



VISÃO COMPUTACIONAL PARA CONTROLE DE QUALIDADE DO CAFÉ ARÁBICA: CLASSIFICAÇÃO DE DEFEITOS PVA VIA RGB E LAB*

VISION COMPUTACIONAL PARA EL CONTROL DE CALIDAD DEL CAFÉ ARÁBICA: CLASIFICACIÓN DE DEFECTOS PVA VÍA RGB Y LAB*

COMPUTER VISION FOR ARABICA COFFEE QUALITY CONTROL: CLASSIFICATION OF PVA DEFECTS VIA RGB AND LAB*

Apresentação: Comunicação Oral

Camile de Melo Silva Nascimento¹; Wanessa Braz da Silva²; Suzana Pedroza da Silva³; Marteson Cristiano dos Santos Camelo⁴

DOI: <https://doi.org/10.31692/VIICIAGRO.0204>

RESUMO

A classificação manual de grãos de café pode ser afetada pela subjetividade, fadiga e inconsistência entre os avaliadores, onde cada um pode classificar de modo diferente, o que impacta negativamente a uniformidade da qualidade. Este estudo teve como objetivo criar um sistema de processamento digital de imagens (PDI) destinado à identificação e categorização de defeitos PVA (preto, verde e ardido) em grãos de café arábica, através da comparação dos espaços de cor RGB e Lab*. Com base em princípios de visão computacional, a pesquisa analisou como esses espaços podem representar as características de cor dos grãos: no modelo RGB, a luminosidade e a cromaticidade estão juntas em três canais, enquanto o modelo Lab* as distingue, utilizando L* para luminosidade e a*, b* para variações nas cores, que se aproxima mais da percepção visual humana. As imagens dos grãos foram obtidas de bancos de dados públicos e processadas usando GNU Octave, onde foram aplicados procedimentos de binarização, redução de ruídos, abertura morfológica e rotulação individual. A classificação foi realizada através do algoritmo k-NN (k=1), utilizando distância euclidiana em relação a padrões de referência. O desempenho do sistema foi medido em termos de acurácia, sensibilidade e especificidade. Os resultados indicaram que o PDI demonstrou eficácia na classificação dos defeitos PVA, alcançando uma acurácia de 96,93% no espaço RGB e 99,49% no Lab*. O espaço Lab* se destacou, especialmente na diferenciação entre grãos pretos e ardidos, com ambas as categorias atingindo 100% em todos os critérios. A maior limitação encontrada foi a classe verde, que apresentou uma sensibilidade de 50% no espaço Lab*, devido à sua semelhança cromática com grãos saudáveis. Assim, conclui-se que o PDI, particularmente utilizando o espaço Lab*, oferece uma alternativa eficiente e padronizada à inspeção manual, contribuindo para uma maior confiabilidade no controle de qualidade dos grãos de café.

Palavras-chave: processamento digital de imagens; espaços colorimétricos; segmentação de imagens.

¹Graduanda em Engenharia de Alimentos, Universidade Federal do Agreste de Pernambuco, camile.melo@ufape.edu.br

² Programa de Pós-graduação em Engenharia Química, Universidade Federal de Pernambuco, wanessa.braz09@gmail.com

³Programa de Pós-graduação em Engenharia Química, Universidade Federal de Pernambuco, wanessa.braz09@gmail.com

³Dra em Engenharia Química, Universidade Federal do Agreste de Pernambuco, suzana.pedroza@ufape.edu.br

⁴Dr em Engenharia Química, Universidade Federal do Agreste de Pernambuco, marteson.camelo@ufape.edu.br

RESUMEN

La clasificación manual de los granos de café puede verse afectada por la subjetividad, la fatiga y la inconsistencia entre los evaluadores, ya que cada uno puede clasificar de manera diferente, impactando negativamente la uniformidad de la calidad. Este estudio tuvo como objetivo crear un sistema de procesamiento digital de imágenes (DIP) para identificar y categorizar defectos de PVA (negro, verde y quemado) en granos de café arábica mediante la comparación de los espacios de color RGB y Lab*. Basándose en principios de visión por computadora, la investigación analizó cómo estos espacios pueden representar las características de color de los granos: en el modelo RGB, la luminosidad y la cromaticidad se combinan en tres canales, mientras que el modelo Lab* las distingue, utilizando L* para la luminosidad y a*, b* para las variaciones de color, lo que se aproxima más a la percepción visual humana. Las imágenes de los granos se obtuvieron de bases de datos públicas y se procesaron utilizando GNU Octave, donde se aplicaron procedimientos de binarización, reducción de ruido, apertura morfológica y etiquetado individual. La clasificación se realizó utilizando el algoritmo k-NN ($k=1$), utilizando la distancia euclidiana relativa a estándares de referencia. El rendimiento del sistema se midió en términos de precisión, sensibilidad y especificidad. Los resultados indicaron que el PDI demostró eficacia en la clasificación de defectos de PVA, alcanzando una precisión del 96,93 % en el espacio RGB y del 99,49 % en el espacio Lab*. El espacio Lab* destacó especialmente en la diferenciación entre granos negros y quemados, alcanzando ambas categorías el 100 % en todos los criterios. La mayor limitación encontrada fue la clase verde, que presentó una sensibilidad del 50 % en el espacio Lab*, debido a su similitud cromática con los granos sanos. Por lo tanto, se concluye que el PDI, particularmente utilizando el espacio Lab*, ofrece una alternativa eficiente y estandarizada a la inspección manual, contribuyendo a una mayor fiabilidad en el control de calidad de los granos de café.

Palabras Clave: procesamiento digital de imágenes; espacios colorimétricos; segmentación de imágenes.

ABSTRACT

Manual classification of coffee beans can be affected by subjectivity, fatigue, and inconsistency among evaluators, where each may classify differently, negatively impacting quality uniformity. This study aimed to create a digital image processing (DIP) system for identifying and categorizing PVA defects (black, green, and burnt) in Arabica coffee beans by comparing the RGB and Lab* color spaces. Based on computer vision principles, the research analyzed how these spaces can represent the color characteristics of the beans: in the RGB model, lightness and chromaticity are combined in three channels, while the Lab* model distinguishes them, using L* for lightness and a*, b* for color variations, which more closely approximates human visual perception. Bean images were obtained from public databases and processed using GNU Octave, where binarization, noise reduction, morphological aperture, and individual labeling procedures were applied. The classification was performed using the k-NN algorithm ($k=1$), utilizing Euclidean distance relative to reference standards. The system's performance was measured in terms of accuracy, sensitivity, and specificity. The results indicated that the PDI demonstrated effectiveness in classifying PVA defects, achieving an accuracy of 96.93% in the RGB space and 99.49% in the Lab* space. The Lab* space stood out, especially in differentiating between black and burnt beans, with both categories reaching 100% in all criteria. The greatest limitation found was the green class, which presented a sensitivity of 50% in the Lab* space, due to its chromatic similarity to healthy beans. Thus, it is concluded that the PDI, particularly using the Lab* space, offers an efficient and standardized alternative to manual inspection, contributing to greater reliability in the quality control of coffee beans.

Keywords: digital image processing; colorimetric spaces; image segmentation.

INTRODUÇÃO

O Brasil ocupa a posição de maior produtor e exportador de café do mundo, com área cultivada superior a dois milhões de hectares e forte participação das variedades arábica e conilon (Brasil, 2023). Segundo a FAO (2025) fatores como clima, custo de produção, transporte, estoques globais e demanda crescente por café afetam o preço da commodity, evidenciando a natureza multifatorial da determinação de preços agrícolas.

A qualidade do café varia de acordo com sua origem geográfica, refletindo diferenças sensoriais entre países, microrregiões e até áreas de uma mesma fazenda. Essa variação decorre da interação entre genética, clima, solo e relevo, aliada às práticas locais de cultivo, colheita e processamento. Esses fatores, juntos, definem a identidade final da bebida (Borém *et al.*, 2023). O café arábica (*Coffea arabica*) é reconhecido pela superior qualidade sensorial da bebida, enquanto o robusta apresenta maior produtividade e melhor adaptação a condições climáticas adversas, refletindo-se também em diferenças de preço entre as duas espécies (Oliveira, 2021).

A qualidade da bebida depende da integridade dos grãos e da presença de imperfeições, contabilizadas manualmente. Para pequenos produtores, essa limitação é crítica, já que a avaliação precisa ser ágil, objetiva e confiável frente à volatilidade do preço. A classificação manual dos grãos de café, feita por avaliadores certificados, impacta diretamente a qualidade e o valor do produto, mas sofre com subjetividade, experiência individual e condições ambientais como iluminação e fadiga (Lube *et al.*, 2023).

Para assegurar a qualidade dos produtos é essencial na maioria dos produtos agrícolas ter uma inspeção visual. Frequentemente, esse tipo de inspeção é executado de forma manual, o que não só consome tempo e é considerado uma tarefa “monótona”, mas também está sujeito a erros operacionais, acarretando custos e complicando a padronização dos resultados. Soluções automatizadas, rápidas e padronizadas, capazes de melhorar a precisão da classificação, especialmente a visão computacional, podem ajudar a aprimorar o processo, assegurando uma maior confiabilidade nos resultados obtidos (Vieira, 2020).

Diante desse contexto, este trabalho tem como objetivo classificar grãos de café em relação à presença de defeitos utilizando processamento digital de imagens, com o intuito de melhorar a velocidade e uniformidade na análise. O foco está em investigar a utilização dos espaços de cor RGB (Red, Green, Blue) e Lab* (CIELAB - espaço de cor definido pela Comissão Internacional de Iluminação, em que L representa a luminosidade e A e B as coordenadas de cromaticidade) como uma solução eficaz para auxiliar ou complementar a inspeção manual.

FUNDAMENTAÇÃO TEÓRICA

A cafeicultura no Brasil é um setor de grande importância econômica e social. Para a safra brasileira de 2025, a produção estimada total é de 55,7 milhões de sacas beneficiadas. Esse volume representa um aumento de 2,7% (ou 1,5 milhão de sacas) em relação à produção registrada em 2024 (Conab, 2025). A qualidade do produto está intimamente ligada às propriedades físicas e visuais dos grãos, sendo a sua classificação um dos principais fatores utilizados para determinar o valor de mercado (Campos, 2016).

Nesse cenário, a elevação dos preços tem levado parte da população a consumir alternativas mais baratas como cafés de baixa qualidade que são resultado de práticas ilícitas que comprometem a qualidade do produto e podem representar riscos à saúde, incluindo desconforto abdominal, gases e diarreia. A relação entre qualidade dos grãos, características da planta e condições da área geográfica é amplamente investigada, pois esses fatores influenciam diretamente a valorização comercial e a formação do preço das commodities cafeeiras (Carvalho, 2025).

A presença de defeitos tem um impacto considerável na qualidade final do café, interferindo em atributos como aroma, sabor e corpo da bebida (Silva *et al.*, 2005). Pelo impacto na qualidade sensorial, consequentemente impacta na questão econômica dos cafés, cafés estes que possuem classificações de acordo com a quantidade de defeitos presentes. Essa classificação pode ser realizada tanto através da análise sensorial da bebida, conhecida como degustação de xícara, quanto pela contagem de defeitos nos grãos em amostras padronizadas.

Os defeitos nos grãos de café podem ser categorizados como intrínsecos ou extrínsecos, sendo os intrínsecos aqueles que exercem o maior impacto na qualidade da bebida. Entre eles, destacam-se os grãos pretos, ardidos e verdes (Brasil, 2003). Apesar de sua importância, esse processo é frequentemente realizado por inspeção visual manual. Nesse contexto, destacam-se alternativas tecnológicas baseadas em visão computacional.


A visão computacional é um ramo da inteligência artificial voltado à interpretação automatizada de imagens, permitindo que sistemas extraiam padrões visuais de forma precisa e padronizada. Aplicada à classificação de grãos de café, essa tecnologia possibilita avaliar características como cor, forma, textura e defeitos com maior objetividade que o método manual. Sua precisão e rapidez tornam o processo menos sujeito à variabilidade humana e mais adequado para análises em larga escala. Assim, a visão computacional se destaca como ferramenta essencial para garantir qualidade, consistência e eficiência no controle de grãos (Fracarolli *et al.*, 2020).

Este procedimento abrange várias fases, que incluem a aquisição da imagem, o pré-processamento, a segmentação, a extração de características e a classificação. A imagem é capturada por meio de dispositivos apropriados e depois passa por um tratamento voltado à melhoria de sua qualidade, envolvendo ajustes de brilho, contraste e remoção de ruídos. Posteriormente, efetua-se a segmentação, que possibilita a separação dos objetos de interesse, permitindo uma análise individual dos grãos. Com base nisso, são identificadas características pertinentes, como cor, forma e textura, as quais serão empregadas na fase de classificação (Souza, 2025).

Em relação à análise de cores, o espaço RGB (Vermelho, Verde, Azul) é frequentemente utilizado em sistemas digitais e baseia-se na combinação das cores primárias (Figura 1). Neste modelo, cada pixel é representado pela intensidade dos canais de vermelho, verde e azul, facilitando

a identificação de padrões visuais nas imagens (Joaquim, 2019).


Figura 1: Sistema de cores RGB.



Fonte: Joaquim, 2019.

Como uma alternativa, foi desenvolvido o espaço de cor CIELAB, comumente chamando de Lab*, com a finalidade de representar as cores de um modo que se assemelhe mais à percepção visual humana. Neste sistema, a componente L^* está relacionada à luminosidade, enquanto as componentes a^* e b^* refletem as variações cromáticas. De acordo com Joaquim (2019), o modelo CIELAB (Figura 2) é demonstrado em um espaço com três dimensões, que é segmentado em um eixo vertical e dois eixos horizontais. O eixo vertical, denominado L , refere-se à luminosidade ou à escala de tons de cinza da imagem. Por sua vez, os eixos horizontais a e b representam a transição entre as cores vermelha e verde, assim como entre azul e amarelo, respectivamente.

Figura 2: Sistema de cores Lab*.



(a) Espaço de Cores

(b) Eixo de Cores

Fonte: Joaquim, 2019.

Com a extração dessas características, é viável aplicar métodos de classificação automática que se baseiam na similaridade dos dados analisados. Dentre esses métodos, destacam-se os que utilizam distâncias, como o algoritmo dos vizinhos mais próximos, possibilitando classificar os objetos de acordo com a proximidade entre seus descritores e padrões pré-estabelecidos. Dessa maneira, a combinação entre digitalização de imagens e técnicas de classificação representa uma estratégia eficaz para a detecção automatizada de defeitos em grãos de café. O modelo de cor CIELAB é amplamente utilizado no tratamento de cores de frutas e hortaliças (Jorge *et al.*, 2011).

METODOLOGIA

Aquisição das imagens

As imagens utilizadas nesta etapa foram obtidas a partir de *datasets públicos de grãos de café verde disponibilizados em repositório no GitHub (J4CKDEV, 2026) e RoboFlow, para fins de validação da modelagem. O conjunto apresentava imagens de grãos sadios e defeituosos, abrangendo diferentes variações visuais relevantes para a análise. As imagens foram trabalhadas no software GNU Octave, com auxílio do pacote image. Inicialmente, cada arquivo foi importado em formato RGB e convertido para o tipo numérico double, permitindo maior precisão no processamento digital e na extração das informações colorimétricas.*

Processamento das imagens e extração de características

Após a importação, as imagens passaram por uma etapa de processamento para identificação individual dos grãos. Inicialmente, a imagem original foi convertida para escala de cinza, com o objetivo de simplificar a segmentação. Em seguida, realizou-se a binarização automática pelo método de Otsu, separando os grãos do fundo da imagem. Para melhorar a qualidade da segmentação, foram aplicadas operações de pré-processamento, como remoção de ruídos e abertura morfológica, permitindo contornos mais regulares e melhor separação entre os objetos. Posteriormente, os grãos foram rotulados individualmente, possibilitando sua contagem automática e a extração isolada das informações de cada objeto identificado.

Análise de cor no espaço RGB

A caracterização inicial dos grãos foi realizada no espaço de cor RGB (Red, Green, Blue), diretamente a partir da imagem original. Depois de realizar a segmentação dos grãos no processamento das imagens, os valores correspondentes aos canais vermelho (R), verde (G) e azul (B) da imagem original foram extraídos. Para cada grão identificado, calculou-se a média dos valores de intensidade dos pixels em cada canal, resultando em uma cor média que serve como representação. Em imagens digitais que utilizam o sistema RGB, os valores de cada canal oscilam entre [0 e 255],

sendo que valores menores refletem tons mais escuros e valores mais altos denotam uma maior intensidade da cor em questão. A análise em RGB foi importante como etapa inicial por representar a composição básica das cores na imagem digital, possibilitando identificar tendências de coloração associadas às diferentes classes analisadas.

Análise de cor no espaço Lab*

Além da análise em RGB, as imagens foram convertidas para o espaço de cor LAB. Esse sistema foi escolhido por proporcionar melhor separação entre luminosidade e cromaticidade, tornando a avaliação colorimétrica mais sensível. No espaço LAB, cada grão foi descrito pelas coordenadas L^* , a^* e b^* , sendo:

L^ : luminosidade, variando de claro para escuro;*

a^ : variação entre verde e vermelho;*

b^ : variação entre azul e amarelo.*

Para cada objeto segmentado, foram calculados os valores médios dessas três coordenadas. Esses dados foram utilizados como descritores colorimétricos mais robustos para a diferenciação entre os grãos, especialmente em situações em que o espaço RGB apresentava maior sobreposição entre classes.

Classificação dos grãos

A categorização dos grãos foi efetuada com fundamento nos valores médios obtidos nos espectros RGB e Lab, utilizando o algoritmo k-Nearest Neighbors (k-NN) com k igual a 1. Nesse processo, cada grão recebeu uma classificação com base na distância euclidiana entre os seus descritores de cor e os modelos de referência previamente definidos para cada categoria (preto, sadio, ardido, verde). A classe atribuída foi a que apresentou a menor distância, caracterizando um classificador fundamentado no vizinho mais próximo. Foram definidos critérios de separação entre as classes avaliadas, considerando principalmente diferenças de luminosidade e tonalidade. Grãos com menor luminosidade e coloração mais escura foram associados à classe preto, enquanto grãos com tonalidades compatíveis com coloração normal foram classificados como sadios. Já os grãos com características intermediárias ou variações específicas de cor foram agrupados nas classes verde e ardido, de acordo com os limiares estabelecidos durante o desenvolvimento do código.

Para avaliação do desempenho do classificador, foram calculadas três métricas baseadas na matriz de confusão, conforme estabelecido na literatura (Parikh *et al.*, 2008; Baratloo *et al.*, 2015). Sensibilidade mostrado na Equação 1, que mede a proporção de grãos de uma classe que foram

corretamente identificados.

$$\text{Sensibilidade} = \frac{VP}{VP+FN} \quad (1)$$

Sendo:

VP: Número de verdadeiros positivos;

FN: Número de falsos negativos.

Outro parâmetro analisado foi a especificidade, Equação 2, que mede a proporção de grãos de outras classes que foram corretamente rejeitados.

$$\text{Especificidade} = \frac{VN}{VN+FP} \quad (2)$$

Sendo:

VN: Número de verdadeiros negativos;

FP: Número de falsos positivos.

E por fim foi avaliada a acurácia, Equação 3, afim de verificar a proporção de acertos totais considerando todas as classes. A acurácia geral foi obtida pela soma dos verdadeiros positivos de todas as classes dividida pelo total de grãos.

$$\text{Acurácia} = \frac{VP+VN}{\text{Total de grãos}} \quad (3)$$

Sendo:

VP: Número de verdadeiros positivos;

VN: Número de verdadeiros negativos.

Após a classificação, foi gerada uma representação visual da imagem processada, em que cada grão recebeu uma identificação conforme sua classe. Além disso, os dados individuais de cada objeto, incluindo valores médios de cor e classe atribuída, foram registrados para posterior organização e interpretação dos resultados.

RESULTADOS E DISCUSSÃO

ANÁLISE DE COR POR ESPAÇO RGB

Validação do método

Em representações digitais no espaço RGB, cada pixel é definido por três valores numéricos que representam a intensidade das cores vermelho (R), verde (G) e azul (B), variando de 0 a 255.


Nesta escala, 0 representa a total ausência da cor, enquanto 255 indica a intensidade máxima. Ao combinar diferentes níveis de intensidade nos três canais, consegue-se criar milhões de cores únicas, o que torna esse espaço um padrão amplamente aceito em sistemas dedicados ao processamento digital de imagens.

Para categorizar os grãos nesse espaço, o método foi implementado em duas fases. A primeira fase envolveu a seleção de imagens de grãos previamente identificados em cada categoria: sadio, preto, verde e ardido, coletadas de repositórios públicos. O sistema, então, extraiu e registrou as médias dos canais R, G e B para cada categoria, estabelecendo um padrão de referência de cor para cada tipo de defeito. Na segunda fase, o sistema analisou imagens de grãos com categorias desconhecidas, calculando a diferença de cor entre cada grão e os quatro padrões de referência.

Segmentação, contagem e classificação

A utilização do processamento digital de imagens no espaço de cor RGB possibilitou a segmentação, a contagem e a caracterização preliminar dos grãos de café em diferentes arranjos na imagem. O primeiro ensaio foi realizado com os grãos dispostos de forma mais afastada uns dos outros, para o teste de segmentação e contagem de forma graduada. Nesse ensaio foi detectado 195 grãos, o que sugere que, em uma condição mais controlada, a abordagem demonstrou eficácia na individualização dos itens. Nesta situação, a distinção entre os grãos e o fundo ocorreu de maneira satisfatória, facilitando a contagem automática e a extração das médias dos canais de cor. Para facilitar a compreensão das fases do processamento digital das imagens, a Figura 3 apresenta a imagem original, a máscara segmentada final e a numeração automatizada dos grãos identificados com grãos mais separados.

Figura 3: Etapas do processamento digital da imagem para segmentação e contagem de grãos de café no espaço RGB: (a) imagem original, (b) máscara final obtida após segmentação e (c) grãos detectados e numerados automaticamente.




Fonte: Autores, 2026.

No segundo ensaio, em que os grãos foram analisados agrupadamente, mais próximos,

identificaram-se 195 grãos. A máscara binária gerada permitiu separar os objetos e rotulá-los individualmente, proporcionando a obtenção das médias RGB para cada grão. Além da contagem, nesse segundo ensaio foi realizada a classificação dos grãos com defeitos PVA. Para a classificação, inicialmente foram realizados testes individuais de cada grão (preto, verde, ardido e sadio) e medida sua média RGB. Com o número das médias RGB de cada grão, foram armazenadas essas médias padrões para o teste do segundo ensaio (Figura 4) os grãos classificados.

Figura 4. Etapas do processamento digital da imagem para classificação de grãos de café com defeitos analisados no espaço RGB: (a) imagem original, (b) máscara final obtida após segmentação, (c) grãos detectados e numerados automaticamente e (d) imagem com a classificação dos grãos por RGB.



Fonte: Autora, 2026.

A Tabela 1 apresenta os resultados numéricos obtidos na análise em RGB para os diversos experimentos realizados. Nota-se que, em todas as condições analisadas, o canal vermelho mostrou os maiores valores médios, seguido pelo canal verde e, por fim, pelo azul. Este padrão indica uma predominância de tons amarronzados nas amostras de grãos de café examinadas. Além disso, observou-se uma variação no número de grãos identificados entre os experimentos, atribuída a diferenças na disposição dos objetos, na densidade da amostra e nas características específicas de cada imagem.

Tabela 1. Distribuição quantitativa e valores médios das coordenadas colorimétricas dos grãos de café classificados individualmente no espaço RGB.

Classe atribuída	Número reais de grãos	Número de grãos contados	Acurácia (%)	Especificidade (%)	Sensibilidade (%)
Preto	45	33	93,85	100	73,33
Sadio	44	44	100	100	100
Ardido	102	113	94,36	88,17	100 *
Verde	4	5	99,49	99,48	100 *
Total	195	195	96,93	96,91	93,33

Fonte: Autora, 2026. *Para as classes ardido e verde, a sensibilidade foi de 100% porque todos os grãos reais dessas classes foram identificados corretamente, apesar da superestimação nas contagens (11 ardidos e 1 verde adicionais).

Os dados apresentados na Tabela 1 mostram que o espaço RGB demonstrou um desempenho satisfatório na classificação dos grãos de café, com uma acurácia média de 96,93%, apesar de apresentar algumas limitações significativas em determinadas categorias. A classe de grãos sadios se destacou, alcançando 100% em todos os critérios: todos os 44 grãos foram identificados corretamente (sensibilidade = 100%) e nenhum grão de uma classe diferente foi erroneamente classificado como sadio (especificidade = 100%). Vieira (2020) também alcançou 100% de precisão para esta classe utilizando o método RGB, atribuindo esse resultado ao perfil colorimétrico característico bem definido dessa categoria.

As classes ardido e verde apresentaram uma sensibilidade de 100%, o que indica que todos os grãos reais foram detectados. No entanto, uma sensibilidade alta não exclui a possibilidade de erros, pois o sistema identificou 113 grãos ardidos (dos quais 102 eram reais) e 5 verdes (com 4 reais), resultando em uma superestimação de 11 e 1 grão, respectivamente. Esses falsos positivos diminuíram a especificidade da classe ardido para 88,17% e da verde para 99,48%.

A maior limitação foi observada na classe preta: uma sensibilidade de 73,33% significa que, dos 45 grãos pretos reais, apenas 33 foram corretamente identificados, os outros 12 foram classificados em outra categoria. A especificidade de 100% sugere que os erros ocorreram apenas em uma direção, pois os grãos pretos foram confundidos com outras classes, e não o contrário.

A análise geral revela que a confusão ocorreu principalmente entre as classes preto e ardido. É provável que os 12 grãos pretos não registrados tenham sido erroneamente categorizados como ardidos, o que justifica a superestimação de 11 grãos nessa classe. Isso se dá pelo fato de que ambas as classes compartilham uma coloração escura e possuem valores RGB relativamente próximos, uma vez que tanto o defeito preto quanto o ardido resultam de processos fermentativos que escurecem o

grão (Vieira, 2020). Como o RGB combina luminosidade e cromaticidade, ele é mais suscetível a variações na iluminação e à sobreposição entre classes que são visualmente semelhantes (Gonzalez; Woods, 2008). Oyama (2014) também constatou que os grãos ardidos apresentaram um desempenho inferior à média geral (sensibilidade de 83,2% contra 85,62%), um valor superior ao encontrado neste estudo (73,33%), corroborando que essa classe representa um desafio persistente e que a dificuldade de separação pode se intensificar conforme as condições de aquisição de imagem.

A classe verde, que contou com apenas 4 grãos reais, obteve uma especificidade de 99,48% e uma sensibilidade de 100%, resultando em apenas 1 falso positivo. O desempenho é satisfatório, mas a amostra reduzida ($n=4$) impede generalizações. Vieira (2020) aponta que, apesar de o grão verde ser facilmente identificável devido à sua película brilhante, suas características cromáticas podem se aproximar de outras classes dependendo da iluminação, ocasionando erros pontuais como os observados.


Do ponto de vista prático, a confusão entre os grãos pretos e ardidos representa um risco real: a superestimação dos grãos ardidos aumenta a taxa de defeitos do lote, podendo resultar em uma desvalorização indevida do produto. Essa limitação indica que, quando a distinção entre classes de coloração semelhante é essencial, o RGB pode não ser suficiente, sendo recomendada a utilização de espaços de cor que separem luminosidade de cromaticidade, como o Lab*.

ANÁLISE DE COR NO ESPAÇO LAB*

Método e segmentação no espaço Lab*

No espaço Lab*, as características dos grãos são apresentadas pelas coordenadas L^* , a^* e b^* , que correspondem, respectivamente, à luminosidade e às variações de cor nos eixos de verde-vermelho e azul-amarelo. Usando essas informações, foi empregado o método dos vizinhos mais próximos, onde cada grão foi classificado com base na semelhança entre seus valores médios de L^* , a^* e b^* , em relação aos padrões de referência estabelecidos para cada categoria. Os achados mostraram que a coordenada L^* foi crucial para diferenciar grãos mais claros de grãos mais escuros, enquanto as coordenadas a^* e b^* ajudaram a identificar variações tonais entre as categorias avaliadas. Assim, a combinação do espaço LAB com o método dos vizinhos mais próximos revelou ser mais eficaz para capturar sutilezas de cor, especialmente em casos onde o RGB mostrou maior sobreposição nos valores médios. A Figura 5 apresenta as etapas da análise dos grãos de café no espaço LAB, incluindo a imagem original, a máscara segmentada e a classificação automática obtida pelo método dos vizinhos mais próximos. Observou-se que essa abordagem permitiu uma interpretação mais detalhada das diferenças visuais entre os grãos, principalmente por separar a informação de luminosidade das componentes cromáticas.

Figura 5. Etapas da análise dos grãos de café com defeitos no espaço LAB: (a) imagem original, (b) máscara segmentada e (c) classificação automática dos grãos com base nas coordenadas L*, a* e b*.



Fonte: Autora, 2026.

A ilustração mostrada na Figura 5 possibilita a visualização da distribuição das classes atribuídas aos grãos após serem categorizados no espaço LAB. Além disso, a Tabela 2 oferece uma análise quantitativa, incluindo a contagem de grãos em cada categoria, as porcentagens correspondentes na amostra e as médias das coordenadas L*, a* e b* para cada classe. Isso facilita uma interpretação mais clara acerca do comportamento das cores dos grupos identificados.

Tabela 2. Distribuição quantitativa e valores médios das coordenadas colorimétricas dos grãos de café classificados individualmente no espaço LAB.

Classe atribuída	Número reais de grãos	Número de grãos contados	Acurácia (%)	Especificidade (%)	Sensibilidade (%)
Preto	45	45	100	100	100
Sadio	44	44	100	100	100
Ardido	102	104	98,97	97,85	100*
Verde	4	2	98,97	100	50
Total/Média	195	195	99,49	99,46	87,5

Fonte: Autora, 2026. A sensibilidade para sadio e ardido foi de 100% porque todos os grãos reais dessas classes foram identificados, embora tenha havido superestimação nas contagens (2 sadios e 2 ardidos adicionais).

Os dados apresentados na Tabela 2 mostram que o espaço Lab* apresentou desempenho superior ao espaço RGB na classificação dos grãos de café, alcançando uma acurácia média por classe de 99,49%. Esses resultados evidenciam a maneira como o Lab* organiza a informação de cor, pois ao contrário do RGB, que integra luminosidade e cromaticidade, o Lab* distingue a luminosidade (L)

das componentes cromáticas (a: verde-vermelho; b*: azul-amarelo). Essa separação faz com que o método seja menos suscetível a variações de iluminação, promovendo maior precisão na diferenciação de classes que variam em brilho ou tonalidade (Billmeyer e Saltzman, 1981; Gonzalez; Woods, 2008).

Essa vantagem foi especialmente evidente nas classes preto e sadio, com ambas apresentando 100% em todos os critérios. Os grãos pretos, que resultam de uma fermentação avançada que escurece uniformemente o grão (Vieira, 2020), mostram valores de L bastante baixos. Como o Lab isola essa informação, o classificador pode identificá-los sem influência cromática de outras classes. Isso explica o porquê, no espaço RGB, 12 grãos pretos foram incorretamente classificados como ardidos, já que a falta de separação entre luminosidade e cor aproximava os vetores dessas classes. No Lab*, a diferença de luminosidade entre a classe preto e ardido estabelece fronteiras de decisão mais evidentes.

Os grãos sadios também atingiram 100% em todos os parâmetros. Ao contrário do RGB, que acumulou erros indiretos (confundindo pretos como ardidos), o Lab* não apresentou falsos positivos ou negativos para essa classe, estabelecendo limites robustos mesmo diante da similaridade com grãos verdes identificada por Vieira (2020). Já a classe ardido, por sua vez, mostrou uma sensibilidade de 100% (todos os 102 grãos reais foram detectados), mas contabilizou 104 grãos, o que gerou 2 falsos positivos, reduzindo a especificidade para 97,85% e a acurácia para 98,97%. Essas falhas provavelmente se referem a grãos de outra classe (provavelmente sadios em começo de degradação) cujas características se assemelharam aos ardidos. Essa limitação de acordo com o que a literatura aponta, que grãos ardidos apresentem coloração marrom irregular que muda conforme o estágio de deterioração (Vieira, 2020). Oyama (2014) também observou que a classe ardido teve o pior desempenho em seu estudo (recall de 83,2% contra uma média de 85,62%), e a acurácia de 98,97% neste estudo representa um avanço significativo.

A classe verde revelou um resultado mais crítico, já que somente 2 dos 4 grãos reais foram identificados, resultando em uma sensibilidade de 50% e uma acurácia de 98,97%. Embora essa acurácia pareça elevada, ela é distorcida pela grande quantidade de verdadeiros negativos (191 grãos de outras categorias que foram corretamente identificados como não verdes), o que oculta a real eficácia do método para essa classe. A sensibilidade de 50% retrata de maneira mais realista o desempenho do classificador, que metade dos grãos verdes foi considerada ausente (falsos negativos). Esse padrão está alinhado com o estudo de Vieira (2020), que indica que os grãos verdes têm valores de Lab* próximos aos dos grãos sadios, especialmente nos canais a* e b*, o que reduz o contraste entre as classes. A especificidade de 100% indica que os erros ocorreram em uma única direção (grãos verdes foram perdidos, mas não adicionados). A amostra reduzida (n=4) limita generalizações mais

abrangentes, mas o padrão sugere que distinguir entre verde e sadio é o maior desafio colorimétrico deste método. Para abordar isso, Oyama (2014) sugere integrar a análise colorimétrica com descritores morfológicos (textura e formato), que podem captar características que a cor sozinha não revela.

Por uma análise comparativa dos métodos, destaca a vantagem do Lab* em relação ao RGB. No RGB, a principal fonte de erro foi a confusão entre preto e ardido, que resultou em uma sensibilidade de apenas 73,33% para a classe preta e uma superestimação de 11 grãos ardidos, um erro causado pela interação entre luminosidade e cromaticidade (Gonzalez; Woods, 2008). Com o Lab, esse desafio foi resolvido: a classe preta obteve 100% em todos os critérios, e a precisão geral aumentou de 96,93% (RGB) para 99,49% (Lab). A única limitação persistente no Lab* ocorreu na classe verde, onde o RGB apresentou desempenho superior (100% de sensibilidade), o que indica que as duas metodologias possuem perfis de erro que se complementam. Em comparação com a inspeção manual, ambos os métodos automatizados superaram problemas tradicionais, como variações entre avaliadores, cansaço visual e falta de padronização entre lotes, questões que prejudicam a confiabilidade da classificação em um contexto industrial (Oyama, 2014).

CONCLUSÕES

Os resultados obtidos demonstram que, apesar de os canais RGB serem eficazes para diferenciar grãos em geral, especialmente os de maior contraste visual, há limitações na separação de classes com características semelhantes. Isso evidencia a necessidade de métodos adicionais para aumentar a precisão da classificação em sistemas de controle de qualidade do café.

Nesse cenário, o uso do espaço de cor Lab* revelou-se mais apropriado, pois possibilita a distinção entre luminosidade (L^*) e cromaticidade (a^* e b^*), oferecendo uma representação mais estável e coerente com a percepção visual. Essa particularidade ajuda a diferenciar grãos que apresentam variações de cor sutis, como os de tonalidades esverdeadas, amareladas e escuras.

O método dos vizinhos mais próximos obteve bons resultados na classificação, especialmente quando combinado com o espaço Lab*, proporcionando maior precisão em relação ao RGB. Entretanto, ainda foram notadas pequenas discrepâncias, como a subestimação de grãos verdes, que podem estar relacionada à sobreposição de cores entre as classes e ao impacto das condições de iluminação.

O sistema PDI baseado no espaço Lab* alcançou acurácia de 99,49%, superando o RGB (96,93%), e demonstrou desempenho de 100% nas classes preto e sadio, eliminando a principal fonte de erro do RGB, a confusão entre grãos pretos e ardidos. O principal desafio remanescente é a classe verde, com sensibilidade de 50% no Lab*, decorrente da sobreposição cromática com grãos sadios,

limitação que pode ser contornada pela integração de descritores morfológicos complementares em estudos futuros. Os resultados obtidos evidenciam o potencial da visão computacional como ferramenta eficiente, objetiva e padronizada para o controle de qualidade do café, com aplicabilidade direta em ambientes industriais e de classificação para pequenos produtores.

REFERÊNCIAS

BARATLOO, A. *et al.* **Part 1: Simple Definition and Calculation of Accuracy, Sensitivity and Specificity.** *Emergency*, v. 3, n. 2, p. 48-49, 2015. Disponível em: <https://pmc.ncbi.nlm.nih.gov/articles/PMC4614595/>. Acesso em: 20 fev. 2026.

BILLMEYER, F. W.; SALTZMAN, M. **Principles of color technology**. 2. ed. New York: Wiley, 1981.

BOREM, F. M. *et al.* Fatores que afetam a produção de café especial. In: BOREM, F. M. (org.). **Tecnologia pós-colheita e qualidade de cafés especiais**. Lavras: Editora UFLA, 2023. cap. 7, p. 262–327.

BRASIL. **Instrução Normativa nº 8, de 11 de junho de 2003**. Regulamento Técnico de Identidade e Qualidade para Classificação do Café Beneficiado Grão Cru. Brasília: MAPA, 2003.

BRASIL. **Brasil é o maior produtor mundial e o segundo maior consumidor de café**. Brasília, 14 abr. 2023. Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/noticias/2023/brasil-e-o-maior-produtor-mundial-e-o-segundo-maior-consumidor-de-cafe>. Acesso em: 30 nov. 2025.

CAMPOS, R. C. **Propriedades físicas dos grãos de café moca durante o processo de torra**. 2016. 74 f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Viçosa, Viçosa, 2016.

CARVALHO, P. Café fake: bebida faz mal para saúde, mas como reconhecer? *CNN Brasil*, 25 fev. 2025. Disponível em: <https://www.cnnbrasil.com.br/saude/cafe-fake-bebidafaz-mal-para-saude-mas-como-reconhecer/>. Acesso em: 28 out. 2025.

COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). **Acompanhamento da safra brasileira de café: safra 2025**. Brasília: Conab, 2025. Disponível em: <https://www.conab.gov.br>. Acesso em: 10 out. 2025.

FOOD AND AGRICULTURE ORGANIZATION (FAO). **Adverse climatic conditions drive coffee prices to highest level in years**. Rome, 14 mar. 2025. Disponível em: <https://www.fao.org/newsroom/detail/adverse-climatic-conditions-drive-coffee-prices-to-highest-level-in-years/en>. Acesso em: 30 nov. 2025.

FRACAROLLI, J. A. *et al.* Visão computacional aplicada a alimentos e produtos agrícolas. *Revista Ciência Agronômica*, v. 51, p. e20207749, 2020.

GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. 3. ed. Upper Saddle River: Pearson Prentice Hall, 2008.

J4CKDEV. **Green Coffee Beans Dataset**. GitHub. Disponível em: <https://github.com/J4ckDev/GreenCoffeeBeansDataset>. Acesso em: 05 jan. 2026.

JOAQUIM, B. M. **Monitoramento da evolução da doença pinta preta em tomates através do processamento de imagens.** 2019. Trabalho de Conclusão de Curso.

JORGE, L. A. C. *et al.* Uso de sistemas de imagem para classificação de frutas e hortaliças. In: FERREIRA, M. D. (Ed.) **Tecnologias pós-colheita em frutas e hortaliças.** São Carlos, SP: Embrapa Instrumentação, 2011. cap. 7, p. 127–153.

LUBE, I. G. *et al.* **Classificação de grãos de café usando visão computacional.** 2023. Dissertação – Instituto Federal do Espírito Santo. Disponível em: <https://repositorio.ifes.edu.br/handle/123456789/4161>. Acesso em: 30 nov. 2025.

OLIVEIRA, E. M. **Sistema de visão computacional para avaliação física de cafés (*Coffea arabica* L.) de diferentes colorações.** 2015. Dissertação (Mestrado em Ciência dos Alimentos) – Universidade Federal de Lavras, Lavras, 2015.

OLIVEIRA, M. B. J. **Cultivo e comercialização dos cafés arábica e robusta no Brasil.** 2021. 34 f. Trabalho de Conclusão de Curso (Tecnologia em Agronegócio) – Centro Paula Souza, São Paulo, 2021. Disponível em: <https://ric.cps.sp.gov.br/bitstream/123456789/23097/1/MAYANE%20BIANKA%20JUSTINO%20DE%20OLIVEIRA.pdf>. Acesso em: 30 nov. 2025.

OYAMA, P. I. C. **Método para classificação de café em grãos por imagens digitais pelo uso de atributos selecionados de morfologia, cor e textura.** 2014. Dissertação (Mestrado em Engenharia Elétrica) – Universidade de São Paulo, São Carlos, 2014.

PARIKH, R. *et al.*, Understanding and using sensitivity, specificity and predictive values. **Indian Journal of Ophthalmology**, v. 56, n. 1, p. 45-50, 2008.

SILVA, M. M.; FERRAZ, V.; FRANÇA, A. S.; OLIVEIRA, L. S. **Análise de compostos voláteis de grãos crus de café sadios e defeituosos (preto, verde e ardido) por cromatografia gasosa acoplada à espectrometria de massas.** In: SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL, 4., 2005, Londrina. Anais... Brasília: Embrapa Café, 2005.

VIEIRA, J. S. **Processamento digital de imagens para identificação de defeitos PVA em grãos de café arábica.** 2020. Trabalho de Conclusão de Curso (Graduação em Engenharia de Alimentos) – Universidade Federal Rural de Pernambuco, Garanhuns, 2020.