

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE MINAS
GERAIS – CAMPUS BAMBUÍ
BACHARELADO EM ENGENHARIA DE COMPUTAÇÃO

Diego de Lima Pereira

**ANÁLISE DE TÉCNICAS DE SEGMENTAÇÃO PARA
SELEÇÃO DE GRÃOS DE CAFÉ TORRADOS EM IMAGENS**

DIEGO DE LIMA PEREIRA

**ANÁLISE DE TÉCNICAS DE SEGMENTAÇÃO PARA
SELEÇÃO DE GRÃOS DE CAFÉ TORRADOS EM IMAGENS**

BambuÍ - MG

2022

Diego de Lima Pereira

**ANÁLISE DE TÉCNICAS DE SEGMENTAÇÃO PARA
SELEÇÃO DE GRÃOS DE CAFÉ TORRADOS EM IMAGENS**

Aprovado em 22 de Julho de 2022 pela banca examinadora:

Prof. Dr. Marcos Roberto Ribeiro – IFMG – Campus Bambuí – (Orientador)

Prof. Dr. Ciniro Aparecido Leite Nametala – IFMG – Campus Bambuí

Prof. Me. Felipe Lopes de Melo Faria – IFMG – Campus Bambuí

RESUMO

O Brasil é o maior produtor de café do mundo e é o segundo maior consumidor. Desde a chegada do café no Brasil, ele vem sendo produto destaque na economia nacional. Cerca de 71% dessa produção é de café torrado e moído. O processo de torrefação é um processo de extrema importância, trazendo ao grão torrado aroma e sabor característico. Existem algumas maneiras de determinar o grau de torra do café, porém os equipamentos especializados possuem alto custo e a utilização dos discos Agtron/SCAA envolve um processo manual e subjetivo, onde é necessário comparar a cor dos grãos e escolher a mais próxima ao disco. Já existem trabalhos de pesquisas que tentam criar opções de baixo custo usando imagens para fazer a detecção do grau de torra. Entretanto, nesses trabalhos, para se atingir uma boa precisão, é necessário selecionar manualmente a região da imagem que contém os grãos de café. Esse processo manual é trabalhoso e impede uma automatização mais completa do processo de detecção de torra. Assim, com o intuito de criar um processo de detecção de grau de torra mais automatizado, o presente projeto analisa técnicas de segmentação avaliando tanto qualitativamente quanto quantitativamente os resultados obtidos.

Palavras-chave: Segmentação de Imagens. Processamento Digital de Imagens. Café

ABSTRACT

Brazil is the largest coffee producer in the world and the second-largest consumer. Since the arrival of coffee in Brazil, it has been a prominent product in the national economy. Approximately 71% of this production is roasted and ground coffee. The roasting process is of utmost importance, as it gives the roasted beans their characteristic aroma and flavor. There are several ways to determine the degree of coffee roast, but specialized equipment is expensive, and the use of Agtron/SCAA discs involves a manual and subjective process of comparing the color of the beans and selecting the closest match. There have been research efforts to create low-cost options using images to detect the degree of roast. However, in these studies, achieving good accuracy requires manually selecting the region of the image that contains the coffee beans. This manual process is laborious and hinders a more complete automation of the roast detection process. Therefore, with the aim of creating a more automated degree of roast detection process, this project analyzes segmentation techniques, evaluating the results both qualitatively and quantitatively.

Keywords: Image Segmentation. Digital Image Processing. Coffee.

LISTA DE FIGURAS

Figura 1 – Passos fundamentais em processamento de imagens digitais	12
Figura 2 – Critérios Usados na Segmentação de Imagens	13
Figura 3 – Método para detecção de bordas	15
Figura 4 – Limiarização	18
Figura 5 – Segmentação através do espectro HSV	18
Figura 6 – Método de segmentação para aplicações de classificação	21
Figura 7 – Implementação do método de segmentação no servidor	21
Figura 8 – Aplicação da técnica de detecção pontos e linhas	24
Figura 9 – Aplicação da técnica de detecção de bordas	24
Figura 10 – Aplicação da técnica de limiarização em imagem com grau de torra 25	25
Figura 11 – Aplicação da técnica de limiarização em imagem com grau de torra 75	25
Figura 12 – Diferença de parâmetro para a segmentação HSV	25
Figura 13 – Aplicação da técnica de segmentação no espectro HSV	26
Figura 14 – Aplicação da técnica K-Means em imagem com grau de torra 25	26
Figura 15 – Aplicação da técnica K-Means em imagem com grau de torra 75	27
Figura 16 – Aplicação da técnica de detecção de bacias	27
Figura 17 – Aplicação da técnica piramidal em imagem com grau de torra 25	28
Figura 18 – Aplicação da técnica piramidal em imagem com grau de torra 75	28
Figura 19 – Aplicação da técnica de crescimento de regiões	29
Figura 20 – Performance do algoritmo utilizando a técnica de limiarização	30
Figura 21 – Performance do algoritmo utilizando a técnica K-means	31
Figura 22 – Performance do algoritmo utilizando a técnica Detecção de Bacias	31
Figura 23 – Performance do algoritmo utilizando a técnica Piramidal	32
Figura 24 – Comparativo de precisão entre as técnicas	34

SUMÁRIO

1	INTRODUÇÃO	7
1.1	Objetivo geral	7
1.2	Objetivos específicos	8
1.3	Justificativa	8
1.4	Resultados esperados	8
1.5	Organização do trabalho	8
2	REFERENCIAL TEÓRICO	10
2.1	Cafeicultura e Torrefação de café	10
2.2	Processamento Digital de Imagens e Visão Computacional	11
2.3	Segmentação de Imagens	13
2.4	Estado-da-arte	17
3	METODOLOGIA	20
3.1	Classificação da pesquisa	20
3.2	Solução	20
3.3	Materiais e Tecnologias	21
3.4	Método e procedimentos	22
4	DESENVOLVIMENTO	23
4.1	Análise Qualitativa	23
4.1.1	<i>Detecção de descontinuidades</i>	23
4.1.2	<i>Segmentação no Espaço de Atributos</i>	24
4.1.3	<i>Detecção de Similaridade</i>	26
4.2	Análise Quantitativa	29
4.2.1	<i>Limiarização</i>	29
4.2.2	<i>K-Means</i>	30
4.2.3	<i>Detecção de Bacias</i>	31
4.2.4	<i>Crescimento de Regiões</i>	32
4.2.5	<i>Piramidal</i>	32
4.2.6	<i>Comparativo das técnicas</i>	33
5	CONSIDERAÇÕES FINAIS	35
5.1	Trabalhos futuros	35
	REFERÊNCIAS	36
	APÊNDICE A – HISTÓRICO DO QUADRO <i>KANBAN</i>	40

1 INTRODUÇÃO

O ramo da cafeicultura é um dos mais importantes para economia do Brasil, sendo que o café foi considerado o produto-chave para o desenvolvimento da economia brasileira (BIANCHI, 2012). De acordo com a Associação Brasileira da Indústria de Café (ABIC), o Brasil, além de ser o maior produtor de café do mundo, está em segundo lugar como consumidor (ABIC, 2021b). Este estudo de 2021 também aponta que cerca de 82% do setor cafeicultor é composto por micro e pequenas empresas e 70% desse número opera com administração exclusivamente familiar. Além disso, 81,4% do faturamento dessas empresas provém do café torrado e moído.

Segundo Eugênio *et al.* (2011), o processo de torrefação do café é de extrema importância, pois através deste processo os grãos crus de café são transformados em grãos torrados com sabor e aroma característicos. Além do desenvolvimento de sabor e aroma, a torrefação faz com que os grãos de café fiquem com uma cor mais escura e uma textura seca e quebradiça. Não apenas a qualidade do grão cru do café irá determinar sua qualidade, mas também o processo de torrefação (MELO, 2004).

Uma das maneiras de determinar o grau de torra do café é por meio da cor como a utilização da escala Agtron. Tal escala foi definida pela a *Specialty Coffee Association of America* (SCAA) e a empresa norte-americana Agtron. No entanto, para realizar essa verificação da torra são necessários alguns equipamentos especializados ou os discos Agtron/SCAA *Roast Classification Color Disk*. Os equipamentos especializados possuem alto custo e a utilização dos discos envolve um processo manual e subjetivo, onde é necessário comparar a cor dos grãos e escolher aquela mais próxima do disco (MELO, 2004).

Uma alternativa de baixo custo é a utilização de técnicas de Inteligência Artificial para definir o grau de torra com base em imagens. O projeto desenvolvido por Rodrigues (2022), foi elaborado pensando nisso. O projeto se trata de um aplicativo, capaz de classificar o grau de torra do café através de imagens, porém tanto no aplicativo quando na base de dados usada para treinamento de um modelo de classificação, a região de interesse das imagens contendo os grãos de café foram cortadas manualmente. Uma alternativa interessante é utilizar métodos de Processamento Digital de Imagens (PDI) e Visão Computacional para selecionar a região com os grãos de café das fotos de forma automática. Com isso, haveriam melhoras no uso do aplicativo e, possivelmente, na precisão da classificação do grau de torra.

1.1 Objetivo geral

O principal objetivo do presente trabalho é analisar e desenvolver técnicas de segmentação para seleção da região de grãos de café em imagens com grãos de café torrado.

1.2 Objetivos específicos

Para atingir o objetivo principal, se fazem necessários os seguintes objetivos específicos:

- preparar uma base de dados de fotos de grãos de café torrados para aplicação de técnicas de segmentação;
- analisar e selecionar as técnicas de segmentação mais adequadas para as imagens de grãos de café torrado;
- avaliar e aprimorar as técnicas selecionadas para integração com métodos de detecção de grau de torra existentes.

1.3 Justificativa

O processo de torra dos grãos de café é de extrema importância, pois assim é definida a qualidade final do produto. Atualmente a escala Agrtron garante tal análise, porém os equipamentos são de custos extremamente elevados. Já existem trabalhos de pesquisas que tentam criar opções de baixo custo usando imagens para fazer a detecção do grau de torra. Entretanto, nesses trabalhos, para se atingir uma boa precisão, é necessário selecionar manualmente a região da imagem que contém os grãos de café. Esse processo manual é trabalhoso e impede uma automatização mais completa do processo de detecção de torra. Assim, com o intuito de criar um processo de detecção de grau de torra mais automatizado, o presente projeto pretende avaliar e implementar métodos de segmentação para a detecção de grãos de café de imagens. Tal método poderá ser combinado com as técnicas de obtenção do grau de torra por imagens já existentes para a construção de ferramentas automatizadas.

1.4 Resultados esperados

Com este trabalho almeja-se avaliar e selecionar as melhores técnicas de segmentação para serem implementadas em um algoritmo de grau de torra. Dessa maneira, melhorando a eficiência na seleção dos grãos de café, e também melhorando a precisão do mesmo.

1.5 Organização do trabalho

No Capítulo 2, será apresentado o referencial teórico utilizado como base para a pesquisa. Serão discutidos os principais conceitos, teorias e estudos relacionados a Cafeicultura, Torrefação de café, Processamento Digital de Imagens, Visão Computacional, Segmentação de Imagens e também o Estado da arte.

No Capítulo 3, será detalhada a metodologia adotada para a realização da pesquisa. Serão apresentados a classificação da pesquisa, a solução proposta, os materiais e tecnologias utilizados, bem como os métodos e procedimentos empregados.

No Capítulo 4, será apresentado o desenvolvimento do trabalho. Serão discutidos as análises realizadas e os resultados obtidos.

No Capítulo 5, serão apresentadas as considerações finais do trabalho. Também serão apresentadas recomendações para pesquisas futuras.

2 REFERENCIAL TEÓRICO

Este capítulo descreve os fundamentos teóricos relacionados com presente trabalho. A Seção 2.1 fala da torrefação do café e sua importância. Em seguida, a Seção 2.2 apresenta conceitos sobre Processamento Digital de Imagens e Visão Computacional. A seção 2.3 apresenta uma breve introdução a segmentação e também apresenta as principais técnicas de segmentação. Por fim, a Seção 2.4 apresenta estudos que estão ligados com o tema do presente trabalho e que, de alguma forma, puderam contribuir para seu desenvolvimento.

2.1 Cafeicultura e Torrefação de café

A cafeicultura no Brasil é um dos produtos-chave para economia do país (BIANCHI, 2012). O cultivo do café em escala comercial no Brasil iniciou-se no ano de 1727, sem muito sucesso devido a sua baixa produtividade. Porém, no ano de 1852, com a chegada do *Bourbon* Vermelho a cafeicultura nacional ganhou maior notoriedade e produtividade (ALVES, 2019). Em 2021, o consumo de café do Brasil chegou a 21,5 milhões de sacas, sendo que, e o grão é destacado como um alimento importante para os brasileiros e também para as indústrias nacionais (ABIC, 2021a).

A agregação de valor ao café pode ser feita com a torrefação do grão para ser vendido ao consumidor final. A etapa de torrefação do café é de suma importância para sua qualidade, pois é através desta etapa que os grãos crus de café são transformados em grãos torrados contendo sabor e aroma característicos (EUGÊNIO *et al.* 2011).

O grau de torra pode ser verificado ou calculado por diversos métodos, sendo o mais popular, a comparação visual dos grãos. Entretanto, este método tem sua precisão comprometida, sobretudo pela subjetividade. Outro método é a utilização de equipamentos especializados para a medição do grau de torra de café, como os da marca Agtron.

Os equipamentos eletrônicos da Agtron utilizam um feixe de luz infravermelho que mede a reflectância dos grãos e, em seguida, apresenta um valor numérico. A verificação também pode ser realizada através dos discos Agtron, que são acessórios com a coloração do café impressa, onde cada tom de cor tem uma numeração pré estabelecida (MELO, 2004; WANG; LIM, 2015). A utilização dos discos envolve um processo manual, no qual é necessário comparar a cor dos grãos e escolher aquela mais próxima do disco, surgindo novamente o problema da subjetividade. Isso mostra a importância da criação de métodos precisos e de baixo custo para os produtores brasileiros, principalmente, aqueles de pequeno porte.

2.2 Processamento Digital de Imagens e Visão Computacional

O processamento digital de imagens é uma um campo da ciência que tem sido cada vez mais utilizada em diversos segmentos. Segundo Almeida, Fernandes e Pedrino (2019) o processamento digital de imagens é uma área de pesquisa abrangente e de grande importância para diversas aplicações, como sistemas de segurança, tecnologias médicas e sistemas de satélites. Algumas aplicações exigem um nível mais avançado de processamento, o que requer mais poder computacional. Este procedimento permite a separação das imagens em diversos elementos, o que possibilita analisá-las e compreendê-las de forma mais clara.

Além disso, este tipo de processamento é essencial para a realização de diversas tarefas, como a segmentação de imagens (GONZALEZ; WOODS; EDDINS, 2003; ACHARYA; RAY, 2005).

Do ponto de vista matemático, uma imagem digital pode ser representada por uma função bidimensional, $f(x, y)$, em que x e y são coordenadas espaciais, e a amplitude de f em qualquer coordenada (x, y) é chamada de intensidade ou nível de cinza da imagem neste ponto. Quando x, y e os valores de intensidade de f são quantias finitas e discretas, a imagem é chamada de imagem digital. Assim, a imagem digital é composta por um número finito de elementos, cada um com um valor e localização específico (GONZALEZ; WOODS; EDDINS, 2003; ACHARYA; RAY, 2005).

A Visão Computacional é uma área que envolve a Inteligência Artificial e o Processamento Digital de Imagens, cuja meta é a utilização de computadores para emular a visão humana, incluindo o aprendizado, capacidade de fazer inferências e agir de acordo com as informações visuais (GONZALEZ; WOODS; EDDINS, 2003).

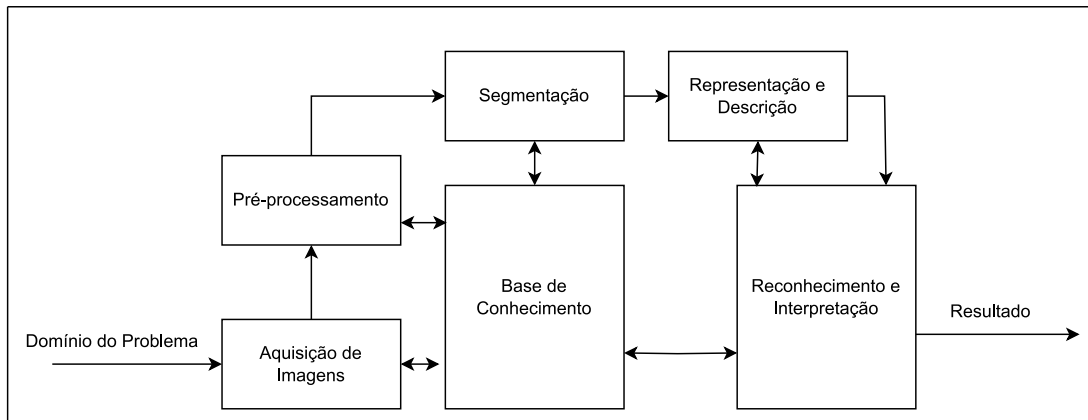
Segundo Gonzalez, Woods e Eddins (2003), a Visão Computacional é dividida em processos de níveis baixo, médio e alto. Os processos de nível baixo são caracterizados pelo fato da entrada e da saída serem imagens. Os processos de nível médio são caracterizados por suas entradas serem imagens e suas saídas serem partes dessas imagens, podendo ser bordas, contornos ou identidade de objetos individuais. O processo de nível alto é caracterizado por dar sentido a um conjunto de objetos reconhecidos, tentando emular a visão humana.

Um sistema de visão computacional envolve as etapas de aquisição de imagens, pré-processamento, segmentação, representação e descrição e reconhecimento (GONZALEZ; WOODS; EDDINS, 2003; SCHWARTZ; PEDRINI, 2003), como ilustrado na Figura 1

A detecção do grau de torra é um processo importante na indústria de café, que envolve a avaliação visual dos grãos para determinar se foram torrados no ponto certo. No entanto, este processo pode ser sujeito a erros humanos e variações devido à subjetividade da avaliação visual. Nesse sentido, a Visão Computacional possui técnicas valiosas para a automatização desse processo. Por este motivo o aplicativo de detecção de torra foi desenvolvido, assim diminuindo a subjetividade desta avaliação visual através das técnicas

de visão computacional.

Figura 1 – Passos fundamentais em processamento de imagens digitais



Fonte: (GONZALEZ; WOODS; EDDINS, 2003)

A Aquisição de Imagens representa como a imagem foi adquirida, seja por meio de uma câmera ou por meio de um *scanner*, trabalhando *on-line* ou *off-line* (GONZALEZ; WOODS; EDDINS, 2003). As imagens utilizadas no presente trabalho serão adquiridas de maneira *off-line*, pois já foram tiradas por uma câmera. O objetivo do Pré-processamento é melhorar a qualidade da imagem para, assim, aumentar a taxa de sucesso nas próximas etapas do processamento (GONZALEZ; WOODS; EDDINS, 2003).

A segmentação permite realizar a separação de fragmentos de interesse para uma análise. No presente trabalho, o objetivo é segmentar as imagens contendo os grãos de café torrado para posteriormente serem classificados por outras aplicações (GONZALEZ; WOODS; EDDINS, 2003).

A Representação está associada ao resultado da segmentação, a forma como é desejado representar os objetos que está sendo analisado. A descrição é a seleção de características ou atributos que será o resultado em alguma informação quantitativa de interesse (GONZALEZ; WOODS; EDDINS, 2003; ACHARYA; RAY, 2005).

O Reconhecimento e interpretação é o processo que atribui rótulo a um objeto, com base em informações fornecidas pelo descritor. A interpretação também envolve atribuir significado a um conjunto de objetos identificados (GONZALEZ; WOODS; EDDINS, 2003). A Base de conhecimento contém conhecimento adquirido e armazenado sobre o problema (GONZALEZ; WOODS; EDDINS, 2003).

O foco do presente trabalho é aplicar as técnicas de segmentação para separar os grãos de café de uma imagem. Assim, durante o desenvolvimento serão testadas várias técnicas para selecionar aquelas que apresentam melhor resultado na seleção dos grãos. Com os resultados será possível realizar testes utilizando o aplicativo em desenvolvimento pelo (RODRIGUES, 2022) que utiliza a visão computacional de alto nível para realizar as análises dos grãos de café.

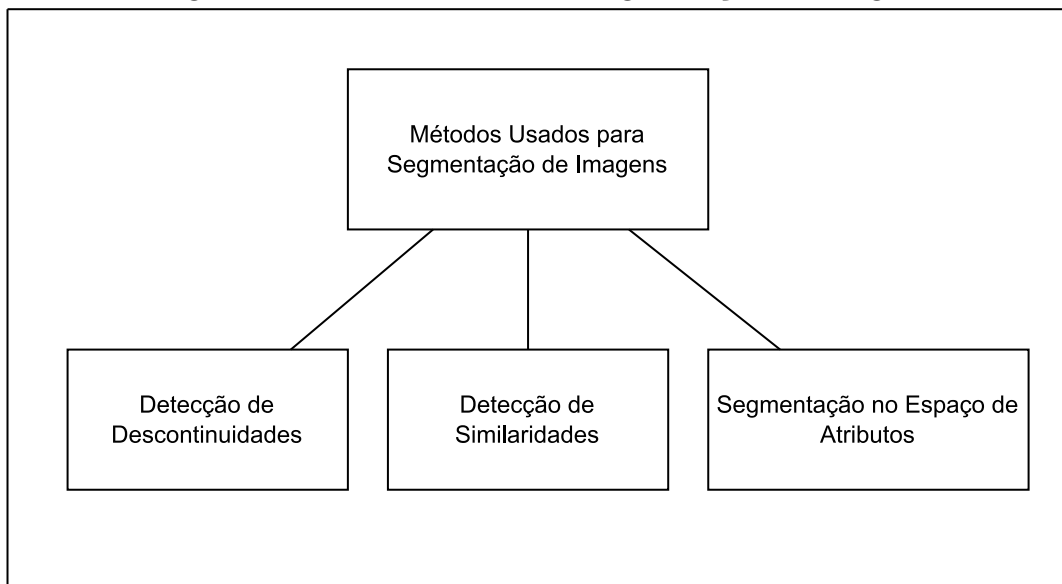
2.3 Segmentação de Imagens

A segmentação de imagens tem como objetivos decompor a imagem em partes, para posterior análise, e realizar uma mudança de representação (SHAPIRO; STOCKMAN *et al.* 2001). O resultado esperado de um processo de segmentação é um número finito de regiões homogêneas, que distinguem as diferentes regiões contidas na imagem original. Assim, a imagem é formada por um conjunto dessas regiões, conectadas por suas bordas, sem sobreposição, de forma que cada pixel da imagem pertence a uma determinada região (ACHARYA; RAY, 2005).

O processo de segmentação consiste em dividir uma imagem em seus componentes ou objetos. Um processo de segmentação bem-sucedido aumenta as chances de resolver com sucesso um problema que requer a identificação de objetos individualmente (GONZALEZ; WOODS; EDDINS, 2003).

Também é possível realizar segmentação utilizando aprendizado de máquina, que é uma área da Inteligência Artificial que trabalha com algoritmos que podem ser melhorados através de treinamentos. A ideia é que esses algoritmos possam aprender com a experiência passada, identificando padrões, tomando decisões sem mediação humana (FACELI *et al.* 2011).

Figura 2 – Critérios Usados na Segmentação de Imagens



Fonte: Adaptado de Saldanha e FREITAS (2009)

Conforme observado na Figura 2, a segmentação de imagens pode ser realizada por meio de diversos critérios, tais como descontinuidade, similaridade e espaço de atributos. O propósito de cada uma dessas abordagens é agrupar os *pixels* de uma imagem em regiões que compartilhem características similares.

A segmentação baseada em descontinuidade é uma técnica que utiliza diferenças abruptas de intensidade, cor ou textura na imagem para dividir a imagem em regiões. Por

exemplo, um objeto que possui uma cor ou textura muito diferente do fundo pode ser facilmente segmentado utilizando essa técnica.

Já a segmentação baseada em similaridade utiliza a similaridade de características entre *pixels* para agrupá-los em regiões. Por exemplo, um grupo de *pixels* que possuem uma cor ou textura similar podem ser agrupados em uma mesma região.

Por fim, a segmentação baseada no espaço de atributos leva em consideração várias características simultaneamente, como cor, textura e forma, para agrupar *pixels* em regiões. Essa técnica utiliza modelos matemáticos que representam as características dos objetos presentes na imagem para segmentá-la em regiões que se ajustam aos modelos.

As descontinuidades encontradas em uma imagem podem ser pontos, linhas ou limites de um objeto. Essas formas se destacam na imagem, seja por possuírem tons de cinza distintos (no caso de pontos e linhas) ou por evidenciarem mudanças bruscas de tons de cinza entre regiões (no caso de bordas e linhas). Algoritmos desenvolvidos para encontrar essas descontinuidades costumam usar convolução, implicando no uso de máscaras (SALDANHA; FREITAS, 2009).

Métodos de detecção de descontinuidade, especialmente detecção de linhas e bordas, geralmente apresentam falhas na detecção. Portanto, esses métodos devem ser seguidos de processamentos visando resolver essas falhas (GONZALEZ; WOODS; EDDINS, 2003).

A lógica por trás dos algoritmos de detecção de pontos e linhas é que essas formas podem ter uma cor cinza muito diferente em comparação com seus vizinhos. Portanto, a detecção pode ser realizada por aplicação de uma máscara que forneça uma resposta R e um adequado limiar positivo T (SALDANHA; FREITAS, 2009). Ao aplicar a máscara, os pontos que retornarem valores acima do limiar estabelecido são detectados, ou seja, $|R| > T$.

A abordagem mais comum para detecção de descontinuidades é a detecção de bordas (GONZALES; WOODS, 1987). Tal detecção visa encontrar e aprimorar os pontos da borda, o que aumenta o contraste entre a borda e o fundo. O processo verifica a variação dos valores de luminosidade de uma imagem (GONZALES; WOODS, 1987; SALDANHA; FREITAS, 2009).

De acordo com Gonzales e Woods (1987) e Saldanha e FREITAS (2009), a técnica de crescimento por regiões é amplamente utilizada na área de processamento de imagens e visa agrupar *pixels* ou sub-regiões em regiões maiores. Esse processo de agrupamento pode ser feito de forma manual, utilizando conhecimento prévio sobre a imagem em questão, ou de forma automática, com o uso de algoritmos específicos para a tarefa.

A escolha dos *pixels* ou sub-regiões a serem agrupados depende da aplicação em questão e dos objetivos do processo de segmentação de imagem. É importante lembrar que o sucesso do processo de crescimento por regiões depende da conectividade entre os

Figura 3 – Método para detecção de bordas



Fonte: (GONZALEZ; WOODS; EDDINS, 2003)

pixels ou sub-regiões, além do conhecimento prévio do problema em questão.

Uma das vantagens da técnica de crescimento por regiões é a sua flexibilidade em relação aos diferentes tipos de imagens e problemas de segmentação. Essa técnica pode ser utilizada em imagens de diferentes resoluções e formatos, bem como em diferentes aplicações, desde a detecção de bordas até a segmentação de objetos em imagens médicas.

Além disso, a técnica de crescimento por regiões pode ser combinada com outras técnicas de processamento de imagem, como filtros e técnicas de detecção de bordas, para melhorar a precisão e a qualidade da segmentação de imagem.

De acordo com Gonzales e Woods (1987) e Saldanha e FREITAS (2009), a técnica piramidal é uma estratégia eficiente de segmentação de imagens que consiste em dividir a imagem original em elementos menores e separados, a fim de realizar a junção ou divisão dessas regiões com maior facilidade e precisão.

Uma das abordagens mais utilizadas na técnica piramidal é a divisão da imagem em quadrantes, utilizando uma estrutura de dados denominada *quadtree*. Essa estrutura é uma árvore com uma raiz e quatro filhos, cada um representando um quadrante da imagem original. Esses filhos, por sua vez, podem ser divididos em outros quatro filhos, representando quatro quadrantes menores e assim por diante, criando uma hierarquia de níveis.

A utilização do *quadtree* permite uma segmentação progressiva da imagem, onde a resolução vai sendo reduzida à medida que se avança nos níveis da árvore. Essa abordagem permite uma análise mais eficiente de áreas de interesse específicas da imagem, sem comprometer a qualidade da segmentação ou a fidelidade da informação contida na imagem.

É importante ressaltar que a escolha da estratégia de divisão da imagem em quadrantes deve ser feita levando em consideração as características da imagem em questão e os objetivos da segmentação. Além disso, a estrutura de dados utilizada deve ser adaptada e otimizada para a aplicação específica, a fim de garantir um desempenho adequado e eficiente na segmentação da imagem.

De acordo com Roerdink e Meijster (2000), Saldanha e FREITAS (2009) e Gonzalez, Woods e Eddins (2003), a detecção de bacias é uma técnica fundamental em processamento de imagens e tem uma ampla variedade de aplicações em áreas como geologia, hidrologia, cartografia e análise de imagens médicas. Esta técnica é baseada em uma combinação de detecção de bordas e junção de regiões, sendo capaz de extrair informações importantes sobre a topografia de uma imagem em níveis de cinza.

O princípio básico por trás da detecção de bacias é o conceito de inundação de relevos topográficos (RUSS, 2006). Isso significa que a imagem em níveis de cinza pode ser vista como um relevo topográfico, onde as porções mais escuras representam vales e as porções mais claras representam montanhas. O objetivo da detecção de bacias é dividir a imagem em regiões que correspondem a esses vales e montanhas.

O primeiro passo na detecção de bacias é a identificação de bordas na imagem. Isso é feito usando técnicas de detecção de bordas, que são projetadas para localizar transições abruptas de intensidade na imagem. As bordas são então suavizadas para evitar a formação de ruído e são utilizadas como linhas guias para a divisão da imagem em regiões.

A próxima etapa envolve a criação de linhas de fluxo, que se movem na direção dos gradientes mais acentuados na imagem. Essas linhas de fluxo são então usadas para dividir a imagem em regiões, com cada região correspondendo a uma bacia hidrográfica. A partir daí, algoritmos de pós-processamento podem ser utilizados para remover regiões de interesse, como áreas com baixa variação de intensidade.

De acordo com Gonzales e Woods (1987) e Saldanha e FREITAS (2009), a Limiarização é uma técnica fundamental para a segmentação de imagens. É considerada uma das formas mais simples e eficientes de segmentação, especialmente em aplicações em que o objetivo é destacar características específicas em uma imagem.

O processo de Limiarização envolve a definição de um valor limite, ou limiar, que separa os *pixels* da imagem em dois grupos distintos: os que possuem intensidades de cinza abaixo do limiar e os que possuem intensidades de cinza acima do limiar.

A partir dessa separação, cada *pixel* é atribuído a um desses grupos, permitindo que as características da imagem possam ser identificadas e destacadas com mais clareza. A escolha do valor do limiar pode ser feita de forma empírica ou por meio de algoritmos que levam em consideração as características da imagem.

Além de ser uma técnica simples e eficiente, a Limiarização é amplamente utilizada em diversas áreas, como processamento de imagens, reconhecimento de padrões,

visão computacional, entre outras. É uma ferramenta poderosa para melhorar a qualidade e a precisão de análises de imagens e pode ser aplicada em diferentes tipos de imagens, como imagens médicas, imagens de satélite, imagens de microscopia, entre outras.

De acordo com Gonzales e Woods (1987) e Saldanha e FREITAS (2009), o Algoritmo k-means é um método de segmentação de imagens não supervisionado que é amplamente utilizado em diversas aplicações de processamento de imagens. Sua função é separar uma imagem em diferentes regiões com características semelhantes, sem a necessidade de categorias ou grupos pré-definidos.

O algoritmo funciona através da identificação de k centros iniciais aleatórios, cada um representando um possível cluster ou grupo na imagem. Em seguida, ele calcula a distância entre cada ponto da imagem e cada centro inicial, atribuindo cada ponto ao centro mais próximo.

Após essa atribuição inicial, o algoritmo recalcula o centro de cada cluster com base na média dos pontos pertencentes a ele. Esse processo é repetido até que a mudança nos centros dos clusters se torne insignificante ou após um número pré-definido de iterações.

O resultado final do algoritmo é uma imagem segmentada em k clusters, cada um representando uma região com características semelhantes. Essas regiões podem ser usadas para aplicar diferentes tipos de processamento de imagem, como realce de bordas, suavização, entre outros.


Uma das principais vantagens do algoritmo k-means é a sua eficiência computacional, tornando-o uma opção viável para segmentar imagens grandes e complexas em tempo real. Além disso, o método é bastante versátil e pode ser adaptado para diferentes tipos de imagens e aplicações, desde imagens médicas até imagens de satélite.

2.4 Estado-da-arte

No projeto de Sarino *et al.* (2019), a técnica de segmentação utilizada foi baseada nas cores dos grãos de café. Os autores realizaram a segmentação utilizando o espaço de cor HSV (Hue, Saturation, Value), em que o canal de Hue é utilizado para separar os grãos da imagem de fundo, e os canais de Saturation e Value são utilizados para separar os grãos com diferentes graus de torra. Essa abordagem permitiu uma segmentação precisa dos grãos de café e contribuiu para a alta acurácia alcançada na classificação do grau de torra.

O trabalho de Ribeiro, Souza Pereira e Falate (2015) apresenta métodos computacionais de processamento digital de imagens para extração de características dos grãos de milho. Neste trabalho eles realizam a segmentação por meio do espaço de cor HSV (*hue, saturation e value*). Para realizar a segmentação e extração das características, foi definido apenas a cor de fundo nas imagens onde continham os grãos de milho, assim


Figura 4 – Limiarização



Fonte: (GONZALEZ; WOODS; EDDINS, 2003)

realizando apenas o recorte do fundo e sobrando apenas os grãos de milho. Na Figura 5 é possível observar a imagem segmentada.

Figura 5 – Segmentação através do espectro HSV



Fonte: (RIBEIRO; SOUZA PEREIRA; FALATE, 2015)

Outro trabalho interessante foi desenvolvido por Belan *et al.* (2019) com o desenvolvimento de um sistema de visão computacional para inspeção da qualidade de grãos de feijão. A etapa de segmentação deste trabalho empregou um método baseado no algoritmo *k-NN* (*k-nearest neighbors*). Onde cada *pixel* da imagem colorida é mapeada para tom de cinza, sendo que as cores típicas de feijão são mapeadas para tons mais escuros enquanto as cores de fundo são mapeadas para tons mais claros. Para realizar a segmentação dos grãos, o autor utilizou a técnica *WT* (*watershed Transform*) que consiste em uma técnica de segmentação que interpreta a imagem como se fosse uma superfície topográfica.

No trabalho de Biffi *et al.* (2021) a limiarização é utilizada para a detecção de frutas em imagens obtidas por câmeras de baixo custo para monitorar o crescimento e a produção de pomares de maçã. A técnica de limiarização é empregada para segmentar as frutas nas imagens, convertendo as imagens RGB em espaço de cor HSI e, em seguida, definindo um limiar para a segmentação.

3 METODOLOGIA

O capítulo atual tem como foco descrever a metodologia usada no desenvolvimento do presente trabalho. A Seção 3.1 trata da classificação da pesquisa. Em seguida, a Seção 3.2 explica a solução proposta para resolver o problema identificado. Já, a Seção 3.3 aborda os materiais e tecnologias utilizados. Por fim, a Seção 3.4 aborda os métodos e os procedimentos adotados.

3.1 Classificação da pesquisa

De acordo com as características relatadas por Wazlawick (2009), o presente trabalho se enquadra no estilo de pesquisa “apresentação de algo presumivelmente melhor”. Até o momento, apesar de existirem trabalhos que propõe metodologias alternativas para a análise de cor do café torrado, esses trabalhos não realizam a segmentação da área do café de maneira automática. Quanto à natureza, segundo os critérios estabelecidos por Gerhardt e Silveira (2009), o presente trabalho se caracteriza como pesquisa aplicada, uma vez que o objetivo principal do trabalho é resolver o problema específico de segmentar de maneira automática as imagens contendo os grãos de café torrados.

Segundo Gil (2002), a pesquisa também podem se classificada quanto aos objetivos e procedimentos. O trabalho em questão é definido como pesquisa exploratória e pesquisa-ação. O enquadramento na pesquisa exploratória está relacionado com a criação de hipóteses sobre qual método de segmentação ou aplicação com aprendizado de máquina terá maior acurácia. Quanto à classificação como pesquisa-ação, serão realizadas análises de trabalhos correlatos que auxiliam no entendimento e resolução do problema.

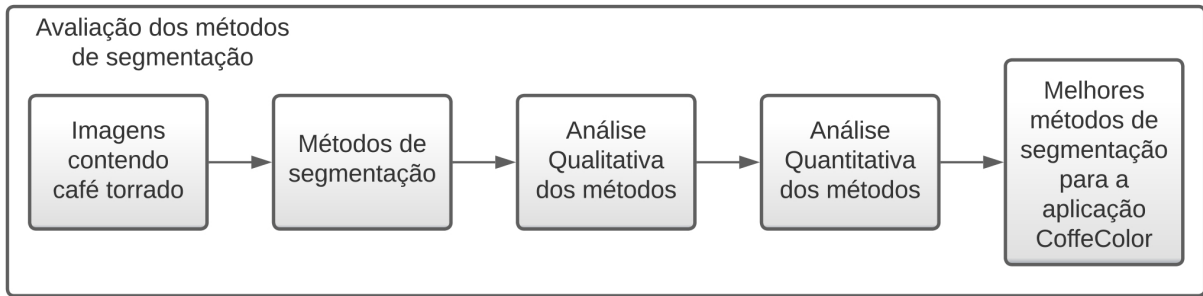
Por fim, segundo Gerhardt e Silveira (2009) os trabalhos podem ser classificados quanto à abordagem. O presente trabalho, em relação a abordagem, é caracterizado como qualiquantitativo, porque será possível verificar a acurácia da segmentação usando os métodos de classificação do grau de torra de café existentes.

3.2 Solução

O projeto consiste na avaliação e aplicação de modelos de segmentação para a seleção de grãos de café torrados, que permitirá uma melhoria ao trabalho Rodrigues (2022) que realiza uma classificação dos grãos de café torrado de acordo com a escala Agtron. Conforme pode ser verificado na Figura 6.

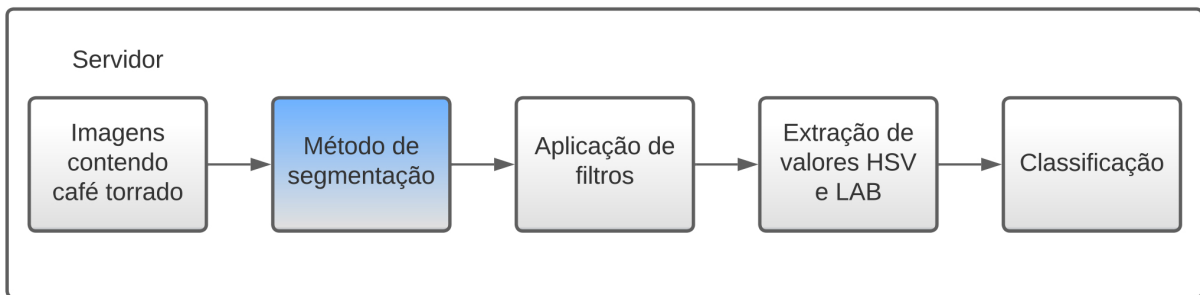
No projeto CoffeColor a imagem é enviada para um servidor responsável por extrair características e classificá-las de acordo com a escala Agtron. O método de segmentação será implementado neste servidor, afim de melhoria na acurácia do classificador.

Figura 6 – Método de segmentação para aplicações de classificação



Fonte: Elaborado pelo Autor, 2022.

Figura 7 – Implementação do método de segmentação no servidor



Fonte: Elaborado pelo Autor, 2022

3.3 Materiais e Tecnologias

A presente seção descreve quais as tecnologias e ferramentas serão utilizadas para desenvolvimento deste trabalho.

Como linguagem de programação base para o desenvolvimento dos algoritmos de processamento digital de imagens e aprendizado de máquina, será utilizado o Python¹. Se tratando de uma linguagem de programação interpretada de alto nível, o Python oferece suporte a vários paradigmas de programação. Podendo ser utilizada para processamento de textos e protocolos de Internet, possuindo uma grande importância na Computação Científica, em especial nas áreas de Análise de Dados e Inteligência Artificial (PYTHON SOFTWARE FOUNDATION, 2021).

A *Open Source Computer Vision Library*² (OpenCV) será utilizada para o pré-processamento das imagens e extração das características para o desenvolvimento da base de dados. A OpenCV é uma biblioteca robusta de código aberto, possuindo módulos focados em processamento de imagens, visão computacional, aprendizado de máquina, estrutura de dados, entre outros. (OPENCV, 2021).

Para auxiliar no fluxo de desenvolvimento e a aplicação do *Scrum*, será utilizado

¹ <https://python.org>

² <https://opencv.org>

o GitHub³, para controle de versão e gerenciamento do projeto.

A base de dados utilizada será a mesma que foi utilizada no trabalho do autor Rodrigues (2022), onde essas mesmas imagens foram utilizadas para uma análise de torra. Essa base de dados é composta por 746 imagens de grãos de café torrados.

Para auxiliar no desenvolvimento o Visual Studio Code⁴ foi escolhido como ferramenta de programação, pela facilidade de uso, a possibilidade de personalização e as extensões. O Visual Studio Code é um editor de código leve e rápido que permite uma customização total do ambiente de trabalho, o que facilita muito o desenvolvimento. Além disso, ele conta com diversas extensões que auxiliam no processo de codificação, como a linha de comando do GitHub(VISUAL STUDIO CODE, 2022).

Para auxiliar no fluxo de desenvolvimento e a aplicação do *Scrum*, o GitHub⁵ será utilizado, pois além das funções de versionamento e hospedagem de repositórios, possui um quadro *Kanban* que vai armazenar as tarefas a serem feitas e suas alterações ao longo do desenvolvimento do projeto (ANDERSON, 2010).

3.4 Método e procedimentos

A etapa inicial do projeto será preparação da base de dados de fotos de grãos de café torrados para aplicação de técnicas de segmentação. Na segunda etapa pretende-se analisar e selecionar as técnicas de segmentação mais adequadas para as imagens de grãos de café torrado. Na etapa três, pretende-se avaliar e aprimorar as técnicas selecionadas para integração com métodos de detecção de grau de torra existentes.

Para auxiliar no processo de desenvolvimento do trabalho, será empregada a metodologia *Scrum* de desenvolvimento ágil. Segundo Sabbagh (2014), o *Scrum* se tornou a forma mais comum de se trabalhar em projetos de desenvolvimento de *software*, sendo utilizado também em diferentes mercados, como empresas de *marketing* e de desenvolvimento de *hardware*. Além disso, o autor evidencia a redução dos riscos do projeto, maior qualidade no produto gerado, visibilidade do progresso do projeto, redução do desperdício, aumento de produtividade, entre outros, como benefícios da utilização desta metodologia.

Como ferramenta de gerenciamento do GitHub, o *Kanban* será utilizado, por sua capacidade de criar um quadro visual de tarefas, definir prazos e acompanhar o progresso em tempo real. Com essa metodologia, é possível ter uma visão clara do andamento do projeto, além de priorizar as atividades mais importantes. (ANDERSON, 2010).

³ <https://github.com>

⁴ <https://code.visualstudio.com/>

⁵ <https://github.com>

4 DESENVOLVIMENTO

O capítulo atual tem como foco descrever as ações e estratégias adotadas para alcançar os objetivos propostos, bem como os resultados alcançados. A Seção 4.1 trata de uma análise qualitativa das técnicas de segmentação aplicadas em imagens de café torrado. A Seção 4.2 trata de uma análise quantitativa das técnicas de segmentação a partir da utilização do aplicativo de detecção do grau de torra.

4.1 Análise Qualitativa

Para a realização de uma análise qualitativa das técnicas de segmentação, foram selecionadas duas imagens com grãos de café torrados. Uma delas com grau de torra 25 e a outra com grau de torra 75. Essa escolha foi feita para testar as técnicas de segmentação com coloração mais clara (grau 75) e mais escura (grau 25).

As Subseções a seguir tem como foco descrever a análise qualitativa de acordos com os tipos de técnicas de segmentação. A Subseção 4.1.1 descreve brevemente sobre como funcionam as técnicas de utilizadas sobre Detecção de Descontinuidades e descreve uma análise qualitativa sobre elas. A Subseção 4.1.2 descreve brevemente sobre como funcionam as técnicas de utilizadas sobre Segmentação no Espaço de Atributos e descreve uma análise qualitativa sobre elas. A Subseção 4.1.3 descreve brevemente sobre como funcionam as técnicas de utilizadas sobre Detecção de Similaridades e descreve uma análise qualitativa sobre elas.

4.1.1 Detecção de descontinuidades

Como detecção de descontinuidades foram implementadas as técnicas de detecção de pontos e linhas e a técnica de detecção de bordas. A técnica de detecção de pontos e linhas apresenta limitações quando se trata da detecção de grãos, já que sua função é identificar apenas pontos e linhas presentes na imagem.

Embora tenham sido feitas variações nos parâmetros da técnica de detecção de pontos e linhas, os resultados foram consistentes e não contribuíram significativamente para o processo de seleção de grãos, como mostrado na Figura 8.

A técnica de detecção de bordas requer a definição de um limiar para a aplicação da limiarização, foram realizados testes com diferentes valores para o limiar, no entanto, não foram observadas alterações significativas nos resultados finais. O resultado da aplicação da técnica de detecção de bordas pode ser visualizado na Figura 9, onde é possível constatar que essa técnica não é tão eficaz para detecção dos grãos de café, pois todas as bordas na imagem são selecionadas.

Figura 8 – Aplicação da técnica de detecção pontos e linhas




(a) – Detecção de pontos

(b) – Detecção de linhas

Fonte: Elaborado pelo Autor, 2022

Figura 9 – Aplicação da técnica de detecção de bordas



Fonte: Elaborado pelo Autor, 2022.

4.1.2 Segmentação no Espaço de Atributos

Na categoria de segmentação no espaço de atributos foram implementadas as técnicas de limiarização, k-means e segmentação no espectro HSV. A limiarização é um método simples e rápido que compara cada pixel da imagem com um limiar pré-definido referente à intensidade de cinza desejada.

Na Figuras 10 e 11, utilizando um limiar de 125, é possível separar os grãos de café do fundo da imagem. O valor do limiar é um fator importante na técnica de limiarização. Valores baixos do limiar podem resultar em bordas falhas e falhas no meio dos grãos, como mostrado na Figura 10(a) e na Figura 11(a). Portanto, é importante ajustar o limiar adequadamente para obter um resultado adequado. Para a imagem com grau de torra 25, limiares entre 125 e 150 entregam resultados satisfatórios, já para a imagem com grau de torra 75, os limiares entre 130 a 140 obtiverem melhores resultados.

A técnica de segmentação no espaço HSV utiliza parâmetros de tonalidade de cor que são definidos durante a implementação. Para sua implementação, é necessário

Figura 10 – Aplicação da técnica de limiarização em imagem com grau de torra 25



Fonte: Elaborado pelo Autor, 2022.

Figura 11 – Aplicação da técnica de limiarização em imagem com grau de torra 75

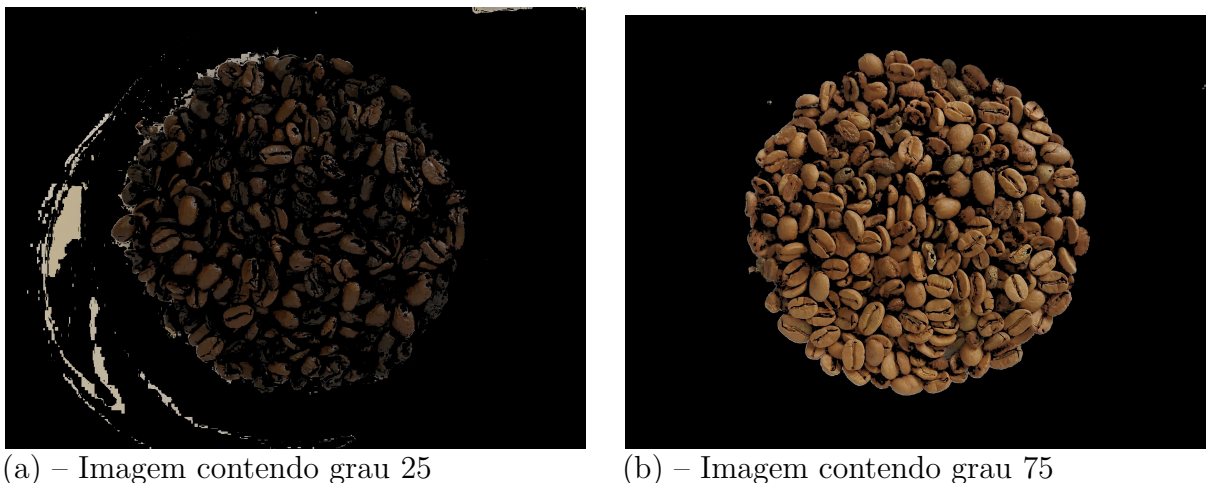


Fonte: Elaborado pelo Autor, 2022.

verificar os códigos de cores corretos que são coerentes com a imagem a ser segmentada, para isso, é recomendável utilizar uma paleta de cores. Como a segmentação de torra é baseada na escala de marrom, foi definido um limite considerando essa tonalidade.

Na Figura 13, é possível notar que a área contendo os grãos de café foi segmentada. Entretanto, há um problema nessa segmentação: para segmentar grãos de torra grau 25, é necessário utilizar parâmetros diferentes dos utilizados em imagens de grau 75. No exemplo da Figura 12, pode-se verificar como a imagem contendo o grão de torra 25 fica em uma segmentação para o grau de torra 75.

Figura 12 – Diferença de parâmetro para a segmentação HSV



Fonte: Elaborado pelo Autor, 2022

Uma alternativa para realizar a segmentação no espaço HSV é selecionar a cor de fundo da imagem como foco, em vez de selecionar as cores dos grãos de café. Em seguida, é feita a inversão da máscara de segmentação. Dessa forma, é possível obter resultados mais satisfatórios na segmentação, porém não é o ideal para o problema em questão, pois nem sempre as imagens contendo os grãos de café torrado terão o fundo com a cor selecionada para a segmentação.


Figura 13 – Aplicação da técnica de segmentação no espectro HSV



Fonte: Elaborado pelo Autor, 2022.

A técnica de segmentação k-means revelou-se promissora na detecção de grãos de café. Ao realizar testes com diferentes parâmetros de segmentação, foram alcançados resultados satisfatórios. Conforme evidenciado nas Figuras 14 e 15, a técnica demonstrou eficiência ao produzir melhores resultados com o parâmetro k (número de grupos) igual a 2. Tanto para as imagens contendo grãos de torra de grau 25 quanto 75, os valores de $k = 2$ e $k = 3$ resultaram em desempenho satisfatório.

Figura 14 – Aplicação da técnica K-Means em imagem com grau de torra 25



(a) – $K = 2$

(b) – $K = 4$


(c) – $K = 8$

Fonte: Elaborado pelo Autor, 2022.

4.1.3 Detecção de Similaridade

Como detecção de similaridades, foram implementadas as técnicas de método piramidal, detecção de bacias e crescimento de regiões. A técnica de detecção de bacias apresentou bons resultados para identificar grãos, graças ao seu processo de limiarização

Figura 15 – Aplicação da técnica K-Means em imagem com grau de torra 75



Fonte: Elaborado pelo Autor, 2022

baseado em gradiente, que destaca os pontos da imagem com maior variação de brilho. Uma vantagem notável dessa técnica é que os grãos não apresentam tantas falhas de segmentação, como pode ser observado na Figura 16.

Também é possível observar que a técnica de detecção de bacias é mais eficaz para a imagem com grau de torra 25. Na imagem de grau 75 é possível identificar alguns pontos não segmentados, onde há luz forte sobre a imagem.

Figura 16 – Aplicação da técnica de detecção de bacias




Fonte: Elaborado pelo Autor, 2022

A técnica de segmentação piramidal é um método que apresenta tanto pontos positivos quanto negativos no processo de segmentação de grãos. Um ponto positivo é que as áreas de interesse são identificadas e destacadas com precisão na imagem. Por outro lado, o método aumenta a complexidade do processo e, conseqüentemente, o tempo de processamento. Além disso, devido à sua natureza baseada em limiares, o método é vulnerável a ruídos na imagem.


A transformada piramidal é um método utilizado para reduzir a resolução de uma imagem, dividindo-a em várias camadas, cada uma com uma resolução menor. Esse processo é feito para reduzir o ruído e o tamanho da imagem, facilitando o processo de segmentação. A técnica se mostrou consideravelmente satisfatória para ambas imagens teste. Para a imagem com grau de torra 25, o número de camadas igual a 2 e a 3 obtiveram os melhores resultados. Já para a imagem com grau de torra 75, o número de camadas entre 3 e 4 se mostrou mais satisfatório. Com número de camadas igual a 2 a imagem apresenta furos na segmentação, devido a luz forte na imagem.

Figura 17 – Aplicação da técnica piramidal em imagem com grau de torra 25



Fonte: Elaborado pelo Autor, 2022

Figura 18 – Aplicação da técnica piramidal em imagem com grau de torra 75



Fonte: Elaborado pelo Autor, 2022

A técnica de segmentação por crescimento apresentou alguns pontos positivos e negativos. Um dos pontos positivos é a capacidade de segmentar regiões homogêneas em uma imagem, permitindo a detecção de grãos com formas e tamanhos variados. Além disso, o método é capaz de lidar com imagens com ruído.

Um dos pontos negativos é que o método é bastante sensível a variações de iluminação na imagem. Isso pode ser constatado na Figura 19, onde a imagem contendo os grãos de café de grau 75 é mais clara, ocorrendo uma pequena falha na segmentação.

Um outro ponto importante na técnica de crescimento de regiões é sua característica de aleatoriedade. Assim, é preciso selecionar uma semente (*seed*) para iniciar o processo de crescimento. A seleção adequada da semente pode influenciar significativamente na qualidade da segmentação, sendo necessário escolher um ponto que esteja localizado na região de interesse e que possua características distintas das demais regiões da imagem. A maneira de selecionar a *seed* é obtendo as coordenadas do centro da imagem, essa abordagem se mostra bem simples e eficaz para esta aplicação, também diminui a complexidade da implementação e da seleção da semente, além de funcionar bem para as duas imagens testadas.

Conforme pode ser verificado na Figura 19, é possível constatar que a técnica é bastante eficaz ao utilizar uma semente bem selecionada. Para obter uma segmentação precisa, recomenda-se definir os valores de variação de tolerância de cor entre 50 e 80 para a imagem de teste. P

Figura 19 – Aplicação da técnica de crescimento de regiões



Fonte: Elaborado pelo Autor, 2022

4.2 Análise Quantitativa

Segundo (RODRIGUES, 2022), em seu projeto o CoffeColor, os algoritmos *Random Forest* e *Decision Tree* comportaram-se de forma estável, e possuíram poucas variações em seus resultados. Por esta razão as análises quantitativas serão realizadas baseadas nestes dois algoritmos de classificação.

Para realizar essa classificação, inicialmente, é realizada a conversão da imagem para uma matriz com valores de intensidade luminosa, que pode ser representada em diferentes espaços de cor, como o RGB, HSV, LAB e escala de cinza.

Após essa conversão, é realizada a extração de características das amostras de café e folha de papel presentes na imagem, como média e desvio padrão de cada canal dos espaços de cores RGB, HSV e LAB, além da escala de cinza. Essas informações são armazenadas em uma tabela que possui diversos atributos para cada imagem teste.


Com base nas informações armazenadas na tabela, é treinado algoritmos para identificar as amostras de café e folha de papel presentes em novas imagens. E assim gerar a precisão de cada algoritmo de classificação.

As Subseções a seguir tem como foco descrever a análise quantitativa de acordos com os resultados obtidos durante os experimentos. A Subseção 4.2.1 apresenta os dados obtidos com a utilização da técnica de Limiarização. A Subseção 4.2.2 apresenta os dados obtidos com a utilização da técnica K-Means. A Subseção 4.2.3 apresenta os dados obtidos com a utilização da técnica Detecção de Bacias. A Subseção 4.2.4 apresenta os dados obtidos com a utilização da técnica Crescimento de Regiões. A Subseção 4.2.5 apresenta os dados obtidos com a utilização da técnica Piramidal. A Subseção 4.2.6 apresenta um comparativo de performance entre as técnicas selecionadas para a análise quantitativa.

4.2.1 Limiarização

O gráfico apresentado na Figura 20(a) mostra a precisão do algoritmo de limiarização utilizando *Random Forest* e as características de cores HSV+LAB para diferentes valores de limiarização.

Figura 20 – Performance do algoritmo utilizando a técnica de limiarização



Fonte: Elaborado pelo Autor, 2023

A precisão do algoritmo varia de 87,1% a 89,7%. Os resultados mostram que a precisão do algoritmo é altamente dependente do valor de limiar escolhido. O melhor resultado foi obtido com um valor de limiar de 138, que teve uma precisão de 89,7%. Quando o valor de limiar é diminuído em relação a 138, a precisão do algoritmo começa a diminuir gradualmente. Por outro lado, quando o valor de limiar é aumentado em relação a 138, a precisão do algoritmo apresenta uma maior queda de precisão.

Para complementar as informações sobre o desempenho do algoritmo de classificação, foram obtidos os tempos de execução para cada limiar de segmentação. Cada tempo foi dividido pelo número de imagens processadas (746), para obter o tempo de processamento de uma única imagem. Os resultados podem ser vistos na tabela abaixo:

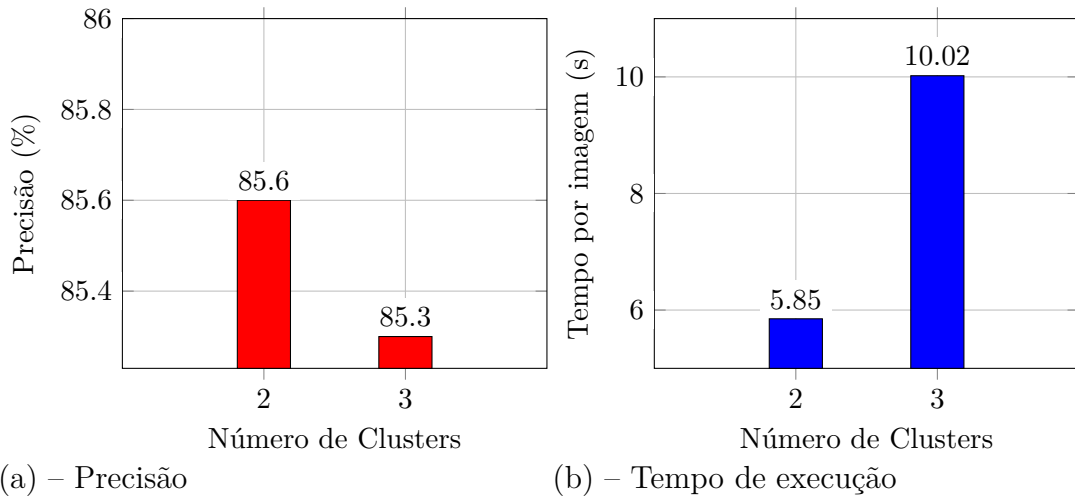
Os resultados apresentados na Tabela 20(b) mostram que o tempo de execução por imagem do algoritmo de limiarização varia de 0,81 a 1,04 segundos, com uma média de 0,92 segundos. Nota-se que o valor de limiarização com a melhor precisão obtida (138) também apresentou o maior tempo de processamento. Isso indica uma relação direta entre o tempo de processamento e a precisão do algoritmo. Portanto, é possível afirmar que quanto maior o tempo de processamento, maior a precisão do algoritmo, em geral. No entanto, é importante ressaltar que essa relação pode não ser linear e depende das características específicas do algoritmo e dos dados utilizados.

4.2.2 *K-Means*

Na Figura 21(a), é possível observar que a precisão do algoritmo K-means apresentou valores relativamente próximos para 2 e 3 clusters, com uma diferença de apenas 0,3 pontos percentuais entre eles. Isso indica que, para este conjunto de dados, não houve um ganho significativo na precisão ao aumentar o número de clusters.

Já na Figura 21(b), é possível notar que apesar da pequena diferença de percentual na precisão o tempo de execução por imagem aumentou consideravelmente.

Figura 21 – Performance do algoritmo utilizando a técnica K-means



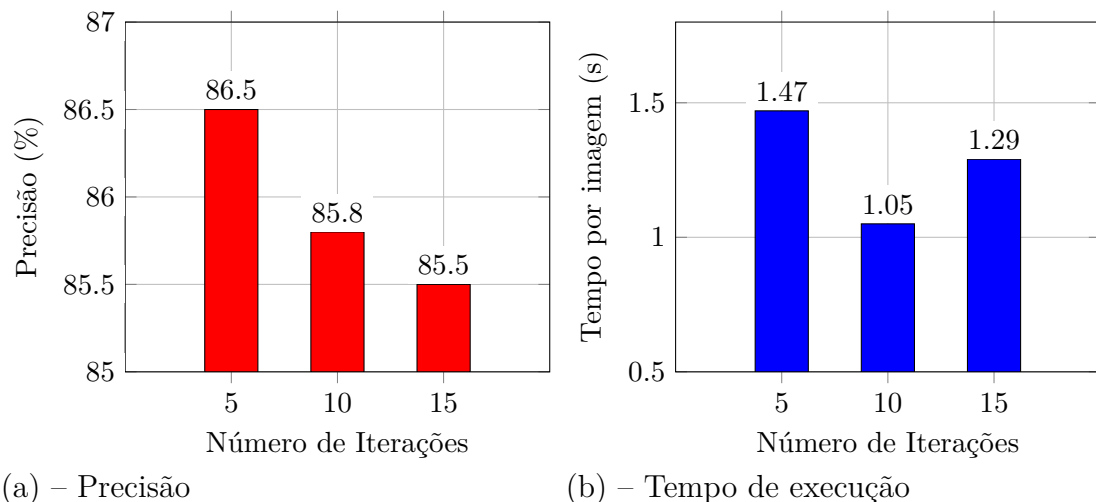
Fonte: Elaborado pelo Autor, 2023

Isso pode indicar que o aumento no número de *clusters* pode aumentar significativamente o tempo de processamento necessário para executar o algoritmo K-means.

4.2.3 Detecção de Bacias

Os dados apresentados na Figura 22(a) mostram a precisão do algoritmo Detecção de Bacias para cada número de iterações. Observando os dados, pode-se notar que a precisão do algoritmo diminui à medida que o número de iterações aumenta. O maior valor de precisão é de 86,5% com 5 iterações, enquanto o menor valor é de 85,5% com 15 iterações. Essa tendência sugere que o algoritmo pode ser mais preciso com menos iterações.

Figura 22 – Performance do algoritmo utilizando a técnica Detecção de Bacias



Fonte: Elaborado pelo Autor, 2023

Observando os dados apresentados na Figura 22(b), pode-se notar que o tempo de execução por imagem varia de forma irregular conforme o número de iterações aumenta.

O menor tempo é de 1,05 segundos com 10 iterações, enquanto o maior tempo é de 1,47 segundos com 5 iterações. Além disso, o tempo de execução aumenta para 1,29 segundos com 15 iterações.

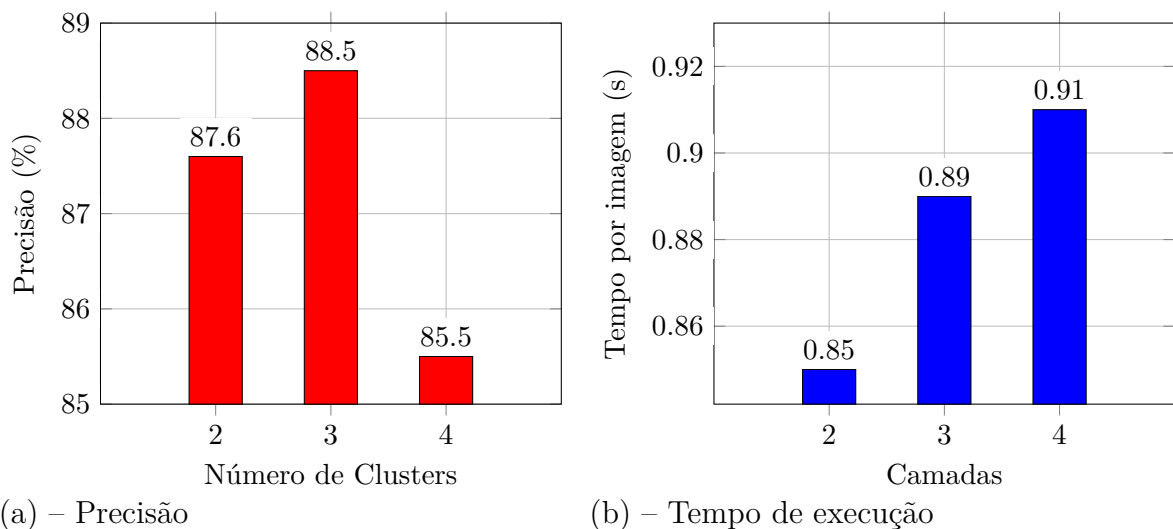
4.2.4 *Crescimento de Regiões*

A técnica de crescimento de regiões apresentou uma precisão de 75.7%, a qual, apesar de ser a menor entre as técnicas utilizadas, ainda é considerada um resultado significativo. A escolha da semente é um fator importante na precisão desta técnica, e neste caso, a abordagem adotada foi a de selecionar o centro da imagem, visando reduzir a complexidade da seleção. No entanto, é importante destacar que a escolha da semente pode impactar significativamente na precisão do método de crescimento de regiões. O tempo de execução por imagem foi de 29.56 segundos.

4.2.5 *Piramidal*

A Figura 23(a) apresenta a precisão obtida pelo algoritmo utilizando a técnica piramidal com diferentes números de camadas. Observa-se que a precisão obtida foi de 87.6% para 2 camadas, 88.5% para 3 camadas e 85.5% para 4 camadas. Verifica-se que a precisão aumenta com o aumento do número de camadas até certo ponto, em que a precisão começa a diminuir. Isso pode ser explicado pelo fato de que, à medida que se aumenta o número de camadas, a imagem é dividida em regiões cada vez menores, o que pode levar a uma perda de informação importante para a detecção de bordas e objetos de interesse.

Figura 23 – Performance do algoritmo utilizando a técnica Piramidal



Fonte: Elaborado pelo Autor, 2023.

Para a técnica piramidal, foram obtidos os tempos de execução para cada nível da pirâmide. Cada tempo foi dividido pelo número de imagens processadas (746), para

obter o tempo de processamento de uma única imagem. Os resultados podem ser vistos gráfico abaixo:

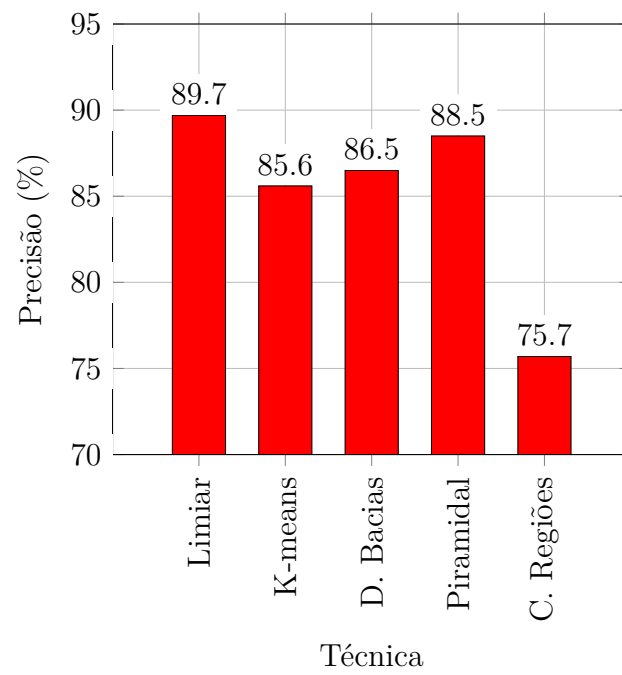
Observando os dados apresentados na Figura 23(b), pode-se notar que o tempo de execução pode-se notar que o tempo aumenta de acordo com o número de camadas utilizadas. Esse resultado é esperado, uma vez que a técnica piramidal envolve a criação de várias imagens em diferentes escalas. Quanto maior o número de camadas, maior a quantidade de imagens geradas e maior o tempo necessário para processá-las.

4.2.6 Comparativo das técnicas

Com base na Figura 24, é possível observar um comparativo de precisão entre cinco técnicas de análise de dados. O gráfico comparativo apresentado inclui apenas as melhores precisões de cada técnica avaliada. A técnica de Limiarização apresentou a maior precisão de todas, com 89.7%, além de ter o tempo de execução mais baixo, apenas 1.04 segundos. A técnica Piramidal obteve uma precisão próxima à Limiarização, com 88.5%, e um tempo de execução ainda mais rápido, apenas 0.89 segundos. A técnica de Detecção de Bacias apresentou uma precisão intermediária, de 86.5%, e um tempo de execução relativamente baixo, de 1.47 segundos. A técnica K-means obteve uma precisão menor, de 85.6%, e um tempo de execução mais longo, de 5.85 segundos. Já a técnica de Crescimento de Regiões apresentou a menor precisão de todas, com 75.7%, e o tempo de execução mais longo, de 29.56 segundos.

Em geral, a escolha da técnica a ser utilizada depende da necessidade de precisão e tempo de execução, sendo a técnica Limiarização e a técnica Piramidal as mais indicadas para um equilíbrio entre ambas as métricas.

Figura 24 – Comparativo de precisão entre as técnicas



Fonte: Elaborado pelo Autor, 2023.

5 CONSIDERAÇÕES FINAIS

O café é muito importante no Brasil. O país é o maior produtor e exportador mundial, sendo essencial para a economia do país. O que deixa oportunidades de desenvolver e aprimorar implementações que visam facilitar a vida do produtor rural, como um classificador de acordo com a escala Agtron.

Neste trabalho, foi realizado um estudo na área de processamento de imagens, com foco na segmentação de grãos de café torrado. O objetivo do trabalho era analisar e desenvolver técnicas de segmentação visando conseguir implementar um modelo que seleciona de maneira automática a região contendo os grãos de café.

Inicialmente, uma base de dados pré-existente de fotos de grãos de café foi preparada, fornecendo uma quantidade adequada de imagens para a aplicação das técnicas de segmentação. Em seguida, foi realizada a análise qualitativa, onde cada técnica foi avaliada considerando a precisão em identificar e separar corretamente as partes relevantes dos dados e assim selecionando as mais promissoras.

Para a análise quantitativa, as técnicas selecionadas foram aprimoradas e implementadas em um algoritmo que realiza a classificação, através do *Random Forest*, permitindo a obtenção da acurácia e do tempo de processamento como métricas de avaliação, e assim foram avaliadas de acordo com estas métricas.

Durante a análise quantitativa, com base nas métricas avaliadas, ficou evidente que a técnica de Limiarização obteve os melhores resultados. Com uma impressionante precisão de 89,7%, superou as demais abordagens consideradas. Além disso, seu tempo de execução foi de 1,04 segundos. Esses resultados destacam a eficácia e eficiência da Limiarização como o método mais promissor entre os avaliados.

5.1 Trabalhos futuros

Além do escopo deste trabalho, existem várias direções promissoras para pesquisas e desenvolvimento futuro, visando aprimorar ainda mais os resultados obtidos através destas análises. Uma das opções seria a implementação do algoritmo de Limiarização no aplicativo (COLOR, 2022), que realiza a classificação do grau de torra.

Como foi utilizado o *Random Forest* para a classificação, seria interessante investigar ainda mais seu desempenho, variando os parâmetros. Essa análise permitiria uma compreensão mais aprofundada dos parâmetros e ajudaria a otimizar o desempenho da implementação.

Uma outra alternativa seria a implementação de um modelo de aprendizado de máquina para realizar a segmentação das imagens de torra de café. Ao invés de utilizar algoritmos de segmentação, um modelo de aprendizado de máquina pode aprender a segmentar automaticamente as regiões de interesse nas imagens, com base em um conjunto de dados de treinamento.

REFERÊNCIAS

- ACHARYA, T.; RAY, A. K. **Image processing: principles and applications**. John Wiley & Sons, 2005.
- ALMEIDA, T. B. de; FERNANDES, M. M.; PEDRINO, E. C. Proposta de Arquitetura Híbrida para Processamento Digital de Imagens. In: XXVI CIC e XI CIDTI-Campus São Carlos. 2019.
- ALVES, J. J. **Café brasileiro de qualidade**. 2019. Trabalho de Conclusão de Curso (Graduação em Engenharia de Alimentos) – Universidade Federal de Uberlândia (UFU), Uberlândia, MG, Brasil, 2019. Disponível em: <https://repositorio.ufu.br/handle/123456789/25554>.
- ANDERSON, D. J. **Kanban: successful evolutionary change for your technology business**. Blue Hole Press, 2010.
- ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE CAFÉ (ABIC). **Indicadores da Indústria de Café - 2020 - ABIC**. 2021. Disponível em: <https://estatisticas.abic.com.br/estatisticas/indicadores-da-industria/indicadores-da-industria-de-cafe-2020/>. Acesso em: 15 jun. 2022.
- _____. **O café brasileiro na atualidade**. 2021. Disponível em: <https://www.abic.com.br/tudo-de-cafe/o-cafe-brasileiro-na-atualidade/>. Acesso em: 14 jun. 2022.
- BELAN, P. A. *et al.* Sistema de visão computacional para inspeção da qualidade de grãos de feijão. Universidade Nove de Julho, 2019.
- BIANCHI, C. G. **CAFÉ E ECONOMIA BRASILEIRA DA ASCENSÃO À EXTINÇÃO DO CICLO DO CAFÉ**. Jovens Pesquisadores-Mackenzie, 2012.
- BIFFI, L. J. *et al.* Evaluating the performance of a semi-automatic apple fruit detection in a high-density orchard system using low-cost digital RGB imaging sensor. **Boletim de Ciências Geodésicas**, SciELO Brasil, v. 27, 2021.
- COFFEECOLOR. **rccoffee**. 2022. Disponível em: <https://github.com/coffeecolor>. Acesso em: 18 jun. 2022.
- EUGÊNIO, M. H. A. *et al.* Expansão volumétrica de grãos de café arábica submetidos a diferentes pontos de torração. In: CONGRESSO BRASILEIRO DE PESQUISAS CAFEEIRAS (CBPC), XXXVII., 2011, Poços de Caldas, MG, Brasil. **Anais**. Brasília, DF, Brasil: Embrapa Café, 2011. p. 1–2. Disponível em: <http://www.sbicafe.ufv.br/handle/123456789/5831>. Acesso em: 17 jun. 2022.
- FACELI, K. *et al.* **Inteligência artificial: uma abordagem de aprendizado de máquina**. LTC, 2011.
- GERHARDT, T. E.; SILVEIRA, D. T. **Métodos de pesquisa**. Porto Alegre, RS, Brasil: Editora da UFRGS, 2009.
- GIL, A. C. **Como elaborar projetos de pesquisa**. São Paulo, SP, Brasil: Editora atlas, 2002.

GONZALES, R. C.; WOODS, R. E. *Digital Image Processing*. Reading, MA: Addison-Wesley, 1987.

GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. L. **Digital Image Processing Using MATLAB**. Nova Jersey, Estados Unidos: Prentice-Hall, Inc., 2003.

MELO, W. L. d. B. A Importância da Informação Sobre do Grau de Torra do Café e sua Influência nas Características Organolépticas da Bebida. **Embrapa Instrumentação Agropecuária**: Comunicado Técnico, Embrapa Instrumentação Agropecuária, São Carlos, SP, Brasil, v. 58, p. 1–4, 2004. Disponível em: <https://agris.fao.org/agris-search/search.do?recordID=BR2004130170>.

OPEN SOURCE COMPUTER VISION LIBRARY (OPENCV). **About OpenCV**. 2021. Disponível em: <https://opencv.org/about/>. Acesso em: 10 jul. 2022.

PYTHON SOFTWARE FOUNDATION. **General Python FAQ**. 2021. Disponível em: <https://docs.python.org/3/faq/general.html>. Acesso em: 13 jul. 2022.

RIBEIRO, S. S.; SOUZA PEREIRA, R. de; FALATE, R. Uso de processamento digital de imagens e mineração de dados para extração de características de grãos de milho. In: X Congresso Brasileiro de Agronômica. Ponta Grossa/PR. 2015.

RODRIGUES, J. V. V. **COFFECOLOR: Desenvolvimento de um aplicativo para detecção do grau de torra de café baseado na cor**. 2022. Diss. (Mestrado) – Bambuí, MG.

ROERDINK, J. B.; MEIJSTER, A. The watershed transform: Definitions, algorithms and parallelization strategies. **Fundamenta informaticae**, IOS press, v. 41, n. 1-2, p. 187–228, 2000.

RUSS, J. C. **The image processing handbook**. CRC press, 2006.

SABBAGH, R. **Scrum: Gestão ágil para projetos de sucesso**. Editora Casa do Código, 2014.

SALDANHA, M. F.; FREITAS, C. Segmentação de imagens digitais: Uma revisão. **Divisão de Processamento de Imagens-Instituto Nacional de Pesquisas Espaciais (INPE), São Paulo**, 2009.

SARINO, J. N. C. *et al.* Classification of Coffee Bean Degree of Roast Using Image Processing and Neural Network. **International Journal of Scientific and Technology Research**, v. 8, n. 10, p. 3231–33, 2019.

SCHWARTZ, W. R.; PEDRINI, H. Método para classificação de imagens baseada em matrizes de coocorrência utilizando características de textura. **III Colóquio Brasileiro de Ciências Geodésicas, CuritibaPR, Brasil**, v. 1, 2003.

SHAPIRO, L. G.; STOCKMAN, G. C. *et al.* **Computer vision**. Prentice Hall New Jersey, 2001. v. 3.

VISUAL STUDIO CODE. **Visual Studio Code FAQ**. 2022. Disponível em: <https://code.visualstudio.com/docs/supporting/faq>. Acesso em: 13 jul. 2022.

WANG, X.; LIM, L.-T. Physicochemical Characteristics of Roasted Coffee. In: COFFEE in Health and Disease Prevention. San Diego, Califórnia, Estados Unidos: Academic Press, 2015. cap. 27, p. 247–254.

WAZLAWICK, R. S. **Metodologia de pesquisa para ciência da computação**. Elsevier, 2009. v. 2.

APÊNDICES

APÊNDICE A – HISTÓRICO DO QUADRO *KANBAN*

Todo 8 ...

- Draft
Aplicar método de detecção de pontos e linhas
- Draft
Aplicar método de detecção de bordas
- Draft
Aplicar método da limiarização
- Draft
Aplicar método piramidal
- Draft
Aplicar método k-means
- Draft
Aplicar método de detecção de bacias
- Draft
Realizar análise subjetiva das técnicas já implementadas
- Draft
Realizar testes no aplicativo que realiza análise do grau de torra

+ Add item

In Progress 1 ...

- Draft
Escrita da monografia

+ Add item

Done 2 ...

- Draft
Preparar base de dados existente para utilizar no projeto
- Draft
Analisar e selecionar técnicas para implementação

+ Add item

Todo 7 ...

- Draft
Aplicar método de detecção de bordas
- Draft
Aplicar método da limiarização
- Draft
Aplicar método piramidal
- Draft
Aplicar método k-means
- Draft
Aplicar método de detecção de bacias
- Draft
Realizar análise subjetiva das técnicas já implementadas
- Draft
Realizar testes no aplicativo que realiza análise do grau de torra

+ Add item

In Progress 2 ...

- Draft
Escrita da monografia
- Draft
Aplicar método de detecção de pontos e linhas

+ Add item

Done 2 ...

- Draft
Preparar base de dados existente para utilizar no projeto
- Draft
Analisar e selecionar técnicas para implementação

+ Add item

Todo 6 ...

- Draft
Aplicar método da limiarização
- Draft
Aplicar método piramidal
- Draft
Aplicar método k-means
- Draft
Aplicar método de detecção de bacias
- Draft
Realizar análise subjetiva das técnicas já implementadas
- Draft
Realizar testes no aplicativo que realiza análise do grau de torra

+ Add item

In Progress 2 ...

- Draft
Escrita da monografia
- Draft
Aplicar método de detecção de bordas

+ Add item

Done 3 ...

- Draft
Preparar base de dados existente para utilizar no projeto
- Draft
Analisar e seleccionar técnicas para implementação
- Draft
Aplicar método de detecção de pontos e linhas

+ Add item

The image shows a Kanban board with three columns: 'Todo', 'In Progress', and 'Done'. Each column contains a list of tasks, each marked as a 'Draft' with a circular icon. The 'Todo' column has 5 items, 'In Progress' has 2, and 'Done' has 4. Each column also features an 'Add item' button at the bottom.

Column	Count	Item 1	Item 2	Item 3	Item 4	Item 5
Todo	5	Aplicar método piramidal	Aplicar método k-means	Aplicar método de detecção de bacias	Realizar análise subjetiva das técnicas já implementadas	Realizar testes no aplicativo que realiza análise do grau de torra
In Progress	2	Escrita da monografia	Aplicar método da limiarização			
Done	4	Preparar base de dados existente para utilizar no projeto	Analisar e selecionar técnicas para implementação	Aplicar método de detecção de pontos e linhas	Aplicar método de detecção de bordas	

Board layout with three columns: **Todo** (4 items), **In Progress** (2 items), and **Done** (5 items). Each item is a draft task.

Column	Item	Status
Todo (4)	Aplicar método k-means	Draft
	Aplicar método de detecção de bacias	Draft
	Realizar análise subjetiva das técnicas já implementadas	Draft
	Realizar testes no aplicativo que realiza análise do grau de torra	Draft
In Progress (2)	Escrita da monografia	Draft
	Aplicar método piramidal	Draft
Done (5)	Preparar base de dados existente para utilizar no projeto	Draft
	Analisar e selecionar técnicas para implementação	Draft
	Aplicar método de detecção de pontos e linhas	Draft
	Aplicar método de detecção de bordas	Draft
	Aplicar método da limiarização	Draft

Each column includes an "Add item" button at the bottom.

Todo 2 ...

- Draft
Realizar análise subjetiva das técnicas já implementadas
- Draft
Realizar testes no aplicativo que realiza análise do grau de torra

+ Add item

In Progress 3 ...

- Draft
Escrita da monografia
- Draft
Aplicar método k-means
- Draft
Aplicar método de detecção de bacias

+ Add item

Done 6 ...

- Draft
Preparar base de dados existente para utilizar no projeto
- Draft
Analisar e selecionar técnicas para implementação
- Draft
Aplicar método de detecção de pontos e linhas
- Draft
Aplicar método de detecção de bordas
- Draft
Aplicar método de limiarização
- Draft
Aplicar método piramidal

+ Add item

Todo 1 ...

- Draft
Realizar testes no aplicativo que realiza análise do grau de torra

+ Add item

In Progress 2 ...

- Draft
Escrita da monografia
- Draft
Realizar análise subjetiva das técnicas já implementadas

+ Add item

Done 8 ...

- Draft
Preparar base de dados existente para utilizar no projeto
- Draft
Analisar e selecionar técnicas para implementação
- Draft
Aplicar método de detecção de pontos e linhas
- Draft
Aplicar método de detecção de bordas
- Draft
Aplicar método de limiarização
- Draft
Aplicar método piramidal
- Draft
Aplicar método de detecção de bacias
- Draft
Aplicar método k-means

+ Add item

Todo 1 ...

Draft: Realizar testes no aplicativo que realiza análise do grau de torra

+ Add item

In Progress 1 ...

Draft: Escrita da monografia

+ Add item

Done 9 ...

Draft: Preparar base de dados existente para utilizar no projeto

Draft: Analisar e selecionar técnicas para implementação

Draft: Aplicar método de detecção de pontos e linhas

Draft: Aplicar método de detecção de bordas

Draft: Aplicar método de limiarização

Draft: Aplicar método piramidal

Draft: Aplicar método de detecção de bacias

Draft: Aplicar método k-means

Draft: Realizar análise subjetiva das técnicas já implementadas

+ Add item

Todo 0 ...

+ Add item

In Progress 2 ...

- Draft
Escrita da monografia
- Draft
Análise Quantitativa

+ Add item

Done 10 ...

- Draft
Preparar base de dados existente para utilizar no projeto
- Draft
Analisar e seleccionar técnicas para implementação
- Draft
Aplicar método de detecção de pontos e linhas
- Draft
Aplicar método de detecção de bordas
- Draft
Aplicar método de limiarização
- Draft
Aplicar método piramidal
- Draft
Aplicar método de detecção de bacias
- Draft
Aplicar método k-means
- Draft
Realizar análise subjetiva das técnicas já implementadas
- Draft
Realizar testes no aplicativo que realiza análise do grau de torra

+ Add item

+

The image shows a Kanban board with three columns: 'Todo', 'In Progress', and 'Done'. Each column has a header with a count and a plus icon for adding items. The 'In Progress' column contains one item, and the 'Done' column contains eleven items. Each item is a 'Draft' card with a title and a plus icon for adding more items.

Column	Count	Item Title
Todo	0	+ Add item
In Progress	1	Escreita da monografia
Done	11	Preparar base de dados existente para utilizar no projeto
Done	11	Analisar e seleccionar técnicas para implementação
Done	11	Aplicar método de detecção de pontos e linhas
Done	11	Aplicar método de detecção de bordas
Done	11	Aplicar método da limiarização
Done	11	Aplicar método piramidal
Done	11	Aplicar método de detecção de bacias
Done	11	Aplicar método k-means
Done	11	Realizar análise subjetiva das técnicas já implementadas
Done	11	Realizar testes no aplicativo que realiza análise do grau de torra
Done	11	Análise Quantitativa

Todo 0 ...

In Progress 0 ...

Done 12 ...

- Analisar e selecionar técnicas para implementação
- Draft
Aplicar método de detecção de pontos e linhas
- Draft
Aplicar método de detecção de bordas
- Draft
Aplicar método de limiarização
- Draft
Aplicar método piramidal
- Draft
Aplicar método de detecção de bacias
- Draft
Aplicar método k-means
- Draft
Realizar análise subjetiva das técnicas já implementadas
- Draft
Realizar testes no aplicativo que realiza análise do grau de torra
- Draft
Análise Quantitativa
- Draft ...
Escrita da monografia

+ Add item

+ Add item

+ Add item