

# UM NOVO DESCRITOR DE FORMAS BASEADO EM ESTATÍSTICAS DO ESPAÇO DE HOUGH

SOUZA, Gustavo Botelho de  
Universidade Estadual Paulista (UNESP)  
gustavo.botelho@gmail.com

MARANA, Aparecido Nilceu  
Universidade Estadual Paulista (UNESP)  
nilceu@fc.unesp.br

**RESUMO:** Diversas atividades nos dias atuais podem ser beneficiadas pela análise automatizada de imagens como o reconhecimento biométrico de pessoas, a busca de imagens por conteúdo e o diagnóstico médico. Dentre as principais características que podem ser analisadas em uma imagem a fim de obter informações sobre seu conteúdo encontra-se a forma de objetos e regiões da mesma. Neste trabalho propõe-se um novo descritor de formas denominado HTS (*Hough Transform Statistics*), o qual se baseia no espaço de Hough para representar e reconhecer objetos em imagens por suas formas. Os resultados obtidos sobre algumas bases de imagens públicas mostram que o HTS, além de apresentar altas taxas de acerto, é muito rápido. Discute-se também uma adaptação na etapa de extração de características do descritor a qual fez com que os resultados melhorassem bastante sem deixar o método muito mais lento.

**PALAVRAS-CHAVE:** Análise de formas, Análise de imagens, Transformada de Hough.

**ABSTRACT:** *Nowadays many activities can be benefitted by the automated image analysis like biometric recognition, content-based image retrieval and medical diagnosis. Among the main features that can be analyzed from a given image in order to obtain information about its contents is the shape of objects or regions. In this paper we propose a new shape descriptor called HTS (Hough Transform Statistics), which uses the Hough space in order to represent and recognize objects in images by their shapes. The results obtained over some public databases show that HTS has high success rates and is very fast. We also discuss a modification in the feature extraction phase of the descriptor, which improves the results of the method without making the descriptor much slower.*

**KEYWORDS:** *Shape analysis, Image analysis, Hough transform.*

## INTRODUÇÃO

A habilidade que o ser humano tem no trato com imagens é extremamente grande. Desde seu surgimento, o homem desenvolveu sistemas neurais e cognitivos altamente sofisticados voltados à tarefa de “processamento de imagens” e “reconhecimento de padrões visuais” (DUDA et al., 2000).

Com o advento dos computadores, pesquisadores e empresas de todo o mundo direcionaram esforços para a automatização do processo de captura, processamento, extração de características e reconhecimento de padrões visuais presentes nas imagens digitais, dada a grande variedade de aplicações.

Inúmeras atividades realizadas por seres humanos poderiam ser (e já estão sendo) executadas em menor tempo, e em alguns casos com maior precisão, se valendo do reconhecimento automático de padrões visuais, tais como a identificação de pessoas a partir de características biométricas, o reconhecimento óptico de caracteres, a análise de sequências de DNA, a busca de imagens baseada em seus conteúdos, conhecida como CBIR (Content-Based Image Retrieval), dentre outras.

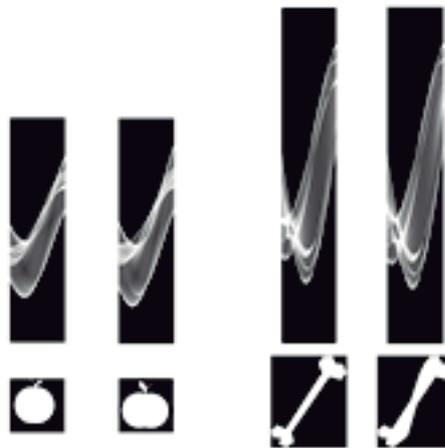
Dentre as características que podem ser analisadas a partir de uma imagem encontra-se a forma de objetos ou regiões da mesma. A forma corresponde a uma das características mais significativas que podem ser utilizadas na análise de imagens

(neste caso denomina-se este processo de análise de formas).

Apesar de o ser humano lidar com o reconhecimento de formas a todo momento, a definição do conceito “forma” não é fácil de ser elaborada. Uma importante definição é apresentada por Costa e Júnior (2000) para os quais uma forma pode ser entendida como um conjunto de pontos conectados (quer no espaço discreto ou no contínuo) os quais apresentam um padrão de distribuição (padrão visual).

Neste trabalho é apresentado um novo método (descritor) para a análise de formas, denominado HTS (*Hough Transform Statistics*) e descrito brevemente por Souza e Marana (2013), o qual se baseia em

medidas estatísticas extraídas dos espaços de Hough (DUDA e HART, 1972) gerados a partir dos pontos de borda dos objetos presentes em imagens a fim de identificá-los. Estes espaços, conforme pode-se observar na Figura 1, são muito semelhantes quando gerados a partir de objetos similares e bastante distintos caso contrário. Uma segunda versão do HTS, denominada HTSn (*HTS Neighborhood*) para facilitar sua identificação, também é apresentada. Esta versão na realidade é bem similar ao descritor original com apenas uma adaptação na etapa de extração de características a qual fez com que o desempenho do método melhorasse substancialmente em alguns experimentos.



**Figura 1:** Exemplos de espaços de Hough (matrizes acumuladoras) gerados a partir de silhuetas de maçãs (esquerda) e ossos (direita) da base de imagens MPEG-7 Part B (JEANNIN e BOBER, 1999). Cada espaço de Hough foi gerado a partir da borda da respectiva forma. As regiões mais claras do espaço de Hough indicam grande concentração de senóides as quais representam cada um dos pontos da borda da forma da imagem.

## 1. A TRANSFORMADA DE HOUGH

Um problema recorrente na análise de imagens automatizada é a detecção de retas. Ele se resume em detectar a presença de conjuntos de pontos colineares ou aproximadamente colineares em uma dada imagem. Este problema pode ser resolvido testando-se todas as retas formadas a partir de todos os possíveis pares de pontos presentes na imagem. Entretanto, testar todos os pares de pontos a fim de encontrar retas é uma estratégia pouco inteligente e demo-

rada, principalmente se o número de pontos for muito grande (HOUGH, 1962). Utilizando-se a Transformada de Hough, proposta originalmente por Paul Hough em 1962 (HOUGH, 1962) e aperfeiçoada depois por Duda e Hart (1972), é possível detectar retas nas imagens de uma maneira mais eficiente tanto em termos de recursos quanto em tempo de processamento.

Duda e Hart (1972) propuseram o uso do espaço de parâmetros  $\rho$ - $\theta$  para resolver este problema. Para mapear cada elemento da imagem para tal espaço utili-

za-se a equação da reta definida por coordenadas polares. Esta parametrização representa cada reta da imagem por meio do ângulo  $\theta$  de seu vetor normal ao eixo das abscissas e de sua distância  $\rho$  em relação à origem.

A equação da reta de acordo com esta parametrização, é:

$$\rho = x \cdot \cos(\theta) + y \cdot \sin(\theta) \quad (1)$$

Se restringirmos  $\theta$  ao intervalo  $[0; \pi]$ , então os parâmetros  $\rho$  e  $\theta$  de uma dada reta são únicos. Com esta restrição, toda reta no espaço  $x$ - $y$  corresponde a um único ponto no espaço de parâmetros  $\rho$ - $\theta$ . Cada ponto da imagem com suas coordenadas  $(x1, y1)$  é representado por uma curva senoidal obtida a partir das coordenadas do ponto e da Equação 1, no espaço  $\rho$ - $\theta$ .

Pode-se verificar que as senóides que representam pontos colineares da imagem no espaço de parâmetros  $\rho$ - $\theta$  têm um ponto de intersecção comum  $(\rho0, \theta0)$  o qual representa a reta da imagem à qual os pontos pertencem (DUDA e HART, 1972). Desta forma, para detectar retas na imagem basta encontrar posições no espaço de parâmetros onde há grande quantidade de intersecções de senóides.

## 2. O DESCRITOR HOUGH TRANSFORM STATISTICS

Baseado na Transformada de Hough proposta por Duda e Hart (1972), um novo método para análise de formas planas de objetos ou regiões presentes em imagens digitais é proposto, o qual denominamos HTS (*Hough Transform Statistics*). Este método se volta à propriedade da Transformada de Hough relacionada à detecção de retas em imagens, que faz com que pontos colineares da imagem sejam representados por senóides no espaço de Hough que se interceptam exatamente no ponto do espaço que representa o segmento de reta da imagem ao qual os pontos pertencem. Desta forma, pontos pertencentes a grandes segmentos de reta na imagem tendem a apresentar alto número de intersecções (picos) em algumas posições ao longo de suas senóides no espaço de

Hough (nas posições que representam, no espaço de Hough, os segmentos de reta da imagem aos quais os pontos pertencem). Pontos que não pertencem a segmentos de reta na imagem tendem a apresentar quantidade de intersecções bem distribuída ao longo de suas senóides e não possuem picos. Com base nisto, é possível diferenciar pontos pertencentes e não pertencentes a segmentos de reta nas imagens.

Esta diferenciação pode ser utilizada na análise de formas: dados os pontos de borda de um objeto sendo analisado e o espaço de Hough gerado com base nos mesmos, pontos pertencentes a segmentos de reta da borda do objeto apresentarão picos ao longo de suas senóides no espaço de Hough, enquanto que pontos de regiões arredondadas da borda apresentarão quantidade de intersecções bem distribuída ao longo de suas senóides. Com isto pode-se caracterizar os pontos de borda e assim diferenciar regiões da borda da forma.

O HTS se vale desta diferenciação de pontos de borda: dada a caracterização dos pontos de borda de um objeto desconhecido e a caracterização dos pontos de borda dos objetos da base de dados pode-se comparar as bordas dos mesmos (características de seus pontos) a fim de identificar o objeto desconhecido. Basicamente o método proposto apresenta, assim como outros descritores de formas, três etapas: Pré-Processamento, Extração de Características e Reconhecimento. Estas etapas são descritas nas próximas subseções.

### 2.1. Etapa de Pré-Processamento

Esta etapa corresponde, no contexto da análise formas, ao processamento de imagens. A partir de uma dada imagem contendo um objeto, realiza-se a segmentação da borda do mesmo a fim de identificá-lo pela forma (através das senóides de seus pontos de borda).

### 2.2. Etapa de Extração de Características

Dada a borda segmentada, cada ponto da borda gera uma senóide (conforme descrito na Seção 1) no espaço de parâmetros  $\rho$ - $\theta$ , o qual é representado por uma

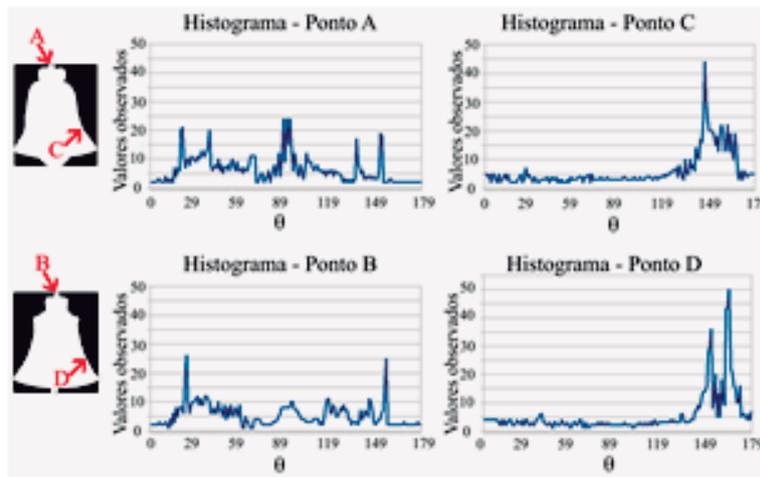
matriz acumuladora, contendo 180 colunas e um número fixo de linhas (que depende do tamanho da imagem), inicialmente zera da em todas suas posições. Cada senóide é registrada no espaço de parâmetros incrementando-se uma unidade nas posições da matriz acumuladora por onde ela passa: a partir da Equação 1 e das coordenadas  $x$  e  $y$  do ponto de borda na imagem, varia-se o ângulo  $\theta$  de  $0^\circ$  a  $179^\circ$  (com  $\Delta\theta=1^\circ$ ), encontra-se um valor arredondado de  $\rho$  (com  $\Delta\rho=1$ ) para cada valor de  $\theta$ , e incrementa-se em uma unidade a posição  $(\rho, \theta)$  da matriz acumuladora. Como mostrado anteriormente pela Figura 1, objetos semelhantes geram espaços de Hough (matrizes acumuladoras) similares enquanto que objetos diferentes produzem espaços de Hough muito diferentes.

Após registrar todas as senóides, as quais representam todos os pontos da borda do objeto no espaço de Hough, a

cada ponto  $p$  da borda é associado um histograma contendo a quantidade de intersecções encontradas ao longo de sua senóide no espaço de parâmetros (percorre-se novamente a senóide associada ao ponto  $p$  verificando-se os valores presentes nas respectivas posições da matriz acumuladora).

Como dito, pontos pertencentes a segmentos de reta na borda do objeto apresentarão picos em algumas posições de seus histogramas, enquanto que pontos pertencentes a regiões arredondadas da borda apresentarão histogramas com valores homogeneamente distribuídos por todas suas posições. A Figura 2 ilustra os histogramas associados a quatro pontos de borda de dois objetos de mesma classe (sinos) da base MPEG-7 Part B (JEANNIN e BOBER, 1999).

Associa-se então a cada ponto de borda, dado seu respectivo histograma, a



**Figura 2:** Histogramas associados a quatro pontos da borda de dois objetos de mesma classe (sinos) da base MPEG-7 Part B (JEANNIN e BOBER, 1999). Pode-se perceber que histogramas de pontos localizados na borda de um mesmo objeto, mas em regiões diferentes (A-C e B-D), são diferentes, e que pontos que pertencem a regiões respectivas em imagens de dois objetos de mesma classe (A-B e C-D) apresentam histogramas similares. Também é possível observar que pontos de borda que pertencem a grandes segmentos relativamente retos das bordas (C e D) apresentam picos bastante sobressalentes em seus histogramas, enquanto que outros pontos das bordas (como A e B) apresentam histogramas com valores mais homogeneamente distribuídos.

média e o desvio padrão desta sua distribuição. Com isto, cada ponto de borda passa a ter apenas dois valores associados a si (os histogramas são descartados). Pontos de borda que pertencem a segmentos de

reta da borda na imagem, por apresentarem picos em seus histogramas, tendem a apresentar desvios padrão maiores que os demais pontos de borda.

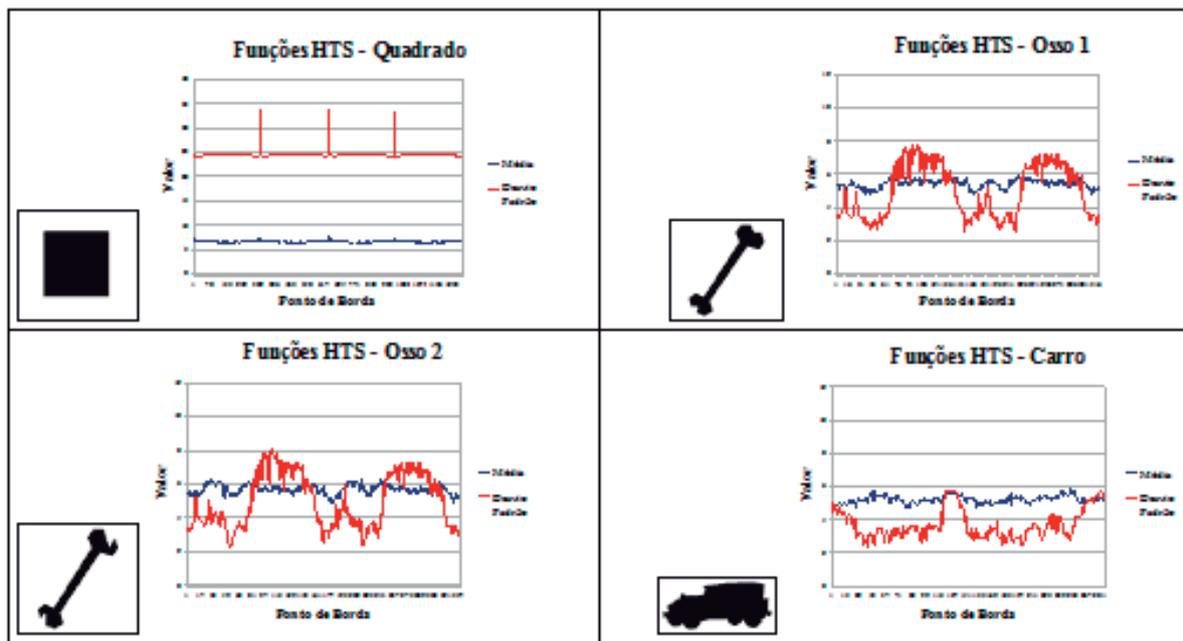
Dado um ponto inicial da borda (no

nosso caso o ponto mais ao topo da borda na imagem) e percorrendo esta em sentido horário, pode-se construir duas funções unidimensionais para o objeto sendo analisado a partir dos dois valores (média e desvio padrão) associados aos pontos de borda (cada valor gera uma função). A Figura 3 ilustra as funções obtidas para alguns objetos. Pode-se perceber que objetos de mesma classe apresentam funções similares enquanto que objetos de diferentes classes apresentam funções bem diferentes.

Ainda na Figura 3 pode-se observar que a função de desvio padrão da silhueta do quadrado apresenta quatro picos. Estes picos correspondem aos quatro vértices do quadrado: por pertencerem a dois grandes segmentos de reta da borda do quadrado eles possuem histogramas com dois grandes picos gerando alto desvio padrão para

os mesmos. Os demais pontos de borda pertencem a apenas um grande segmento de reta da borda e, portanto, apresentam desvios elevados, porém menores que os dos vértices do quadrado. Além disto, como os quatro segmentos de reta (lados do quadrado) são do mesmo tamanho, os desvios padrão dos quatro vértices são praticamente iguais e os desvios padrão dos outros pontos de borda também são muito próximos entre si.

Após encontrar as funções unidimensionais para um objeto, elas são amostradas em posições igualmente espaçadas entre si para se gerar o vetor de características do mesmo. Cada posição do vetor de características contém dois valores: a média e o desvio padrão amostrados das funções unidimensionais em uma dada posição.



**Figura 3:** Funções obtidas para silhuetas da base Kimia-216 (SEBASTIAN et al., 2004). Pode-se notar que as funções de objetos diferentes são bastante diferentes enquanto que funções de objetos de mesma classe são similares

### 2.3. Etapa de Reconhecimento

Dados dois vetores de características, a comparação dos mesmos é realizada por meio da distância  $L_1$  de forma que valores de média nas posições dos vetores de características são comparados com va-

lores de média e valores de desvio padrão são comparados com valores de desvio padrão:

$$L_1(s, r) = \sum_{i=1}^N [ |s_{im} - r_{im}| + |s_{id} - r_{id}| ] \quad (2)$$

onde  $s$  e  $r$  são os vetores de características,  $s_{im}$  e  $r_{im}$  são os valores de média presentes nas posições  $s_i$  e  $r_i$  dos vetores e  $s_{id}$  e  $r_{id}$  são os valores de desvio padrão presentes nas posições  $s_i$  e  $r_i$  dos vetores de características. O valor de  $N$  corresponde ao tamanho dos vetores.

Para determinar a classe de um objeto desconhecido, compara-se seu vetor de características com os vetores da base de dados. O objeto da base de imagens mais parecido (com menor distância) com o de teste pode ser utilizado então para determinar a classe deste (outros classificadores podem ser utilizados).

Na verdade, a comparação de dois vetores de características é realizada  $k$  vezes, onde  $k$  corresponde ao tamanho dos mesmos, isto é, ao número de posições amostradas das funções unidimensionais, rotacionando-se um dos vetores a cada comparação (trocando de posição de forma circular os dados presentes nas posições do vetor). A menor distância obtida nos  $k$  casamentos é tomada como a distância final entre os dois vetores. Isto é realizado para evitar que caso o objeto esteja rotacionado em uma dada imagem seu vetor de características seja penalizado em seus casamentos com outros vetores por também estar rotacionado (“deslocado” em algumas posições) visto que sempre se começa a construção das funções unidimensionais pelo ponto de borda que está mais no topo da forma na imagem (e continuando em sentido horário).

#### 2.4. HTSn: Histogramas Baseados na Vizinhaça das Senóides

Uma modificação na etapa de Extração de Características do método HTS fez com que suas taxas de acerto aumentassem consideravelmente. Em resumo esta adaptação consiste em, ao invés de se percorrer a senóide de um dado ponto de borda verificando-se apenas os valores presentes nas posições da matriz acumuladora por onde a senóide passa a fim de construir o histograma do ponto, observa-se também, para cada posição desta curva, os valores nas posições adjacentes do espaço de Hough. Desta forma, o valor final obser-

vado para uma dada posição da senóide corresponde à soma do valor presente na respectiva posição do espaço de Hough com todos os valores presentes nas oito posições adjacentes do espaço (vizinhança de ordem oito). Como observação, para facilitar a identificação desta versão do HTS nos experimentos deste trabalho demos o nome de HTSn (HTS *Neighborhood*) à mesma.

### 3. EXPERIMENTOS, RESULTADOS E DISCUSSÃO

O HTS e o HTSn foram testados sobre algumas bases de imagens para avaliar seus desempenhos e compará-los com os resultados obtidos por importantes descritores de formas encontrados na literatura. Além dos testes realizados sobre duas importantes bases públicas de imagens denominadas Kimia-216 (SEBASTIAN et al., 2004) e MPEG-7 Part B (JEANNIN e BOBER, 1999), onde são analisados tanto as taxas de acerto quanto os tempos de processamento dos descritores, em um terceiro experimento realizou-se uma comparação mais detalhada sobre os tempos de processamento dos dois métodos propostos e do descritor BAS (ARICA e VURAL, 2003) (os três melhores métodos segundo os resultados obtidos).

Vale observar que em todos os testes realizados os vetores de características dos métodos HTS, HTSn e BAS (ARICA e VURAL, 2003) apresentavam tamanho de 50 posições. Também é importante lembrar que na realização dos experimentos utilizou-se um computador Macintosh Power Mac G5 com processador PPC970 de 2.0 GHz (dois núcleos), 4 GB de memória RAM e com sistema operacional Debian 6.0.4. Os descritores de formas foram implementados em linguagem C.

#### 3.1. Primeiro Experimento - Base de Imagens Kimia-216

Kimia-216 (SEBASTIAN et al., 2004) é uma base pública tradicional de imagens disponível para testes de descritores de formas. Nela existem 216 imagens: 18 classes de objetos com 12 imagens por classe. Em cada imagem há a silhueta de

um objeto em preto e um fundo branco. A Figura 4 mostra algumas destas imagens. Para analisar o desempenho dos descritores testados gerou-se as curvas *Precision*

*Recall* e *Multiscale Separability* dos mesmos, típicas da comparação de descritores de formas.



Figura 4: Imagens (de 4 classes) presentes na base Kimia-216 (SEBASTIAN et al., 2004).

A Figura 5(a) ilustra as curvas *Precision-Recall* para a base Kimia-216 (SEBASTIAN et al., 2004). Quanto mais elevada a curva, melhor o descritor. Pode-se perceber que os três melhores métodos foram o BAS (ARICA e VURAL, 2003) e os dois descritores propostos: HTS e HTSn.

Por sua vez, a Figura 5(b) mos-

tra as curvas *Multiscale Separability* destes três melhores descritores para a base Kimia-216 (SEBASTIAN et al., 2004). De forma similar, quanto mais elevada a curva, melhor o método. Pode-se observar que os dois descritores propostos apresentaram resultados bastante superiores ao do BAS (ARICA e VURAL, 2003).

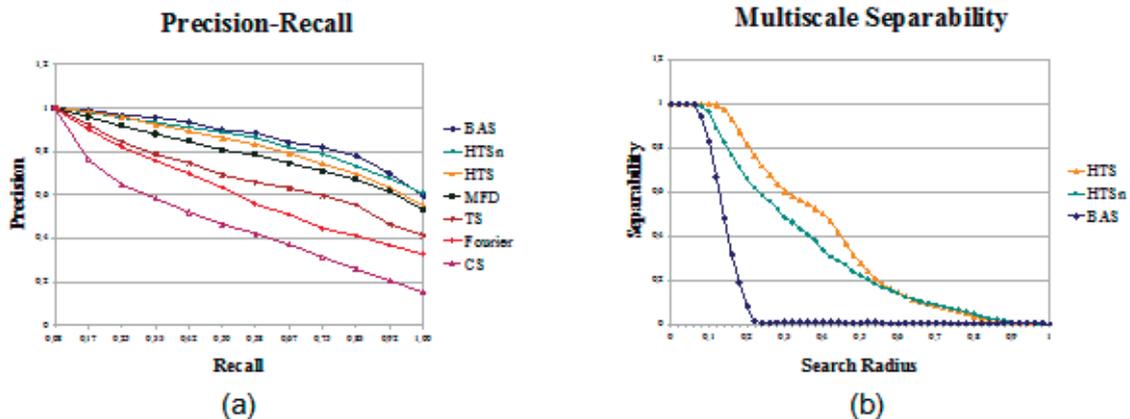


Figura 4: (a) Curvas *Precision-Recall* para os métodos testados na base Kimia-216 (SEBASTIAN et al., 2004): *Beam Angle Statistics* (BAS) (ARICA e VURAL, 2003), HTSn, HTS, *Multiscale Fractal Dimension* (MFD) (TORRES et al., 2004), *Tensor Scale* (TS) (MIRANDA et al., 2005), *Fourier* (ZHANG e LU, 2001) e *Contour Saliency* (CS) (TORRES e FALCÃO, 2007). Os descritores BAS (ARICA e VURAL, 2003), HTSn, e HTS apresentaram os melhores resultados. (b) Curvas *Multiscale Separability* para a base Kimia-216 (SEBASTIAN et al., 2004) dos três melhores métodos em termos de *Precision-Recall*. Os métodos HTS e HTSn obtiveram desempenhos muito superiores ao do BAS (ARICA e VURAL, 2003).

Em relação aos tempos de processamento utilizados por cada um dos três melhores métodos nas etapas de Extração de Características e Reconhecimento sobre a base Kimia-216 (SEBASTIAN et al., 2004), a Tabela 1 ilustra os resultados obtidos. Vale lembrar que na etapa de Extração de Características mediu-se o tempo gasto

por cada método para realizar a extração de características dos objetos das 216 imagens da base Kimia-216 (SEBASTIAN et al., 2004) e na etapa de Reconhecimento mediu-se o tempo usado por cada método para realizar as 216-216 comparações de vetores de características. O HTS foi o método mais rápido.

**Tabela 1** - Tempos aproximados em segundos tomados pelos três métodos em questão sobre a base Kimia-216 (SEBASTIAN et al., 2004) nas etapas de Extração de Características e Reconhecimento.

Método	Tempo em segundos (s) para Extração de Características	Tempo em segundos (s) para o Reconhecimento
HTS	9	6
HTSn	11	6
BAS	11	72

A partir dos resultados obtidos, pode-se verificar que os descritores HTS e o HTSn apresentaram desempenhos muito bons, similares aos do BAS (ARICA e VURAL, 2003) e melhores do que os dos outros descritores testados. Em relação às curvas *Precision-Recall*, os descritores HTS e HTSn superaram, junto com o BAS (ARICA e VURAL, 2003), os resultados dos outros descritores testados. As curvas *Precision-Recall* do descritor HTS e do HTSn ficaram ligeiramente abaixo da curva do BAS (ARICA e VURAL, 2003) mas muito próximas. A curva do HTSn se apresentou um pouco melhor que a do HTS e chegou até a superar a curva do BAS (ARICA e VURAL, 2003) para valores de *Recall* elevados. Em relação às curvas de *Multiscale Separability*, as do HTS e HTSn se configuraram muito melhores que a do BAS (ARICA e VURAL, 2003).

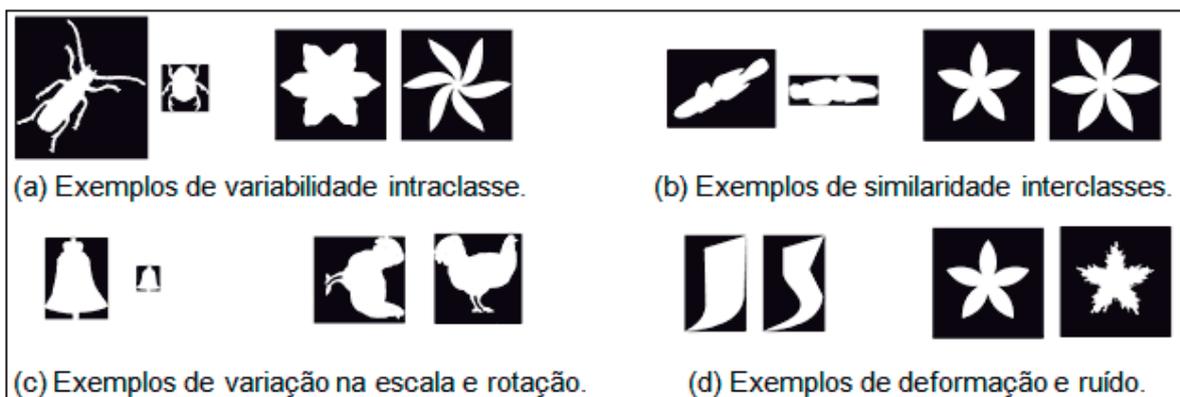
Por fim, em termos de tempo de processamento percebe-se que o HTS e o HTSn são métodos mais rápidos que o BAS (ARICA e VURAL, 2003), em especial na etapa de Reconhecimento. Pode-se provar que tanto o HTS como o HTSn apresentam complexidade linear em seu algoritmo na etapa de Extração de Características e Reconhecimento enquanto que o BAS (ARICA e VURAL, 2003) apresenta complexidade quadrática nestas duas etapas, justificando sua maior lentidão. O HTSn é mais lento que o HTS na etapa de Extração de Características por nesse método ser necessário verificar os valores das posições vizinhas no espaço de Hough ao se percorrer a senóide de um ponto de borda (no HTS verifica-se apenas os valores nas posições da matriz sob a senóide). Em relação à etapa de Reconhecimento, os dois métodos utilizam o

mesmo algoritmo (casamento usando a distância  $L_1$ ) e, portanto, apresentaram tempos iguais.

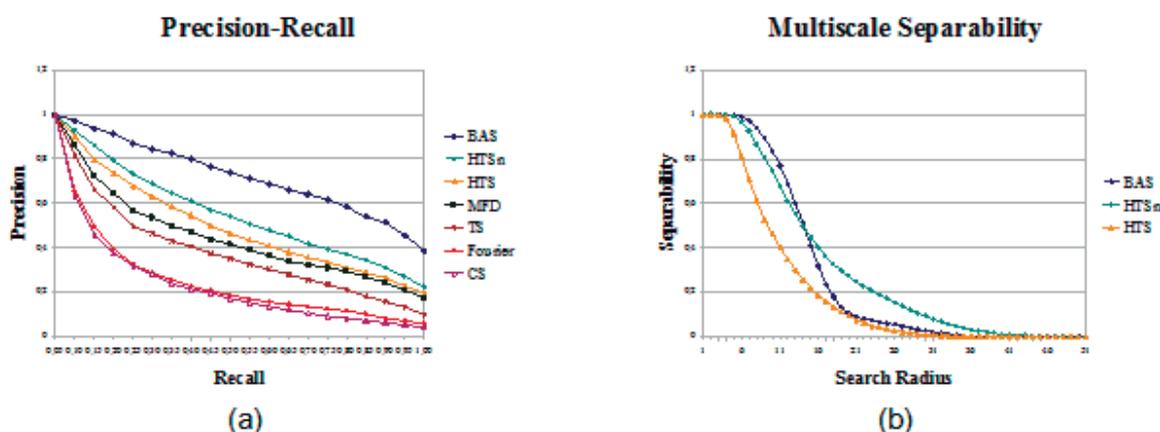
### 3.2. Segundo Experimento - Base de Imagens MPEG-7 Part B

Outra base pública de imagens disponível é a MPEG-7 CE-Shape-1 Part B (JEANNIN e BOBER, 1999). Nesta base existem 1400 imagens (divididas em 70 classes, cada classe com 20 imagens) onde o fundo é preto e a silhueta do objeto é branca. Esta base é mais complexa do que a base Kimia-216 (SEBASTIAN et al., 2004) uma vez que, além de ser maior e de possuir mais classes, o tamanho das imagens varia muito, há rotação, translação e mudança de escala nos objetos, além de deformações e ruídos. Também, há grande variabilidade intraclasse e em alguns casos grande similaridade interclasses. A Figura 6 ilustra casos destas transformações e características da base.

Os descritores HTS e HTSn bem como métodos encontrados na literatura foram testados nesta base de imagens e suas curvas *Precision-Recall* e *Multiscale Separability* foram encontradas. A Figura 7(a) mostra as curvas *Precision-Recall* obtidas e a Figura 7(b) mostra as curvas *Multiscale Separability*. Em relação às curvas *Precision-Recall*, a do BAS (ARICA e VURAL, 2003), do HTSn e do HTS foram as três melhores (nesta ordem). Nas curvas *Multiscale Separability* o HTSn apresentou desempenho equivalente ao do BAS (ARICA e VURAL, 2003) e o HTS mostrou desempenho apenas um pouco pior que o deste método.



**Figura 6:** Exemplos das imagens da base MPEG-7 Part B (JEANNIN e BOBER, 1999). Em (a), (c) e (d) cada par de imagens corresponde a imagens de uma mesma classe. Em (b) em cada par há imagens de duas classes diferentes. As imagens estão representadas proporcionalmente aos seus tamanhos reais (exceto as dos peixes e sinos que estão aumentadas para melhorar a visualização).



**Figura 7:** (a) Curvas *Precision-Recall* para os métodos testados na base MPEG-7 Part B (JEANNIN e BOBER, 1999): *Beam Angle Statistics* (BAS) (ARICA e VURAL, 2003), HTSn, HTS, *Multiscale Fractal Dimension* (MFD) (TORRES e FALCÃO, 2004), *Tensor Scale* (TS) (MIRANDA et al., 2005), Fourier (ZHANG e LU, 2001) e *Contour Saliency* (CS) (TORRES e FALCÃO, 2007). Mais uma vez o BAS (ARICA e VURAL, 2003) e os métodos propostos (HTS e HTSn) apresentaram os melhores resultados. (b) Curvas *Multiscale Separability* para a base MPEG-7 Part B (JEANNIN e BOBER, 1999) dos três melhores métodos em termos de resultados *Precision-Recall*: BAS (ARICA e VURAL, 2003), HTSn e HTS. Os desempenhos do HTSn e HTS foram próximos ao desempenho do BAS (ARICA e VURAL, 2003).

A Tabela 2 ilustra os tempos de processamento utilizados por cada um dos três melhores métodos nas etapas de Extração de Características e Reconhecimento sobre a base MPEG-7 Part B (JEANNIN e BOBER, 1999). Na etapa de Extração de Características mediu-se o tempo gasto por cada método para realizar a extração de características dos objetos das 1400 imagens da base MPEG-7 Part B (JEANNIN e BOBER, 1999) e na etapa de Reconhecimento mediu-se o tempo usado por cada método

para realizar as 1400·1400 comparações de vetores de características. O HTS foi o método mais rápido.

Tabela 2 - Tempos aproximados em segundos tomados pelos três métodos em questão sobre a base MPEG-7 Part B (JEANNIN e BOBER, 1999) nas etapas de Extração de Características e Reconhecimento.

Método	Tempo em segundos (s) para a Extração de Características	Tempo em segundos (s) para o Reconhecimento
HTS	296	221
HTSn	315	221
BAS	1157	2997

Os resultados apresentados mostram que os descritores HTS e HTSn também demonstraram desempenhos muito bons na a base MPEG-7 Part B (JEANNIN e BOBER, 1999). Suas curvas *Precision-Recall* foram as melhores dentre as curvas de todos os descritores testados, exceto em relação à do BAS (ARICA e VURAL, 2003), descritor cuja curva se apresentou um pouco melhor que as dos dois métodos propostos.

As curvas *Multiscale Separability* do HTS e do HTSn ficaram muito próximas à do BAS (ARICA e VURAL, 2003): a curva do HTSn foi praticamente equivalente à do BAS (ARICA e VURAL, 2003) e a do HTS apenas um pouco pior que esta.

Com relação ao tempo de processamento, percebe-se que o HTS e o HTSn foram muito mais rápidos que o BAS (ARICA e VURAL, 2003). Como já dito anteriormente, isto se justifica pelo fato da complexidade dos dois primeiros métodos ser linear enquanto que a do BAS (ARICA e VURAL, 2003) é quadrática.

### 3.3. Terceiro Experimento - Tempo de Processamento

O HTS e o HTSn foram mais rápidos que o BAS (ARICA e VURAL, 2003) nos experimentos com as bases Kimia-216 (SEBASTIAN et al., 2004) e MPEG-7 Part B (JEANNIN e BOBER, 1999). Para se obter uma melhor comparação dos tempos de processamento nas etapas de Extração de Características e Reconhecimento dos dois descritores de formas propostos com o BAS (ARICA e VURAL, 2003), um terceiro experimento foi realizado. Para o teste da

etapa de Extração de Características foram criadas oito imagens binárias contendo em cada uma delas um quadrado com dimensões variando de 20 pixels por lado a 2560 pixels por lado (de uma imagem para outra dobra-se o tamanho dos lados do quadrado). Mediu-se o tempo utilizado por cada método para, a partir dos pontos de borda segmentados dos quadrados (dobrando em quantidade de uma imagem para outra), gerar os vetores de características para as formas.

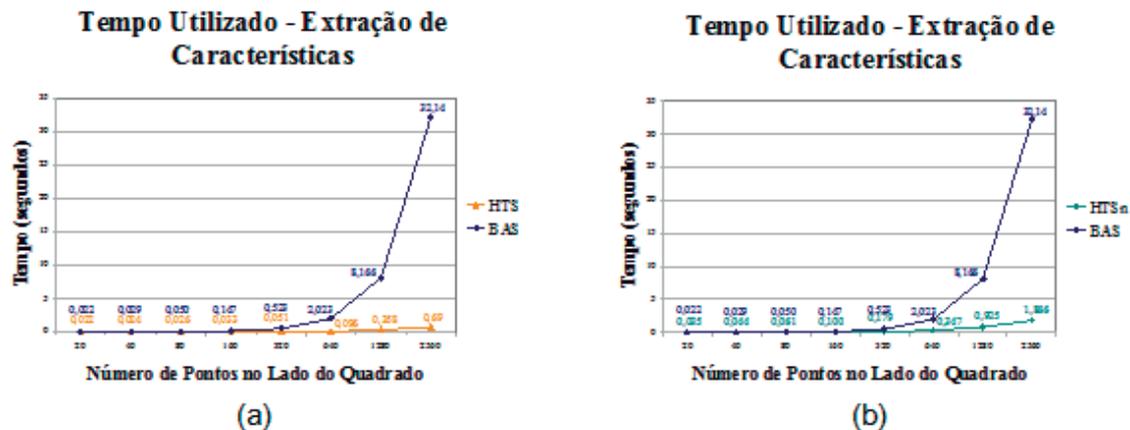
As Figuras 8(a) e 8(b) ilustram as comparações dos tempos de processamento na etapa de Extração de Características dos métodos propostos (HTS e HTSn) com os do BAS (ARICA e VURAL, 2003). Os tempos do BAS (ARICA e VURAL, 2003) são iguais nas duas imagens. Não se representou os tempos dos três métodos em uma só imagem para não dificultar a visualização.

Percebe-se que o HTS é mais rápido que o BAS (ARICA e VURAL, 2003) e conforme se aumenta o tamanho do objeto, esta diferença cresce muito. O HTSn nos testes com quadrados pequenos (até 80 pontos por lado) foi um pouco mais lento que o BAS (ARICA e VURAL, 2003), mas ao se aumentar o tamanho dos quadrados o BAS (ARICA e VURAL, 2003) se torna muito mais lento.

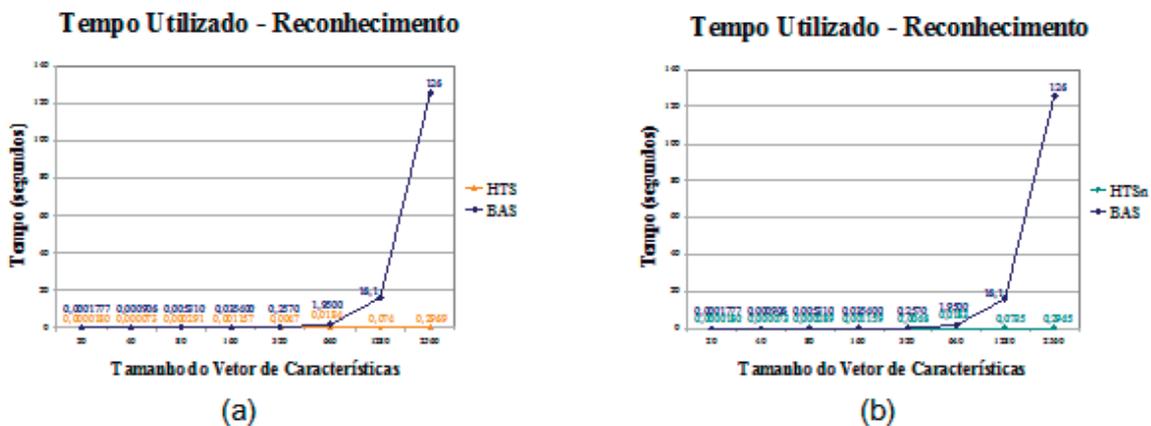
Para testar o tempo de processamento da etapa de Reconhecimento do BAS (ARICA e VURAL, 2003) e dos métodos propostos (HTS e HTSn) utilizou-se apenas a imagem do maior quadrado e a partir dela foram gerados vetores de características com dimensões cada vez maiores: o primeiro vetor continha tamanho de 20 posições

e o último 2560 posições (de um vetor para outro dobra-se o tamanho). Os tempos gastos por cada método na comparação de dois vetores de características com cada um dos comprimentos testados foram verificados. As Figuras 9(a) e 9(b) ilustram os resulta-

dos. Novamente o HTS foi muito mais rápido que o BAS (ARICA e VURAL, 2003). Por sua vez, o HTSn apresentou tempos muito próximos do HTS visto que ambos utilizam a distância  $L_1$  no casamento de vetores de características.



**Figura 8:** (a) Tempos de processamento do BAS (ARICA e VURAL, 2003) e do HTS (etapa de Extração de Características) obtidos ao se aumentar o tamanho do quadrado nas imagens. (b) Tempos de processamento do BAS (ARICA e VURAL, 2003) e do HTSn (etapa de Extração de Características) obtidos ao se aumentar o tamanho do quadrado nas imagens.



**Figura 9:** (a) Tempos de processamento do BAS (ARICA e VURAL, 2003) e do HTS (etapa Reconhecimento) obtidos ao se aumentar o tamanho dos vetores de características sendo comparados. (b) Tempos de processamento do BAS (ARICA e VURAL, 2003) e do HTSn (etapa Reconhecimento) obtidos ao se aumentar o tamanho dos vetores de características sendo comparados.

Em resumo, conforme se pode observar nos gráficos dos tempos de processamento do BAS (ARICA e VURAL, 2003) e do HTS, este último método foi muito mais rápido que aquele. Estes resultados podem ser explicados pelo fato da complexidade do BAS (ARICA e VURAL, 2003) ser quadrática e do HTS linear tanto na etapa de

Extração de Características como na de Reconhecimento.

Em relação aos gráficos comparativos do HTSn e do BAS (ARICA e VURAL, 2003), na etapa de Extração de Características o HTSn foi um pouco mais lento que BAS (ARICA e VURAL, 2003) quando se trabalhou com quadrados de pequenas di-

mensões, mas pela complexidade quadrática do BAS (ARICA e VURAL, 2003), este método logo se tornou mais lento que o HTSn ao aumentar o tamanho dos quadradinhos. Na fase de Reconhecimento o HTSn foi muito mais rápido que o BAS (ARICA e VURAL, 2003), com tempos similares ao do HTS por ambos usarem a mesmo algoritmo (estruturas de dados, função de distância, etc.).

## CONSIDERAÇÕES FINAIS

A análise automatizada de imagens pode ser uma poderosa ferramenta em muitas atividades como a busca de imagens baseada em conteúdo e o reconhecimento biométrico de pessoas. dentre as características que podem ser analisadas em uma imagem encontra-se a forma de objetos e regiões da mesma. A forma em geral é a característica mais discriminante e às vezes a única passível de análise.

Diversos descritores de formas encontram-se na literatura e cada um deles se baseia em um princípio a fim de conseguir caracterizar a forma e classificá-la posteriormente com base nas características extraídas. Dependendo de seu modo de funcionamento e das características com que o descritor trabalha ele pode obter melhores ou piores resultados bem como ser mais rápido ou mais lento. Neste contexto, novos métodos de análise de formas são propostos buscando-se cada vez mais extrair de maneira eficiente, isto é, com baixo custo computacional e consumo de recursos, as informações importantes das formas dos objetos nas imagens.

Neste trabalho é apresentado um novo descritor de formas denominado HTS (*Hough Transform Statistics*). Este descritor associa valores estatísticos aos pontos de borda do objeto sob análise com base em histogramas obtidos do espaço de *Hough* do mesmo. Através dos resultados obtidos pode-se concluir que o HTS é muito eficiente e uma boa escolha caso se necessite analisar as formas planas de objetos em imagens digitais uma vez que apresenta desempenhos melhores que os dos demais métodos da literatura testados e similares aos do bas (ARICA E VURAL, 2003) e é

muito rápido devido à complexidade linear de seu algoritmo. Outros métodos como o próprio bas (ARICA E VURAL, 2003) apresentam complexidade quadrática (e muitas vezes até superior) se tornando muito lentos em especial quando se trabalha com imagens de grandes dimensões, com alta resolução, com grandes bases de imagens ou com grandes vetores de características, uma tendência nos dias atuais dado o barateamento dos sensores de captura e das mídias de armazenamento.

Uma segunda versão do HTS com taxas de acerto ainda melhores na maior parte dos casos, denominada HTSn (*HTS Neighborhood*), também é proposta. Como o HTS, ela possui algoritmo com complexidade linear e pelos resultados obtidos pode-se concluir que também é muito eficiente superando o desempenho dos outros descritores de formas da literatura avaliados, inclusive o BAS (ARICA E VURAL, 2003) em parte dos testes.

Por fim, pode-se também concluir que os espaços de Hough são uma eficiente opção para a caracterização de formas: além de armazenarem importantes informações sobre elas, suas representações são realizadas através de matrizes acumuladoras cujo acesso é simples, direto e rápido.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ARICA, N.; VURAL, F. T. Y. BAS: a Perceptual Shape Descriptor Based on the Beam Angle Statistics. **Pattern Recognition Letters**, v. 24, n. 9-10, p. 1627-1639, 2003.
- COSTA, L. F.; JÚNIOR, R. M. C. **Shape Analysis and Classification – Theory and Practice**. Estados Unidos: CRC Press, 2000.
- DUDA, R. O.; HART, P. E. Use of the Hough Transformation to Detect Lines and Curves in Pictures. **Communications of ACM**, n. 1, p. 1-15, 1972.
- DUDA, R. O.; HART, P. E.; STORK, D. G. **Pattern Classification**. Estados Unidos: Wiley-Interscience, 2000.
- HOUGH, P. V. C. **A Method and Means for Recognizing Complex Patterns**. Patente (Estados Unidos) 3.069.654, 1962.
- JEANNIN, S.; BOBER, M. **Description of Core Experiments for MPEG-7 Motion/Shape**. Documento Técnico ISO/IEC/JTC1/SC29/WG11MPEG99/N2690,

1999.

MIRANDA, P. A. V.; TORRES, R. S.; FALCÃO, A. X. TSD: a Shape Descriptor Based on a Distribution of Tensor Scale Local Orientation. **Proceedings of Brazilian Symposium on Computer Graphics and Image Processing**, p. 139-146, 2005.

SEBASTIAN, T.; KLEIN, P.; KIMIA, B. Recognition of Shapes by Editing their Shock Graphs. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 26, p. 551-571, 2004.

SOUZA, G. B.; MARANA, A. N. HTS: a New Shape Descriptor Based on Hough Transform. **Proceedings of IEEE International Symposium on Circuits and Systems**, Pequim, 2013.

TORRES, R. S.; FALCÃO, A. X.; COSTA, L. F. A Graph-Based Approach for Multiscale Shape Analysis. **Pattern Recognition**, n. 37, p. 1163-1174, 2004.

TORRES, R. S.; FALCÃO, A. X. Contour Saliency Descriptors for Effective Image Retrieval and Analysis. **Image and Video Computing**, n. 25, p. 3-13, 2007.

ZHANG, D.; LU G. A Comparative Study on Shape Retrieval Using Fourier Descriptors with Different Shape Signatures. **Proceedings of International Conference on Intelligent Multimedia and Distance Education**, p. 1-9, 2001.

**Gustavo Botelho de Souza** é técnico em informática pelo Colégio Técnico Industrial da Universidade Estadual Paulista (UNESP), campus de Bauru, e bacharel em Ciência da Computação pela mesma universidade. Atualmente é aluno de mestrado (em Ciência da Computação) da UNESP, campus de São José do Rio Preto. Tem interesse nas áreas de pesquisa: análise de imagens, visão computacional e biometria.

**Aparecido Nilceu Marana** é graduado em Matemática pelo Instituto de Biociências, Letras e Ciências Exatas, UNESP, São José do Rio Preto. Mestre em Ciência da Computação pelo Instituto de Computação da UNICAMP, Campinas, e doutor em Engenharia Elétrica pela Faculdade de Engenharia Elétrica e de Computação da UNICAMP, Campinas. Realizou pós-doutorado na Michigan State University na área de biometria. É livre-docente em Sistemas Biométricos pela Universidade Estadual Paulista. Também tem interesse nas áreas de pesquisa: análise de imagens, visão computacional e biometria.