

ESTUDO COMPARATIVO DE MÉTODOS DE ANÁLISE DE IMAGENS PARA A DIFERENCIAÇÃO DE TECIDOS CÓLICOS

Carlos Andres Ferrero¹, Huei Diana Lee², Cláudio Saddy Rodrigues Coy³,
Juvenal Ricardo Navarro Góes⁴, João José Fagundes⁵, Wu Feng Chung⁶

Abstract — *The storage of medical images has motivated the application of Image Analysis and Artificial Intelligence methods to find patterns to identify morphological abnormalities. In this work, a comparative study of the application of a methodology to characterize colic tissues was performed. It is part of the Medical Analysis Project developed by LABI/UNIOESTE in partnership with Serviço de Coloproctologia/UNICAMP. The developed methodology was implemented into a computational system which gives support to image analysis. A total of 134 colonoscopy images, described by 11 texture characteristics, were considered in this work. The constructed model was compared to a prior study in which models were generated using texture spectrum of red, green and blue components of the images. The methodology application considering colonoscopy images enabled the highlighting of pictorial patterns related to tissues with and without abnormality.*

Index Terms — *artificial intelligence, colonoscopic images, medical image analysis, texture features.*

INTRODUÇÃO

O crescente volume de dados que vem sendo acumulado devido à utilização de sistemas de gerenciamento de dados, nas mais diversas áreas do conhecimento, tem incentivado a aplicação de métodos que permitam analisar de modo mais completo esse volume de informações. Mais recentemente a tecnologia tem possibilitado o armazenamento de dados multimídia (vídeo, imagens e texto) [1]-[3]. Decorrente ao fato, surgiu a necessidade de aplicar métodos para a análise desses dados e, conseqüentemente, prover suporte a processos de tomada de decisões. No contexto de dados do tipo imagem, essa análise pode ser realizada por meio da inter-relação entre as áreas de Análise de Imagens – AI – e de Inteligência Artificial – IA –, a qual consiste primeiramente na extração de características visuais intrínsecas das imagens para, posteriormente, reconhecer padrões que permitam classificar novas imagens.

Na área médica, comumente, são registrados exames de pacientes utilizando imagens digitais, o que permite auxiliar

no processo de tomada de decisões e complementar o registro do diagnóstico de pacientes. Uma das doenças de maior ocorrência no Brasil e no mundo é o câncer colorretal que, segundo o Instituto Nacional do Câncer, constitui a quarta maior incidência entre todos os tumores malignos, independentemente do sexo [4]. Em relação à mortalidade, as neoplasias do intestino grosso também ocupam o quarto lugar, ocorrendo em menor frequência apenas que tumores de pulmão, estômago e mama [5]. Nesse sentido, o exame de colonoscopia, apresenta-se como uma ferramenta indispensável para o diagnóstico de doenças do intestino grosso [4][5].

Este trabalho 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 –, o Parque Tecnológico Itaipu – PTI – e o Serviço de Coloproctologia da Faculdade de Ciências Médicas – FCM – da Universidade Estadual de Campinas – UNICAMP.

O projeto de Análise de Imagens Médicas é constituído de duas fases. Na primeira fase, Identificação de Padrões, um conjunto de imagens coletadas, a partir de exames médicos, são analisadas e representadas por um conjunto de características, com base nas quais são encontrados padrões utilizando técnicas de Aprendizado de Máquina, uma subárea da Inteligência Artificial [6]. Na segunda fase, caracterizada como Classificação de Imagens, são construídos sistemas computacionais que permitem classificar novas imagens utilizando esses padrões. Dessa maneira, é possível auxiliar aos especialistas da área nos processos de tomada de decisões associados à identificação de anormalidades presentes em imagens médicas.

Neste trabalho é apresentado um estudo comparativo da utilização de atributos baseados em textura para a caracterização de tecidos cólicos e está estruturado da seguinte maneira. Na próxima seção é descrita a metodologia proposta para realizar a análise de imagens. Posteriormente é mostrado um estudo de caso utilizando um conjunto de imagens de exames de colonoscopia e os

¹ Carlos Andres Ferrero, Laboratório de Bioinformática, Universidade Estadual do Oeste do Paraná, Av. Presidente Tancredo Neves, 6731, 85866-900, Foz do Iguacu, PR, Brasil, anfer86@gmail.com.

² Huei Diana Lee, Laboratório de Bioinformática, Universidade Estadual do Oeste do Paraná, Foz do Iguacu, PR, Brasil, hueidianalee@gmail.com.

³ Cláudio Saddy Rodrigues Coy, Serviço de Coloproctologia da Faculdade de Ciências Médicas, Universidade Estadual de Campinas, Campinas, SP, Brasil.

⁴ João José Fagundes, Serviço de Coloproctologia da Faculdade de Ciências Médicas, Universidade Estadual de Campinas, Campinas, SP, Brasil.

⁵ Juvenal Ricardo Navarro Góes, Serviço de Coloproctologia da Faculdade de Ciências Médicas, Universidade Estadual de Campinas, Campinas, SP, Brasil.

⁶ Feng Chung Wu, Laboratório de Bioinformática, Universidade Estadual do Oeste do Paraná, Foz do Iguacu, PR, Brasil, Fundação Parque Tecnológico Itaipu, Foz do Iguacu, PR, Brasil, Serviço de Coloproctologia da Faculdade de Ciências Médicas, Universidade Estadual de Campinas, Campinas, SP, Brasil, wufc@pti.org.br.

resultados são comparados com um estudo prévio e, por fim, na são apresentadas as conclusões e os trabalhos futuros.

METODOLOGIA

A metodologia proposta tem como objetivo a utilização de atributos baseados em textura para a caracterização de tecidos cólicos em imagens de exames de colonoscopia e está constituída de cinco etapas: coleta do conjunto de imagens, construção do vetor de características, construção do modelo para classificação e avaliação do modelo. Essas etapas são descritas a seguir.

Etapa 1 – Coleta do Conjunto de Imagens

A utilização de sistemas de gerenciamento para o registro de exames de colonoscopia em hospitais e clínicas médicas através de imagens e laudos médicos, tem se tornado uma atividade comum. Essas imagens contêm informações sobre diversos tipos de anormalidade como polípóide, diverticular e vascular entre outras. Desse modo, é de grande importância a diferenciação de tecidos de mucosa cólica de anormalidade e tecidos de mucosa cólica sem anormalidade. Essa etapa consiste em selecionar manualmente, para cada uma das imagens consideradas, um fragmento de tecido de mucosa cólica de alguma anormalidade e um fragmento de mucosa cólica que não apresente anormalidade. Um exemplo de seleção de tecidos cólicos é ilustrado na Figura 1, a qual apresenta uma imagem real de exame de colonoscopia contendo uma anormalidade do Tipo Ip (Pólipo Protruso Pediculado, segundo a classificação morfológica de pólipos da Sociedade Japonesa de Pesquisa do Câncer Colorretal) [4][5]. Nessa imagem, são ressaltadas as duas classes de fragmentos, *a* e *b*, que representam tecidos cólicos com e sem presença de anormalidade, respectivamente.

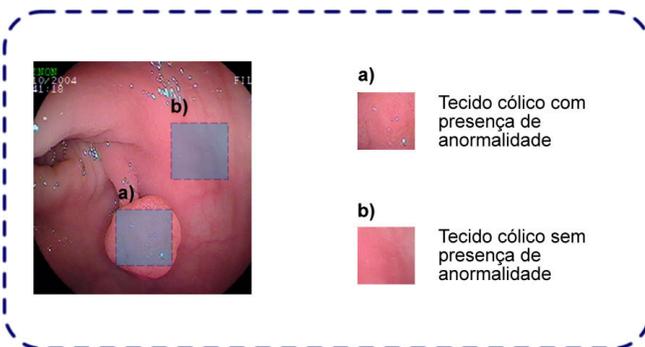


FIGURA 1

EXEMPLO DE COLETA DE IMAGENS ATRAVÉS DA SELEÇÃO DE UM TECIDO DE PÓLIPO E UM TECIDO SEM ANORMALIDADE.

Uma vez realizada a coleta dos dois fragmentos para cada uma das imagens consideradas é constituído o Conjunto de Imagens – CI – definido por

$CI = \{Im_1, Im_2, \dots, Im_n, Im_{n+1}, Im_{n+2}, \dots, Im_{2n}\}$, onde cada elemento de *CI* representa um registro de imagem e *n* o número de imagens consideradas.

Etapa 2 – Construção do Vetor de Características

No contexto de Análise de Imagens, um conjunto de características é utilizado para a representação de imagens. Essas características são comumente classificadas como baseadas em cor, textura e forma [7]. Esse processo de representação das imagens por meio de características permite que as imagens sejam entendidas não apenas como um conjunto de pontos (pixels), mas como um grupo de informações em que cada uma delas tem um valor associado. Desse modo, é possível obter uma representação da imagem no formato atributo-valor, que é o formato de entrada de dados comumente utilizado pela maioria dos algoritmos para a construção de padrões.

Nessa etapa, as imagens são representadas por um vetor de características $V = \{C_1, C_2, \dots, C_d\}$, onde *d* corresponde à dimensão do vetor, isto é, ao número de características extraídas. Cada exemplo é descrito pelo conjunto $E_i = \{A_{i,1}, A_{i,2}, \dots, A_{i,d+1}\}$ composto por *d*+1 valores de atributos, no qual o último atributo indica a classe a que o exemplo pertence e $A_{i,j}$ corresponde ao valor do atributo (característica) *j* do exemplo *i*. Com base em *CI* é construído o Conjunto de Dados Inicial – CDI – definido como $CDI = \{E_1, E_2, \dots, E_{2n}\}$, isto é, *2n* exemplos descritos por *d*+1 atributos.

Características Baseadas em Textura

Atributos baseados em textura constituem um dos aspectos mais importantes da percepção visual humana. Essas características permitem obter informações sobre propriedades de disposição e espaço dos principais elementos da imagem, por exemplo, os níveis de cinza que a compõem, sendo que, esses atributos consistem comumente, na análise de um conjunto de matrizes de co-ocorrência [2][8][9]. Essas matrizes representam as transições de níveis de cinza presentes na imagem, em que as linhas e as colunas representam o intervalo de nível de cinza e o valor $P(l,c)$, correspondente ao elemento da matriz na posição (*l*,*c*), representa a frequência de níveis de cinza *l* e *c* considerando uma distância e uma direção.

Na Figura 2 é representado um exemplo de uma imagem constituída de três níveis de cinza e a matriz de co-ocorrência correspondente, com direção de 0° e distância de 1. Por exemplo, na posição (0,1) da matriz de co-ocorrência encontra-se o valor $P(0,1) = 8$. Esse valor é obtido considerando-se que para cada elemento da matriz da imagem onde o valor é 0, se o valor do elemento adjacente à esquerda ou a direita for igual a 1, o valor $P(0,1)$ da matriz de co-ocorrência é incrementado em uma unidade. Em [7] foi proposto um conjunto de 11 atributos de textura baseados

em valores calculados a partir dessas matrizes de co-ocorrência: 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.



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° E A DISTÂNCIA 1 [2].

Etapa 3 – Construção de Modelos para Classificação

Após a extração de características é executada a etapa de construção de modelos para classificação de exemplos. Desse modo, podem ser utilizados algoritmos de IA para construir modelos a partir de grandes conjuntos de dados [6]. Posteriormente, esses modelos podem ser utilizados por sistemas computacionais para classificar situações futuras e auxiliar especialistas a tomar decisões com base na experiência acumulada através da solução bem-sucedida de problemas anteriores [11]. Nesse contexto, a partir de CDI, que contém $2n$ exemplos, é realizada a construção de modelos a partir desses dados.

Etapa 4 – Avaliação de Modelos

Na quinta etapa, os modelos construídos são avaliados através de métodos para a avaliação de modelos, com o intuito de analisar a qualidade dos padrões encontrados. Entre as diversas maneiras de se avaliar modelos têm-se o de validação cruzada e a utilização da Tabela de Contingência – TC – para o cálculo de quatro métricas de precisão, as quais são definidas a seguir [12]:

- Valor preditivo positivo – VPP – percentagem de exemplos de tecidos de pólipo do total de exemplos classificados como tecidos de pólipo;
- Valor preditivo negativo – VPN – percentagem de exemplos de tecidos sem pólipo do total de exemplos classificados como tecidos sem de pólipo;
- Sensibilidade – percentagem de exemplos classificados como tecidos de pólipo do total de exemplos de tecidos de pólipo;
- Especificidade – percentagem de exemplos classificados como tecidos sem pólipo do total de exemplos de tecidos sem pólipo.

Ainda nessa etapa, os modelos construídos são avaliados e validados em conjunto com especialistas do

domínio. Essas avaliações podem contribuir não apenas para quantificar a qualidade das características extraídas e dos modelos construídos, mas também para a escolha e a investigação de novas características presentes nas imagens que poderiam ser extraídas computacionalmente.

ESTUDO DE CASO

A metodologia apresentada foi aplicada a um conjunto de 67 imagens de exames de colonoscopia referentes a pólipos, coletadas pelo Serviço de Coloproctologia da Faculdade de Ciências Médicas – FCM – da Universidade Estadual de Campinas – UNICAMP. Inicialmente, para cada imagem, foram selecionados, manualmente, fragmentos de tecido de mucosa cólica de anormalidade e sem presença de anormalidade morfológica. Na Figura 2 foi apresentado um exemplo de seleção desses fragmentos utilizando o aplicativo MIAS [13]-[14]. A partir dessa seleção foi criado o conjunto de imagens.

Posteriormente, foi realizada a representação das imagens, conforme a segunda etapa da metodologia. Primeiramente, as imagens foram transformadas do formato original (RGB) para o formato escala de cinzas, considerando 64 níveis, pois a matriz de co-ocorrência é construída a partir do valor de intensidade de cada ponto (pixel), o qual é representado por esse formato. A partir dessa transformação utilizando o aplicativo MIAS foram construídas as matrizes de co-ocorrência para cada uma das imagens e extraídas as 11 características mencionadas anteriormente, dando origem ao conjunto de dados a ser utilizado na etapa de construção do modelo. Esse modelo foi induzido utilizando Aprendizado Simbólico Supervisionado, por meio da geração de árvores de decisão, utilizando o algoritmo J48, o qual é uma implementação do algoritmo C4.5 [15] disponibilizado na ferramenta WEKA*.

O algoritmo utilizado para construção da árvore de decisão considerou cinco atributos para a construção desse modelo. Esses atributos foram: Diferença da Entropia, Soma da Média, Variância, Soma da Variância e Diferença da Variância.

O modelo construído foi analisado do ponto de vista da precisão preditiva. Para isso, foi utilizado o método de validação cruzada, utilizando dez partições, com o objetivo de obter uma aproximação ao erro verdadeiro do modelo construído. Assim, os valores de erro médio e desvio padrão foram $0,2258$ e $0,1029$, respectivamente. Para complementar esse resultado foi construída a TC – Tabela I – e extraídas as medidas de valor preditivo positivo, valor preditivo negativo, sensibilidade e especificidade.

Com base nessa tabela, os valores de VPP, VPN, sensibilidade e especificidade foram $78,46$, $76,81$, $76,12$ e $79,10$, respectivamente.

TABELA I

TABELA DE CONTINGÊNCIA DO MODELO CONSTRUÍDO.

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

Tecido	Classificação		Total
	De pólipos	Sem pólipos	
De pólipos	51	16	67
Sem pólipos	14	53	67
Total	65	69	134

Estudo Comparativo

A partir dos resultados apresentados anteriormente foi realizado um estudo comparativo com experimentos realizados em um trabalho anterior [16]. Nesse trabalho, foi aplicada a metodologia apresentada neste trabalho, porém a segunda etapa, de extração de características, foi realizada utilizando-se a técnica Espectro de Textura [10][17], a qual tem como objetivo quantificar a frequência de pequenas estruturas dentro da imagem de cada uma das componentes RGB (vermelho, verde e azul) que a constituem. Na etapa posterior, de construção de modelos de classificação, foi utilizado método do vizinho mais próximo [18], de acordo com uma medida de distância baseada no teste estatístico Qui-Quadrado [19].

As precisões preditivas discutidas em ambos os trabalhos foram comparadas utilizando o teste estatístico *t-student* com nível de significância de 95%. Na Tabela II são apresentados os dados de média e desvio padrão, dos modelos construídos em ambos os trabalhos, bem como os *p-valores*.

Por meio da Tabela II pode ser constatado, considerando um nível de significância de 95%, que o modelo construído neste trabalho apresentou uma precisão significativamente melhor apenas em comparação com o modelo construído com a componente R, sendo que, em relação aos modelos de G e B não foi possível constatar uma melhoria estatisticamente significativa.

TABELA II
COMPARAÇÃO DA PRECISÃO PREDITIVA DOS MODELOS.

	Trabalho anterior			Trabalho atual
	R	G	B	
Média	0,3879	0,2912	0,2830	0,2258
Desvio padrão	0,1125	0,0824	0,1133	0,1029
p-valor	0,0034 [†]	0,1310	0,2487	-

Em uma outra análise, foram comparados os valores das medidas calculadas a partir da TC de ambos os trabalhos, conforme apresentado na Tabela III.

Com base nessas informações foi possível constatar um aumento dos valores de VPN e de sensibilidade do modelo apresentado no trabalho atual em relação aos modelos de R, G e B. Isso representa um aumento na probabilidade de classificar corretamente um tecido sem pólipos (VPN) e na probabilidade de que dada uma imagem de tecido de pólipos, seja classificada como tal (sensibilidade). Por outro lado os valores de VPP e de especificidade foram menores no trabalho atual do que nos modelos do trabalho anterior, representando uma diminuição na probabilidade de

classificar corretamente imagens de tecidos de pólipos (VPP) e na probabilidade de que dada uma imagem de tecido sem pólipos, seja classificada como tal (especificidade).

TABELA III

COMPARAÇÃO DAS MEDIDAS DA TABELA DE CONTINGÊNCIA DOS MODELOS.

Medida (%)	Trabalho anterior			Trabalho atual
	R	G	B	
VPP	65,96	78,00	79,59*	78,46
VPN	58,62	66,67	67,05	76,81*
Sensibilidade	46,27	58,21	58,21	76,12*
Especificidade	76,12	83,58	85,07*	79,10

Os modelos de G e B do trabalho anterior caracterizaram-se por classificar grande parte dos exemplos como sem pólipos, sendo que, quando classificado como tecido de pólipos a taxa de acerto era alta. Em contrapartida, muitas imagens de tecidos de pólipos foram classificadas como tecidos sem pólipos. Nesse sentido, o modelo construído neste trabalho permitiu aumentar em 18% a probabilidade de que imagens de tecidos de pólipos sejam classificadas corretamente. Consequentemente, o modelo melhorou a taxa de acerto de classificação dos tecidos sem pólipos, devido à diminuição de falsos negativos.

CONCLUSÕES

Os resultados apresentados e discutidos neste trabalho mostraram que o modelo construído apresentou uma melhoria na probabilidade de predição de tecidos de pólipos em comparação com os modelos construídos no trabalho anterior. A melhoria na sensibilidade, devido ao aumento de verdadeiros positivos e à diminuição de falsos negativos, permitiu evidenciar que o modelo classificou um número menor de imagens de tecidos de pólipos como sendo sem pólipos em comparação com os modelos de R, G e B.

Trabalhos futuros incluem a coleta de um número maior de imagens de tipos bem definidos de anormalidades, de modo a incrementar os padrões reconhecidos nos modelos, além de permitir que padrões relevantes sejam encontrados, a extração de outras características que identifiquem melhor cada tipo de tecido de mucosa cólica e a aplicação de outros métodos de construção de padrões que permitam encontrar modelos mais relevantes.

AGRADECIMENTOS

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

[†] p-valor menor que 0,05.

* Maior valor de precisão para cada medida.

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”, *Proceedings of Workshop on Machine Learning in Medical Applications*, 1999, 63–69.
- [2] FELIPE, J. C.; TRAINA, A. J. M.; TRAINA, C., “Retrieval by content of medical images using texture for tissue identification”, *Proceedings of 16th IEEE Symposium on Computer-based Medical Systems (CBMS 2003)*, 2003, 26–27.
- [3] FERRERO, C. A.; MALETZKE, A. G.; LEE, H. D.; WU, F. C.; NETO, A. P.; FAGUNDES, J. J.; GÓES, J. R. N., “Endia – uma ferramenta para a construção de repositórios de dados de endoscopia digestiva alta”, *X Congresso Brasileiro de Informática em Saúde (CBIS 2006)*, 2006, 1–6.
- [4] QUILICI, F. A., “Colonoscopia”, 2000.
- [5] COTRAN, R. S.; KUMAR, V.; COLLINS, T., “Patologia Estrutural e Funcional”, 2000.
- [6] MONARD, M. C.; BATISTA, G. E. A. P. A.; KAWAMOTO, S.; PUGLIESI, J. B., “Uma introdução ao aprendizado de máquina por exemplos”, *Notas de aula do Instituto de Ciências Matemáticas de São Carlos – ICMC/USP*, 1997.
- [7] 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, 740–749.
- [8] HARALICK, R.; SHANMUGAM, K.; DINSTEN, I., “Texture features for image classification”, *IEEE Transactions on Systems, Man, and Cybernetics (SMC)*, 3, 1973, 610–621.
- [9] MARQUES, P. M. D. A.; HONDA, M. H.; J. RODRIGUES, A. H.; TRAINA, A. J. M.; TRAINA, C., “Recuperação de imagens baseada em conteúdo: Uso de atributos de textura para caracterização de microcalcificações mamográficas”, *Revista Brasileira de Radiologia*, 35, 2002, 93–98.
- [10] HE, D. C.; WANG, L., “Texture unit, texture spectrum, and texture analysis”, *Proceedings of IEEE Trans. on Geoscience and Remote Sensing*, 28, 1990, 509–512.
- [11] WITTEN, H.; FRANK, E., “Data mining: practical machine learning tools and techniques”, 2005.
- [12] DORIA, U., “Introdução à Bioestatística: para simples mortais”, 1999.
- [13] FERRERO, C. A.; LEE, H. D.; CHERMAN, E. A.; COY, C. S. R.; FAGUNDES, J. J.; GÓES, J. R. N.; WU, F. C., “Utilização de Atributos Baseados em Textura para a Caracterização de Tecidos Cólicos em Imagens de Colonoscopia”, *VII Workshop de Informática Médica – WIM –*, 2007, 1–10.
- [14] FERRERO, C. A.; LEE, H. D.; WU, F. C.; COY, C. S. R.; FAGUNDES, J. J.; GÓES, J. R. N., “Identificação de padrões de anormalidades em tecidos cólicos”, *I Congresso da Academia Trinacional de Ciências*, 2006, 1–1.
- [15] QUINLAN, J. R., “C4.5: Programs for Machine Learning”, 1993.
- [16] FERRERO, C. A.; LEE, H. D.; CHERMAN, E. A.; COY, C. S. R.; FAGUNDES, J. J.; GÓES, J. R. N.; WU, F. C., “Utilização do Espectro de Textura para a Diferenciação de Imagens Cólicas em Exames Colonoscópicos”, *10º Simposio Argentino de Informática y Salud – SIS2007 –*, 36º Jornadas Argentinas de Informática – JAIIO –, 2007, 1–12.
- [17] TJOA, M. P.; KRISHNAN, S. M., “Feature extraction for the analysis of colon status from the endoscopic images”, *BioMedical Engineering OnLine*, 2, 2003, 1–17.
- [18] AHA, D. W.; KIBLER, D.; ALBERT, M. K., “Instance-based learning Algorithms”, *Machine Learning*, 6, 1991, 37–66.
- [19] SERGE, B.; MALIK, J.; PUZICHA, J., “Matching Shapes”, *IEEE International Conf. on Computer Vision (1991)*.