

Avaliação de Modelos de Classificação para a Diferenciação de Tecidos Cólicos Representados por Matrizes de Co-ocorrência

Carlos Andres Ferrero^{1,3,4}, Newton Spolaôr^{1,4}, Huei Diana Lee¹,
João José Fagundes², Cláudio Saddy Rodrigues Coy², Feng Chung Wu^{1,2,3,4}

¹Laboratório de Bioinformática — LABI,
Universidade Estadual do Oeste do Paraná — UNIOESTE, Brasil
²Serviço de Coloproctologia da Faculdade de Ciências Médicas — FCM,
Universidade Estadual de Campinas — UNICAMP, Brasil
³Instituto de Ciências Matemáticas e de Computação — ICMC,
Universidade de São Paulo — USP/São Carlos, Brasil
⁴Fundação Parque Tecnológico Itaipu — FPTI, Brasil

Resumo - O crescente armazenamento de informações no formato multimídia, nas diversas áreas, tem incentivado a aplicação de técnicas que permitam obter uma análise mais completa a respeito desses dados. Na área médica, essa análise e a descoberta de padrões, são de grande interesse, pois podem contribuir para a construção de sistemas de suporte à decisão. Nesse sentido, técnicas de Análise de Imagens e de Inteligência Computacional, podem auxiliar nessa tarefa por meio da construção de modelos de classificação. Neste trabalho, 67 imagens de exames de coloscopia foram submetidas a uma metodologia de construção de modelos de classificação para a diferenciação de tecidos cólicos. Foram consideradas diferentes representações de imagens em matrizes de co-ocorrência, por meio da variação do valor do parâmetro de distância, e avaliados os desempenhos de três métodos de classificação com base nessas representações: árvores de decisão, vizinho mais próximo e redes neurais artificiais. O método de validação cruzada, para 10 partições, foi utilizado para obter uma aproximação do erro verdadeiro de cada modelo. Os resultados evidenciaram que o parâmetro de distância para a construção de matrizes de co-ocorrência pode influenciar significativamente no desempenho de modelos de classificação, dependendo do algoritmo utilizado para a construção de padrões.

Palavras-chave: inteligência computacional, análise de imagens médicas, imagens de coloscopia, matriz de co-ocorrência.

Abstract - The growing information storage at multimedia format and the interest to obtain a more complete analysis related to these data has motivated the application of computational techniques. In the medical area, data analysis and pattern discovery are of great interest, as they can contribute to the implementation of decision support systems. Thus, Image Analysis and Computational Intelligence techniques can help in this task through the generation of classification models. In this work, 67 images of coloscopic exams were submitted to a classification methodology to differentiate mucous colic tissues. Five representations of co-occurrence matrices were considered, using different values of distance parameter, and the performance was evaluated through three classification methods: decision trees, nearest neighbor and artificial neural networks. The ten fold cross-validation technique was used to obtain an approximation of the true error of each model. Experimental results showed that the distance parameter used to construct co-occurrence matrices can influence significantly the performance of classification models, depending on the algorithm used to generate them.

Key-words: computacional intelligence, medical image analysis, coloscopic images, co-occurrence matrices.

1. Introdução

Sistemas de gerenciamento de dados têm se tornado comuns nas diversas áreas do conhecimento, proporcionando um crescente volume de informações, referentes a dados do tipo multimídia,

como vídeo, imagem e texto [1, 2]. O acúmulo desse grande conjunto de informações, tem incentivado a aplicação de métodos computacionais para permitir uma análise mais completa desses dados, no intuito de construir sistemas que permitam auxiliar especialistas em processos de tomada de decisões. No con-

texto de dados do tipo imagem, essa análise pode ser realizada por meio de uma interação entre as áreas de Análise de Imagens — AI — e de Inteligência Computacional — IC —, que consiste, primeiramente, na extração de características visuais intrínsecas das imagens e, posteriormente, no reconhecimento dos padrões que permitam classificar novas imagens.

Em hospitais e clínicas médicas, exames são comumente registrados no formato de imagens para complementar os laudos médicos descritos pelos especialistas e prover uma descrição mais completa a respeito do estado de saúde do paciente. Ainda, as imagens registradas, também são utilizadas pelo especialista para dar suporte ao diagnóstico de enfermidades.

De acordo com o Instituto Nacional do Câncer — INCA —, no Brasil, o câncer colorretal constitui a quarta maior incidência entre todas as neoplasias malignas em homens e a terceira em mulheres. Segundo as estimativas do INCA, em 2008, haverá aproximadamente 12.490 casos de câncer colorretal em homens e 14.500 em mulheres. Em relação à mortalidade média mundial, o câncer de cólon e reto varia entre 40 e 50%, não apresentando maiores diferenças entre países desenvolvidos e países em desenvolvimento [3]. O exame de coloscopia representa uma ferramenta indispensável para o diagnóstico de doenças do intestino grosso, sendo assim de interesse a análise de imagens referentes às anormalidades que podem ser evidenciadas por meio desse exame médico.

Nesse sentido, está sendo desenvolvido o projeto Análise de Imagens Médicas, de característica multidisciplinar, o qual tem como o objetivo identificar padrões em imagens médicas para a construção de modelos, que permitam auxiliar especialistas em processos de tomada de decisões. O projeto é constituído de duas fases. Na primeira fase, Identificação de Padrões, imagens coletadas a partir de exames médicos são processadas por métodos de AI e representadas por um conjunto de características. Essa representação, possibilita a aplicação de técnicas de Aprendizado de Máquina, uma subárea da IC, que permite encontrar padrões nessas representações [4]. Na segunda fase, caracterizada como Classificação de Imagens, os padrões encontrados são utilizados para a construção de sistemas computacionais que permitem classificar novas imagens. Dessa maneira, é possível auxiliar aos especialistas da área nos processos de tomada de decisões associados à identificação de anormalidades presentes em imagens médicas.

No presente trabalho, o qual constitui parte desse projeto, é apresentado um estudo de representação de imagens médicas por meio de características de

textura, baseadas em matrizes de co-ocorrência, para construção de modelos de classificação. Desse modo, o objetivo do trabalho consiste em, com base em diferentes representações de imagens em matrizes de co-ocorrência, avaliar o desempenho de três métodos de classificação: árvores de decisão, vizinho mais próximo e redes neurais artificiais.

Na Seção 2 é descrita a metodologia utilizada para a realização dos experimentos. Posteriormente, na Seção 3, é apresentada a aplicação da metodologia em imagens de exames de coloscopia. Ainda nessa seção, os modelos são comparados e a qualidade desses modelos discutida. Ao final, são apresentadas as conclusões e os trabalhos futuros na Seção 4.

2. Material e Método

A metodologia proposta tem como objetivo diferenciar tecidos cólicos presentes em imagens de exames de coloscopia, por meio da construção de modelos a partir de informações contidas nas imagens. Essa tarefa é realizada mediante a aplicação de quatro etapas: (1) coleta do conjunto de imagens, (2) construção do vetor de características, (3) construção de modelos para classificação e (4) avaliação de modelos, as quais são descritas a seguir.

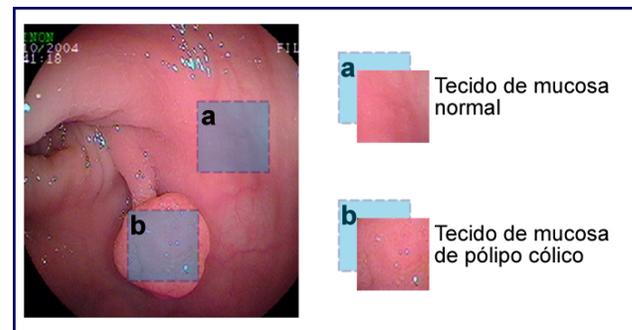


Figura 1: (a) Tecidos de mucosa normal (a) e de pólipo cólico (b).

Etapa 1 — Coleta do Conjunto de Imagens

Os sistemas de gerenciamento de imagens médicas vêm se tornando comuns em ambientes médicos, permitindo o armazenamento de imagens que possibilitam complementar os diagnósticos realizados pelos especialistas. No caso de exames de coloscopia, as imagens registram anormalidades do tipo polipóides, diverticulares e vasculares, dentre outras. Desse modo, pode ser interessante oferecer suporte à diferenciação entre tecidos de mucosa cólica normal e de pólipo cólico.

Na Etapa 1 da metodologia, a partir de um conjunto de n imagens, são selecionados fragmentos

de imagem que apresentam tecidos cólicos. Para cada imagem são selecionados dois fragmentos: um de tecido de mucosa normal e outro de pólipó cólico. A Figura 1 ilustra a seleção de fragmentos de tecido de mucosa normal e de pólipó cólico. Uma vez realizada a coleta dos dois fragmentos para cada uma das imagens consideradas é constituído o Conjunto de Imagens definido por $CI = \{Im_1, Im_2, \dots, Im_n, Im_{n+1}, Im_{n+2}, \dots, Im_{2n}\}$, em que cada elemento de CI representa um registro de imagem e n o número de imagens consideradas.

Etapa 2 — Construção do Vetor de Características

Na análise de imagens é freqüente a descrição de imagens conforme propriedades baseadas em cor, textura e forma [5]. Na Etapa 2, a partir das propriedades de cada imagem pertencente ao conjunto CI , são extraídas diversas características. Essas informações podem ser representadas no formato atributo-valor, o qual é um padrão freqüente dos dados de entrada de algoritmos para a construção de modelos. As d características a serem extraídas em cada imagem constituem o vetor de atributos $V = \{C_1, C_2, \dots, C_d\}$. A i -ésima imagem processada origina o exemplo E_i , o qual é descrito por $E_i = \{A_{i,1}, A_{i,2}, \dots, A_{i,d}, A_{i,d+1}\}$, em que os atributos de A_1 a A_d correspondem aos valores das características definidas em V e o atributo A_{d+1} contém a classe do exemplo. A união de todos os exemplos define o Conjunto de Dados Inicial, que é denotado por $CDI = \{E_1, E_2, \dots, E_{2n}\}$.

Como mencionado, algumas das maneiras mais comuns de representação de imagens médicas são as baseadas em textura, as quais podem ser extraídas por meio da construção de Matrizes de Co-ocorrência — MC — [2, 6, 7, 8] e de espectros de textura [1, 9], entre outras técnicas. As matrizes de co-ocorrência representam as transições de níveis de cinza presentes em imagens. A construção dessas MC permite extrair atributos que descrevem as propriedades de disposição e espaço entre níveis de cinza e outros elementos que compõem uma imagem. A extração de características de textura a partir de MC, foco deste trabalho, possibilita a representação computacional de imagens de coloscopia para que seja possível realizar o restante de metodologia. Essas matrizes são constituídas de lc linhas e colunas, em que lc indica o número de Níveis de Cinza — NC — considerado, de modo que o valor na posição (i, j) indica o número de transições de nível de cinza i para nível de cinza j presentes na imagem. Na Figura 2 é apresentado um exemplo de construção de uma MC a partir de uma imagem.

A construção da matriz de co-ocorrência observada na Figura 2 pode ser exemplificada pela

obtenção do valor na posição $(1,0)$. O valor 8 corresponde à contabilização dos pixels de valor 1, cujo vizinho direito ou esquerdo apresenta valor 0. A observação dos vizinhos direito e esquerdo é indicada pela direção 0° e a distância 1. Desse modo, a partir das MC construídas, são extraídos valores calculados (descritores). Em [6] foram propostos 11 descritores para representar propriedades de textura das imagens: Segundo Momento Angular, Contraste, Correlação, Variância, Entropia, Momento Inverso da Diferença, Soma da Média, Soma da Variância, Soma da Entropia, Diferença da Variância e Diferença da Entropia [6].

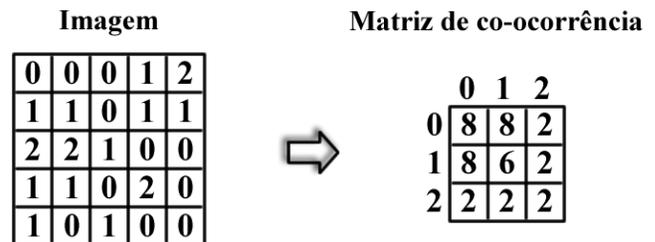


Figura 2: Imagem representada em três NC como uma matriz de pixels 5×5 e a respectiva MC para a direção 0° e a distância 1.

Etapa 3 — Construção de Modelos para Classificação

Após a construção do conjunto CDI, é realizada a indução de modelos utilizando algoritmos de Inteligência Computacional. A geração de modelos com base em grandes conjuntos de dados possibilita a classificação de novos exemplos, a partir do aprendizado obtido na resolução bem-sucedida de problemas anteriores. Desse modo, os modelos construídos podem ser úteis para auxiliar especialistas no processo de tomada de decisões [4, 10].

Três métodos são amplamente utilizados para a indução de modelos de classificação: (1) árvores de decisão, (2) vizinho mais próximo e (3) redes neurais artificiais. O método (1) consiste na construção de uma estrutura de dados hierárquica compreensível, a qual implementa a estratégia dividir e conquistar. Posteriormente, essa estrutura hierárquica é utilizada para a classificação de novos exemplos [4]. O método (2) consiste na classificação de novos casos através da similaridade com exemplos de treinamento previamente armazenados em memória. Desse modo, considerando-se o(s) exemplo(s) mais próximo(s) é realizada a tomada de decisão de atribuição da classe ao novo exemplo [11]. E, o método (3) consiste em modelos matemáticos inspirados na estrutura neural biológica, os quais têm a capacidade computacional adquirida por meio de aprendizado e generalização [12].

¹<http://www.cs.waikato.ac.nz/ml/weka/>.

A ferramenta WEKA¹ disponibiliza algoritmos para cada um desses métodos. Para o método (1), é disponibilizado o algoritmo J48, uma implementação do algoritmo C4.5 [13], que consiste na divisão do conjunto de dados de acordo com o atributo que melhor divide as classes. Esse processo é realizado recursivamente até a obtenção de sub-conjuntos de uma única classe. Para o método (2), WEKA disponibiliza o algoritmo 1-*Nearest-Neighbor* — 1NN —, que consiste rotular um exemplo não classificado com base no exemplo mais próximo do conjunto de treinamento. Por fim, para o método (3), é disponibilizado o algoritmo de *Multi-Layer Perceptron* — MLP —, que consiste em interconectar unidades básicas, e atribuindo pesos às interconexões utilizando o algoritmo de retropropagação de erros.

Etapa 4 — Avaliação de Resultados

Os modelos construídos devem ser avaliados quanto à sua qualidade preditiva, considerando a eficiência que apresentam na predição de novos exemplos. No intuito de se avaliar essa capacidade, uma técnica comumente empregada consiste no cálculo da precisão preditiva, a qual consiste na proporção de exemplos corretamente classificados do total de exemplos classificados.

Para se obter uma aproximação da precisão verdadeira do modelo construído, isto é, a precisão que apresentaria o modelo no caso de que forem apresentados exemplos nunca vistos, pode ser utilizado o método de validação cruzada [14]. Esse método consiste em dividir o conjunto de exemplos em k amostras iguais, comumente dez [11], e criar k grupos, em que cada um é constituído pela k -ésima amostra como conjunto de teste e pelas $k - 1$ amostras restantes como conjunto de treinamento. Para cada grupo é construído um modelo com base no conjunto de treinamento e testado com os exemplos de teste. Assim, a precisão preditiva é estimada como a média das precisões dos k modelos construídos.

Outra técnica envolvida nessa etapa corresponde à avaliação e à validação dos modelos por parte de especialistas do domínio. A contribuição dos especialistas auxilia na eliminação de padrões desnecessários e na certificação dos demais padrões, o que proporciona maior robustez preditiva aos modelos construídos. Nessa avaliação podem ser propostas melhorias nas etapas anteriores, de modo a extrair características mais significativas e, conseqüentemente, formular hipóteses mais consistentes.

As Etapas 1 e 2 são realizadas com o suporte de um sistema computacional desenvolvido no Laboratório de Bioinformática — LABI —, denominado *Medical Image Analysis System* — MIAS [15]. A Etapa 3 é desenvolvida com o auxílio da ferramenta WEKA.

3. Resultados e Discussão

A metodologia apresentada foi aplicada a um conjunto de 67 imagens de exames de coloscopia provenientes do Serviço de Coloproctologia da Faculdade de Ciências Médicas da UNICAMP no período de outubro de 2004 a novembro de 2005. As imagens utilizadas correspondem a exames de coloscopia nos quais foram identificados tecidos de mucosa de pólipos cólicos do Tipo Ip (classificado como Pólipo Protruso Pediculado, conforme as normas da Sociedade Japonesa de Pesquisa do Câncer Colorretal) [16, 17].

Na Etapa 1, para cada imagem foram selecionados, manualmente, fragmentos de tecido de mucosa normal e de pólipos cólicos — Figura 1. Cada tecido cólico foi selecionado considerando o tamanho da região interna de cada pólipo cólico, de modo a utilizar a maior quantidade de informação possível a respeito da anormalidade morfológica. A partir dessa seleção foi criado o conjunto *CI* contendo 134 fragmentos de imagens.

Posteriormente, na Etapa 2, foi realizada a representação das imagens por meio da transformação de cada imagem do formato original RGB (vermelho, verde e azul, do inglês *red, green, blue*) para o formato em escala de cinza, o qual é adequado para a definição do valor de intensidade de cada ponto (pixel) e para a conseqüente construção da MC. Foi utilizada a representação em 64 níveis de cinza, para a representação das imagens. Esse número de níveis de cinza têm sido utilizado na literatura [1, 2, 5, 9] e, para essas imagens, tem-se apresentado como uma representação promissora para a construção de modelos de classificação [15]. As matrizes de co-ocorrência foram construídas para as distâncias $D = 1, 2, 3, 4$ e 5 , com o intuito de verificar a distância mais adequada para a construção de modelos de classificação. Nesse sentido, foi utilizado o aplicativo MIAS para construir as MC correspondentes de cada imagem, considerando as direções 0, 45, 90 e 135 graus. A partir das MC, foram extraídas as 11 características de textura mencionadas na Etapa 2 da metodologia utilizada. Para cada característica, apenas o valor da média dos valores das quatro direções foi considerado. Com isso, foi possível uma representação atributo-valor do conjunto de fragmentos de imagem para cada distância.

A partir dos dados no formato atributo-valor foram induzidos modelos de classificação para os conjuntos de dados utilizando os três algoritmos apresentados na Etapa 3 da metodologia proposta: J48, para a construção de árvores de decisão; 1NN, para a classificação de novos exemplos com base no exemplo mais próximo da base de exemplos; e MLP, para a construção de redes neurais artificiais. Todos os ex-

perimentos foram executados com o auxílio da ferramenta WEKA, utilizando os parâmetros configurados com valores padrão.

Tabela 1: Avaliação dos modelos construídos por meio da técnica de validação cruzada.

Dist	J48		MLP		1NN	
	EM	DP	EM	DP	EM	DP
1	0,239	0,124	0,344	0,151	0,259	0,109
2	0,283	0,122	0,328	0,149	0,335	0,137
3	0,223	0,119	0,329	0,154	0,230	0,105
4	0,290	0,101	0,319	0,139	0,207	0,071
5	0,306	0,084	0,312	0,111	0,170	0,096

Os modelos construídos pelos algoritmos foram avaliados com base na precisão preditiva. Foi utilizada a técnica de validação cruzada, considerando dez partições, de modo a obter uma aproximação do erro verdadeiro dos modelos. Os valores de erro médio e desvio-padrão, resultantes da aplicação dos métodos de classificação sobre os conjuntos de dados referentes a cada distância considerada, são apresentados na Tabela 1.

Com os dados apresentados foi possível constatar que, para o algoritmo J48 os menores valores de EM e DP foram para $D = 3$ e 5 , respectivamente; para 1NN os menores valores para ambas as medidas foram obtidas utilizando $D = 5$; e, para MLP, os menores valores de EM e DP foram para $D = 5$ e 4 , respectivamente. Para verificar se alguma das distâncias utilizadas para a construção das matrizes de co-ocorrência permitiu melhorar significativamente o desempenho de modelos de classificação, foi aplicado o teste $t - student$ para dados emparelhados. Para cada algoritmo, foi realizada a comparação dos erros referentes à distância que apresentou menor EM, em relação aos erros de cada uma das outras distâncias. Os p -valores referentes às comparações são apresentados na Tabela 2.

Tabela 2: Resultado da aplicação do teste estatístico t -student.

	Distância				
	1	2	3	4	5
J48	0,5500	0,1314	–	0,04760	0,1012
1NN	0,6210	0,7326	0,7301	0,8096	–
MLP	0,0196	0,0047	0,0576	0,0947	–

Considerando essas informações apresentadas foi possível evidenciar que, considerando o nível de confiança de 90%, para o algoritmo J48, foi possível constatar diferença estatisticamente significativa entre os valores de erro de $D = 3$ e 4 , sendo que, para os outros valores de D não foi possível evidenciar diferença. No caso do algoritmo 1NN não

foi possível constatar diferença significativa entre os erros de $D = 5$ e os outros valores de D . E, em relação a MLP, foi possível constatar diferença estatisticamente significativa entre os erros de $D = 5$ e os erros dos outros quatro valores de D . Esses resultados também permitem evidenciar que, de acordo com o algoritmo a ser utilizado, a influência do parâmetro k pode, ou não, ser significativa.

4. Conclusão

Os sistemas de gerenciamento vem incentivando o armazenamento crescente de grandes volumes de dados em diferentes formatos. Na área médica, imagens são armazenadas e utilizadas pelos especialistas para dar suporte ao diagnóstico de enfermidades. Esse armazenamento, faz com que haja necessidade de se realizar uma análise mais completa dos dados, no intuito de auxiliar especialistas em processos de tomada de decisões. Neste trabalho, uma metodologia para a construção de modelos de classificação foi apresentada e aplicada a um conjunto contendo 67 imagens de exames coloscópicos. Os modelos construídos foram avaliados de acordo com a precisão preditiva e comparados, no intuito de verificar a influência do parâmetro de distância na qualidade desses modelos.

Os resultados apresentados neste trabalho permitem concluir que o parâmetro de distância, utilizado pelas matrizes de co-ocorrência para a representação de imagens, pode proporcionar melhora significativa para a construção de modelos de classificação, dependendo do algoritmo a ser utilizado. No caso dos algoritmos J48 e 1NN não foi possível constatar uma melhora significativa de precisão para nenhum dos valores de distância considerados, exceto para o algoritmo J48, no qual os erros de precisão utilizando distância 3 apresentaram melhora estatisticamente significativa apenas em relação ao modelo construído com distância 4. Para o algoritmo MLP, o valor de distância referente ao modelo de menor erro médio apresentou melhora estatisticamente significativa em relação às outras distâncias consideradas. Esse fato mostrou que, para a construção de redes neurais artificiais, o valor do parâmetro de distância influencia significativamente no desempenho de modelos de classificação.

Trabalhos futuros incluem a aplicação de métodos de seleção de atributos para encontrar subconjuntos de características relevantes e/ou não redundantes, presentes nas imagens; a utilização de outras características para a representação de imagens de exames de coloscopia; e a coleta de um número maior de imagens de coloscopia, de tipos de anormalidades bem definidas, com o intuito de construir modelos melhor adaptados a problemas reais.

Agradecimentos

Ao Programa de Desenvolvimento Tecnológico Avançado — PDTA/FPTI-BR — pelo auxílio por meio da linha de financiamento de bolsas. À Fundação de Apoio ao Desenvolvimento Científico e Tecnológico do Paraná — ARAUCARIA — pelo auxílio por meio da linha de financiamento de projetos de pesquisa.

Referências

- [1] Karkanis S, Galoussi K, Maroulis D. Classification of Endoscopic Images Based on Texture Spectrum. Advance Course in Artificial Intelligence, In Proceedings of Workshop on Machine Learning in Medical Applications. 1999;p. 63–69.
- [2] Felipe JC, Traina AJM, Traina C. Retrieval by Content of Medical Images Using Texture for Tissue Identification. 16th IEEE Symposium on Computer-based Medical Systems. 2003;p. 26–27.
- [3] Instituto Nacional de Câncer (INCA). Estimativa 2008: Incidência de Câncer no Brasil. Rio de Janeiro — RJ, Brasil; 2007.
- [4] Rezende SO. Sistemas Inteligentes: Fundamentos e Aplicações. Barueri, Brasil: Editora Manole; 2003.
- [5] Howarth P, Yavlinsky A, Heesch D, Rüger S. Medical Image Retrieval Using Texture, Locality and Colour. Lecture Notes from the Cross Language Evaluation Forum. 2005;p. 740–749.
- [6] Haralick R, Shanmugam K, Dinstein I. Texture features for image classification. IEEE Transactions on Systems, Man, and Cybernetics. 1973;3(6):610–621.
- [7] Krishnan SM, Yap CJ, Asari KV, Goh PMY. Neural network based approaches for the classification of colonoscopic images. Engineering in Medicine and Biology Society, Proceedings of the 20th Annual International Conference of the IEEE. 1998;3:1678–1680.
- [8] Marques PMDA, Honda MH, Rodrigues JAH, Santos RR, Traina AJM, Traina C. Recuperação de Imagens Baseada em Conteúdo: Uso de Atributos de Textura para Caracterização de Microcalcificações Mamográficas. Revista Brasileira de Radiologia. 2002;35:93–98.
- [9] He DC, Wang L. Texture Unit, Texture Spectrum, And Texture Analysis. IEEE Trans on Geoscience and Remote Sensing. 1990 Jul;28(4):509–512.
- [10] Witten IH, Frank E. Data mining: practical machine learning tools and techniques. 2nd ed. Elsevier; 2005.
- [11] Alpaydin E. Introduction to Machine Learning. Cambridge, England: MIT Press; 2004.
- [12] Haykin S. Neural Networks: a comprehensive foundation. 2nd ed. Upper Saddle River, USA: Prentice-Hall; 1999.
- [13] Quinlan JR. Induction of Decision Trees. Machine Learning. 1986;1(1):81–106.
- [14] Doria U. Introdução à Bioestatística: para simples mortais. São Paulo, Brasil: Elsevier; 1999.
- [15] Ferrero CA, Spolaôr N, Lee HD, Coy CSR, Fagundes JJ, Wu FC. Estudo Comparativo de Matrizes de Co-ocorrência em Análise de Imagens Médicas: Diferenciação de Tecidos Cólicos. In: X Simpósio de Informática y Salud, Jornadas Argentina de Informática. Santa Fe — SF, Argentina; 2008. p. 1–12.
- [16] Quilici FA. Colonoscopia. São Paulo, Brasil: Lemos-Editorial; 2000.
- [17] Cotran RS, Kumar V, Collins T. Patologia Estrutural e Funcional. USA: Guanabara Koogan; 2000.

Contato

C. A. Ferrero¹ — anfer86@gmail.com
N. Spolaôr² — newtonspolaor@gmail.com
H. D. Lee³ — huei@pti.org.br
J. J. Fagundes⁴ — jffagundes@mpcnet.com.br
C. S. R. Coy⁵ — ccoy@terra.com.br
F. C. Wu⁶ — wufc@pti.org.br

^{1,2,3,6}Laboratório de Bioinformática — LABI, Universidade Estadual do Oeste do Paraná — UNIOESTE, Parque Tecnológico Itaipu — PTI, Av. Tancredo Neves, 6731, CEP 85866-900, Foz do Iguaçu — PR.

^{4,5,6}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.

¹Instituto de Ciências Matemáticas e de Computação — ICMC —, Universidade de São Paulo — USP/São Carlos. Av. Trabalhador São-Carlense, 400, CEP 13560-970, São Carlos — SP.