAN, F.; HAHN, M.; SAEEDI, S. Position estimation for aerial vehicle based on a vision aided navigation system. **Visualization and Exploration of Geospatial Data**, v. 35, p. 6, 2007. 12

SAMAL, M.; ANAVATTI, S.; GARRATT, M. Real-time neural network based identification of a rotary-wing uav dynamics for autonomous flight. In: INTERNATIONAL CONFERENCE ON INDUSTRIAL TECHNOLOGY. **Proceedings ...** Churchill, Austrália: IEEE, 2009. p. 1–6. 2

SANTOS, B. A. O.; SHIGUEMORI, E. H. Determinação de pontos de controle em imagens aéreas e de videografia para aplicação na navegação autônoma. In: SEMINARIO ANUAL DE INICIACAO CIENTIFICA E POS-GRADUACAO DO IEAV, 3. **Anais ...** São José dos Campos, Brasil: IEAv, 2009. v. 1, p. 41–42. 13

SCHULTZ, A.; REKECZKY, C.; SZATMARI, I.; ROSKAF, T.; CHUA, L. . Spatio-temporal cnn algorithm for object segmentation and object recognition. In: IEEE INTERNATIONAL WORKSHOP ON CELLULAR NEURAL NETWORKS AND THEIR APPLICATIONS, 5. **Proceedings ...** Londres, Inglaterra: IEEE, 1998. p. 347–352. 4

SHIGUEMORI, E. H. **Recuperação de perfis de temperatura e umidade da atmosfera a partir de dados de satélite: abordagens por redes neurais artificiais e implementação em hardware.** Tese (Doutorado) — INPE, São José dos Campos, Brasil, 2007. 56

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. **Proceedings ...** San Jose, Califórnia, EUA: IS&T/SPIE, 2007. v. 6497. 3, 5, 13, 14, 53

SHIMONOMURA, K.; YAGI, T. Neuromorphic vlsi vision system for real-time texture segregation. **Neural Networks**, v. 21, n. 8, p. 1197 – 1204, 2008. ISSN 0893-6080. Neuroinformatics. Disponível em: <<http://www.sciencedirect.com/science/article/B6T08-4T3M678-1/2/83ef6406ec766a3ff688b2faa649ff18>>. 4

SOUZA, C. R. M. de; DIAS, M. H. C.; SANTOS, J. C. A. dos. Análise da vulnerabilidade de receptores gps comerciais sob ação de interferência intencional. In: SIMPOSIO DE GUERRA ELETRONICA, 8. São José dos Campos, Brasil: ITA, 2006. 1, 10

SPAGNOL, C.; MURADORE, R.; ASSOM, M.; BEGHI, A.; FREZZA, R. Model based gps/ins integration for high accuracy land vehicle applications. In: IEEE INTELLIGENT VEHICLES SYMPOSIUM. **Proceedings ...** Las Vegas, EUA: IEEE, 2005. p. 400–405. 10

TORRES-HUITZIL, C.; GIRAU, B.; CASTELLANOS-SÁNCHEZ, C. On-chip visual perception of motion: a bio-inspired connectionist model on fpga. **Neural Networks**, v. 18, n. 5-6, p. 557 – 565, 2005. ISSN 0893-6080. IJCNN 2005. Disponível em: <<http://www.sciencedirect.com/science/article/B6T08-4GX1J0V-1/2/584a31fd9b9001849b3804ddbccdc047>>. 4

URSINO, M.; CARA, G. E. L. A model of contextual interactions and contour detection in primary visual cortex. **Neural Networks**, Elsevier Science Ltd., Oxford, Reino Unido, v. 17, n. 5-6, p. 719–735, 2004. ISSN 0893-6080. 4

WOO, J.; SON, K.; LI, T.; KIM, G.; KWEON, I. S. Vision-based uav navigation in mountain area. In: CONFERENCE ON MACHINE VISION APPLICATIONS. **Proceedings ...** Kyoto, Japão: MVA, 2007. p. 236–239. 11

XU, G.; ZHANG, Y.; JI, S.; CHENG, Y.; TIAN, Y. Research on computer vision-based for uav autonomous landing on a ship. **Pattern Recognition Letters**, v. 30, n. 6, p. 600 – 605, 2009. ISSN 0167-8655. Disponível em: <<http://www.sciencedirect.com/science/article/B6V15-4VBDGM5-3/2/409e8dd307797da2f6dfa25bfc84129f>>. 2

YOO, C.-S.; AHN, I.-K. Low cost gps/ins sensor fusion system for uav navigation. In: DIGITAL AVIONICS SYSTEMS CONFERENCE IEEE, 22. **Proceedings ...** Indianapolis, EUA: IEEE, 2003. v. 2, n. 8A, p. 1–9. 1, 10

ZHANG, J.; LIU, W. Vision-based uav navigation using 3d gis data. In: VASUDEV, B.; HSING, T. R.; TESCHER, A. G.; EBRAHIMI, T. (Ed.). SPIE, 2003. v. 5022, n. 1, p. 910–920. Disponível em: <<http://link.aip.org/link/?PSI/5022/910/1>>. 2, 11

ANEXO A - IMAGENS AÉREAS E DE SATÉLITE UTILIZADAS



Figura A.1 - Região 1: direita imagem aérea e esquerda de satélite.



Figura A.2 - Região 2: direita imagem aérea e esquerda de satélite.



Figura A.3 - Região 3: direita imagem aérea e esquerda de satélite.



Figura A.4 - Região 4: direita imagem aérea e esquerda de satélite.



Figura A.5 - Região 5: direita imagem aérea e esquerda de satélite.



Figura A.6 - Região 6: direita imagem aérea e esquerda de satélite.

**ANEXO B - IMAGENS AÉREAS E DE SATÉLITE COM BORDAS
EXTRAÍDAS PELO OPERADOR CANNY**




Figura B.1 - Região 1: direita imagem aérea e esquerda de satélite.




Figura B.2 - Região 2: direita imagem aérea e esquerda de satélite.




Figura B.3 - Região 3: direita imagem aérea e esquerda de satélite.




Figura B.4 - Região 4: direita imagem aérea e esquerda de satélite.



Figura B.5 - Região 5: direita imagem aérea e esquerda de satélite.




Figura B.6 - Região 6: direita imagem aérea e esquerda de satélite.

ANEXO C - IMAGENS AÉREAS E DE SATÉLITE COM BORDAS
EXTRAÍDAS PELA REDE COM FUNÇÕES DE BASE RADIAL




Figura C.1 - Região 1: direita imagem aérea e esquerda de satélite.




Figura C.2 - Região 2: direita imagem aérea e esquerda de satélite.




Figura C.3 - Região 3: direita imagem aérea e esquerda de satélite.




Figura C.4 - Região 4: direita imagem aérea e esquerda de satélite.




Figura C.5 - Região 5: direita imagem aérea e esquerda de satélite.




Figura C.6 - Região 6: direita imagem aérea e esquerda de satélite.

ANEXO D - IMAGENS AÉREAS E DE SATÉLITE COM BORDAS EXTRAÍDAS PELA REDE PERCEPTRON DE MÚLTIPLAS CAMADAS




Figura D.1 - Região 1: direita imagem aérea e esquerda de satélite.




Figura D.2 - Região 2: direita imagem aérea e esquerda de satélite.




Figura D.3 - Região 3: direita imagem aérea e esquerda de satélite.




Figura D.4 - Região 4: direita imagem aérea e esquerda de satélite.




Figura D.5 - Região 5: direita imagem aérea e esquerda de satélite.




Figura D.6 - Região 6: direita imagem aérea e esquerda de satélite.

**ANEXO E - IMAGENS AÉREAS E DE SATÉLITE COM BORDAS
EXTRAÍDAS PELA REDE NEURAL CELULAR**

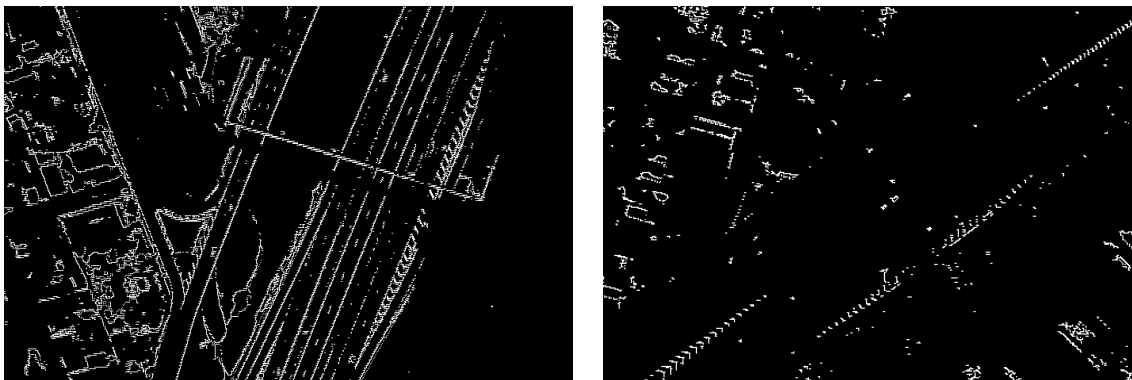


Figura E.1 - Região 1: direita imagem aérea e esquerda de satélite.




Figura E.2 - Região 2: direita imagem aérea e esquerda de satélite.




Figura E.3 - Região 3: direita imagem aérea e esquerda de satélite.




Figura E.4 - Região 4: direita imagem aérea e esquerda de satélite.




Figura E.5 - Região 5: direita imagem aérea e esquerda de satélite.




Figura E.6 - Região 6: direita imagem aérea e esquerda de satélite.

ANEXO F - PUBLICAÇÕES REFERENTES AOS ESTUDOS DESENVOLVIDOS NO CAPÍTULO 5

Detecção de Bordas em Imagens Aéreas e de Satélite com uso de Redes Neurais Artificiais

Gustavo Augusto Mascarenhas Goltz

José Demísio Simões da Silva

Haroldo Fraga de Campos Velho

Instituto Nacional de Pesquisas Espaciais, INPE

12227-010, São José dos Campos, SP

E-mail: gustavo_goltz@yahoo.com.br; [demisio;haroldo]@lac.inpe.br

Elcio Hideiti Shiguemori

Instituto de Estudos Avançados, IEAv – Comando-Geral de Tecnologia Aeroespacial, CTA

12228-001, São José dos Campos, SP

E-mail: elcio@ieav.cta.br

RESUMO

Processamento de imagens em tempo real é uma tarefa fundamental em diversas aplicações de visão computacional como rastreamento, visão estéreo e navegação autônoma. O objetivo deste trabalho é utilizar redes neurais artificiais (RNAs) na detecção de bordas para aplicação na navegação autônoma por imagens de veículos aéreos não-tripulados (VANTs). O uso de bordas na identificação de objetos comuns em imagens de navegação aérea autônoma é útil, principalmente, quando obtidas por diferentes sensores. Uma das abordagens na navegação aérea por imagens é reconhecer o local sobrevoado pelo VANT através da identificação automática de objetos comuns entre uma imagem obtida durante a navegação e uma imagem de satélite embarcada [4]. As principais motivações para se utilizar RNAs nesta aplicação são: o baixo custo computacional, uma vez treinadas; tolerância a falhas; e processamento paralelo e distribuído. Num primeiro passo, as RNAs foram comparadas com imagens-verdade disponíveis num catálogo para este fim [1], bem como com resultados do operador Canny [2]. Num segundo passo as RNAs foram testadas com imagens reais de um voo realizado sobre a cidade de São José dos Campos, em 2005, e imagens pancromáticas do satélite Quickbird.

Neste trabalho foram empregadas três RNAs, a Rede Perceptron de Múltiplas Camadas (RPMC), a Rede com Funções de Base Radial (RBF) e a Rede Neural Celular (RNC), por serem utilizadas por uma grande gama de aplicações, entre elas processamento de imagens. As RNAs foram treinadas com um conjunto de padrões de borda semelhante ao utilizado em [3].

A RBF e a RPMC foram treinadas utilizando-se padrões binários associados a um número escalar desejado. Para as RNCs, propostas por [5,6], foi utilizado o treinamento baseado no algoritmo do perceptron proposto em [7]. A RNC foi treinada com padrões polares ruidosos associados a um padrão desejado.

Os resultados alcançados pelas RNAs para as imagens-teste estão representados na Tabela 1, juntamente com os resultados alcançados pelo operador Canny. Esta tabela contém o Erro Quadrático Médio de cada operador em relação à verdade considerada [1], bem como a porcentagem de pixels de borda em relação ao total de pixels das imagens para cada operador como também o percentual da imagem tida como verdade. A Figura 1 contém as imagens-teste utilizadas no passo 1 deste trabalho.



Figura 1. Imagens-teste, da esquerda para direita: 1 a 5

Imagem	Verdade	Canny		RBF		RPMC		RNC	
	% borda	EQM	% borda	EQM	% borda	EQM	% borda	EQM	% borda
1	1,2539	0,0125	6,3278	0,0313	3,1656	0,0232	2,0196	0,0260	1,9516
2	1,6093	0,0161	5,8992	0,0463	4,9378	0,0403	3,3468	0,0444	3,1296
3	1,2205	0,0122	9,7427	0,0989	9,6478	0,0638	5,7179	0,0365	2,6512
4	1,4391	0,0144	4,8979	0,0538	5,3861	0,0399	3,3377	0,0499	4,1623
5	1,3364	0,0133	5,5307	0,0596	5,2388	0,0409	3,2637	0,0216	1,3266

Tabela 1. Porcentagem de pontos de borda e EQM em relação às imagens-verdade

Na Figura 2 são apresentadas as imagens utilizadas nos testes do segundo passo. Na Tabela 2 apresentam-se os índices da Tabela 1 para as imagens da Figura 2, considerando-se o resultado do Canny como verdade, visto seu desempenho nos testes anteriores.



Figura 2. Da esquerda para direita: Imagens aéreas 1 e 2, e imagens de satélite 3 e 4

Imagem	Canny	RBF		RPMC		RNC	
	% borda	EQM	% borda	EQM	% borda	EQM	% borda
1	10,3586	0,1867	14,6901	0,1590	9,5707	0,1474	6,3551
2	6,9003	0,1022	6,7951	0,0917	4,1713	0,0782	1,5664
3	12,0398	0,2454	24,0282	0,2176	14,5614	0,1375	2,1936
4	9,4452	0,2085	19,8609	0,1786	12,7677	0,1182	3,1480

Tabela 2. Porcentagem de pontos de borda e EQM em relação às imagens aéreas e de satélite

No geral todos os operadores encontraram mais bordas que as imagens-verdade e segmentaram regiões com textura que não haviam sido segmentadas nas imagens-verdade. A RPMC obteve os melhores resultados entre os operadores neurais nos dois passos. Esta não possui parâmetros iniciais como o Canny e as demais RNAs. O Canny demonstrou ser mais robusto que as RNAs em regiões de baixo contraste. A RNC mostrou ser mais robusta em regiões de textura, porém gerou menos segmentos comparando-se com os demais operadores. As RNAs mostraram ser viáveis na tarefa de detecção de bordas para a aplicação desejada. Serão testadas outras formas de se construir suas arquiteturas e outras formas de treinamento com o objetivo de melhorá-las, para posterior implementação na aplicação em tempo real em navegação aérea autônoma.

Palavras-chave: Detecção de bordas, Redes Neurais Artificiais, Método de Canny

Referências

- [1] Berkeley Segmentation Dataset: Images. Disponível em: <<http://www.eecs.berkeley.edu/Research/Projects/CS/vision/grouping/segbench/BSDS300/html/dataset/images.html>>. Acesso: Maio/2009.
- [2] J. Canny, A Computational Approach to Edge Detection, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 8, n. 6, pp. 679-698 (1986).
- [3] A. P. A. Castro, "Detecção de Bordas e Navegação Autônoma utilizando Redes Neurais Artificiais", Dissertação de Mestrado, INPE, 2003.
- [4] E. H. Shiguemori, M. V. T. Monteiro, M. P. Martins. Landmarks recognition for autonomous aerial navigation by neural networks and gabor transform, IS&T/SPIE 19th Annual Symposium Electronic Imaging Science and Technology, Image Processing: Algorithms and Systems V, San Jose, California, EUA, v. 6497 (2007).
- [5] L. O. Chua, L. Yang, Cellular Neural Networks: Theory, IEEE Transactions on Systems and Circuits, vol. 35, n.10, pp. 1257-1272 (1988).
- [6] L. G. Corrêa, "Memória Associativa em Redes Neurais Realimentadas", Dissertação de Mestrado, USP, 2004.
- [7] D. Liu, Z. Lu, A New Synthesis Approach for FeedBack Neural Networks Based on the Perceptron Training Algorithm, IEEE transactions on Neural Networks, vol. 8, n.6, pp. 1468-1492 (1997).

Figura F.1 - Resumo publicado nos Anais do 32^o CNMAC: Congresso Nacional de Matemática Aplicada e Computacional (Ano: 2009).

Redes Neurais para Detecção de Bordas em Imagens Aéreas e de Satélite Aplicadas em Navegação Aérea Autônoma

Gustavo Augusto Mascarenhas Goltz***, Elcio Hideiti Shiguemori**, José Demísio Simões da Silva*, Haroldo Fraga de Campos Velho*

*Instituto Nacional de Pesquisas Espaciais, S. J. dos Campos, Brasil – e-mail: [demisio.haroldo@lac.inpe.br; gustavo_goltz@yahoo.com.br
**Instituto de Estudos Avançados, S. J. dos Campos, Brasil – e-mail: elcio@ieav.cta.br

Resumo — Foram implementadas três redes neurais artificiais para detecção de bordas. Resultados preliminares são comparados com o operador Canny e mostram-se viáveis para aplicação em navegação aérea autônoma, que exige processamento em tempo real e embarcado.
Palavras Chave: RNAs, detecção de bordas, Canny.

I. INTRODUÇÃO

Em análise de imagens, a segmentação é responsável por separar regiões ou objetos de interesse [1]. O processo de segmentação exige a identificação das bordas desses objetos ou regiões. O uso de bordas na identificação de objetos comuns em imagens obtidas por diferentes sensores é útil em navegação aérea autônoma por imagens. Isto exige processamento em tempo real e embarcado, tornando a utilização de redes neurais artificiais (RNAs) implementadas em dispositivos eletrônicos de alto desempenho, uma alternativa para suprir estas necessidades. As RNAs desenvolvidas neste trabalho foram comparadas com o operador Canny [2], o qual obtém bordas de forma precisa e robusta ao ruído, porém é um algoritmo complexo para implementação em hardware.

II. METODOLOGIA

Neste trabalho empregaram-se as seguintes RNAs: rede perceptron de múltiplas camadas – RPMC; rede de função de base radial – RBF; e uma rede neural celular – RNC. Estas RNAs foram escolhidas por serem utilizadas com sucesso na detecção de bordas em [3] e [4]. Todas foram treinadas de forma supervisionada com um conjunto de padrões de borda, baseados em [3]. A RBF e a RPMC tiveram uma saída associada a cada padrão de borda do conjunto de treinamento. A RNC foi treinada associando-se padrões de borda ruidosos com o padrão desejado. A RBF e a RPMC foram treinadas com padrões de borda binários e a RNC com padrões de borda polares. A RBF e a RPMC são ativadas com uma janela 3x3 que caminha na imagem ao passo de um pixel e captura esta região, a qual é enviada à rede neural. A saída da rede (um escalar) é comparada com todas as saídas que correspondem a cada padrão de borda. É atribuída à imagem de saída o valor central do padrão que está mais associado à saída da rede neural. A entrada de ativação da RNC ocorre de forma semelhante, porém utiliza uma equação de ativação recorrente que pára quando sua saída torna-se estável. O pixel central da saída da rede é atribuído à imagem de saída da rede.

III. RESULTADOS

Para a detecção de bordas utilizou-se um conjunto de imagens aéreas e de satélite das mesmas regiões. Cada uma foi processada pelas RNAs implementadas e pelo operador Canny. Na Fig. 1 tem-se um dos resultados encontrados de imagem de satélite utilizada e suas bordas extraídas pela RBF.

Foi realizada uma análise quantitativa ao calcular o erro quadrático médio (EQM) das imagens de bordas geradas pelas RNAs em relação às geradas pelo Canny, e através da porcentagem de bordas encontradas em relação ao total de pixels da imagem. Ambos os cálculos estão descritos em detalhes em [3].




FIGURA 1: Bordas extraídas pela RBF

A Tab. 1 mostra o EQM bem como a porcentagem de pixels de borda em duas imagens (1 e 2) pertencentes ao conjunto de imagens analisado, dado o método de extração de borda aplicado.

TABELA 1: EQM e porcentagem de borda das imagens geradas

Tipo de Imagem	Método	Imagem	EQM	% de borda
Imagens de Satélite	Canny	1	---	12,0398
	Canny	2	---	9,4452
	RBF	1	0,2454	24,0282
	RBF	2	0,2085	19,8609
	RP	1	0,2176	14,5614
	RP	2	0,1786	12,7677
Imagens Aéreas	RNC	1	0,1375	2,1936
	RNC	2	0,1182	3,1480
	Canny	1	---	10,3586
	Canny	2	---	6,9003
	RBF	1	0,1867	14,6901
	RBF	2	0,1022	6,7951
Imagens Aéreas	RP	1	0,1590	9,5707
	RP	2	0,0917	4,1713
	RNC	1	0,15	6,3551
	RNC	2	0,0782	1,5664

IV. DISCUSSÃO E CONCLUSÕES

A RNC apresentou os menores e detectou menos bordas. A RBF e a RPMC foram mais rápidas que a RNC pelo custo da ativação iterativa desta rede. As RNAs implementadas mostraram resultados próximos ao Canny.

V. REFERÊNCIAS

- [1] C. R. Gonzalez, E. R. Woods, Processamento de Imagens Digitais. São Paulo: Editora Edigard Blucher Ltda, 2000.
 - [2] J. A. Canny. "Computational Approach to Edge Detection", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 8, nº 6, pp. 679-698, 1986.
 - [3] A. P. A. Castro, Detecção de Bordas e Navegação Autônoma utilizando Redes Neurais Artificiais, Dissertação de Mestrado. São José dos Campos: INPE, 2003.
 - [4] L. G. Corrêa, Memória Associativa em Redes Neurais Realimentadas, Dissertação de Mestrado, São Carlos: USP, 2004.
- Agradecimentos:* ao CNPq e ao COMAER, projeto PITER, No. V01050303
Grupo de Pesquisa no IEAv: Sensoriamento Remoto

Figura F.2 - Resumo publicado nos Anais do IX WAI: *Workshop* Anual de Pesquisa e Desenvolvimento do IEAv (Ano: 2009).

Avaliação do Erro de Estimção da Posição de um VANT através da Correlação entre Imagens Aéreas e de Satélite

Gustavo Augusto Mascarenhas Goltz, Elcio Hideiti Shiguemori e Haroldo Fraga de Campos Velho

IEAV – Instituto de Estudos Avançados – São José dos Campos, Brasil
INPE – Instituto Nacional de Pesquisas Espaciais – São José dos Campos, Brasil

Resumo — Neste trabalho aplicou-se a correlação no domínio espacial entre imagens aéreas e de satélite com o objetivo de estimar a posição geográfica de um veículo aéreo não tripulado (VANT) durante seu voo, através de imagens capturadas do terreno sobrevoado correlacionadas com uma imagem de satélite georeferenciada da mesma região. Para possibilitar a correlação, a imagem aérea deve ser corrigida em escala e rotação, que são grandezas estimadas pelo altímetro e pela bússola do VANT, respectivamente. Inserindo-se erro nestas grandezas, avaliou-se o erro gerado pela correlação na estimativa da posição geográfica do VANT.

Palavras-chave — Inteligência de máquinas e robótica, correlação, navegação aérea autônoma por imagens.

I. INTRODUÇÃO

A aplicação de Veículos Aéreos Não Tripulados (VANTS) intensificou-se nos últimos tempos, devido ao baixo custo operacional e de fabricação comparados às aeronaves convencionais, ausência de tripulação, entre outros fatores. São empregados em sensoriamento remoto (com sensores óticos ou SAR embarcados) para monitoramento de cidades, atividades humanas ou áreas de risco, como o levantamento aéreo de zonas de conflito ou de catástrofes naturais. VANTS rádio-controlados possuem limitação do alcance da antena, bem como possível interferência na comunicação com a base de controle. Interferências no sinal também podem ocorrer com VANTS que utilizam sinal GPS (*Global Positioning System*) aliado ao INS (*Inertial Navigation System*) para navegação. Um exemplo deste tipo de sistema de navegação em VANTS pode ser visto em [1]. Um possível bloqueio do sinal GPS também se torna uma limitação ao seu uso. Uma alternativa para estes problemas é a navegação aérea baseada na captura em tempo real de informações sobre o terreno sobrevoado, como o mapa digital de elevação do terreno [2] ou seu imageamento, extraindo das imagens a informação de textura [3] ou bordas [4]. Técnicas de visão computacional também auxiliam a navegação do VANT com o reconhecimento de objetos do terreno, como é feito em [5] com visão estéreo, e em [6] com a aplicação de correspondência entre imagens. A posição geográfica de um VANT pode ser estimada pelo casamento das imagens do

G. A. M. Goltz, gustavo.goltz@ieav.cta.br, E. H. Shiguemori, elcio@ieav.cta.br, H. F. Campos Velho, haroldo@lac.inpe.br

Este trabalho foi financiado pelo COMAER, através do Projeto PITER, No. V01050303 e CNPq. terreno sobrevoado, capturadas em tempo real, com imagens de satélite georeferenciadas embarcadas no VANT, da mesma região sobrevoada.

Existe um alto custo computacional de se encontrar uma pequena região sobrevoada em uma imagem de satélite contendo toda a região do plano de voo. Este custo pode ser reduzido concentrando-se a busca da região sobrevoada em torno de um ponto estimado pelo sensor inercial do VANT, o qual é corrigido pelo próprio casamento entre as imagens periodicamente.

II. FATORES QUE DIFICULTAM O CASAMENTO ENTRE AS IMAGENS

Fatores como, escala, rotação, diferença de luminosidade e diferença na resposta espectral da cena capturada entre os dois sistemas (câmera de imageamento do VANT e sistema de imageamento do satélite) fazem com que uma mesma cena seja representada de forma diferente na imagem capturada em tempo real pelo VANT e na imagem de satélite utilizada.

Um dos fatores comuns é que ambas as imagens foram capturadas em visada nadir, eliminando efeitos de perspectiva. A rotação pode ser corrigida através da informação da bússola do VANT. A diferença de escala entre as imagens pode ser estimada pela informação do altímetro do VANT. Detalhes do terreno em ambas as imagens podem ser eliminados ao aplicar nestas imagens um filtro passa-baixas. Isso faz com que sejam mantidos nas imagens apenas os objetos e feições do terreno mais relevantes. Fatores ligados às diferenças de luminosidade e de resposta espectral são eliminados utilizando-se somente as bordas extraídas das imagens.

III. OBTENÇÃO DO CASAMENTO ENTRE AS IMAGENS AÉREAS E DE SATÉLITE

Inicialmente a imagem capturada em tempo real pelo VANT é corrigida em escala e rotação, em relação à região da imagem de satélite embarcada. Esta região é delimitada em torno do ponto onde o sensor inercial estima ser a posição geográfica do VANT. Um filtro da mediana com uma máscara de convolução 3x3 é aplicado nas duas imagens, com o intuito de eliminar pequenos detalhes nas imagens. Em seguida as bordas são extraídas. Neste trabalho utilizou-se o operador Sobel para este fim. Com as bordas das duas

imagens, o casamento é feito com o cálculo da correlação [7] no domínio espacial, dada por (1).

$$c(s,t) = \sum_x \sum_y f(x,y)w(x-s,y-t) \quad (1)$$

Sendo $c(s,t)$ a correlação c de índices s,t , com $s = 0,1,\dots,M-1$ e $t = 0,1,\dots,N-1$, sendo M e N 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 $K \leq N$, contendo as bordas da imagem aérea. Dada a maior correlação c encontrada entre as matrizes f e w , o ponto na imagem de satélite f que coincide com o ponto central da imagem aérea w corresponde-se à localização do VANT no momento em que este sobrevoou tal região imageada. Conhecendo-se este ponto, suas coordenadas corrigem o sensor inercial e o processo de casamento entre as imagens recomeça. O diagrama da Fig. (1) resume o processo de casamento descrito. Para acelerar o cálculo da correlação, a imagem aérea também tem sua área reduzida em torno do seu ponto central, após as correções de escala e rotação.

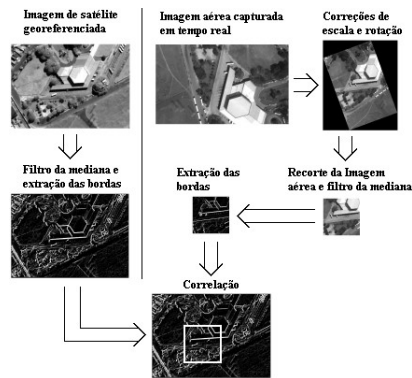


Fig. 1. Passos do processo de casamento

IV. MATERIAIS UTILIZADOS E METODOLOGIA

Para simular as imagens capturadas em tempo real por um VANT, foram utilizadas imagens de uma videografia aérea realizada a uma altitude constante. A imagem de satélite utilizada possui alta resolução espacial de 0,6m a fim de facilitar o casamento com a imagem aérea. O cálculo da correlação foi realizado em 10 pares de imagens (uma imagem aérea e uma de satélite) que simulam 10 regiões diferentes sobrevoadas por um VANT, sendo que cada imagem de satélite contém a região da imagem aérea correspondente. As dimensões das imagens utilizadas no cálculo da correlação foram: para a imagem de satélite 480x340 pixels e para a imagem aérea 191x191 pixels. A

imagem aérea tem dimensões ímpares para que haja um pixel central. O ponto na imagem de satélite que coincide com este pixel central é a posição geográfica do VANT calculada. Para cada par de imagens foi estimado visualmente o ponto central que coincide a imagem aérea na imagem de satélite, representando o ponto geográfico onde o VANT se encontra naquele momento. Este ponto assumiu-se como verdade para o cálculo do erro. A escala e rotação necessárias para corrigir a imagem aérea em relação à de satélite também foram estimadas visualmente. Atribuindo-se erros de +5% e -10% nos valores de escala e rotação estimados, avaliou-se a robustez do método para a estimação da localização do VANT. Os resultados obtidos encontram-se a seguir.

V. RESULTADOS

As seguintes situações com ocorrência de erro na escala e rotação foram estabelecidas:

- escala com 0% de erro e rotação com 0% de erro
- escala com 0% de erro e rotação com +5% de erro
- escala com 0% de erro e rotação com +10% de erro
- escala com +5% de erro e rotação com 0% de erro
- escala com +5% de erro e rotação com +5% de erro
- escala com +5% de erro e rotação com +10% de erro
- escala com +10% de erro e rotação com 0% de erro
- escala com +10% de erro e rotação com +5% de erro
- escala com +10% de erro e rotação com +10% de erro

A correlação foi calculada entre os 10 pares de imagens, para cada situação acima. O erro médio, em metros, foi calculado para cada situação de erro estabelecida e pode ser visualizado na Tabela 1. O erro em metros foi obtido pela distância euclidiana entre o ponto estimado pela correlação e ponto considerado como verdade, multiplicando esta distância em pixels por 0,6, que se corresponde à resolução espacial em metros de cada pixel.

TABELA I ERRO MÉDIO EM METROS PARA CADA SITUAÇÃO DEFINIDA DE ERROS DE ESCALA E ROTAÇÃO

		Rotação				
		Erro	0%	+5%	-5%	+10%
E s c a l a	0%	17,5691	26,0526	23,9107	37,0409	22,4340
	+5%	27,4574	25,8143	21,7140	33,6119	22,0860
	-5%	18,7518	22,4229	14,5507	29,2616	14,4072
	+10%	32,1567	37,7637	27,7461	52,7081	34,1553
	-10%	33,0129	41,3799	25,8231	47,4098	26,3929

O maior erro registrado nos testes foi de 116,5175 m, ocorrido em um par de imagens com erros de escala e de rotação de -10%. Um erro igual a zero foi obtido, em relação ao ponto estimado, com um par de imagens com erro de escala com +5% e com a rotação correta.

Um teste aplicando erros de +15% de escala e rotação atingiu um erro médio de 49,3319 m, com o maior erro amostral de 95,1582 m, e ao inserir um erro de +20% na escala e na rotação, o erro médio passou para 52,3564 m, com o maior erro amostral de 116,8399 m. O par de imagens que apresentou erro máximo de estimação da posição do VANT, em cada situação de erro de escala e rotação estabelecida, não foi o mesmo.

Levando-se em consideração as dimensões das imagens aéreas e de satélite utilizadas nos testes, o maior erro possível de ocorrer para a estimação da posição do VANT é de 197,4985 m.

VI. DISCUSSÃO, CONCLUSÕES E TRABALHOS FUTUROS

Na Tabela (1) observa-se que, no geral, o erro possui uma taxa de aumento maior ao se percorrer esta tabela no mesmo sentido do aumento do erro de escala, do que no sentido do aumento do erro de rotação, com isso conclui-se que o método estudado é mais sensível a erros de escala do que de rotação.

O método possui relativa robustez a erros de escala e rotação devido à forma com que são extraídas as bordas pelo método de Sobel, o qual produz bordas largas e com diferentes níveis de cinza, aonde os pixels gradualmente vão diminuindo de intensidade ao se afastarem do ponto onde o gradiente de borda é máximo. Em testes preliminares, onde se utilizou o operador Canny ao invés do Sobel, constatou-se um aumento considerável do erro de estimação da posição do VANT, devido ao operador Canny gerar bordas mais precisas, dificultando o processo de casamento entre as imagens.

Ao se mudar os erros de escala e rotação de 0% e +10%, respectivamente, para +5% (ou -5%) e +10%, respectivamente, nota-se uma diminuição do erro de estimação da posição do VANT. Isso também ocorre em outros casos da Tabela (1), onde o erro de estimação da posição do VANT melhorou ao aumentar o erro de escala e/ou rotação. Estes fatos podem estar ligados ao erro presente na estimação visual dos pontos corretos de localização do VANT, como também na estimação visual de escala e rotação consideradas como corretas. Uma forma de evitar erros na estimação de escala, rotação e posição real do VANT é utilizar imagens aéreas georeferenciadas para a validação do método abordado. Outra possível forma de eliminar o erro de estimação visual da posição do VANT é utilizar um simulador de voo com a informação do sinal GPS para validar o método. Isso será futuramente realizado.

Este trabalho limitou-se a avaliar o erro de estimação da posição do VANT com o uso da correlação entre as imagens, não demonstrando uma forma de eliminar “falsos positivos”, ou seja, correlações erradas consideradas como corretas. Uma forma de eliminar estas correlações pode ser feita de semelhante forma à utilizada em [4], onde um histórico do desvio-padrão entre a posição estimada pelo sensor inercial e pelo sistema de imageamento é guardado, para um dado intervalo de tempo. Caso o sistema de imageamento estime uma posição do VANT que produza um desvio-padrão maior

que o desvio-padrão médio (levando-se em conta um limiar), esta posição é rejeitada.

O cálculo da correlação no domínio da frequência [7] é uma alternativa caso haja interesse em aumentar a velocidade de computação do casamento entre as imagens aéreas e de satélite.

REFERÊNCIAS

- [1] Yoo, C.-S.; Ahn, I.-K. Low cost GPS/INS sensor fusion system for UAV navigation. 22nd Digital Avionics Systems Conference IEEE, v. 2, n. 8A, p. 1-9, 2003.
- [2] Jun Zhang and Weisong Liu. Vision-Based UAV Navigation using 3D GIS data. Proc. SPIE 5022, 910 (2003), DOI:10.1117/12.476705
- [3] Shiguemori, E. H. ; Monteiro, Marcus Vinicius T. ; Martins, Mauricio Pozzobon . Landmarks recognition for autonomous aerial navigation by neural networks and Gabor transform. In: IS&T/SPIE 19th Annual Symposium Electronic Imaging Science and Technology, 2007, San Jose, CA, USA. Image Processing: Algorithms and Systems V, 2007. v. 6497.
- [4] Conte, G. and Doherty, P. An Integrated UAV Navigation System Based on Aerial Image Matching. Aerospace Conference, 2008 IEEE.
- [5] Lee, S.; Yoon, S.; Kim, H. J.; Kim, Y. Wireless stereo vision system development for rotary-wing UAV guidance and control. 3rd International Conference on Sensing Technology, p. 168-173, 2008.
- [6] Nemra, A.; Aouf, N. Robust feature extraction and correspondence for UAV map building. Mediterranean Conference on Control and Automation, IEEE Computer Society, Los Alamitos, EUA, v. 0, p. 922-927, 2009.
- [7] Gonzalez, R. C. and Woods, R. E. (2000). *Processamento de Imagens Digitais*. São Paulo, 1 edição.

Figura F.3 - Artigo publicado nos Anais do IX SIGE: Simpósio de Aplicações Operacionais em Áreas de Defesa (Ano: 2009).

PUBLICAÇÕES TÉCNICO-CIENTÍFICAS EDITADAS PELO INPE

Teses e Dissertações (TDI)

Teses e Dissertações apresentadas nos Cursos de Pós-Graduação do INPE.

Manuais Técnicos (MAN)

São publicações de caráter técnico que incluem normas, procedimentos, instruções e orientações.

Notas Técnico-Científicas (NTC)

Incluem resultados preliminares de pesquisa, descrição de equipamentos, descrição e ou documentação de programas de computador, descrição de sistemas e experimentos, apresentação de testes, dados, atlas, e documentação de projetos de engenharia.

Relatórios de Pesquisa (RPQ)

Reportam resultados ou progressos de pesquisas tanto de natureza técnica quanto científica, cujo nível seja compatível com o de uma publicação em periódico nacional ou internacional.

Propostas e Relatórios de Projetos (PRP)

São propostas de projetos técnico-científicos e relatórios de acompanhamento de projetos, atividades e convênios.

Publicações Didáticas (PUD)

Incluem apostilas, notas de aula e manuais didáticos.

Publicações Seriadas

São os seriados técnico-científicos: boletins, periódicos, anuários e anais de eventos (simpósios e congressos). Constam destas publicações o Internacional Standard Serial Number (ISSN), que é um código único e definitivo para identificação de títulos de seriados.

Programas de Computador (PDC)

São a seqüência de instruções ou códigos, expressos em uma linguagem de programação compilada ou interpretada, a ser executada por um computador para alcançar um determinado objetivo. Aceitam-se tanto programas fonte quanto os executáveis.

Pré-publicações (PRE)

Todos os artigos publicados em periódicos, anais e como capítulos de livros.