

Methodology to Classify Coffee Beans Samples through Shape, Colour and Texture Descriptors

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 — One of the problems the coffee beans distributors face nowadays is providing reliable qualitative analyses of their product with the speed the production process demands. Focusing on solving this problem, a computational methodology to classify coffee beans samples using digital images is proposed. The methodology is based on using neural networks classifiers to analyse a bean under three different perspectives: shape, colour and texture. In the first one a few simple descriptors were added to the feature vector defined in a previous work. The second analysis is done through global colour histograms with the best of several colour spaces evaluated. The last one is executed using Haralick texture features extracted from three bands of a colour space. Once again some different colour spaces were evaluated. The shape analysis yielded 61.60% accuracy, the colour analysis, 74.33%, and the texture analysis, 80.98%. Further research is being conducted in order to provide a final classification.

Keywords — coffee beans, classification, neural network, pattern recognition.

I. Introdução

Um dos desafios que cooperativas de café brasileiras tem enfrentado é avaliar a qualidade dos grãos de café de seus produtores associados a uma velocidade compatível com o processo produtivo. A análise qualitativa de colheitas é um passo importante no ciclo do produto do café, pois o mercado, principalmente externo, exige cada vez mais um produto de qualidade, demandando a utilização apenas de grãos saudáveis na linha de produção. O método atualmente empregado na determinação da qualidade de uma colheita adota a inspeção visual de amostras de grãos por especialistas, que identificam e quantificam a presença de impurezas e grãos defeituosos. Obviamente esse método apresenta dificuldades em acompanhar o ritmo produtivo, que é quase totalmente mecanizado, e além disso, a análise é baseada em critérios subjetivos, que sofrem variações de avaliador para avaliador e até de análises diferentes feitas pelo mesmo avaliador.

Por essas razões busca-se desenvolver um método computacional para promover a análise de qualidade de grãos de café baseada em visão computacional, de modo a auxiliar análises em laboratório. Há muitos trabalhos publicados acerca de classificação de grãos diversos,

como trigo [1] e milho [2], mas publicações centradas em grãos de café são dificilmente encontradas.

Este trabalho propõe uma metodologia para classificação de amostras de café em grãos por imagens digitais, utilizando como classificadores redes neurais artificiais. De acordo com a proposta, as amostras são submetidas a três classificações distintas, cada uma utilizando descritores de naturezas diferentes: forma, cor e textura.

Este texto está estruturado como descrito a seguir. Na seção II serão expostos os fundamentos nos quais o trabalho se embasa. Na seção III serão mostrados os materiais utilizados e caracterizadas as amostras utilizadas no trabalho. Nas seções IV e V serão apresentados o pré-processamento empregado nas imagens e as topologias das redes neurais utilizadas. Nas seções VI, VII e VIII é explicada a metodologia utilizada nas classificações por forma, cor e textura. Na seção IX são apresentados e discutidos os resultados obtidos. Finalmente, na seção X serão apresentadas as conclusões deste trabalho e os esforços que serão realizados para dar continuidade ao estudo.

II. Fundamentação Teórica

A. Descritores de Forma

Muitas aplicações de visão computacional exigem o reconhecimento da forma que um objeto apresenta. Para tanto é necessário se utilizar uma maneira de representar uma forma através de um conjunto de valores numéricos, que são os descritores de forma. A literatura conta com um sem-número desses descritores, tanto para descrever formas 2D como 3D, para representar apenas o contorno de um objeto, ou todo o seu conteúdo, etc.. As complexidades também variam desde descritores obtidos diretamente da imagem, como o seu número de pixels, até descritores envolvendo cálculos avançados. Uma boa revisão de descritores de forma foi apresentada em [3].

B. Espaços de Cor

A noção de cor é fisicamente associada aos comprimentos de onda que são refletidos/absorvidos por um objeto ao se iluminá-lo. Os seres humanos captam as

diferenças de cores através de células fotossensíveis presentes na retina do olho – bastonetes e cones. As primeiras são sensíveis a intensidade de luminosidade, principalmente em baixos níveis, e as últimas são subdivididas em três categorias, as sensíveis a curtos comprimentos de onda, a médios comprimentos de onda, e a longos comprimentos de onda. De acordo com os números de células sensibilizadas de cada tipo, o cérebro é capaz de associar uma cor específica.

Para lidar computacionalmente com cores é necessário se utilizar um sistema matemático de representação, sistema esse denominado espaço de cor. Inúmeros espaços de cor foram propostos no meio científico [4], cada um com suas peculiaridades e potencialidades, que devem ser exploradas de acordo com a aplicação em que serão empregados.

C. Descritores de Haralick

Em 1973 Robert Haralick publicou um artigo [5] descrevendo métodos matemáticos para se descrever texturas de imagens digitais. Esse artigo apresenta 14 características que podem ser extraídas de uma imagem para representar texturas. Elas ficaram conhecidas como descritores de Haralick, os quais passaram a ser a base para aplicações que envolvem análise de texturas por imagens digitais. O estudo de Haralick se baseia na utilização de matrizes de co-ocorrência de níveis de cinza (GLCM - *Grey Level Co-occurrence Matrix*).

A GLCM é uma representação matricial da frequência com que diferentes combinações de brilho (níveis de cinza) ocorrem em uma imagem. A relação entre combinações de brilho é determinada comparando-se um pixel de referência a um pixel vizinho. Visto que uma imagem é uma representação matricial, cada pixel tem até 8 pixels a sua volta, e portanto é necessário se definir qual deles será o pixel vizinho, como ilustrado na Fig. 1. Desta forma, se, por exemplo, o pixel vizinho for escolhido como o PV_0°, as combinações de brilho serão determinadas comparando-se o pixel de referência ao pixel à sua direita. A contagem das diferentes combinações é feita percorrendo-se todos os pixels da imagem, com cada um deles sendo o pixel de referência da vez.

PV_135°	PV_90°	PV_45°
PV_180°	PR	PV_0°
PV_225°	PV_270°	PV_315°

Fig. 1 - Relação entre o pixel de referência (PR) e o pixel vizinho (PV)

Todas as possíveis combinações de níveis de cinza são contadas e formatadas em uma matriz, a GLCM. Supondo uma imagem com apenas três níveis de cinza (0, 1 ou 2), a GLCM referente a ela teria o formato apresentado na Fig. 2. Sendo que $V_{i,j}$ indica quantas ocorrências de pixels de referência com nível de cinza i cujo pixel vizinho apresenta nível de cinza j há na imagem.

		Valor do pixel vizinho		
		0	1	2
Valor do pixel de referência	0	$V_{(0,0)}$	$V_{(0,1)}$	$V_{(0,2)}$
	1	$V_{(1,0)}$	$V_{(1,1)}$	$V_{(1,2)}$
	2	$V_{(2,0)}$	$V_{(2,1)}$	$V_{(2,2)}$

Fig. 2 - Formato de uma GLCM para uma imagem com 3 níveis de cinza.

As GLCMs utilizadas no cálculo dos descritores de Haralick devem ser simétricas em relação à diagonal principal. Para tanto, a ocorrência de um pixel de referência com valor i cujo pixel vizinho apresenta valor j deve ser contada duas vezes, uma para $V_{i,j}$, e outra para $V_{j,i}$. Também é necessário que as GLCMs sejam normalizadas, apresentando probabilidades de ocorrência de combinações ao invés de números absolutos. Essas probabilidades $P_{i,j}$ são calculadas segundo a equação (1), para N níveis de cinza.

$$P_{i,j} = \frac{V_{i,j}}{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} V_{i,j}} \quad (1)$$

Os 14 descritores de Haralick são: segundo momento angular, contraste, correlação, variância, momento inverso da diferença, soma das médias, soma das variâncias, soma das entropias, entropias, diferença da variância, diferença da entropia, duas medidas de correlação e máximo coeficiente de correlação. Para ilustrar, a equação (2) apresenta o cálculo do descritor entropia.

$$Entropia = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} P_{i,j} (-\ln P_{i,j}) \quad (2)$$

III. Material

Imagens de amostras de café foram capturadas através de uma câmara com resolução de 1024x768 pixels acoplada a uma câmara isolada de luz externa, onde se situa a amostra, iluminada por lâmpadas de LED branco. A amostra é colocada sob uma superfície azul, cor escolhida para facilitar a segmentação.

Foi construído um banco de imagens através de grãos previamente classificados por especialistas através de seus critérios e nomenclaturas de classificação. Esse banco foi utilizado como referência para o desenvolvimento da metodologia e sua validação. As diferentes classes de grãos e impurezas a serem identificadas neste trabalho são apresentadas Fig. 3. Os defeitos são: ardido, barrento, branco, brocado, cabeça, chocho, concha, marinho, melado, preto, preto-verde, quebrado, marago, velho e verde. As impurezas são: casca, casca de marinho, coco, pau e pedra. Portanto, com a classe de grãos perfeito, tem-se um total de 21 classes.




Fig. 3 - Classes de grãos e impurezas.

(a) ardido, (b) barrento, (c) branco, (d) brocado, (e) cabeça, (f) casca, (g) casca de marinho, (h) perfeito, (i) chocho, (j) coco, (k) concha, (l) marinho, (m) melado, (n) pau, (o) pedra, (p) preto, (q) preto-verde, (r) quebrado, (s) triângulo, (t) velho, (u) verde

O número de amostras de cada uma das classes no banco de imagens é apresentado na TABELA I. A classe de grãos perfeitos apresenta quantidade muito superior de amostras em relação às outras classes, pois ela compreende amostras de 10 peneiras diferentes, que apesar de terem tamanhos distintos, se englobam na mesma classificação.

TABELA I - Quantidade de grãos por classe (a) ardido, (b) barrento, (c) branco, (d) brocado, (e) cabeça, (f) casca, (g) casca de marinho, (h) perfeito, (i) chocho, (j) coco, (k) concha, (l) marinho, (m) melado, (n) pau, (o) pedra, (p) preto, (q) preto-verde, (r) quebrado, (s) triângulo, (t) velho, (u) verde

Classe	a	b	c	d	e	f	g
Quantidade	518	788	667	710	698	496	499
Classe	h	i	j	k	l	m	n
Quantidade	2585	798	544	588	547	502	637
Classe	o	p	q	r	s	t	u
Quantidade	710	577	746	920	820	633	790

IV. Pré-processamento

Como os objetos de interesse não apresentam tonalidades azuis, como o fundo, pôde-se fazer a segmentação a partir dessa informação. Analisando-se o espaço de cor RGB, percebe-se que as tonalidades de azul apresentam valores de B significativamente maiores que de R e G. Definiu-se então a seguinte função de segmentação:

$$\begin{aligned} \text{SE } B \geq X * R \text{ e } B \geq X * G \\ \text{ENTÃO é um pixel de fundo.} \\ \text{SENÃO é um pixel de objeto.} \end{aligned}$$

Sendo que R, G e B são as componentes de cor do pixel a ser avaliado e X é um parâmetro a ser encontrado empiricamente.

A função de segmentação foi testada para diversos valores de X, avaliando-se visualmente o resultado obtido. Os testes foram realizados utilizando-se amostras que apresentassem objetos de diferentes colorações, desde grãos muito escuros a grãos mais claros e com tonalidades diversificadas (pedras, paus, grãos marinho, etc.). O valor de X que apresentou os melhores resultados foi 3,3.

Depois de segmentada, a imagem é binarizada e é aplicado o método dos componentes conexos [6] para a individualização e rotulação dos grãos. A partir da imagem binária, um simples algoritmo de detecção de bordas é executado para que os objetos sejam identificados junto com seus contornos. Um exemplo de saída do pré-processamento é a Fig. 4.




Fig. 4 - Grãos identificados e rotulados

V. Configuração das Redes Neurais

As redes neurais empregadas tanto na classificação por forma, como por cor e textura são do tipo *Perceptron* Multicamadas e o algoritmo de treinamento adotado em todos os casos foi o *backpropagation*, com taxa de aprendizagem de 0,1, momento de 0,5 e como critério de parada 5.000 épocas. As topologias são a mesma para todas as redes, com três camadas: uma de entrada (com um neurônio para cada elemento do vetor de características), uma de saída (um neurônio para cada uma das classes a serem identificadas), e uma escondida. Como o trabalho exigiu a comparação de resultados de classificações com números diferentes de dados de entrada e de saída, padronizou-se o número de neurônios da camada escondida em função do número de entradas e saídas. Dessa forma, o número de neurônios da camada escondida N_{ce} é calculado para cada rede, segundo a equação (3), arredondando-se para baixo.

$$N_{ce} = (N_e + N_s)/2 \quad (3)$$

N_e : Número de neurônios na camada de entrada.

N_s : Número de neurônios na camada de saída.

Todas as classificações foram realizadas utilizando o método da validação cruzada, com 20% das amostras reservadas para validação.

VI. Classificação por Forma

Ao analisar os diferentes tipos de grãos e impurezas, percebe-se claramente que algumas classes podem ser determinadas pela forma do objeto. Assim, selecionou-se as classes que julgou-se serem distinguíveis por seu contorno para comporem a classificação por forma. Essas classes são: cabeça, casca, coco, concha, pau, pedra, perfeito, quebrado e triângulo.

Em [7] foram avaliados para este mesmo problema o uso dos seguintes descritores de forma como entradas de uma rede neural: momentos de Zernike, assinaturas, descritores de Fourier, coeficientes do Modelo Autoregressivo, Descritores de Fourier Genéricos e um conjunto contendo os atributos área, comprimento e largura, perímetro e excentricidade. O estudo conseguiu os melhores resultados – acurácia de 52, 83% – utilizando este último conjunto de atributos, sugerindo que para a aplicação, descritores que extraem alguma informação da forma com significado físico, como área e perímetro, por exemplo, têm maior poder de discriminação que descritores que são combinados para definir a forma geral do objeto, como os momentos de Zernike, por exemplo.

Adotou-se os descritores área, comprimento, largura, perímetro e excentricidade para formar o vetor de características a ser utilizado na classificação por forma,

complementando-os com mais sete outros descritores: *spread*, *slenderness* e cinco outros que são derivados dos anteriores. Esses são descritores utilizados em [8] na análise de grãos de trigo, gerando bons resultados. Eles são calculados pelas equações abaixo:

$$spread = \mu_{2,0} + \mu_{0,2} \quad (4)$$

$$slenderness = \sqrt{(\mu_{2,0} - \mu_{0,2})^2 + 4\mu_{1,1}^2} \quad (5)$$

Onde $\mu_{p,q}$ é o momento central de ordem (p,q) de uma região R com centroide em (\bar{x}, \bar{y}) , dado por:

$$\mu_{p,q} = \sum_{(x,y) \in R} (x - \bar{x})^p (y - \bar{y})^q \quad (6)$$

Os outros descritores derivados, denominados D_1 , D_2 , D_3 , D_4 e D_5 são definidos pelas seguintes equações:

$$D_1 = \frac{4\pi \text{Área}}{\text{Perímetro}^2} \quad (7)$$

$$D_2 = \frac{\text{Comprimento}}{\text{Área}} \quad (8)$$

$$D_3 = \frac{\text{Área}}{\text{Comprimento}^3} \quad (9)$$

$$D_4 = \frac{\text{Área}}{\pi(\text{Comprimento}/2)^2} \quad (10)$$

$$D_5 = \frac{\text{Área}}{\pi(\text{Comprimento}/2)(\text{Largura}/2)} \quad (11)$$

Como os descritores são variantes à escala, as dimensões dos grãos são normalizadas através de um parâmetro determinado na capturada das imagens, o qual identifica quantos milímetros cada pixel representa.

VII. Classificação por Cor

Para a etapa de classificação pela coloração dos grãos optou-se pela abordagem de utilizar como vetor de características o histograma global de cor de cada grão. Histogramas de vários espaços de cor foram avaliados. A saber: HSV, YUV, YIQ, YPbPr, YCbCr, YCgCr, YDbDr, CIE XYZ, descritos em [4], CIELAB, descrito em [9], $I_1 I_2 I_3$ e RGB normalizado (rgb), especificados em [10].

Foram utilizados histogramas com 10 frequências, e portanto, uma quantização do espaço de cor foi necessária. A quantização foi feita pela equação (12).

$$Q_B = \text{ARREDONDA} \left(10 \cdot \frac{V_B - V_{\min,B}}{V_{\max,B} - V_{\min,B}} \right) \quad (12)$$

Q é o valor quantizado, V é o valor do modelo de cor original, cujo domínio é limitado por V_{\min} e V_{\max} . O índice B determina a banda do espaço de cor que está sendo quantizada. A função ARREDONDA(x) arredonda x para o inteiro mais baixo, e para o caso de x ser igual a 10, é retornado o valor 9, garantindo que os valores quantizados estejam entre 0 e 9.

Dessa forma, os classificadores foram desenhados para receber como entrada 30 valores: 10 frequências de histograma para cada um dos três canais de cor de um dado espaço de cor.

As classes a serem identificadas neste processo foram aquelas diferenciáveis por sua coloração: perfeito, pedra, melado, branco, concha, casca, preto-verde, barrento, coco, preto, pau, ardido, marinho, brocado, velho, verde e casca de marinho. E visto que o par de classes coco e casca representam essencialmente a mesma classe no que diz respeito à cor, já que ambos têm a mesma composição externa, porém com interiores diferentes, sendo diferenciáveis somente por forma, essas duas classes foram condensadas em uma só. A mesma situação é observada com as classes marinho e casca de marinho, as quais também foram englobadas em uma classe só. Sendo assim, tem-se 15 classes diferentes.

VIII. Classificação por Textura

Para análise por textura foram calculadas as GLCMs com distância 1 e computados os 14 descritores de Haralick para cada uma das bandas dos seguintes espaços de cor: RGB, RGB normalizado, $I_1 I_2 I_3$ e CIE-LAB.

Para cada banda calculou-se uma única GLCM computada para todos os *pixels* do grão, com o valor de cada *pixel* variando de 0 a 31. *Pixels* posicionados nas bordas, e que, portanto, não têm vizinhos, foram ignorados no cômputo da matriz. Para a mesma GLCM foram utilizadas quatro tipos de vizinhança: 0°, 45°, 90° e 135°.

Testes de classificação foram realizados para cada conjunto de descritores de bandas distintas e também para a união dos conjuntos de descritores de bandas de um mesmo espaço de cor, resultando em 20 testes. As classes a serem identificadas são as mesmas 15 empregadas na classificação por cor, definidas na seção VII.

IX. Resultados e Discussão

Na classificação por forma, a adição dos 7 descritores melhorou a taxa de acerto de 52,84% para 61,60%, o que ainda é considerado muito baixo para uma solução com

aplicações práticas. Pela matriz de confusão do resultado obtido, apresentada na TABELA II, percebe-se que a confusão entre classes acontece de modo generalizado, dificultando a tarefa de se encontrar descritores que ajudem a sanar deficiências específicas.

TABELA II - Matriz de confusão para a classificação por forma. As colunas representam a classificação pela rede neural e as linhas a classe real do grão. (a) Perfeito, (b) Coco, (c) Pedra, (d) Triângulo, (e) Concha, (f) Casca, (g) Chocho, (h) Cabeça, (i) Pau, (j) Quebrado.

	a	b	c	d	e	f	g	h	i	j
a	2112	12	10	137	19	4	128	131	1	31
b	172	169	9	39	36	24	23	60	5	7
c	77	7	349	9	22	17	89	1	8	131
d	193	0	0	500	26	0	2	0	10	89
e	150	18	5	158	139	37	6	6	5	64
f	61	43	18	33	70	164	5	15	54	33
g	173	0	33	13	0	0	504	0	0	75
h	131	27	0	0	0	3	0	537	0	0
i	27	20	5	52	23	76	3	2	364	65
j	31	0	98	61	31	3	106	0	10	580

As classificações por histograma global de cor geraram os resultados da TABELA III.

TABELA III - Taxas de acerto (T.A.) em % obtidos na classificação por cor

Espaço de Cor	RGB	HSV	YCbCr	YCgCr	YIQ	YPbPr
T.A.	69,92	74,33	69,93	67,06	68,98	69,87
Espaço de Cor	YUV	YDbDr	XYZ	LAB	rgb	$I_1 I_2 I_3$
T.A.	69,79	69,88	58,63	74,23	63,71	70,99

Notam-se poucas diferenças significativas entre os resultados, com exceção dos modelos CIE-XYZ, RGB normalizado, CIE-LAB e HSV. Os dois primeiros apresentaram resultados muito abaixo dos demais, enquanto os dois últimos apresentaram significativa superioridade em relação aos outros modelos. Pode-se dizer que o CIE-LAB e o HSV têm o mesmo potencial de discriminação no problema proposto. Supõe-se que a boa vantagem obtida pelo espaço de cor HSV se deva pelo fato de ele separar informação de brilho em uma banda diferente, o que o torna menos sensível a variações da distribuição de luz pelo sistema de iluminação. O CIE-LAB obteve um bom desempenho por ser perceptualmente uniforme [11], ou seja, a diferença entre cores percebidas por humanos resultam em uma diferença proporcional nos valores das componentes do modelo, de modo que as diferenças percebidas por classificadores humanos são captadas pelo sistema de cor. Este resultado corrobora a afirmação de [9], de que o CIE-LAB é amplamente utilizado em aplicações envolvendo frutas e hortaliças, reforçando que esse espaço de cor tem forte potencial discriminatório quando empregado em tais aplicações.

Os resultados de classificação de textura utilizando somente descritores provenientes de uma única banda de um espaço de cor foram todos inferiores aos resultados alcançados pela união dos descritores de um sistema de cor, como já era esperado, já que informações importantes são ignoradas. As taxas de acerto alcançadas para cada sistema de cor (com as três bandas) avaliados são apresentadas na TABELA IV.

TABELA IV - Taxas de acerto (T.A.) em % obtidas para a classificação por textura

	RGB	Rgb	$I_1I_2I_3$	LAB
T.A.	79,08	78,95	80,98	59,81

O único sistema de cor que apresentou resultado destoante em relação aos outros foi o CIE-LAB, com taxa de acerto muito inferior. Apesar de ele ser o melhor espaço de cor para evidenciar as diferenças de coloração entre as distintas classes (junto com o HSV), ele não tem muito potencial para discriminar diferenças de texturas no problema abordado. O melhor resultado foi obtido pelo $I_1I_2I_3$, com 80,98% de acurácia.

Percebe-se, então, que a análise de textura é a que melhor consegue discriminar as diferenças entre os defeitos e as impurezas, em contraste com a análise de forma, que mesmo tendo um menor número de classes para diferenciar, gerou o pior resultado.

Uma metodologia adicional deve ser desenvolvida para gerar uma classificação final a partir das três classificações apresentadas. Uma possibilidade é formar um conjunto de descritores abrangendo as três naturezas e utilizá-lo como entrada para um único classificador. Outra possibilidade seria utilizar as saídas das classificações como entrada para um sistema que gerará a classificação final. Neste último caso, como nem todas as classes são abrangidas nas classificações intermediárias se faz necessário utilizar uma classe que englobe as classes ignoradas, como uma classe ‘indefinido’, por exemplo.

X. Conclusões e Trabalhos Futuros

Este trabalho apresentou uma metodologia computacional para classificação de grãos de café por imagens digitais com o intuito de substituir a metodologia amplamente empregada atualmente no mercado, que é lenta e subjetiva. Foram utilizadas redes neurais para realizar três tipos de análise: por forma, por cor e por textura.

O melhor resultado da classificação por forma foi uma taxa de acerto de 61,60% utilizando 12 descritores. A análise por cor mostrou que os melhores espaços de cor para diferenciar as classes são o HSV, por conseguir desconsiderar uniformidades na iluminação, e o CIE-LAB, por ser perceptualmente uniforme. A taxa de acerto de 74,33% foi o melhor resultado da análise de cor.

Conclui-se que a textura é a característica com maior poder discriminante no problema abordado, pois sua análise conseguiu a melhor taxa de acerto – 80,98% – com significativa superioridade em relação à classificação por cor. Os números obtidos por este estudo se mostram animadores, pois acredita-se poder gerar uma classificação final com acurácia superior à obtida pela análise de textura, através do cruzamento ou da fusão das análises feitas e de refinamentos na metodologia.

Estudos futuros serão focados em desenvolver uma metodologia para a geração da classificação final através dos conhecimentos adquiridos até então e em aplicar métodos para selecionar os melhores descritores dentre os apresentados, de modo a descartar aqueles que carregam muita redundância de informação e/ou contribuem negativamente para o resultado da classificação.

XI. Agradecimentos

Agradecemos ao apoio financeiro da Cooperativa Regional de Cafeicultores em Guaxupé (Cooxupé), Guaxupé, MG.

REFERÊNCIAS

- [1] A. Arefi, A. M. Motlagh, R. F. Teimourlou. Wheat class identification using computer vision system and artificial neural networks. *International Agrophysics*, v. 25, p. 319-325, 2011.
- [2] X. Chen, Y. Xun, W. Li, J. Zhang. Combining discriminant analysis and neural networks for corn variety identification. *Computers and Electronics in Agriculture*, v. 71, p. 48-53, 2010.
- [3] D. Zhang, G. Lu. Review of shape representation and description techniques. *Pattern Recognition*, 37:1-19, 2004.
- [4] J. M. Chaves-González, M. A. Vega-Rodríguez, J. A. Gómez-Pulido, J. M. Sánchez-Pérez. Detecting skin in face recognition systems: a colour spaces study. *Digital Signal Processing*, 23 out. 2009. 806-823.
- [5] R. M. Haralick, K. Shanmugam, I. Dinstein. Textural features of image classification. *IEEE Transactions on Systems, Man, & Cybernetics*, Vol. 3(6), Nov 1973, 610-621.
- [6] L. Costa, R. C. Jr. *Shape analysis and classification: theory and practice*. [S.l.]: CRC Press, 2002.
- [7] P.I.C. Oyama, L. A. C. Jorge, E. L. L. Rodrigues. Comparação de descritores de forma aplicados na classificação de grãos de café. In: VIII Workshop de Visão Computacional, 2012, Goiânia-GO.
- [8] S. P. Shouche, S. Rastogi, S. G. Bhagwat, J. K. Sainis. Shape analysis of grains of indian wheat varieties. *Computers and Electronics in Agriculture*. v. 33, pp. 55-76, 2001.
- [9] L. A. C. Jorge, D. S. Gonçalves, P. I. C. Oyama, M. D. Ferreira. Uso de sistemas de imagem para classificação de frutas e hortaliças. In: M. D. FERREIRA. *Tecnologias pós-colheita em frutas e hortaliças*. São Carlos, SP: Embrapa Instrumentação, 2011. Cap. 7, p. 135-137.
- [10] S. PEICHUNG, L. CHENGJUN. Comparative assessment of content-based face image retrieval in different color spaces. *International Journal of Pattern Recognition and Artificial Intelligence*. Vol. 19, No. 7 (2005) 873-893.
- [11] F. W. J. BILLMEYER, M. SALTZMAN. *Describing colors*. In: _____ *Principles of color technology*. 2ª. ed. New York, USA: Wiley-Interscience, 1981. Cap. 2, p. 25-66.