

Redes Neurais Supervisionadas para Detecção de Bordas

Ana Paula Abrantes de Castro
Instituto Nacional de Pesquisas Espaciais
apaula@lac.inpe.br

José Demisio Simões da Silva
Instituto Nacional de Pesquisas Espaciais
demisio@lac.inpe.br

Resumo

Este artigo apresenta um estudo e a implementação de Redes Neurais Artificiais na detecção de bordas em imagens. São apresentados quatro modelos de redes neurais artificiais com aprendizagem supervisionada, com o objetivo de buscar o modelo mais adequado para a tarefa de detecção de bordas, segundo critérios de desempenho que comparam as redes neurais artificiais com um algoritmo tradicional na área de visão computacional, como por exemplo, o operador de Canny. Os resultados encontrados mostram-se promissores, com as redes neurais apresentando desempenho similar ao método de Canny.

Palavras-chave: *redes neurais, detecção de bordas e visão computacional.*

1. Introdução

Este artigo apresenta um estudo e a implementação de Redes Neurais Artificiais na detecção de bordas em imagens [1]. São apresentados quatro modelos de redes neurais artificiais com aprendizagem supervisionada, a rede Perceptron de Múltiplas Camadas (PMC) [2], a rede de Funções de Base Radial (RBF) [2] e a rede Aprendizagem por Quantização Vetorial (LVQ1 e LVQ2) [3], com o objetivo de buscar o modelo mais adequado para a tarefa de detecção de bordas, segundo critérios de desempenho que comparam as redes neurais artificiais com um algoritmo tradicional na área de visão computacional, como por exemplo, o operador de Canny [4]. São usadas diferentes imagens teste na experimentação das redes neurais no processo de detecção de bordas.

A motivação para o desenvolvimento deste trabalho foi o artigo de Castro et al. [5], que desenvolveu um modelo computacional adaptável para um sistema de navegação autônoma baseado em imagens, utilizando decisões de controle baseado em lógica nebulosa. No sistema a direção e a velocidade a ser empregada pelo veículo são obtidas, do sistema de decisão nebuloso, com base nas informações extraídas das imagens do ambiente de navegação, utilizando um operador gradiente para localizar as regiões

de auto-contraste da imagem, entre a pista e as faixas laterais, permitindo o cálculo das direções das faixas laterais para a tomada de decisão de navegação. O operador gradiente mostrou-se sensível a ruídos (nas imagens) oriundos do processo de transmissão por rádio frequência, desde a câmera a bordo do veículo.

Com objetivo de buscar operadores mais tolerantes a falhas, neste trabalho propõem-se o estudo, a implementação e a análise de modelos de RNAs como operadores para extração das informações do ambiente.

A abordagem para usar redes neurais na detecção de bordas utilizada neste artigo, consiste em treinar as redes neurais a reconhecer elementos de bordas (padrões) na imagem, assumindo que uma borda resulta da união de elementos básicos. Assim, os padrões utilizados nos treinamentos das redes neurais são padrões considerados como possíveis elementos de bordas.

O trabalho apresenta também um método para medir a qualidade das imagens de borda geradas pelos operadores de redes neurais. Os resultados encontrados mostram-se promissores, com as redes neurais apresentando desempenho similar ao método de Canny [6].

2 Sistema de detecção de bordas por redes neurais

Neste artigo, descreve-se o uso de redes neurais como alternativa para realizar tarefas na área de processamento digital de imagens. O diagrama hierárquico da Figura 2.1 mostra a metodologia adotada para testar os diferentes modelos de redes neurais utilizados na tarefa de detecção de bordas em imagens.




Figura 2.1 – Diagrama hierárquico do sistema

A abordagem para usar redes neurais na detecção de bordas, consiste em treinar as redes neurais a reconhecer elementos de bordas (padrões) na imagem, assumindo que

uma borda resulta da união de elementos básicos. Assim, os padrões utilizados nos treinamentos das redes neurais são padrões considerados como possíveis elementos de bordas (Figura 2.2).




Figura 2.2 – Exemplos dos 26 padrões de bordas.

No processo de detecção de bordas nas imagens, utiliza-se uma janela deslizante 3×3 sobre a imagem principal, para extração de estruturas locais de bordas. Os dados da janela são normalizados antes de serem apresentados às redes. Dependendo do modelo de rede usado, quando um padrão de borda é detectado uma matriz binária equivalente ao padrão de borda detectado é associada a uma área de mesma dimensão numa imagem de saída, ou um número representando a identificação do padrão de borda encontrado é associado ao elemento central da janela.

A aplicação das redes neurais na janela da imagem é precedida pelo cálculo da variância, que indica a presença ou não de elementos de bordas. A variância é utilizada neste contexto como uma medida de contraste da janela, medindo a dispersão quadrática média dos pixels na janela. A variância calculada é utilizada para uma pré-seleção das janelas da imagem que devem ser submetidas ao processamento pelas redes.

Depois de treinadas, as redes são ativadas para detecção de bordas. Cada rede recebe como entrada a janela da imagem de onde se deseja extrair bordas. Os parâmetros para o funcionamento das redes são aqueles obtidos durante o treinamento. As imagens de bordas encontradas são binárias, enfatizando as áreas da imagem que apresentam contraste significativo, segundo um critério de decisão dependente dos objetivos da aplicação.

4 Resultados

Nesta seção são apresentados os resultados obtidos na detecção de bordas utilizando técnicas de redes neurais artificiais, como proposto neste artigo, são considerados dois aspectos dos algoritmos: o tempo de processamento sobre as imagens e a qualidade das imagens de bordas geradas. Os resultados obtidos são comparados aqueles produzidos pelo operador de Canny [4].

A comparação entre os resultados foi feita qualitativamente, através de uma análise visual, quantitativamente através da comparação das imagens de bordas geradas por cada algoritmo, com as imagens de bordas tomadas como verdade terrestre (*ground truth*), usando diferentes técnicas.

As imagens de bordas geradas pelos operadores neurais possuem intensidades binárias ou numéricas. O operador

de Canny, por sua vez, gera imagens com diferentes intensidades (gradiente), proporcionais às informações de bordas calculadas em cada ponto. Assim, faz-se necessário tornar as imagens compatíveis, antes de aplicar um método de comparação. Para isso, as imagens de bordas geradas pelo operador de Canny são binarizadas. A binarização das imagens neste artigo utiliza o método de limiarização unimodal proposto por [7].

No algoritmo de [6], a limiarização da imagem de borda é feita através da limiarização por histerese. Para verificar o resultado da limiarização pelo método [7], utilizou-se o algoritmo de Ma [8], que usa limiarização por histerese para efeito de comparação. Nas Figuras 4.1 (a)-(c) tem-se a imagem original, a imagem de bordas gerada pelo operador de Canny [6], a imagem pelo método de histerese [8] e a imagem após a aplicação do método de limiarização [7].




Figura 4.1 - Imagem da Lena em níveis de cinza: (a) original, (b) Canny, (c) Limiarizada pelo método de Rosin e (d) Limiarizada pelo método de histerese.




Figura 4.2 - Imagem da Lena com limiar 100: (a) RPMC, (b) RBF, (c) LVQ1 e (d) LVQ2.

As Figuras 4.2(a)-(d) apresentam os resultados obtidos pelas redes neurais RPMC, RBF, LVQ1, LVQ2 respectivamente, sobre a imagem da Lena em níveis de cinza. O valor do limiar igual a 100 foi encontrado de

forma empírica. Este limiar significa que as janelas com variância abaixo de 100 são consideradas homogêneas, não apresentando, portanto informação de contraste significativo. Uma análise visual entre as imagens, mostra que as redes tiveram um desempenho qualitativo parecido. Uma comparação visual com os resultados das redes neurais mostra que as redes apresentam resultados satisfatórios, quando comparados com o operador Canny. Uma diferença que pode ser notada está na intensidade das bordas detectadas.

A Tabela 4.1 apresenta o percentual de pontos de bordas encontrados pelo operador de Canny, em relação às dimensões da imagem; o percentual de pontos de bordas encontrados pelos operadores neurais, em relação às dimensões das imagens; o erro quadrático médio entre as imagens de bordas geradas; o tipo de rede e as imagens utilizadas. As imagens geradas pelos operadores neurais consideravam um limiar de variância igual a 100.

Tabela 4.1 - Diferenças entre as imagens de bordas de Canny e os operadores neurais com limiar 100.

	Canny	BP	RBF	LVQ1	LVQ2
No. de Pontos	39365	37387	37387	37387	37387
Percentual de Pontos de Bordas	0.15	0.14	0.14	0.14	0.14
MQE entre Canny e RN	-	0.04	0.04	0.04	0.04

Através da Tabela 4.1, podemos observar que algumas redes neurais tiveram o mesmo desempenho. Isso aconteceu devido ao modelo de rede utilizado. Em alguns modelos as saídas estão associadas aos tipos de bordas. Em outros modelos a saída da rede é o próprio elemento de borda. A Tabela 4.2 apresenta o tempo de processamento de cada algoritmo para um limiar de variância igual 100.

Tabela 4.2 – Tempo de processamento de cada algoritmo sobre as diferentes imagens (em segundos).

Imagem	Canny	BP	RBF	LVQ1	LVQ2
Lena	15,8	29,3	34,0	27,1	27,6

Através da Tabela 4.2, pode-se observar que o algoritmo de Canny é mais rápido. Porém o algoritmo implementado não utilizou nenhum tipo de limiarização. A limiarização foi realizada após a medida do tempo. A rede RBF foi a mais demorada, e a rede LVQ1 foi a rede que obteve o menor tempo.

5 Conclusão

Neste artigo, são apresentados resultados de pesquisa, estudos e experimentações do uso de RNA diferentes na detecção de bordas em imagens. Os estudos e experimentos foram realizados procurando mostrar a

eficiência das redes neurais como operadores para detecção de bordas, comparando-as com algoritmos de detecção de bordas considerados padrões na literatura de visão computacional. Foram experimentados quatro modelos de RNA que utilizam paradigmas de aprendizagem supervisionada.

Foi observado, que o número de padrões utilizados no treinamento não influencia o desempenho das redes. Outro fator importante é a escolha do parâmetro limiar de variância que evita processamento excessivo; a escolha do limiar influencia os resultados. Observou-se que a escolha de um limiar inadequado pode implicar em perdas de informação de bordas. A análise comparativa visual com o operador de Canny, tomado como operador padrão (Shin et al. 2001), apresenta resultados semelhantes com as redes apresentando bordas mais definidas na intensidade, por terem saídas binárias.

Os resultados encontrados mostram-se promissores, com as redes neurais apresentando desempenho aproximado a um método padrão em visão computacional, na tarefa de detecção de bordas. Ressalte-se que cada modelo de rede neural exigiu adequação dos dados de treinamento devido às suas características de aprendizagem. Entretanto, dada à existência de um número crescente de modelos de redes neurais, é possível concluir que muita pesquisa ainda precisa ser realizada para explorar todo o potencial dos sistemas de redes neurais artificiais.

6. Referências

- [1] Castro, A.P.A. Detecção de Bordas e Navegação Autônoma Utilizando Redes Neurais Artificiais. São José dos Campos - SP, 2003. 154p. *Dissertação de Mestrado* - Instituto Nacional de Pesquisas Espaciais, INPE.
- [2] Haykin, S. *Redes Neurais: Princípios e Prática*. Porto Alegre: Bookman, 2001. 900 p.
- [3] Fausett, L. *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*. New Jersey: Prentice Hall, 1994. 461 p.
- [4] Canny, J. F. A Computational Approach to Edge Detection. *IEEE Trans. Pattern Analysis and Machine Intelligence*, v. PAMI, n. 8, p. 679-698, 1986.
- [5] Castro, A. P. A.; Silva, J. D. S.; Simoni, P. O. Image Based Autonomous Navigation Fuzzy Logic Control. *IJCNN International Joint Conference on Neural Networks*, v.1, p. 2200-2205, 2001.
- [6] Parker, J.R. *Algorithms for Image Processing and Computer Vision*. New York: Wiley Computer Publishing, 1997. 417 p.
- [7] Rosin, P. Unimodal Thresholding. *Pattern Recognition*, v. 34, n. 11, p. 2083-2096, November 2001.
- [8] Ma, Yi. Canny Edge Detector [online], April 1996. <<http://robotics.eecs.berkeley.edu/~mayi/imgproc/cacode.html>>. 989, 9(6), 8-27.