

Estudo de Detecção de Bordas em Imagens Usando Kernel

Bruna Cavallero Martins , Matheus Fuhman Stigger , Wemerson Delcio Parreira

Resumo— Este trabalho apresenta uma aplicação de funções kernel no problema de detecção de bordas em imagens. Em Support Vector Machines – SVM, os kernels são uma classe de medidas de similaridade. Assim, um algoritmo para detecção de bordas com análise pixel à pixel é proposto para dois kernels, o gaussiano e o polinomial. Os resultados das simulações são apresentados para exibir o seu desempenho. Os resultados foram considerados satisfatórios, considerando a escolha do kernel e do(s) parâmetro(s) do kernel.

Palavras-Chave— Detecção de bordas, kernel, processamento de imagens.

Abstract— This paper presents an application of the kernel functions in the image edge detection problem. In Support Vector Machines – SVM, the kernels are a measure similarity class. Thus, an algorithm for edge detection with pixel-to-pixel analysis is proposed for two kernels, the Gaussian and the Polynomial kernel. Simulation results are presented to show its performance. The results were considered satisfactory, given the choice of the kernel and the kernel parameter(s).

Keywords— Edge detection, kernel, image processing.

I. INTRODUÇÃO

Muitas aplicações práticas (por ex., visão computacional, engenharia biomédica) requerem um processo para detecção de bordas. Uma borda é o limite entre duas regiões com propriedades relativamente distintas de níveis de cinza [1]. Ao processo de localização e realce dos pixels de borda, aumentando o contraste entre a borda e o fundo, denomina-se Detecção de Bordas [1], [2]. Existem vários algoritmos para detecção de borda na literatura, como os operadores de Sobel, Prewitt e Roberts de primeira ordem; e Laplaciano e Laplaciano de Gaussiana dentre outros métodos de segunda ordem (ver em [1] e suas referências).

Este trabalho apresenta uma investigação que trata a detecção de bordas como uma filtragem no domínio espacial por uma operação “pixel a pixel”, avaliando as medidas de similaridade de um dado pixel e seus vizinhos. A medida de similaridade é realizada a partir de funções kernel. Essas funções oferecem estruturas gerais para representação de dados, que satisfazem algumas condições matemáticas úteis, gerando algoritmos com um grau maior de liberdade, podendo ser ajustados à aplicação [3], [4]. O objetivo deste trabalho não é estabelecer um comparativo entre as técnicas presentes na

literatura, mas investigar possíveis aplicações envolvendo os kernels.

A. As funções kernel

A ideia básica dos algoritmos baseados em kernels é transformar um dado \mathbf{x} do espaço de entrada em um vetor $\phi(\mathbf{x})$ pertencente a um espaço denominado Espaço das Características. Nesse espaço o produto interno pode ser calculado usando uma função kernel definida positiva que satisfaça a condição de Mercer [3]:

$$\kappa(\mathbf{x}, \mathbf{y}) = \langle \phi(\mathbf{x}), \phi(\mathbf{y}) \rangle$$

em que $\langle \cdot, \cdot \rangle$ denota o produto interno usual¹. Uma propriedade interessante do Espaço das Características é que o RKHS – Espaço Hilbertiano de Kernels Reprodutivos, o espaço gerado pelas funções $\{\kappa(\cdot, \mathbf{y}) : \mathbf{y} \in \mathcal{X}\}$, define um único funcional no espaço de Hilbert. Essa propriedade dá origem à propriedade reprodutiva dos kernels [3]. Outra propriedade importante é que dado um algoritmo o qual é formulado em termos de um kernel, pode-se construir um algoritmo alternativo trocando $\kappa(\cdot, \cdot)$ por um outro kernel $\tilde{\kappa}(\cdot, \cdot)$, esse é o “truque” do kernel [3]. Porém, não há indícios que essa alteração resulte em algoritmos com o mesmo desempenho [4]. Neste trabalho um algoritmo é proposto para detecção de bordas usando kernels, com o objetivo de estabelecer o(s) melhor(es) parâmetro(s) para a aplicação. Para isso duas funções kernels foram utilizadas, à saber, o kernel Gaussiano² e o kernel Polinomial.

1) O kernel Gaussiano [3]:

$$\kappa(\mathbf{x}, \mathbf{y}) = \exp\left(0,5 \|\mathbf{x} - \mathbf{y}\|^2 / \xi^2\right) \quad (1)$$

em que $\mathbf{x}, \mathbf{y} \in \mathcal{X}$, $\xi \in \mathbb{R}_+^*$ e $\|\cdot\|$ representa a Norma Euclidiana. O parâmetro ξ é denominado parâmetro do kernel Gaussiano ou *kernel bandwidth*.

2) O kernel Polinomial de γ -ésimo grau [3]:

$$\kappa(\mathbf{x}, \mathbf{y}) = \left(\alpha \mathbf{x}^\top \mathbf{y} + \beta\right)^\gamma \quad (2)$$

em que $\mathbf{x}, \mathbf{y} \in \mathcal{X}$, $\alpha \in \mathbb{R}^*$, $\beta \in \mathbb{R}$ e $\gamma \in \mathbb{N}^*$. Os parâmetros α, β e γ são os parâmetros de ajuste da função kernel Polinomial³.

Bruna C. Martins, Bolsista IC/CNPq. Curso de Eng. da Computação, Univ. Católica de Pelotas, Pelotas, Brasil. E-mail: cmbruna16@gmail.com.

Matheus F., Bolsista IC/FAPERGS. Curso de Eng. da Computação, Univ. Católica de Pelotas, Pelotas, Brasil. E-mail: matheustigger@outlook.com.

Wemerson Delcio Parreira, Centro Politécnico, Universidade Católica de Pelotas, Pelotas, Brasil. E-mail:wemerson.parreira@ucpel.edu.br.

¹Maiores detalhes em [5].

²Função classificada no grupo das funções de base radial (*Radial Based Function* - RBF).

³Neste caso o parâmetros α realizada um escalamento do mapeamento no Espaço das Características, β impõe um deslocamento desse mapeamento.

II. METODOLOGIA

Esta seção apresenta uma metodologia para detecção de bordas em imagens usando kernels. A análise da borda é feita a partir da medida de similaridade em um pixel de referência e seus vizinhos mais próximos, da seguinte maneira: Seja \mathbf{I} uma imagem qualquer, cujas intensidades de níveis de cinza estão associadas às componentes da matriz \mathbf{F} , denotada por $[\mathbf{F}]_{i,j}$. Fazendo $[\mathbf{F}]_{i,j}$ ser a intensidade de referência, e os vizinhos $[\mathbf{F}]_{i,(j+1)}$, $[\mathbf{F}]_{(i+1),j}$ e $[\mathbf{F}]_{(i+1),(j+1)}$. A matriz \mathbf{T} , cujas componentes representam os níveis de cinza de \mathbf{I} transformados pelo processo de detecção de bordas proposto, é dada por:

- 1) Escolhe-se uma função kernel e seu(s) respectivo(s) parâmetro(s).
- 2) Para cada pixel $[\mathbf{F}]_{i,j}$ calcula-se:

$$\begin{cases} \kappa_{cr} = \kappa([\mathbf{F}]_{i,j}, [\mathbf{F}]_{i,(j+1)}) \\ \kappa_{cb} = \kappa([\mathbf{F}]_{i,j}, [\mathbf{F}]_{(i+1),j}) \\ \kappa_{cbr} = \kappa([\mathbf{F}]_{i,j}, [\mathbf{F}]_{(i+1),(j+1)}) \end{cases} \quad (3)$$

- 3) Se $\min\{\kappa_{cr}, \kappa_{cb}, \kappa_{cbr}\} \geq \rho$, então $[\mathbf{T}]_{i,j} = 1$.
Caso contrário, $[\mathbf{T}]_{i,j} = [\mathbf{F}]_{i,j}$.

O parâmetro ρ é um parâmetro de limiarização e deverá ser escolhido empiricamente de acordo com o problema proposto. Na próxima seção serão apresentados os resultados obtidos com o algoritmo descrito nesta seção.

III. RESULTADOS

O problema tratado neste trabalho é o reconhecimento de bordas de uma placa de circuito integrado Fig. 1A [1]. Esse processo trata a imagem, num pré-processamento, para posteriormente ser realizado um processo de reconhecimento ou identificação dos componentes e de análise dos componentes conectados, por exemplo. A imagem analisada foi normalizada, para reduzir a variância das intensidades de níveis de cinza. A Fig. 1 apresenta alguns resultados a partir do kernel

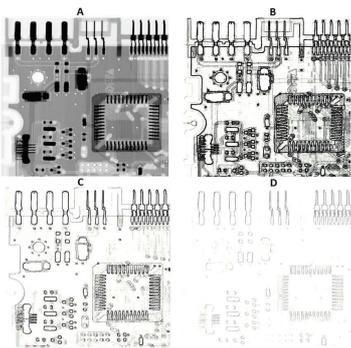


Fig. 1. Aplicação usando $\rho = 0,6$ e um kernel Gaussiano: (A) Imagem original [1], (B) com $\xi = 0,05$, (C) com $\xi = 0,15$ e (D) com $\xi = 0,5$.

Gaussiano (1) com $\xi \in \{0,05, 0,06, \dots, 0,5\}$. Nota-se que com $\xi = 0,05$, Fig. 1B, o processo não é tão eficiente, o que poderia comprometer um processo de identificação automática dos componentes, por exemplo. Usando $\xi = 0,5$, Fig. 1D, alguns detalhes da imagem foram perdidos, isso dificultaria um processo de identificação de conexão entre os componentes. Dentre os valores testados $\xi = 0,15$, Fig. 1C, apresentou o

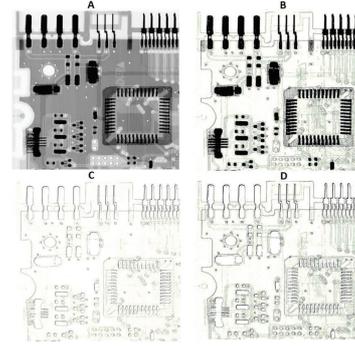


Fig. 2. Aplicação usando $\rho = 0,6$ e um kernel Polinomial: (A) Imagem original [1], (B) com $\alpha = 1, \beta = 0, \gamma = 2$, (C) com $\alpha = 1, \beta = 0,5, \gamma = 2$ e (D) com $\alpha = 1, \beta = 0,5, \gamma = 4$.

melhor resultado, foi possível detalhar os componentes sem perder as informações mais relevantes. A Fig. 2 apresenta alguns dos resultados obtidos para o kernel Polinomial (2), com $\beta \in \{0, 0,5\}$ e $\gamma \in \{1, 2, 3, 4\}$. Observa-se que se o parâmetro β é nulo, Fig. 2B, a detecção de borda falha. Comparando a Fig. 2C e Fig. 2D nota-se que aumentando o grau do polinômio, parâmetro γ , aumenta o nível de detalhamento da imagem. Dentre as funções testadas para este exemplo, mantendo o mesmo limiar, nota-se por inspeção visual que o kernel Polinomial destaca mais eficientemente as regiões de interesse que o Gaussiano. Porém, deve-se evitar o uso do kernel Polinomial homogêneo ($\beta = 0$).

IV. CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

A aplicação de kernels permite o realce da diferença entre um dado pixel e seus vizinhos mais próximos, detectando transições suaves ou abruptas, por ser ajustável à aplicação desejada. Esta pesquisa tratou de um processo para detecção de bordas usando as funções kernel Gaussiano e Polinomial. Considerando imagens desprovidas de ruídos aditivos os resultados foram satisfatórios.

Posteriormente, será realizada uma modificação no algoritmo para reduzir o número de operações, dado que a função kernel pode ser aplicada a dados vetoriais. Além disso, espera-se que a partir de uma análise prévia da imagem a escolha automática dos parâmetros de limiarização e do kernel seja possível.

AGRADECIMENTOS

Ao nosso orientador Prof. Dr. Wemerson Parreira, aos órgãos de fomento CNPq e FAPERGS e à Universidade Católica de Pelotas.

REFERÊNCIAS

- [1] GONZALEZ, Rafael C. WOODS, Richard E. *Digital Image Processing*, 3rd Edition. Prentice-Hall, Inc., NJ, USA, 2006.
- [2] SEARA, Daniela. "Algoritmos para detecção de bordas". UFSC, 1998. <http://www.inf.ufsc.br/~visao/1998/seara/index.html>. Acesso em 23 Mar. 2015
- [3] SCHÖLKOPF, Bernhard; SMOLA, Alexander J. *Learning with kernels*, The MIT Press, 2001.
- [4] PARREIRA, Wemerson D. "Comportamento Estocástico do Algoritmo Kernel Least-Mean-Square". Tese de Doutorado, UFSC, 2012.
- [5] KREYSZIG, Erwin. *Introductory Functional Analysis with Applications*, John Wiley & Sons, 1989.