Simpósio de Métodos Numéricos em Engenharia

25 a 27 de outubro, 2017

UFPR

Utilizando um algoritmo do tipo Simulated Annealing para resolver o problema de detecção de curvas em imagens

Emerson V. Castelani, Wesley V. I. Shirabayashi, Eduardo A. Neves, Daniela Borghi
Departamento de Matemática
Universidade Estadual de Maringá
Maringá-Pr, Brasil

Jair da Silva
Câmpus Avançado da Universidade Federal do Paraná
Universidade Federal do Paraná
Jandaia do Sul-Pr, Brasil

***Resumo*—Este trabalho apresenta um estudo sobre o problema de detecção de curvas em imagens. Essencialmente, apresentamos uma estratégia baseada em funções do tipo OVO (Odered Value Optimization) e no método Simulated Annealing utilizado para resolver problemas de otimização sem derivadas. Comparamos a nova técnica com a clássica Tranformada de Hough e com uma versão do Método de Gauss-Newton introduzido em [2].**

***Palavras-chave*—visão computacional; detecção de circunferências; Transformada de Hough; Gauss-Newton; Simulated Annealing.**

I. INTRODUÇÃO

O problema de detecção de curvas em imagens constitui uma classe primitiva porém muito relavante no campo da visão computacional, com importantes aplicações. Basicamente, este tipo de problema pode ser formulado da seguinte forma. Considere uma imagem binarizada, onde a quantidade pontos que representa esta imagem é dada por t. Neste caso, podemos associá-la a um conjunto de pontos do plano denotado por $Ib = \{(a_i, b_i) \in \mathbb{N} \times \mathbb{N}, i = 1, \cdots, t\}$. Suponha que se queira detectar uma curva definida por n parâmetros $x = (x_1, x_2, ..., x_n)$ representada por $\varphi(x_1, ..., x_n, a, b) = 0$, onde $\varphi : \mathbb{R}^n \times \mathbb{R}^2 \to \mathbb{R}$. A priori, φ pode descrever qualquer curva. Neste trabalho, por simplicidade, vamos considerar o caso em que φ é uma circunferência. Formalmente, pretendemos encontrar um subconjunto de pontos $FIb \subset Ib$ e parâmetros x_1, x_2, x_3 tais que $\forall (a, b) \in FIb$ tem-se $\varphi(x_1, x_2, x_3, a, b) = (a - x_1)^2 + (b - x_2)^2 - x_3^2 \approx 0$. Dentre as técnicas mais populares de resolução deste tipo de problema, destacamos a Transformada de Hough [5] e suas variações [4], [8], [9].

Uma outra técnica popular é o método RANSAC, proposto em [6]. Não tão conhecida como os citados aqui, mas apresentando resultados promissores é a abordagem tratada em [2], onde os autores exploram um modelo de otimização contínua baseado em funções ordenadas do tipo OVO [1] e propõem um novo modelo para resolver o problema de detecção de curvas em imagens utilizando uma adaptação do método de Gauss-Newton, muito comum na resolução de mínimos quadrados.

O principal problema da técnica apresentada em [2], reside no fato de que o algoritmo apresentado é propenso a encontrar soluções que, do ponto de vista de otimização, são minimizadores locais. Do ponto de vista prático, uma solução local pode não representar uma detecção adequada do objeto. Além disso, o modelo de otimização que os autores apresentam é contínuo mas não é diferenciável. Embora a última afirmação não represente grandes problemas práticos, é natural nos questionarmos sobre o uso de métodos de otimização que não dependem de derivadas e que têm tendências a obter minimizadores globais. É esta lacuna que este trabalho pretende preencher.

Para tanto, utilizamos o mesmo modelo apresentado em [2], mas com a proposta de resolução através do método probabilístico Simulated Annealing [3] e [7]. Foram gerados exemplos artificiais e estabelecemos uma comparação entre os métodos considerando robustez e tempo de processamento.

II. Metodologia e Resultados

Primeiramente, apresentaremos o modelo a ser considerado. Com efeito, para cada $i = 1, ..., t$ definimos a medida do erro do ponto $(a_i, b_i) \in Ib$ pertencer à curva definida pelo parâmetro x por $F_i(x_1, x_2, x_3) = ((a_i - x_1)^2 + (b_i - x_2)^2 - x_3^2)^2$. Seja $p \leq t$ a quantidade de pontos que representa uma detecção de circunferência. Para cada terna $x = (x_1, x_2, x_3)$ ordenamos o conjunto das imagens $F_i(x)$ de forma crescente:

$$F_{i_1(x)}(x) \leq F_{i_2(x)}(x) \leq ... \leq F_{i_t(x)}(x).$$

Ao considerar a soma dos p primeiros termos, definimos uma função $S_p(x) = \sum_{k=1}^{p} F_{i_k(x)}(x)$. Assim, ao encontrar o minimizador global do problema

$$\min_{x \in \mathbb{R}^3} S_p(x) = \min_{x \in \mathbb{R}^3} \sum_{k=1}^{p} F_{i_k(x)}(x). \quad (1)$$

estaremos encontrando (x_1, x_2, x_3) tal que, para p pontos da imagem, os desvios são mínimos. O problema (1) é um problema do tipo OVO introduzido em [2] e foi resolvido utilizando uma adaptação do método de Gauss-Newton. Para fins práticos, estaremos nos referindo a este método apenas por *GN-circle*.

Nossa proposta é motivada pelo uso do método híbrido proposto em [7] no contexto de funções OVO. Os passos fundamentais da nova proposta são dados pelo algoritmo seguinte.

Algoritmo 1 Simulated Annealing para detecção de circunferências.

1: Considere $(\bar{x}_1^i, \bar{x}_2^i), i = 1, ..., m$ aproximações iniciais para (x_1, x_2) e fixe $\bar{x}_3^i = r_0$, onde r_0 é um valor qualquer positivo.
2: Para cada $i = 1, ..., m$ faça
   - Utilize o método Simulated Anneling com ponto inicial $(\bar{x}_1^i, \bar{x}_2^i, \bar{x}_3^i)$;
   - Obtenha (x_1^i, x_2^i, x_3^i), a solução encontrada pelo método Simulated Annealing.

3: Encontre $(x_1, x_2, x_3) \in \arg\min_{i \in \{1,...,m\}} \{S_p(x_1^i, x_3^i, x_3^i)\}$

A solução encontrada pelo Algoritmo 1, corresponde à detecção de uma circunferência definida por p pontos. A implementação do método acima foi feita em linguagem Julia [1] e a implementação do método Simulated Annealing do passo 2 foi extraída do Pacote Optmin.jl [2] . Por simplicidade, estaremos nos referindo ao algoritmo acima por *SA-circle*.

Comparações massivas entre vários métodos para detecção de circunferência, foram estabelecidas em [2]. Por esta razão, expomos nossos resultados limitados aos métodos *GN-circle*, *SA-circle* e a Transformada de Hough (*HT*). Os testes que foram realizados englobam apenas simulações em imagens artificialmente geradas caracterizadas pela existência de *outliers* e ruídos. Foram gerados 25 exemplos. A Tabela I, expressa os resultados obtidos considerando percentual de problemas resolvidos (PR), o tempo (em segundos) de processamento médio (TM), o pior (PT) e melhor (MT) tempo de processamento entre todos os problemas testados.

[1] www.julialang.org

[2] https://github.com/JuliaNLSolvers/Optim.jl

Tabela I: Resultados dos testes.

Método	PR	TM	PT	MT
Simulated Ann.	100%	0.3302384	0.33959	0.32481
GN-circle.	92%	0.1052664	0.19157	0.02618
HT-circle	100%	0.4972621	0.61883	0.25495

III. Conclusões

O presente trabalho representa um estágio inicial de uma abordagem do problema de detecção de curvas utilizando métodos probabilísticos. Neste sentido, estabelecemos um algoritmo baseado no método Simulated Annealing pois este se caracteriza por ser mais tendencioso a encontrar pontos que são minimizadores globais. Além disso, o uso deste tipo de método não depende de derivadas o que se adequa bastante ao problema proposto. Nos testes computacionais, a nova abordagem é promissora. De fato, todos os problemas foram resolvidos e com tempo de processamento moderado. Destacamos ainda, que o método apresentado em [2] foi o que consumiu o menor tempo, porém foi que resolveu menos problemas. Isto deve-se a tendência em parar em pontos estacionários que não são minimizadores globais.

Agradecimentos

À Universidade Estadual de Maringá e à Universidade Federal do Paraná pelo apoio à pesquisa. Ao revisor do presente trabalho, pelas construtivas sugestões.

Referências

[1] R. Andreani, C. Dunder, and J. M. Martínez. Nonlinear-programming reformulation of the order-value optimization problem. *Mathematical Methods of Operations Research*, 61(3):365–384, 2005.

[2] Roberto Andreani, Giovani Cesar, José Mario Martínez, and Paulo J. S. Silva. Efficient curve detection using a Gauss-Newton method with applications in agriculture. *1st International Workshop on Computer Vision Applications for Developing Regions in Conjunction with ICCV 2007*, pages 1–13, 2007.

[3] Dimitris Bertsimas, John Tsitsiklis, et al. Simulated annealing. *Statistical science*, 8(1):10–15, 1993.

[4] Opas Chutatape and Linfeng Guo. A modified Hough transform for line detection and its performance. *Pattern Recognition*, 32(2):181–192, 1999.

[5] R O Duda and P E Hart. Use of the Hough transform to detect lines and curves in pictures. *Communications of the Association Computing Machinery*, 15(1), 1972.

[6] M. A. Fischler and R. C. Bolles. Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography. *Communications of ACM*, 24:381–395, 1981.

[7] Gabriel Haeser and M Gomes Ruggiero. Aspectos teóricos de simulated annealing e um algoritmo duas fases em otimização global. *Trends in Applied and Computational Mathematics*, 9(3):395–404, 2008.

[8] Chun-ta Ho and Ling-Hwei Chen. A high-speed algorithm for line detection. *Pattern Recognition Letters*, 17(5):467–473, 1996.

[9] J. Illingworth and J. Kittler. A survey of the hough transform. *Computer Vision, Graphics, and Image Processing*, 44(1):87–116, 1988.