

# Seleção de Características Baseadas em Textura para a Identificação de Anormalidades em Imagens de Colonoscopia

Carlos Andres Ferrero<sup>1</sup>, Huei Diana Lee<sup>2</sup>, Wu Feng Chung<sup>3</sup>, Cláudio Sady Rodrigues Coy<sup>4</sup>, João José Fagundes<sup>5</sup>, Juvenal Ricardo Navarro Góes<sup>6</sup>

<sup>1,2,3</sup>Laboratório de Bioinformática — LABI,  
Universidade Estadual do Oeste do Paraná — UNIOESTE, Brasil  
<sup>3,4,5,6</sup>Serviço de Coloproctologia da Faculdade de Ciências Médicas — FCM,  
Universidade Estadual de Campinas — UNICAMP, Brasil

**Resumo** — O desenvolvimento tecnológico tem promovido o aumento das bases de dados em hospitais e clínicas médicas. Essas bases de dados são compostas principalmente por resultados de exames complementares e laboratoriais. Nos exames complementares, o registro dos resultados de exames em imagens têm incentivado o estudo e o desenvolvimento de ferramentas que auxiliem na identificação de padrões nessas imagens, por exemplo, por meio da extração de características. Entre os diversos tipos de características aplicadas, as baseadas em textura, têm sido amplamente utilizadas para a identificação de diferenças de padrões em imagens médicas. Em razão disso, neste trabalho é apresentado um estudo, utilizando um conjunto de imagens artificiais, para a seleção de características baseadas em textura. A análise dos resultados mostrou que três das 11 características consideradas, apresentaram comportamento estável em função dos ângulos visuais considerados, permitindo também diferenciar as texturas no conjunto de imagens utilizado.

**Palavras-chave:** Bioinformática, Cólon, Reconhecimento de Padrões, Análise de Textura, Matriz de Co-ocorrência.

**Abstract** — Technological advances have permitted the fast increasing of the databases in hospitals and medical clinics, which are compounded mainly by results from various exams. The recording of these results using images and the volume of data generated from these records have stimulated the study and the development of tools that help on the identification of patterns in these images, using for example extraction of characteristics. Among the many types of characteristics, the ones based on texture, which allow the description of important aspects of the image based on the gray's level distribution, have been used to identify diseases in medical images. In this work, it is presented a study of the behavior of texture-based characteristics using a set of artificial images. The analysis of the results showed that three of the total of 11 considered characteristics presented a stable behavior related to different visual angles, thus permitting also the differentiation between the textures in this image set.

**Key-words:** Bioinformatics, Colon, Pattern Recognition, Texture Analysis, Co-occurrence Matrix.

## Introdução

A utilização de sistemas de gerenciamento de dados, nas diversas áreas de conhecimento, tem permitido o acúmulo de informações e o crescimento de repositórios de dados multimídia (vídeo, imagens e texto). Decorrente desse grande volume de dados surgiu a necessidade do desenvolvimento de ferramentas para a recuperação imagens médicas, por meio da execução de consultas.

Nesse contexto, a Recuperação de Imagem Baseada em Conteúdo (*Content-Based Image Retrieval* — CBIR) é um dos recursos que pode auxiliar nessa tarefa, a qual consiste na utilização de características visuais intrínsecas das imagens, como cor,

forma e textura para caracterizá-las e, desse modo, organizá-las e recuperá-las.

Métodos de CBIR têm sido propostos e amplamente utilizados na caracterização de imagens de diversas áreas [1, 2, 3, 4]. Em um ambiente médico é relevante a diversidade e a quantidade de informações que podem ser produzidas ao longo de tratamentos e acompanhamento do paciente. Esses dados, encontram-se, freqüentemente, no formato de laudos textuais, contendo informações gerais sobre o paciente, bem como no formato de imagens, resultantes de exames realizados pelo especialista [5]. Por esse motivo torna-se necessária a aplicação de métodos de CBIR para organizar e recuperar essas informações, a partir do conteúdo pictórico da ima-

gem, o qual poderá auxiliar especialistas no processo de tomada de decisões.

Uma das doenças de maior ocorrência no Brasil é o câncer colorretal que, segundo o Instituto Nacional do Câncer, constitui a quarta maior incidência entre todos os tumores malignos, independentemente do sexo. A taxa de mortalidade em neoplasias do intestino grosso também ocupam o quarto lugar, ocorrendo em menor frequência apenas em relação aos tumores de pulmão, de estômago e de mama [6]. Atualmente, no Serviço de Coloproctologia da Universidade Estadual de Campinas — UNICAMP —, são coletadas mais de 200 imagens por mês relacionadas a exames de colonoscopia. Esse exame endoscópico é imprescindível para o diagnóstico de doenças do intestino grosso [7]. Desse modo, torna-se necessário o desenvolvimento de métodos e ferramentas que possam auxiliar na detecção e em processos de tomada de decisões associados a anormalidades detectadas por meio do exame de colonoscopia.

Neste trabalho, foi realizado um estudo, utilizando imagens modeladas computacionalmente, para a análise do comportamento de características que poderiam ser utilizadas na classificação de anormalidades histológicas ou lesões detectadas em imagens de colonoscopia. Esse estudo constitui parte do projeto de Análise de Imagens Médicas, o qual está sendo desenvolvido em uma parceria entre o Laboratório de Bioinformática — LABI — da Universidade Estadual do Oeste do Paraná — UNIOESTE — e o Serviço de Coloproctologia da Faculdade de Ciências Médicas da UNICAMP.

## Materiais e Métodos

As imagens utilizadas neste trabalho representam tipos de anormalidades considerando duas texturas diferentes a partir de diversos ângulos de visão. Por meio do aplicativo POV-RAY<sup>1</sup>, de utilização gratuita, é possível a modelagem de cenas a partir de objetos geométricos, luzes e câmeras. O aplicativo também permite a modelagem de objetos por meio da combinação de figuras geométricas primitivas, como esferas, cilindros e cubos, associadas por alguma operação, como junção e intersecção. Além disso, é possível aplicar texturas aos objetos modelados.

Para a representação dos tipos de anormalidades foram consideradas as estruturas côncava, convexa e plana, representando anormalidades histológicas do tipo ulcerada, polipóide e plana, respectivamente [6, 7, 8]. Sobre essas estruturas, foram aplicadas as

texturas: *Gray(20%)* e *Oilslick*, apresentadas na Figura 1, as quais estão disponíveis no aplicativo Macromedia Fireworks<sup>2</sup> e são denominadas, neste trabalho, como  $T_1$  e  $T_2$ , respectivamente.



(a) Textura  $T_1$ . (b) Textura  $T_2$ .

**Figura 1:** Texturas aplicadas às estruturas.

Por meio da aplicação das texturas  $T_1$  e  $T_2$  em cada uma das estruturas (côncava, convexa e plana) originaram-se seis classes de imagens. Essas imagens foram produzidas utilizando um foco de luz e uma câmera, sendo o foco de luz posicionado acima da câmera e, ambas, focando a estrutura que representa a anormalidade. Assim, o conjunto câmera e foco de luz, assumem diversos valores de localização e angulação. Para cada uma das classes foram produzidas imagens com uma distância de cinco centímetros e ângulos de  $-45$ ,  $-30$ ,  $0$ ,  $30$  e  $45$  graus em relação à estrutura. Desse modo, o Conjunto de Imagens — CI — foi composto de 30 imagens.

No contexto de CBIR, imagens são representadas por um conjunto de características denominado Vetor de Características — VC —, o qual é extraído a partir de características contidas na imagem. Esse VC possibilita a recuperação de imagens semelhantes da Base de Dados — BD — por meio da comparação entre os atributos<sup>3</sup> da imagem e os contidos na BD, utilizando medidas de similaridade. De modo geral, essas características intrínsecas da imagem, podem ser baseadas na cor, na forma ou na textura da imagem.

## Extração de Características

Neste trabalho foram utilizados atributos baseados em textura, os quais constituem um aspecto importante da percepção visual humana. Esses atributos permitem obter informações sobre propriedades de disposição e espaço dos principais elementos da imagem, por exemplo, os níveis de cinza que a compõem [1, 2, 3, 5].


Usualmente, atributos relacionados à textura consistem na análise de um conjunto de matrizes de co-ocorrência. Nessas matrizes, as linhas e as colunas representam o intervalo de níveis de cinza e

<sup>1</sup><http://www.povray.org/>

<sup>2</sup><http://www.macromedia.com/>

<sup>3</sup>Neste trabalho, os termos atributo e característica são utilizados indistintamente.

o valor  $P(i,j)$  corresponde ao elemento da matriz na posição  $(i,j)$ , o qual representa a freqüência de níveis de cinza  $i$  e  $j$  considerando uma distância e uma direção. Na Figura 2 é representada uma imagem com três níveis de cinza e a sua matriz de co-ocorrência correspondente, sendo consideradas uma direção de  $0^\circ$  e uma distância de um.



**Figura 2:** Imagem representada em três níveis de cinza como uma matriz de pixels 5x5 e a respectiva matriz de co-ocorrência para a direção  $0^\circ$  e a distância um [4].

Na posição  $(0,1)$  da matriz de co-ocorrência encontra-se o valor  $P(0,1) = 8$ . Esse valor é obtido do seguinte modo: o valor  $P(0,1)$  da matriz de co-ocorrência é incrementado em uma unidade, se o valor do elemento adjacente à esquerda ou à direita for igual a 1, para cada elemento da matriz da imagem com valor 0. Diversos atributos de textura foram propostos na literatura [1], utilizando valores calculados a partir da matriz de co-ocorrência, apresentados na Tabela 1, na qual  $R$  corresponde à quantidade de elementos que compõem a matriz e  $\sum_i$  e  $\sum_j$  equivalem a  $\sum_{i=1}^{N_g}$  e  $\sum_{j=1}^{N_g}$ , respectivamente.

Tabela 1: Valores calculados a partir da matriz de co-ocorrência.

Valores Calculados	
$p(i,j)$	Elemento $(i,j)$ normalizado, $P(i,j)/R$ .
$p_x(i)$	Soma dos valores da $i$ -ésima linha, $\sum_j p(i,j)$ .
$p_y(j)$	Soma dos valores da $j$ -ésima coluna, $\sum_i p(i,j)$ .
$N_g$	Número de níveis de cinza que compõem a imagem.
$p_{(x+y)}(k)$	$\sum_i \sum_j p(i,j)$ , se $i + j = k$ .
$p_{(x-y)}(k)$	$\sum_i \sum_j p(i,j)$ , se $ i - j  = k$ .

Essas características propostas em [1] são apresentadas a seguir:

**Segundo Momento Angular:** essa medida corresponde à homogeneidade da imagem. Em uma imagem homogênea existem poucas transições bruscas de níveis de cinza, conseqüentemente, a matriz terá valores menores nas posições de  $p$  que se encontram mais afastadas da diagonal principal em comparação com os valores mais próximos, nos quais

se concentram os pares de pixels com pouca ou nenhuma diferença de níveis de cinza. O Segundo Momento Angular —  $f_1$  — é obtido pela soma dos quadrados dos elementos de  $p$  conforme a Equação 1. Isso mostra que as imagens homogêneas, as quais têm valores elevados e concentrados na diagonal principal, terão valores maiores de Segundo Momento Angular do que imagens menos homogêneas, as quais apresentam valores menores e mais dispersos na matriz.

$$f_1 = \sum_i \sum_j p(i,j)^2 \quad (1)$$

**Contraste:** definido como o conjunto de variações locais presentes na imagem. Desse modo, tem-se que imagens com maior número de variações locais possuem maior valor de contraste, enquanto imagens com menores variações de níveis de cinza nos diversos locais terão valores menores de contraste. O valor do contraste —  $f_2$  — é obtido por meio da Equação 2.

$$f_2 = \sum_{n=0}^{N_g-1} n^2 \left\{ \sum_i \sum_j p(i,j), \text{ se } |i - j| = n \right\} \quad (2)$$

**Correlação:** corresponde à dependência linear de tons de cinza da imagem. O valor de correlação —  $f_3$  — é obtido por meio da Equação 3:

$$f_3 = \frac{\sum_i \sum_j (ij) p(i,j) - \mu_x \mu_y}{\sigma_x \sigma_y} \quad (3)$$

onde  $\mu_x$ ,  $\mu_y$ ,  $\sigma_x$  e  $\sigma_y$  são respectivamente a média e o desvio padrão de  $p_x$  e  $p_y$ , definidos na Tabela 1.

**Variância:** entende-se por variância quão distantes os valores de tons de cinza, que compõem uma imagem, encontram-se do valor esperado. Numericamente, a variância é a soma dos quadrados dos desvios dos valores da média. Em [1] a variância —  $f_4$  — é obtida pela Equação 4.

$$f_4 = \sum_i \sum_j (i - \mu)^2 p(i,j) \quad (4)$$

onde  $\mu$  corresponde à média dos valores da imagem em níveis de cinza. Desse modo, a diferença entre o nível  $i$  e o nível de cinza obtido pela média, resulta em um peso no valor de  $p(i,j)$ .

**Entropia:** a entropia é uma grandeza associada ao grau de desordem das moléculas em um sistema no qual podem ocorrer transferências de calor. Em 1877, Ludwig Boltzmann (1844 — 1906) mensurou a entropia, por meio de um método probabilístico, para um determinado número de partículas de um gás ideal. Desse modo, a entropia foi definida como proporcional ao logaritmo do número de micro-estados

que um gás pode ocupar. Em [1], a entropia —  $f_5$  — foi apresentada conforme a Equação 5.

$$f_5 = - \sum_i \sum_j p(i,j) \log(p(i,j)) \quad (5)$$

**Outras Características:** outras características propostas em [1] com base nas matrizes de co-ocorrência são apresentadas na Tabela 2, juntamente com a equação que as define.

Para a realização deste trabalho, as imagens foram normalizadas para 8 níveis de cinza, considerando matrizes de co-ocorrência para direções 0, 45, 90 e 135 graus e distância um. Na extração de características a partir das matrizes de co-ocorrência, para cada característica apenas o valor da média dos valores das quatro direções foi considerado. Desse modo, as 11 características apresentadas foram extraídas para as 30 imagens que compõem CI, constituindo o Conjunto de Dados — CD —, no qual as linhas representam os exemplos (imagens) e as colunas os atributos.

Tabela 2: Outras características propostas em [1].

Característica	Equação
Momento Inverso da Diferença	$f_6 = \sum_i \sum_j p(i,j)/(1 + (i - j)^2)$
Soma da Média	$f_7 = \sum_{i=2}^{2Ng} i p_{x+y}(i)$
Soma da Entropia	$f_8 = - \sum_{i=2}^{2Ng} p_{x+y}(i) \log(p_{x+y}(i))$
Soma da Variância	$f_9 = \sum_{i=2}^{2Ng} (i - f_7)^2 p_{x+y}(i)$
Diferença da Entropia	$f_{10} = \sum_{i=0}^{Ng-1} p_{x-y}(i) \log(p_{x-y}(i))$
Diferença da Variância	$f_{11} = \text{variância de } p_{x-y}$

Neste trabalho, foi utilizada uma ferramenta implementada na linguagem de programação JAVA, a qual permitiu a extração das características apresentadas anteriormente.

### Análise dos Dados

Após os procedimentos, a partir de CD constituído de 30 exemplos descritos por um conjunto de 11 atributos, foi realizada a análise desses dados com o intuito de avaliar o comportamento dessas características em função da variação do ângulo visual. Para isto, a análise dos dados foi realizada através de gráficos, os quais foram gerados utilizando o aplicativo ORIGIN 7.5<sup>4</sup>.

<sup>4</sup><http://www.originlab.com>

## Resultados

Na Figura 3 são apresentados seis gráficos correspondentes às classes de imagens, isto é, à combinação entre as três estruturas e as duas texturas, que compõem o CI. Cada gráfico, rotulado com o nome da classe, representa a variação de cada característica em função do ângulo visual.

## Discussão e Conclusões

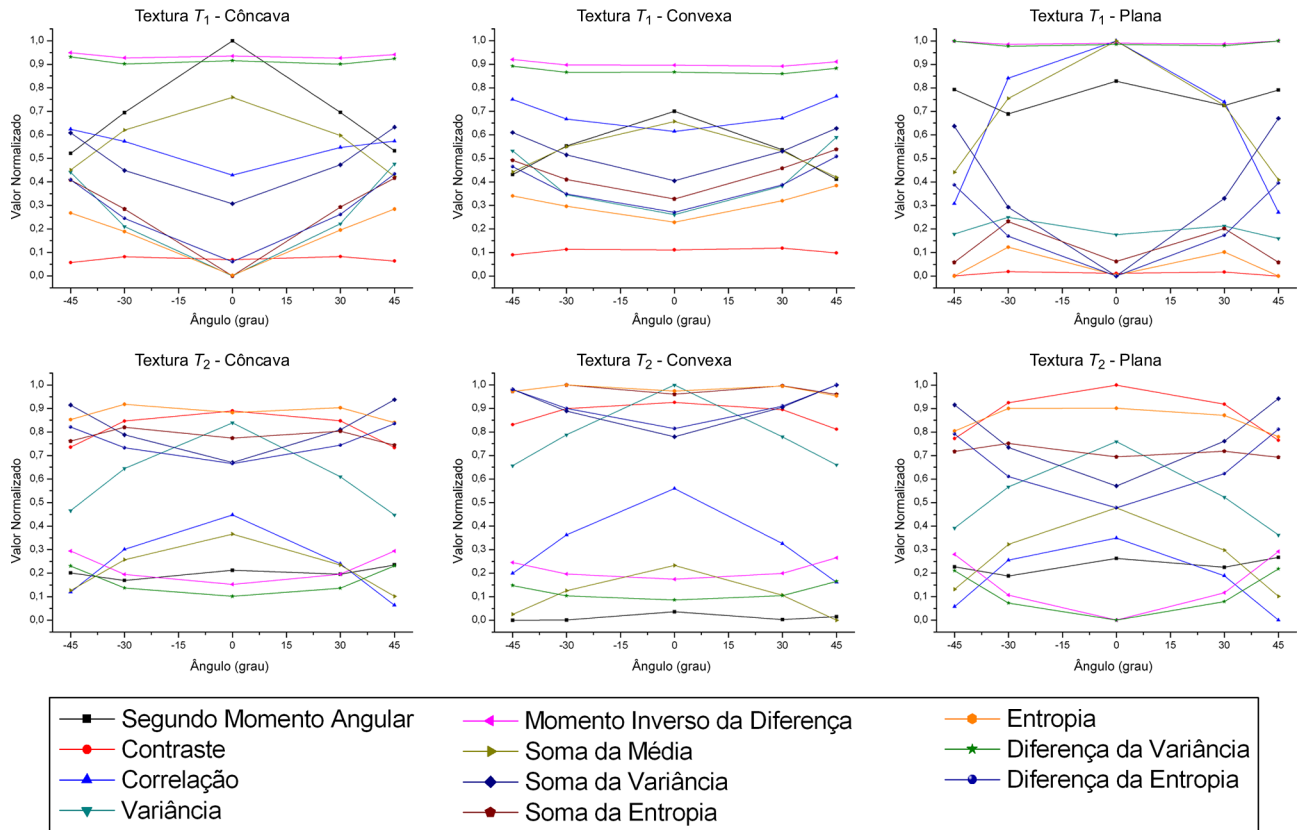
As doenças do intestino grosso representam uma das doenças de maior incidência na população brasileira e as neoplasias nesses locais ocupam a quarta maior ocorrência de mortalidade segundo o Instituto Nacional do Câncer [6]. Decorrente desses fatos, o estudo e o desenvolvimento de ferramentas que permitam auxiliar os especialistas nos processos de tomada de decisões são importantes e vitais.

O grande volume de imagens de colonoscopia produzido em hospitais e clínicas médicas, tem incentivado pesquisadores no desenvolvimento de ferramentas de apoio, que possam auxiliar na busca de padrões e na identificação dos diversos tipos de anormalidades e lesões presentes nessas imagens. Um dos aspectos importantes da percepção visual humana é a textura, a qual coleta informações sobre a distribuição dos níveis de cinza presentes na imagem. Atributos baseados em textura foram propostos por [1, 4, 9] e têm sido utilizados, por exemplo, na representação e identificação de tecidos em imagens médicas [4] e na classificação de lesões em imagens endoscópicas [10, 11].

Em exames de colonoscopia, os especialistas apresentam diversas maneiras de registrar as imagens que apresentam anormalidades. Variáveis como a distância entre a câmera e a lesão e o ângulo visual poderiam implicar em variações nas características utilizadas para representar as imagens. Por esse motivo, surge a necessidade de avaliar as características em função da distância e do ângulo visual. Neste trabalho, foram utilizadas imagens produzidas computacionalmente, as quais simulam lesões reais, com o intuito de manter um ambiente controlado. As imagens produzidas correspondem a seis classes com variações angulares de -45, -30, 0, 30 e 45 graus, mantendo uma distância fixa de cinco centímetros.

Na Figura 3 são apresentados gráficos para cada classe, representando o comportamento das características de textura extraídas das imagens em função da variação do ângulo visual.

Nas imagens correspondentes à textura  $T_1$  as características Momento Inverso da Diferença,



**Figura 3:** Gráficos correspondentes a cada uma das classes de imagens.

Diferença da Variância e Contraste, mantiveram-se estáveis em relação ao ângulo visual. Em relação às imagens correspondentes à textura  $T_2$ , apenas a característica Segundo Momento Angular manteve-se estável.

Em uma análise comparativa sobre Contraste, as imagens correspondentes a  $T_1$  mostraram baixo valor em comparação com as imagens de  $T_2$ . Do mesmo modo, Momento Inverso da Diferença e Diferença da Variância indicaram valores maiores para às imagens de  $T_1$  em comparação com as imagens de  $T_2$ . Isso demonstra que, além dessas três características apresentarem comportamento estável em relação aos ângulos visuais considerados, permitiram também diferenciar ambos tipos de textura.

As matrizes de co-ocorrência das imagens correspondentes à textura  $T_1$  apresentaram valores concentrados na diagonal principal, enquanto as matrizes correspondentes às imagens com  $T_2$  apresentaram maiores valores nas posições as quais indicam transições de níveis de cinza. Desse modo, a disposição dos valores nessas matrizes contribuíram para diferenciação das duas texturas.

A característica Contraste mostrou valores menores em  $T_1$  do que em  $T_2$ , pois, conforme  $f_2$ , o valor  $n$  pondera a soma dos elementos da matriz em virtude da grandeza da transição de nível de cinza.

Para o cálculo do valor da característica Momento Inverso da Diferença, conforme  $f_6$ , cada elemento da matriz é normalizado em função da variação de nível de cinza a que pertence. Devido à alta concentração dos valores das matrizes de co-ocorrência de  $T_1$  na diagonal principal, a característica resultou em valores maiores, pois a normalização possibilitou a valorização dos elementos com pouca ou nenhuma transição de nível de cinza, enquanto as imagens de  $T_2$ , com maior quantidade de variações de níveis de cinza, resultaram em valores maiores da característica Momento Inverso da Diferença.

Por fim, a característica Diferença da Variância, calculada por  $f_{11}$ , considera a variância em função da quantidade de elementos da matriz que pertencem a cada transição nível de cinza. Como as matrizes de co-ocorrência das imagens de  $T_1$  têm poucas variações de níveis de cinza, a diferença entre os valores dos elementos que indicam pouca e muita

variação é alta, resultando em valores maiores dessa característica em comparação com as imagens de  $T_2$ . Essas imagens de  $T_2$  apresentam maiores transições de níveis de cinza e, desse modo, menor variância em relação à quantidade de pares pixels pertencentes a cada transição de nível de cinza.

De acordo com os resultados apresentados, é possível concluir que as características Momento Inverso da Diferença, Diferença da Variância e Contraste apresentaram-se estáveis para  $T_1$  em relação aos ângulos visuais considerados, permitindo assim, a diferenciação dos dois tipos de textura. Desse modo, essas três características baseadas em textura apresentaram-se como importantes candidatas para a caracterização de anormalidades com diferentes texturas e estruturas.

Como trabalhos futuros, essas características que apresentaram comportamento estável em função do ângulo visual, poderão ser utilizadas para o estudo de outros conjuntos de imagens e para a análise do comportamento em função da variação da distância entre a câmera e a lesão.

## Agradecimentos

Ao Programa de Desenvolvimento Tecnológico Avançado — PDTA/FPTI-BR — pelo auxílio por meio da linha de financiamento de bolsas.

## Referências

- [1] Haralick, R.M., Shanmugam, K., Dinstein, I. (1973), "Texture features for image classification", *IEEE Transactions on Systems, Man, and Cybernetics (SMC)*, v. 3, n. 6, p. 610–621.
- [2] Haralick, R.M. (1979), "Statistical and structural approaches to texture", *Proceedings of the IEEE*, v. 67, n. 5, p. 786–804.
- [3] Tjoa, M.P., Krishnan, S.M. (2003), "Feature extraction for the analysis of colon status from the endoscopic images", *BioMedical Engineering OnLine*, v. 2, n. 9.
- [4] Felipe, J.C., Traina, A.J.M., Traina, C. (2003), "Retrieval by Content of Medical Images Using Texture for Tissue Identification", *16th IEEE Symposium on Computer-based Medical Systems (CBMS)*, p. 26–27.
- [5] Marques, P.M.D.A., Honda, M.H., Rodrigues, J.A.H., Santos, R.R., Traina, A.J.M., Traina, C. (2002), "Recuperação de Imagens Baseada

em Conteúdo: Uso de Atributos de Textura para Caracterização de Microcalcificações Mamográficas", *Revista Brasileira de Radiologia*, v. 35, p. 93–98.

- [6] Quilici, F.A. (2000), *Colonoscopia*, São Paulo — SP, Brasil: Lemos-Editorial.
- [7] Cordeiro, F., Filho, J.S.M., Prolla, J.C. (1994), *Endoscopia digestiva*, Rio de Janeiro — RJ, Brasil: MEDSI.
- [8] Cotran, R.S., Kumar, V., Collins, T. (2000), *Patologia Estrutural e Funcional*, Philadelphia — PA, USA: Guanabara Koogan.
- [9] He, D.C., Wang, L. (1990), "Texture Unit, Texture Spectrum, And Texture Analysis", *Geoscience and Remote Sensing, IEEE Transactions on*, v. 28, n. 4, p. 509–512.
- [10] Karkanis, S., Magoulas, G., Iakovidis, D., Maroulis, D., Schurr, M. (2000), "On the Importance of Feature Descriptors for the Characterisation of Texture". In *4th World Multiconference on Systems, Cybernetics and Informatics (SCI)*, p. 1–6.
- [11] Krishnan, S.M., Yap, C.J., Asari, K.V., Goh, P.M.Y. (1998), "Neural network based approaches for the classification of colonoscopic images", *In Engineering in Medicine and Biology Society, Proceedings of the 20th Annual International Conference of the IEEE*, Hong Kong Sar, China, v. 3, p. 1678–1680.

## Contato

C. A. Ferrero<sup>1</sup> — anfer86@gmail.com  
H. D. Lee<sup>2</sup> — huei@unioeste.br  
F. C. Wu<sup>3</sup> — wufc@unioeste.br  
C. S. R. Coy<sup>4</sup> — ccoy@terra.com.br  
J. J. Fagundes<sup>5</sup> — jjfagundes@mpcnet.com.br  
J. R. N. Góes<sup>6</sup> — rgoes@mpcnet.com.br

<sup>1,2,3</sup>Laboratório de Bioinformática — LABI, Universidade Estadual do Oeste do Paraná — UNIOESTE. Av. Tarquínio Joslin dos Santos, 1300, Pólo Universitário, CEP 85870-650, Foz do Iguaçu — PR.

<sup>3,4,5,6</sup>Serviço de Coloproctologia, Faculdade de Ciências Médicas — FCM, Universidade Estadual de Campinas — UNICAMP. Rua Carlos Chagas, 420, Cidade Universitária "Zeferino Vaz", CEP 13031-970, Campinas — SP.