

Detecção e Classificação de Tipos de Pólipos Colorretais Utilizando Técnicas de Processamento de Imagens

Fábio Rezende de Souza *, Francisco de Assis Zampirolli *

*Universidade Federal do ABC, Santo André, SP, Brasil
fabio.rezende@ufabc.edu.br, fzampirolli@ufabc.edu.br

Abstract - This paper presents a semi-automatic approach for segmentation of colorectal polyps based on the Watershed algorithm, and a polyp classification scheme based on its shape (flat or peduncular), using Support Vector Machines (SVMs). Specifically, our method is composed by four main steps: given a colonoscopy frame, the first step consists in applying filters for noise removal and edge enhancement on a grayscale version of the original image. The second step consists in applying a marker-controlled Watershed segmentation. The third step consists in calculating topological and statistical measures over both the grayscale images and its correspondent binary polyp masks. Those measures are used in the fourth and final step for training the SVMs on polyp shape classification. The supervised learning method we adopted correctly classified 93,75 % of the polyp shapes from this database using gold-standard binary polyp masks, and 90 % of the polyp shapes using the binary polyp masks obtained from our Watershed segmentation approach.

Palavras-chave: Colorectal Cancer, Polyp Detection, Image Processing, Watershed..

Introdução

O câncer colorretal corresponde ao segundo tipo de câncer com maior grau de incidência no mundo e estima-se que no Brasil surjam cerca de 34.000 novos casos a cada ano [1]. O exame de colonoscopia consiste na principal forma de detecção e prevenção deste tipo de câncer, por permitir a identificação de pólipos cancerígenos em sua fase inicial. Pacientes diagnosticados precocemente podem aumentar a chance de cura em até 80 % [2].

Um pólipo colonoscópico consiste em uma massa de tecido protuberante relativamente à cavidade interna do cólon [3], e pode ser classificado como *não-neoplásico* ou *neoplásico*: a primeira categoria correspondendo a lesões benignas de menor potencial cancerígeno, e a segunda aos pólipos que podem evoluir para o câncer do tipo *carcinoma*. Existem diferentes tipos de pólipos *neoplásicos*, como *adenomas*, *adenocarcinomas* e *serrilhados* [3]. Os pólipos *serrilhados* podem ser identificados durante o exame de colonoscopia de acordo com o seu formato, como *sésseis* (estruturas plano-elevadas) ou *pediculadas* (ver Figura 1). Estudos comprovam a relação entre pólipos serrilhados e risco de desenvolvimento de câncer [4] [5]; além disso, caso se faça necessária a remoção cirúrgica destes, cada tipo de pólipo podem vir a requerer métodos de diferentes graus de complexidade e eficácia - reforçando a necessidade do conhecimento de sua anatomia [6].

Diferentes abordagens já foram propostas na literatura para a resolução deste problema, como a busca automatizada por formatos semelhantes ao pólipo [7], e ainda a utilização de informações de formato e contexto [8]. No entanto, o resultado obtido por estes trabalhos não se mostraram universalmente aplicáveis, sendo uma área de pesquisa ainda em desenvolvimento, onde a proposição de



Figura 1 – Exemplo dos dois tipos de pólipo considerados: pediculado, à esquerda, e sésseil, à direita.

novas técnicas pode vir a otimizar as idéias anteriormente propostas sobre o tema e estimular novos estudos na área.

Este artigo tem como objetivo propôr um método para segmentação semi-automática e classificação de pólipos em imagens colonoscópicas, de acordo com suas respectivas estruturas anatômicas. Além disso, serão propostas medidas (topológicas e estatísticas) para o desenvolvimento de um modelo de aprendizado supervisionado de classificação de pólipos intestinais. Além disso, as segmentações realizadas serão comparadas às segmentações *gold-standard* fornecidas por especialistas, em relação ao desempenho como parâmetros de classificação de pólipos coloscópicos em relação aos seus respectivos formatos anatômicos.

Materiais e Métodos

Base de Dados

Foi utilizada a base de dados pública *CVC-ColonDB*, disponibilizada por [9], que contém 380 *frames* de colonoscopia onde pólipos são detectados, selecionados a partir de 15 diferentes vídeos. Esta base de dados também inclui imagens binárias correspondentes a cada *frame*, onde o contorno de cada pólipo é explicitado. Tais imagens serviram como parâmetro de comparação para o resultado final do processo de segmentação aqui apresentado (ver Figura 2). Bernal *et. al.* [9] apresenta uma classificação dos dois tipos de pólipos presentes na base de dados *CVC-ColonDB* em *Flat* (Sésseil), ou *Peduncular* (Pediculada).



Figura 2 – Exemplo de imagem de pólipo disponível na base de dados CVC-ColonDB. À esquerda, imagem original, ao centro e à direita, imagens binárias destacando o contorno do pólipo.

Método

O método de segmentação e classificação dos pólipos colonoscópicos a partir de *frames* retirados de exames de

colonoscopia a ser apresentado consiste em um procedimento semi-automático, dividido em quatro etapas centrais: aplicação de filtros sobre a imagem, segmentação do pólipo, cálculo de medidas topológicas e classificação do tipo de pólipo correspondente. Uma descrição geral deste método pode ser observado na Figura 3. Foi desenvolvida uma ferramenta *CAD* para a aplicação deste método.



Figura 3 – Fluxograma explicitando o funcionamento do método desenvolvido.

Aplicação de Filtros

Neste trabalho, a aplicação de filtros morfológicos foi realizada com duas finalidades: aprimorar a imagem pela eliminação de ruídos de diferentes naturezas (devido ao instrumento de captação ou à presença de dejetos eventualmente presentes no cólon intestinal), e realce das bordas da imagem, de maneira a melhorar, em uma etapa subsequente, a performance da aplicação do *Watershed* na segmentação do pólipo. Para a eliminação de ruídos, foram selecionados os filtros *Area Open*, *ASF*, *Flat Zones* e *Close Holes* [10]. Para o realce das bordas das imagens, foram utilizados os algoritmos de detecção de bordas de *Canny* e *Sobel*. Estes algoritmos apresentam, como dados de saída, imagens binárias ressaltando as bordas das imagens de entrada. Tais imagens binárias são somadas às originais, realçando o contorno dos objetos a serem segmentados (os pólipos) e eventualmente melhorando a eficiência do algoritmo de segmentação *Watershed*.

Segmentação

O procedimento de segmentação consiste na aplicação do algoritmo de *Watershed*. O algoritmo de *Watershed*, inicialmente proposto por [11], trata-se de uma ferramenta clássica de Morfologia Matemática. Consiste em uma abstração da imagem em níveis de cinza como uma região topográfica. O *Watershed* pode ser descrito como a inundação do relevo desta região topográfica, a partir de marcadores apontados sobre a imagem. Diferentes marcadores podem ser fornecidos, cada um deles originando uma bacia hidrográfica cujos limites consistem nos mínimos locais em torno dos quais um marcador foi aplicado. Os três parâmetros de entrada do *Watershed* são a imagem de entrada f , usualmente um gradiente, uma imagem m contendo os marcadores, e a conectividade, definida por um elemento estruturante, representado por D . O *Watershed* é dado pela Equação 1:

$$WS_D(f, m) = SM_D(fR_{minD}(f)) \quad (1)$$

Neste trabalho, aplica-se o *Watershed* tomando como parâmetros iniciais um marcador externo (delimitando a região de interesse, em torno do pólipo), e um marcador interno à superfície do pólipo, a partir do qual inicia-se o processo de inundação, finalizado ao serem encontrados mínimos locais, correspondentes aos limites das bordas visíveis do pólipo em questão. Um marcador interno é automaticamente sugerido como o ponto central do marcador definido como região de interesse. Caso a segmentação obtida não seja satisfatória, o marcador interno pode ser substituído

por outro definido pelo usuário. A qualidade da segmentação varia conforme a aplicação de filtros de remoção de ruídos e realce de bordas, realizado na etapa anterior. A Figura 4 demonstra dois exemplos de marcação.

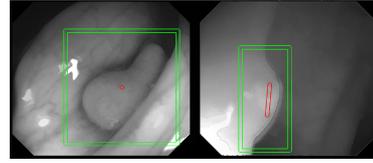


Figura 4 – Exemplos de marcadores aplicados. À esquerda, marcador interno definido automaticamente, à direita um marcador interno definido manualmente pelo usuário.

Realizada a segmentação, serão registradas a imagem original, no formato *.tiff*, os marcadores aplicados e o rótulo da imagem segmentada, sendo estas duas últimas imagens binárias, no formato *.gif*. A Figura 5 exemplifica tais imagens resultantes.

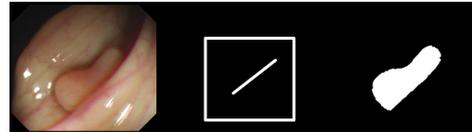


Figura 5 – Imagens salvas na base de dados após a segmentação. Da esquerda para a direita: imagem original, marcadores utilizados e segmentação obtida.

Cálculo de Medidas

O próximo passo consiste no cálculo de medidas relativas a cada pólipo, a serem utilizadas como modelo de aprendizado supervisionado para classificação dos dois diferentes tipos de pólipos (*flat* ou *peduncular*). As medidas topológicas relativas ao pólipos segmentado consistem em uma adaptação das adotadas em [12] no contexto das células epiteliais e adiposas. Além destas medidas, foram adicionados outros dois atributos estatísticos, o desvio padrão e a média da intensidade dos *pixels* da região segmentada na versão em níveis de cinza da imagem original.

Foram calculadas as seguintes medidas:

- *Perimeter* = distância ao redor da margem do pólipo;
- *Area* = número de *pixels* correspondentes ao pólipos;
- *MajorAxisLength* = maior eixo da elipse contendo o pólipos;
- *MinorAxisLength* = menor eixo da elipse contendo o pólipos;
- *Orientation* = ângulo entre o eixo x (horizontal) e o maior eixo da elipse que contém o pólipos;
- *ConvexArea* = área da região convexa dos pólipos;
- *Eccentricity* = razão entre a distância focal e o maior eixo da elipse;
- *EquivDiameter* = diâmetro de um círculo com a mesma área que o pólipos;
- *Extent* = razão entre os *pixels* do pólipos e os *pixels* da região delimitante;
- *Solidity* = $Area/ConvexArea$;
- $FormFactor = \frac{4 * \pi * Area}{Perimeter^2}$;
- $Roundness = \frac{4 * Area}{\pi * MajorAxisLength^2}$;
- $AspectRatio = \frac{MajorAxisLength}{MinorAxisLength}$;

- $Convexity = \frac{ConvexPerimeter}{Perimeter}$;
- $StandardDeviation = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2}$;
- $MeanPixelValue = \bar{x}$;

Os atributos topológicos foram calculados a partir das propriedades de região dos rótulos binários resultantes da segmentação. Os atributos estatísticos foram calculados a partir da sobreposição da imagem de rótulo (binárias, composta por valores de intensidade 0(preto) e 255(branco)), e da imagem original em níveis de cinza (com intensidades entre 0 e 255), obtida através da obtenção de valor mínimo entre as duas. A Figura 6 demonstra a composição da imagem a partir da qual os atributos estatísticos foram calculados.

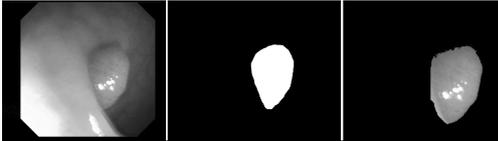


Figura 6 – Da esquerda para direita: imagem original, resultado da segmentação da imagem e sobreposição das imagens anteriores. A sobreposição foi realizada, neste caso, tomando os *pixels* de menor intensidade entre as duas imagens.

Classificação

A classificação foi realizada através do algoritmo de *Support Vector Machines* (SVM), conforme implementação fornecida pela Ferramenta WEKA [13]. Para o uso dessa técnica no âmbito de problemas de classificação, um conjunto de dados supervisionados deve ser fornecido. No caso da detecção dos tipos de pólipos, os dados de entrada são compostos por pares de exemplos da forma (\mathbf{x}_i, y_i) , onde \mathbf{x}_i , com $\mathbf{x}_i \in \mathfrak{R}^m$ corresponde ao valor do conjunto m de medidas calculadas sobre cada *frame*, e $y_i \in \{-1, +1\}$, correspondendo ao seu respectivo rótulo *flat* ou *peduncular*. SVMs irão procurar por um hiperplano ($\mathbf{w} \cdot \mathbf{x} + b = 0$) capaz de separar os dados com uma margem máxima. Para realizar esta tarefa, deve-se resolver o seguinte problema de otimização [14] [12]:

$$\begin{aligned} \text{Minimizar: } & \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \\ \text{Sujeito a: } & \begin{cases} \xi_i \geq 0 \\ y_i (\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - \xi_i \end{cases} \end{aligned}$$

onde C é uma constante de complexidade e ξ_i correspondem às variáveis de folga.

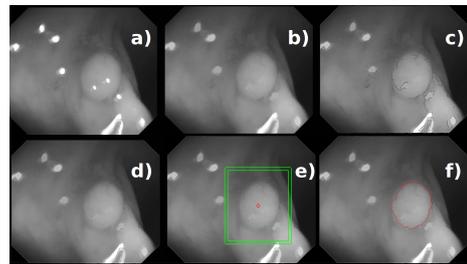
A borda de decisão obtida para a classificações dos novos dados é dada por:

$$f(\mathbf{x}) = \sum_{\mathbf{x}_i \in \text{SV}} y_i \alpha_i \mathbf{x}_i \cdot \mathbf{x} + b, \quad (2)$$

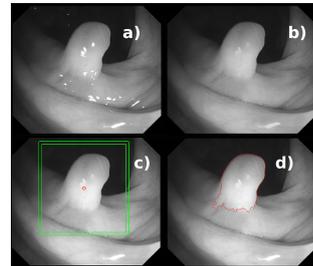
onde as constantes α_i são multiplicadores Lagrangeanos determinados no procedimento de otimização. SV corresponde ao conjunto de vetores de suporte (SVs), nos quais os multiplicadores de Lagrange são maiores do que zero, sendo os demais descartados. Estes dados serão aqueles mais próximos do hiperplano ótimo. De maneira a obter a classificação final utilizando a Equação 2, uma função de sinal é aplicada a $f(\mathbf{x})$, tal que, se $f(\mathbf{x}) > 0$, a classe de predição será +1 e se $f(\mathbf{x}) < 0$, será -1 [12].

Resultados e Discussão

Foram selecionados 80 *frames* da base de dados *CVC-ColonDB* buscando uma distribuição uniforme em dois grupos de igual tamanho (40 do tipo *flat* e 40 do tipo *peduncular*), priorizando imagens onde os pólipos possuíssem ao menos uma de suas facetas completamente visíveis (isto é, que não se encontrasse parcialmente ocultado pelas bordas da imagem), para evitar a ocorrência de contornos de segmentação que não representassem o contorno natural do pólipo, prejudicando o cálculo de medidas topológicas. As imagens binárias explicitando o contorno do pólipo presente em cada imagem, fornecidas pela base de dados foram tomadas como o *gold-standard* de segmentação, para efeitos de comparação com a segmentação obtida através do método desenvolvido. A Figura 7 demonstra alguns exemplos do passo-a-passo do processo de aplicação de filtros e marcadores, bem como a segmentação obtida.



(a) a) Gray Scale, b) Area Open, c) Canny, d) Flat zones, e) Marcadores finais definidos f) Imagem final segmentada.



(b) a) Gray Scale, b) Area Open c) Marcadores finais definidos, d) Imagem final segmentada.

Figura 7 – Exemplos de resultados de segmentação obtidos

Resultados de Classificação

O relatório de execução do WEKA [13] apontou a classificação correta de 93,75 % dos 80 *frames* selecionados, utilizando-se *cross-validation* de 10 *foldds*. Como atributos mais expressivos de classificação foram apontados, respectivamente, o perímetro, a área, o desvio padrão e a média. A matriz de confusão pode ser observada na Tabela 1.

Tabela 1 – Matriz de Confusão da classificação da base de dados com o *gold-standard* de segmentação.

Real(R)/Previsto(P)	Flat (P)	Peduncular (P)
Flat (R)	38	2
Peduncular (R)	3	37

Este mesmo conjunto de imagens foi segmentado manualmente através da ferramenta *CAD* desenvolvida aplicando o método descrito na Seção . O resultado observado foi de 90 % de classificações corretas, utilizando-se *cross-validation* de 10 *folde*s. A matriz de confusão pode ser observada na Tabela 2.

Tabela 2 – Matriz de Confusão para a base de dados segmentada pelo método desenvolvido.

Real(R)/Previsto(P)	Flat (P)	Peduncular (P)
Flat (R)	37	3
Peduncular (R)	5	35

Discussão

Os atributos de área e perímetro dos rótulos binários dos pólipos e as medidas estatísticas de intensidade dos *pixels* (Média e Desvio Padrão) nos *frames* em tons de cinza foram responsáveis pela maior parte de classificações corretas. Pode-se atribuir a eficiência da classificação segundo os atributos de área e perímetro ao fato de que o tamanho médio dos pólipos do tipo *peduncular* ser relativamente maior em relação aos pólipos do tipo *flat*. No entanto, tais atributos não podem ser levados em conta isoladamente, considerando que o instrumento de captação das imagens aqui estudadas não traz informação sobre as dimensões reais dos pólipos apresentados. Quanto à média e o desvio-padrão, a eficiência de tais atributos pode ser justificada pelo fato de que os *pixels* correspondentes ao contorno dos pólipos do tipo *peduncular*, em sua maioria, possuem baixa intensidade (mais escuros), em contraste à intensidade dos *pixels* de suas regiões interiores. Além disso, a maior irregularidade da estrutura dos pólipos do tipo *peduncular* possibilitam que exista maior variabilidade no espectro da intensidade dos *pixels* em relação aos pólipos do tipo *flat*. O uso de *SVMs* mostrou-se bem sucedido em classificar instâncias desconhecidas de pólipos segundo suas respectivas estruturas anatômicas.

Conclusões

Foi proposto um método para segmentação semi-automática de *frames* retirados de exames de colonoscopia, bem como um modelo para classificação de pólipos de acordo com as suas respectivas estruturas anatômicas. O modelo de classificação desenvolvido, cujos argumentos de entrada correspondem a medidas topológicas e estatísticas calculadas sobre as imagens originais e segmentadas, classificou corretamente 93,75% dos pólipos através das segmentações *gold-standard* e 90% através das segmentações realizadas pelo *Watershed*, indicando a eficiência do método de segmentação semi-automática em reproduzir os resultados produzidos por especialistas. A necessidade de intervenção humana na aplicação de marcadores e rotulação dos tipos de pólipos, no entanto, tornam o método aqui desenvolvido de caráter experimental, que visou testar a qualidade dos algoritmo de segmentação e classificação sobre imagens de colonoscopia, e de alguma forma estimular trabalhos futuros em detecção de pólipos através de técnicas de processamento de imagens.

Agradecimentos

Agradecimento ao Prof. Dr. Jianming Liang, filiado ao *Department of Biomedical Informatics* da *Arizona State Uni-*

versity pela colaboração na seleção do tema deste projeto e sugestão de artigos de referência, e à Dra. Márcia Ito, filiada à *IBM Research Brazil*, pela leitura e revisão deste presente trabalho.

Referências

- [1] INCA, “Tipos de câncer: Colorretal,” *Instituto Nacional de Câncer José Gomes da Silva*, 2015.
- [2] J. C. Van Rijn, J. B. Reitsma, J. Stoker, P. M. Bossuyt, S. J. van Deventer, and E. Dekker, “Polyp miss rate determined by tandem colonoscopy: a systematic review,” *The American journal of gastroenterology*, vol. 101, no. 2, pp. 343–350, 2006.
- [3] M. Elizabeth N. Kuhn and M. Anil Rustgi, “All about colon polyps,” *The Abramson Cancer Center of the University of Pennsylvania*, 2014.
- [4] R. M. Summers, “Polyp size measurement at ct colonography: What do we know and what do we need to know? 1,” *Radiology*, vol. 255, no. 3, pp. 707–720, 2010.
- [5] M. J. O’Brien, S. J. Winawer, A. G. Zauber, M. T. Bushey, S. S. Sternberg, L. S. Gottlieb, J. H. Bond, J. D. Wayne, M. Schapiro, and N. P. S. Workgroup, “Flat adenomas in the national polyp study: is there increased risk for high-grade dysplasia initially or during surveillance?,” *Clinical Gastroenterology and Hepatology*, vol. 2, no. 10, pp. 905–911, 2004.
- [6] L. Bujanda, A. Cosme, I. Gil, and J. I. Arenas-Mirave, “Malignant colorectal polyps,” *World journal of gastroenterology: WJG*, vol. 16, no. 25, p. 3103, 2010.
- [7] S. Hwang, J. Oh, W. Tavanapong, J. Wong, and P. C. De Groen, “Polyp detection in colonoscopy video using elliptical shape feature,” in *Image Processing, 2007. ICIIP 2007. IEEE International Conference on*, vol. 2, pp. II–465, IEEE, 2007.
- [8] N. Tajbakhsh, S. Gurudu, and J. Liang, “Automated polyp detection in colonoscopy videos using shape and context information,” 2015.
- [9] J. Bernal, J. Sánchez, and F. Vilariño, *Towards automatic polyp detection with a polyp appearance model.*, vol. 45. Pattern Recognition, 2012.
- [10] E. R. Dougherty, R. A. Lotufo, and T. I. S. for Optical Engineering SPIE, *Hands-on morphological image processing*, vol. 71. SPIE Optical Engineering Press Washington, 2003.
- [11] F. Meyer and S. Beucher, “Morphological segmentation,” *Journal of visual communication and image representation*, vol. 1, no. 1, pp. 21–46, 1990.
- [12] F. d. A. Zampiroli, B. Stransky, A. C. Lorena, and F. L. de Melo Paulon, “Segmentation and classification of histological images-application of graph analysis and machine learning methods,” in *Graphics, Patterns and Images (SIBGRAPI), 2010 23rd SIBGRAPI Conference on*, pp. 331–338, IEEE, 2010.
- [13] I. H. Witten and E. Frank, *Data Mining: Practical machine learning tools and techniques*. Morgan Kaufmann, 2005.
- [14] N. Cristianini, Shawe-Taylor, and E. J., *An introduction to Support Vector Machines and other kernel-based learning methods*. Cambridge University Press, 2000.