

INSTITUTO FEDERAL DO ESPÍRITO SANTO  
ENGENHARIA DE CONTROLE E AUTOMAÇÃO

**BRUNO MESCHIATTI VASCONCELLOS**

**CLASSIFICAÇÃO DE GRÃOS DE CAFÉ USANDO VISÃO COMPUTACIONAL  
ALIADO AO MACHINE LEARNING**

SERRA  
2022

BRUNO MESCHIATTI VASCONCELLOS

**CLASSIFICAÇÃO DE GRÃOS DE CAFÉ USANDO VISÃO COMPUTACIONAL  
ALIADO AO MACHINE LEARNING**

Trabalho de Conclusão de Curso apresentado à Coordenadoria do Curso de Engenharia de Controle e Automação do Instituto Federal do Espírito Santo, Campus Serra, como requisito parcial para a obtenção do título de Bacharel em Engenharia de Controle e Automação.

Orientador: Prof. Dr. Gustavo Maia de Almeida.

SERRA

2022

## Dados Internacionais de Catalogação na Publicação (CIP)

---

V331c Vasconcellos, Bruno Meschiatti  
2022 Classificação de grãos de café usando visão computacional  
aliado ao machine learning / Bruno Meschiatti Vasconcellos. - 2022.  
58 f.; il.; 30 cm

Orientador: Prof. Dr. Gustavo Maia de Almeida.  
Monografia (graduação) - Instituto Federal do Espírito Santo,  
Coordenadoria de Automação, Curso de Graduação em Engenharia  
de Controle de Automação, 2022.

1. Visão por computador. 2. Café - Classificação. 3. Aprendizado  
do computador. 4. Sistemas de reconhecimento de padrões. I.  
Almeida, Gustavo Maia de. II. Instituto Federal do Espírito Santo. III.  
Título.

CDD 006.37

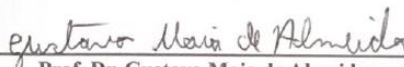
BRUNO MESCHIATTI VASCONCELLOS

**CLASSIFICAÇÃO DE GRÃOS DE CAFÉ USANDO VISÃO COMPUTACIONAL ALIADO  
AO MACHINE LEARNING**

Trabalho de Conclusão de Curso apresentado como parte das atividades para obtenção do título de Bacharel em Engenharia de Controle e Automação, do curso de Engenharia de Controle e Automação do Instituto Federal do Espírito Santo.

Aprovado em 13 de outubro de 2022.

**COMISSÃO EXAMINADORA**



**Prof. Dr. Gustavo Maia de Almeida**  
Instituto Federal do Espírito Santo  
Campus Serra



**Prof. Dr. Marco Antônio de Souza Leite Cuadros**  
Instituto Federal do Espírito Santo  
Campus Serra



**Prof. Dr. Daniel Cruz Cavaliere**  
Instituto Federal do Espírito Santo  
Campus Serra

Para todos aqueles que estiveram comigo durante esse curso.

## **AGRADECIMENTOS**

O desenvolvimento desse trabalho de conclusão de curso contou com a ajuda de diversas pessoas, dentre as quais eu agradeço:

Ao professor orientador e membros do grupo de pesquisa, que sempre me ajudaram pontualmente, do início ao fim.

Aos professores do IFES, que através dos seus ensinamentos permitiram que eu aprendesse não só conhecimentos técnicos, mas habilidades interpessoais que só um local plural como a faculdade ensina.

Aos meus amigos, onde sempre houve apoio e compreensão.

Aos meus pais, que ajudaram como uma força imparável e incentivaram em todos os momentos.

## RESUMO

O agronegócio mundial do café engloba, anualmente, recursos que chegam a 91 bilhões de dólares e envolve meio bilhão de pessoas. É nesse mercado gigantesco que está centrado o interesse da cadeia produtiva do café brasileiro, que contribuiu com mais de 30% da produção mundial nas últimas safras. O mercado do café é caracterizado por um conjunto de atividades de enorme complexidade, dinamismo, e um crescente nível de exigência dos consumidores quanto à qualidade da bebida. Isso impõe aos países produtores, consumidores e exportadores um elevado controle de qualidade. Atualmente, a definição da qualidade e, portanto, do valor do café é baseada na classificação manual, ou seja, uma pessoa exerce o papel de um classificador treinado (certificado) para qualificar as amostras de café. Assim, o processo atual de classificação de café sofre com a subjetividade dos classificadores e uma grande dificuldade de padronização do processo devido a possíveis inconsistências. O presente trabalho propõe o uso de aprendizado não-supervisionado de máquina, através de clusterização (K-Means) para análise de amostras de café em grãos pela análise de imagens digitais, a fim de se aumentar a velocidade e reduzir as subjetividades envolvidas no atual processo manual de classificação, considerando: forma, tamanho e cor. Dentre os benefícios da automação do processo de classificação de café destacam-se a redução de custos, a agilidade e a padronização da classificação.

Palavras-chave: Aprendizagem de Máquinas. Visão Computacional. K-Means. KNN. White-Patch.

## **ABSTRACT**

The world's coffee agribusiness is worth US \$ 91 billion annually and involves a half billion people. It is in this gigantic market that the interest of the Brazilian coffee production chain is placed, which contributed with more than 30% of the world production in the last harvests. The coffee market is characterized by a combination of activities of enormous complexity, dynamism, and a growing level of consumer demand for beverage quality. This imposes a high-quality control on producing, consuming and exporting countries. Currently, the definition of quality and hence the value of coffee is based on manual grading, so, a person performs the role of a trained (certified) classifier to qualify coffee samples. Thus, the current coffee grading process suffers from the subjectivity of the classifiers and a great difficulty to pave the process due to possible inconsistencies. The present work proposes the use of Fuzzy Logic for the analysis of coffee bean samples by digital image analysis, in order to increase the speed and reduce the subjectivities involved in the current manual classification process, shape, size and colour. Among the benefits of the automation of the coffee classification process are the reduction of costs, the agility and the standardization of the classification.

Keywords: Machine Learning. Computer Vision. K-Means. KNN. White-Patch.



## LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplo de KNN, $k = 3$ .	19
Figura 2 - Dados clusterizados de acordo com suas grandezas.	20
Figura 3 – Ilustração do método hold-out.	22
Figura 4 – Exemplo de k-fold com $k = 5$ .	23
Figura 5 – Exemplo de matriz de confusão.	24
Figura 6 – Mesa iluminada com especialista em classificação trabalhando.	28
Figura 7 – Cartolina preta graduada.	29
Figura 8 – Combinação das cores vermelha, verde e azul.	31
Figura 9 - Imagem utilizada para segmentação em escala de cinza.	32
Figura 10 – Exemplo de binarização com imagem original acima.	33
Figura 11 – Amostras de café recebidas.	36
Figura 12 – Grãos dispostos sem se tocar sobre folha branca.	37
Figura 13 – Imagens dos grãos separados individualmente em pasta.	38
Figura 14 – Imagem de grão após a binarização, sem mais interferência do fundo da figura.	39
Figura 15 – Imagem de grão com suas características em valores numéricos ao lado.	40
Figura 16 – 5 primeiras linhas da base de dados em CSV.	41
Figura 17 – Grão bom segmentado.	48
Figura 18 – Grão brocado segmentado.	48
Figura 19 – Grão marinheiro segmentado.	48
Figura 20 – Da esquerda para a direita: Imagem original e Imagem com <i>White-Patch</i> .	52

## LISTA DE TABELAS

Tabela 1 – Tipo de produto por quantidade de defeitos. ....	26
Tabela 2 – Equivalência de defeitos.....	27
Tabela 3 – Totalização das amostras.....	41
Tabela 4 – Matriz de Confusão do K-Means. ....	46
Tabela 5 – Métricas de desempenho utilizando o algoritmo K-Means. ....	47
Tabela 6 – Matriz de Confusão utilizando o algoritmo KNN e Hold-out.....	49
Tabela 7 – Métricas de desempenho utilizando o algoritmo KNN e Hold-out. ....	50
Tabela 8 – Acurácia geral utilizando o algoritmo KNN e K-fold = 5.....	51
Tabela 9 – Métricas de desempenho utilizando o algoritmo <i>K-Means</i> com as imagens após <i>White-Patch</i> .....	53

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>11</b>
1.1 OBJETIVOS .....	12
1.1.1 Objetivo geral .....	12
1.1.2 Objetivo específico.....	13
1.2 ESTADO DA ARTE .....	13
<b>2 REFERENCIAL TEÓRICO</b> .....	<b>16</b>
2.1 INTRODUÇÃO AO MACHINE LEARNING .....	16
2.1.1 Aprendizado supervisionado .....	16
2.1.2 Aprendizado não-supervisionado.....	17
2.2 ALGORITMOS .....	17
2.2.1 K-Nearest Neighbors (KNN).....	18
2.2.2 Clusterização pelo método K-Means.....	19
2.3 MÉTODOS DE VALIDAÇÃO .....	20
2.3.1 Hold-out.....	21
2.3.2 K-Fold .....	22
2.4 MATRIZ DE CONFUSÃO.....	23
2.5 ACURÁCIA.....	24
2.6 PRECISÃO.....	25
2.7 CLASSIFICAÇÃO DE CAFÉ .....	25
2.7.1 Classificação por tipo .....	25
2.7.2 Tipos de grãos.....	29
<b>3 INTRODUÇÃO A VISÃO COMPUTACIONAL</b> .....	<b>30</b>
3.1 SISTEMA RGB.....	30
3.2 GRAYSCALE .....	32
3.3 LIMARIZAÇÃO AUTOMÁTICA E BINARIZAÇÃO DE OTSU .....	33
3.4 EXTRAÇÃO DE CARACTERÍSTICAS .....	34
<b>4 METODOLOGIA</b> .....	<b>35</b>
4.1 AMOSTRAS DE CAFÉ.....	35
4.2 MÉTODO.....	36
4.3 AQUISIÇÃO DE IMAGENS .....	37
4.4 SEGMENTAÇÃO .....	38
4.5 ATRIBUTOS IDENTIFICADOS .....	39
4.6 CRIAÇÃO DE BASE DE DADOS.....	40

4.7 IMPLEMENTAÇÃO DOS ALGORITMOS.....	42
<b>4.7.1 Implementação no algoritmo K-Means.....</b>	<b>42</b>
<b>4.7.2 Implementação no algoritmo KNN.....</b>	<b>43</b>
<b>5 RESULTADOS E DISCUSSÃO.....</b>	<b>45</b>
5.1 CLASSIFICAÇÃO POR K-MEANS.....	45
5.2 CLASSIFICAÇÃO POR KNN.....	49
5.3 ALGORITMO WHITE-PATCH.....	51
<b>6 CONCLUSÕES.....</b>	<b>54</b>
<b>REFERÊNCIAS.....</b>	<b>55</b>

## 1 INTRODUÇÃO

Desde o século XIX o Brasil se mostra como um grande destaque na produção e exportação de café, tendo períodos de bonança econômica justificada em muitos momentos graças aos rendimentos provenientes do grão. Já nos dias de hoje, o país é responsável por 37% da produção mundial, e isso o torna, de longe, o maior produtor e exportador no mercado mundial (ICO, 2020).

No estado do Espírito Santo, a história mostra a correlação, nos primórdios do século XIX o café chegava pela região Sul, trazidos pela expansão dos campos vindo da região de plantio fluminense (INCAPER, 2004). Já na metade do século, o estado se consolidava como um dos grandes produtores nacionais, o que se mantém até os dias de hoje, sendo a principal atividade agrícola do estado, com atuação em todos os municípios (fora a capital). O café também traz grande importância para as famílias capixabas, gerando 400 mil empregos diretos e indiretos.

O Espírito Santo é o maior produtor de café conilon do país, sendo responsável por acima de 70% do grão que é cultivado no país. (INCAPER, 2022)

Tal soberania, tanto do estado, como do país, não os torna alheios aos altos padrões de qualidade desenvolvidos no mercado mundial, que submete os grãos a rigorosos testes, onde estes devem ser bastante precisos e com grande fluidez - visto o alto volume produtivo-. Esse controle é imposto em vários estágios da produção, e as cooperativas enfrentam essa fase com certa adversidade ao avaliar as safras.

O café beneficiado grão cru é o endosperma do fruto de espécies do gênero *Coffea*, ele é avaliado através de amostragem da saca por um operador para a checagem de defeitos, ou seja, anomalias que possam o caracterizar como não-saudável. A quantidade e o grau de defeitos achados são atribuídos a pesos e ao final é dada uma classificação geral para aquela amostra (REVISTA CAFEICULTURA, 2004).

Essa abordagem é feita de forma visual, e muitas vezes sujeita a fadiga do avaliador, o que pode torná-la imprecisa e inexata, e assim trazer prejuízos para o produtor (SENAR, 2005).

Com o avanço do processamento computacional, o uso de técnicas de machine learning tem se tornado cada vez mais comuns em processos visando classificar os dados disponíveis (GOODFELLOW, 2016).

Devido a esse maior poder computacional e aliado ao crescimento de tecnologias de imagem surge também a visão computacional, um método para retirar informações e características provenientes de uma imagem recebida, e com isso pode-se automatizar diversos processos que antes eram necessários a presença de um operador humano.

Com isso em mente, e tendo em vista o grande potencial produtivo da região, é de grande importância que se desenvolvam novas tecnologias com a finalidade de auxiliar o trabalho da cooperativa e assim reduzir incertezas e atrasos trazidos por avaliações manuais. Este trabalho então visou a utilização de algoritmos de machine learning para a análise e classificação de amostras de café em grãos e a utilização de técnicas de visão computacional como meio para adquirir as características necessárias.

## 1.1 OBJETIVOS

### 1.1.1 Objetivo geral

Estudar e desenvolver de um classificador de grãos de café através de algoritmos de *machine learning*: clusterização e vizinhos semelhantes.

### 1.1.2 Objetivo específico

São objetivos específicos desse trabalho:

- Estudar visão computacional com a linguagem de programação Python.
- Estudar técnicas de *machine learning*.
- Desenvolver algoritmo classificador por clusterização.
- Desenvolver algoritmo classificador por vizinhos semelhantes.
- Avaliar as métricas de resultados dos algoritmos classificadores.
- Propor melhoria para a indústria cafeeira.

## 1.2 ESTADO DA ARTE

No que tange a classificação de grãos e sementes via imagem, o tema já foi bastante explorado por grupos de pesquisa e desenvolvedores de produtos, porém quando se fala da junção das técnicas de *machine learning* e classificação de café vemos que não existem muitos trabalhos relacionados na literatura. A seguir vamos traçar um panorama geral desses estudos:

No trabalho de Carrillo e Peñaloza (2009) foram construídos classificadores utilizando a distância de Mahalanobis para identificar seis classes de um grão de café. Usando um conjunto de amostras, foram encontrados os valores RGB dos pixels das amostras e posteriormente divididos em classes. Então foi verificada a distância de Mahalanobis da amostra para os agrupamentos padrão e se classificava-se igual ao agrupamento onde a distância se mostrava de menor valor. Seu resultado mostrou assertividade próxima aos 90% com as seis classes.

Chen et al. (2010) desenvolveram um classificador de grãos de milho de cinco classes diferentes usando um digitalizador de mesa. Foram extraídos atributos geométricos como a área, perímetro, comprimento e larguras dos grãos em diferentes locais. Foi tratada a cor transformando de RGB para outros quatro tipos: RGB normalizado, YCbCr, I1I2I3 e HSV e então, posteriormente, foram calculados desvios padrões e médias de componentes desses espaços de cor. A classificação foi feita de duas formas: Uma utiliza-se também da distância de Mahalanobis e o outro consistiu na criação de uma rede neural MLP.

Delwiche, Yang e Graybosch (2013) propuseram um trabalho para a classificação binária de grãos de trigo, porém as imagens de entrada seriam tomadas de orientações diferentes.

Valiente-Gonzalez et al (2014) trouxeram um classificador de grãos de milho usando visão computacional. A abordagem se baseava em analisar os pixels ruins na imagem e os bons, criando assim uma proporção que definiria a classificação do grão.

Ahmad et al (2010) revelaram um dispositivo para diferenciar automaticamente grãos de café utilizando a visão computacional. O modelo tinha a intenção de classificar entre quatro tipos de grãos, três bons sendo divididos pelo seu tamanho e um reprovado sendo diferenciado pelo tamanho e cor. Para passar esses atributos de forma que o classificador pudesse compreender logicamente, foram usados como entrada a área, o comprimento e a cor.

Faridah, Parikesit e Ferdiansjah (2013) trouxeram um método utilizando um algoritmo de rede neural PMC, o objetivo seria a criação de um classificador de café completo, englobando o grão em sete categorias. A entrada para o classificador foram as médias dos canais de cor RGB e quatro descritores de Haralick (energia, entropia, contraste e homogeneidade).



No trabalho de Pizzaia et al. (2018) foi proposto uma rede neural Perceptron Multicamadas (MLP) para classificar os grãos. Os atributos utilizados foram: forma, tamanho e cor. Todos os grãos passados para as imagens foram classificados anteriormente por especialistas. Primeiramente essas imagens foram segmentadas pela binarização de Otsu e em seguida obtido os atributos computacionalmente. Ao treinar a rede MLP com tais dados, obteve-se uma média de 94% de acurácia.

Com Lube et al. (2021) foi possível ver o comportamento de uma rede neural do tipo Mask RCNN atuando frente a cinco tipos de grãos: brocados, marinho, preto, ruim e bom. Para melhorar seus resultados, foi utilizado a técnica de transferência de aprendizado com o *COCO dataset*. Sua média de acurácia ficou em 94,81% e sua precisão em 85,35%.

## 2 REFERENCIAL TEÓRICO

Nesta seção é discutido sobre os principais temas abordados neste trabalho.

### 2.1 INTRODUÇÃO AO MACHINE LEARNING

Utiliza-se o termo *machine learning* para referenciar a interação de uma máquina com uma quantidade satisfatória de dados de entrada, e como consequência a apresentação de uma resposta de classificação, diagnóstico, controle ou previsão. Isso se dá, principalmente, através do reconhecimento de correlações e padrões existentes na estrutura destes dados que nem sempre são triviais à percepção humana. Este computador então demonstra aprendizado toda vez que muda sua estrutura, programação ou dados para a realização de tarefas (NILSSON, 1998).

Há dois principais aprendizados: aprendizado supervisionado, aprendizado não-supervisionado (ABU-MOSTAFA *et al.*, 2012). Aqui discorreremos sobre eles.

#### 2.1.1 Aprendizado supervisionado

No método de aprendizado supervisionado, os dados que serão apresentados para a máquina foram classificados anteriormente por um especialista. O objetivo deste método é criar um modelo através de exemplos já rotulados. Um exemplo comum é o uso para a avaliação de e-mails como spam, só há duas classes possíveis: spam e não-spam. Então se expõe ao algoritmo mensagens das duas formas e já avaliadas, para que se possa fazer essa predição no futuro com alguma mensagem que ainda não houve interação. Dentre os métodos mais conhecidos estão: K-Nearest

Neighbor (KNN), Support Vector Machine (SVM), Regressão logística, Naive-Bayes e Árvore de decisão (VEMURI, 2020).

### 2.1.2 Aprendizado não-supervisionado

No modo não-supervisionado, o dado usado para o treinamento do modelo não contém nenhuma informação que classifique sua saída e assim o modelo tem que aprender por si só uma forma de rotular. As regiões de decisão podem ser idênticas àquelas que se tem no aprendizado supervisionado, porém agora o método e como agrupá-las se torna menos intuitivo. E o modo para solucionar é exatamente esse: agrupando. Todo dado estruturado contém um padrão, e ao achar esse padrão podemos agrupar ele aos seus semelhantes.

Pode-se dizer então que o aprendizado não-supervisionado é a tarefa de espontaneamente encontrar padrões e estruturas num determinado dado de entrada para assim classificá-lo de acordo com um grupo de semelhança (ABU-MOSTAFA *et al.*, 2012).

## 2.2 ALGORITMOS

Como este trabalho busca uma possível solução autônoma para a classificação de grão cru de café, temos então que nossa saída esperada se dará em forma de classes possíveis que o grão pode vir a ter, ou seja, precisamos de um algoritmo do tipo classificador.

Foram então escolhidos dois tipos de algoritmos de *machine learning*, um supervisionado e outro não-supervisionado, para a realização dos testes com o dataset disponível e apuração da acurácia. Estes algoritmos foram o KNN e a

Clusterização pelo método *K-Means*. Nesta seção é falado sobre eles e suas particularidades.


### **2.2.1 K-Nearest Neighbors (KNN)**

O KNN é um algoritmo supervisionado, ou seja, utiliza-se dados de treinamento e seus rótulos para poder realizar suas classificações futuras. É considerado um dos tipos mais simples de algoritmos de classificação e não demandam um alto poder computacional para realizar as operações.

Sua definição baseia-se no uso de uma métrica, usualmente euclidiana, para se calcular a distância entre os dados postos ao treinamento e assim, ao se colocar um novo elemento para ser realizada a predição de sua suposta classe, é procurado os  $k$  vizinhos mais próximos dele e se contabiliza um voto de acordo com o peso de sua distância (GOLDBERGER *et al*, 2005).

A Figura 1 ilustra a inserção de um elemento novo representado por um losango num plano com os dados do treino sendo representados por círculos de classe vermelha e azul e tendo o valor  $k = 3$ . Com esses argumentos, o losango será classificado com base nos seus 3 vizinhos mais próximos - que são mostrados dentro do círculo - para cada vizinho circulado será calculada a distância euclidiana e receberá um peso para sua classe na classificação do novo elemento.

Figura 1 – Exemplo de KNN,  $k = 3$ .



Fonte: Do autor.

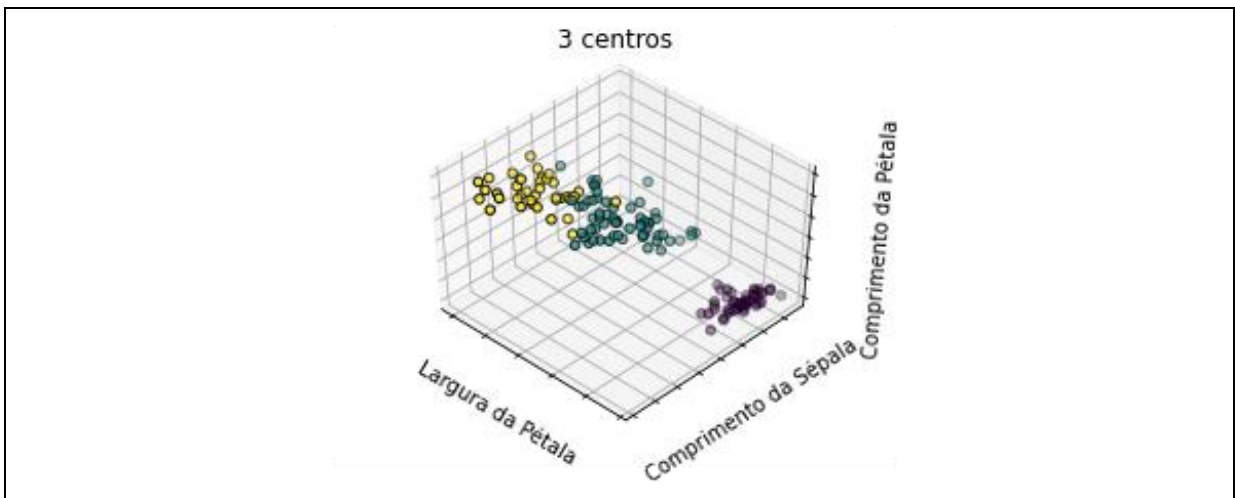
### 2.2.2 Clusterização pelo método *K-Means*

O agrupamento utilizando o algoritmo K-Means tem como meta classificar os dados de acordo com seus semelhantes a partir da distância euclidiana e um número de classes. Primeiramente recebe-se o número de centros que estamos tentando dividir os dados, esses centros podem ser distribuídos de forma randômica ou através de parâmetros passados na função. Feito isso, há a iteração sobre todos os pontos dos dados. Esses pontos então vão pertencer ao centro mais próximo a eles.

Ao mudar de iteração, esse centro se move para o centróide dos pontos que lhe pertencem. Essas iterações se repetem até que o movimento dele cesse ou seja mínimo (Meila, 2006).

A Figura 2 abaixo ilustra a utilização do algoritmo para a classificação no famoso dataset Iris, que contém 3 tipos de flor (Iris Setosa, Iris Versicolour, Iris Virginica) e essas são classificadas ao receber como parâmetro de entrada o comprimento da pétala, a largura da pétala e o comprimento da sépala.

Figura 2 - Dados clusterizados de acordo com suas grandezas.



Fonte: Do autor (Google Colab – 2022).

## 2.3 MÉTODOS DE VALIDAÇÃO

Para validar nosso modelo de classificação construído e assim verificar sua eficácia ao rotular dados que ele não teve contato prévio, ou seja, mensurar sua capacidade de generalização, há vários métodos disponíveis, mas aqui discorreremos sobre a validação cruzada e seus três métodos utilizados no trabalho.

A validação cruzada é um método estatístico de avaliar e comparar os modelos de aprendizado, este baseia-se em dividir os dados em grupos de treino e teste e os levar para realizar a criação do modelo. Numa iteração o grupo de teste é apenas usado para validar o nosso classificador ou regressor, assim simulando sua capacidade de generalização no mundo real.

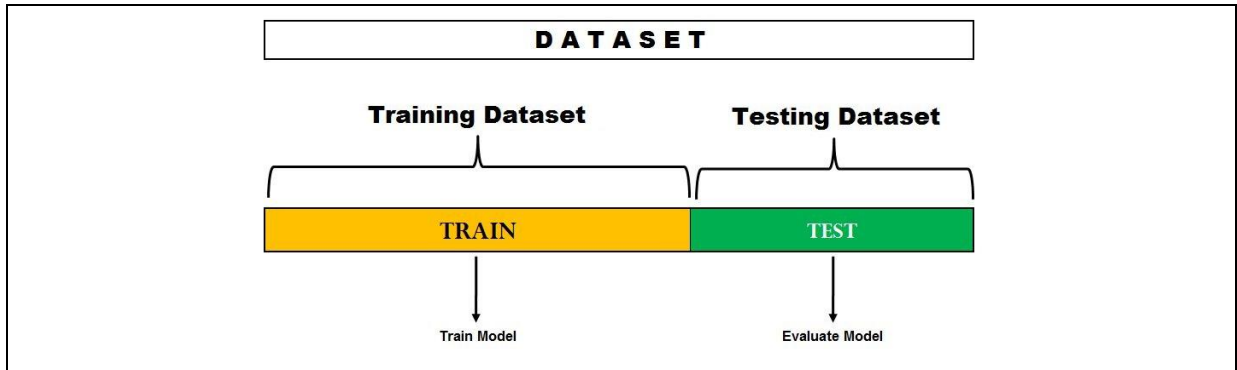
### 2.3.1 Hold-out

Também conhecido como *train-test split*, esse método baseia-se na divisão dos dados disponíveis em um grupo de treino e outro de teste. Os dados de teste são separados e não são utilizados pelo classificador durante o treino. Então o classificador é modelado de acordo com os dados de treino e depois é validado usando as métricas de validação ao fazer a predição para os dados de teste.

A vantagem de utilizar o *hold-out* é que temos assim uma separação clara entre os dados que vamos usar para a criação do modelo e os dados que serão usados para validá-lo, ou seja, podemos testar sua capacidade de generalização ao encontrar com dados que ele nunca teve nenhum tipo de contato antes. Porém, também há um lado negativo em sua utilização. Ao separarmos os dados, podemos acabar criando grandes variações de classes e assim o grupo de treino pode acabar recebendo muito de um tipo e pouco de outro, originando um problema para a generalização futura. Seu uso também não é aconselhado para datasets pequenos, visto que a divisão diminui ainda mais os dados que poderiam ir para a modelagem (REFAEILZADEH et al, 2009).

Na Figura 3 é mostrado o método hold-out, com a parte separada para o treino ilustrada na cor laranja e a parte separada para o teste ilustrada na cor verde. Percebe-se então que se trata de uma separação simples. Dados de treino nunca viram de teste e nem o inverso.

Figura 3 – Ilustração do método hold-out.



Fonte: <https://datavedas.com/wp-content/uploads/2018/04/image001.jpg>.

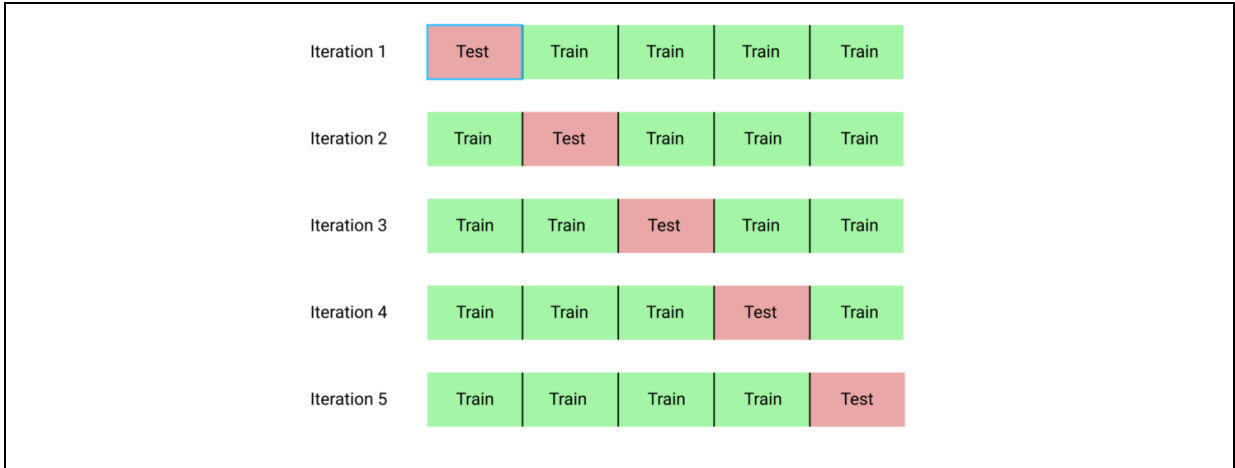
### 2.3.2 K-Fold

O método mais básico de validação cruzada é o k-fold, que consiste na separação do dataset em k grupos de tamanhos iguais, onde uma parte vai atuar como teste e k-1 grupos atuarão como integrantes do treino. Após feito a avaliação das métricas, o grupo pertencente ao teste passa a integrar o treino, e assim um grupo anteriormente escolhido como treino será utilizado como teste. Ao final das iterações e com todas as partições tendo participado uma vez como o conjunto de teste, suas métricas são contabilizadas e será retirada a média, nos dando assim uma visão mais real do comportamento desse classificador (REFAEILZADEH *et al*, 2009).

A Figura 4 traz a estrutura do k-fold. Todo o dataset é dividido em 5 partes ( $k = 5$ ) e a cada iteração  $1/5$  é usado como teste e o resto para treino. Dessa forma, todos os dados são usados em teste e treino, porém em iterações diferentes.



Figura 4 – Exemplo de k-fold com k = 5.



Fonte: <https://towardsdatascience.com/cross-validation-explained-evaluating-estimator-performance-e51e5430ff85>

## 2.4 MATRIZ DE CONFUSÃO

A matriz de confusão, também conhecida como matriz de classificação, é uma representação visual dos resultados provenientes de uma classificação e dela podem ser tiradas várias informações úteis para validar nosso modelo a ser testado. Essas informações possíveis de serem retiradas são denominadas de Métricas de Validação, e são elas: acurácia, precisão, recall e f-score.

A matriz, constituída de linhas e colunas, nos proporciona a visualização de verdadeiros positivos, falsos positivos, falsos negativos e verdadeiros negativos, podendo assim proporcionar uma análise visual de quantos dados foram acertados e quantos foram classificados erroneamente, o que é de suma importância durante o processo de construção de um modelo (THARWAT, 2018).

A Figura 5 mostra uma matriz de confusão, salientando a nomenclatura dada na interação dos dois eixos: Real e Detectada.

Figura 5 – Exemplo de matriz de confusão.

		Detectada	
		Sim	Não
Real	Sim	Verdadeiro Positivo (VP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (VN)

Fonte: <https://medium.com/@vitorborbarodrigues/m%C3%A9tricas-de-avalia%C3%A7%C3%A3o-acur%C3%A1cia-precis%C3%A3o-recall-quais-as-diferen%C3%A7as-c8f05e0a513c>.

## 2.5 ACURÁCIA

A acurácia se mostra como a métrica mais fundamental para classificações por permitir uma visualização simples da validação do modelo. Ela é a proporção de classificações corretas pelo total de classificações daquele domínio. Ou seja, um classificador que se mostra com 80% de acurácia tem, por definição, um acerto de 80 objetos a cada 100 que serão classificados (THARWAT, 2018). Porém, essa simplicidade pode trazer um problema, imagine que temos um *dataset* de compras de cartão de crédito de 500.000 casos, onde 490 mil são normais e 10 mil são fraudulentos. Um modelo que classificasse tudo como normal, teria 98% de acurácia. Logo não é uma métrica definitiva para *datasets* não balanceados.

## 2.6 PRECISÃO

Por mais que haja confusões acerca dos termos, a precisão nos entrega uma informação diferente da acurácia. Ao utilizar a precisão como métrica, temos a visualização de quantos resultados positivos recebidos são realmente positivos. Sendo assim, a precisão é uma métrica para se utilizar quando é necessário um rigor maior no que diz respeito aos falsos positivos (THARWAT, 2018).

Tomando como o exemplo uma classificação de cores, falsos positivos serão problemáticos por exigirem um maior controle de qualidade manual no final do processo, é custoso, porém pode ser algo que não seja de extrema importância a depender do valor da precisão. Já um falso positivo em um diagnóstico médico tem de ser tratado com extremo rigor, visto o impacto desse resultado para o paciente, ou seja, a precisão e sensibilidade, nesse caso, tem de ser extremamente altas.

## 2.7 CLASSIFICAÇÃO DE CAFÉ

A classificação manual de café é o modelo mais realizado na maioria das cooperativas atualmente. Nesta seção será aprofundado sobre o tema.

### 2.7.1 Classificação por tipo

No Brasil é realizada a classificação por tipo e qualidade, sendo a de qualidade referente ao gosto e outras características sensoriais da bebida já pronta. A classificação que trataremos será a por tipo, que se refere a defeitos visuais do grão de café após o descascamento.

Esse tipo de classificação consiste na contagem de grãos defeituosos e de impurezas em uma amostra de 300g de café. Proporcionalmente ao número de defeitos encontrados, são definidos o tipo que o café será denominado e sua porcentagem de catação, conseqüentemente, seu valor é definido.

Na Tabela 1 temos o tipo de café que ele será denominado após a contagem de todos os defeitos. E na Tabela 2 mostra o valor de cada defeito que pode ser encontrado de acordo com a Classificação Oficial Brasileira (COB).

Tabela 1 – Tipo de produto por quantidade de defeitos.

Tipo	Soma de defeitos
2	4 - 11
3	12 - 25
4	26 - 44
5	46 - 79
6	86 - 153
7	160 - 340
8	360

Fonte: SENAR (2017).

Tabela 2 – Equivalência de defeitos.

Grãos Imperfeitos/Impurezas	Número de defeitos
1 grão preto	1
2 grãos ardidos	1
2 a 5 grãos brocados	1
3 grãos concha	1
5 grãos verdes	1
5 grãos quebrados ou esmagados	1
5 grãos chochos ou mal granados	1
1 pedra, pau ou torrão grande	5
1 pedra, pau ou torrão regular	2
1 pedra, pau ou torrão pequeno	1
1 coco	1
1 casca grande	1
2 a 3 cascas pequenas	1
2 marinheiros	1

Fonte: SENAR (2017).

O processo de contagem desses defeitos e impurezas é manual. Após a amostra ser recolhida, os grãos são espalhados numa cartolina preta sob mesa iluminada. Os grãos são separados um a um através da catação. Na Figura 6 temos a mesa iluminada e na Figura 7 há a cartolina preta graduada.

Figura 6 – Mesa iluminada com especialista em classificação trabalhando.



Fonte: SENAR, 2017.

Figura 7 – Cartolina preta graduada.



Fonte: SENAR, 2017.

### 2.7.2 Tipos de grãos

Devido a disponibilidade dos grãos recebidos, esse trabalho focou seu desenvolvimento em classificar os seguintes tipos de grãos:

- Grão bom: Grãos com uniformidade de cor e forma, sem apresentar nenhuma imperfeição significativa.
- Grão escuro: Grão ou pedaço de grão de coloração preta ou opaca.
- Grão brocado: Grão danificado pela praga conhecida como broca-do-café. Causando orifícios na camada exterior.
- Grão marinheiro: Grão cujo o pergaminho não foi totalmente retirado no beneficiamento.

### 3 INTRODUÇÃO A VISÃO COMPUTACIONAL

TRIVEDI e ROSENFELD (1989) definem: “visão computacional é a disciplina que investiga as questões computacionais e algorítmicas associadas à aquisição, ao processamento e à compressão de imagens”.

Tendo tal conceito em vista, podemos então conectar visão computacional a quando ocorre qualquer tipo de resposta que a máquina chega tendo como entrada uma ou mais imagens.

Com o avanço do processamento presente nos computadores possibilitando o desenvolvimento do *machine learning*, ocorre uma aproximação dos pesquisadores de visão computacional para se unir a essa área e assim ter resultados melhores e menos presos a conjuntos de regras criadas mecanicamente (FISHER, 1994).

Nesta seção falaremos um pouco dos principais termos associados à visão computacional e que foram utilizados no desenvolvimento do trabalho. São eles: o sistema RGB, sistema *Grayscale*, limiarização e a extração de características.

#### 3.1 SISTEMA RGB


A coloração dos objetos entrega as mais básicas informações para a percepção humana. Cor é também elementar como informação que é ativada nos pixels que constituem a imagem digital. Logo, a cor é uma das principais características para medição de objetos, interpretação de imagens e detalhamento de itens (SUN et al, 2006).



A nomenclatura RGB vem do inglês tendo as letras explicadas como: vermelho (Red), verde (Green), azul (Blue). Ao combinar essas cores é possível reproduzir um largo espectro cromático. Uma de suas principais funções desse sistema no mundo atual é a reprodução de cores em dispositivos eletrônicos, como em monitores de computador (HUNT, 1991).

Na Figura 8 é mostrada uma ilustração com a combinação das cores RGB.

Figura 8 – Combinação das cores vermelha, verde e azul.



Fonte: <https://www.hisour.com/pt/rgb-color-model-24867/>.

Em computadores é variado dentro de cada pixel esses três canais de cores, em uma escala de 0 a 255, onde sua junção gera uma cor resultante dentro do espectro possível. Sendo assim, é possível fazer análises cromáticas apenas acessando a matriz de pixels de uma imagem.

### 3.2 GRAYSCALE

Uma das formas mais rudimentares de aquisição de imagem é através da escala de cinza (*grayscale*). Tal forma consiste em representar as cores numa mistura de branco e preto. Nesse método de captura, o preto é representado por 0 e o branco por 255 (HUNT, 1991).

Esse tipo de representação é muito utilizado quando se é necessária uma unificação de objetos para sua detecção das bordas e conseqüente separação do fundo.

A Figura 9 traz um exemplo de imagem passada para a escala de cinza com o intuito de segmentar. Na esquerda temos a versão original e colorida, na direita possuímos a imagem convertida à *grayscale*.

Figura 9 - Imagem utilizada para segmentação em escala de cinza.




Fonte: SERT, 2014.

### 3.3 LIMIAZIZAÇÃO AUTOMÁTICA E BINARIZAÇÃO DE OTSU

Ao trabalhar com a segmentação de objetos presentes numa imagem, é muito comum binarizar a imagem, para assim conseguir separar o fundo do objeto em questão. Porém, um grande problema presente para ter efetividade nessa ação é a escolha do limiar de binarização (*threshold*), ou seja, do valor onde se consegue se diferenciar de forma clara os dois itens (GAZZONI et al, 2006).

A Figura 10 traz um exemplo de binarização, mostrando o realce das bordas.

Figura 10 – Exemplo de binarização com imagem original acima.



Fonte: OTSU, 1979.

Para encontrar uma solução e que funcione sem intervenção humana, Otsu (1979) desenvolveu um método de seleção automática do limiar baseado nos valores encontrados na imagem em escala de cinza a ser realizada para segmentação. A ideia central desse método é a separação do histograma da imagem em dois clusters com o valor de limiar definido como o resultado da minimização da variância ponderada das classes.

### 3.4 EXTRAÇÃO DE CARACTERÍSTICAS

Com o trabalho de reconhecimento do objeto feito, é importante a extração das características que serão utilizadas para a tomada de decisões futuras. Essas características podem ser denominadas como:

- Forma: São as propriedades dimensionais tanto mais simples das formas, como a Área, Perímetro, Raios, Número de furos, Número de vértices. Tanto como inclui exemplos mais sofisticados, que incluem a morfologia matemática, tais como: Número de Euler, Centro Geométrica e Momentos (CONCI, 2007).
- Aspecto: São as propriedades da internalidade da forma, como a rugosidade, cor e textura (CONCI, 2007).

Com essas informações à disposição, é possível a alimentação da entrada de um classificador, permitindo que seja feita a distinção entre um grupo de objetos, definindo se eles são semelhantes ou não.

## 4 METODOLOGIA

Nessa seção será citado a respeito dos materiais e métodos utilizados no projeto.

### 4.1 AMOSTRAS DE CAFÉ

As amostras de café utilizadas para compor o banco de dados do projeto foram conseguidas através de uma parceria entre os IFES (Instituto Federal do Espírito Santo) dos campi da Serra e Alegre.

Os exemplares conseguidos pertenciam aos tipos bons e ruins, sendo o objetivo classifica-los em 4 tipos: bons, brocados, marinheiros e escuros. Todas as amostras foram separadas previamente por especialistas.

A Figura 11 mostra algumas das amostras de café recebidas.

Figura 11 – Amostras de café recebidas.



Fonte: Do autor.

## 4.2 MÉTODO

Para fins de comparação entre os dois principais métodos de aprendizado de máquina, foi escolhido para representar o aprendizado não-supervisionado o método de clusterização utilizando o algoritmo K-Means e para representação do aprendizado supervisionado, foi utilizado o método dos vizinhos mais próximos, utilizando o algoritmo KNN.

Como a entrada desses algoritmos é feito de forma numérica, foi utilizado a binarização de Otsu para separar o fundo das imagens e a ferramenta OpenCV foi a responsável pela extração dos atributos do grão, tais como: cor, tamanho, redondeza.

Após realizado o experimento, os resultados foram mostrados de acordo com as métricas de precisão e acurácia. Sendo também visualizados através de uma matriz de confusão.

### 4.3 AQUISIÇÃO DE IMAGENS

Para capturar a imagem dos grãos de forma sempre metódica, foi utilizado um suporte em madeira para fixar uma câmera e os grãos ficam abaixo dispostos e sem se encostar sobre uma folha de papel branco.

A Figura 12 mostra o método de fotografia, sempre com os grãos espalhados em folha branca.

Figura 12 – Grãos dispostos sem se tocar sobre folha branca.



Fonte: Do autor.

#### 4.4 SEGMENTAÇÃO

Devido a entrada dos dados nos algoritmos de predição serem sempre na forma numérica, se optou por separar os grãos e extrair as características deles individualmente, para obter melhor controle dos resultados. Dessa forma, cada imagem do grão foi nomeada de acordo com sua classe e uma numeração respectiva. Na Figura 13 temos os grãos segmentados e separados figura a figura.

Figura 13 – Imagens dos grãos separados individualmente em pasta.




Fonte: Do autor.

Após feita a divisão, foi realizada uma binarização de cor em cada imagem e retirado o fundo através da limiarização de Otsu, o resultado é visto na Figura 14. Esse método permitiu então que apenas o grão fosse considerado e enviado para a ferramenta OpenCV para extração de atributos.



Figura 14 – Imagem de grão após a binarização, sem mais interferência do fundo da figura.



Fonte: Do autor.

#### 4.5 ATRIBUTOS IDENTIFICADOS

Os principais atributos levados em consideração na avaliação manual dos especialistas se encontram na cor e na forma do grão (Revista Cafeicultura, 2007).

Pensando dessa forma e traduzindo para uma linguagem onde o código poderia compreender, foram extraídas as informações referentes a área, média de valor do canal de cor R, média do canal de cor G, média do canal de cor B e a redondeza de cada grão. Esses valores foram coletados através da utilização da ferramenta OpenCV no Python, e sua representação gráfica pode ser vista na Figura 15.

Figura 15 – Imagem de grão com suas características em valores numéricos ao lado.



Fonte: Do autor.

O valor da área assume o tamanho do espaço que o grão ocupa em relação a foto de 100x100, dando então o número em pixels ao quadrado.

A redondeza, vem do inglês *roundness*, onde o objeto assume um valor entre 0 e 1, sendo o valor de 1 um círculo perfeito.

Os canais R, G, B, conforme explicados anteriormente, assumem valores entre 0 e 255. Sendo 0 o valor onde não há nada desse canal no pixel e 255 o valor máximo que a cor poderia assumir. O valor de cada canal que aparece na imagem é, na verdade, uma média dos valores encontrados na área do grão.

#### 4.6 CRIAÇÃO DE BASE DE DADOS

Após a segmentação e a extração dos atributos foi necessária a construção de uma base de dados contendo apenas os valores de cada grão. Onde cada linha mostra as características de um único grão. Na Figura 16 conseguimos ver as 5 primeiras linhas do banco de dados, contendo como colunas as áreas, grau de redondeza e média dos canais de cor R, G e B.

Figura 16 – 5 primeiras linhas da base de dados em CSV.

	Area	Roundness	R	G	B
0	1686.5	0.860310	146.814374	91.722222	78.931217
1	1582.5	0.867122	154.086069	99.466282	87.618456
2	1476.0	0.875663	153.118258	95.830282	81.781296
3	1576.5	0.856058	148.290476	91.926190	80.050952
4	1462.5	0.870554	143.559487	85.235897	73.726667

Fonte: Do autor.

A totalização da base de dados mostrando todos os grãos contidos no *data-set* é mostrada na Tabela 3:

Tabela 3 – Totalização das amostras.

TIPO	QUANTIDADE
Bom	88
Brocado	41
Escuro	19
Marinheiro	14
<b>Total</b>	<b>162</b>

Fonte: Do autor.

## 4.7 IMPLEMENTAÇÃO DOS ALGORITMOS

Nessa seção será discutida a implementação dos dois algoritmos escolhidos para o desenvolvimento dos classificadores.

### 4.7.1 Implementação no algoritmo K-Means

O algoritmo usado para a implementação da clusterização (método não-supervisionado) foi desenvolvido em Python e faz parte de uma biblioteca denominada Scikit-Learn. O link do seu modelo está disponível em <https://scikit-learn.org/stable/modules/generated/sklearn.cluster.KMeans.html>.

As principais modificações usadas para o treinamento do modelo de classificação estão nos argumentos do número de clusters, o método de inicialização dos grupos e o número máximo de iterações que o modelo irá fazer para buscar a convergência.

No caso do modelo feito, foi escolhido o número de clusters igual a quatro, representando o número de classes de café que há nas nossas amostras.

O método de inicialização da posição dos clusters escolhidos foi o 'k-means++', que é um método mais inteligente na seleção, que promove uma maior velocidade de convergência do que seria possível na forma randômica.

Quanto ao número de iterações máximo foram testados diversos valores, porém foi mostrado que acima de 100.000 não há ganho nas métricas estabelecidas.

No método não-supervisionado não é necessária a validação cruzada, pois separar as amostras de treino e teste apenas fariam sentido quando se durante o treino o classificador tivesse acesso aos resultados reais da classificação.

O código desenvolvido está disponível no GitHub e é mostrado como um Jupyter Notebook. O link está disponível em: [https://colab.research.google.com/drive/1oya5wvoPiAtdmSeCADgPr-YEbfm\\_bp8k?usp=sharing](https://colab.research.google.com/drive/1oya5wvoPiAtdmSeCADgPr-YEbfm_bp8k?usp=sharing)

#### 4.7.2 Implementação no algoritmo KNN

Para o desenvolvimento do modelo classificador com treinamento supervisionado, foi adaptado o algoritmo KNN presente em <https://scikit-learn.org/stable/modules/generated/sklearn.neighbors.KNeighborsClassifier.html>.

O mesmo foi projetado em Python e faz parte, assim como o K-Means, da biblioteca Scikit-Learn.

As modificações necessárias no desenvolvimento se deram apenas na seleção de quantos vizinhos mais próximos seriam considerados para formar a decisão do classificador. Após testes foi constatado que o melhor número, de acordo com as métricas, seriam 3.

Neste método foi utilizado a validação cruzada *Hold-out*, também conhecida como *train-test split*, e *k-fold*. Ambas foram usadas devido ao método se tratar de uma aprendizagem supervisionada, logo, o modelo não pode ser testado com as exatas mesmas características que ele foi treinado.

No hold-out foram usados 70% das amostras para treino e 30% para teste.

Já no *k-fold* o grupo amostral foi dividido em 5 partes iguais.

O código desenvolvido está disponível no GitHub e é mostrado como um Jupyter Notebook. O acesso está disponível em:  
<https://colab.research.google.com/drive/1z-cheM-0JOGwWbbdS8QR9wUzLIJNqneE?usp=sharing>

## 5 RESULTADOS E DISCUSSÃO

Nesta seção são expostos os resultados obtidos pelos classificadores. Temos como objetivo inicial detectar corretamente os grãos de acordo com a classe que lhes foi dada pelo especialista. No método supervisionado temos também a verificação dos dois métodos de validação cruzada utilizados.

### 5.1 CLASSIFICAÇÃO POR K-MEANS

No classificador utilizando o método de clusterização, mesmo não havendo a necessidade de validação cruzada, separamos 30% dos grãos do dataset para a realização da validação, para dessa forma a comparação com a KNN ser no mesmo molde. A Tabela 4 abaixo ilustra a matriz de confusão do modelo treinado.

Tabela 4 – Matriz de Confusão do K-Means.

	Bom	Brocado	Escuro	Marinheiro
Bom	25	2	0	0
Brocado	3	9	0	0
Escuro	0	0	4	2
Marinheiro	0	1	0	3

Fonte: Do autor.

A Tabela 5 a seguir mostra a precisão, acurácia por classe e a métrica de acurácia geral para o algoritmo K-Means utilizando Hold-out:



Tabela 5 – Métricas de desempenho utilizando o algoritmo K-Means.

	ACURÁCIA	PRECISÃO
Bom	89,79%	89,28%
Brocado	93,87%	75%
Escuro	95,91%	100%
Marinheiro	93,87%	60%
<b>Média</b>	<b>93,26%</b>	<b>81%</b>

	ACURÁCIA
<b>Geral</b>	<b>83,67%</b>

Fonte: Do autor.

Como podemos ver nas tabelas acima, os menores valores encontrados nas métricas de validação, são vistos nos grãos brocados e marinheiros.

Essa dificuldade se dá por conta desses tipos de grãos serem quase idênticos entre si e os bons. A área e forma deles se dão de forma muito semelhantes. A diferenciação visual ficaria a cargo das cores: No caso do brocado, o que teríamos como diferença seria o ponto escuro onde há a broca.

Já no Marinheiro, conseguimos ver que ele possui um tom mais amarelado. Nas figuras abaixo conseguimos ver as diferenças. Sendo a Figura 17 do grão bom, Figura 18 do grão brocado e Figura 19 do grão marinho.

Figura 17 – Grão bom segmentado.



Fonte: Do autor.

Figura 18 – Grão brocado segmentado.



Fonte: Do autor.

Figura 19 – Grão marinho segmentado.



Fonte: Do autor.

## 5.2 CLASSIFICAÇÃO POR KNN

Na modelagem do classificador através do algoritmo *K-Nearest Neighbor* (KNN) houve a necessidade de separar qual seria o volume do *data-set* responsável pelo treino e o volume responsável pelo teste. Foram utilizados os dois métodos de validação cruzada citados: *Hold-out* e *K-Fold*. Abaixo as tabelas ilustram o resultado obtido. Na Tabela 6 temos a matriz de confusão no método *hold-out*.

Tabela 6 – Matriz de Confusão utilizando o algoritmo KNN e Hold-out.

	Bom	Brocado	Escuro	Marinheiro
Bom	26	1	0	0
Brocado	1	11	0	0
Escuro	0	0	6	0
Marinheiro	0	0	0	4

Fonte: Do autor.

Na Tabela 7, temos as métricas de acurácia e precisão por classe do método *hold-out*.

Tabela 7 – Métricas de desempenho utilizando o algoritmo KNN e Hold-out.

	ACURÁCIA	PRECISÃO
Bom	95,91%	96,29%
Brocado	95,91%	91,66%
Escuro	100%	100%
Marinheiro	100%	100%
<b>Média</b>	<b>97,95%</b>	<b>96,98%</b>

	ACURÁCIA
<b>Geral</b>	<b>95,91%</b>

Fonte: Do autor.

Na Tabela 8 temos a acurácia geral utilizando o KNN e método de validação k-fold = 5.

Tabela 8 – Acurácia geral utilizando o algoritmo KNN e K-fold = 5.

	ACURÁCIA
<b>Geral</b>	<b>93,18%</b>

Fonte: Do autor.

Com o *K-fold* conseguimos ter uma visão mais ampla do que o nosso *data-set* pode proporcionar, devido sua divisão igual em 5 grupos diferentes que são usados tanto para treino quanto para teste, em momentos diferentes. Porém é no Hold-out que conseguimos visualizar de melhor forma como cada uma das classes estão se comportando. O KNN mostra altos valores de acurácia e precisão em todos as classes de grãos.

### 5.3 ALGORITMO *WHITE-PATCH*

Na tentativa de buscar uma melhora de resultado para o K-Means, foi tentado um método de tratamento de imagem onde seria possível ressaltar as características de cor que diferenciam os grãos Brocados e Marinheiros dos Bons.

Foi utilizado um algoritmo para melhoria e padronização da luminosidade das imagens de amostra, o *White-Patch*.

O *White-patch* consiste em alterar os valores da matriz de cores de cada pixel (0 a 255) baseado no maior valor original, e então é alterado para 255 em RGB e os outros pontos são alterados respeitando escala. (FUNT *et al*, 1994).

A Figura 20 mostra uma comparação de uma das imagens com e sem o algoritmo *White-Patch*.

Figura 20 – Da esquerda para a direita: Imagem original e Imagem com *White-Patch*.



Fonte: Do autor.

Apesar de visualmente a imagem com o processamento do *White-Patch* se tornar mais fácil de distinguir as características de cor, não foi possível para o classificador *K-Means* o aumento das métricas. Os resultados se deram como idênticos ao anterior.

A Tabela 9 mostra a acurácia geral e acurácia e precisão por classe após o uso do *White-Patch*.

Tabela 9 – Métricas de desempenho utilizando o algoritmo *K-Means* com as imagens após *White-Patch*.

	ACURÁCIA	PRECISÃO
Bom	89,79%	89,28%
Brocado	93,87%	75%
Escuro	95,91%	100%
Marinheiro	93,87%	60%
<b>Média</b>	<b>93,26%</b>	<b>81%</b>

	ACURÁCIA
<b>Geral</b>	<b>83,67%</b>

Fonte: Do autor.

## 6 CONCLUSÕES

Com a chegada da indústria 4.0 e o desenvolvimento de técnicas de processamento de imagem, o uso de visão computacional vem se tornando mais comum em tarefas que antes eram pouco ou nada padronizadas, e executadas de forma manual.

Esse trabalho busca uma forma de substituir o processo atual por um método automático, mais eficiente, confiável e padronizado. A taxa de acurácia de 83,67% para o *K-Means* e 93,18% para o KNN (*K-Fold*) é considerada satisfatória pela literatura, porém, falta explorar mais dos tipos de defeitos dos grãos para se haver uma real implementação. O uso de técnicas mais avançadas, como o *deep learning*, podem levar a precisões ainda maiores.

O número baixo de amostras também pode implicar em um enviesamento dos modelos, porém a razão se deu pela dificuldade no contato com especialistas dispostos enviar quantidades maiores de grãos classificados individualmente.

As maiores dificuldades do trabalho se deram no desenvolvimento dos algoritmos de extração de características dos grãos, onde envolveu a separação do fundo e montagem da base de dados em CSV.

Um trabalho futuro seria aprofundar-se nos tipos de grãos, apresentando uma gama maior ao adicionar defeitos tais como coco, chocho, quebrado e conchas, de forma a tornar a classificação mais abrangente e eficiente.

Para realizar uma melhora nos grãos brocados, os mais problemáticos por sua semelhança com os grãos bons, seria interessante a adição de uma característica binária, informando se há ou não brocas.

A utilização dos algoritmos mais modernos de classificação, poderia também aumentar as métricas, aproveitando ainda mais a potência em crescimento exponencial dos *hardwares*.



## REFERÊNCIAS

ABU-MOSTAFA, Y. S.; MAGDON-ISMAIL, M., LIN, H.-T. **Learning From Data**. [S.l.]: AMLBook, 2012. ISBN 1600490069, 9781600490064.

AHMAD, Usman; SEMINAR, Kudang Boro; SOEDIBYO, Dedy Wirawan; SUBRATA, I Dewa Made. **The development of automatic coffee sorting system based on image processing and artificial neural network**. Proceedings Of Afita 2010 International Conference. **The Quality Information For Competitive Agricultural Based Production System And Commerce**. Bogor, p. 272-275. out. 2010.

**Cafeicultura – Café Conilon**. INCAPER, Espírito Santo, 12 de jul. de 2022. Disponível em: < <https://incaper.es.gov.br/cafeicultura-conilon>>. Acesso em: 12 de jul. de 2022.

**Cafeicultura**. INCAPER, Espírito Santo, 12 de jul. de 2022. Disponível em: <<https://incaper.es.gov.br/cafeicultura>>. Acesso em: 12 de jul. de 2022.

CARRILLO, Eduardo; PEÑALOZA, Alexander Aristizábal. **Artificial vision to assure coffee-excelso beans quality**. Proceedings Of The 2009 Euro American Conference On Telematics And Information Systems New Opportunities To Increase Digital Citizenship - Eatis '09, [S.L.], p. 35-35, 2009. ACM Press.

CHEN, X.; XUN, Y.; LI, W. and ZHANG, J. **Combining discriminant analysis and neural networks for corn variety identification**. Computers and Electronics in Agriculture, v. 7, 2010.

CONCI, A., AZEVEDO, E., LETA, F.; **Computação Gráfica**. LTC, 2007.

DELWICHE, Stephen R.; YANG, I-Chang; GRAYBOSCH, Robert A. **Multiple view image analysis of freefalling U.S. wheat grains for damage assessment**.

Computers And Electronics In Agriculture, [S.L.], v. 98, p. 62-73, out. 2013. Elsevier BV.

FARIDAH, F.; PARIKESIT, G.O. and FERDIANSJAH, F. **Coffee bean grade determination based on image parameter**. TELKOMNIKA (Telecommunication, Computing, Electronics and Control), v 9, 2013.

FISHER, R. B. **Is Computer Vision still AI?** AI Magazine, p.21-7, 1994.

FUNT, B.; CARDEI, V., **Committee-based color constancy**. J.Opt.Soc.Am. A, 11 (11):3011–3020, 1994.

GAZZONI, J. C.; MARCON C, L.; FRANCISCON, M. A.; MORAES, F. B., **Limiarização e binarização na análise de objetos em imagens digitais**, Synergismus, scyentifica UTFPR, 2006.

GOLDBERGER J., ROWEIS, S., HINTON, G., SALAKHUTDINOV, R.; **Neighbourhood components analysis**. In L. K. Saul, Y. Weiss, and L. Bottou, editors, Advances in Neural Information Processing Systems 17, pages 513–520, Cambridge, MA, 2005. MIT Press.

GOODFELLOW, I., BENGIO, Y., COURVILLE, A.; **Deep Learning**. MIT Press, 2016.

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

International Coffee Organization, **Exporting countries: total production**. 2020.

LUBE, I. ALMEIDA, G.; **Analysis of Machine Learning Techniques Applied to Coffee Bean Classification**. In: XLII CILAMCE and III PANACM, 2021, Rio de Janeiro. Proceedings of the Ibero-Latin-American Congress on Computational Methods in Engineering, 2021.

MEILA, M.; **The uniqueness of a good optimum for K-means**. 2020. 625-632. 10.1145/1143844.1143923.

NILSSON, N. J.; **Artificial Intelligence: A New Synthesis**. Kaufmann, 1998.

**Normas de classificação do café**. REVISTA CAFEICULTURA. Disponível em: <<https://revistacafeicultura.com.br/?mat=13103>>. Acesso em: 03 Set. de 2018.

OTSU, N.; **A Threshold selection method from gray level histograms**. IEEE Trans. System Man and Cybernet, 9, pp. 62-66, 1979.

PIZZAIA, Joao Paulo Lebarck; SALCIDES, Igor Rodrigues; ALMEIDA, Gustavo Maia de; CONTARATO, Rodrigo; ALMEIDA, Ricardo.; **Arabica coffee samples classification using a Multilayer Perceptron neural network**. 2018 13Th IEEE International Conference On Industry Applications (Induscon), [S.L.], p. 80-84, nov. 2018. IEEE.

REFAEILZADEH, P., TANG, L., LIU, H.; **Cross-Validation**. **Encyclopedia of Database Systems**. 2009. 532–538. 532-538. 10.1007/978-0-387-39940-9\_565.

SENAR. Serviço nacional de aprendizagem rural. **Café: classificação e degustação**. 2017.

SERT, E., OKUMUS, I. T.; **Segmentation of Mushroom and Cap width Measurement using Modified K-Means Clustering Algorithm**. Advances in Electrical and Electronic Engineering. 2014. 12. 10.15598/aeer.v12i4.1200.

THARWAT, A.; **Classification assessment methods**, Applied Computing and Informatics. 2020. <https://doi.org/10.1016/j.aci.2018.08.003>

TRIVEDI, M.M., ROSENFELD, A.; **On making computers “See”**. IEEE transactions on systems, man and cybernetics, v.19, n.6, p.1333-6, 1989.

VALIENTE-GONZALES, J.; **Automatic corn (Zea mays) kernel inspection system using novelty detection based on principal component analysis**. Biosystems Engineering, v. 117, 2014.

VEMURI, V. K.; **The Hundred-Page Machine Learning Book**, Journal of Information Technology Case and Application Research, 2020. DOI: 10.1080/15228053.2020.1766224

ZHENG, C., SUN, D. W., ZHENG, L.; **Recent developments and applications of image features for food quality evaluation and inspection-a review**. Trends in Food Science & Technology. 2006. 17(12), 642-655