

Sistema para Classificação Automática de Café em Grãos por Cor e Forma Através de Imagens Digitais

Pedro Ivo de Castro Oyama,* Lúcio André de Castro Jorge,
Evandro Luis Linhari Rodrigues e Carlos Cesar Gomes

Resumo: Este capítulo apresenta um sistema de visão computacional desenvolvido para classificação de pequenas amostras de café em grãos, sendo utilizado em laboratórios de análise. Ele tem o intuito de substituir o atual processo de inspeção visual feito por especialista humano, que é lento e muitas vezes incapaz de satisfazer a demanda da indústria de café. O sistema usa algoritmos de processamento de imagem para extrair atributos de cor e forma de imagens de amostra de grãos. Redes neurais artificiais do tipo *Multilayer Perceptron* foram usadas para reconhecer padrões de cor e forma. Bons resultados preliminares foram obtidos, mas melhorias ainda são necessárias.

Palavras-chave: Visão computacional, Classificação de café, Redes neurais, Reconhecimento de padrões.

Abstract: *This chapter presents a vision system for the classification of small samples of coffee beans to be used in the laboratory of coffee quality analysis. It is aimed at replacing the current visual inspection made by a human specialist, which is slow and often unable to fulfil the demands of the coffee industry. The system uses image processing algorithms to extract color and shape attributes from images of samples of beans. Multilayer Perceptron neural networks were used to recognize color and shape patterns. Good preliminary results were achieved, although improvements are still necessary.*

Keywords: *Computer vision, Coffee beans classification, Neural networks, Pattern recognition.*

* Autor para contato: pedro.oyama@gmail.com

1. Introdução

Com o aumento da produção e da demanda pelo produto de qualidade, cada vez mais o número de análises rápidas e precisas dos atributos físicos e fisiológicos dos grãos tem se tornado o gargalo na tomada de decisões rápidas em tempo compatível com o processo produtivo (Bewley & Black, 1994).

A análise dos atributos físicos de um lote de grãos é baseada principalmente em caracteres morfológicos 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 (Brasil, 1992). A análise física em grãos é um procedimento moroso e dependente da interpretação do analista, pois hoje é feita manualmente.

Os atributos fisiológicos de um lote de sementes devem indicar a sua capacidade de germinar e o seu vigor. No caso do grão, servem para identificar principalmente defeitos baseados na cor da amostra. Vários testes para avaliação dos atributos físicos e fisiológicos de um lote de sementes são relatados e descritos em Krzyzanowski et al. (1991), Marcos Filho (1995) e Vieira (1994) e podem ser aplicados aos grãos. Com o avanço na área de visão computacional, com a criação de sensores mais rápidos e processamentos mais eficientes, podem ser encontrados na literatura muitos trabalhos envolvendo classificação de sementes e grãos. Pode-se citar Khatchatourian & Padilha (2008), que utiliza técnicas de visão computacional e redes neurais artificiais para a classificação de sementes de soja baseada na forma. Em MacDougall (2002) é descrito como a análise de cor é incorporada em máquinas utilizadas pela indústria alimentícia para a separação de grãos.

Em geral, as aplicações aparecem em máquinas e sistemas para aplicação no processo de produção de produtoras de sementes. No laboratório, a análise de amostras ainda continua sendo feita de forma subjetiva e manual. Neste contexto, está sendo desenvolvida uma máquina para a classificação automática de grãos de café através de imagens digitais e neste trabalho serão apresentados os primeiros resultados da classificação feita através da aplicação de algoritmos de processamento de imagem numa amostra de grãos de café com base nos atributos de cor e forma.

Na Seção 2 são explicados os conceitos teóricos envolvendo cor e forma, e também as redes neurais *Multilayer Perceptron*. A Seção 3 apresenta como as imagens são adquiridas e explica os procedimentos adotados para se chegar à classificação. Os resultados obtidos e comentários sobre estes são mostrados na Seção 4. Finalmente, a Seção 5 apresenta as conclusões e possibilidades futuras para o trabalho.

2. Fundamentação Teórica

2.1 Espaços de cor

Os seres humanos percebem cores através de células sensíveis a luz presentes na retina do olho. Estas células são denominadas cones e bastonetes, sendo os primeiros muito mais eficazes em proporcionar distinção de cores que os últimos, que são mais relacionados à visão noturna por serem mais sensíveis a baixos níveis de iluminação. Existem três tipos de cones, diferenciados pelo comprimento de onda que são capazes de estimulá-los. Os cones do tipo L são sensíveis a comprimentos de onda longos, referentes ao espectro de cores avermelhadas. Os cones de tipo M são sensíveis a médios comprimentos de onda, referentes ao espectro de cores esverdeadas. Finalmente os cones de tipo S são sensíveis a comprimentos de onda curtos, referentes ao espectro de cores azuladas. Assim, as cores que percebemos estão relacionadas ao número de cones sensibilizados de cada tipo. Por exemplo, quando há muitos cones S sensibilizados, e poucos dos outros tipos, vemos uma cor de tonalidade azul.

Esta é a forma como o olho humano capta as cores. Para lidarmos matematicamente ou computacionalmente com elas, algum sistema semelhante deve ser utilizado, e estes sistemas são chamados de espaços de cor. Existem diversos deles na literatura, sendo que suas eficiências são dependentes da aplicação em que estão sendo empregadas. Uma comparação entre vários espaços de cor, especificamente avaliados para a detecção de pele em reconhecimento de face, foi feita por [Chaves-González et al. \(2010\)](#). Neste trabalho foi adotado como primeira alternativa o espaço de cor RGB, por ser um sistema simples, cujas componentes podem ser obtidas diretamente da imagem a ser processada, sem necessidade de conversões.

O modelo RGB trata as cores da mesma forma como o olho humano as capta. As cores são representadas pelas componentes R, G e B, que definem respectivamente intensidade com a qual as cores primárias vermelho, verde e azul estão presentes. Todas as componentes são números inteiros que variam entre 0 e 255.

2.2 Descritores de forma

Um dos desafios da visão computacional é conseguir definir formas de objetos através de representações matemáticas de maneira concisa, e que ainda assim consigam expor informações intrínsecas da forma, as quais as pessoas conseguem perceber naturalmente, como circularidade e excentricidade, para citar alguns exemplos. Essas representações podem ser denominadas de descritores de forma. Inúmeras técnicas já foram apresentadas e suas eficiências dependem muito da aplicação e de quais características da forma se deseja exaltar. Outro critério muito relevante envolvendo os descritores é o custo computacional exigido nos cálculos, que sendo muito alto pode comprometer algumas aplicações.

Neste projeto os descritores utilizados para representar os grãos necessitam atender a duas exigências. A primeira é que eles devem ser invariantes à rotação, isto é, os valores dos descritores de um objeto e os da sua versão rotacionada devem ser os mesmos. A segunda é não ter um custo computacional elevado, visto que a aplicação deve ter a resposta mais rápida possível, por ser tratar de uma solução a ser empregada na indústria. Portanto, inicialmente foram avaliadas as variâncias das assinaturas e as magnitudes dos descritores de Fourier, em conjunto com descritores mais triviais: área, perímetro, comprimento e largura.

2.2.1 Assinaturas

Assinaturas são uma função 1D calculada a partir dos pontos do contorno de uma forma. Geralmente elas são normalizadas para se obter invariância quanto a escala. Existem várias abordagens para calculá-la, como, por exemplo, a tangente do ângulo, a área, comprimento da corda e a distância do centróide (Zhang & Lu, 2004). Esta última foi a utilizada neste trabalho. Vale ressaltar que as assinaturas não são invariantes à rotação, mas como o descritor adotado foi a variância (σ^2) destes valores, a invariância é obtida.

As coordenadas (\bar{x}, \bar{y}) do centróide de uma figura representada pela região \mathcal{R} contendo N *pixels* são dadas pelas Equações 1 e 2:

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

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

Portanto, para um objeto com contorno \mathcal{C} , as assinaturas $z(i)$ são calculadas pela Equação 3, com $(x(i), y(i)) \in \mathcal{C}$.

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

2.2.2 Comprimento e largura

Os passos envolvidos no cálculo do comprimento e da largura de uma forma são descritos em Jain (1989).

Os momentos centrais de ordem (p, q) de uma figura representada pela região \mathcal{R} contendo N *pixels* são calculados pela Equação 4.

$$\mu_{p,q} = \sum_{(x,y) \in \mathcal{R}} \sum (x - \bar{x})^p (y - \bar{y})^q \quad (4)$$

A partir dos momentos é possível se calcular a orientação de um objeto, ou seja, o ângulo θ (Figura 1) com o qual ele possui o menor momento de inércia. θ é dado pela Equação 5.

$$\theta = \frac{1}{2} \arctan\left(\frac{2\mu_{1,1}}{\mu_{2,0} - \mu_{0,2}}\right) \quad (5)$$

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 1.

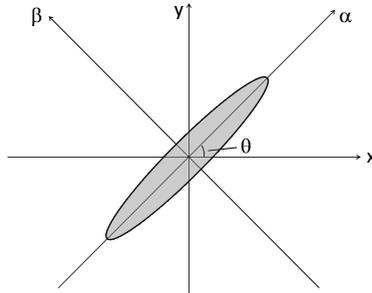


Figura 1. Imagem adaptada de Jain (1989), p.393.

Assim, as coordenadas α e β podem ser calculadas a partir das coordenadas x e y utilizando as seguintes Equações 6 e 7:

$$\alpha = x \cos \theta + y \sin \theta \quad (6)$$

$$\beta = -x \sin \theta + y \cos \theta \quad (7)$$

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 \mathcal{R} , pode-se definir o comprimento e a largura da forma:

$$largura = MIN(\alpha_{max} - \alpha_{min}, \beta_{max} - \beta_{min}) \quad (8)$$

$$comprimento = MAX(\alpha_{max} - \alpha_{min}, \beta_{max} - \beta_{min}) \quad (9)$$

2.2.3 Descritores de Fourier

Em 1822 foi publicada por Fourier uma teoria que afirma que qualquer sinal periódico pode ser representado como uma soma de senóides multiplicadas por diferentes coeficientes. Mais tarde esta definição foi estendida para sinais não-periódicos, e estes coeficientes podem ser calculados pela chamada transformada de Fourier (Gonzalez & Woods, 2001). Esta transformada é amplamente utilizada na área de análise de sinais por permitir uma visualização do sinal no domínio da frequência, fornecendo possibilidades não

alcançadas no domínio do tempo. Nas últimas décadas ela também vem sendo muito explorada no processamento de imagens. A versão discreta da transformada (transformada discreta de Fourier) pode ser utilizada na representação de forma em imagens digitais, bastando tratar um conjunto de assinaturas como sendo um sinal e aplicar 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 à rotação.

Os descritores de Fourier $F(u)$ de um conjunto de N assinaturas $z(i)$ são obtidos pela Equação 10, para $u = 0, 1, 2, \dots, N - 1$:

$$F(u) = \frac{1}{N} \sum_{i=0}^{N-1} z(i)e^{-j2\pi ui/N} \quad (10)$$

Na Figura 2 foram comparados exemplos de assinatura e magnitudes de descritores de Fourier para contornos de grãos normais e quebrados, mostrando como eles podem ser utilizados para diferenciar os dois tipos de grãos.

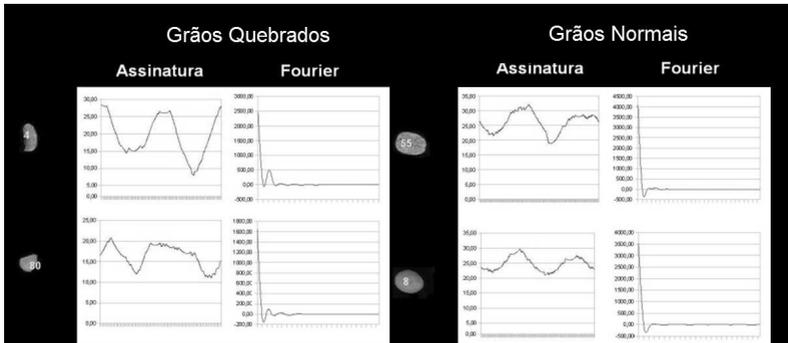


Figura 2. Comparação entre as magnitudes dos descritores de Fourier e as assinaturas de grãos quebrados e grãos normais.

2.3 Multilayer Perceptron

Redes neurais artificiais do tipo *Multilayer Perceptron* (MLP) são modelos computacionais inspirados no modelo biológico de interligação entre neurônios, e visam promover o aprendizado de máquina. Elas são largamente utilizadas na classificação de padrões, ou seja, indicar a que classe pertencem os dados de entrada. As MLPs são redes neurais cujo aprendizado é supervisionado. Portanto, antes de realizar qualquer classificação é necessário um processo de treinamento, no qual vários exemplos de dados

pré-classificados são apresentados. As MLPs são constituídas de várias camadas de neurônios artificiais, sendo uma de entrada, por onde dados são inseridos, uma de saída, por onde os resultados são fornecidos, e pelo menos uma camada escondida (Figura 3). O número de camadas escondidas e o número de neurônios em cada uma devem ser definidos de acordo com a aplicação e influenciam na taxa de sucesso da classificação (Silva et al., 2010).

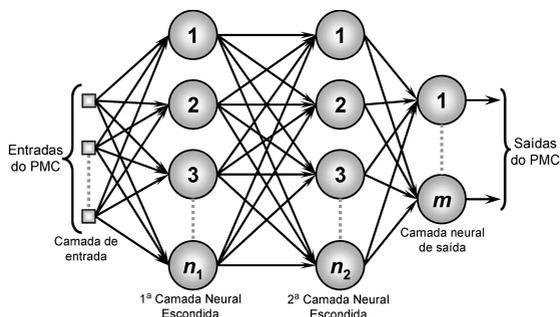


Figura 3. Topologia de uma MLP (Silva et al., 2010).

3. Materiais e Métodos

A metodologia utilizada neste trabalho é dividida em: aquisição de imagens da amostra, aplicação de algoritmos de processamento de imagem para detecção dos objetos e extração de suas características, classificação por padrões de cor, definição de descritores de forma e, finalmente, classificação por padrões de forma.

3.1 Amostragem e classificação

As classes de grãos e impurezas a serem identificadas pelo *software* foram definidas de acordo com o modelo de classificação utilizado pela Cooperativa Regional de Cafeicultores de Guaxupé Ltda (Cooxupé), que forneceu amostras de grãos defeituosos, impurezas e grãos saudáveis de diferentes peneiras. Esse foi o conjunto de amostras utilizado no processo de treinamento das redes neurais, como será detalhado mais adiante. Todas as amostras foram previamente separadas e classificadas por especialistas da cooperativa através do processo manual. As classes de defeitos e de grãos saudáveis são apresentadas na Figura 4. As impurezas de uma amostra são paus e pedras. O grão do tipo brocado não foi tratado nesta fase do trabalho, por ser caracterizado pela presença de pequenas perfurações, sendo que o processo necessário para identificá-las não coincide com a metodologia empregada no reconhecimento das outras classes.

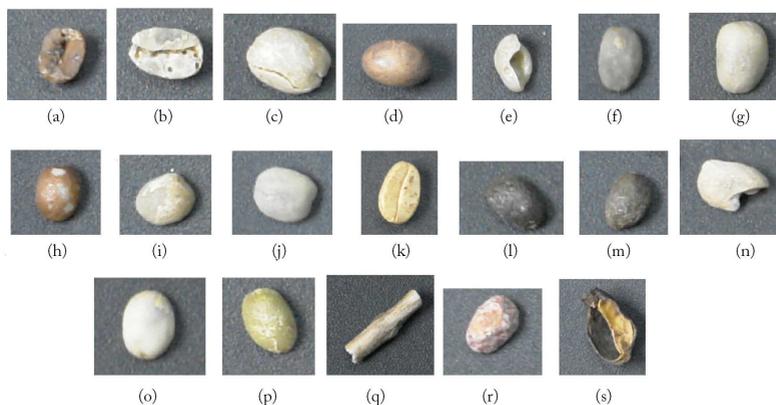


Figura 4. Classes de grãos e impurezas. (a) ardido, (b) brocado, (c) cabeça, (d) coco, (e) concha, (f) fava escura, (g) marago, (h) melado, (i) película, (j) perfeito, (k) pergaminho, (l) preto, (m) preto-verde, (n) quebrado, (o) secador, (p) verde, (q) paus, (r) pedras e (s) cascas.

3.2 Aquisição de imagens

Para se poder capturar imagens de amostras de café por um método sistemático, com o qual todas as condições que afetam a foto pudessem ser reproduzidas exatamente da mesma forma a cada processo de aquisição, uma máquina foi desenvolvida (Figura 5). Ela é composta por uma bandeja horizontal de vidro, onde os grãos são depositados, sob condições controladas de luz. Ambos os lados da bandeja são iluminadas por lâmpadas de LED e duas câmeras de vídeo são posicionadas cerca de 60 cm acima e abaixo dela, de forma que possam ser capturadas imagens de cada um dos lados da amostra, podendo-se analisar quase toda a superfície dos grãos. As imagens superior e inferior são capturadas em momentos distintos, tornando necessária a presença de um dispositivo manual para alternar as duas placas de metal revestidas com a cor azul, utilizadas como fundo das fotos. As câmeras de vídeo utilizadas são do tipo IP e são conectadas ao computador que executa o software através de uma interface *Gigabit Ethernet*. As imagens são capturadas diretamente pelo software e são salvas no formato *bitmap* com resolução de 1024×768 *pixels*.

3.3 Processamento

O software desenvolvido foi dividido em módulos: pré-processamento, classificação por cor, por forma e por tipo de grão, conforme descrito no diagrama da Figura 6.

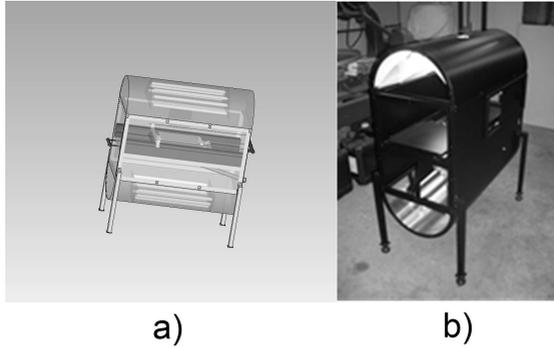


Figura 5. (a) Representação gráfica da máquina de classificação de café, (b) Foto da primeira versão construída.

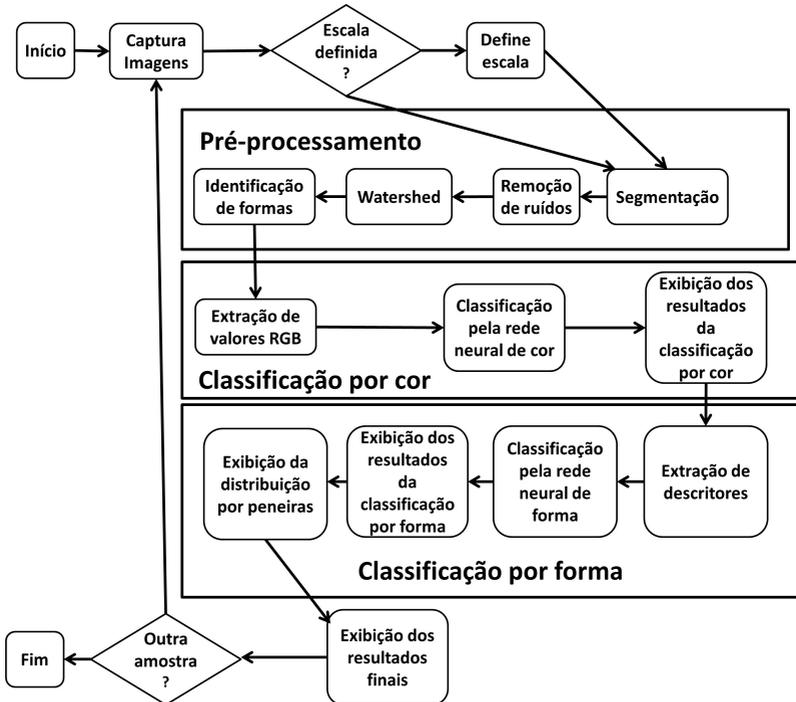


Figura 6. Diagrama de blocos do Qualicafé.

Todos os processos de classificação são feitos por redes neurais artificiais do tipo *Multilayer Perceptron* (MLP), utilizando o algoritmo *backpropagation*, com taxa de aprendizado de 0,1, momento de 0,7 e 5000 épocas como condição de parada. Os números de neurônios das camadas de entrada e de saída são iguais, respectivamente, ao número de atributos e ao número de classes definidos. As MLPs continham apenas uma camada escondida, com n neurônios cada, sendo n definido pela Equação 11 (arredondado para baixo).

$$n = \frac{\text{numero de atributos} + \text{numero de classes}}{2} \quad (11)$$

3.4 Pré-processamento

A primeira etapa de processamento é a identificação de grãos e impurezas presentes na amostra, que é feita pela aplicação de tradicionais algoritmos de processamento de imagem.

O fundo de cor azul foi escolhido devido ao fato de nenhuma das classes apresentarem tonalidades próximas a esta cor, de forma a facilitar a segmentação da imagem. A segmentação foi feita comparando-se *pixel* a *pixel* as componentes de cor do modelo RGB. Naturalmente, a cor azul apresenta valores mais expressivos de B e valores mais baixos de R e G. Imagens contendo todos os tipos de grãos e impurezas foram submetidas a algoritmos de segmentação que separam os *pixels* utilizando diferentes expressões que comparam valores de B aos valores de R e G. Os resultados foram comparados visualmente para se eleger a expressão que apresenta a melhor segmentação. Assim sendo, definiu-se que um *pixel* seria considerado como fundo se para dadas suas componentes RGB, $B \geq 3,3R$ E $B \geq 3,3G$. Caso contrário o *pixel* é considerado objeto. Tendo os objetos sido separados do fundo, a imagem é binarizada para que os outros algoritmos possam ser aplicados. Utiliza-se os processos morfológicos de erosão e dilatação, para suavizar os objetos, eliminar possíveis ruídos e imperfeições da segmentação.

Visando separar grãos que estejam encostados uns nos outros, podendo gerar problemas na contagem de grãos e objetos com formas anormais, um algoritmo de *Watershed* é executado. Para cada *pixel* “objeto” da imagem, sua distância ao *pixel* “fundo” mais próximo é calculada e armazenada. Então são definidos os pontos com as distâncias máximas locais e cada um destes pontos é dilatado até que se chegue à borda do objeto ou à borda da região de outro ponto sendo dilatado. Desta forma, a região de encontro entre os pontos crescentes é definida como “fundo”, separando os objetos (Ferreira & Rasband, 2011).

A partir da imagem binarizada é finalmente executado um algoritmo para rotular as diferentes formas. A rotulação é feita pelo método das componentes conexas, o qual agrupa os *pixels* de acordo com as suas conecti-

vidades. Existem duas variantes que definem a conectividade dos *pixels*: a vizinhança-de-4 e a vizinhança-de-8. A primeira considera que dois *pixels* são vizinhos somente se estiverem conectados pelos eixos vertical ou horizontal, enquanto a segunda, adotada neste trabalho, também considera os diagonais. Uma componente conexa é um grupo de *pixels* que compartilham da propriedade de que existe um caminho de ligação (uma sucessão de vizinhos) entre quaisquer dois deles (Costa & Cesar Jr., 2000). Uma vez definidas as componentes conexas, cada uma delas e seus respectivos *pixels* são rotulados, representando um objeto diferente. Depois de rotuladas todas as formas presentes na imagem, é trivial se extrair os *pixels* de seus contornos.

Finalmente, são descartados os objetos compostos por menos que 40 *pixels*, por eles serem muito pequenos para representar um objeto de interesse, provavelmente sendo resultado de ruído da imagem ou uma falha no algoritmo de identificação.

Na Figura 7 pode ser visualizada uma imagem de saída do processo de identificação de grãos. Nesta imagem, os contornos dos grãos são pintados de verde e numerados sequencialmente. A rotulação é armazenada juntamente com os *pixels* localizados nos seu interior.

Para se trabalhar com as dimensões reais dos objetos durante a análise por forma, foi desenvolvida uma ferramenta para a indicação da escala da imagem, através da qual se desenha uma linha sobre a imagem e informa-se a distância real que ela representa.

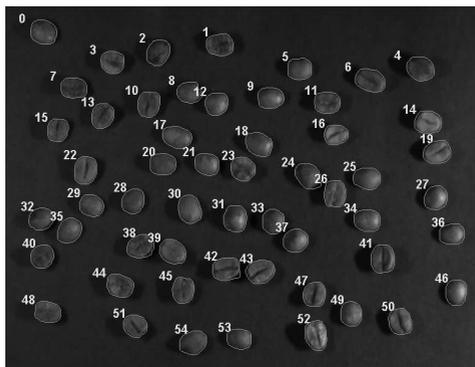


Figura 7. Objetos identificados e rotulados.

3.5 Classificação por cor

A análise de cor dos grãos de café é feita para se distinguir grãos bons de grãos com certos tipos de defeito, como: grãos verdes, pretos, pretos-

verdes, ardidos, etc. Esta análise se baseia no reconhecimento de padrões de cor presentes nos grãos, visto que certos defeitos são identificados por uma cor característica do grão, ou de uma parte dele, como por exemplo o tom mais esverdeado que é comum nos grãos-verdes e manchas marrons nos grãos melados. Da mesma forma, as sementes perfeitas também têm uma coloração característica que as definem.

Sendo assim, cada um dos defeitos passíveis de serem identificados pela análise de cor foi associado a uma classe, que juntamente com a classe de grão perfeito formam o conjunto de padrões a serem reconhecidos pela rede neural. As classes são: ardido, casca/coco, fava escura, melado, pau, pedra, película, perfeito, pergaminho, preto, preto-verde, secador e verde (todas ilustradas na Figura 4). A MLP foi definida com três atributos de entrada: as componentes de cor R, G e B e 13 neurônios na camada de saída. Pela aplicação da Equação 11 obteve-se uma camada escondida com oito neurônios.

Para cada uma das classes, foram capturadas imagens de amostras contendo grãos da classe em questão para execução do treinamento da rede. Foram utilizadas janelas selecionadas manualmente sobre a imagem, cujas áreas apresentavam a coloração característica do defeito do grão (Figura 8), ou um padrão de saudável. Para cada um dos *pixels* que compõem estas áreas foi determinado o valor médio de R,G e B, com base nos *pixels* imediatamente vizinhos. Estes valores foram então utilizados como entrada para a MLP no seu treinamento. Para cada classe foram coletados cerca de 1700 *pixels*.

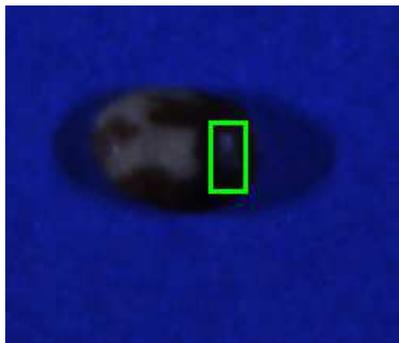


Figura 8. Seleção de amostra em um grão para treinamento da MLP.

A classificação dos grãos de uma amostra é feita se passando como entrada para a MLP treinada os valores médios de R, G e B de cada um dos *pixels* do grão com seus vizinhos. Conforme os *pixels* são classificados eles são pintados na imagem da amostra com uma cor diferente para cada classe,

de modo que os padrões de cor que constituem o grão sejam facilmente identificados, como exibido na Figura 9. Quando todos os *pixels* de um grão tiverem sido classificados, a classe atribuída ao maior número de *pixels* é definida como a classe do grão.

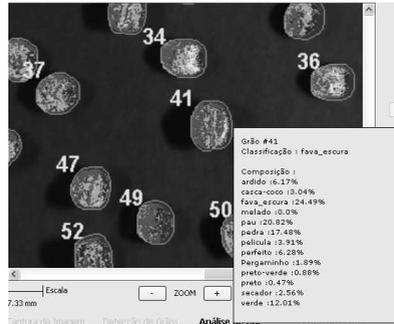


Figura 9. Resultado de uma classificação por cor.

3.6 Classificação por forma

As impurezas de uma amostra de grãos de café podem ser facilmente reconhecidas através de suas formas, que estão fora do padrão que as sementes apresentam. Os paus apresentam um contorno fino e comprido, e as pedras são pequenas e têm um contorno irregular. A análise de forma também é capaz de indicar grãos com defeitos, como no caso de grãos quebrados, que naturalmente são menores e não possuem o característico formato arredondado de uma semente perfeita. Seguindo estas premissas foram testadas duas configurações de MLP para reconhecer os padrões de forma dos objetos presentes na imagem de uma amostra e indicar de qual classe de grão ou impureza estes padrões são característicos. As MLPs se diferenciam pelos descritores de forma utilizados como entrada. As classes definidas foram nove, a saber: cabeça, casca, coco, concha, marago, pau, pedra, perfeito, e quebrado (apresentadas da Figura 4). Nesta etapa do projeto somente uma das duas imagens (superior e inferior) foi utilizada na análise.

A primeira configuração de MLP foi definida com 44 atributos, dos quais 40 são magnitudes dos descritores de Fourier, os restantes são largura, comprimento e perímetro (em milímetros), e o último é área em milímetros quadrados. Sendo assim, pela Equação 11 a camada escondida foi definida com 26 neurônios.

A segunda MLP foi configurada com cinco atributos: variância(σ^2) das assinaturas, largura, comprimento e perímetro em milímetros e área em milímetros quadrados. A variância das assinaturas foi adotada com o intuito de se identificar as irregularidades do contorno do grão. Visto que

um grão arredondado e com poucas imperfeições no contorno apresenta menores variâncias em relação a grãos quebrados e irregulares. O número de neurônios na camada escondida calculada pela Equação 11 foi de sete.

Analogamente ao treinamento da MLP de cor, o das redes de forma foi feito capturando-se imagens contendo grãos ou impurezas de uma classe específica e então extraíndo seus contornos para serem utilizados no cálculo dos descritores. Foi coletado um conjunto de cerca de 160 formas para cada uma das classes.

Além de indicar os padrões de forma presentes, também é gerado um histograma com a distribuição dos grãos por peneira, uma classificação utilizada pelas cooperativas de café. Em geral esta classificação é feita por um jogo de peneiras, que separa os grãos pela forma e pelo tamanho. As peneiras têm crivos com diversas medidas e dois formatos diferentes: podem ser oblongos, para separar os cafés mocas, ou circulares, para separar os cafés chatos. As medidas dos crivos das peneiras são dadas em frações de 1/64 de polegada e o número da peneira corresponde ao numerador da fração. Por exemplo: peneira 19 = 19/64 de polegada (Brasil, 2003).

4. Resultados e Discussão

4.1 Identificação dos objetos

Constatou-se que o processo de reconhecimento de formas na imagem apresenta algumas falhas. O problema mais recorrente ocorre na execução do algoritmo de *Watershed*, que algumas vezes divide a forma de um único objeto em várias (o que ocorre com frequência com os paus), como ilustrado na Figura 10 e em certas ocasiões traça erroneamente a fronteira entre dois objetos que se encostam.

Na identificação e extração de contorno de 2766 objetos, incluindo grãos e impurezas de todas as classes, constatou-se apenas 48 falhas, ou seja, houve uma precisão de 98,45%. Dessas 43 falhas, notou-se que 18 (41,86%) são referentes à segmentação do fundo azul, com sombras sendo identificadas como partes dos objetos, e 25 (58,14%) são resultantes da execução do *Watershed*. Destas, 20 (80%) deram-se em objetos da classe pau. Outras pequenas falhas na extração de contorno puderam ser notadas em algumas ocorrências, mas estas foram consideradas insignificantes e foram ignoradas. Deve-se salientar que procurou-se sempre posicionar os objetos para a captura de imagem de modo que eles não se encostassem, deixando o algoritmo de *Watershed* somente para eventuais ocorrências.

A taxa de acerto de 98,45% indica que o algoritmo de reconhecimento de objetos se mostrou muito eficiente, apresentando precisão adequada para a aplicação.

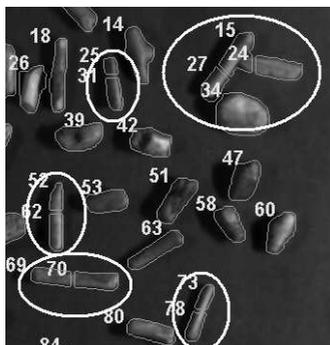


Figura 10. Deficiências na identificação de paus.

4.2 Classificação por cor

Com a rede neural de cor devidamente treinada, alguns testes foram conduzidos para se avaliar a eficiência da classificação. Amostras de grãos e impurezas de todas as classes foram submetidas ao processo de classificação por cor. A matriz de confusão resultante deste conjunto de experimentos é apresentada na Tabela 1.

Tabela 1. Matriz de confusão da classificação por cor, onde: a=ardido, b=casca/coco, c=fava escura, d=melado, e=pau, f=pedra, g=película, h=perfeito, i=pergaminho, j=preto-verde, k=preto, l=secador, m=verde, T.A.=taxa de acerto.

	a	b	c	d	e	f	g	h	i	j	k	l	m	T.A.
a	31	44	0	0	100	5	0	0	0	1	28	0	8	14,29%
b	5	131	0	8	25	2	0	0	0	3	16	0	0	68,95%
c	4	0	83	0	35	36	0	0	0	0	0	0	0	52,53%
d	0	23	5	69	110	14	0	0	1	0	0	0	1	30,94%
e	0	1	0	0	166	39	0	0	0	0	0	0	0	80,58%
f	0	1	0	0	14	135	0	0	0	0	0	0	0	90,00%
g	0	0	18	0	88	63	7	0	0	0	0	1	1	3,93%
h	1	0	65	0	60	24	3	0	0	0	0	0	42	0,00%
i	0	4	0	4	13	0	1	0	151	0	0	0	0	87,28%
j	22	93	0	0	18	3	0	0	0	8	57	0	0	3,98%
k	18	43	0	0	7	2	0	0	0	6	151	0	0	66,52%
l	0	0	26	1	93	38	1	0	2	0	0	4	7	2,33%
m	9	2	13	0	25	9	0	0	0	0	0	0	102	63,75%

A taxa de acerto global foi de 43,47%, a qual não pode ser considerada um bom resultado. Avaliando as taxas de acerto por classe, percebe-se que existem resultados muito bons para casca/coco, pau, pedra, pergaminho e

preto, resultados medianos para fava escura, melado e verde e resultados muito ruins para ardido, película, perfeito, preto-verde e secador.

Espera-se que ao se cruzar os dados dos resultados das duas classificações – por cor e por forma – muitas das baixas taxas de acerto possam ser melhoradas. Como exemplo, pode se perceber que há um grande número de ocorrências de falsos positivos das classes pau e pedra, mas elas apresentam um alto número de verdadeiros positivos, e, como será mostrado na Seção 4.3, na análise de forma estas classes apresentam boas taxas de acerto e poucos falsos positivos. Portanto, um objeto só seria classificado como pau ou pedra, se ambas as análises indicassem tal, o que diminuiria a ocorrência de falsos positivos.

Mesmo com as prováveis melhorias resultantes do cruzamento das classificações, o resultado obtido encoraja a exploração de outros espaços de cor, tendo em vista a possibilidade de eles exaltarem informações que o sistema RGB não é capaz, ou ainda, de serem mais tolerantes às variações de luminosidade presentes na bandeja onde as amostras são depositadas, problema este que pode ter afetado negativamente o resultado.

4.3 Classificação por forma

As duas MLPs propostas para a classificação de forma foram avaliadas utilizando o método da validação cruzada com 10 *folds*, sendo destinadas 80% das amostras para o treinamento e 20% para a validação.

A matriz de confusão originada pela rede neural que utiliza os descritores de Fourier é mostrada na Tabela 2 e a matriz obtida pela rede neural que utiliza a variância das assinaturas é apresentada na Tabela 3. Constata-se que a segunda abordagem apresentou melhores resultados para todas as classes, conseguindo uma taxa de acerto global de 54,5%, a qual é consideravelmente maior que os 40,8% conseguidos pela primeira. Além disto, a primeira MLP conta com muito menos neurônios, tanto na camada de entrada como na camada escondida, proporcionando um custo computacional na geração das classificações muito menores.

Analisando a Tabela 3 percebe-se que as principais classes responsáveis por limitar a eficiência da classificação são cabeça, coco e quebrado. A classe cabeça apresenta uma confusão muito grande com a classe perfeito, por elas apresentarem uma semelhança muito grande no contorno. A classe quebrado foi muito confundida com a classe concha, classes estas que apresentam visualmente contornos muito semelhantes, por se tratarem grãos lascados. Assim, conclui-se que o conjunto de descritores não são muito eficientes em distinguir pequenas diferenças, sendo necessário, ou substituí-los ou adicionar mais alguns que sejam capazes de enaltecer outras particularidades que definem a forma dos grãos.

Tabela 2. Matriz de confusão da classificação por forma utilizando os descritores 40 coeficientes de Fourier, perímetro, área, comprimento e largura, onde: a=cabeça, b=casca, c=coco, d=concha, e=marago, f=pau, g=pedra, h=perfeito, i=quebrado, T.A.=taxa de acerto.

	a	b	c	d	e	f	g	h	i	T.A.
a	45	8	18	8	12	0	0	65	3	28,3%
b	3	77	18	18	5	15	6	11	12	46,7%
c	8	13	31	42	11	0	19	13	14	20,5%
d	2	21	16	76	1	6	0	10	30	46,6%
e	13	4	3	2	88	0	0	21	0	67,2%
f	0	14	0	6	3	119	1	0	13	76,3%
g	0	5	5	7	0	0	115	0	16	77,7%
h	11	5	6	0	7	0	0	166	0	85,1%
i	0	8	20	43	0	7	17	1	55	36,4%

Tabela 3. Matriz de confusão da classificação por forma utilizando os descritores variância das assinaturas, perímetro, área, comprimento e largura, onde: a=cabeça, b=casca, c=coco, d=concha, e=marago, f=pau, g=pedra, h=perfeito, i=quebrado, T.A.=taxa de acerto.

	a	b	c	d	e	f	g	h	i	T.A.
a	45	8	18	8	12	0	0	65	3	28,3%
b	3	77	18	18	5	15	6	11	12	46,7%
c	8	13	31	42	11	0	19	13	14	20,5%
d	2	21	16	76	1	6	0	10	30	46,6%
e	13	4	3	2	88	0	0	21	0	67,2%
f	0	14	0	6	3	119	1	0	13	76,3%
g	0	5	5	7	0	0	115	0	16	77,7%
h	11	5	6	0	7	0	0	166	0	85,1%
i	0	8	20	43	0	7	17	1	55	36,4%

4.4 Classificação por peneiras

Foram conduzidos testes para a obtenção da distribuição por peneira em três amostras de grãos, cada uma proveniente de um processo de separação por peneira com crivos diferentes. As peneiras em questão eram 15, 17 e 19. Nos três casos pôde-se perceber uma maior concentração em torno da furação utilizada na separação, a qual também apresentou em todos os casos o maior número de ocorrências. A Figura 11 mostra o histograma obtido da amostra da peneira 17.

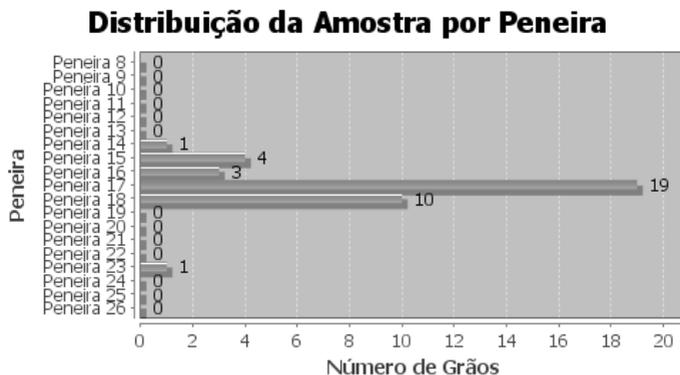


Figura 11. Distribuição por peneira de uma amostra de peneira 17.

4.5 Distinção entre grãos e impurezas

Comparando-se as classificações geradas pelo software com as reais classes presentes nas amostras, observou-se que foi capaz de distinguir entre impurezas (paus e pedras) e grãos, sejam eles com defeitos ou não, com uma acurácia satisfatória. Dado que a presença de impurezas na amostra exerce uma depreciação no café muito maior que os grãos defeituosos, esta característica indica um importante resultado. Na Figura 12 é mostrado um exemplo de classificação, na qual esta distinção é notada. Em branco estão os objetos corretamente classificados (como paus, pedras ou grãos) em pelo menos umas das duas análises, de cor e de forma, e em preto aqueles cujas classificações não foram corretas em nenhuma delas.

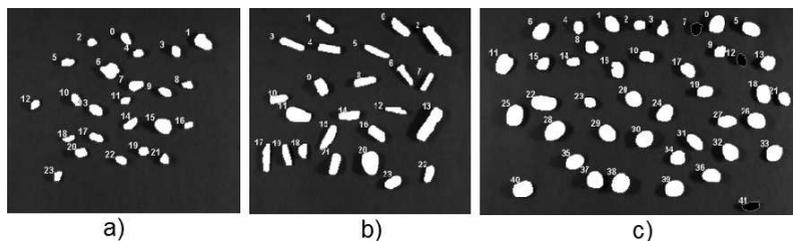


Figura 12. Acertos de classificação de grãos e impurezas a) pedras b) paus c) grãos.

Uma tela da interface do software é mostrada na Figura 13. Ela apresenta os resultados da classificação de uma amostra.

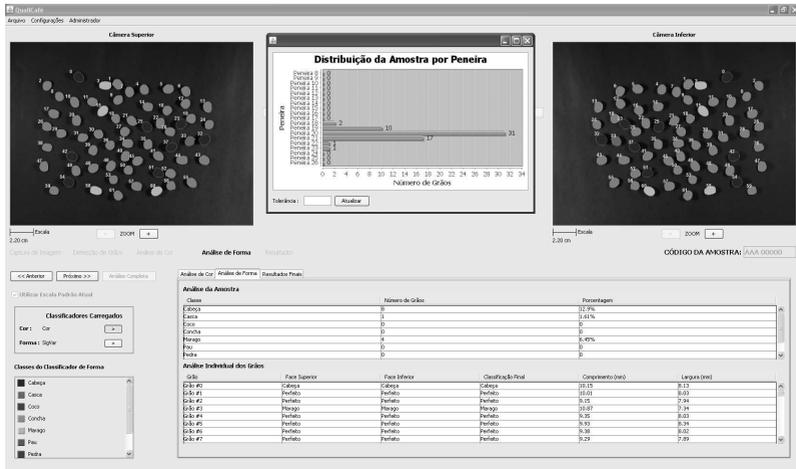


Figura 13. Tela de resultados.

5. Conclusões e Trabalhos Futuros

Este trabalho buscou desenvolver um software que substituísse o atual processo manual de classificação de grãos de café por um método automático, mais eficiente e confiável. Os resultados obtidos mostraram que as atuais técnicas de processamento de imagem são capazes de extrair da imagem de um grão informações suficientes para definir sua forma e coloração, alguns dos atributos utilizados por especialistas humanos para classificar os grãos.

A taxa de acerto das classificações ainda é insatisfatória, mas pode-se considerar que os resultados preliminares são bons – distinguir grãos de impurezas e identificar certas classes com um acerto significativo – visto que as técnicas utilizadas são triviais na área de processamento de imagem e visão computacional, sugerindo que melhores resultados podem ser conseguidos com técnicas mais sofisticadas.

Algumas possibilidades futuras para o trabalho descrito são explorar outros espaços de cor e descritores de forma e se adicionar uma etapa de análise por textura, com o objetivo de se capturar informações que não podem ser avaliadas por cor ou forma. Também se faz necessário se desenvolver uma técnica para cruzar as informações das duas classificações de modo a otimizar o resultado da classificação final.

Agradecimentos

Agradecemos ao apoio financeiro da Cooxupé, Guaxupé, MG, aos alunos Gabriel Marcondes, Daniel Bueno e Alex Rodrigues pelas contribuições na fase inicial do projeto.

Referências

- Bewley, J.D. & Black, M., *Seeds: physiology of development and germination*. 2a edição. New York, USA: Plenum Press, 1994.
- Brasil, , *Regras para análise de sementes*. Brasília, DF: Ministério da Agricultura e Reforma Agrária, SNDA/DNDV/CLAV, 1992.
- Brasil, , Ministério da Agricultura, Pecuária e Abastecimento. *Instrução Normativa N° 8*, de 11 de junho de 2003. Diário Oficial da União. Sessão I. 2003. 20 ago.
- Chaves-González, J.M.; Vega-Rodríguez, M.A.; Gómez-Pullido, J.A. & Sánchez-Pérez, J.M., Detecting skin in face recognition systems: a colour space study. *Digital Signal Processing*, 20(3):806–823, 2010.
- Costa, L.F. & Cesar Jr., R.M., *Shape Analysis and Classification: Theory and Practice*. Boca Raton, USA: CRC Press, 2000.
- Ferreira, T. & Rasband, W.. *The ImageJ User Guide* 1.44, 2011. p. 111–112. [Http://imagej.nih.gov/ij/docs/user-guide.pdf](http://imagej.nih.gov/ij/docs/user-guide.pdf).
- Gonzalez, R.C. & Woods, R.E., *Digital Image Processing*. 2a edição. Upper Saddle River, USA: Prentice Hall, 2001.
- Jain, A.K., *Fundamentals of Digital Image Processing*, Englewood Cliffs, USA: Prentice Hall. p. 392–394.
- Khatchatourian, O. & Padilha, F.R.R., Reconhecimento de variedades de soja por meio do processamento de imagens digitais usando redes neurais artificiais. *Engenharia Agrícola*, 28(4):759–769, 2008.
- Krzyzanowski, F.C.; França Neto, J.B. & Henning, A.A., Relato de testes de vigor disponíveis para as grandes culturas. *Informativo ABRATES*, 1(2):15–50, 1991.
- MacDougall, D.B. (Ed.), *Colour in food: Improving quality*. Boca Raton, USA: CRC Press, 2002.
- Marcos Filho, J., Utilização de testes de vigor em programas de controle de qualidade de sementes. *Informativo ABRATES*, 4(2):59–61, 1995.
- Silva, I.N.; Spatti, D.H. & Flauzino, R.A., *Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas: Um Curso Prático*. Porto Alegre, RS: Artliber, 2010.
- Vieira, R.D., *Testes de vigor em sementes*. Jaboticabal, SP: FUNEP/UNESP, 1994.
- Zhang, D. & Lu, G., Review of shape representation and description techniques. *Pattern Recognition*, 37(1):1–19, 2004.

Notas Biográficas

Pedro Ivo de Castro Oyama é graduado em Engenharia de Computação (UFSCar, 2010) e atualmente é mestrando em Engenharia da Elétrica na USP São Carlos.

Lúcio André de Castro Jorge é graduado em Engenharia Elétrica (Faculdade de Engenharia de Barretos, 1987), mestre em Ciência da Computação (USP São Carlos, 2001) e doutor em Engenharia Elétrica na área de processamento digital de imagens (USP São Carlos, 2011). Atualmente é pesquisador da EMBRAPA Instrumentação em São Carlos.

Evandro Luis Linhari Rodrigues é graduado e mestre em Engenharia Elétrica (Escola de Engenharia de Lins, 1983 e Universidade de São Paulo, 1992), e doutor em Física (Universidade de São Paulo, 1998). Atualmente é professor da Universidade de São Paulo no Departamento de Engenharia Elétrica.

Carlos Cesar Gomes é analista de qualidade na Cooperativa Regional de Cafeicultores de Guaxupé Ltda. (Cooxupé)

