



EMANUELLE MORAIS DE OLIVEIRA

**SISTEMA DE VISÃO COMPUTACIONAL PARA
AVALIAÇÃO FÍSICA DE CAFÉS (*Coffea
arabica* L.) DE DIFERENTES COLORAÇÕES**

LAVRAS - MG

2015

EMANUELLE MORAIS DE OLIVEIRA

**SISTEMA DE VISÃO COMPUTACIONAL PARA AVALIAÇÃO FÍSICA
DE CAFÉS (*Coffea arabica* L.) DE DIFERENTES COLORAÇÕES**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Ciência dos Alimentos, área de concentração Ciência dos Alimentos, para a obtenção do título de Mestre.

Orientadora

Dra. Rosemary Gualberto Fonseca Alvarenga Pereira

Coorientador

Dr. Bruno H. G. Barbosa

LAVRAS - MG

2015

**Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).**

Oliveira, Emanuelle Morais de.

Sistema de visão computacional para avaliação física de cafés
(*Coffea arabica* L.) de diferentes colorações / Emanuelle Morais de
Oliveira. – Lavras : UFLA, 2015.

104 p. : il.

Dissertação(mestrado acadêmico)–Universidade Federal de
Lavras, 2015.

Orientador(a): Rosemary Gualberto Fonseca Alvarenga Pereira.
Bibliografia.

1. Redes neurais. 2. Café. 3. Sistema de visão computacional. I.
Universidade Federal de Lavras. II. Título.

EMANUELLE MORAIS DE OLIVEIRA

**SISTEMA DE VISÃO COMPUTACIONAL PARA AVALIAÇÃO FÍSICA
DE CAFÉS (*Coffea arabica* L.) DE DIFERENTES COLORAÇÕES**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Ciência dos Alimentos, área de concentração Ciência dos Alimentos, para a obtenção do título de Mestre.

APROVADA em 27 de fevereiro de 2015.

Dr. Danton Diego Ferreira UFLA

Dra. Mirian Pereira Rodarte UFJF

Dra. Rosemary Gualberto Fonseca Alvarenga Pereira
Orientadora

Dr. Bruno H. G. Barbosa
Coorientador

LAVRAS - MG

2015

*À minha mãe que sempre foi meu chão, em seus longos conselhos me fez a mulher que sou hoje, graças a seu esforço e amor. Sozinha lutou e conseguiu o que prometeu a meu pai. Sempre ao meu lado nos momentos felizes e tristes.
Amo-te, meu pai e mãe – Teresinha.*

DEDICO

AGRADECIMENTOS

Agradeço em primeiro lugar a Deus por iluminar meu caminho e por ser meu guia. Agradeço à Universidade Federal de Lavras pela minha formação, pelo apoio concedido dos Departamentos. Agradeço à FAPEMIG pelo apoio ao projeto, a Capes pelo financiamento e apoio enquanto fui bolsista.

Agradeço ao Programa de Pós- graduação em Ciência dos Alimentos pelo aprendizado disponibilizado por meio dos professores e do meu orientador.

Agradeço ao pessoal do Polo de Tecnologia do Café pela ajuda e amizade à Adriene, Fernanda, Katiany, Miriam Helena, Edson, Larissa e Mirian Rodarte, Raquel.

Agradeço, em especial, à minha amiga Sandra que foi minha parceira nestes momentos difíceis de viagens por que passei, ela sempre esteve ao meu lado me ajudando e me aconselhando.

Agradeço ao professor Bruno e ao Dimas pela grande ajuda e contribuição no artigo, pelas longas reuniões que tivemos todas as sextas e paciência nos resultados e momentos mais conturbados.

Agradeço em especial à minha orientadora Rosemary Gualberto que vem me acompanhando por mais de cinco anos. Agradeço, primeiramente, a amizade, os conselhos que somente ela, com sua experiência, saberia me auxiliar. Agradeço a orientação em todos os momentos, a compressão pela fase conturbada que passei e, principalmente, o apoio que sempre me deu. Agradeço o conhecimento passado para mim em todos os momentos até nos nossos cafezinhos. Agradeço, em especial, a alegria e preocupação que sempre teve comigo fazendo com que eu me sentisse em casa e protegida por uma pessoa com um coração enorme, enfim agradeço tudo que fez por mim e faz pelos seus orientados.

Agradeço ao IFMG pelo apoio para minha capacitação e pelo entendimento nos meus horários das sextas - feiras para o mestrado.

À minha mãe, que sempre esteve ao meu lado, apoiando-me em tudo!
Às minhas irmãs Ellen, Suellen e a Melzinha pela amizade e companheirismo. À minha Tia Lica, às minhas amigas Mayara, Paula, Sandra, Raquel que estiveram ao meu lado nas horas difíceis e, também, na diversão.

Também, em especial, à minha mais nova família Flávio H. e Belinha vocês são minha base, meu espelho para a vida, amo vocês mais que tudo nesta vida. Flávio, agradeço a sua paciência e compreensão comigo, sabemos que não foi fácil chegar aqui, mas você foi meu parceiro e, ainda, continuaremos na nossa jornada, muito obrigada, você é luz na minha vida.

E a todos que de alguma maneira contribuíram para realização deste sonho.

RESUMO GERAL

A cor do café varia em decorrência da espécie, condições de armazenamento e tipo de processamento. A avaliação da cor nos grãos de café é feita por inspeção visual por provadores treinados, método este subjetivo. Existe, assim, a demanda pelas empresas de comércio por metodologias rápidas e objetivas para avaliação da cor. O sistema de visão computacional surge como uma alternativa para verificação da cor em grãos de café, assim, objetiva-se com este trabalho a construção de um sistema de visão computacional para identificação das diferentes cores nos grãos de café. Para isso, foi realizada uma conversão do RGB de câmaras digitais, visto que são capazes de obter informações em pixels, nos parâmetros de cor L^* , a^* e b^* para cada pixel da imagem digital, obtendo assim uma informação mais geral da cor do grão de café. Para criação do sistema de visão computacional, foram utilizados: uma caixa metálica escura, câmera digital, sistema de iluminação e um software processador de imagens baseado em redes neurais. Na construção do modelo de transformação, foram usadas cartelas de cores e para o reconhecimento do padrão foram adquiridas amostras de cafés de diferentes colorações: esbranquiçadas, verde cana, verde e verde azulada. Cada classe de cor possuía 30 amostras contendo 50 g cada. Além disso, foi utilizado um sistema de classificação (classificador bayesiano) para separação das amostras em classes e verificação da eficiência do sistema criado. O modelo de transformação destacou-se com um erro de apenas $1,20 \pm 1,24$ para treinamento e $1,15 \pm 1,1$ para o teste. O sistema de classificação bayesiano foi eficiente para classificação das amostras utilizadas na validação dentro das classes. As amostras foram classificadas dentro das classes de cores, o que representa uma eficiência de 100%. Por meio dos resultados obtidos, verificou-se que as amostras esbranquiçadas apresentaram um elevado valor dos parâmetros L^* , a^* e b^* o que representa uma aproximação ao branco, já as amostras verde cana e verde mostraram valores dos parâmetros intermediários, porém o parâmetro b^* para a verde cana foi mais alto demonstrando um amarelamento da amostra. As amostras verdes obtiveram valores mais baixos de a^* o que demonstra que esta está mais próxima da cor verde, no entanto as amostras verde azuladas apresentaram baixos valores de L^* , a^* e b^* o que representa a aproximação as cores verde e azul. As amostras de diferentes cores foram eficientemente classificadas demonstrando a eficácia do sistema de visão computacional. O sistema implementado neste trabalho poderá futuramente ser expandido para cooperativas e empresas proporcionando uma maneira mais rápida e objetiva de avaliação da cor.

Palavras-chave: Cor. Café. Redes neurais. Sistema de visão computacional.

GENERAL ABSTRACT

The color of coffee varies due to species, storage conditions and type of processing. The evaluation of coffee bean color is done by visual inspection by trained panelists, a very subjective method. Thus, trading companies demand for rapid and objective methods for color evaluation. The computer vision system emerges as an alternative for verifying the color of coffee beans, therefore, this work aims at building a computer vision system for identifying the different colors in coffee beans. To do so, we performed a conversion of the RGB of digital cameras, given that they are capable of obtaining information in pixels in the color parameters $L^* a^* b^*$ for each pixel of the digital image, thus obtaining a more complete set of information on the coffee bean color. In order to create the computer vision system, we used: a dark metal box, digital camera, lighting system and an image processing software based on neural networks. For the construction of the transformation model, we used color cards and, for the pattern recognition, we acquired coffee samples in different colors: off-white, sugarcane green, green and blue-green. Each color class presented 30 samples containing 50g each. In addition, we used a classification system (Bayesian classifier) to separate the samples into classes and verify the efficiency of the created system. The transformation model stood out with an error of only $1.20 + 1.24$ for training and of $1.15 + 1.1$ for testing. The Bayesian classifying system was efficient for classifying the samples used for validation within the classes. The samples were classified within the color classes, which represents an efficiency of 100%. With the results obtained, we verified that the off-white samples showed a high value of the L^* , a^* and b^* parameters, which represents an approximation to white, while the sugarcane green and green samples showed intermediate parameter values; however the b^* parameter for sugarcane green was higher, showing a certain yellowing of the sample. The green samples presented lower a^* values, demonstrating that it is closer to the green color. However, the blue-green samples showed low values of L^* , a^* e b^* , which represents the approximation to green and blue colors. The different color samples were efficiently classified, demonstrating the efficiency of the computer vision system. The system implemented in this work can be expanded to cooperatives and companies in the near future, providing a faster and more objective way to evaluate color.

Keywords: Color. Coffee. Neural networks. Computer vision system.

LISTA DE FIGURAS

PRIMEIRA PARTE

Figura 1	Representação em 3D do espaço de cor RGB	25
Figura 2	Representação do modelo CIEL*a*b*. <i>White</i> = Branco, <i>Green</i> = Verde, <i>Black</i> = Preto, <i>Yellow</i> = amarelo, <i>Red</i> = Vermelho, <i>Blue</i> = Azul (APACHE TECHNOLOGIES, 2014)	28
Figura 3	Modelo de um sistema computacional (LEÓN et al., 2006)	32
Figura 4	Representação das áreas e subáreas da Inteligência Computacional.....	38
Figura 5	Representação da estrutura de uma rede neural (REDES..., 2015)	41
Figura 6	Funcionamento de um neurônio artificial.....	42
Figura 7	Rede multilayer feedforward	48

SEGUNDA PARTE – ARTIGO 1

Fig. 1.	Image acquisition system developed to classify coffee beans.	68
Fig. 2.	Examples of color charts used to identify the transformation model	70
Fig. 3.	Histograms of CIELAB measurements taken from the Minolta colorimeter over the available color charts. (a) L^* , (b) a^* , and (c) b^* values.	71
Fig. 4.	Steps used to build the RGB–CIELAB transformation model.	72
Fig. 5.	Structure of the three artificial neural networks used for RGB– CIELAB transformation. Each NN yields one output, L, a or b color units.	73

Fig. 6.	Image acquisition and pre-processing of coffee beans samples. (a) image without pre-processing; (b) image after removal of the black background.	75
Fig. 7.	CIELAB values of the available coffee beans samples (WH- whitish samples, CG- cane green samples, GR- green samples and BG- bluish-green samples).	78
Fig. 8.	Distribution of a* and b* values according to the color classes: WH- whitish samples, CG- cane green samples, GR- green samples and BG- bluish-green samples.	79

LISTA DE TABELAS

PRIMEIRA PARTE

Tabela 1 Conjunto de treinamento para prever o problema de inadimplência.....	50
---	----

SEGUNDA PARTE - ARTIGO 1

Table 1. Mean and standard deviations of errors obtained by the color space transformation models based on artificial neural networks.	77
Table 2. Mean values of color parameters for each class estimated by the Naive-Bayes classifier.	78

SUMÁRIO

	PRIMEIRA PARTE	
1	INTRODUÇÃO	13
1.1	Organização do trabalho	14
2	REFERENCIAL TEÓRICO	16
2.1	Aspectos comerciais e econômicos do café no Brasil	16
2.2	Avaliação física do café beneficiado	16
2.3	A cor em alimentos	19
2.3.1	Cor do café	20
2.4	Espaços de cores	23
2.5	Medição por meio de inspeção visual	28
2.6	Métodos instrumentais de avaliação da cor	29
2.7	Sistema de visão computacional	30
2.7.1	Iluminação	32
2.7.2	Câmera digital	33
2.7.3	Software processador de imagem	34
2.8	Inteligência Computacional	38
2.8.1	Reconhecimento de padrões	39
2.8.2	Redes Neurais	40
2.8.3	Projeto de uma rede neural	45
2.8.4	Redes Perceptron	46
2.8.5	Classificador Bayesiano	48
	REFERÊNCIAS	51
	SEGUNDA PARTE – ARTIGO	62
	ARTIGO 1 A classification system for coffee grades based on computational intelligence techniques	62
	ANEXOS	85

PRIMEIRA PARTE

1 INTRODUÇÃO

O café constitui uma das principais fontes de divisas do Brasil, porém o aumento da produção e a melhoria da qualidade dos cafés de outros países fizeram com que o Brasil verificasse a necessidade de uma busca de novas tecnologias e, atualmente, vem buscando por métodos físicos que auxiliem na avaliação da qualidade do café.

As diferentes colorações dos grãos de café cru podem provir de problemas, durante processamento,, em virtude da utilização de diferentes processos, tipo de cultivar, altitude da plantação, secagem e armazenamento.

A Instrução Normativa nº 8 é que normatiza a classificação física do café no Brasil (BRASIL, 2003), já a Specialty Association of America é uma associação que delega as diretrizes dos cafés especiais (SPECIALTY COFFEE ASSOCIATION OF AMERICA - SCAA, 2014). Ambas descrevem e classificam as cores que os grãos de café apresentam após o beneficiamento.

Os procedimentos de avaliação da cor dos grãos de café crus são subjetivos, limitando-se a uma série de comparações visuais do produto, com a desvantagem dos resultados obtidos serem influenciados pelo julgamento e pelas limitações do observador. Assim, existe a necessidade da criação de métodos objetivos para a avaliação da cor, que permitam melhor definição das condições de iluminação e observação.

A utilização de inteligência computacional baseada em redes neurais surgiu como uma alternativa para verificação da cor em alimentos. O espaço de cor utilizado e as variáveis obtidas, durante a calibração do sistema, envolvem características do alimento e outras externas como luz, câmera fotográfica e temperatura. Além de avaliar de forma mais geral o alimento analisando cada

pixel da superfície. Outros instrumentos de avaliação da cor como colorímetros e espectrofotômetros analisam a cor pontual do alimento não fornecendo uma análise geral da coloração, assim o sistema de visão computacional oferece a vantagem de proporcionar uma análise que envolve toda superfície deste.

Atualmente, para um classificador memorizar e descrever a cor dos grãos de café, são utilizados muitos termos, o que dificulta a descrição, já que há muitas nuances e variações. Alguns desses termos são confusos e demasiadamente subjetivos, como as denominações verde carregado, desbotado, esverdeado para azul, esverdeado para azulado e outros.

Uma classificação adequada pela cor poderá ser satisfatória com a utilização de instrumentos capazes de expressar valores numéricos e nominais de cor em uma linguagem de fácil compreensão e que permita a percepção da cor sem a necessidade da destruição da amostra. Assim, este trabalho foi realizado com o objetivo de construir um sistema de visão computacional baseado em redes neurais para classificação da cor de cafés beneficiados.

1.1 Organização do trabalho

A dissertação está organizada da seguinte maneira. Na primeira seção tem-se uma introdução geral do assunto abordado e os objetivos do estudo. A próxima seção apresenta o Referencial Teórico, no qual é introduzida a relevância do problema a ser estudado e as ferramentas que serão utilizadas ao longo do trabalho.

Na terceira seção é desenvolvido um artigo no qual são utilizados os procedimentos metodológicos introduzidos na seção anterior. Esta seção tem no início uma introdução específica que segue para os materiais e a metodologia utilizados para desenvolvimento do mesmo. Assim, tem-se a apresentação dos

resultados e discussão destes. E, por fim, as conclusões obtidas com base no trabalho proposto e possíveis trabalhos futuros.

2 REFERENCIAL TEÓRICO

2.1 Aspectos comerciais e econômicos do café no Brasil

O café sempre teve alta participação no agronegócio brasileiro, sendo o segundo produto de maior exportação agrícola. De acordo com a Companhia Nacional de Abastecimento - CONAB (2015), a primeira estimativa para produção da safra cafeeira (espécies arábica e conilon) em 2015 indica que o país deverá colher entre 44,11 e 46,61 milhões de sacas de 60 quilos de café beneficiado.

O café arábica representa em 2015, 73,7% da produção total (arábica e conilon) de café do país. O resultado expressivo se deve, principalmente, ao crescimento de produção na região da Zona da Mata mineira, que compensou as perdas nas demais regiões do estado, sobretudo nas regiões do Triângulo, Alto Paranaíba e Noroeste. E, também, ao crescimento estimado na produção paranaense, a qual, na safra anterior, teve uma produção 88,6% abaixo do normal, em razão das condições climáticas adversas, principalmente, das baixas temperaturas (CONAB, 2015).

2.2 Avaliação física do café beneficiado

Após o beneficiamento, o café é caracterizado, em função de sua qualidade, esta caracterização é conhecida como classificação física (FIGUEIREDO et al., 2009). No Brasil as principais normas responsáveis pela classificação física do café são descritas pela COB (Classificação Oficial Brasileira) a qual é baseada na Instrução Normativa nº 8. A instituição da IN nº 8 foi para cumprir o disposto no Artº 1º da Lei 9.972, de 25.05.00, servindo

exclusivamente para normalizar a compra e a venda de café pelo governo (BRASIL, 2003).

A Instrução Normativa nº 8 (ANEXO A) foi criada pelo Ministério da Agricultura, Pecuária e Abastecimento em 11 de junho de 2003 tendo como objetivo a definição das características de identidade e de qualidade para classificação do café beneficiado grão cru. Na normativa estão descritos os critérios para classificação dos cafés em categoria, subcategoria, grupo, subgrupo, classe e tipo, segundo a espécie, formato do grão e a granulometria, o aroma e o sabor, a bebida, a cor e a qualidade, respectivamente (BRASIL, 2003).

De acordo com a Instrução Normativa nº8, os cafés deverão ser classificados de acordo com a cor em:

- a) verde azulado e verde cana: corresponde a cores características do café despulpado ou degomado;
- b) verde: café com grão de coloração verde em suas nuances;
- c) amarelada: café com grãos de coloração amarelada, indicando sinais de envelhecimento do produto;
- d) amarela;
- e) marrom;
- f) chumbado;
- g) esbranquiçado;
- h) discrepante: mistura de cores provenientes de ligas de diferentes safras.

A alta qualidade de grãos crus relaciona-se ao termo cafés especiais, o qual também está ligado aos grãos torrados, aos seus potenciais aromáticos e aos padrões de preparo pré- estabelecidos. A SCAA (Specialty Coffee Association of America – Associação de Café Especiais da América) é uma organização civil

de comércio para a indústria de cafés visando estabelecer padrões de qualidade para o cultivo, torrefação, processamento e consumo de cafés especiais (SCAA, 2014).

De acordo com SCAA, os grãos crus de café deverão ser classificados de acordo com a cor em (ANEXO B):

- a) azul esverdeado;
- b) verde azulado;
- c) verde;
- d) esverdeado;
- e) verde amarelado;
- f) amarelo pálido;
- g) amarelado;
- h) amarronzado.

De acordo com Borém et al. (2013), a cor do grão de café está relacionada com a qualidade da bebida e é um fator importante para a comercialização do produto. Segundo Monteiro (2002), a cor é uma das características que mais chama a atenção, durante o processo de comercialização, pois dela dependerá a aceitação e rejeição pelo comprador. Ribeiro et al. (2011) alertam que grãos de cafés crus descoloridos recebem menor preço no mercado.

A diferenciação de cor nos grãos de café cru já foi descrita por muitos autores (AFONSO JÚNIOR; CORRÊA, 2003; AMORIM, 1978; BORÉM et al., 2013; CORRÊA et al., 2003; RIBEIRO et al., 2011; VILELA; CHANDRA; OLIVEIRA, 2000) como um processo conhecido por branqueamento, no qual a cor do café muda gradualmente de verde-azulada para amarelada ou esbranquiçada. A intensidade do branqueamento dependerá da cultivar, das

condições ambientais de algum dano que o grão possa vir a sofrer, umidade, tipo de processamento, secagem, tempo de armazenamento e tipo de embalagem.

2.3 A cor em alimentos

A cor é uma resposta mental da percepção da luz no espectro visível (distribuição de luz em energia em determinado comprimento de onda) refletida ou emitida por um objeto. Tal sinal de resposta interage no olho com a retina e é, então, transmitido ao cérebro pelo nervo óptico, o que torna possível a capacidade humana de atribuir cores a este sinal. Portanto, a cor não é uma propriedade intrínseca do objeto, uma vez que, se a fonte de luz é alterada, a cor do objeto, também, muda (MELENDEZ-MARTINEZ; VICARIO; HEREDIA, 2005; WU; SUN, 2013b).

A percepção da cor é um fenômeno muito complexo, que depende de fatores relacionados, por exemplo: iluminação ambiente, as características do olho, cérebro e os ângulos de iluminação e visualização (WU; SUN, 2013b).

A cor da superfície de um alimento é o primeiro parâmetro de qualidade avaliado pelos consumidores e é crítica para a aceitação do produto (LEÓN et al., 2006). A qualidade individual de cada produto é julgada durante toda cadeia produtiva que envolve a produção, estocagem, marketing e utilização. A base para determinação da qualidade em todas as etapas é a determinação do aspecto (KAYS, 1999). O aspecto é avaliado considerando o tamanho, forma, cor, condições de frescura e, finalmente, a ausência de defeitos visuais (COSTA et al., 2011; MCCAIG, 2002).

Após a primeira avaliação visual da qualidade do produto, o consumidor vai julgar o alimento com base em outros atributos sensoriais, como gosto e aroma. Mas a cor tem grande influência ainda nesta etapa, pois dependendo da aceitação ou rejeição da cor, o consumidor poderá tentar prever a sensação de

sabor e aroma que está por vir influenciando, assim, a resposta que poderia ter sem a visualização anterior da cor. Assim, a compreensão dos fatores que modulam a cor de um produto desejável ou indesejável é essencial (LEÓN et al., 2006).

2.3.1 Cor do café

Das características que dependem do aspecto físico dos grãos de café crus, a cor tem grande importância econômica, pois grãos descoloridos recebem menor preço no mercado, portanto esta característica interfere decisivamente no processo de comercialização, pois dela dependerá a aceitação ou rejeição pelo comprador (RIBEIRO, 2013).

Segundo Corrêa, Afonso Júnior e Pinto (2002), a coloração do grão de café, assim como a da película prateada, geralmente está relacionada com a qualidade da bebida, e é um fator importante na valorização do produto. Essa característica é indicativa do estágio de maturação, condições de secagem, armazenamento inadequado, alterações bioquímicas ou realização apropriada ou não, de um tratamento tecnológico.

Os frutos do cafeeiro, quando colhidos em seu ponto ótimo de maturação (estádio de cereja) e após processados, resultam em grãos crus ou beneficiados que apresentam coloração verde. Neste estágio, a composição química permite que as sementes contidas nos frutos expressem sua máxima qualidade, como foi demonstrado pelos autores Amorim e Teixeira (1975), Garruti e Gomes (1961) e Sampaio e Azevedo (1989).

Oliveira et al. (2013) observaram diferenças sensoriais significativas entre diferentes bebidas de café. Cafés de melhor qualidade mantêm a coloração característica, enquanto cafés de pior qualidade sofrem reações oxidativas, com consequente branqueamento. Lopes, Hara e Silva (1998) citam a tonalidade

azul- esverdeada como indicativa de grãos de melhor qualidade, mediante a prova de xícara.

Os cafés podem adquirir diferentes cores, as quais dependerão principalmente dos seguintes fatores:

- a) altitude;
- b) cultivar;
- c) processos de preparo (colheita e processamento);
- d) secagem;
- e) condições de armazenamento.

A cor intrínseca dos grãos pode estar relacionada a um destes fatores ou a associação de todos. Na literatura científica são raros artigos elucidativos sobre este tema.

Existe uma ampla gama de cultivares de café as quais apresentam as mais variadas características. A cor também varia quanto à cultivar a exemplo da cultivar Cera que apresenta grãos amarelados. Autores como Mazzafera, Guerreiro e Carvalho (1984) realizaram comparações entre as sementes dos cultivares Mundo Novo de café arábica com os do cultivar Cera, não houve variação significativa no teor de clorofila entre estes grãos, porém diferenças foram constatadas quanto ao teor de carotenoides.

Na pós- colheita há dois tipos de processamento: via seca e úmida. No processamento por via seca, o fruto é secado na sua forma integral (com casca), dando origem aos cafés denominados como coco ou naturais (MALTA, 2011; MALTA; CHAGAS; CHALFOUN, 2008).

O preparo por via úmida pode originar os cafés cereja descascado, despolpado e desmucilado. Para a obtenção do café cereja descascado, os frutos são descascados mecanicamente e parte da mucilagem que ainda permanece

aderida ao endocarpo dos frutos. Na obtenção do café despulpado, após o descascamento, a parte da mucilagem que ainda estava aderida aos frutos é removida em tanques de fermentação biológica. Se a remoção desta mucilagem remanescente for realizada mecanicamente, tem-se, então, o café desmucilado (MALTA, 2011).

Corrêa, Afonso Júnior e Pinto (2002) e Oliveira et al. (2013) estudaram a influencia das diferentes formas de processamento sobre a coloração dos grãos de café. Segundo estes autores, o processamento via úmida diminui a aproximação da coloração indesejável vermelho- amarelado e aproxima da coloração desejável verde- azulado (menores valores dos parâmetros L^* , a^* e b^*), já o processamento via seca indica um maior potencial dos grãos de café para o branqueamento (maiores valores dos parâmetros L^* , a^* e b^*).

Assim a retirada do exocarpo e mesocarpo nos cafés processados por via úmida contribui para a aproximação da coloração azulada, a qual provavelmente esta relacionada à manutenção da qualidade do produto (CORRÊA; AFONSO JÚNIOR; PINTO, 2002).

A cor é alterada por vários fatores presentes durante a etapa de secagem como: velocidade do ar de secagem, temperatura, tipo de secador, umidade relativa, condições de secagem, entre outros.

Coradi, Borém e Oliveira (2008) estudaram a influência de diferentes tipos de secagem (natural, secador mecânico a 40° e 60°C) na cor dos grãos de café. Verificaram que a secagem altera a cor dos grãos de café, especialmente em secadores mecânicos. Sugeriram, também, que a utilização de temperaturas superiores a 80°C favorece o surgimento de uma coloração amarelada nos grãos que, ao reabsorverem umidade, as temperaturas provocam branqueamento irregular. Por outro lado, a secagem em terreiro, por utilizar apenas temperatura ambiente, afeta as características da cor dos grãos, quando comparada aos cafés secados sob temperaturas mais elevadas nos secadores.

Oliveira et al. (2013) verificaram que o aumento da temperatura do ar de secagem reduz a intensidade de cor verde, independentemente do processamento empregado.

As interações entre fatores abióticos, como temperatura, teor de água, concentração de gases, umidade relativa (principalmente para valores acima de 80%), tipo e condições do armazém, características do sistema de armazenagem e fatores bióticos, como grãos, insetos, ácaros, fungos e bactérias, fazem com que os grãos armazenados se tornem um ecossistema cuja dinâmica, dependendo dos níveis dos fatores e do grau de interação, pode levar ao processo de deterioração dos mesmos, com maior ou menor velocidade (RIGUEIRA et al., 2009).

A influência da luz durante o armazenamento foi estudada por Lopes (2000) o qual verificou que nem todos os comprimentos de onda têm efeito maléfico na cor dos grãos de café. A exposição do grão de café à luz branca e à luz transmitida nos comprimentos de onda da faixa do violeta- azul é que provocaram alterações na cor e qualidade da bebida do café.

Vários autores já descreveram que o café natural é menos susceptível à descoloração por possuir todos os revestimentos externos o que contribui para a sua proteção, reduzindo assim os efeitos ambientais (AFONSO JÚNIOR; CORRÊA, 2003; OLIVEIRA et al., 2013; RIGUEIRA et al., 2009).

2.4 Espaços de cores

O olho humano distingue as cores, de acordo com a variação da sensibilidade das células na retina e de acordo com o comprimento de onda da luz incidente. Existem três tipos de células fotorreceptoras (chamados cones) para o homem, com sensibilidade em picos de comprimentos de onda de curta

duração (azulada, 420 e 440 nm), média (esverdeada, 530 e 540 nm) e longa (avermelhado, 560 e 580 nm) (HUNT, 1995).

A sensação de cor é formada por estes três componentes de cor nos olhos, os quais são chamados de valores tristímulos. Estes valores são gerados com base nos três tipos de cones na medida em que cada um é estimulado (WU; SUN, 2013b).

O espaço de cor é um modelo matemático cujo objetivo é associar os valores tristímulos com cada cor. Atualmente existem três tipos de espaços de cor os quais correspondem a: espaço orientado para o hardware, espaço orientado para o humano e o espaço instrumental (SANTANA et al., 2006). Alguns destes espaços de cor foram criados para ajudar os seres humanos a selecionar as cores e para facilitar o processamento de dados em máquinas (PASCALE, 2003; WU; SUN, 2013b).

Dentre os espaços de cores, o espaço orientado para o hardware foi proposto para o processamento de um hardware, tais como a aquisição de imagem, armazenamento e visualização. Este espaço é completo e pode detectar uma pequena variação na cor especialmente em avaliações para produtos alimentícios. Assim este espaço para hardware vem sendo amplamente empregado para avaliação de alimentos principalmente durante o processamento onde são avaliados os estádios de maturação, os efeitos da temperatura e tempo durante armazenamento. Vários autores descreveram o emprego deste espaço para avaliação de alimentos, como, por exemplo, Liliana et al. (2007) e Uribe, Giraldo e Tascon (2008) que analisaram a cor de frutos do cafeeiro em diferentes estágios de maturação.

O espaço de cor orientado para o hardware mais popularmente conhecido é o RGB, ele é definido por coordenadas em três eixos, isto é, vermelha, verde e azul (LEÓN et al., 2006). Ele representa a forma em que câmaras exibem seu trabalho.

Na figura 1 é apresentado o espaço de cor RGB (*red, green, blue*) gerado pelo software livre RGBCube (2014). Este espaço de cor é orientado para hardware.

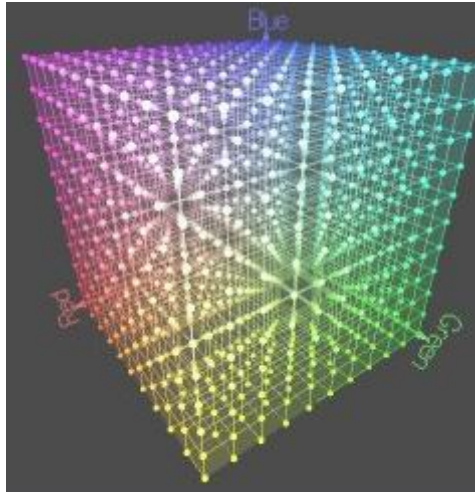


Figura 1 Representação em 3D do espaço de cor RGB

Outros dois espaços orientados para o hardware são o YIQ (luminância, em fases de quadratura) e o CMYK (ciano, magenta, amarelo, preto), principalmente utilizados para a transmissão de televisão e em impressoras, respectivamente, e, portanto, não são utilizados para a medição da cor na indústria alimentar (WU; SUN, 2013b). Já os espaços orientados para humanos correspondem aos conceitos de tonalidade (*hue*), que são definidos com base nas características intuitivas da cor. Em geral, esses espaços têm como base a matiz e a saturação (HS), entre eles tem-se: HSI (matiz, saturação, intensidade), HSV (matiz, saturação, valor), HSL (matiz, saturação, luminosidade) e HSB (matiz, saturação e brilho).

A tonalidade da cor ou matiz é uma comparação entre a cor em observação e exemplos previamente conhecidos. De modo geral, trata-se da

identificação da cor (ou comprimento de onda) dominante, isto é, a determinação de uma luz monocromática que corresponda, aproximadamente, à cor observada. Já a saturação refere-se ao grau de pureza de uma cor, ou seja, alguma graduação que represente uma cor qualquer como uma grandeza entre uma onda monocromática (espectro de frequência com um único fator na frequência da onda) e a luz branca (que contém todas as cores). Assim, as cores monocromáticas têm saturação máxima e a luz branca, mínima (SIMÕES, 2000).

Gomes e Velho (1994) foram uns dos primeiros autores a conceituar o brilho, já que este conceito é de difícil definição por ser considerado subjetivo, segundo eles o brilho é uma grandeza que varia monotonicamente com a luminância. Para Fairchild (2005) o brilho é considerado um atributo de uma sensação visual para emitir leveza.

O espaço de cor HS, diferentemente do espaço RGB (coordenadas cúbicas), usa coordenadas cilíndricas para orientação no espaço. Segundo Du e Sun (2005), os espaços de cor como o HS orientados com base no conceito de percepção visual dos olhos humanos tem medições das cores de fácil utilização e são melhor relacionados às superfícies dos alimentos. Porém, estes espaços não são sensíveis a pequenas variações de cor, sendo, no entanto pouco adequados para avaliação de mudanças na cor dos produtos durante o processamento.

Os espaços instrumentais foram criados para serem usados nos instrumentos de medição de cor. Em 1931 estes espaços foram padronizados pela CIE - Comissão Internacional de Iluminação (Commission Internationale d'Eclairage) e a maioria de suas padronizações permanece até hoje tais como: XYZ e YUV.

O espaço XYZ da CIE foi definido matematicamente por meio da percepção fisiológica da luz. Neste espaço, um conjunto de cores correspondentes a três funções, as quais estão relacionadas com os cones

vermelhos, verdes e azuis nos olhos, é chamado de observador padrão (HUNT, 1998).

No espaço o Y representa leveza, já o X e Z correspondem a dois componentes virtuais que se parecem com uma curva sensível dos cones vermelho e azul. Assim, o XYZ não representa uma gradação uniforme de cor . Por isso dois espaços de cor, o CIE ($L^* a^* b^*$) ou CIELAB e o CIE ($L^* u^* v^*$) ou CIELUV, que são transformações não lineares da XYZ, foram divulgados e ainda são adotados em muitos instrumentos de medição de cores (WU; SUN, 2013b).

Para alimentos o espaço de cor mais utilizado é o $L^* a^* b^*$, ele é perceptivelmente uniforme, ou seja, a distância euclidiana entre duas cores diferentes corresponde aproximadamente à diferença de cor percebida pelo olho humano (LEÓN et al., 2006). As coordenadas polares do sistema $CIE L^* a^* b^*$ são amplamente utilizadas e seus parâmetros variam de:

L^* ou luminosidade \rightarrow 0 (preto) a 100 (branco)

a^* \rightarrow -120 (verde) a 120 (vermelho)

b^* \rightarrow -120 (azul) a 120 (amarelo).

A figura 2 representa este espaço de cor em 3D (três dimensões) para melhor visualização dos parâmetros de cor.




Figura 2 Representação do modelo CIE L*a*b*. *White*= Branco, *Green*= Verde, *Black*= Preto, *Yellow*= amarelo, *Red*= Vermelho, *Blue*= Azul (APACHE TECHNOLOGIES, 2014)

2.5 Medição por meio de inspeção visual

A avaliação sensorial dos alimentos envolve a avaliação qualitativa da cor, nestes casos pessoas treinadas em salas iluminadas verificarão as suas percepções de cor em relação ao alimento. Esta resposta de percepção de cor dependerá da memória e do conhecimento relativo a este alimento.

A inspeção humana é muito subjetiva, já que a percepção de cor é subjetiva, variável, trabalhosa e tediosa, além de envolver a memória de cor para o alimento depende da iluminação e inúmeros outros fatores, portanto não é adequada para a medição da cor em grande escala de rotina (MCCAIG, 2002).

A inspeção visual dos grãos de café crus é um assunto amplamente discutido atualmente, pois provadores treinados e com alto conhecimento têm aprovação para identificação da cor do café.

Segundo vários autores, cafés de boa qualidade têm coloração verde azulada, já cafés esbranquiçados podem resultar em bebida de pior qualidade,

porém algumas empresas de comercialização hoje recebem cafés de outras colorações como verde, esverdeado, verde cana os quais apresentam bebida de boa qualidade, no entanto a cor reconhecida pelos classificadores pode variar daí a necessidade de novos métodos de avaliação objetiva da cor do grão de café (LOPES; HARA; SILVA, 1998; OLIVEIRA et al., 2013).

2.6 Métodos instrumentais de avaliação da cor

Os instrumentos de medição de cor mais utilizados em alimentos são conhecidos como colorímetros. Os colorímetros convencionais costumam fornecer leituras nos espaços de cores: XYZ, RGB, e L^* , a^* , b^* (MENDOZA; AGUILERA, 2004). Colorímetros tais como: (i) Minolta Chroma Meter; (ii) colorímetro Hunter Lab e (iii) Colorímetros Dr. Lange (LEÓN et al., 2006) oferecem como resultado as coordenadas polares do sistema CIEL*a*b*.

Embora os colorímetros forneçam medições de cores simples e rápidas eles apresentam algumas limitações (YAGIZ et al., 2009; YAM; PAPADAKIS, 2004). O problema é que a medição da cor pelo colorímetro apenas é realizada na superfície da amostra (alimento) que é pequena podendo ser uniforme ou não. Por isso é importante a obtenção de uma amostra representativa, pois se a superfície do alimento se apresentar de forma homogênea, a representação é facilmente obtida, porém se este alimento for mais heterogêneo a superfície de abrangência de medição deverá ser maior para que se possa ter uma amostra representativa (LEÓN et al., 2006; WU; SUN, 2013b; YAGIZ et al., 2009; YAM; PAPADAKIS, 2004).

Assim para se obter uma caracterização detalhada da imagem de um produto alimentício e para que sua qualidade seja avaliada com precisão é necessário saber o valor de cada pixel da superfície do mesmo (LEÓN et al., 2006). Então a utilização de medições instrumentais como colorímetros não é

ideal, o que demanda a criação de novos processos automatizados de medição de cor, com análise de cada pixel da superfície de uma amostra promovendo deste modo uma avaliação rápida e geral da superfície do alimento sem ocasionar danos de qualquer natureza.

Outro instrumento bastante utilizado para verificação da cor de alimentos corresponde aos espectrofotômetros os quais são capazes de fornecer coordenadas colorimétricas ($L^*a^*b^*$). Estes equipamentos fazem a varredura de toda a faixa de medição visível, em intervalos discretos de 1, 5, 10 ou 20 nm, de acordo com sua resolução.

Nos espectrofotômetros ajustados para operar no comprimento de onda do espectro visível, aproximadamente de 380 a 770 nm, pode-se obter o índice colorimétrico de qualquer objeto pela quantidade de luz refletida ou absorvida por sua superfície em cada comprimento de onda desse espectro (FERREIRA, 1981).

2.7 Sistema de visão computacional

Sistemas de visão computacional são tecnologias de engenharia que combinam mecânica, instrumentação óptica, câmera digital e tecnologia de processamento de imagem (PATEL et al., 2012). Empregam métodos e técnicas que permitem ao computador extrair conteúdos relevantes a partir de imagens e interpretar as suas características mais significativas para alcançar objetivos tais como classificação, avaliação da qualidade e detecção de defeitos (GOMES; LETA, 2012).

Nos últimos anos, a visão computacional surgiu como uma alternativa para avaliação da cor em alimentos principalmente por apresentar algumas vantagens frente a outras metodologias como, por exemplo: a rapidez, objetividade, abrangência e eficiência.

A técnica de visão computacional consiste na utilização de um sistema envolvendo um iluminante, uma câmera digital e um software de processamento de imagem (YAM; PAPADAKIS, 2004). Esta técnica corresponde a uma ciência que se desenvolveu com base em algoritmos que vão extrair e analisar informações úteis de um objeto ou cena a partir de uma imagem, conjunto imagem ou sequência de imagens (DU; SUN, 2006; WU; SUN, 2013b).

No sistema computacional, as imagens são obtidas e avaliadas de acordo com os pixels de cada uma, isso faz com que ele forneça uma análise mais especializada e detalhada da amostra avaliada.

Segundo Balaban e Odabasi (2006), a diferença primordial entre a visão computacional e a colorimetria convencional é a quantidade de informação espacial fornecida por ambas. Uma alta resolução espacial permite avaliar cada pixel da superfície inteira da amostra, calcular a média e desvio padrão de cor, isolar e especificar a aparência, medir a textura e cor, avaliar mais de uma amostra ao mesmo tempo, gerar mapa de distribuição de cores e proporcionar um registro permanente por meio da imagem sem o contato e sem destruição da amostra (LEÓN et al., 2006). A visão computacional oferece uma resolução alta e por isso vem sendo comumente preferida como método de avaliação da cor.

Os sistemas de visão computacional foram utilizados para avaliar a qualidade e comercialização de muitos alimentos como: alcachofras (AMODIO et al., 2011) e vegetais recém-colhidas nectarinas (PACE et al., 2011), alface (PACE et al., 2014), carnes (LARRAIN; SCHAEFER; REED, 2008), peixes (YAGIZ et al., 2009) e bebidas (FERNANDEZ-VAZQUEZ et al., 2011).

A figura 3 ilustra um modelo de sistema computacional.




Figura 3 Modelo de um sistema computacional (LEÓN et al., 2006)

Como já descrito anteriormente, durante a avaliação da cor de um alimento pelo sistema de visão computacional, são necessários um sistema de iluminação, uma câmera digital de alta resolução e um software processador de imagem, a seguir estes itens serão discutidos separadamente.

2.7.1 Iluminação

Diversos fatores externos podem contribuir para alteração da cor de um alimento. Estes fatores externos estão relacionados à iluminação, distância da câmera da amostra, local onde a amostra está alocada para avaliação da cor, além da câmera utilizada e suas configurações (VALOUS et al., 2009). Neste caso, a iluminação utilizada e a câmara de colocação da amostra influenciam altamente na cor após a utilização do sistema de visão computacional.

A iluminação corresponde a um fator muito importante na análise de cor, já que dependendo deste pode-se chegar a valores de cor que não são condizentes com a realidade. Durante a análise pelo sistema de visão

computacional, a iluminação pode vir de dois lugares: da luz propriamente dita para realizar a foto e da iluminação externa do ambiente. Em muitos trabalhos (LEÓN et al., 2006; MENDOZA; DEJMEK; AGUILERA, 2006; MERY; PEDRISCHI, 2004; YAM; PAPADAKIS, 2004; URIBE; GIRALDO; TASCÓN, 2008; VALOUS et al., 2009), foi utilizada a iluminação fornecida por uma luz e uma câmara de armazenamento da amostra que impede a chegada da luz externa sobre este, eliminando assim interferências da luminosidade externa.

Assim como acontece no olho humano, a operação de visão computacional também depende da intensidade da iluminação e quanto melhor projetado o sistema iluminante mais precisa será a análise, menor tempo de análise será necessário e menor será a complexidade dos passos subsequentes do processamento de imagens (BROSNAN; SUN, 2004; NOVINI; ENGINEERS, 1995; SLIWINSKA et al., 2014).

As lâmpadas mais utilizadas como fonte de luz são as fluorescentes e incandescentes. Diodos luminescentes elétricos (LED), lâmpadas de quartzo halógenas, lâmpadas de iodetos metálicos (aplicadas em microscopia) também são utilizadas para outras aplicações. Porém as luzes fluorescentes são as mais popularmente utilizadas por proporcionarem uma dispersão de luz mais uniforme e intensa em comprimentos de onda específicos (ABDULLAH, 2008; SLIWINSKA et al., 2014; WU; SUN, 2013b).

2.7.2 Câmera digital

A utilização de fotos para medição de cor é comumente chamada de fotometria, utilizada para avaliação de cor de muitos alimentos, sendo assim um método de avaliação colorimétrica.

Nesse aspecto a câmera fotográfica funciona como o olho humano. Na realidade não se vê os objetos e, sim, a luz refletida destes que chega até nossos

olhos. Dessa maneira, o que passa pela lente da câmera fotográfica é a luz refletida dos objetos. Medir a quantidade exata de luz necessária para formar a imagem no sensor ou filme fotográfico é o que chamamos de fotometria (BATELLO, 1999).

O objetivo de se utilizar uma câmera como parte do sistema de análise de imagem é o de gravar uma fotografia de um determinado objeto. Existem dois tipos de câmeras, ou seja, câmeras analógicas e digitais as quais são equipadas com CCD (charge-coupled device) ou CMOS (complementary metal-oxide-semiconductor) que correspondem a matrizes de sensores, os quais são dois meios diferentes para gerar a imagem digitalmente (WU; SUN, 2013a).

Os sistemas de visão computacional consistem de uma câmera CCD de alta resolução associada a um hardware, para estes tipos de câmaras a área de varredura e modo de digitalização são os mais comuns (ZHANG et al., 2014).

Numa câmera analógica, a imagem gravada é transformada em sinal analógico e depois transferida para um detector de imagens (sob a forma de um cartão), que vai transformar o sinal analógico em um fluxo de dados digital e enviá-lo para a memória do computador. Já nas câmeras digitais, a placa de captura não é necessária porque o sinal analógico é enviado diretamente para o computador por meio de um adaptador USB ou FireWire (BROSNAN; SUN, 2004).

2.7.3 Software processador de imagem

Os espaços de cores RGB e $L^* a^*$ e b^* são comumente aplicados na quantificação da coloração de muitos alimentos. A utilização da câmera digital como parte integrante do sistema de visão computacional proporciona o registro da cor de qualquer pixel da imagem do objeto usando três sensores de cor por

pixel (FORSYTH; PONCE, 2003). Neste modelo de cor cada sensor captura a intensidade de luz no espectro vermelho (R), verde (G) e azul (B).

Segundo León et al. (2006), a tendência atual é analisar os alimentos digitalmente, pois assim pode-se realizar primeiramente uma análise pontual, que abrange um pequeno grupo de pixels com a finalidade de detectar pequenas características do objeto e, em segundo lugar, efetuar uma análise global do objeto em estudo, tais como um histograma de cor, a fim de avaliar a homogeneidade do objeto.

No entanto, os sinais de RGB gerados pelos dispositivos são dependentes destes, ou seja, cada câmara tem a sua característica própria fazendo com que os diferentes sensores dêem diferentes respostas. Ilie e Wech (2005) relatam que a maioria das câmaras, até mesmo aquelas do mesmo tipo, não apresentam respostas consistentes.

O espaço de cor RGB apresenta alguns problemas como o fato deste não ser um espaço uniforme, ou seja, as diferenças de cores (distâncias euclidianas) no espaço RGB não correspondem à diferença de cor na percepção dos humanos (MENDOZA; DEJMEK; AGUILERA, 2006). Um outro problema apresentado pelo RGB é o fato deste ser uma espaço de cor não absoluto, o que faz com que a medição dependa de fatores externos como a sensibilidade dos sensores da câmara, iluminação, etc (LEÓN et al., 2006). Assim, este modelo não deve ser empregado para padronização de equipamentos de processamento de imagens de visão computacional, já que uma mesma cor dependendo das variações utilizadas pelo equipamento pode apresentar diferentes coordenadas.

O modelo de cor CIELab cobre um espaço visível pelo olho humano e representa-o de modo uniforme, o que faz com que este possa ser utilizado para descrever cores visíveis, independente de qualquer tecnologia gráfica, assim ao ser utilizado tem se a garantia que a cor representada será vista do mesmo modo por qualquer equipamento.

Assim, o software processador de imagens entra como uma alternativa para a realização da conversão do modelo de cor proveniente de fotografias (espaço de cor RGB) para $L^* a^* b^*$ espaço de cor amplamente utilizado para alimentos e perceptivelmente uniforme, ou seja, a distância euclidiana entre duas cores diferentes corresponde aproximadamente à cor percebida pelo olho humano. O software faz a conversão do modelo RGB para Lab proporcionando a construção de um colorímetro digital.

A conversão de cor do modelo RGB para $L^* a^* b^*$, que é o modelo mais comumente utilizado para o estudo com alimentos, não pode ser feita diretamente por meio de uma fórmula padrão como acontece na transferência de unidades matemáticas (LEÓN et al., 2006; MENESATTI et al., 2012). Cientes deste problema, vários autores propuseram soluções para esta transformação com base em inteligência computacional (HARDEBERG et al., 1996; MENDOZA; DEJMEK; AGUILERA, 2006; MENESATTI et al., 2012; POUCKE et al., 2010).

Em virtude da grande capacidade de aprendizado a partir do ambiente, a aplicação de redes neurais para o modelo de conversão na análise de coloração de alimentos é atraente. O processamento neural é capaz de extrair relações das variáveis de entrada sobre os espaços que tipicamente as caracterizam, sendo assim uma ferramenta valiosa em problemas complexos de reconhecimento de padrões. Por outro lado, as redes neurais podem trabalhar em conjunto com outras técnicas de processamento permitindo que se utilize o conhecimento acumulado em uma determinada área de aplicação. Assim, os dados podem ser pré-processados, identificando-se a informação relevante à tarefa de processamento de interesse, e a rede neural irá operar sobre esta informação qualificada, em vez de trabalhar com os dados brutos. Desta maneira, evitam-se modelos neurais de alta complexidade, que normalmente são poucos práticos. Redes Neurais Artificiais (RNA) podem ser aplicadas em problemas de

regressão, classificação e compactação de dados, como também em situações onde existem interações não-lineares entre as variáveis dependentes e as independentes (SANTOS et al., 2005).

León et al. (2006) avaliaram cinco modelos de conversão de RGB para L* a* e b*: direto, gama, linear, rede neural e quadrática. Os erros de cada modelo neural foram avaliados por meio do modelo de regressão linear.

Regressão é a tarefa de aprender uma função alvo f que mapeie cada conjunto de atributos x em uma saída de valores contínuos y . O objetivo da regressão é encontrar uma função alvo que possa ajustar os dados de entrada com um erro mínimo (TAN; STEINBACH; KUMAR, 2009). A função erro para uma tarefa de regressão pode ser expressa em termos da soma do erro quadrado:

$$\text{Erro Quadrado} = \sum_i (y_i - f(x_i))^2 \quad (1)$$

A regressão é utilizada como forma de calcular o erro dos valores de conversão de dados de entrada em saída.

No trabalho de León et al. (2006), os menores erros obtidos foram para os modelos de conversão de rede neural e quadrática, próximos de 1% . No entanto, embora a metodologia apresentada possa ser utilizada em qualquer sistema de visão computacional, é preciso entender que os resultados obtidos após a calibração para um sistema (por exemplo, sistema A) não pode ser usado para outro sistema (por exemplo, sistema B). Isso acontece porque a calibração obtida para o sistema de visão computacional A é aplicável apenas para a câmera, iluminação e configurações específicas usadas no sistema A. Já o sistema B necessita de um novo procedimento de calibração que considere as configurações utilizadas para o sistema B.

2.8 Inteligência Computacional

A inteligência computacional agrupa um conjunto de paradigmas baseados principalmente em comportamentos observados na natureza que permitem encontrar soluções de problemas complexos para os quais técnicas matemáticas tradicionais falham, combinando aprendizagem, adaptação e evolução (SUMATHI; PANEERSELVAM, 2010).

A inteligência computacional é um ramo da computação natural e é formada principalmente por redes neurais artificiais, computação evolutiva, lógica nebulosa e inteligência artificial. A figura 4 representa as áreas e subáreas da inteligência computacional.

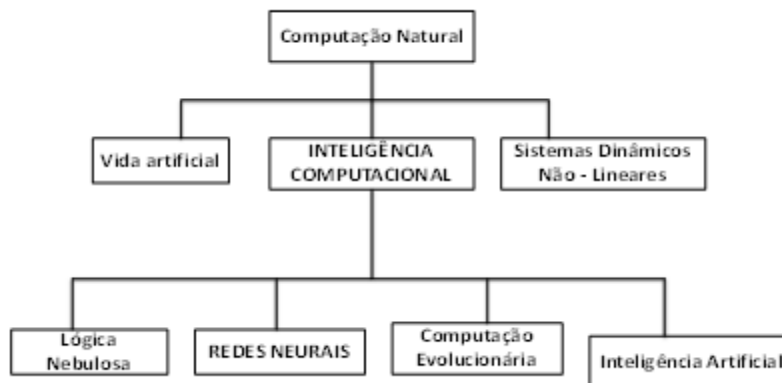


Figura 4 Representação das áreas e subáreas da Inteligência Computacional

Os principais tipos de problemas nos quais se tem a aplicação da Inteligência Computacional são: problemas de otimização, problemas de controle, problemas de classificação e problemas de regressão.

A classificação constitui-se uma tarefa difícil em produtos alimentícios e a grande dificuldade é produzir um modelo computacional que seja capaz de

descrever corretamente e detalhadamente o comportamento do alimento frente a diversas condições.

Um sistema classificador tem a capacidade de gerar respostas melhores e aprender a responder a situações pouco familiares ao tratar suas regras como uma população a ser evoluída (COPPIN, 2012).

A utilização de sistemas classificadores acaba gerando alguns desafios relacionados ao desenvolvimento de métodos de classificação que fazem com que se ampliem os estudos nestes casos.

2.8.1 Reconhecimento de padrões

As propriedades que determinam o agrupamento de objetos semelhantes dentro de uma classe ou categoria correspondem ao padrão, mediante a interpretação de dados de entrada, que permitam a extração das características relevantes desses objetos (TOU; GONZÁLES, 1981). Assim uma classe de um padrão é o conjunto de atributos comuns ao objeto de estudo.

O reconhecimento de padrões é um procedimento que busca a identificação de certas estruturas nos dados de entrada em comparação a estruturas conhecidas e sua posterior classificação dentro de categorias, de modo que o grau de associação seja maior entre estruturas de mesma categoria e menor entre as categorias de estruturas diferentes (THEODORIDIS; KOUTROUMBAS, 2009).

Com a ampliação dos recursos computacionais e dos estudos, a aplicação de técnicas de reconhecimento de padrões vem sendo utilizada em diversas áreas além de principalmente a utilização para análises de cor de imagens (LEÓN et al., 2006), destacando-se os diagnósticos médicos (SILVA, 2014), reconhecimento de voz, investigação da qualidade do papel industrial,

análise de eletrocardiogramas, sinais de radar, reconhecimento de faces, dentre outras.

2.8.2 Redes Neurais

Warren McCulloch e Walter Pitts, em 1943, após 20 anos de pesquisas, na tentativa de simular o sistema nervoso, publicaram em seu celebre artigo a introdução das “redes neurais artificiais (RNA)”. Assim, Rosenblatt, em 1978, introduziu um novo modelo denominado *perceptron* e mais tardiamente Hebb inicializou estudos com treinamento de redes. Widrow, neste mesmo espaço de tempo, também, desenvolveu o modelo neural linear ADALINE (Adaptive Linear Element) (BRAGA; CARVALHO; LUDERMIR, 2014).

Na década de 70, houve certa estagnação com relação aos estudos o que mostrava um pouco das limitações quanto às teorias desenvolvidas. E, somente em 1982, John Hopfield publicou um novo artigo impulsionando novamente as pesquisas em redes neurais. O desenvolvimento das memórias associativas marca esta nova fase, o que corresponde à capacidade de uma rede neural de associar modelos apresentados a ela a modelos presentes em uma memória prévia (COPPIN, 2012).

Posteriormente, outros estudos foram realizados com desenvolvimento de algoritmos como a “retropropagação do erro” (error backpropagation) e com o avanço da tecnologia houve a criação de computadores mais rápidos e baratos possibilitando assim a expansão de suas aplicações.

As RNAs possuem estrutura semelhante a um neurônio biológico, porém neste caso o neurônio constitui a unidade computacional básica da rede em questão. A arquitetura de uma RNA constitui a estrutura topológica de como os neurônios são conectados, e a aprendizagem é o processo que adapta a rede de

modo a computar uma função desejada ou realizar uma tarefa (FERNANDES, 2005).

Uma RNA é composta por uma combinação de neurônios em uma ou mais camadas, que podem conter um ou mais neurônios interligados por meio de sinapses (LUDWING JUNIOR; MONTGOMERY, 2007). As camadas da RNA são classificadas em três grupos:

- a) **Camada de entrada:** onde os padrões são apresentados à rede e a única função desta camada é representar a distribuição dos dados de entrada para cada neurônio da camada seguinte;
- b) **Camadas intermediárias ou escondidas:** onde é realizada a maior parte do processamento, por meio das conexões ponderadas, sendo consideradas extratoras de características (FERNANDES, 2005);
- c) **Camada de saída:** onde os resultados finais serão apresentados.

A figura abaixo demonstra como é estruturada uma rede neural:

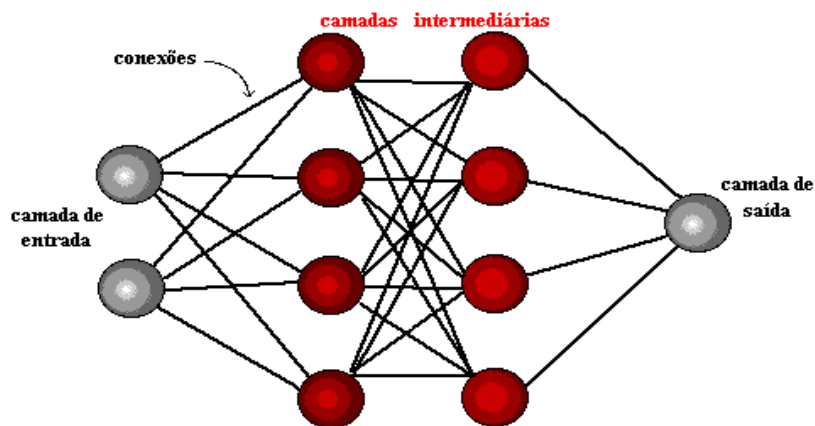


Figura 5 Representação da estrutura de uma rede neural (REDES..., 2015)

O modo com que uma RNA fica estruturada é importante para prever seu comportamento. As redes possuem diversos modos de classificação quanto à arquitetura (BRAGA; CARVALHO; LUDERMIR, 2014; HAYKIN, 2009). Uma das principais classificações corresponde ao tipo de conexão, a rede pode ser considerada *feedforward* ou acíclica quando a saída de um neurônio na i -ésima camada da rede não pode ser usada como entrada de nodos em camadas de índice menor ou igual a i , já a rede *feedback* ou cíclica determina que a saída de algum neurônio na i -ésima camada da rede seja usada como entrada de nodos em camadas de índice menor ou igual a i (BRAGA; CARVALHO; LUDERMIR, 2014).

Segundo Anderson (1972), os neurônios são ligados por conexões, cada um com um peso (w) associado, que corresponde à influência do neurônio no processamento do sinal de saída. Pesos positivos correspondem a fatores de reforço do sinal de entrada, e pesos negativos correspondem a fatores de inibição. Portanto, cada neurônio é capaz de processar um sinal de entrada e transformá-lo em um sinal de saída.

O neurônio pode ser definido sistematicamente conforme mostra a figura 6.

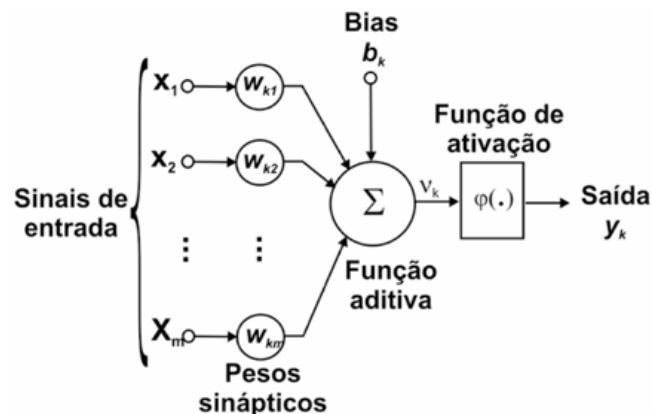


Figura 6 Funcionamento de um neurônio artificial

Fonte: O NEURÔNIO... (2014).

Pela figura 6 é possível entender o funcionamento do neurônio computacional com base nos dados acima:

- a) X_1, X_2, \dots, X_n correspondem aos sinais de entrada, cada sinal de entrada possui um peso sináptico representado pela letra w . Os pesos sinápticos têm a função de multiplicar o sinal em cada sinapse. Por exemplo, na sinapse n será multiplicada a entrada X_n pelo seu peso sináptico w_{kn} .
- b) O somatório (Σ) corresponde à soma ponderada de cada entrada multiplicada pelo peso correspondente, assim, a função aditiva corresponde a:

$$V_k = \sum_{n=1}^n W_{kn} X_n \quad (2)$$

- c) O bias b_x também conhecido como limiar (threshold) tem a função de controlar a intensidade da função de ativação $\varphi(\cdot)$, assim esta vai evitar o acréscimo progressivo dos valores de saída ao longo das camadas da rede, visto que tais funções possuem valores máximos e mínimos contidos em intervalos determinados.

Assim a saída da função de ativação é dada por:

$$y_k = \varphi(V_k + b_k) \quad (3)$$

Onde: V_k é a saída do combinador linear de entrada, b_k é o bias, $\varphi(\cdot)$ é a função de ativação e y_k é a saída do neurônio.

Uma das principais propriedades que as RNAs possuem é a capacidade de aprender por exemplos e fazer interpolações e extrapolações do que aprenderam. Quando se utiliza uma RNA na solução de um problema passa-se primeiramente por uma fase de aprendizagem, na qual a rede vai extrair informações importantes de padrões de informações a ela apresentados, criando deste modo uma representação própria para o problema. Esta etapa é altamente relevante, pois, consiste em um processo iterativo de ajuste de parâmetros da rede e os pesos das conexões entre as unidades de processamento, que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando (HAYKIN, 2009). O processo de aprendizado de uma rede neural pode - se dar de duas formas: o aprendizado supervisionado (com professor) e o aprendizado não- supervisionado (apenas pela experiência). No aprendizado supervisionado é fornecido um conjunto de entradas e saídas desejado por meio de um supervisor (professor) externo.

Segundo Braga, Carvalho e Ludermir (2014), o objetivo deste aprendizado é ajustar os parâmetros da rede, de forma a encontrar uma ligação entre os pares de entrada e saída fornecidos. A rede tem sua saída corrente (calculada) comparada com a saída desejada, recebendo informações do supervisor sobre o erro da resposta atual. A cada padrão de entrada a rede compara a saída calculada com a saída desejada e, assim, ajustam-se os pesos para minimização do erro, de tal forma que estes caminhem para uma solução possível.

O aprendizado não – supervisionado, como o próprio nome já diz, não tem o acompanhamento de um supervisor, nele então são somente fornecidas as entradas, não recebendo, portanto informações sobre as saídas desejadas. A rede é treinada apenas com os valores de entrada e organiza sua estrutura de modo a fazer a classificação destes valores em grupos. De acordo com Ludwing Junior e Montgomery (2007), este tipo de rede tem por finalidade a classificação de

dados pelo reconhecimento de padrões, ou seja, detecção de características em comum entre conjuntos de dados. Este tipo de organização ocorre por meio de processos de competição e cooperação entre os neurônios.

2.8.3 Projeto de uma rede neural

Durante a construção de um modelo neural, cinco fases devem ser seguidas para garantir uma boa funcionalidade e aplicabilidade da rede (LUDWING JUNIOR; MONTGOMERY, 2007). As etapas correspondem a:

- a) ***Coleta e seleção de dados*** - nesta etapa os dados são coletados e separados em duas categorias (dados de treinamento e validação). Os dados de treinamento correspondem aos dados que serão utilizados para treinamento da rede, já os dados de validação serão utilizados para verificar o desempenho da rede.
- b) ***Configuração da rede*** - a primeira escolha a se realizar nesta etapa corresponde à seleção do paradigma neural apropriado à aplicação, ou seja, qual a configuração neural que deverá ser utilizada (perceptron simples, perceptron de múltiplas camadas, etc). Após esta escolha pode-se determinar a topologia da rede, isto é, o número de camadas e o número de neurônios em cada camada. Nesta fase também deve-se escolher o algoritmo de treinamento a ser utilizado, taxa de aprendizado e outros parâmetros de treinamento. Assim determina-se a função de transferência que melhor se enquadra.
- c) ***Treinamento*** - nesta etapa serão ajustados os pesos das conexões, assim o projetista da rede poderá definir os valores iniciais dos pesos sinápticos (inicialização da rede), o algoritmo de aprendizagem e também o tempo de treinamento para o aprendizado da rede.

- d) **Teste** - esta etapa corresponde à utilização do conjunto de dados de validação para determinar o desempenho da rede com dados ainda não apresentados a ela.
- e) **Integração** - corresponde a etapa final onde a rede neural será aplicada segundo o objetivo desejado. Após treinamento e validação da rede é possível a integração desta a um sistema. O sistema deverá conter facilidades de utilização, de aquisição de dados por meio de planilhas eletrônicas e interfaces com unidades de processamento de sinais ou arquivos padronizados.

2.8.4 Redes Perceptron

O perceptron constitui a arquitetura mais simples da rede neural, apresentando apenas um conjunto de neurônios de entrada e um conjunto de neurônios de saída, sem haver nenhuma camada intermediária. Nesta rede os elementos da camada de entrada fazem a distribuição de cada sinal de entrada para todos os neurônios da camada de saída, que é formada por um número de neurônios igual ao número de sinais de saída. Nesse caso, a codificação proveniente do mundo exterior deve ser suficiente para implementar esse mapeamento (FAUSETT, 1994).

Segundo Haykin (2009), a rede perceptron quando apresenta resultados padrões de entrada com estruturas similares, fornecidos do mundo externo, que levam a saídas diferentes, estes não são possíveis de ser mapeados por redes sem representações internas, isto é camadas intermediárias. Assim este tipo de rede neural, embora simples, apresenta problemas específicos não podendo ser utilizada em aplicações mais avançadas, não sendo assim capazes de solucionar problemas que não fossem linearmente separáveis.

Em virtude da necessidade da resolução de problemas, processos de aprendizagem e aplicação de uma nova estratégia, houve a introdução de camadas intermediárias entre as entradas e as saídas da rede neural, o que eliminou tais problemas anteriormente encontrados no perceptron. Esta inovação levou a um avanço e retomada dos estudos com inteligência artificial, esta arquitetura com camadas de neurônios internas recebeu o nome de *Multilayer Perceptron*. conhecida como MLP (LUDWING JUNIOR; MONTGOMERY, 2007).

De acordo com Fernandes (2005), no perceptron multicamadas (MLP) cada camada tem uma função específica. A camada de saída recebe os estímulos da camada intermediária e constrói o padrão que será a resposta. As camadas intermediárias funcionam como extratoras de características, seus pesos são uma codificação de características apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação, mais rica e complexa, do problema.

A rede MLP opera durante o treinamento com o algoritmo backpropagation, nele a rede apresenta uma sequência de dois passos.

No primeiro passo, um padrão é apresentado à entrada da rede. A atividade resultante flui por meio da rede, camada por camada, até que a resposta seja produzida pela camada de saída. No segundo passo, a saída obtida é comparada à saída desejada para esse padrão particular. Se esta não estiver correta o erro é calculado. Assim o erro é propagado com base na camada de saída até a camada de entrada, e os pesos das conexões das unidades das camadas internas vão sendo modificados conforme o erro é retropropagado (FERNANDES, 2005; RUSSEL; RUSSEL, 2004).

Vários autores descrevem a utilização da rede neural para aplicação do sistema de visão computacional em alimentos dentre estes têm-se: salmão (YAGIZ et al., 2009), suco de laranja (FERNANDEZ-VAZQUEZ et al., 2011), bebidas alcoólicas como vinho (MARTIN et al., 2007) e cerveja (SUN et al.,

2004), batata chips (PEDRESCHI et al., 2006), sementes (ZAPOTOCZNY; MAJEWSKA, 2010) e em frutos do cafeeiro (LILIANA et al., 2007; URIBE; GIRALDO; TASCÓN, 2008).

A figura 5, a seguir, representa uma rede multilayer do tipo feedforward para entendimento de como ocorrem suas conexões e como esta fica estruturada.




Figura 7 Rede multilayer feedforward

Fonte: (BARBOSA; FREITAS; NEVES, 2005).

2.8.5 Classificador Bayesiano

Os classificadores Bayesianos são classificadores estatísticos que classificam um objeto numa determinada classe com base na probabilidade deste objeto pertencer a esta classe. Estes classificadores produzem resultados rápidos e podem ser aplicados a um grande volume de dados, os resultados apresentados

por eles podem ser comparados aos resultados produzidos por árvores de decisão e redes neurais (HECKERMAN, 1996).

Os classificadores Bayesianos simples supõem como hipótese de trabalho que o efeito do valor de um atributo não pertencente à classe é independente dos valores dos outros atributos, ou seja, o valor de um atributo não influencia o outro.

O teorema de Bayes pode ser usado para calcular a probabilidade de que um evento venha a ocorrer ou que uma proposição seja verdadeira, dado que já se conhece um fragmento relacionado de informação. O teorema é declarado do seguinte modo:

$$P(B/A) = \frac{P(A/B).P(B)}{P(A)} \quad (4)$$

$P(B)$ é chamada de probabilidade a priori de B. $P(B/A)$ além de ser chamada de probabilidade condicionada, também chamada de probabilidade a posteriori de B.

Supondo que A denote o conjunto de atributos e B denote a variável da classe. Se esta apresentar um relacionamento não determinístico com os atributos, então pode-se tratar A e B como variáveis aleatórias e capturar este relacionamento usando a probabilidade $P(B/A)$. Esta probabilidade condicional também é conhecida como probabilidade posterior de B, em oposição à probabilidade anterior, $P(B)$ (TAN; STEINBACH; KUMAR, 2009).

Durante a fase de treinamento, é necessário descobrir as probabilidades posteriores $P(B/A)$ para cada combinação de A e B baseada em informações coletadas a partir dos dados de treinamento. Conhecendo estas probabilidades, um registro teste A'' pode ser classificado encontrando-se a classe B'' que maximize a probabilidade posterior, $P(B''/A'')$ (COPPIN, 2012).

Um exemplo de aplicação de classificação do Bayesiano está demonstrado na tabela 1, no caso tem-se um conjunto de treinamento com os seguintes atributos: idade, profissão e renda. Supondo que se deseje a solicitação de empréstimos, os solicitantes que ficam inadimplentes são classificados como SIM, enquanto que aqueles que pagaram o empréstimo são classificados como NÃO.

Tabela 1 Conjunto de treinamento para prever o problema de inadimplência

Cientes	Idade	Profissão	Renda- Salário mínimo (SM)
1	26	Professor	3 SM
2	49	Engenheiro	6 SM
3	38	Jornalista	2 SM
4	58	Porteiro	1 SM
5	31	Motoboy	2 SM

Considerando-se um registro de teste para o seguinte conjunto de atributos: A= (Idade= 46, Profissão= jornalista, Renda= 3 SM). Para classificar este registro é necessário calcular as probabilidades posteriores $P(\text{SIM} / A)$ e $P(\text{NÃO} / A)$ baseadas nas informações disponíveis nos dados de treinamento. Se $P(\text{SIM} / A) > P(\text{NÃO} / A)$, então o registro é classificado como SIM, caso contrário é classificado como NÃO.

Barbosa e Ferreira (2013) estudaram os distúrbios na energia elétrica classificando em simples e múltiplos, para isso foi construída uma árvore de decisão, vista no item a seguir, por meio de dois classificadores simples: o perceptron e o classificador bayesiano. Os resultados mostraram que o sistema construído foi eficaz e com boa precisão para ser usado na identificação dos distúrbios reais encontrados na energia elétrica.

REFERÊNCIAS

ABDULLAH, M. Z. Image acquisition systems. In: SUN, D. W. (Ed.). **Computer vision technology for food quality evaluation**. San Diego: Elsevier, 2008. p. 7-23.

AFONSO JÚNIOR, P. C.; CORRÊA, P. C. Influência do tempo de armazenagem na cor dos grãos de café pré- processados por “via seca” e “via úmida”. **Ciência e Agrotecnologia**, Lavras, v. 27, n. 6, p. 1268-1276, nov./dez. 2003.

AMODIO, M. L. et al. Post-cutting quality changes of fresh-cut artichokes treated with different anti-browning agents as evaluated by image analysis. **Postharvest Biology and Technology**, Amsterdam, v. 62, n. 2, p. 213-220, Nov. 2011.

AMORIM, H. V. **Aspectos bioquímicos e histoquímicos do grão de café verde relacionados com a deterioração de qualidade**. 1978. 85 f. Tese (Livre-Docência em Bioquímica) - Escola Superior de Agricultura “Luiz de Queiroz”, Piracicaba, 1978.

AMORIM, H. V.; TEIXEIRA, A. A. Transformações bioquímicas, químicas e físicas do grão de café verde e qualidade da bebida. In: CONGRESSO BRASILEIRO DE PESQUISA CAFEEIRAS, 3., 1975, Curitiba. **Resumos...** Rio de Janeiro: MIC/TBC, 1975. p. 21.

ANDERSON, J. A. A simple neural network generating an interactive memory. **Mathematical Biosciences**, New York, v. 14, p. 197-220, 1972.

APACHE TECHNOLOGIES. **CIE Lab color space**. Disponível em: <<http://apachetechnology.in/KC/Multimedia/DIP/Segmentation/kMeans.aspx>>. Acesso em: 10 nov. 2014.

BALABAN, M. O.; ODABASI, A. Z. Measuring color with machine vision. **Food Technology**, Oxford, v. 60, p. 32-36, 2006.

BARBOSA, A. H.; FREITAS, M. S. R.; NEVES, F. A. Confiabilidade estrutural utilizando o método de Monte Carlo e redes neurais. **REM: Revista Escola de Minas**, Ouro Preto, v. 58, n. 3, p. 247-255, jul./set. 2005.

BARBOSA, B. H. G.; FERREIRA, D. D. Classification of multiple and single power quality disturbances using a decision tree-based approach. **Journal of Control, Automation and Electrical Systems**, New York, v. 24, n. 5, p. 638-648, Oct. 2013.

BATELLO, C. **Iridologia e irisdiagnose**: o que os olhos podem revelar. São Paulo: Ground, 1999. 267 p.

BORÉM, F. M. et al. Evaluation of the sensory and color quality of coffee beans stored in hermetic packaging. **Journal of Stored Products Research**, Sapele, v. 52, p. 1-6, Jan. 2013.

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais**: teoria e aplicações. 2. ed. Rio de Janeiro: LTC, 2014. 248 p.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Instrução normativa nº 8**, de junho de 2003. Aprova o regulamento técnico da identidade e de qualidade para a classificação do café beneficiado grão cru. Brasília, 2003. Disponível em: <<http://www.ministerio.gov.br>>. Acesso em: 25 set. 2014.

BROSNAN, T.; SUN, D. W. Improving quality inspection of food products by computer vision: a review. **Journal of Food Engineering**, Essex, v. 61, n. 1, p. 3-16, Jan. 2004.

COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento da safra brasileira de café, safra 2015, primeiro levantamento, janeiro/2015**. Disponível em: <<http://www.conab.gov.br>>. Acesso em: 4 jan. 2015.

COPPIN, B. **Inteligência artificial**. Rio de Janeiro: LTC, 2012. 636 p.

CORADI, P. C.; BORÉM, F. M.; OLIVEIRA, J. A. Qualidade do café natural e despolpado após diferentes tipos de secagem e armazenamento. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 12, n. 2, p. 181-188, 2008.

CORRÊA, P. C.; AFONSO JUNIOR, P. C.; PINTO, F. A. C. Efeito da temperatura de secagem na cor dos grãos de café pré- processado por “via seca” e “via úmida”. **Revista Brasileira de Armazenamento**, Viçosa, MG, n. 5, p. 22-27, 2002. Edição especial café.

CORRÊA, P. C. et al. Qualidade dos grãos de café (*Coffea arábica* L.) durante o armazenamento em condições diversas. **Revista Brasileira de Armazenamento**, Viçosa, MG, n. 7, p. 137-147, 2003. Especial café.

COSTA, C. et al. Shape analysis of agricultural products: a review of recent research advances and potential application to computer vision. **Food and Bioprocess Technology**, Chicago, v. 4, p. 673-692, 2011.

DU, C. J.; SUN, D. W. Comparison of three methods for classification of pizza topping using different colour space transformations. **Journal of Food Engineering**, Essex, v. 68, n. 5, p. 277-287, July 2005.

DU, C. J.; SUN, D. W. Learning techniques used in computer vision for food quality evaluation: a review. **Journal of Food Engineering**, Essex, v. 72, n. 1, p. 39-55, Jan. 2006.

FAIRCHILD, M. D. **Color appearance models**. 2nd ed. London: J. Wiley, 2005. 417 p.

FAUSETT, L. **Fundamentals of neural networks: architectures, algorithms and applications**. New Jersey: Prentice-Hall International, 1994. 461 p.

FERNANDES, A. M. R. **Inteligência artificial: noções gerais**. 3. ed. Florianópolis: VisualBooks, 2005. 160 p.

FERNANDEZ-VAZQUEZ, R. et al. Visual and instrumental evaluation of orange juice color: a consumers' preference study. **Journal of Sensory Studies**, Westport, v. 26, n. 6, p. 436-444, Dec. 2011.

FERREIRA, V. L. P. **Princípios e aplicações da colorimetria em alimentos**. Campinas: Instituto de Tecnologia de Alimentos, 1981. 86 p. (Instruções Técnicas, 19).

FIGUEIREDO, L. P. et al. Avaliação das características físicas dos grãos de café (*Coffea arabica* L.) submetidos a diferentes tempos de fermentação natural. In: SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL, 6., 2009, Vitória. **Anais...** Brasília: EMBRAPA Café, 2009. 1 CD-ROM.

FORSYTH, D.; PONCE, J. **Computer vision: a modern approach**. New Jersey: Prentice Hall, 2003. 792 p.

GARRUTI, R. S.; GOMES, A. G. Influência do estado de maturação sobre a qualidade da bebida do café na região do Vale do Paraíba. **Bragantia**, Campinas, v. 20, p. 989-995, 1961.

GOMES, J.; VELHO, L. **Computação gráfica: imagem**. Rio de Janeiro: Instituto de Matemática Pura e Aplicada, 1994. 421 p.

GOMES, J. F. S.; LETA, F. R. Applications of computer vision techniques in the agriculture and food industry: a review. **European Food Research and Technology**, Berlin, v. 235, n. 6, p. 989-1000, 2012.

HARDEBERG, J. Y. et al. Color science, systems and applications. In: COLOR IMAGING CONFERENCE, 4., 1996, Scottsdale. **Proceedings...** Scottsdale: DBLP, 1996. p. 108-113.

HAYKIN, S. S. **Neural networks and learning machines**. 3rd ed. Rio de Janeiro: Prentice Hall, 2009. 936 p.

HECKERMAN, D. **Bayesian networks for knowledge discovery**. Cambridge: MIT, 1996. 305 p.

HUNT, R. W. G. **Measuring colour**. London: Fountain, 1998. 492 p.

HUNT, R. W. G. **The reproduction of colour**. 5th ed. London: Fountain, 1995. 724 p.

ILIE, A.; WELCH, G. Ensuring color consistency across multiple câmeras. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION, 20., 2005, Beijing. **Proceedings...** Beijing: IEEE, 2005. v. 2, p. 17-20.

KAYS, S. J. Preharvest factors affecting appearance. **Postharvest Biology and Technology**, Amsterdam, v. 15, n. 3, p. 233-247, Mar. 1999.

LARRAIN, R. E.; SCHAEFER, D. M.; REED, J. D. Use of digital images to estimate CIE color coordinates of beef. **Food Research International**, Barking, v. 41, n. 4, p. 380-385, 2008.

LEÓN, K. et al. Color measurement in L*a*b* units from RGB digital images. **Food Research International**, Barking, v. 39, n. 10, p. 1084-1091, Dec. 2006.

LILIANA, Z. et al. Caracterización de café cereza empleando técnicas técnicas de visión artificial. **Revista Facultad Nacional de Agronomía Medellín**, Medellín, v. 60, n. 64, p. 4105-4127, 2007.

LOPES, M. V. Avaliação da qualidade de grãos de diferentes cultivares de cafeeiro (*Coffea arabica* L.). **Revista Brasileira de Armazenamento**, Viçosa, MG, v. 25, p. 3-8, 2000. Número especial.

LOPES, R. P.; HARA, T.; SILVA, J. S. Avaliação da qualidade de grãos de café pela colorimetria. **Engenharia na Agricultura**, Viçosa, MG, v. 6, n. 3, p. 160-169, 1998.

LUDWING JUNIOR, O.; MONTGOMERY, C. E. **Redes neurais: fundamentos e aplicações com programas em C**. Rio de Janeiro: Ciência Moderna, 2007. 136 p.

MALTA, M. R. Critérios utilizados na avaliação da qualidade do café. **Informe Agropecuário**, Belo Horizonte, v. 32, n. 261, p. 114-126, 2011.

MALTA, M. R.; CHAGAS, S. J. de R.; CHALFOUN, S. M. Colheita e pós-colheita do café: recomendações e coeficientes técnicos. **Informe Agropecuário**, Belo Horizonte, v. 29, n. 247, p. 83-94, 2008.

MARTIN, M. L. G. M. et al. Measuring colour appearance of redwines. **Food Quality and Preference**, Barking, v. 18, n. 6, p. 862-871, Sept. 2007.

MAZZAFERA, P.; GUERREIRO, F. O.; CARVALHO, A. Estudo de coloração verde do grão de café: determinação de flavonóides e clorofilas. In: CONGRESSO BRASILEIRO DE PESQUISAS CAFEEIRAS, 11., 1984, Londrina. **Resumos...** Rio de Janeiro: MIC/IBC, 1984. p. 178-181.

MCCAIG, T. N. Extending the use of visible/near-infrared reflectance spectrophotometers to measure colour of food and agricultural products. **Food Research International**, Barking, v. 35, p. 731-736, 2002.

MELLENDEZ-MARTINEZ, A. J.; VICARIO, I. M.; HEREDIA, F. J. Instrumental measurement of orange juice colour: a review. **Journal of the Science of Food and Agriculture**, London, v. 85, n. 8, p. 894-901, 2005.

MENDOZA, F.; AGUILERA, J. M. Application of image analysis for classification of ripening bananas. **Food Engineering and Physical Properties**, Philadelphia, v. 69, n. 9, p. 471-477, 2004.

MENDOZA, F.; DEJMEK, P.; AGUILERA, J. M. Calibrated color measurements of agricultural foods using image analysis. **Postharvest Biology and Technology**, Amsterdam, v. 41, n. 3, p. 285-295, 2006.

MENESATTI, P. et al. RGB color calibration for quantitative image analysis: the “3D thin-plate spline” warping approach. **Sensors**, New York, v. 12, n. 6, p. 7063-7079, 2012.

MERY, D.; PEDRESCHI, F. Segmentation of colour food images using a robust algorithm. **Journal of Food Engineering**, Essex, v. 66, n. 3, p. 353-360, 2004.

MONTEIRO, M. A. M. **Caracterização da bebida de café (*Coffea arábica* L.): análise descritiva quantitativa, análise tempo-intensidade e testes afetivos**. 2002. 158 p. Tese (Doutorado em Ciência e Tecnologia de Alimentos) - Universidade Federal de Viçosa, Viçosa, MG, 2002.

NOVINI, A. R.; ENGINEERS, S. O. M. **The latest in vision technology in today's food and beverage container manufacturing industry**. Minneapolis: Society of Manufacturing Engineers, 1995. 219 p.

O NEURÔNIO artificial. Disponível em:
<http://www.grigma.ufsc.br/~popov/aulas/rna/neuronio_artificial/index.html>.
Acesso em: 13 nov. 2014.

OLIVEIRA, P. D. et al. Aspectos fisiológicos de grãos de café, processados e secados de diferentes métodos, associados à qualidade sensorial. **Coffee Science**, Lavras, v. 8, n. 2, p. 211-220, abr./jun. 2013.

PACE, B. et al. Non-destructive evaluation of quality and ammonia content in whole and fresh-cut lettuce by computer vision system. **Food Research International**, Barking, v. 64, p. 647-655, Oct. 2014.

PACE, B. et al. Relationship between visual appearance and browning as evaluated by image analysis and chemical traits in fresh-cut nectarines. **Postharvest Biology and Technology**, Amsterdam, v. 61, n. 2/3, p. 178-183, Aug. 2011.

PASCALE, D. **A review of RGB color spaces**. Montreal: The Babel Color, 2003. 35 p.

PATEL, K. K. et al. Machine vision system: a tool for quality inspection of food and agricultural products. **Journal of Food Science and Technology**, Trivandrum, v. 49, n. 2, p. 123-141, Apr. 2012.

PEDRESCHI, F. et al. Development of a computer vision system to measure the color of potato chips. **Food Research International**, Barking, v. 39, n. 10, p. 1092-1098, Dec. 2006.

POUCKE, S. van et al. Automatic colorimetric calibration of human wounds. **BMC Medical Imaging**, London, v. 10, n. 7, p. 1-11, Mar. 2010.

REDES neurais. Disponível em: <<http://www.din.uem.br/ia/neurais/>>. Acesso em: 20 jan. 2015.

RIBEIRO, F. C. **Métodos alternativos para armazenamento de café especiais**. 2013. 110 p. Tese (Doutorado em Engenharia Agrícola) - Universidade Federal de Lavras, Lavras, 2013.

RIBEIRO, F. C. et al. Storage of green coffee in hermetic packaging injected with CO₂. **Journal of Stored Products Research**, Sapele, v. 47, n. 4, p. 341-348, Oct. 2011.

RIGUEIRA, R. J. de A. et al. Armazenamento de grãos de café cereja descascado em ambiente refrigerado. **Engenharia na Agricultura**, Jaboticabal, v. 17, n. 4, p. 323-333, 2009.

RGBCUBE. **Couleur.Org**. Disponível em: <<http://www.couleur.org/index.php?page=rgbcube>>. Acesso em: 7 out. 2014.

RUSSEL, S. J.; RUSSEL, P. N. **Inteligência artificial**. Rio de Janeiro: Elsevier, 2004. 420 p.

SAMPAIO, J. B. R.; AZEVEDO, I. A. Influência de grãos de café secos no pé em mistura com grãos maduros (cereja) sobre a qualidade do café. In:

CONGRESSO DE PESQUISAS CAFEEIRAS, 15., 1989, Maringá. **Resumos...**
Rio de Janeiro: MIC/IBC, 1989. p. 1-3.

SANTANA, C. F. et al. Espaço de cores. **Psicologia USP**, São Paulo, v. 17, n. 4,
p. 35-62, 2006.

SANTOS, A. M. et al. Usando redes neurais artificiais e regressão logística na
predição da hepatite A. **Revista Brasileira de Epidemiologia**, São Paulo, v. 8,
n. 2, p. 117-126, 2005.

SILVA, R. N. **Identificação de pacientes com potencial para desenvolver o
pé diabético baseada em técnicas de reconhecimento de padrões e ações de
autocuidado**. 2014. 84 f. Dissertação (Mestrado em Engenharia de Sistemas e
Automação) - Universidade Federal de Lavras, Lavras, 2014.

SIMÕES, A. S. **Segmentação de imagens por classificação de cores: uma
abordagem neural**. 2000. 132 p. Dissertação (Mestrado em Engenharia) - Escola
Politécnica da Universidade de São Paulo, São Paulo, 2000.

SLIWINSKA, M. et al. Food analysis using artificial senses. **Journal of
Agricultural and Food Chemistry**, Easton, v. 62, n. 7, p. 1423-1448, Feb.
2014.

SPECIALTY COFFEE ASSOCIATION OF AMERICA. **Specialty coffee facts
& figures**. Disponível em: <<http://www.scaa.org/PDF/resources/fcts-and-figures.pdf>>. Acesso em: 25 set. 2014.

SUMATHI, S.; PANEERSELVAM, S. **Computational intelligence
paradigmas: theory and applications using MATLAB**. Boca Raton: CRC, 2010.
851 p.

SUN, F. X. et al. Determination of beer color using image analysis. **Journal of
the American Society of Brewing Chemists**, Saint Paul, v. 62, n. 4, p. 163-167,
2004.

TAN, P. N.; STEINBACH, M.; KUMAR, V. **Introdução ao DATAMINING mineração de dados**. Rio de Janeiro: Ciência Moderna, 2009. 900 p.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern recognition**. 3rd ed. London: Academic, 2009. 984 p.

TOU, J. T.; GONZÁLEZ, R. C. **Pattern recognition principles**. London: Addison-Wesley, 1981. 377 p.

URIBE, J. R. S.; GIRALDO, P. J. R.; TASCÓN, C. E. O. Algorithm to identify maturation stages of coffee fruits. In: ADVANCES IN ELECTRICAL AND ELECTRONICS ENGINEERING - IAENG SPECIAL EDITION OF THE WORLD CONGRESS ON ENGINEERING AND COMPUTER SCIENCE, 8., 2008, San Francisco. **Proceedings...** San Francisco: IEEE, 2008. p. 167-174.

VALOUS, N. A. et al. Colour calibration of a laboratory computer vision system for quality evaluation of pre-sliced hams. **Meat Science**, Barking, v. 81, n. 1, p. 132-141, Jan. 2009.

VILELA, E. R.; CHANDRA, P. K.; OLIVEIRA, G. A. Efeito da temperatura e umidade relativa no branqueamento de grãos de café. **Revista Brasileira de Armazenamento**, Viçosa, MG, v. 1, p. 31-37, 2000. Número especial.

WU, D.; SUN, D. W. Advanced applications of hyperspectral imaging technology for food quality and safety analysis and assessment: a review, part I, fundamentals. **Innovative Food Science and Emerging Technologies**, London, v. 19, p. 1-14, July 2013a.

WU, D.; SUN, D. W. Colour measurements by computer vision for food quality control: a review. **Food Science & Technology**, Trivandrum, v. 29, n. 1, p. 5-20, Jan. 2013b.

YAGIZ, Y. et al. Comparison of Minolta colorimeter and machine vision system in measuring colour of irradiated Atlantic salmon. **Journal of the Science of Food and Agriculture**, London, v. 89, n. 4, p. 728-730, Mar. 2009.

YAM, K. L.; PAPADAKIS, S. E. A simple digital imaging method for measuring and analyzing color of food surfaces. **Journal of Food Engineering**, Essex, v. 61, n. 1, p. 137-142, 2004.

ZAPOTOCZNY, P.; MAJEWSKA, K. A comparative analysis of colour measurements of the seed coat and endosperm of wheat kernels performed by various techniques. **International Journal of Food Properties**, Philadelphia, v. 13, n. 1, p. 75-89, June 2010.

ZHANG, B. et al. Principles, developments and applications of computer vision for external quality inspection of fruits and vegetables: a review. **Food Research International**, Barking, v. 62, p. 326-343, Aug. 2014.

SEGUNDA PARTE – ARTIGO**ARTIGO 1 A classification system for coffee grades based on computational intelligence techniques**

Emanuelle Morais de Oliveira^a, Dimas Samid Leme^b, Bruno Henrique Groenner Barbosa^c, Mirian Pereira Rodarte^d, Rosemary Gualberto Fonseca Alvarenga Pereira^e.

a Department of Food Science, Federal University of Lavras.

b Engineering Department, Federal University of Lavras.

c Engineering Department, Federal University of Lavras.

d Department of Pharmaceutical Sciences, Federal University of Juiz de Fora.

e Department of Food Science, Federal University of Lavras.

Artigo a ser submetido na revista Food Research International.

Abstract

The color evaluation of dried coffee beans is a very important process to define their quality. This evaluation is normally carried out by visual inspection or by traditional instruments like colorimeters and spectrophotometers. However, the visual inspection is subjective and the traditional instruments can only measure the surface of sample that is uniform and rather small. Hence, computer vision systems come out as reliable methods to evaluate the color of coffee beans. Thus, the objective of this work is the construction of a computer vision system that yields the $L^*a^*b^*$ measures of coffee beans and classifies them according to their colors. The computer vision system is composed of: a RGB digital camera, a dark metallic chamber, an internal light source, a software and a personal computer. The software was designed in order to convert the acquired RGB camera values to $L^*a^*b^*$ color units (color space transformation model), and to classify the coffee beans (pattern recognition system). Neural networks were used as the transformation models and the Bayes classifier was used to classify the coffee beans into four groups: whitish, green cane, green and bluish-green. The neural networks models achieved a generalization error of 1.15% which is satisfactory and the Bayesian classifier was able to classify all samples into their expected classes (100% accuracy) using different training/validation datasets. Moreover, a discussion about some relationships between CIELAB values and coffee quality is also presented. Thereby, the computer vision system proposed in this work was effective at classifying different colors of coffee beans and can be applied to help cooperatives to analyze the quality of coffee beans.

Keywords: coffee bean, computational vision system, Bayes classifier, artificial neural networks, pattern recognition.

1. Introduction

Color is an important attribute that is widely used to evaluate food quality and is a key factor in the market acceptance of food (WU; SUN, 2013).

Among characteristics related to the physical appearance of coffee beans, color is of great economic importance once discolored beans achieve lower market prices. Thereby, this characteristic interferes decisively in the commercialization process of this product (BORÉM et al., 2013).

The change in color that occurs in coffee beans during storage is known as fading; bluish-green beans gradually fade to yellowish-red, yellow, or whitish. The intensity of fading is directly related to environmental conditions and to factors such as damage to the beans, light, relative humidity, temperature, water level, storage time, and packaging type (AFONSO JÚNIOR & CORRÊA, 2003; RIBEIRO et al., 2011; OLIVEIRA et al., 2013).

The CIE $L^*a^*b^*$ or CIELAB color space has been used worldwide to measure foodstuff color because it has a uniform distribution. The Euclidian distance between two colors in the CIELAB color space corresponds to the difference perceived by the human eye (LEÓN et al., 2006; BERBERICH et al., 2002). This color space uses the following spacial coordinates in the Cartesian system: (i) L^* or luminescence, related to the grade of a material's shade and ranging from 0 (black) to 100 (white); (ii) a^* , the red–green axis, ranging from –120 to 120; and (iii) b^* , the blue–yellow axis, ranging from –120 to 120.

The equipments traditionally used to measure color in CIELAB, such as colorimeters and spectrophotometers, normally visualize small and uniform color surfaces. This limitation has generated the need to implement computer vision systems.

Computer vision is a science based on algorithms used to extract and automatically analyze useful information about an object or scene based on observed images (WU & SUN, 2013). Quantitative information about color is extracted from digital images using image processing and analysis to perform rapid and non-invasive color measurement. This method is less expensive and more versatile than the use of traditional instruments to measure color (LEÓN et al., 2006). On the other hand, most computer vision systems operate in the RGB (red, gree and blue) color space and are dependent on the device used, generating non-uniform results. To overcome this limitation, a model for the transformation from RGB to CIELAB color space is needed.

A computer vision system basically consists of a digital camera used to acquire images, a standard illumination system and software for image processing, and analysis (BROSNAN & SUN, 2003). The use of computer vision systems for laboratory analyses has grown in the last decade (LEÓN et al., 2006; VALOUS et al., 2009). The objective of these computer vision systems is to replace common colorimeters with digital color cameras, which can be referred to as digital colorimeters.

Such systems have been widely adopted to rapidly quantify the colors of various foodstuffs using easily acquired equipment and at a reasonable cost (VALOUS et al., 2009; MENDOZA; DEJMEK; AGUILERA, 2006; SEGNINI; DEJMEK; ÖSTE, 1999). Computer vision systems are chosen for this task because colorimeters are not appropriate for non-homogenous samples (as in this study) or those with large surface areas due to the small area of a single measurement (SEGNINI et al., 1999; PAPADAKIS et al., 2000).

Computer vision systems have been widely applied to analyze food in studies of beef (LARRAIN; SCHAEFER; REED, 2008), pork (SUN et al., 2011), fish (YAGIZ et al., 2009), orange juice (FERNANDEZ-VAZQUEZ et al., 2011), wine (MARTIN et al., 2007), beer (SUN et al., 2004), potato chips (PEDRESCHI et al., 2011), wheat (ZAPOTOCZNY & MAJESWSKA, 2010), bananas (MENDOZA & AGUILERA, 2004) and coffee fruits (URIBE; GIRALDO; TASCÓN, 2008).

Many terms are used to describe the color of coffee beans, rendering difficult the classification, memorization, and description of all nuances and variations in bean color. The objective of this study was to implement a computer vision system enabling quantitative expression of the colors of coffee bean samples in CIELAB and their classification according to the Specialty Coffee Association of America (SCAA) and the Brazilian Official Classification (COB) methodologies.

Thus, the contribution of this paper is to show a methodology to construct the transformation model that converts from RGB to CIELAB color spaces using Artificial Neural Networks (NNs) (HAYKIN, 2009), and to propose a pattern recognition system to classify coffee beans based on their measured L*a*b color units using a Bayesian classifier (MITCHELL, 1997). Besides, some analysis are presented showing relationships between the coffee bean quality and its measured L*a*b color units.

This brief is organized as follows. Section 2 presents the methodology. The results and discussions about the color space transformation model and the classification system are presented in Section 3. Finally, the conclusions of this work and future works are summarized in Section 4.

2. Material and Methods

2.1 Coffee samples

We selected samples of Arabica coffee (*Coffea arabica* L.) harvested in 2013 and provided by the Regional Cooperative of Coffee Growers in Guaxupé (Cooxupé) localized in Guaxupé, Minas Gerais, Brazil. Using the SCAA or COB methods, we've selected 120 50-g samples (30 per color) of the following colors groups: whitish, green, cane green and bluish-green. According Cooxupé these color classes correspond to the colors most used commercially.

The experiment was conducted at the Polo technology in Coffee Quality located at the Federal University of Lavras, localized in Lavras, Minas Gerais, Brazil.

2.2 Computer vision system

The computer vision system developed in this study was designed to measure the color of coffee bean samples in the CIELAB color space, an international color measurement standard adopted by the Commission Internationale d'Eclairage (CIE, 1986). The system consisted of:

- a dark metallic chamber that minimizes background light and eliminates interference from outside light (Fig. 1);
- a Canon Powershot G12 digital camera with 10-megapixel resolution installed 40 cm above the sample space, with the ability to adjust parameters such as no flash use, fluorescent white balance, f/6.0 aperture, 1/10-s exposure, and ISO 160 speed;
- an intense white lighting system with two lamps arranged at 45° from the digital camera's lens; and
- a personal computer and software to analyze and process the images.



Fig. 1. Image acquisition system developed to classify coffee beans.

Images were taken at the highest resolution that the camera permitted and saved in Canon's raw image (NEF) format. Digital Photo Professional® software (©CANON INC. 2005) was used to convert raw images to the widely used and readily interpreted tagged image file format (TIFF), with a resolution of 16 bits per channel in the RGB color space. This procedure facilitated a band ranging from 0 to 65,535 intensities per channel per pixel. Size adjustment and image selection of each picture were performed using ImageJ® software (Powerful image analysis) of public domain.

As the image obtained depends on various factors, such as lighting and digital camera parameters, the direct conversion from RGB to absolute CIELAB color space is not possible (International Commission on Illumination, 1986). System calibration following the method reported by León et al. (2006) is thus

necessary to build a transformation model for the color space. Such a transformation is described in the next section.

2.2.1 The Transformation Model

The methodology used to identify the transformation model is described in Fig. 4. Thus, the following steps were taken:

1. select the color charts. We constructed a dataset comprised of 564 samples in order to obtain a wide range of color unit values and to cover the colors of coffee bean samples used in this study. Some samples are shown in Fig. 2;
2. measure the $L^*a^*b^*$ values of each color chart using a Minolta CR 400 colorimeter. We measured L^* , a^* and b^* values of each color charts in triplicate and averaged the measurements to obtain final CIELAB values. The histograms of the measured values are shown in Fig. 3, and one can notice that a wide range of values was accomplished;
3. take pictures of the color charts using the digital camera in raw format;
4. convert the acquired images to TIFF 16 bits format using the Digital Photo Professional® software and resize them using the ImageJ® software;
5. read the TIFF images using the MatLab® program which returns a three-dimensional matrix for each image corresponding to the RGB color space.

- estimate the transformation model using the mean RGB values of each color chart as model inputs, and the respective CIELAB values provided by the colorimeter as outputs.





Fig. 2. Examples of color charts used to identify the transformation model.

(a)





(b)**(c)**

Fig. 3. Histograms of CIELAB measurements taken from the Minolta colorimeter over the available color charts. (a) L^* , (b) a^* , and (c) b^* values.

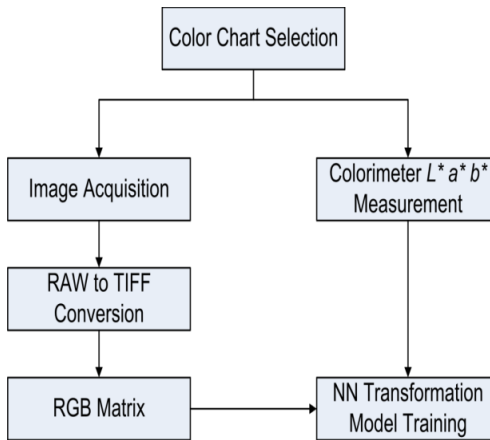


Fig. 4. Steps used to build the RGB–CIELAB transformation model.

Transformation models may have various structures, including linear and non-linear polynomial models with parameters estimated by the least squares algorithm (SÖDERSTRÖM; STOICA, 1989), direct transformation models (HUNT, 1991), and non-linear models based on computational intelligence techniques like the artificial neural networks (HAYKIN, 2009).

A *Multi Layer Perceptron* feed-forward NN (Fig. 5) composed of a hidden layer with five neurons with non-linear activation function (hyperbolic tangent) and one linear output neuron was trained using the Levenberg-Marquardt algorithm with the early-stopping procedure (HAYKIN, 2009). We used NNs in this study because of their proven efficiency presented in (LEÓN et al., 2006). However, different to (LEÓN et al., 2006), we built 3 distinct neural networks, one for each output (L^* , a^* or b^*), as shown in Fig. 5.

The dataset of 564 color chart images was randomly divided into two datasets: training dataset (80% of samples) and validation dataset (20% of samples). Structure choice of the NNs was based on cross fold validation over

training dataset, as described by Bishop (1996). To test network generalization, we used the validation dataset.




Fig. 5. Structure of the three artificial neural networks used for RGB-CIELAB transformation. Each NN yields one output, L, a or b color units.

The network error was evaluated using the following criterion (LEÓN et al., 2006):

$$\bar{e} = \frac{e_L + e_a + e_b}{3}, \quad (1)$$

in which:

$$e_L = \frac{1}{N} \sum_{i=1}^N \frac{|L_i^* - \hat{L}_i|}{\Delta L}, \quad (2)$$

$$e_a = \frac{1}{N} \sum_{i=1}^N \frac{|a_i^* - \hat{a}_i|}{\Delta a}, \quad (3)$$

$$e_b = \frac{1}{N} \sum_{i=1}^N \frac{|b_i^* - \hat{b}_i|}{\Delta b}, \quad (4)$$

where ΔL , Δa , and Δb refer to the lengths of variation intervals for CIELAB components ($0 \leq L \leq 100$, $-120 \leq a \leq 120$, and $-120 \leq b \leq 120$); that is, $\Delta L = 100$ and $\Delta a, \Delta b = 240$.

After building the transformation model and converting RGB to CIELAB values, the next step is to implement the pattern recognition system to classify the coffee beans into the available color groups.

2.3 Pattern Recognition System

Images of the coffee beans from the four color classes (whitish, green, cane green and bluish-green) were obtained by laying the beans on a black surface in the dark chamber with the convex sides facing up (Fig. 6a). The black background of the acquired images was then removed using a segmentation process based on the conversion of the color image to a grayscale one and on the selection of a threshold. So, RGB matrixes corresponding only to coffee beans were obtained (Fig. 6b). These matrixes were converted to the CIELAB color space using the trained NN transformation models.




Fig. 6. Image acquisition and pre-processing of coffee beans samples. (a) image without pre-processing; (b) image after removal of the black background.

After obtaining the coffee beans color parameters (L^* , a^* and b^*) pattern classification tools can be employed to recognize the color group of coffee samples. Despite many classifiers could be implemented to accomplish this task, we decided to implement the Naive-Bayes classifier which is very simple, fast, robust, easy to understand and with good interpretability feature.

2.3.1 The Bayesian Classifier

The Bayesian classifier learns probability distributions from data and classifies a test instance, x , by choosing the class with the maximum a posteriori probability (MAP) (MITCHELL, 1997). The class is chosen to satisfy:

$$\mathcal{H}_{MAP} = \arg_{\mathcal{H}i \in \mathcal{H}} \max p(x/\mathcal{H}i) p(\mathcal{H}i), \quad (5)$$

where $p(\mathcal{H}i)$ is a priori probability and $p(x/\mathcal{H}i)$ is the conditional probability density function of class ($\mathcal{H}i$) where x is the attribute value (color

parameters L^* , a^* and b^*), and $i = 1, 2, 3$ and 4 , corresponding to four color classes studied in this work: whitish, cane green, green and bluish-green.

Considering the Naive-Bayes classifier assumes independence between features, the conditional probability density function based on the Gaussian distribution is expressed by:

$$P(x/\mathcal{H}i) = \prod_{k=1}^3 P(x_k/\mathcal{H}i) \quad (6)$$

$$p(x_k/\mathcal{H}i) = \frac{1}{(2\pi\sigma_{ik}^2)^{\frac{1}{2}}} \exp\left\{-\frac{1}{2\sigma_{ik}^2} (x_k - \mu_{ik})^2\right\},$$

with μ_{ik} being the mean value of class $\mathcal{H}i$ and σ_{ik} being its variance.

Assuming uniform a priori probabilities, the following formula is simplified such that:

$$\mathcal{H}_{ML} = \operatorname{arg}_{\mathcal{H}i \in \mathcal{H}} \max p(x/\mathcal{H}i), \quad (7)$$

here \mathcal{H}_{ML} is the Maximum Likelihood hypothesis.

3. Results and Discussions

3.1 The Transformation Models

After training the NNs transformation models as described in Section 2.2.1, the average errors presented in Table 1 were achieved. The results obtained in this work $1.20\% \pm 1.24\%$ for the training set and $1.15\% \pm 1.01\%$ for the test set are comparable to those reported by León et al. (2006) where errors of $0.95\% \pm 1.28\%$ for the training set and $0.87\% \pm 1.22\%$ for the test set were

reached. However, it is important to notice that we used 564 color samples whereas only 32 color samples were used in León et al. (2006).

Table 1. Mean and standard deviations of errors obtained by the color space transformation models based on artificial neural networks.

	Training	Test
$e_L(\%)$	2.33 ±2.23	2.26±1.96
$e_a(\%)$	0.63±0.51	0.57±0.43
$e_b(\%)$	0.64±0.64	0.62±0.60
$\hat{e}(\%)$	1.20±1.24	1.15±1.01

According to CIE (1986), the difference between colors in the CIELAB space can be expressed as:

$$\Delta E_{ab}^* = \sqrt{(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2} . \quad (8)$$

The human eye can distinguish colors separated by a minimum of 2.2 or up to 4 ΔE_{ab}^* units (BRAINARD, 2003; BLACKWELL, 2005). The transformation models developed in this study reached an average of 2.97 ΔE_{ab}^* units with test data, confirming that they were well estimated and can be used to analyze the coffee beans samples.

1.2 The Pattern Recognition System

Using the converted L*a*b* mean values (Fig. 7) of the coffee beans samples images, the parameters of the Naive-Bayes classifier were estimated. The mean values of the Gaussian conditional probability density function are shown in Table 2.




Fig. 7. CIELAB values of the available coffee beans samples (WH- whitish samples, CG- cane green samples, GR- green samples and BG- bluish-green samples).

Table 2. Mean values of color parameters for each class estimated by the Naive-Bayes classifier.

	L*	a*	b*
Whitish	46,78	-4,62	-6,75
Cane Green	40,84	-6,35	-9,15
Green	32,83	-8,07	-10,56
Bluish-Green	32,49	-8,93	-11,27

As it can be inferred from Table 2, the parameter L^* was higher for the whitish samples (46.78) demonstrating a high whitening value, as expected since the L^* represents the lightness. The cane green samples showed high values of L^* (40.84), which are smaller than the values obtained by the whitish samples but higher than those achieved by green or bluish-green samples. The green and bluish-green samples showed the lowest values of L^* . According to Coradi et al (2007) and Ribeiro (2011) the L^* , a^* and b^* values increase as high as the storage time has increased, which corroborates the findings of this work. To make this clear Fig. 8 presents only the a^* and b^* color values of the coffee

samples. It can be noted that these values really increased from the bluish-green (best quality) samples to the whitish (worst quality) samples. It can be noticed from the results that the whitish class showed high values of the parameters a^* (-4.62) and b^* (-6, 35) demonstrating loss of green and blue colors, and being closer to yellow colors. On the other hand, the bluish-green class has lower a^* (-8.93) and b^* (-11.27) values than the other classes, which makes this class closer to the green and blue colors, as expected. So, higher values of L^* , a^* and b^* are related to poor quality of coffee beans.




Fig. 8. Distribution of a^* and b^* values according to the color classes: WH- whitish samples, CG- cane green samples, GR- green samples and BG- bluish-green samples.

From Figure 8 it can be also observed that the color classes are linearly separated, which means that the whole system here developed was well implemented and is capable to distinguish colors as done by coffee experts, that classify coffee beans using visual inspection. Since the classes are linearly separated, the Naive-Bayes classifier achieved 100% of classification accuracy.

Besides, analyzing Figure 8 only the parameter a^* would be necessary to achieve 100% of classification accuracy, because linearly separated classes

would be still found if just this parameter was kept. However, it is interesting to keep the other two color units in order to make the classifier more robust and reliable.

4. Conclusions

This work presented a computer vision system based on computational intelligence techniques to analyze and classify coffee beans. The results showed that the developed system allows determining the color of coffee beans in the CIELAB color space in a precise and objective way. To do so, it was necessary to: *i.* obtain a dark chamber with appropriate lighting system; *ii.* setup the right parameters of the digital camera; *iii.* select color charts that represent colors close to those normally found in coffee beans; *iv.* train the transformation model composed of three Neural Networks to convert from the RGB to the CIELAB color spaces.

After achieving reliable measurements of L^* , a^* and b^* values of coffee beans, their classification became an easy task (linearly separated classes) and it was possible to obtain a classification accuracy of 100% using a Naive-Bayes classifier.

The results also showed the relation between the coffee beans quality (color classes) and the CIELAB values, where higher values for these color units reveal loss of quality.

In addition, this computer vision system could be used in coffee cooperatives to analyze coffee beans quality and can be extended to other food industries allowing a better characterization of food and, consequently, improving the quality control.

5. Bibliographic References

BERBERICH, J.; DEE, K.H.; HAYAUCHI, V.; PÖRTNER, C. A new method to determine discoloration kinetics of uncoated white tablets occurring during stability testing – an application of instrumental color measurement in the development pharmaceuticals, **International Journal of Pharmaceutics**, v. 234, p. 55-66, 2002.

BISHOP, M. J. **Guide to human genome computing** (2° edição) Hinxton, Cambridge, 1996.

BORÉM, F. M. ; RIBEIRO, F. C. ; FIGUEIREDO, L. P. ; GIOMO, G. S. ; FORTUNATO, V. A. ; ISQUIERDO, E. P. . Evaluation of the sensory and color quality of coffee beans stored in hermetic packaging. **Journal of Stored Products Research**, v. 52, p. 1-6, 2013.

BRAINARD, D. H. Color appearance and color difference specification. In S. K. Shevell (Ed.), **The science of color** (2nd ed., pp. 191–216). Amsterdam: Elsevier Science Ltd. (2003).

BROSNAN, T.; SUN, D. W. Influence of Modulated Vacuum Cooling on the Cooling Rate, Mass Loss and Vase Life of Cut Lily Flowers. **Biosystems Engineering**, v. 86, n. 1, p.45-49, 2003.

CIE Colorimetry (2nd ed.). Wien, Austria: **CIE Central Bureau Kegelgasse** Publication No. 15.2. (1986). 27 A-1030.

CORADI, P. C. ; BORÉM, F. M.; SAATH, R.; MARQUES, E. R. Effect of drying and storage conditions on the quality of natural and washed coffee. **Coffee Science**, Lavras, v. 2, n. 1, p. 38- 47, jan./jun. 2007.

FERNANDEZ-VAZQUEZ, R.; STINCO, C. M.; MELENDEZ-MARTINEZ, A. J.; HEREDIA, F. J.; VICARIO, I. M. Visual and instrumental evaluation of orange juice color: a consumers' preference study. **Journal of Sensory Studies**, v. 26, 436- 444, 2011.

HAYKIN, S.S. **Neural Networks and Learning Machines** (3rd ed.) Canada: Pearson, 2009.

HUNT, R. W. G. **Measuring color** (2nd ed.). New York: Ellis Horwood, 1991.

LARRAIN, R. E.; SCHAEFER, D. M.; REED, J. D. Use of digital images to estimate CIE color coordinates of beef. **Food Research International**, v.41, p. 380-385, 2008.

LEÓN, K.; MERY, D.; PEDRESCHI, F.; LEÓN, J. Color measurement in L*a*b* units from RGB digital images. In: **Food Research International**, Chile, v. 39, p. 1084-1091, 2006.

MARTIN, M. L. G. M.; JI, W.; LUO, R.; HUTCHINGS, J.; HEREDIA, F. J. Measuring colour appearance of red wines. **Food Quality and Preference**, v. 18, p. 862-871, 2007.

MENDOZA, F.; AGUILERA, J. M. Application of image analysis for classification of ripening bananas. **Journal of Food Science**, v. 69, p. 471- 477, 2004.

MENDOZA, F.; DEJMEK, P.; AGUILERA, J. M. Calibrated color measurements of agricultural foods using image analysis **Postharvest Biology and Technology**, v. 41, p. 285– 295, 2006.

MITCHELL, T. **Machine Learning**, 1st edn, McGraw-Hill Education, 1997.

OLIVEIRA, P.D; BORÉM, F. M.; ISQUIERDO, E.P.; GIOMO, G.S.; LIMA, R.R.; CARDOSO, R.A. Physiological aspects of coffee beans, processed and dried through different methods, associated with sensory quality. **Coffee Science**, Lavras, v. 8, n. 2, p. 211-220, abr./jun. 2013.

PAPADAKIS, S. E.; ABDUL- MALEK, S.; KAMDEM, R. E.;YAM, K. L. A versatile and inexpensive technique for measuring color of foods. **Food Technology**, v. 54(12), p.48–51, 2000.

PEDRESCHI, F.; MERY, D.; BUNGER, A.;YANEZ, V. Computer vision classification of potato chips by color. **Journal of Food Process Engineering**, v. 34, p. 1714-1728, 2011.

RIBEIRO, F. C. ; BORÉM F. M.; GIOMO, G. S.; LIMA, R. R.; MALTA, M. R.; FIGUEIREDO, P. F. Storage of green coffee in hermetic packaging injected with CO₂ . **Journal of Stored Products Research**, v. 47, p. 341- 348, 2011. SPECIALTY COFFEE ASSOCIATION OF AMERICA (SCAA). **Specialty coffee facts & figures**. 2014. Available at: <http://www.scaa.org/PDF/resources/fcts-and-figures.pdf>. Last access: 09/25/2014.

SEGNINI, S.; DEJMEK, P.; ÖSTE, R. A low cost video technique for color measurement of potato chips. **LWT – Food Science & Technology**, v.32, p. 216–222, 1999.

STÖDERSTRÖM, T.; STOICA, P. **System identification**. New York: Prentice-Hall,1989.

SUN, F. X.; CHANG, Y. W.; ZHOU, Z. M.; YU, Y. F. Determination of beer color using image analysis. **Journal of the American Society of Brewing Chemists**, v. 62, p. 63-167, 2004.

SUN, X.; CHEN, K.; BERG, E. P.; MAGOLSKI, J. D. Predicting fresh beef color grade using machine vision imaging and support vector machine (SVM) analysis. **Journal of Animal and Veterinary Advances**, v.10, p.1504-1511, 2011.

URIBE, J. R. S.; GIRALDO, P. J. R.; TASCÓN, C. E. O. Algorithm to Identify Maturation Stages of Coffee Fruits. **Advances in Electrical and Electronics Engineering** - IAENG Special Edition of the World Congress on Engineering and Computer Science 2008, p. 167–174, 2008.

VALOUS, N. A.; MENDOZA, F.; SUN, Da-Wen; ALLEN, P. Colour calibration of a laboratory computer vision system for quality evaluation of pre-sliced hams. **Meat Science**, v. 81, p. 132–141, 2009.

WU, D. ;SUN, D.W. Colour measurements by computer vision for food quality control- A review. **Food Science e Technology**, v.29, p. 5-20, 2013.

YAGIZ, Y.; BALABAN, M. O. ; KRISTINSSON H. G.;WELT, B. A.; MARSHALL, M.R. Comparison of Minolta colorimeter and machine vision system in measuring colour of irradiated Atlantic salmon. **Journal Science Food Agric.**, v. 89, p. 728–730, 2009.

ZAPOTOCZNY, P.; MAJEWSKA, K. A comparative analysis of colour measurements of the seed coat and endosperm of wheat kernels performed by various techniques. **International Journal of Food Properties**, v. 13, p.75-89, 2010.

ZHANG, Y.; WANG, S.; JI, G.; PHILLIPS, P. Fruit classification using computer vision and feedforward neural network. **Journal of Food Engineering**, v. 143, p. 167- 177, 2014.

(VERSÃO PRELIMINAR)

ANEXOS

ANEXO A- Instrução Normativa nº 8

INSTRUÇÃO NORMATIVA Nº 8, DE 11 DE JUNHO DE 2003 O MINISTRO DE ESTADO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO, no uso da atribuição que lhe confere o art. 87, inciso II, da Constituição, tendo em vista o disposto no Decreto no 4.629, de 21 de março de 2003, na Lei no 9.972, de 25 de maio de 2000, no Decreto no 3.664, de 17 de novembro de 2000, e o que consta do Processo no 21000.006212/2002-41, resolve:

Art. 1º Aprovar o Regulamento Técnico de Identidade e de Qualidade para a Classificação do Café Beneficiado Grão Cru, em anexo.

Art. 2º Os casos omissos e as dúvidas suscitadas na execução desta Instrução Normativa serão resolvidos pela Secretaria de Apoio Rural e Cooperativismo deste Ministério.

Art. 3º Esta Instrução Normativa entra em vigor na data de sua publicação.

Art. 4º Fica revogada a Instrução Normativa no 048, de 16 de agosto de 2002.

ROBERTO RODRIGUES

ANEXO

REGULAMENTO TÉCNICO DE IDENTIDADE E DE QUALIDADE PARA A CLASSIFICAÇÃO DO CAFÉ BENEFICIADO GRÃO CRU

1. Objetivo: o presente Regulamento tem por objetivo definir as características de identidade e de qualidade para a classificação do Café Beneficiado Grão Cru.

2. Definição do Produto: entende-se por Café Beneficiado Grão Cru o endosperma do fruto de diversas espécies do gênero Coffea, principalmente Coffea arabica e Coffea canephora (robusta ou conillon).

1. Conceitos: para efeito deste Regulamento, considera-se.

3.1. Umidade: percentual de água encontrado na amostra do produto, a qual deverá se apresentar isenta de matérias estranhas e impurezas.

3.2. Matéria estranha: detritos vegetais não oriundos do produto, grãos ou sementes de outras espécies e corpos estranhos de qualquer natureza, tais como pedras ou torrões.

3.2.1. Pedra ou torrão: qualquer pedra ou torrão, de diferentes tamanhos, oriundos da varrição ou de fragmentos do piso do terreiro.

3.3. Impureza: casca, pau e outros detritos provenientes do próprio produto.

3.3.1. Casca: fragmento de casca seca do fruto do cafeeiro, de diversos tamanhos, provenientes da má regulação da máquina de benefício;

3.3.2. Pau: fragmento do ramo de cafeeiro.

3.4. Grão preto: grão ou pedaço de grão de coloração preta opaca.

3.5. Grão ardido: grão ou pedaço de grão que apresenta a coloração marrom, em diversos tons, devido à ação de processos fermentativos.

3.6. Grão preto-verde: grão preto que se apresenta brilhante devido à aderência da película prateada.

3.7. Grão verde: grão imaturo, com película prateada aderida, com sulco ventral fechado e de coloração verde em tons diversos.

3.8. Marinheiro: grão que, no benefício, o pergaminho não foi total ou foi parcialmente retirado.

3.9. Quebrado: pedaço de grão, de forma ou tamanho variável.

3.10. Concha: grão em forma de concha, resultante da separação de grãos imbricados oriundos da fecundação de dois óvulos em uma única loja do ovário.

3.11. Coco: grão que não teve a casca retirada no beneficiamento.

- 3.12. Miolo de concha: grão plano e pouco espesso, resultante da separação de grãos imbricados oriundos da fecundação de dois óvulos em uma única loja do ovário.
- 3.13. Grão mal granado: grão com formação incompleta apresentando-se com pouca massa e, às vezes, com a superfície enrugada.
- 3.14. Grão esmagado: grão que se apresenta com a forma alterada devido ao esmagamento.
- 3.15. Grão brocado: grão danificado pela broca do café, apresentando um ou mais orifícios limpos ou sujos, podendo ser:
- 3.15.1. Brocado sujo: grão ou pedaço de grão danificado pela broca do café que se apresenta com partes pretas ou azuladas;
- 3.15.2. Brocado rendado: grão ou pedaço de grão danificado pela broca do café que se apresenta com três ou mais furos e sem partes pretas;
- 3.15.3. Brocado limpo: grão ou pedaço de grão danificado pela broca do café que se apresenta com até três furos e sem partes pretas.
- 3.16. Grão triângulo: grão de formato triangular por ter se desenvolvido no fruto três ou mais sementes.
- 3.17. Grão grinder: grão quebrado que vazar nas peneiras inferiores à peneira 14 (14/64”), com pelo menos 2/3 de grãos inteiros.
- 3.18. Café cabeça: grão composto por dois grãos imbricados, oriundos da fecundação de dois óvulos em uma única loja do ovário. Não será considerado defeito, a menos que se separe, dando origem à concha e ao miolo de concha.
- 3.19. Café melado (peliculado): grão perfeito, tendo, entretanto, a película do espermoderma aderida devido a fatores climáticos e coloração marrom, ligeiramente avermelhada.
- 3.20. Grão pálido: grão que se apresenta com coloração amarelada, destoando na amostra, após a mesma ter sido submetida á “Torrção Americana”.

4. Classificação: o Café Beneficiado Grão Cru será classificado em CATEGORIA, SUBCATEGORIA, GRUPO, SUBGRUPO, CLASSE e TIPO, segundo a espécie, formato do grão e a granulometria, o aroma e o sabor, a bebida, a cor e a qualidade, respectivamente.

4.1. Categoria: de acordo com a espécie a que pertença, o Café Beneficiado Grão Cru será classificado em 2 (duas) categorias:

4.1.1. Categoria 1: café proveniente da espécie *Coffea arabica*;

4.1.2. Categoria II: café proveniente da espécie *Coffea canephora*.

4.2. Subcategoria: o Café Beneficiado Grão Cru, segundo o formato do grão e a sua granulometria, será enquadrado em 2 (duas) subcategorias:

4.2.1. Chato: constituída de grãos com superfície dorsal convexa e a ventral plana ou ligeiramente côncava, com a ranhura central no sentido longitudinal.

4.2.1.1. O Café Beneficiado Grão Cru da Subcategoria Chato, de acordo com o tamanho dos grãos e a dimensão dos crivos circulares das peneiras que os retêm, será classificado em:

4.2.1.1.1. Chato graúdo: peneiras 19/18 e 17;

4.2.1.1.2. Chato médio: peneiras 16 e 15;

4.2.1.1.3. Chato miúdo: peneira 14 e menores.

4.2.2. Moca: constituída de grãos com formato ovóide, também com ranhura central no sentido longitudinal.

4.2.2.1. O Café Beneficiado Grão Cru da Subcategoria Moca, de acordo com o tamanho dos grãos e a dimensão dos crivos oblongos das peneiras que os retêm, será classificado em:

4.2.2.1.1. Moca graúdo: peneiras 13/12 e 11;

4.2.2.1.2. Moca médio: peneira 10;

4.2.2.1.3. Moca miúdo (moquinha): peneira 9 e menores.

4.2.3. Quando o Café Beneficiado Grão Cru não for submetido à separação em peneiras, ou quando submetido se enquadre em quatro ou mais peneiras, será considerado BICA CORRIDA (B/C).

4.2.4. Na classificação por peneiras, o vazamento máximo admissível para cada peneira será de 10%, sendo que vazamento superior a esse valor caracterizará a ocorrência de outra peneira, abaixo da que o originou, no lote em análise.

4.3. Grupo: o Café Beneficiado Grão Cru, de acordo com o aroma e o sabor, será classificado em 2 (dois) grupos. O sabor e o aroma serão definidos por meio da prova de xícara.

4.3.1. GRUPO I - Arábica.

4.3.2. GRUPO II - Robusta.

4.4. Subgrupo: o Café Beneficiado Grão Cru, de acordo com a bebida e com o grupo a que pertença, será classificado em 07 (sete) Subgrupos do Grupo I e 4 (quatro) Subgrupos II, assim discriminados:

4.4.1. Bebidas Finas do Grupo I - Arábica.

4.4.1.1. Estritamente mole: café que apresenta, em conjunto, todos os requisitos de aroma e sabor “mole”, porém mais acentuado;

4.4.1.2. Mole: café que apresenta aroma e sabor agradável, brando e adocicado;

4.4.1.3. Apenas mole: café que apresenta sabor levemente doce e suave, mas sem adstringência ou aspereza de paladar;

4.4.1.4. Duro: café que apresenta sabor acre, adstringente e áspero, porém não apresenta paladares estranhos.

4.4.2. Bebidas Fenicadas do Grupo I - Arábica.

4.4.2.1. Riado: café que apresenta leve sabor, típico de iodofórmio;

4.4.2.2. Rio: café que apresenta sabor típico e acentuado de iodofórmio;

4.4.2.3. Rio Zona: café que apresenta aroma e sabor muito acentuado, assemelhado ao iodofórmio ou ao ácido fênico, sendo repugnante ao paladar.

4.4.3. Bebidas do Grupo II - Robusta.

- 4.4.3.1. Excelente: café que apresenta sabor neutro e acidez mediana;
- 4.4.3.2. Boa: café que apresenta sabor neutro e ligeira acidez;
- 4.4.3.3. Regular: café que apresenta sabor típico de robusta sem acidez;
- 4.4.3.4. Anormal: café que apresenta sabor não característico ao produto.

4.5. Classe: o Café Beneficiado Grão Cru, de acordo com a coloração do grão, será classificado em 8 (oito) classes:

- 4.5.1. Verde Azulado e Verde Cana: cores características do café despolpado ou degomado;
- 4.5.2. Verde: café que apresenta grão de coloração verde e suas nuances;
- 4.5.3. Amarelada: café que apresenta grão de coloração amarelada, indicando sinais de envelhecimento do produto;
- 4.5.4. Amarela;
- 4.5.5. Marrom;
- 4.5.6. Chumbado;
- 4.5.7. Esbranquiçada;
- 4.5.8. Discrepante: mistura de cores oriundas de ligas de safras ou cores diferentes.

4.6. Tipo: o Café Beneficiado Grão Cru, de acordo com o percentual de defeitos e matérias estranhas e impurezas, será classificado conforme o estabelecido nas Tabelas 1, 2 e 3 deste Regulamento.

5. Umidade

5.1. Independente de sua classificação, os teores de umidade do Café Beneficiado Grão Cru não poderão exceder os limites máximos de tolerância de 12,5% (doze e meio por cento).

6. Matérias estranhas e impurezas

6.1. O percentual máximo de matérias estranhas e impurezas permitido no Café Beneficiado Grão Cru será de 1% (um por cento). Excedendo esse valor, o produto será desclassificado temporariamente, sendo impedida a sua comercialização até o rebeneficiamento para enquadramento em tipo.

7. Fora de Tipo: será classificado como Fora de Tipo o Café Beneficiado Grão Cru que apresentar:

7.1. Os percentuais de ocorrência de defeitos excedendo aos limites máximos de tolerância estabelecidos nas tabelas deste Regulamento;

7.2. Mais de 50 grãos pretos ou mais de 100 grãos ardidos ou mais de 100 grãos preto verde;

7.3. Mais de 300 defeitos, excetuando-se os grãos quebrados, mal granados, conchas, miolos de concha e os brocados limpos;

7.4. O produto classificado como Fora de Tipo não poderá ser comercializado e internalizado como tal, devendo ser:

7.4.1. Rebeneficiado, desdobrado e recomposto, para efeito de enquadramento em Tipo;

7.4.2. Reensacado e remarcado, para efeito de atendimento às exigências deste Regulamento.

8. Desclassificado

8.1. Será Desclassificado temporariamente e proibida a sua comercialização, até o rebeneficiamento, o Café Beneficiado Grão Cru que apresentar mais de 1% (um por cento) de matérias estranhas e impurezas.

8.2. Será Desclassificado temporariamente, e proibida a sua comercialização e internalização, até o expurgo, o Café Beneficiado Grão Cru que apresentar insetos vivos.

8.3. Será Desclassificado o Café Beneficiado Grão Cru que apresentar uma ou mais das características indicadas abaixo, sendo proibida a sua comercialização e internalização para consumo humano e animal:

8.3.1. Aspecto generalizado de mofo;8.3.2. Mau estado de conservação;

8.3.3. Odor estranho de qualquer natureza, impróprio ao produto.

8.3.4. Resíduos de produtos fitossanitários, teor de micotoxinas e outros contaminantes ou substâncias nocivas à saúde acima do limite estabelecido por legislação específica vigente;

8.3.5. Presença de sementes tóxicas.

8.3.6. Somente será permitida a utilização do produto desclassificado, para outros fins, após ouvido o Ministério da Agricultura, Pecuária e Abastecimento.

8.3.7. O Serviço de Classificação deverá comunicar imediatamente ao Ministério da Agricultura, Pecuária e Abastecimento sobre a ocorrência de produto desclassificado, para as providências cabíveis junto ao setor técnico competente.

8.3.8. Caberá ao Ministério da Agricultura, Pecuária e Abastecimento, a decisão quanto ao destino do produto desclassificado, podendo para isso articular-se, quando couber, com outros órgãos oficiais.

8.3.9. No caso específico da permissão ou autorização de utilização do produto desclassificado para outros fins, o Ministério da Agricultura, Pecuária e Abastecimento deverá estabelecer ainda todos os procedimentos necessários ao acompanhamento do produto até a sua completa desnaturação, cabendo ao proprietário do produto ou ao seu preposto, além de arcar com os custos pertinentes a operação, ser o seu fiel depositário e responsável pela inviolabilidade e indivisibilidade do lote em todas as fases de manipulação, imputando-lhe as ações civis e penais cabíveis, em caso de irregularidades ou de uso não autorizado do produto nestas condições.

9. Embalagem

9.1. As embalagens utilizadas no acondicionamento do Café Beneficiado Grão Cru poderão ser de material natural, sintético ou outro material apropriado.

9.2. Dentro de um mesmo lote será obrigatório que todas as embalagens sejam do mesmo material e tenham idêntica capacidade de acondicionamento.

9.3. As especificações quanto á confecção e à capacidade das embalagens devem estar de acordo com legislação específica vigente.

10. Marcação ou rotulagem

10.1. Não será exigida nenhuma marcação ou rotulagem relativa à sua classificação, entretanto, deverá o produto estar acompanhado do seu respectivo Certificado de Classificação.

11. Amostragem

11.1. Previamente à amostragem, deverão ser observadas as condições gerais do lote do produto e, em caso de verificação de qualquer anormalidade, tais como: presença de insetos vivos ou a existência de quaisquer das características de desclassificação (odor estranho, mau estado de conservação, aspecto generalizado de mofo, entre outras), adotar os procedimentos específicos previstos neste Regulamento.

11.2. A amostragem deverá ser realizada por furação ou calagem, sendo os sacos tomados inteiramente ao acaso, em no mínimo de 10% do lote, mas sempre representando a expressão média do lote numa quantidade mínima de 30g (trinta gramas) de cada saco.

11.3. As amostras assim extraídas serão homogeneizadas, reduzidas e acondicionadas em no mínimo 3 (três) vias, com peso de no mínimo 1kg (um quilograma) cada, devidamente identificadas, lacradas e autenticadas.

11.4. Será entregue 01 (uma) via para o interessado, 02 (duas) ficarão com a pessoa jurídica responsável pela classificação e o restante da amostra será obrigatoriamente recolocado no lote ou devolvido ao detentor do produto.

11.5. A amostra para efeito de classificação (amostra de trabalho) será de 300g (trezentos gramas), obtida após homogeneização e quarteamento de uma das duas amostras destinadas a pessoa jurídica responsável pela classificação, ficando a outra como contraprova.

12. Roteiro de Classificação

12.1. Verificar primeiramente, de forma cuidadosa, se na amostra há presença de insetos vivos e se o Café Beneficiado Grão Cru apresenta uma ou mais características desclassificantes. Caso se constate alguma situação, o classificador deverá tomar as providências contidas no item 8.2 e 8.3 deste Regulamento.

12.2. Se o produto estiver em condições de ser classificado, deve-se homogeneizar a amostra destinada à classificação, reduzi-la pelo processo de quarteamento até a obtenção da amostra de trabalho, ou seja: 300g (trezentos gramas) pesada em balança digital previamente aferida.

12.3. Verificar o aspecto do produto, identificar a característica de seca e a classe do produto, anotando o resultado no laudo.

12.3.1. A informação da característica de preparo deverá ser prestada pelo interessado e anotada no laudo.

12.4. Efetuar a separação das matérias estranhas e impurezas presentes na amostra. Pesá-las, anotando no laudo o peso e o percentual encontrado. Constatando-se um percentual superior ao estabelecido no item 6.1, desclassificar temporariamente o produto.

12.5. Do restante da amostra destinada à classificação, deve-se obter, ainda pelo processo de quarteamento, 01 (uma) subamostra destinada à determinação da

umidade, da qual se retirará, quando houver, as matérias estranhas e impurezas. O peso da subamostra deverá estar de acordo com as recomendações do fabricante do equipamento utilizado para verificação da umidade. Uma vez verificada a umidade, deve-se anotar o valor encontrado no laudo.

12.6. De posse da amostra de trabalho, isenta de matérias estranhas e impurezas, separar os defeitos, observando os seguintes aspectos:

12.6.1. Quando for verificada a incidência de dois ou mais defeitos em um mesmo grão, prevalecerá o de maior gravidade, de acordo com a seguinte escala decrescente: preto; ardido; preto verde; concha; mal granado; verde; quebrado.

12.7. Anotar no laudo os defeitos encontrados na amostra.

12.8. Agrupar os defeitos observando aqueles que apresentam a mesma equivalência estabelecida nas tabelas deste Regulamento.

12.9. Nas matérias estranhas e impurezas, separar as cascas, os paus, as pedras e os torrões, efetuar a contagem, anotar no laudo e estabelecer a equivalência de defeitos de acordo com as tabelas deste Regulamento.

12.10. Efetuar a soma dos defeitos e enquadrar o produto em tipo de acordo com os parâmetros estabelecidos nas Tabelas deste Regulamento, anotando o resultado no laudo.

12.11. Determinar a Categoria do Café Beneficiado Grão Cru, de acordo com a espécie a que pertence o Produto, e anotar no seu respectivo campo no laudo.

12.12. Determinação da Subcategoria: para a determinação da Subcategoria do produto, deverá adotar o seguinte procedimento:

12.12.1. Quartear novamente a amostra de trabalho obtida após a separação dos defeitos e das matérias estranhas e impurezas, reduzindo-a a exatamente 100g;

12.12.2. Passar o produto pela série de peneiras, dispostas na seguinte ordem:

- Peneira 19 = chato

- Peneira 13 = moca

- Peneira 18 = chato

- Peneira 12 = moca
- Peneira 17 = chato
- Peneira 11 = moca
- Peneira 16 = chato
- Peneira 10 = moca
- Peneira 15 = chato
- Peneira 9 = moca
- Peneira 14 = chato
- Peneira 13 = chato
- Peneira 8 = moca
- Peneira 10 = chato
- Fundo plano

12.12.3. Pesar as quantidades retidas em cada peneira e anotar no laudo;

12.12.4. Na determinação da Subcategoria, o peso encontrado é igual ao percentual.

12.13. Determinação do Grupo e Subgrupo: a determinação do grupo e do subgrupo do Café Beneficiado Grão Cru será realizada mediante a “Prova de Xícara”, adotando-se os seguintes procedimentos:

12.13.1. Higienização do moinho e dos demais utensílios (xícaras, chaleiras, colheres, etc.);

12.13.2. Passar pelo moinho regulado para a moagem grossa uma pequena quantidade do café torrada a ser submetido à prova de xícara, descartando o produto moído, a fim de eliminar possíveis contaminações de produtos testados anteriormente;

12.13.3. Retirar da amostra de café torrado, porções de aproximadamente 8 a 10 gramas e colocá-las no moinho, posicionando cada xícara no orifício de saída do

produto moído. Repetir esta operação 7 (sete) vezes, visto que deverão ser provadas 7 (sete) xícaras;

12.13.4. Dispor as xícaras em uma mesa de prova circular e giratória, agrupadas por lote de produto a ser testado;

12.13.5. Escaldar o pó, utilizando água mineral ou natural filtrada, não submetida a tratamentos químicos, vertendo-a cuidadosamente sobre o produto, logo após a primeira fervura;

12.13.6. Mexer a infusão com a colher de prova, devendo o provador cheirá-la para obter um julgamento preliminar dos vapores desprendidos e retirando-se a espuma sobrenadante;

12.13.7. Por meio dos aromas desprendidos, o classificador deve estabelecer um juízo prévio da qualidade da bebida de cada amostra, separando as bebidas de características mais favoráveis, que deverão ser degustadas primeiro, daquelas de características menos favoráveis, que deverão ser degustadas posteriormente;

12.13.8. Ao passar de uma amostra para outra, em todas as amostras, a colher de prova deve ser lavada, em xícaras colocadas no braço fixo anexo à mesa giratória;

12.13.9. Aguardar a decantação do pó e em seguida retirar com a colher de prova a espuma e os resíduos que ficarem na borda da xícara;

12.13.10. Aguardar o resfriamento da mistura, ficando a critério do provador a determinação da temperatura adequada à execução do teste;

12.13.11. Iniciar a prova mergulhando a colher suavemente na xícara, de forma que a infusão entre na mesma. Levar à boca, succionando fortemente, fazendo com que um pouco da bebida aspergida vá ao encontro da língua e ao palatino, conservando-a na boca apenas o tempo suficiente para sentir o sabor e os aromas, expelindo-a depois na cuspeira;

12.13.12. Anotar no laudo a qualidade de bebida apresentada pela amostra, enquadrando o produto em Grupo e Subgrupo;

12.13.13. Caso tenha sido solicitado pelo interessado na análise do teor de cafeína, deverá constar do laudo o resultado obtido em laboratório credenciado, mencionando o nome e o número do registro no conselho de classe do profissional autor do laudo laboratorial, devendo uma cópia de tal documento ser arquivada, junto ao laudo de classificação;

12.13.14. Fazer constar do laudo de classificação os motivos que levaram o produto a ser considerado como Fora de Tipo ou Desclassificado;

12.13.15. Revisar, datar, carimbar e assinar o laudo de classificação devendo constar obrigatoriamente do carimbo, do nome do classificador e do número do registro no Ministério da Agricultura, Pecuária e Abastecimento.

13. Certificado de Classificação

13.1. O Certificado de Classificação será emitido pelo Ministério da Agricultura, Pecuária e Abastecimento ou pelas pessoas jurídicas devidamente credenciadas pelo mesmo, de acordo com a legislação vigente.

13.2. O Certificado de Classificação é o documento hábil para comprovar a realização da classificação, correspondendo a um determinado lote do produto classificado.

13.3. O Certificado somente será considerado válido quando possuir a identificação do classificador (carimbo e assinatura), pessoa física devidamente registrado no Ministério da Agricultura, Pecuária e Abastecimento.

13.4. O prazo para contestação do resultado da classificação por meio de solicitação de arbitragem será de 45 (quarenta e cinco) dias, contados a partir do momento da emissão do Certificado de Classificação.

13.5. No Certificado de Classificação, deverão constar, além das informações estabelecidas nesse Regulamento, as seguintes indicações:

13.5.1. A discriminação dos resultados de cada análise efetuada e dos percentuais encontrados, para cada determinação de qualidade do produto, bem

como as informações conclusivas (enquadramento em Categoria, Subcategoria, Grupo, Subgrupo, Classe e Tipo) que serão transcritas do seu respectivo laudo de classificação;

13.5.2. Os motivos que determinaram a classificação do produto como Fora de Tipo;

13.5.3. Os motivos que determinaram a desclassificação do produto.

14. Fraude

14.1. Considerar-se-á fraude toda a alteração dolosa, de qualquer ordem ou natureza, praticada na classificação, na embalagem, no acondicionamento, bem como nos documentos de qualidade do produto.

14.2. Será também considerada fraude a comercialização do Café Beneficiado Grão Cru, em desacordo com o estabelecido neste Regulamento.

15. Disposições gerais

15.1. Será de competência exclusiva do Órgão Técnico do Ministério da Agricultura, Pecuária e Abastecimento resolver os casos omissos porventura surgidos na utilização do presente Regulamento.

16. Tabelas

16.1. TABELA 1 - Classificação do Café Beneficiado Grão Cru quanto à equivalência de defeitos (intrínsecos).

Defeitos	Quantidade	Equivalência
Grão Preto	1	1
Grãos Ardidos	2	1
Conchas	3	1
Grãos Verdes	5	1
Grãos Quebrados	5	1
Grãos Brocados	2 a 5	1
Grãos Mal Granados ou Chochos	5	1

Observações:

- 1 - O Grão Preto será considerado o principal defeito ou capital;
- 2 - Os Grãos Ardidos e Brocados serão considerados defeitos secundários;
- 3 - O defeito Verde Preto “STINKER” será considerado como defeito ardido.

16.2. TABELA 2 - Classificação do Café Beneficiado Grão Cru quanto à equivalência de impurezas (extrínsecos).

Impurezas	Quantidade	Equivalência
Coco	1	1
Marinheiros	2	1
Pau, Pedra, Torção grande	1	5
Pau, Pedra, Torção regular	1	2
Pau, Pedra, Torção pequeno	1	1
Casca grande	1	1
Casca pequena	2 a 3	1

Observações:

- 1 - As Pedras, os Torrões e os Paus Grandes correspondem a mais ou menos as dimensões da Peneira Grão Chato de 18/19/20;
- 2 - As Pedras, os Torrões e os Paus Regulares correspondem a mais ou menos as dimensões da Peneira é Grão Chato de 15/16/17;
- 3 - As Pedras, os Torrões e os Paus Pequenos correspondem a mais ou menos as dimensões da Peneira Grão Chato de 14 abaixo;

4 - As Cascas serão relacionadas a mais ou menos com o tamanho do Café em Coco.

16.3.TABELA 3 - Classificação do Café Beneficiado Grão Cru, em função do defeito/tipo.

Defeitos	Tipos	Pontos	Defeitos	Tipos	Pontos
4	2	+100	46	5	50
4	2-05	+95	49	5-05	55
5	2-10	+90	53	5-10	60
6	2-15	+85	57	5-15	65
7	2-20	+80	61	5-20	70
8	2-25	+75	64	5-25	75
9	2-30	+70	68	5-30	80
10	2-35	+65	71	5-35	85
11	2-40	+60	75	5-40	90
11	2-45	+55	79	5-45	95
12	3	+50	86	6	100
13	3-05	+45	93	6-05	105
15	3-10	+40	100	6-10	110
17	3-15	+35	108	6-15	115
18	3-20	+30	115	6-20	120
19	3-25	+25	123	6-25	125
20	3-30	+20	130	6-30	130
22	3-35	+15	138	6-35	135
23	3-40	+10	145	6-40	140
25	3-45	+05	153	6-45	145
26	4	Base	160	7	150
28	4-05	05	180	7-05	155
30	4-10	10	200	7-10	160
32	4-15	15	220	7-15	165
34	4-20	20	240	7-20	170
36	4-25	25	260	7-25	175
38	4-30	30	280	7-30	180
40	4-35	35	300	7-35	185
42	4-40	40	320	7-40	190
44	4-45	45	340	7-45	195
			360	8	200
			> 360	Fora de Tipo	

17. Modelo de Laudo de Classificação (IDENTIFICAÇÃO DO ÓRGÃO RESPONSÁVEL PELA CLASSIFICAÇÃO) LAUDO DE CLASSIFICAÇÃO DE CAFÉ BENEFICIADO GRÃO CRU N° ____/____(MODELO/FRENTE)

() Café Arábica () Café Robusta

INTERESSADO:					
SAFRA:			AMOSTRA Nº :		
ARMAZÉM:			CIDADE:		
PAVILHÃO:			BLOCO:		Quadra:
Nº DE SACOS:			LOTE:		
CLASSIFICAÇÃO FÍSICA					
Equivalência de Defeitos					
Descrição	Nº de Grãos Imperfeitos	Nº de Defeitos	Descrição	Nº de Grãos Imperfeitos	Nº de Defeitos
- Grão preto			- Coco		
- Grão ardido			- Marinheiro		
- Concha			- Esmagado		
- Mal Granado /chocho			- Casca grande		
- Verde			- Casca média/pequena		
- Quebrado			- Pau ou pedra ou torrão grande		
- Brocado:			- Pau ou pedra ou torrão regular		
- Brocado Sujo			- Pau ou pedra ou torrão pequeno		
- Brocado Rendado			SUBTOTAL (2)		
- Brocado Limpo			ENQUADRAMENTO EM TIPO		
SUBTOTAL(1)			- SUBTOTAL (1)		
			- SUBTOTAL (2)		
			TOTAL GERAL (1) + (2)		
			TIPO		

CATEGORIA:					
SUBCATEGORIA: Peneira %		() CHATO		() MOCA	
() 15 AC	() 18 AC	() Graúdo		() Graúdo	
() 16 AC	() 19	() Médio		() Médio	
() 17 AC	() Bica Corrida	() Miúdo		() Miúdo	
GRUPO:		() GRUPO I: ARÁBICA		() GRUPO II: ROBUSTA	
SUBGRUPO:		() Estritamente Mole		() Riado	
		() Mole		() Rio	
		() Apenas Mole		() Rio Zona	
		() Duro		() CARACTERÍSTICA	
				() Excelente	
				() Regular	
				() Boa	
				() Anormal	
CLASSE:					
() Verde Azulado		() Amarelada		() Chumbado	
() Verde Cana		() Amarela		() Esbranquiçada	
() Verde		() Marron		() Discrepante	
() Esverdeada					

CONCLUSÃO

UMIDADE: _____ APARELHO: _____
 CATEGORIA: _____ SUCATEGORIA: _____
 GRUPO: _____ SUBGRUPO: _____
 CLASSE: _____ TIPO: _____
 OBS.: _____

POSTO DE SERVIÇO DE CLASSIFICAÇÃO DE _____ DE _____ DE _____

CLASSIFICADOR/REG. MAPA N^o _____

LAUDO DE CLASSIFICAÇÃO DE CEFÉ BENEFICIADO GRÃO CRU N^o ____/____
 (MODELO/VERSO)

Café Arábica


Café Robusta

CARACTERÍSTICAS QUALITATIVAS ADICIONAIS		
PELO PREPARO: () Via Seca () Via Úmida	PELA SECA: () Seca Boa () Seca Regular () Seca Má	PELO ASPECTO: () Bom () Regular () Mau
PELA TORRAÇÃO		
<i>Coffea arabica:</i> () Torração Fina () Torração Boa () Torração Regular () Torração Má	<i>Coffea canephora:</i> () Torração Excelente () Torração Quase Excelente () Torração Muito Boa () Torração Boa () Torração Regular () Torração Má	
PELO TEOR DE CAFEÍNA		
() CAFÉ	() CAFÉ DESCAFEINADO	


POSTO DE CLASSIFICAÇÃO DE _____ DE _____ DE _____

CLASSIFICADOR/REG. MAPA N^o _____


ANEXO B- Classificação da SCAA quanto as diferentes colorações nos grãos de café.



Green Arabica Coffee CLASSIFICATION SYSTEM



SPECIALTY GRADE
No Category 1 Defects Allowed. No more than 5 Full Defects.



QUAKER
An unripe bean that does not fully develop during roasting.

STANDARD METHOD OF CLASSIFICATION

SAMPLE WEIGHTS:
Green Coffee – 350 grams | Roasted Coffee – 100 grams

GREEN COFFEE MOISTURE CONTENT:
Washed Coffee should be between 10 – 12% upon Import.

SCENT OF THE GREEN COFFEE:
Coffee must be free of foreign odor.

BEAN SIZE:
No more than 5% variance from purchase contracted specification, measured by retention on traditional round-holed grading screens.

FULL BLACK BEAN
Predominately opaque black.

FULL SOUR BEAN
Predominately reddish or yellowish brown.

DRIED CHERRY/POD
Bean partially or fully enclosed in dark outer fruit husk.

FUNGUS DAMAGED BEAN
Exhibiting yellowish or brownish fungal attack.

FOREIGN MATTER
Any non-coffee item, such as sticks or stones.

SEVERE INSECT DAMAGE BEAN
With three or more insect perforations.

CATEGORY 1 DEFECTS	FULL DEFECT EQUIVALENTS	CATEGORY 2 DEFECTS	FULL DEFECT EQUIVALENTS
Full Black	1	Partial Black	3
Full Sour	1	Partial Sour	3
Dried Cherry/Pod	1	Parchment/Pergamino	5
Fungus Damaged	1	Floater	5
Foreign Matter	1	Immature/Unripe	5
Severe Insect Damage	5	Withered	5
		Shell	5
		Broken/Chipped/Cut	5
		Hull/Husk	5
		Slight Insect Damage	10

ROAST UNIFORMITY:
Specialty Grade – No quakers allowed

CUPPING METHODOLOGY:
Cupping is a professional technique for evaluating coffee's fragrance, aroma, taste, body and aftertaste. ISO milliliters of hot water are poured directly onto 8.25 grams of roast and ground coffee and allowed to steep. Using a large spoon, the coffee is stirred, sniffed, allowed to settle, then vigorously sipped at various temperatures to reveal its flavor characteristics.

FLAVOR CHARACTERISTICS:
Upon cupping, sample must exhibit distinctive attributes in the areas of taste, acidity body and aroma as determined between buyer and seller. Must be free from faults and taints.

PARTIAL BLACK BEAN
Less than one-half opaque black.

PARTIAL SOUR BEAN
Less than one-half reddish or yellowish-brown.

PARCHMENT/PERGAMINO BEAN
Partially or fully enclosed in dried parchment.

FLOATER BEAN
Light in color and low in density.

IMMATURE/UNRIPE BEAN
Underdeveloped and greenish with silverskin attached.

WITHERED BEAN
Lightish green bean with a wrinkled surface.

SHELL
Part of a malformed bean consisting of a cavity.


BROKEN/CHIPPED/CUT
A cut bean or fragment.

HULL/HUSK
Fragment of a dried cherry/pod.

SLIGHT INSECT DAMAGE BEAN
With less than three insect perforations.

GREEN COFFEE COLOR GRADIENT

Unroasted coffee's color ranges from a blue-green to a pale yellow depending upon origin, processing or age.



Blue-Green Bluish-Green Green Greenish Yellow-Green Pale Yellow Yellowish Brownish

Specialty Coffee Association of America | 330 Golden Shore, Suite 50, Long Beach, CA 90802 | T: 562.624.4100 | F: 562.624.4101 | scaa.org