

CIÊNCIAS EXATAS E DA TERRA:

Conhecimentos didático-pedagógicos
e o ensino-aprendizagem



Milson dos Santos Barbosa
(Organizador)

Atena
Editora
Ano 2022

CIÊNCIAS EXATAS E DA TERRA:

Conhecimentos didático-pedagógicos
e o ensino-aprendizagem



Milson dos Santos Barbosa
(Organizador)

Atena
Editora
Ano 2022

Editora chefe

Profª Drª Antonella Carvalho de Oliveira

Editora executiva

Natalia Oliveira

Assistente editorial

Flávia Roberta Barão

Bibliotecária

Janaina Ramos

Projeto gráfico

Bruno Oliveira

Camila Alves de Cremo

Daphynny Pamplona

Luiza Alves Batista

Natália Sandrini de Azevedo

Imagens da capa

iStock

Edição de arte

Luiza Alves Batista

2022 by Atena Editora

Copyright © Atena Editora

Copyright do texto © 2022 Os autores

Copyright da edição © 2022 Atena Editora

Direitos para esta edição cedidos à Atena Editora pelos autores.

Open access publication by Atena Editora



Todo o conteúdo deste livro está licenciado sob uma Licença de Atribuição *Creative Commons*. Atribuição-Não-Comercial-Não-Derivativos 4.0 Internacional (CC BY-NC-ND 4.0).

O conteúdo dos artigos e seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva dos autores, inclusive não representam necessariamente a posição oficial da Atena Editora. Permitido o *download* da obra e o compartilhamento desde que sejam atribuídos créditos aos autores, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

Todos os manuscritos foram previamente submetidos à avaliação cega pelos pares, membros do Conselho Editorial desta Editora, tendo sido aprovados para a publicação com base em critérios de neutralidade e imparcialidade acadêmica.

A Atena Editora é comprometida em garantir a integridade editorial em todas as etapas do processo de publicação, evitando plágio, dados ou resultados fraudulentos e impedindo que interesses financeiros comprometam os padrões éticos da publicação. Situações suspeitas de má conduta científica serão investigadas sob o mais alto padrão de rigor acadêmico e ético.

Conselho Editorial**Ciências Exatas e da Terra e Engenharias**

Prof. Dr. Adélio Alcino Sampaio Castro Machado – Universidade do Porto

Profª Drª Alana Maria Cerqueira de Oliveira – Instituto Federal do Acre

Profª Drª Ana Grasielle Dionísio Corrêa – Universidade Presbiteriana Mackenzie

Profª Drª Ana Paula Florêncio Aires – Universidade de Trás-os-Montes e Alto Douro

Prof. Dr. Carlos Eduardo Sanches de Andrade – Universidade Federal de Goiás

Profª Drª Carmen Lúcia Voigt – Universidade Norte do Paraná



Prof. Dr. Cleiseano Emanuel da Silva Paniagua – Instituto Federal de Educação, Ciência e Tecnologia de Goiás
Prof. Dr. Douglas Gonçalves da Silva – Universidade Estadual do Sudoeste da Bahia
Prof. Dr. Eloi Rufato Junior – Universidade Tecnológica Federal do Paraná
Profª Drª Érica de Melo Azevedo – Instituto Federal do Rio de Janeiro
Prof. Dr. Fabrício Menezes Ramos – Instituto Federal do Pará
Profª Dra. Jéssica Verger Nardeli – Universidade Estadual Paulista Júlio de Mesquita Filho
Prof. Dr. Juliano Bitencourt Campos – Universidade do Extremo Sul Catarinense
Prof. Dr. Juliano Carlo Rufino de Freitas – Universidade Federal de Campina Grande
Profª Drª Luciana do Nascimento Mendes – Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte
Prof. Dr. Marcelo Marques – Universidade Estadual de Maringá
Prof. Dr. Marco Aurélio Kistemann Junior – Universidade Federal de Juiz de Fora
Prof. Dr. Miguel Adriano Inácio – Instituto Nacional de Pesquisas Espaciais
Profª Drª Neiva Maria de Almeida – Universidade Federal da Paraíba
Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Profª Drª Priscila Tessmer Scaglioni – Universidade Federal de Pelotas
Prof. Dr. Sidney Gonçalo de Lima – Universidade Federal do Piauí
Prof. Dr. Takeshy Tachizawa – Faculdade de Campo Limpo Paulista



Ciências exatas e da terra: conhecimentos didático-pedagógicos e o ensino-aprendizagem

Diagramação: Camila Alves de Cremo
Correção: Yaidy Paola Martinez
Indexação: Amanda Kelly da Costa Veiga
Revisão: Os autores
Organizador: Milson dos Santos Barbosa

Dados Internacionais de Catalogação na Publicação (CIP)

C569 Ciências exatas e da terra: conhecimentos didático-pedagógicos e o ensino-aprendizagem / Organizador Milson dos Santos Barbosa. – Ponta Grossa - PR: Atena, 2022.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

Inclui bibliografia

ISBN 978-65-258-0422-4

DOI: <https://doi.org/10.22533/at.ed.224220408>

1. Ciências exatas - Estudo e ensino. I. Barbosa, Milson dos Santos (Organizador). II. Título.

CDD 507

Elaborado por Bibliotecária Janaina Ramos – CRB-8/9166

Atena Editora

Ponta Grossa – Paraná – Brasil

Telefone: +55 (42) 3323-5493

www.atenaeditora.com.br

contato@atenaeditora.com.br



Atena
Editora
Ano 2022

DECLARAÇÃO DOS AUTORES

Os autores desta obra: 1. Atestam não possuir qualquer interesse comercial que constitua um conflito de interesses em relação ao artigo científico publicado; 2. Declaram que participaram ativamente da construção dos respectivos manuscritos, preferencialmente na: a) Concepção do estudo, e/ou aquisição de dados, e/ou análise e interpretação de dados; b) Elaboração do artigo ou revisão com vistas a tornar o material intelectualmente relevante; c) Aprovação final do manuscrito para submissão.; 3. Certificam que os artigos científicos publicados estão completamente isentos de dados e/ou resultados fraudulentos; 4. Confirmam a citação e a referência correta de todos os dados e de interpretações de dados de outras pesquisas; 5. Reconhecem terem informado todas as fontes de financiamento recebidas para a consecução da pesquisa; 6. Autorizam a edição da obra, que incluem os registros de ficha catalográfica, ISBN, DOI e demais indexadores, projeto visual e criação de capa, diagramação de miolo, assim como lançamento e divulgação da mesma conforme critérios da Atena Editora.



DECLARAÇÃO DA EDITORA

A Atena Editora declara, para os devidos fins de direito, que: 1. A presente publicação constitui apenas transferência temporária dos direitos autorais, direito sobre a publicação, inclusive não constitui responsabilidade solidária na criação dos manuscritos publicados, nos termos previstos na Lei sobre direitos autorais (Lei 9610/98), no art. 184 do Código Penal e no art. 927 do Código Civil; 2. Autoriza e incentiva os autores a assinarem contratos com repositórios institucionais, com fins exclusivos de divulgação da obra, desde que com o devido reconhecimento de autoria e edição e sem qualquer finalidade comercial; 3. Todos os e-book são *open access*, *desta forma* não os comercializa em seu site, sites parceiros, plataformas de *e-commerce*, ou qualquer outro meio virtual ou físico, portanto, está isenta de repasses de direitos autorais aos autores; 4. Todos os membros do conselho editorial são doutores e vinculados a instituições de ensino superior públicas, conforme recomendação da CAPES para obtenção do Qualis livro; 5. Não cede, comercializa ou autoriza a utilização dos nomes e e-mails dos autores, bem como nenhum outro dado dos mesmos, para qualquer finalidade que não o escopo da divulgação desta obra.



APRESENTAÇÃO

A coleção “Ciências exatas e da terra: Conhecimentos didático-pedagógicos e o ensino-aprendizagem” é um e-book que tem o intuito de fornecer *insights* sobre metodologias educacionais e aplicações tecnológicas para fomentar e desenvolver processos e produtos inovadores. O volume reúne estudos teóricos e práticos (revisões bibliográficas, relatos de casos, pesquisas científicas, entre outros) envolvendo cálculos matemáticos e afins para solucionar problemas e beneficiar diretamente a sociedade.

Neste contexto, a obra apresenta de maneira objetiva e didática estudos desenvolvidos por docentes e discentes de diferentes instituições de ensino e pesquisa do país. Os artigos englobam desenvolvimentos recentes no campo das tecnologias, energias renováveis, modelagens e simulações computacionais, algoritmos e softwares, bem como máquinas e equipamentos. Outra direção importante fomentada no e-book é abordagem utilizada para difundir os conhecimentos pedagógicos e o ensino científico nas ciências exatas e da terra.

Questões relevantes para a sociedade moderna são, portanto, debatidas a partir de uma perspectiva crítica, trazendo discussões de temáticas da área e propiciando um conhecimento específico e aprofundado para discentes, docentes e pesquisadores. Deste modo, a obra composta por capítulos que abordam múltiplos temas e com conceitos interdisciplinares da área de ciências exatas e da terra. Diante dessa oportunidade de aprendizagem, convido todos os leitores para usufruírem das produções da coletânea. Tenham uma ótima leitura!

Milson dos Santos Barbosa

SUMÁRIO

CAPÍTULO 1..... 1

CIÊNCIA, TECNOLOGIA E SOCIEDADE (CTS) E O ENSINO DE CIÊNCIAS ATRAVÉS DA TECNOLOGIA

Micheline Soares Costa Oliveira

Letícia Martins Nunes

Letícia de Araújo Rodrigues

Hemilly Sales Alburquerque

 <https://doi.org/10.22533/at.ed.2242204081>

CAPÍTULO 2..... 6

DESENVOLVIMENTO DE SOFTWARE COMO AÇÃO DE EXTENSÃO: RELATO DE EXPERIÊNCIA

Luis Fernando Meneghel Benatto

Daniela de Freitas Guilhermino Trindade

Carlos Eduardo Ribeiro

Renata Alfredo

José Reinaldo Merlin

 <https://doi.org/10.22533/at.ed.2242204082>

CAPÍTULO 3..... 13

A CONCEPÇÃO DOS PROFESSORES DE QUÍMICA EM RELAÇÃO À CONTRIBUIÇÃO DA EXPERIMENTAÇÃO NA APRENDIZAGEM SIGNIFICATIVA DOS ALUNOS

Tatiana Medeiros Ibiapina

 <https://doi.org/10.22533/at.ed.2242204083>

CAPÍTULO 4..... 34

O ENSINO DE QUÍMICA E CULTURA: CONCEPÇÕES PRESENTES NA REVISTA QUÍMICA NOVA NA ESCOLA

Cleiseano Emanuel da Silva Paniagua

Rafael Martins Mendes

 <https://doi.org/10.22533/at.ed.2242204084>

CAPÍTULO 5..... 48

CLASSROOM COMO RECURSO TECNOLÓGICO PARA A EDUCAÇÃO EM MATEMÁTICA

Mauricio da Silva Oliveira

 <https://doi.org/10.22533/at.ed.2242204085>

CAPÍTULO 6..... 74

PRÁTICAS EXPERIMENTAIS SOBRE POLUIÇÃO SONORA

Maria Lúcia Grillo

Luiz Roberto Perez Lisbôa Baptista

 <https://doi.org/10.22533/at.ed.2242204086>

CAPÍTULO 7..... 83

ANÁLISE DE TÉCNICAS DE APRENDIZADO DE MÁQUINA APLICADOS À CLASSIFICAÇÃO DE GRÃOS DE CAFÉ

Igor Garcia Lube

Gustavo Maia de Almeida

Fidelis Zanetti de Castro

 <https://doi.org/10.22533/at.ed.2242204087>

CAPÍTULO 8..... 94

MODELAGEM E SIMULAÇÃO DE PAINÉIS FOTOVOLTAICOS COMERCIAIS ORGÂNICOS E FLEXÍVEIS MECANICAMENTE

Ana Carolina da Silva Mota

Cleber Lourenço Izidoro

Vagner da Silva Rodrigues

Jorge Javier Gimenez Ledesma

Oswaldo Hideo Ando Junior

Marco Roberto Cavallari

 <https://doi.org/10.22533/at.ed.2242204088>

CAPÍTULO 9..... 106

SIMULAÇÃO DE ALGORITMOS DE RASTREAMENTO DO PONTO DE MÁXIMA POTÊNCIA APLICADOS A PAINÉIS FOTOVOLTAICOS ORGÂNICOS COM CONVERSOR CC-CC SOB SOMBREAMENTO PARCIAL

Ana Carolina da Silva Mota

Vagner da Silva Rodrigues

Cleber Lourenço Izidoro

Jorge Javier Gimenez Ledesma

Oswaldo Hideo Ando Junior

Marco Roberto Cavallari

 <https://doi.org/10.22533/at.ed.2242204089>

CAPÍTULO 10..... 120

IDENTIFICAÇÃO E MODELAGEM DE PLUMAS GASOSAS NA COLUNA D'ÁGUA ATRAVÉS DE MÉTODOS GEOFÍSICOS DE ALTA RESOLUÇÃO

Jorge Fiori Fernandes Sobreira

Carlos Eduardo Borges de Salles Abreu

Esmeraldino Aleluia Oliveira Júnior

Marcelo Rocha Peres

Marco Ianniruberto

Luciano Emídio da Fonseca

 <https://doi.org/10.22533/at.ed.22422040810>

CAPÍTULO 11..... 135

NUMERICAL SIMULATION OF A CONNECTED-PIPE TEST RAMJET MOTOR

Douglas Carvalho Cerbino

Olexiy Shynkarenko

 <https://doi.org/10.22533/at.ed.22422040811>

CAPÍTULO 12..... 149

UMA REVISÃO DE LITERATURA SOBRE A TEORIA DOS CAMPOS CONCEITUAIS E O CAMPO CONCEITUAL DAS ESTRUTURAS ADITIVAS

Grazielle Jenske

Verônica Gesser

 <https://doi.org/10.22533/at.ed.22422040812>

CAPÍTULO 13..... 162

INFLUENCE OF NON-LINEAR DAMPING ON NON-LINEAR STRUCTURES VIBRATIONS

Thiago R. Carvalho

Zénon J. Guzman N. Del Prado

 <https://doi.org/10.22533/at.ed.22422040813>

CAPÍTULO 14..... 168

ESTUDO DA VULNERABILIDADE AMBIENTAL EM NOSSA SENHORA DA GLÓRIA/SE

José Batista Siqueira

Edson Magalhães Bastos Júnior

José Antônio Pacheco Almeida

 <https://doi.org/10.22533/at.ed.22422040814>

SOBRE O ORGANIZADOR..... 182

ÍNDICE REMISSIVO..... 183

ANÁLISE DE TÉCNICAS DE APRENDIZADO DE MÁQUINA APLICADOS À CLASSIFICAÇÃO DE GRÃOS DE CAFÉ

Data de aceite: 01/08/2022

Data de submissão: 08/07/2022

Igor Garcia Lube

Instituto Federal do Espírito Santo – Campus
Serra
Serra – Espírito Santo
<http://lattes.cnpq.br/3887819544364378>

Gustavo Maia de Almeida

Instituto Federal do Espírito Santo – Campus
Serra
Serra – Espírito Santo
<http://lattes.cnpq.br/2650921349694794>

Fidelis Zanetti de Castro

Instituto Federal do Espírito Santo – Campus
Serra
Serra – Espírito Santo
<http://lattes.cnpq.br/2373180848461397>

RESUMO: O mercado cafeeiro caracteriza-se por um conjunto de atividades de enorme complexidade, dinamismo e um nível crescente de exigência dos consumidores quanto à qualidade da bebida. Isso impõe um alto controle de qualidade aos países produtores, consumidores e exportadores. Atualmente, a definição da qualidade e, portanto, do valor do café é baseada na classificação manual, ou seja, uma pessoa desempenha o papel de classificador treinado (certificado) para qualificar amostras de café. Assim, o atual processo de classificação sofre com a subjetividade dos classificadores e uma grande dificuldade em padronizar o

processo devido a possíveis inconsistências no processo. Diante desse cenário, o presente trabalho propõe uma comparação entre três algoritmos que classificam amostras de café, considerando forma e imperfeições. Os algoritmos são classificadores, um baseado em MLP (Multi-Layer Perceptron), outro em clustering por K-Means e o último consiste em um classificador baseado em Deep Learning e redes convolucionais regionais (R-CNN). O objetivo deste trabalho é comparar qual dos algoritmos é mais eficaz na classificação dos grãos de acordo com os defeitos intrínsecos presentes na amostra.

PALAVRAS-CHAVE: Classificação de grãos de café. Deep Learning. Mask R-CNN. K-Means. Multi-Layer Perceptron.

ANALYSIS OF MACHINE LEARNING TECHNIQUES APPLIED TO COFFEE BEAN CLASSIFICATION

ABSTRACT: The coffee market is characterized by a set of activities of enormous complexity, dynamism, and a growing level of demand from consumers regarding the quality of the drink. This imposes high quality control on producer, consumer and exporter countries. Currently, the definition of the quality and, therefore, the value of coffee is based on manual classification, that is, a person plays the role of a trained (certified) classifier to qualify coffee samples. Thus, the current classification process suffers from the subjectivity of the classifiers and a great difficulty in standardizing the process due to possible inconsistencies in the process. Given this

scenario, the present work proposes a comparison between three algorithms that classify coffee samples, considering shape and imperfections. The algorithms are classifiers, one based on MLP (Multi-Layer Perceptron), another in clustering by K-Means and the latter consists of a classifier based on Deep Learning and regional convolutional networks (R-CNN). The objective of this work is to compare which of the algorithms is more effective in classifying the grains according to the intrinsic defects present in the sample.

KEYWORDS: Classification of coffee beans. Deep Learning. Mask R-CNN. K-Means. Multi-Layer Perceptron.

1 | INTRODUÇÃO

O café é a segunda bebida mais consumida do mundo de acordo com a Organização Internacional do café (ICO, 2019) que também revela o Brasil tem se destacado na produção e exportação do café e atualmente ocupa a primeira posição mundial tanto na produção como na exportação do produto, o que torna o produto uma das mais importantes fontes de renda do país e de vários municípios, gerando mais de 8 milhões de empregos em todo território brasileiro (MAPA, 2018).

Devido à alta exigência do mercado internacional por produto de qualidade, o café brasileiro exportado necessita passar por um rígido controle de qualidade, o qual deve ser preciso e rápido, dado o grande volume do produto que deve ser avaliado.

Uma das principais dificuldades dos produtores é a avaliação de qualidade de suas safras, que deve ser rápida e confiável para acompanhar a volatilidade do preço dessas commodities. A qualidade da bebida depende, dentre outros fatores, da qualidade dos grãos utilizados e da quantidade de imperfeições e impurezas misturadas aos grãos bons. Os defeitos encontrados nas amostras de café são contabilizados para que se defina qual o tipo de café.

Atualmente, a avaliação é feita visualmente por especialistas e apresenta as seguintes desvantagens: a subjetividade do processo é grande pois cada avaliador pode ter uma classificação diferente da mesma amostra de modo que diferentes avaliadores podem dar diferentes diagnósticos para a mesma amostra; é um processo lento, já que cada grão deve ser avaliado individualmente; e a qualidade da avaliação também sofre efeitos negativos no decorrer do turno de trabalho por motivos inerentes a fisiologia humana e condições ambientais como a fadiga, stress, iluminação deficiente etc. A velocidade e confiabilidade são extremamente dependentes do profissional, o que torna difícil a padronização desta etapa da cadeia de produção já que cada ser humano tem suas particularidades.

Em geral os métodos automáticos aparecem em máquinas e sistemas para aplicação no processo de produção de beneficiadoras de sementes. Neste sentido, o presente trabalho propõe uma análise comparativa entre três diferentes técnicas de visão computacional aplicada à classificação de grãos de café: Multi-layer Perceptron Pizzaia et

al (2018); Clusterização por K-Means, Vasconcellos et al (2019) e por fim, redes neurais convolucionais regionais por meio da rede Mask R-CNN Lube e Almeida (2020).

2 | TRABALHOS RELACIONADOS

Apesar de o problema já ter sido explorado por grupos que desenvolveram produtos e patentes relacionados, ou seja, classificação de soja, milho, arroz, cevada, entre outros, não há muitos trabalhos acadêmicos tratando classificação de grãos de café com visão computacional na literatura.

No trabalho de Carrillo e Penalzoza (2019) foram utilizados classificadores baseados na distância de Mahalanobis para identificar 6 classes de café em grãos em uma amostra, porém, o recall médio obtido nesse método foi de apenas 67,7%.

Ahmad et al. (2010) apresentaram uma máquina para realizar separação automática de grãos de café por visão computacional, porém, eles apenas separavam e não classificava, além do fato de se ter uma acurácia de apenas 78,32%.

Pizzaia et al. (2018) propõem uma rede neural Perceptron Multicamadas (MLP) para classificar grãos de café através da forma, tamanho e cor das amostras. As imagens usadas continham grãos de café bons e ruins classificados previamente por especialistas. Os grãos foram segmentados por binarização de Otsu e em seguida calculadas as áreas, arredondamento e a média dos valores de cor de cada grãos nas camadas RGB. Estas características foram alimentadas na rede MLP que classifica os grãos como bons ou defeituosos. A rede obteve uma média de 94% de acurácia.

No trabalho de Vasconcellos et al. (2019) é proposto um sistema utilizando clusterização por K-Means para classificar quatro tipos de grãos de café, sendo eles o grão bom, brocado, marinho e escuro. As amostras foram tratadas com o algoritmo de padronização de luminosidade White-Patch. Foram usadas no classificador a área, arredondamento e média dos canais RGB de cada grão obtendo uma taxa de acerto de 90,74%.

A abordagem proposta por Lube e Almeida (2020) utiliza Deep Learning na forma de uma Rede Neural Convolucional (R-CNN) aplicada na técnica Mask R-CNN proposta por He et al (2017). Neste trabalho as imagens continham amostras de grãos de café que foram separadas em 5 classes: bom, brocado, marinho, escuro e ruim, sendo esta última um agrupamento de vários defeitos não contemplados nas classes antes mencionadas. A técnica obteve uma acurácia média de 93,94% e um F-score de 82,24% para as cinco classes abrangidas.

3 | FUNDAMENTAÇÃO TEÓRICA

Esta seção descreve de forma mais detalhada as três técnicas analisadas neste

artigo abrangendo suas diferenças e similaridades.

3.1 Classificação utilizando rede Multi-Layer Perceptron

O método de classificação proposto por Pizzaia et al. (2018) utiliza uma MLP para classificar os grãos de café. A rede usa como parâmetros de entrada a cor, área e arredondamento de cada grão. As imagens usadas para treinamento foram compostas por amostras previamente separadas por especialistas que continham grãos bons e grãos com várias impurezas e defeitos não discriminados. Por este motivo, as classes abrangidas na classificação foram as de “grãos bons” e “grãos ruins”. As imagens passaram por um processo de segmentação por binarização de Otsu (1975), separando os grãos do plano de fundo, os contornos dos grãos foram obtidos e as Regiões de Interesse foram destacadas, caracterizando o processo como um aprendizado supervisionado, desta forma os parâmetros de cor, área e arredondamento foram calculados para cada amostra contida nas imagens. Na Figura 1 é mostrado o fluxograma do algoritmo desenvolvido.

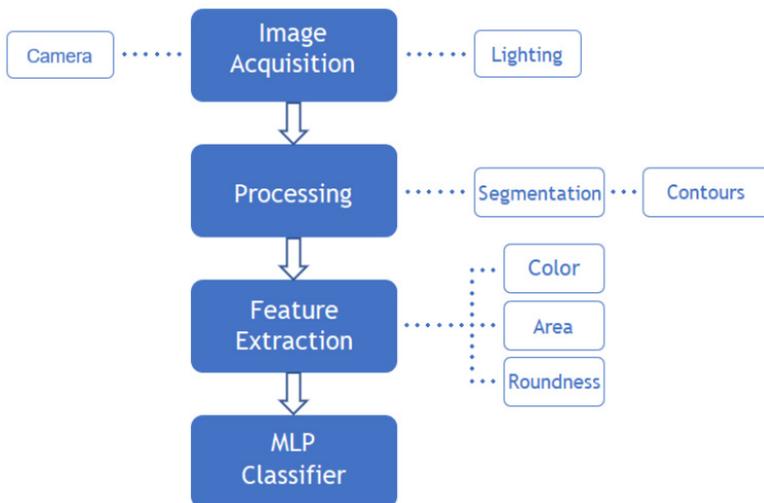


Figura 1. Fluxograma do Classificador MLP

O parâmetro de Área é calculado pela quantidade de pixels em cada amostra. O Arredondamento define o quanto cada amostra se aproxima de um círculo perfeito, deste modo, a rede consegue diferenciar um grão inteiro de um grão quebrado, entre outros defeitos. O Arredondamento (*Roundness*) é obtido através da equação:

$$\text{Arredondamento} = \frac{4 \cdot \pi \cdot \text{area}}{\text{perimetro}^2}$$

O parâmetro de cor calcula a média dos canais RGB (RGB Mean). Estes cinco parâmetros são as entradas usadas no classificador MLP para obter as classes “grão bom”

e “grão ruim”.

O classificador foi exposto a 848 amostras, sendo 748 para treinamento e 100 amostras para validação. A rede possui cinco neurônios na camada de entrada (um para cada parâmetro), uma camada oculta com 100 neurônios do tipo sigmoide usando o algoritmo Levenberg-Marquardt e uma camada de saída contendo 1 neurônio com saída binária sendo “0” para um grão bom e “1” para um grão ruim. Na Figura 2 temos exemplos de um grão bom (Fig. 2a) e de um grão ruim (Fig. 2b).

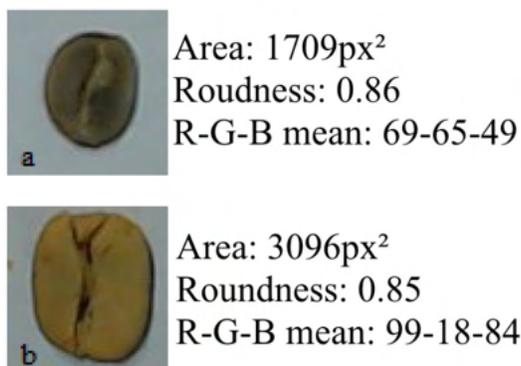


Figura 2. Exemplos de um grãos bom (a) e grão ruim (b)

3.2 Classificação por Clusterização K-Means

Na classificação proposta por Vasconcellos et al. (2019) o método utilizado foi a clusterização utilizando o algoritmo *K-Means*, Lloyd (1982) que é um método de aprendizado não supervisionado que se dá pela criação de *k* grupos de elementos previamente conhecidos. Cada Cluster engloba dados com características semelhantes que são verificadas matematicamente utilizando a distância Euclidiana. Este trabalho é uma outra abordagem de classificador que utiliza a mesma base de dados, porém desmembrando os grãos ruins em três novas classes que são: grão escuro, grão brocado e grão marinheiro. A classe de “grãos bons” foi mantida.

As imagens com as amostras passaram por um processamento utilizando o algoritmo White-Patch que visa a melhoria da luminosidade e padronização no tratamento da base de dados.

As características utilizadas no treinamento foram: Area, Arredondamento e média dos canais RGB e seus valores obtidos da mesma forma que o trabalho de Pizzaia et al. (2018). A Figura 3 exemplifica uma imagem após o tratamento e pronta para extração das características que serão utilizadas na rede.

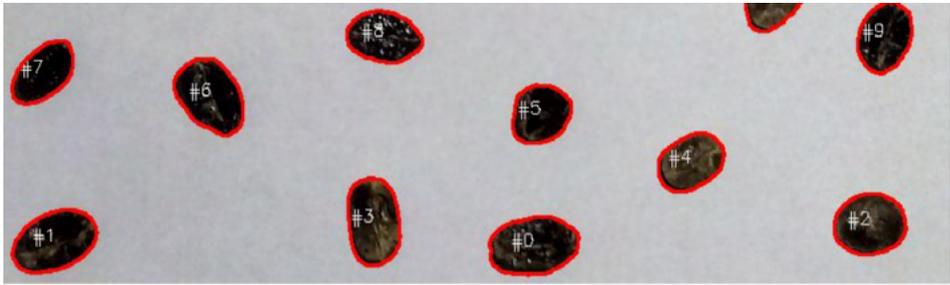


Figura 3. Grãos contornados e numerados

3.3 Classificação utilizando o framework Mask R-CNN

A rede proposta por Lube e Almeida (2020) utiliza como base a rede Mask R-CNN que foi definida por He et al. (2017) como um framework simples e flexível para segmentação de instância, a Mask R-CNN é baseado em um framework proposto por Ren et al. (2017) chamado Faster R-CNN, um sistema para detecção de objetos e segmentação semântica, que é rápido, robusto e intuitivo

A Mask R-CNN adiciona um novo ramo de predição de máscaras que funciona paralelamente ao ramo existente de classificação e regressão de bounding box da Faster R-CNN. Este novo ramo é uma pequena FCN (Full Connection Network) aplicada pixel a pixel em cada região de interesse (RoI) e aliada a essa FCN existe uma camada denominada RoIAlign com a função de melhorar a precisão das máscaras criadas e desacoplar o ramo das máscaras do ramo de predição de classe, garantindo uma melhoria de 10% a 50% na acurácia das máscaras. Na Figura 4 é exibido o framework da arquitetura Mask R-CNN.

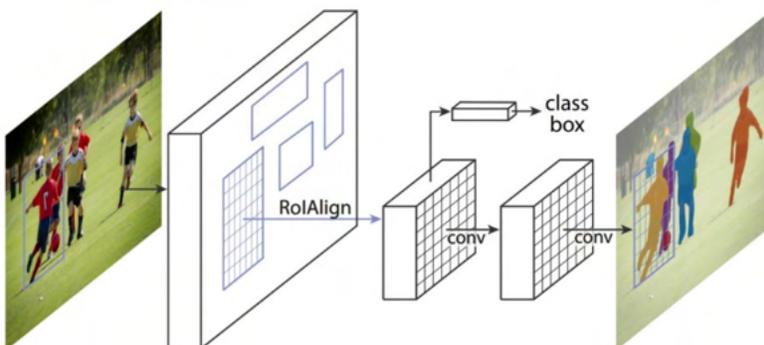


Figura 4. Framework da Mask R-CNN

O banco de dados de grãos de café foi montado a partir das imagens usadas nos trabalhos citados na seção 3.1 e 3.2. As amostras contêm grãos bons e grãos defeituosos (brocado, marinho, escuro e ruim). O tratamento das imagens foi por segmentação no

qual uma imagem com vários grãos foi subdividida em imagens menores com somente um grão e com fundo escuro. Por causa da baixa quantidade de amostras necessárias para o aprendizado com Deep Learning, foi necessário usar o processo de Data Augmentation que aplica rotações, espelhamentos, entre outras estratégias para aumentar a base de dados e, conseqüentemente, a precisão da rede. As classes são grão bom, ruim, brocado, escuro e marinheiro.



Figura 5. Grãos antes (esquerda) e depois da segmentação (direita)

O algoritmo deste trabalho recebeu as imagens com anotações para o treinamento, porém a base de dados é muito pequena para treinar uma rede do zero. Para resolver este impasse foi utilizada a técnica conhecida como fine tuning que é uma transferência de aprendizado de características de uma rede treinada com uma base de dados maior para uma rede menor.

Foi utilizado o software VGG Image Annotator (VIA tool) para produzir as Regiões de Interesse (RoI), estas contém as anotações com a localização dos grãos e suas respectivas classes que são parâmetros de entrada da rede junto as imagens com as amostras.

A rede proposta foi treinada por transferência de aprendizado de uma rede pré-treinada com base no banco de dados Microsoft COCO: Common Objects on Context Lin et al (2014). Com o fine tuning é possível ter uma rede com bons resultados mesmo com um banco de dados razoavelmente pequeno. A rede foi treinada com as 606 amostras de grãos segmentados por 45 épocas, com 100 passos por época e confiança mínima de 60%, a taxa de aprendizado foi fixada em 0.001.

3.4 Tipos de Grãos de Café

As classes de grãos tem características que as diferenciam por atributos como cor, aspecto e uniformidade como mostrado na Tab 1.

Classe	Características
Bom	Cor e aparência uniformes. Ausência de defeitos
Ruim	Grãos quebrados, pequenos, mal formados entre outros defeitos
Brocado	Canais escuros no grão provenientes do ataque da broca-do-café na plantaçoão
Escuro	Cor escura devido a um processo de fermentação indesejável
Marinheiro	Possui película amarelada que não foi corretamente removida durante beneficiamento

Tabela 1. Características dos grãos analisados

A rede MLP foi treinada com as classes “Bom” e “Ruim”, sendo a última uma composição das classes “Broca”, “Escura” e “Marinheiro”, uma vez que para este trabalho, não se tinha uma amostra separada em termos específicos do tipo de grãos, tais como broca, escuro e marinheiro. A rede de classificação por clusterização usou para treino a classe “ruim” desmembrada em outras três (Broca, Escuro e Marinheiro) e por fim, a rede Mask R-CNN foi treinada com todas as classes presentes na Tab. 1. Analisando a tabela é possível notar que alguns valores não se fazem presentes devido ao modo como as amostras foram divididas.

4 | RESULTADOS E DISCUSSÕES

Nesta seção serão apresentados os resultados de cada classificador e a análise comparativa de seus resultados.

A tabela 2 mostra as métricas de desempenho para cada tipo de classificador.

	ACCURACIA			PRECISÃO			RECALL			F-SCORE		
	MLP	K-M	Mask	MLP	K-M	Mask	MLP	K-M	Mask	MLP	K-M	Mask
Bom	94,1	94,4	93,1	95,1	94,3	83,3	92,8	95,4	58,8	93,9	94,8	68,9
Ruim	94,1	-	91,0	93,1	-	68,1	95,3	-	78,9	94,2	-	73,1
Brocado	-	90,1	96,1	-	73,1	100	-	85,7	86,4	-	78,9	92,7
Escuro	-	100	94,6	-	100	87,7	-	100	100	-	100	93,4
Marinheiro	-	95,6	98,4	-	100	87,5	-	66,6	87,5	-	80,0	87,5
Média	94,1	95,0	94,8	94,1	91,8	85,3	94,1	86,6	82,3	94,1	88,4	83,1

Tabela 2. Comparação da performance dos classificadores (%)

O classificador MLP apresenta valor médio superior a 94% em todas as métricas, porém com classes limitadas a grãos “bons” e “ruins” o que torna a comparação direta

imprecisa quando relacionada aos demais classificadores, contudo para a tarefa mais simples de apenas selecionar amostras positivas, ou seja, grãos bons esta proposta é eficaz e de baixo custo computacional, porém requer etapas para cálculo dos parâmetros de entrada (cor, arredondamento e área).

A clusterização por K-Means se destaca por ser uma técnica com aprendizado não supervisionado e também precisa de cinco parâmetros de entrada para classificação dos grãos. Os autores do artigo mencionam em sua conclusão a baixa eficiência na classificação de grãos “brocados”, o que pode ser confirmado nas métricas de precisão e recall presentes na Tab. 2. As métricas dos grãos “escuros” são o destaque desta técnica e devido a subdivisão da classe “ruim” os valores de performance deste não constam na tabela.

A Mask R-CNN por ser um algoritmo de Deep Learning necessita de um banco de amostras com grande volume, a classe “ruim” foi prejudicada por este aspecto, pois dela foram retiradas várias amostras que ganharam suas próprias classes (brocado, escuro e marinheiro) e o restante das amostras como grãos pequenos, quebrados e disformes não possuíam um volume suficiente para o treinamento da rede. O grande destaque foram os grãos brocados que apresentaram valores acima de 95% em acurácia e precisão, o que demonstra a capacidade da rede classificar estes grãos corretamente mesmo com uma grande similaridade em relação aos grãos ditos “bons”.

5 | CONCLUSÕES

Este trabalho visou demonstrar por meio das métricas de performance e da análise das técnicas de visão computacional apresentadas que não existe um classificador que é superior aos demais em todas as situações. O classificador MLP é muito eficaz em identificar grãos bons usando uma rede simples e de baixo custo computacional. Em algumas situações este tipo de classificador já produz uma performance suficiente para atender os almejados. A clusterização por K-Means atende de forma satisfatória quando a tarefa requer a classificação de grãos com características bem distintas entre as classes, pois a técnica agrupa os semelhantes nos clusters, tornando difícil a diferenciação de amostras similares como é o caso dos grãos bons e brocados.

A rede Mask R-CNN necessita de um banco de dados de grande volume, mas é capaz de distinguir diferenças sutis entre amostras caso seja treinada com número suficiente de imagens. Este classificador é o mais generalista e escalável entre os três estudados e o mais promissor, pois seu aprendizado profundo permite aumentar o número de classes sem alterar os parâmetros de entrada, somente adicionando mais amostras e suas anotações. Impurezas como “pedaços de pau”, “pedras” e “torrões” que também fazem parte da classificação dos grãos de café, poderiam ser facilmente adicionadas ao classificador e obteriam resultados promissores, o que não se pode afirmar das outras

técnicas que usam cor, arredondamento e área para classificação.

Como trabalho futuro, os autores estão buscando parceria com cooperativas do Estado do ES, com o intuito de obter amostras de todos os tipos de defeitos de grãos de café, além do que já temos, para que assim seja treinado um classificador com a capacidade de identificar todos os tipos de grãos de café e de aumentar as métricas apresentadas pela Mask-RCNN, pois é sabido de que quanto mais imagens se tem no dataset, mais eficiente se torna a rede.

AGRADECIMENTOS

Os autores agradecem ao Edital FAPES/CNPq Nº 23/2018 pela contribuição financeira.

REFERÊNCIAS

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**. 2010. p. 272-275. INTERNATIONAL CONFERENCE-THE QUALITY INFORMATION FOR COMPETITIVE AGRICULTURAL BASED PRODUCTION SYSTEM AND COMMERCE.

CARRILLO, Eduardo; PEÑALOZA, Alexander Aristizábal. **Artificial vision to assure coffee-excelso beans quality**. 2009. p. 35-35. EURO AMERICAN CONFERENCE ON TELEMATICS AND INFORMATION SYSTEMS NEW OPPORTUNITIES TO INCREASE DIGITAL CITIZENSHIP - Eatis '09. 2009. **Proceedings...** [S.L.]: ACM Press, 2009. p. 35-35.

HE, Kaiming; GKIOXARI, Georgia; DOLLÁR, Piotr; GIRSHICK, Ross. **Mask R-CNN**. 2017. v. 42. p. 386-397. IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION (ICCV). Out. 2017. [S.L.]: IEEE, out. 2017.

LUBE, Igor Garcia; ALMEIDA, Gustavo Maia de. **Classification of coffee beans using Deep Learning**. 2020. XLI CILAMCE, Foz do Iguaçu.

INTERNATIONAL COFFEE ORGANIZATION (Londres). **World coffee consumption**. (2019). Disponível em: <<http://www.ico.org/prices/new-consumption-table.pdf>>. Acesso em: 12 jun. 2020.

LIN, Tsung-Yi; MAIRE, Michael; BELONGIE, Serge; BOURDEV, Lubomir; GIRSHICK, Ross; HAYS, James; PERONA, Pietro; RAMANAN, Deva; ZITNIK, C. Lawrence; DOLLÁR, Piotr. **Microsoft COCO: common objects in context**. 2014. p. 740-755. Computer Vision – Eccv 2014, [S.L.]. Springer International Publishing.

LOYD, Stuart P. **Least square quantization in PCM**. 1982. V. 28. p. 129–137. IEEE Transactions on Information Theory.

MAPA (Brasil). **Café no Brasil**. 2018. Disponível em: <<http://antigo.agricultura.gov.br/assuntos/politica-agricola/cafe/cafeicultura-brasileira>>. Acesso em: 05 maio 2020.

OTSU, Nobuyuki. **A threshold selection method from gray-level histograms**. (1975). v. 11(285-296), p. 23-27. Automatica,

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. p. 80-84. IEEE INTERNATIONAL CONFERENCE ON INDUSTRY APPLICATIONS (INDUSCON). 13., nov. 2018. Proceedings... [S.L.]: IEEE, 2018.

REN, Shaoqing; HE, Kaiming; GIRSHICK, Ross; SUN, Jian. **Faster R-CNN: towards real-time object detection with region proposal networks**. 2017. v. 39, n. 6, p. 1137-1149. IEEE Transactions On Pattern Analysis And Machine Intelligence. jun. 2017.

VASCONCELLOS, Bruno Meschiatti; ALMEIDA, Gustavo Maia de; CONTARATO, Rodrigo; ALMEIDA, Ricardo. **Classificação de amostras de café usando visão computacional**. 2019. p. 2505-2508. SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE. 14., 2019. Anais, Galoa.

ÍNDICE REMISSIVO

A

Algoritmos 83, 106, 154

Ambientes acadêmicos 74, 75

Aprendizagem 2, 13, 14, 15, 16, 17, 18, 19, 22, 23, 24, 25, 26, 28, 29, 30, 31, 32, 36, 38, 39, 40, 43, 44, 45, 48, 49, 50, 51, 71, 72, 76, 77, 78, 82, 150, 153, 154, 156, 157, 158, 159, 160

C

Café 83, 84, 85, 86, 88, 89, 90, 91, 92, 93

Campo conceitual aditivo 149, 150, 151, 152, 153, 155, 156, 157, 158, 159, 160, 161

Ciência da computação 6, 7

Ciências exatas 22, 158

Comunidade 6, 11

Covid-19 1

D

Desenvolvimento 6, 7, 8, 11, 12, 16, 17, 19, 23, 25, 26, 28, 29, 30, 31, 33, 35, 37, 38, 39, 42, 43, 62, 64, 75, 76, 95, 104, 107, 119, 150, 151, 160, 168, 169, 182

Docente 17, 18, 19, 23, 31, 32, 34, 38, 39, 40, 44, 47, 49, 63, 156, 159, 182

E

Ecologia 41, 42, 45, 47

Educação 1, 2, 3, 4, 5, 7, 14, 15, 16, 18, 19, 20, 23, 24, 27, 29, 30, 31, 32, 33, 34, 37, 38, 40, 45, 46, 47, 48, 49, 50, 51, 61, 63, 64, 71, 72, 76, 156, 157, 158, 159, 182

Educação científica 4, 19

Energia solar 94, 95, 96, 107

Ensino 1, 3, 5, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 40, 41, 42, 44, 45, 46, 47, 48, 49, 50, 51, 52, 53, 61, 62, 63, 64, 75, 76, 81, 156, 157, 158, 159, 160, 161

Estruturas aditivas 149, 152, 155, 156, 157, 158, 159, 161

Experimentação no ensino 13, 16, 17, 19, 20, 21, 24, 26, 31, 32, 33

Extensão 6, 7, 11, 12, 168, 172, 179

F

Fluidodinâmica computacional 136

M

Máquina 83, 85

Matemática 18, 19, 29, 30, 31, 32, 48, 49, 50, 51, 52, 53, 61, 62, 63, 64, 65, 68, 71, 72, 77, 120, 121, 149, 151, 152, 154, 156, 157, 158, 159, 160, 161

Meio ambiente 6, 7, 11, 23, 29, 94, 95

Métodos geofísicos 120, 121

Modelagem 22, 30, 94, 96, 105, 107, 108, 119, 120, 121, 123, 127, 128, 129, 133, 160, 175, 177

Motor ramjet 135

N

Non-linear damping 162, 163, 166

P

Painéis fotovoltaicos 94, 106, 107

Poluição ambiental 75

Poluição sonora 74, 75, 76, 78, 81, 82

Professor 14, 18, 19, 38, 49, 50, 51, 53, 54, 62, 64, 65, 68, 76, 77, 79, 80, 81, 149, 151, 152, 155, 159, 160, 182

Q

Química 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 40, 42, 43, 44, 45, 46, 47, 135

R

Recurso tecnológico 48, 51, 71, 72

Relato de experiência 6, 24, 32

S

Simulação 24, 32, 94, 96, 97, 98, 99, 100, 101, 102, 103, 106, 107, 112, 118, 133, 135, 136, 146

Software 2, 6, 7, 8, 9, 11, 75, 89, 94, 95, 96, 99, 106, 107, 110, 139, 140, 141, 158

Structures vibrations 162

Sustentabilidade 104, 119

T

Tecnologia 1, 2, 5, 17, 30, 31, 32, 33, 35, 49, 50, 75, 96, 104, 107, 158

CIÊNCIAS EXATAS E DA TERRA:

Conhecimentos didático-pedagógicos
e o ensino-aprendizagem



 www.atenaeditora.com.br
 contato@atenaeditora.com.br
 @atenaeditora
 www.facebook.com/atenaeditora.com.br


Ano 2022

CIÊNCIAS EXATAS E DA TERRA:

Conhecimentos didático-pedagógicos
e o ensino-aprendizagem



 www.atenaeditora.com.br
 contato@atenaeditora.com.br
 [@atenaeditora](https://www.instagram.com/atenaeditora)
 www.facebook.com/atenaeditora.com.br


Ano 2022