

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 vôo 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 respresentados 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 pertentual 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						
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 19° 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).