

Anais do VIII Workshop de Visão Computacional - ISSN 2175-6120



Goiânia-GO
Brasil
27 a 30 de maio
2012

Comparação de Descritores de Forma aplicados na Classificação de Grãos de Café

Pedro Ivo de Castro Oyama¹; Evandro Luís Linhari Rodrigues²; Lúcio André de Castro Jorge³

- 1- Mestrando, Escola de Engenharia de São Carlos - USP, São Carlos – SP, pedro.oyama@gmail.com
- 2- Professor, Escola de Engenharia de São Carlos - USP, São Carlos – SP, evandro@sc.usp.br
- 3- Pesquisador, Embrapa Instrumentação, São Carlos – SP, lucio@cnpdia.embrapa.br

Abstract

In a previous work a computer vision system for coffee beans classification was proposed as a solution to replace the manual procedures, which have some serious drawbacks, currently adopted by quality analysis laboratories. The proposed system uses image processing algorithms and artificial neural networks to analyse colour and shape features of the beans. Now, aiming to enhance the performance of the system, a comparative study on shape descriptors has been conducted. The results of five descriptors, along with some other basic descriptors, applied to coffee beans classification using neural networks were compared: signatures, Fourier descriptors, generic Fourier descriptors, autoregressive model and Zernike moments. The analysed descriptors did not produce satisfactory results, suggesting that other descriptors that can better capture small differences between shapes should be sought.

1. Introdução

Desde o século XIX o Brasil tem se destacado na produção e exportação do café, e atualmente ocupa a primeira posição mundial tanto na produção como na exportação do produto, contando com cerca de 30% do total das exportações mundiais do café[4][5]. Devido à alta exigência do mercado internacional por produtos de qualidade, o café brasileiro exportado necessita passar por um rígido controle de qualidade, o qual deve ser preciso e rápido dado o grande volume do produto que deve ser avaliado. Esse controle diz respeito tanto ao café em pó quanto ao grão antes da torrefação e da moagem.

A análise do café em grãos é dada através da inspeção dos atributos físicos de um lote de grãos baseando-se principalmente em características morfológicas das frações componentes da amostra. Dentre os atributos físicos do lote destacam-se as dimensões, a forma, a presença de impurezas tais como restos vegetais, pedras, partículas de solo, frações de grãos menores que sua metade, etc. [1].

Em geral, os métodos automáticos de classificação aparecem em máquinas e sistemas para aplicação no processo de produção de produtoras de sementes. No

laboratório, a análise de amostras continua sendo feita de forma subjetiva e manual, não conseguindo acompanhar o ritmo da produção.

Desta forma, o projeto de uma máquina para classificação automática de café em grãos e seus primeiros resultados foram apresentados em [7]. A máquina proposta utiliza redes neurais artificiais para identificar padrões de cor e de forma apresentados pelas diferentes classes de grãos que contribuem na composição da qualidade da bebida.

No presente trabalho foi realizado um estudo comparativo de alguns descritores de forma aplicados na classificação de grãos de café, visando aperfeiçoar os resultados. Na literatura encontram-se vários artigos comparando o desempenho de descritores de forma aplicados a imagens genéricas, como pode-se citar [9] e [11], mas não são facilmente encontrados trabalhos aplicados a grãos de café especificamente.

Foram implementados e comparados descritores de forma encontrados na literatura que apresentam características importantes para o problema prático de classificação de grãos de café: invariância a rotação, baixa complexidade computacional, e não exigência de um alto número de elementos no vetor de características. Também foram comparados descritores mais básicos, facilmente obtidos a partir do contorno da forma.

Na seção 2 serão apresentados sucintamente os descritores comparados neste estudo e a sua teoria. Na seção 3 serão mostrados os procedimentos e materiais utilizados na condução dos experimentos para determinar a eficácia de cada um dos descritores. Na seção 4 serão apresentados e comentados os resultados obtidos. E, finalmente, na seção 5 serão apresentadas as conclusões obtidas deste trabalho e as possibilidades para trabalhos futuros.

2. Fundamentação Teórica

Os descritores de forma comparados neste trabalho são: assinaturas, descritores de Fourier, modelo autorregressivo, momentos de Zernike e descritores genéricos de Fourier. Junto com eles também foram utilizados alguns descritores que podem ser considerados mais básicos.

2.1 Assinaturas

Assinaturas são uma função 1D calculada a partir dos pontos do contorno de uma forma. Geralmente elas são normalizadas para se obter invariância a escala. Existem várias abordagens para calculá-las, como a tangente do ângulo, a área, comprimento da corda e a distância do centroide [11]. Esta última foi a utilizada neste trabalho.

As coordenadas (\bar{x}, \bar{y}) do centróide de uma figura representada pela região R contendo N pixels são dadas por (1) e (2) [6].

$$\bar{x} = \frac{1}{N} \sum_{(x,y) \in R} x \quad (1)$$

$$\bar{y} = \frac{1}{N} \sum_{(x,y) \in R} y \quad (2)$$

Portanto, a i -ésima assinatura $z(i)$ é calculada pela equação (3), sendo $(x(i), y(i))$ as coordenadas do i -ésimo ponto da borda do objeto, com $i = 1, \dots, N$ e N sendo o número de pontos presentes na borda.

$$z(i) = \sqrt{(x(i) - \bar{x})^2 + (y(i) - \bar{y})^2} \quad (3)$$

2.2 Descritores de Fourier

Utilizando-se a transformada de Fourier é possível se representar qualquer sinal como uma soma de senóides multiplicadas por diferentes coeficientes[3]. Ela pode ser utilizada na representação de forma, bastando tratar um conjunto de assinaturas como sendo um sinal e aplicar sobre ele a transformada. Os coeficientes das senóides obtidas passam então a ser chamados de descritores de Fourier. Características típicas dos descritores de Fourier são que geralmente a forma geral da figura é relativamente bem definida a partir de alguns dos termos de menor ordem da expansão, e as magnitudes dos termos são invariantes a rotação.

Os descritores de Fourier $F(u)$ de um conjunto de N assinaturas $z(i)$ são obtidos pela equação (4):

$$F(u) = \frac{1}{N} \sum_{i=0}^{N-1} z(i) e^{-j2\pi ui/N} \quad (4)$$

Para $u = 0, 1, \dots, N-1$

2.3 Modelo Autorregressivo

O modelo autorregressivo [2] é uma técnica de representação de forma invariante a rotação e a escala, que utiliza as distâncias do centroide da forma até os

pontos da borda, as quais são chamadas de raio, para calcular seus elementos. O vetor de características é formado pelos parâmetros de uma regressão linear aplicada sobre um conjunto de amostras de raios, de forma que duas amostras consecutivas sejam separadas por um mesmo ângulo $\Delta\varphi = 2\pi/N$, sendo N o número de amostras utilizadas.

O modelo sugere que o conjunto de amostras de raios pode ser dado pela seguinte composição linear:

$$r_t = \alpha + \sum_{j=1}^m \theta_j r_{t-j} + \sqrt{\beta} w_t \quad t = 1, \dots, N \quad (5)$$

Sendo,

m : Ordem do modelo

r_t : Amostra do raio corrente

r_{t-j} : Raio situado j posições anteriores ao raio corrente

$\theta_1, \dots, \theta_m$: Coeficientes da autorregressão a serem estimados

$\sqrt{\beta}$: Constante a ser estimada

α : Constante a ser estimada

$\{w_t\}$: Uma sequência aleatória de amostras independentes com média 0 e variância 1

Considera-se r_t uma função periódica, de modo que $r_t = r_{t+N}$.

Os parâmetros utilizados como descritores de forma podem ser estimados segundo as equações (6) e (7).

$$\beta = \frac{1}{N} \sum_{t=1}^N (r_t - \alpha - \sum_{j=1}^m \theta_j r_{t-j})^2 \quad (6)$$

$$\begin{bmatrix} \theta_1 \\ \vdots \\ \theta_m \\ \alpha \end{bmatrix} = \begin{bmatrix} \sum_{t=1}^N r_{t-1}^2 & \cdots & \sum_{t=1}^N r_{t-1} r_{t-m} & \sum_{t=1}^N r_{t-1} \\ \vdots & \ddots & \vdots & \vdots \\ \sum_{t=1}^N r_{t-m} r_{t-1} & \cdots & \sum_{t=1}^N r_{t-m} & \sum_{t=1}^N r_{t-m} r_t \\ \sum_{t=1}^N r_{t-1} & \cdots & \sum_{t=1}^N r_{t-m} & N \end{bmatrix}^{-1} \begin{bmatrix} \sum_{t=1}^N r_{t-1} r_t \\ \vdots \\ \sum_{t=1}^N r_{t-m} r_t \\ \sum_{t=1}^N r_t \end{bmatrix} \quad (7)$$

A razão $\alpha/\sqrt{\beta}$ pode ser interpretada como a relação sinal-ruído da forma, e os parâmetros $\{\theta_1, \dots, \theta_m\}$ estabelecem a função que determina o seu contorno. Assim sendo, o conjunto $\{\frac{\alpha}{\sqrt{\beta}}, \theta_1, \dots, \theta_m\}$ pode ser utilizado como um vetor de características para descrever o contorno de uma forma.

2.4 Momentos de Zernike

Os momentos de Zernike [8] são um conjunto de momentos complexos formados através da projeção de uma função $f(x, y)$, mapeada no círculo unitário $x^2 +$

$y^2 \leq 1$, em uma família de polinômios complexos - os polinômios de Zernike.

As principais características dos momentos de Zernike são que eles são invariantes a rotação, e por se tratarem de momentos ortogonais, contam com um mínimo de redundância de informação.

O cálculo dos momentos de Zernike para uma imagem digital $f(x, y)$ quadrada de lado N , é definido pela equação (8):

$$Z_{n,m} = \frac{n+1}{\pi(N-1)} \sum_{x=1}^N \sum_{y=1}^N f(x,y) V_{n,m}(\rho, \theta) \quad (8)$$

Com $\rho = \frac{\sqrt{x^2+y^2}}{N}$ e $\theta = \tan^{-1}(y/x)$. n é um número natural chamado de ordem do momento e m é denominado repetição, sendo que $n - |m|$ é par e $|m| < n$.

$V_{n,m}$ é a família de polinômios de Zernike, definida por (9).

$$V_{n,m}(\rho, \theta) = R_{n,m}(\rho) e^{-jm\theta} \quad (9)$$

Com

$$R_{n,m}(\rho) = \sum_{s=0}^{n-\frac{|m|}{2}} (-1)^s \frac{\rho^{n-2s} (n-s)!}{s! \left[\frac{n+|m|}{2} - s \right]! \left[\frac{n-|m|}{2} - s \right]!}$$

Para seu uso como descritores de forma, são utilizadas as magnitudes dos momentos de até certa ordem pré-definida. O número de momentos da ordem 0 até a ordem n é dado por $\left(\frac{n}{2} + 1\right)(n+1)$.

2.5 Descritores de Fourier Genéricos

Uma das desvantagens da transformada de Fourier 2D é que ela não é invariante a rotação, pois girar uma imagem em θ acarreta a mesma rotação θ no espectro da frequência. Os descritores genéricos de Fourier (GFDs) [10] foram propostos para contornar esse problema, utilizando-se de coordenadas polares ao invés de retangulares.

Desta forma, para se calcular os GFDs, primeiramente é aplicada uma transformada de Fourier polar modificada (MPFT) sobre a forma. Essa transformada trata uma forma descrita em coordenadas polares como se fosse uma forma em coordenadas retangulares, como ilustrado na figura 1. Então aplica-se a transformada de Fourier 2D discreta sobre ela.

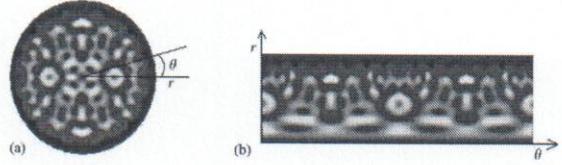


Figura 1. Retirada de [10] (a) Uma imagem em coordenadas polares (b) a mesma imagem em coordenadas polares tratada como coordenadas retangulares.

Dessa forma, a MPFT é dada pela equação (10):

$$MPFT(\rho, \varphi) = \sum_r \sum_i f(r, \theta_i) e^{-j2\pi\left(\frac{r}{R}\rho + \frac{2\pi i}{T}\varphi\right)} \quad (10)$$

Onde ρ e φ são respectivamente as frequências radial e angular. E $0 \leq r = \sqrt{(x-\bar{x})^2 + (y-\bar{y})^2} < R$ (sendo (\bar{x}, \bar{y}) o centroide da forma), $\theta_i = \frac{i2\pi}{T}$ ($0 \leq i < T$). $0 \leq \rho < R$ e $0 \leq \varphi < T$. R e T são, respectivamente, o número de frequências radiais e angulares a serem utilizadas.

Para se obter invariância quanto à rotação e escala, uma normalização se faz necessária. Assim, os GFDs são definidos como segue:

$$GFD = \left\{ \frac{MPFT(0,0)}{\text{Área}}, \frac{MPFT(0,1)}{MPFT(0,0)}, \dots, \frac{MPFT(0,n)}{MPFT(0,0)}, \dots, \frac{MPFT(m,0)}{MPFT(0,0)}, \dots, \frac{MPFT(m,n)}{MPFT(0,0)} \right\}$$

Sendo *Área*, a área do círculo que circunscribe a forma.

2.6 Descritores Básicos

Os descritores de forma aqui chamados de básicos utilizados neste estudo são: área, perímetro, largura, comprimento e excentricidade. Os dois primeiros são obtidos por meio do contorno da forma, enquanto o cálculo dos outros três é dado a seguir, conforme descrito em [6].

• Largura e comprimento

Temos que os momentos centrais de ordem (p,q) de uma figura representada pela região R contendo N pixels são calculados pela expressão (11)

$$\mu_{p,q} = \sum_{(x,y) \in R} (x-\bar{x})^p (y-\bar{y})^q \quad (11)$$

Sendo \bar{x} e \bar{y} as coordenadas do centroide.

A partir dos momentos é possível se calcular a orientação de um objeto, ou seja, o ângulo θ (figura 2) com o qual ele possui o menor momento de inércia. θ é dado pela equação (12).

$$\theta = \arctan\left(\frac{\mu_{1,1}}{\mu_{2,0} - \mu_{0,2}}\right) \quad (12)$$

Pode-se adotar um sistema alternativo de coordenadas - eixos α e β - que sejam respectivamente paralelo e perpendicular à orientação do objeto, como ilustrado na figura 2.

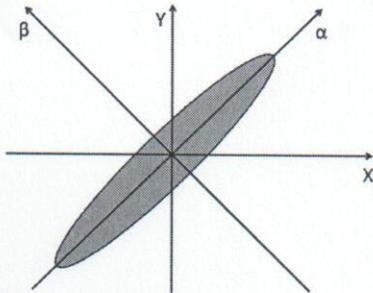


Figura 2. Imagem adaptada de [6]. Orientação do objeto e sistema alternativo de coordenadas.

Assim, as coordenadas α e β podem ser calculadas a partir das coordenadas x e y utilizando as seguintes equações:

$$\alpha = x \cos \theta + y \sin \theta \quad (13)$$

$$\beta = -x \sin \theta + y \cos \theta \quad (14)$$

Encontrando o menor e maior valores de α (α_{min} e α_{max} respectivamente) e o menor e maior valores de β (β_{min} e β_{max} respectivamente) dos pontos da região R pode-se definir o comprimento e a largura da forma:

$$Largura = \text{MIN}(\alpha_{max} - \alpha_{min}, \beta_{max} - \beta_{min}) \quad (15)$$

$$Comprimento = \text{MAX}(\alpha_{max} - \alpha_{min}, \beta_{max} - \beta_{min}) \quad (16)$$

- **Excentricidade**

A excentricidade de uma forma é calculada por

$$\varepsilon = \frac{(\mu_{2,0} - \mu_{0,2})^2 + 4\mu_{1,1}^2}{\text{Área}} \quad (17)$$

3. Material e Métodos

3.1 Amostras e Classificação

O sistema de classificação de grãos e impurezas adotado foi o utilizado pela Cooperativa Regional Cafeicultores de Guaxupé Ltda. (Cooxupé), a qual forneceu amostras de grãos sadios e com defeitos e impurezas já separados e classificados por especialistas da cooperativa.

Das diferentes classes de grãos e impurezas identificadas pela Cooxupé, foram selecionadas nove que podem ser distinguidas pela forma, sendo estas as empregadas no processo de classificação deste estudo. As nove classes são apresentadas na Figura 3.

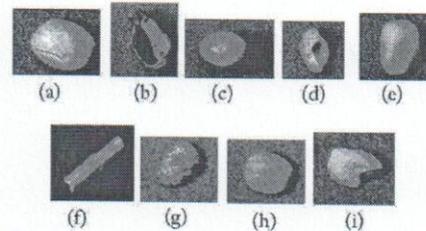


Figura 3. Classes de grãos e impurezas. (a) cabeça, (b) casca, (c) coco, (d) concha, (e) marago, (f) pau, (g) pedra, (h) perfeito, (i) quebrado.

3.2 Segmentação e extração de contornos

Para a captura de imagens, segmentação e extração de contornos foram utilizados os mesmos equipamentos e procedimentos descritos em [7], com a exceção de que o sistema de iluminação por lâmpadas fluorescentes foi substituído por LEDs brancos, contribuindo para uma distribuição de luz mais homogênea.

A imagem capturada de uma amostra é primeiramente segmentada e binarizada pela aplicação de um simples *thresholding*. Os diferentes objetos são então separados por um algoritmo de rotulação, possibilitando que os contornos sejam finalmente extraídos.

3.3 Conjunto de experimentos

Para se comparar a eficácia dos descritores apresentados na classificação de grãos de café por forma, foi realizado um conjunto de experimentos. Cada um deles consistiu na composição de um conjunto de amostras de grãos e impurezas representados por vetores de características formados por elementos de somente um descritor. Esse conjunto de amostras foi então submetido ao método da validação cruzada com 10 *folds*, sendo 80% das amostras utilizadas para treinamento e 20% para a validação, utilizando-se redes neurais do tipo Perceptron Multicamadas.

O algoritmo de treinamento utilizado foi o *backpropagation*, com taxa de aprendizagem de 0,1, momento de 0,7 e 5.000 épocas como condição de parada. Foi utilizado um conjunto de 1414 amostras de grãos e impurezas das nove classes apresentadas na figura 3. A topologia de cada uma das redes neurais apresenta três camadas: uma de entrada (com um neurônio para cada elemento do vetor de características), uma de saída (um neurônio para cada uma das nove classes dos grãos), e uma escondida. O número N_{ce} de neurônios da camada escondida foi calculado para cada experimento, segundo a fórmula seguinte, arredondando-se para baixo.

$$N_{ce} = (N_e + N_s)/2$$

N_e : Número de neurônios na camada de entrada.

N_s : Número de neurônios na camada de saída.

Para cada um dos descritores foram realizados 3 experimentos (experimentos #1 a #15), utilizando em cada um deles um número diferente de elementos no vetor de características. Esses experimentos foram então repetidos adicionando-se ao vetor de características os descritores básicos (experimentos #1* a #15*).

Além dos experimentos descritos acima, mais dois foram realizados (experimentos #16 e #17): um utilizando somente os descritores básicos e outro utilizando a variância das assinaturas em conjunto com os descritores básicos. A tabela 1 resume cada um dos experimentos realizados.

Tabela 1 – Resumo dos experimentos realizados

Exp. #	Vetor de características
1, 2 e 3	20, 30 e 40 assinaturas
4, 5, 6	20, 30 e 40 primeiros descritores de Fourier
7, 8 e 9	Coefficientes do modelo AR de ordens 10, 20 e 30
10, 11 e 12	Momentos de Zernike até ordem 7, 10 e 12
13, 14 e 15	GFD com R=4 e T= 7, R=4 e T=9 e R = 5 e T = 10
16	Variância das assinaturas e descritores básicos
17	Descritores Básicos
1* a 15*	Respectivamente os mesmos descritores dos experimentos 1 a 15 em conjunto com os descritores básicos

As assinaturas utilizadas são angularmente equidistantes e foram normalizadas, e os coeficientes do modelo autorregressivo foram calculados utilizando uma amostragem de 40 pontos do contorno da forma.

4. Resultados e discussões

Na tabela abaixo são apresentadas as taxas de acerto (T.A. - percentual de amostras corretamente classificadas) obtidas em cada um dos experimentos.

Tabela 2 – Taxas de acertos em % (T.A.) dos experimentos realizados (#).

#	T.A.	#	T.A.	#	T.A.	#	T.A.
1	36.99	9	18.88	1*	47.17	9*	39.60
2	36.92	10	49.86	2*	48.66	10*	50.14
3	36.00	11	49.58	3*	47.52	11*	48.73
4	46.82	12	49.22	4*	47.31	12*	50.28
5	43.42	13	42.57	5*	43.85	13*	46.25
6	38.90	14	42.22	6*	42.22	14*	45.83
7	27.86	15	41.80	7*	48.80	15*	42.93
8	21.00	16	52.62	8*	43.70	17	52.83

O melhor resultado foi obtido utilizando-se somente os descritores básicos. Diferentemente dos outros descritores, eles não definem como é uma forma, mas extraem informações importantes sobre estas, as quais conseguem diferenciar as classes de grãos. Dessa maneira, informações importantes estão condensadas em apenas cinco descritores, contribuindo para uma melhor diferenciação pela rede neural. Os outros descritores possuem um grande número de elementos, mas cada um deles, separadamente, carrega poucas informações significativas sobre a forma, sendo que o conjunto de elementos não filtra as características realmente importantes na discriminação das classes de grãos de café. Por esse mesmo motivo, os momentos de Zernike apresentaram um resultado superior em comparação aos outros, uma vez que projetam a imagem em polinômios ortogonais, o que reduz a redundância de informações em cada descritor.

Os descritores de Fourier obtiveram melhores resultados para um número menor de descritores pelo fato dos coeficientes de mais baixa frequência carregarem a maior parte das informações, visto que as assinaturas dos grãos dificilmente variam muito abruptamente de valor. Isso atribui valores pouco significativos às componentes de alta frequência, sendo estas também muito sensíveis a ruídos adquiridos nos processos entre a aquisição da imagem e a extração da borda.

A análise da forma pelo seu espectro de frequência, como é feito pelos descritores de Fourier e os descritores genéricos de Fourier, não produziu bons resultados, indicando que as componentes de frequência não conseguem exaltar os atributos mais importantes na caracterização dos diferentes tipos de grãos.

Uma provável causa que contribuiu para a baixa eficácia apresentada pelas assinaturas foi o fato de elas serem invariantes a rotação, característica essencial para o problema abordado. Uma possível modificação para

minimizar o problema seria utilizar um algoritmo para definir a primeira assinatura da sequência, de acordo com a orientação do objeto, por exemplo.

Os coeficientes do modelo autorregressivo apresentaram resultados muito ruins, principalmente para ordens maiores. Como os tamanhos dos objetos variam muito (de minúsculas pedras com 40 *pixels* a pedaços de madeira com mais de 250 *pixels*), não foi possível estabelecer uma taxa de amostragem de *pixels* da borda que pudesse ser utilizada por objetos muito pequenos e que ao mesmo tempo apresentasse uma boa resolução para objetos grandes. Como este problema pode ter contribuído sobremaneira para o baixo desempenho do descritor, será necessário analisar esse resultado com mais cuidado.

A tabela 3 apresenta a matriz de confusão obtida pelo experimento com melhor resultado (#17).

Tabela 3 – Matriz de confusão do experimento #17 (em %). (a) cabeça, (b) casca, (c) coco, (d) concha, (e) marago, (f) pau, (g) pedra, (h) perfeito, (i) quebrado

a	b	c	d	e	f	g	h	i	
34	1	7	5	6	0	0	45	1	a
4	36	5	23	4	12	2	7	6	b
5	5	17	32	10	0	14	12	4	c
1	10	10	57	0	3	0	6	13	d
14	4	1	2	61	1	0	17	1	e
0	13	1	7	1	71	0	0	6	f
0	1	7	4	0	0	75	0	13	g
11	1	1	2	2	0	0	82	0	h
1	3	7	38	0	7	11	0	34	i

O padrão da matriz apresentada se repetiu de forma muito semelhante nos outros experimentos. Percebe-se que os objetos com contornos muito diferentes (pedras e paus) foram bem identificados, enquanto há uma confusão muito grande nas classes muito semelhantes, como casca, concha e quebrado, por exemplo, as quais apresentam contornos irregulares e tamanhos parecidos.

O experimento com melhor desempenho apresentou taxa de acerto de 52,83%, o que é um resultado inaceitável para um sistema de classificação para aplicações práticas. Sendo assim, é necessário se buscar por descritores que sejam capazes de destacar os detalhes das formas, já que os estudados aqui não conseguiram, e essa é uma das exigências do problema.

5. Conclusões e Trabalhos Futuros

Os resultados revelaram que a capacidade de resolver o problema abordado dos descritores comparados está muito abaixo do exigido, principalmente por não serem capazes de reconhecer pequenas diferenças entre as formas, e por não captarem de forma compacta as características que discriminam as classes de grãos e

impurezas. Assim, trabalhos futuros serão direcionados à pesquisa de descritores com essas características. E para se atingir o objetivo final de se desenvolver um sistema para classificação de grãos de café, serão realizados estudos mais profundos para se descrever os grãos pela sua coloração, e então, serão desenvolvidos métodos para cruzar os resultados das análises de forma e cor.

6. Agradecimentos

Agradecemos ao apoio financeiro da Cooxupé, Guaxupé, MG.

7. Referências

- [1] BRASIL. Ministério da Agricultura e Reforma Agrária. Regras para análise de sementes. Brasília, 1992. 365p.
- [2] DUBOIS, S. R.; GLANZ, F. H., Na Autoregressive Model Approach to Two-Dimensional Shape Classification, IEEE Transactions On Pattern Analysis and Machine Intelligence, vol. PAMI-8, NO. 1, janeiro de 1996.
- [3] GONZALEZ, R.; WOODS, R., Digital Image Processing, Upper Saddle River: Prentice Hall. 2ª edição, pp.148-154.
- [4] ICO – International Coffee Organization. Total production of exporting countries. 2012. Disponível em <www.ico.org>. Acesso em 26 abr. 2012.
- [5] ICO – International Coffee Organization. Exports by exporting countries to all destinations. 2012. Disponível em <www.ico.org>. Acesso em 26 abr. 2012.
- [6] JAIN, A. K. , Fundamentals of Digital Image Processing, Englewood Cliffs: Prentice Hall. p. 392.
- [7] OYAMA, P. I. C.; Jorge, L. A. C.; GOMES, C. C., Sistema de Visão Computacional para Classificação de Grãos de Café por Cor e Forma. VII Workshop de Visão Computacional. pp.202-207.
- [8] TEAGUE, M.R., Image Analysis via the General Theory of Moments, J. Optical Soc. Am., vol. 70, pp. 920-930, Aug. 1980.
- [9] ZHANG, D.; LU, G., Evaluation of MPEG-7 Descriptors Against Other Shape Descriptors. Multimedia Systems, issue 9. 2003. Pp. 15-30.
- [10] ZHANG, D.; LU, G., Generic Fourier Descriptor for Shape-based Image Retrieval. In Proc. of IEEE International Conference on Multimedia and Expo (ICME2002), Vol.1, pp.425-428, Lausanne, Switzerland, August 26-29, 2002.
- [11] ZHANG, D.; LU, G., Review of shape representation and description techniques. Pattern Recognition, 37:1-19,2004.