

DARLISSON MEDEIROS SANTOS

REDES NEURAIS CONVOLUCIONAIS PARA CLASSIFICAR A MATURAÇÃO DE
FRUTOS DE CAFÉ

Dissertação apresentada ao Programa de Pós-Graduação em Agricultura e Informações Geoespaciais da Universidade Federal de Uberlândia, Campus Monte Carmelo, como parte das exigências para obtenção do título de “Mestre” em Agricultura e Informações Geoespaciais.

Orientador

Prof. Dr. Cleyton Batista de Alvarenga

Coorientador

Prof. Dr. Murillo Guimarães Carneiro

MONTE CARMELO MG
MINAS GERAIS - BRASIL
2022

DARLISSON MEDEIROS SANTOS

REDES NEURAIS CONVOLUCIONAIS PARA CLASSIFICAR A MATURAÇÃO DE
FRUTOS DE CAFÉ

Dissertação apresentada ao Programa de Pós-Graduação
em Agricultura e Informações Geoespaciais da
Universidade Federal de Uberlândia, Campus Monte
Carmelo, como parte das exigências para obtenção do
título de “Mestre” em Agricultura e Informações
Geoespaciais.

APROVADO em 18 de fevereiro de 2022.

Banca examinadora

Prof. Dr. Cleyton Batista de Alvarenga – Instituto de Ciências Agrárias-ICIAG (UFU)

Dr. Enrique Anastacio Alves – Embrapa Rondônia

Dr. Rogner Carvalho Avelar – Educampo/SEBRAE/Expocaccer

Prof. Dr. Cleyton Batista de Alvarenga
Instituto de Ciências Agrárias-ICIAG (UFU)
(Orientador)

MONTE CARMELO-MG
MINAS GERIAS - BRASIL
2022

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

S237	Santos, Darlisson Medeiros, 1989-
2022	Redes neurais convolucionais para classificar a maturação de frutos de café [recurso eletrônico] : Redes neurais convolucionais para classificar a maturação de frutos de café / Darlisson Medeiros Santos. - 2022.
<p>Orientador: Cleyton Batista de Alvarenga. Coorientador: Murillo Guimarães Carneiro. Coorientadora: Gleice Aparecida de Assis. Coorientadora: Paula Cristina Natalina Rinaldi. Dissertação (Mestrado) - Universidade Federal de Uberlândia, Pós-graduação em Agricultura e Informações Geoespaciais. Modo de acesso: Internet. Disponível em: http://doi.org/10.14393/ufu.di.2021.359 Inclui bibliografia.</p>	
<p>1. Agronomia. I. Alvarenga, Cleyton Batista de ,1981-, (Orient.). II. Carneiro, Murillo Guimarães ,1988-, (Coorient.). III. Assis, Gleice Aparecida de ,1986-, (Coorient.). IV. Rinaldi, Paula Cristina Natalina ,1981-, (Coorient.). V. Universidade Federal de Uberlândia. Pós-graduação em Agricultura e Informações Geoespaciais. VI. Título.</p>	
CDU: 631	

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091


UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Coordenação do Programa de Pós-Graduação em Agricultura e Informações
Geoespaciais

Rodovia LMG 746, Km 01, s/nº, Bloco 1AMC, Sala 1A202, Monte Carmelo-MG, CEP 38.500-000
Telefone: (34) 3810-1033 - ppgaig@iciag.ufu.br


ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Agricultura e Informações Geoespaciais				
Defesa de:	Dissertação de Mestrado Acadêmico				
Data:	18/02/2022	Hora de início:	13:00	Hora de encerramento:	15:35
Matrícula do Discente:	32012AIG015				
Nome do Discente:	Darlisson Medeiros Santos				
Título do Trabalho:	Redes neurais convolucionais para classificar a maturação de frutos de café				
Área de concentração:	Informações geoespaciais e tecnologias aplicadas à produção agrícola				
Linha de pesquisa:	Sistemas integrados de produção vegetal				

Reuniu-se na sala virtual Microsoft Teams (https://teams.microsoft.com/l/meetup-join/19%3AIMKFWIOrPLwsVRxrsMzrxwZLQ20iC88Dw1_nI7sSbbI1%40thread.tacv2/1645197768878?context=%7B%22Tid%22%3A%22cd5e6d23-cb99-4189-88ab-1a9021a0c451%22%2C%22Oid%22%3A%2221d1dac0-348d-47b1-a802-5613b90d1859%22%7D) a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Agricultura e Informações Geoespaciais, assim composta: Dr. Enrique Anastácio Alves (EMBRAPA Rondônia), Dr. Rogner Carvalho Avelar(Educampo /SEBRAE/Expocacker), Dr. Cleyton Batista de Alvarenga (UFU) – orientador(a) do(a) candidato(a).

Iniciando os trabalhos o(a) presidente da mesa, Dr(a). Cleyton Batista de Alvarenga, apresentou a Comissão Examinadora e o candidato(a), agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(as) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

APROVADO

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Cleyton Batista de Alvarenga, Professor(a) do Magistério Superior**, em 18/02/2022, às 16:10, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Enrique Anastácio Alves, Usuário Externo**, em 16/03/2022, às 14:31, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Rogner Carvalho Avelar, Usuário Externo**, em 23/03/2022, às 16:32, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **3387925** e o código CRC **CD0FB7FE**.

Dedico este trabalho à minha família

AGRADECIMENTOS

Primeiramente a DEUS, criador de todas as coisas.

Ao professor Cleyton Batista de Alvarenga pelo incentivo, motivação e orientação para a conclusão deste projeto.

Ao professor Murillo Guimarães Carneiro pela orientação e esclarecimento.

Ao professor Gleice Aparecida de Assis pelo apoio, ensinamentos, sugestões e contribuições no trabalho.

Ao professor Paula Cristina Natalina Rinaldi pelo apoio, ensinamentos, sugestões e contribuições no trabalho.

Ao técnico de laboratório Renan Zampioli e ao amigo Anagê Calixto Mundim Filho pelo auxílio na execução do experimento.

Ao pesquisador Enrique Anastácio Alves pelas sugestões e contribuições no trabalho.

Aos produtores e amigos, Sr Walter Toshio Nishioka, Sr Acácio José Dianim, José Fernando Almeida Cordeiro, Fabio Kobiraki, Marcio Aparecido Macedo, Israel Alves e todos os demais, que permitiram as visitas em suas propriedades para a captura das imagens.

Ao meu pai Jair e a minha saudosa mãe Maria Agna. A meus irmãos Jackson, Jairo e Luciano pelo apoio.

A minha esposa Nayara e filho Filipe, pelo amor, compreensão, incentivo nos momentos difíceis.

“Entrega o teu caminho ao Senhor; confia nele, e ele o fará”. Salmos 37:5

RESUMO

A formação do preço do café é fortemente influenciada pela qualidade dos seus frutos. Essa qualidade é construída durante o seu desenvolvimento, fornecendo condições de nutrição, clima e sanidade adequadas. Definir o melhor momento para a colheita é fundamental para assegurar essa qualidade. O uso da tecnologia na agricultura tem contribuído com produtores rurais para o desenvolvimento de técnicas de manejo que permitem maior crescimento e desenvolvimento das lavouras. O objetivo deste trabalho foi desenvolver um método computacional utilizando redes neurais convolucionais, capaz de identificar frutos de café e sua maturação, que posteriormente será embarcado em um aplicativo mobile para definir o momento ideal de colheita do café, auxiliando o produtor na tomada de decisão. O trabalho foi desenvolvido utilizando imagens de frutos de café de propriedades rurais dos municípios de Romaria-MG e Monte Carmelo-MG. As imagens foram coletadas acompanhando a maturação fisiológica dos frutos de café, essas imagens foram analisadas, selecionadas e rotuladas por cinco especialistas, formando o banco de imagens. Após a criação do banco de imagens foram selecionados três modelos de redes neurais para serem treinados com as imagens, após ajustes o melhor modelo foi escolhido para desenvolver os protótipos. Foram desenvolvidos dois protótipos, um classifica a figura com saída de colher ou não colher e outro classifica os estádios de maturação dos frutos. Os resultados alcançados através de simulações computacionais foram satisfatórios, o protótipo colher ou não colher alcançou resultados de acurácia superiores a 92%.

Palavras-chave: MobileNet, MobileNetV2, NASNetMobile, Colheita do Café, Inteligência Artificial.

ABSTRACT

The price of coffee is strongly influenced by the quality of its fruits. This quality is built during its development, by providing adequate nutrition, climate, and health conditions. Defining the best time to harvest is fundamental to ensure this quality. The use of technology in agriculture has contributed to the rural producers for the development of management techniques that allow better growth and development of the plantations. The objective of this work was to develop a computational method using Convolutional Neural Networks, capable of identifying coffee fruits and their ripeness, which will later be embedded in a mobile application to define the ideal time to harvest coffee, helping the producer in the decision-making process. The work was developed using images of coffee fruits from rural properties in the cities of Romaria-MG and Monte Carmelo-MG. The images were collected following the physiological maturation of the coffee fruits. These images were analyzed, selected, and labeled by five specialists, forming the image bank. After the image bank was created, three neural network models were selected to be trained with the images. After adjustments, the best model was chosen to develop the prototypes. Two prototypes were developed, one classifies the image with an output of harvesting or not harvesting and the other classifies the maturation stages of the fruits. The results achieved through computer simulations were satisfactory, the harvest or not to harvest prototype reached accuracy results higher than 92%.

Keywords: Coffee Harvest. Artificial Intelligence. MobileNet. MobileNetV2. NASNetMobile.

1	INTRODUÇÃO	12
2	REVISÃO DE LITERATURA	13
2.1	FENOLOGIA DO CAFEEIRO	13
2.2	ÍNDICE DE MATURAÇÃO DO CAFEEIRO E PONTO DE COLHEITA	14
2.3	QUALIDADE DO CAFÉ DE ACORDO COM A CLASSIFICAÇÃO DE BEBIDA	16
2.4	COLORAÇÃO DOS FRUTOS	18
2.5	COLHEITA DO CAFÉ	19
2.6	VISÃO COMPUTACIONAL	21
2.7	MACHINE LEARNING	22
2.8	REDE NEURAL ARTIFICIAL	23
2.9	REDE NEURAL CONVOLUCIONAL - RNC	25
2.10	TENSORFLOW	29
2.11	MOBILENET	30
2.12	MOBILENETV2	33
2.13	NASNET MOBILE - NEURAL ARCHITECTURE SEARCH (NAS)	34
2.14	TRABALHOS RELACIONADOS	37
3	MATERIAIS E MÉTODOS	38
3.1	COLETA DAS IMAGENS PARA CRIAÇÃO DO BANCO DE IMAGENS	39
3.2	ROTULAGEM, CLASSIFICAÇÃO E SELEÇÃO DAS IMAGENS	40
3.3	PREPARAÇÃO DOS DADOS PARA TREINAMENTO	41
3.4	SELEÇÃO DO ALGORITMO DA REDE NEURAL	42
3.5	PARÂMETROS DE AJUSTE APLICADOS PARA TREINAMENTO	43
4	RESULTADOS E DISCUSSÃO	44
4.1	BANCO DE IMAGENS	44
4.2	RESULTADO APÓS TREINAMENTO DAS MODELOS (MOBILENET, MOBILENET V2 E NASNETS)	45
4.3	TESTE DO PROTÓTIPO EM CAMPO	48
4.3.1	<i>Protótipo 1 – Resposta de saída com valores binários</i>	48
4.3.2	<i>Protótipo 2 - Classificação multiclasse</i>	49
5	CONSIDERAÇÕES FINAIS	51

1 INTRODUÇÃO

O território brasileiro equivale a 850,3 milhões de hectares, a área explorada com pastagens, lavouras e florestas plantadas é de 256,8 milhões de hectares, sendo atividades que ocupam em torno de 30,2% do território nacional. O Brasil é o maior produtor e exportador e segundo maior consumidor mundial de café, com área plantada de 2,16 milhões de hectares na safra 2020. A produção total para a safra 2020 foi de 63,08 milhões de sacas beneficiadas de 60 kg, recorde de produção na série histórica nacional (CONAB, 2021).

Segundo dados do Observatório do Café do Consórcio Pesquisa Café, coordenado pela EMBRAPA Café, o estado de Minas Gerais foi o maior produtor do Brasil com uma produção recorde na safra 2020, o qual correspondeu a quase 55% da produção nacional, a estimativa para a safra 2021 ficou entre 19,8 e 22,1 milhões de sacas de café beneficiado (CONSÓRCIO PESQUISA CAFÉ, 2021).

O preço do café representa em grande parte a sua qualidade, cafés com maior qualidade possuem maior valor agregado. A formação da qualidade do café é influenciada por diversos fatores como a fertilidade do solo, nutrição das plantas, controle de pragas e doenças, disponibilidade de mão de obra e de maquinário e, principalmente, o estádio de maturação em que os frutos são colhidos (ALVES et al., 2020; GRACIANO et al., 2019).

O ponto ideal de colheita é fundamental para a manutenção da qualidade de bebida e sensorial do café. A definição do melhor momento para iniciar a colheita depende principalmente da identificação do estádio de maturação do fruto, que deve preferencialmente ocorrer no estádio cereja, momento que comumente ocorre sete meses após a florada principal, de abril a junho (HELENA et al., 2020; MEIRELES et al., 2009).

A metodologia atual de amostragem de frutos e separação em estádios de desenvolvimento para definir o índice de maturação não é empregada de maneira homogênea em todo o talhão, ou seja, amostra-se poucos pontos próximos a carreadores e infere-se que o restante da área esteja uniforme.

Entretanto, JACINTHO et al. (2017), KAZAMA et al. (2020) e MESQUITA et al. (2016a) demonstraram que há variabilidade espacial na maturação dentro da propriedade e dentro da planta.

A colheita antecipada ou tardia, efetuada com grande percentual de frutos verdes ou secos, reduz a qualidade do café. Frutos verdes vão exigir maior área para secagem em terreiros, ocasionarão bebida com sabor adstringente, além de menor rendimento, ou seja, maior volume

de café da roça necessário para obtenção de uma saca de 60 kg de café beneficiado (GRACIANO et al., 2019; MESQUITA et al., 2016a).

Assim, a definição do momento ideal para iniciar a colheita é um desafio ao cafeicultor. A visão humana é superficial para permitir uma definição clara, rápida e precisa do percentual de frutos em cada estádio de maturação, o que inviabiliza uma tomada de decisão rápida.

A metodologia de amostragem convencional, baseada no volume de frutos verdes (JACINTHO et al., 2017), demanda a coleta de amostras de frutos nos talhões, o que torna o processo de amostragem mais lento, outro problema é a baixa precisão na definição do estádio de maturação que reflete em baixo rigor amostral.

Uma alternativa para agrupar agilidade e precisão é a introdução da tecnologia da informação e suas diversas técnicas inseridas em dispositivos móveis, tais como aplicativos, que são ferramentas fáceis de manusear e acessíveis aos produtores e técnicos de campo.

Tal ferramenta pode auxiliar o agricultor na identificação do momento ideal de realizar a colheita, na organização das áreas da propriedade que devem ser colhidas em ordem cronológica e no planejamento do número de máquinas necessárias para realizar a colheita com eficiência, priorizando colher os frutos na máxima qualidade.

Desta forma, este trabalho foi conduzido com o objetivo de desenvolver uma metodologia computacional utilizando redes neurais convolucionais, capaz de identificar frutos de café e sua maturação, que pudesse ser embarcada em aplicativos mobile e, assim, apoiar o cafeicultor na decisão do melhor momento para realizar a colheita do café.

2 REVISÃO DE LITERATURA

2.1 Fenologia do cafeiro

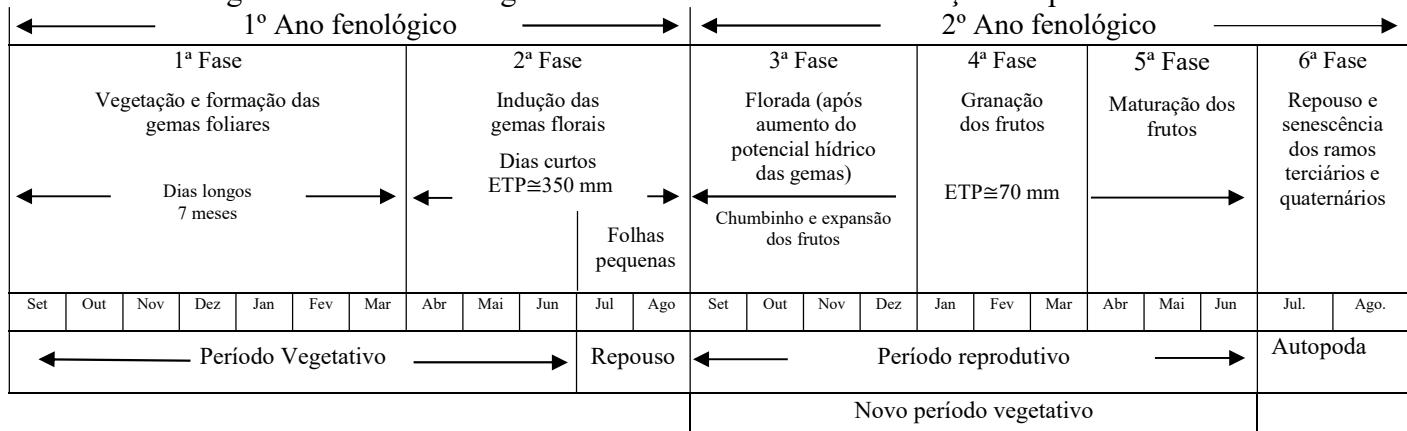
O cafeiro é uma Rubiácea, possui flores hermafroditas, porte arbustivo, originalmente é uma planta de sombra, prefere temperatura média de 22º com alta precipitação e altitude mais elevada, em temperaturas mais elevadas há um estímulo para a abertura dos botões florais, aumentando a frutificação (MACHADO et al., 2020).

Diferentemente de outras culturas é colhido com uma grande variação no teor de água dos frutos, o que torna o processo bastante trabalhoso. Essas variações no teor de água se dão devido a características evolutivas comuns em diversas espécies vegetais, assim como no café,

os frutos do terço superior ficam maduro primeiro, uma estratégia evolutiva que impede o esgotamento das suas reservas (MEIRELES et al., 2009).

Diante do clima tropical predominante no Brasil, vários esquemas foram realizados para definir a fenologia do cafeeiro, o mais aceito para as variedades Catuaí e Mundo novo é o modelo apresentado por CAMARGO; CAMARGO (2001) (Figura 1).

Figura 1 – Fases fenológicas do cafeeiro arábica nas condições tropicais do Brasil.



Fonte: CAMARGO; CAMARGO (2001).

A Figura 01 mostra a fenologia do cafeeiro dividido em seis fases, em dois anos, que é o período que leva para iniciar a produção. No primeiro ano ocorre processos vegetativos e no segundo inicia-se a florada (CAMARGO; CAMARGO, 2001; MEIRELES et al., 2009; MACHADO et al., 2020).

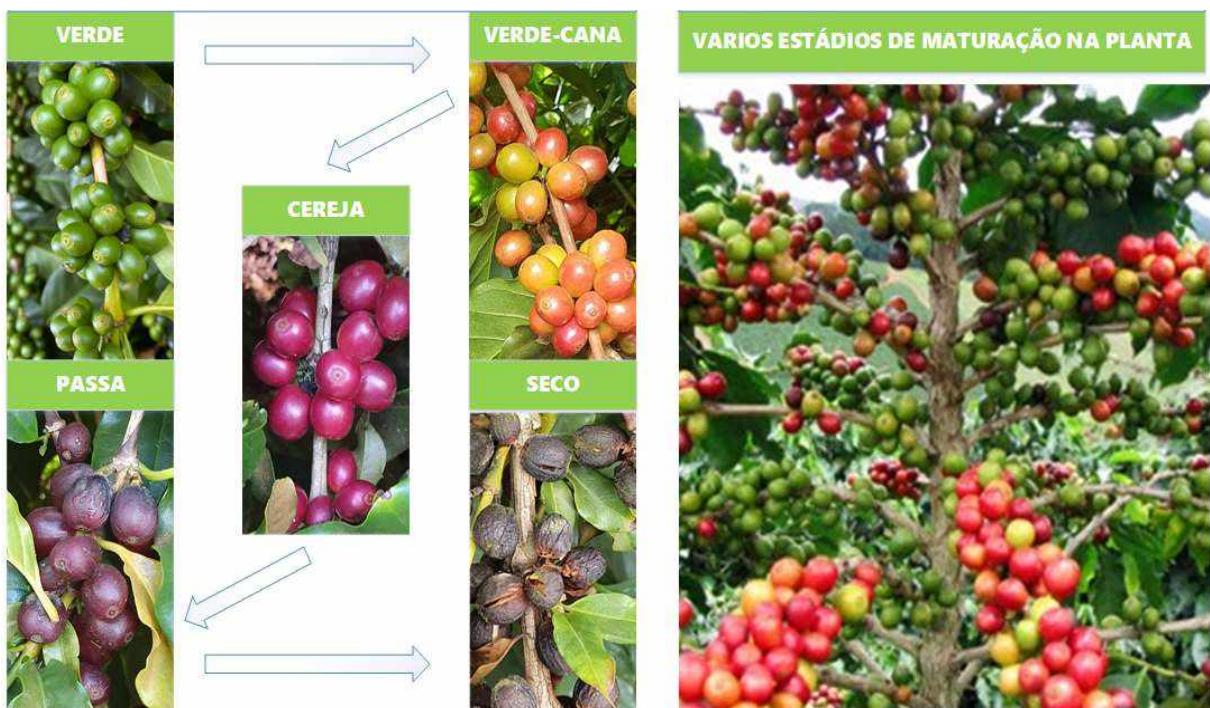
2.2 Índice de maturação do cafeeiro e ponto de colheita

O ponto de colheita é definido pelo índice de maturação dos frutos, ou seja, a percentagem de frutos no estádio cereja, que é o ponto ideal para iniciar a colheita, para isso divide-se a lavoura em talhões, seleciona-se aleatoriamente algumas plantas representativas de cada talhão, colhe o café e, após misturar o café colhido, retira-se um litro de café e faz a contagem (MESQUITA et al., 2016a), entretanto os frutos não ficam maduros de forma uniforme.

A metodologia atual de amostragem de frutos e separação em estádios de desenvolvimento para definir o índice de maturação não é empregada de maneira homogênea em todo o talhão, ou seja, amostra-se poucos pontos próximos a carreadores e infere-se que o restante da área esteja uniforme. Jacintho et al. (2017); Kazama et al. (2020) e Mesquita et al.

(2016a) demonstraram que há variabilidade espacial na maturação dentro da propriedade e dentro da planta, conforme Figura 2.

Figura 2 - Estágios de maturação dos frutos do café.



Fonte: O autor.

A decisão de deixar o café na planta (Figura 3), ou iniciar a derriça no momento menos propício, afeta negativamente o processo de colheita e a qualidade dos frutos. GRACIANO et al. (2019) e MESQUITA et al. (2016a) evidenciaram em seus trabalhos que o aumento na quantidade de frutos verdes e passa (Figura 3a) e a permanência do fruto na planta (Figura 3b) podem afetar a qualidade de bebida.

Figura 3 – Ação de microrganismos no café na planta/frutos imaturos.



Fonte: O autor.

GRACIANO et al. (2019) correlacionam a maior percentagem de frutos nos estádios passa e seco com a classificação de bebida em apenas mole, que poderia ter alcançado classificação estritamente mole caso tivesse mais frutos no estádio cereja. Portanto, na colheita tardia existirá muitos frutos secos (nas plantas e/ou no chão), o que ocasiona aumento do número de defeitos, pretos e ardidos, depreciando a qualidade do café. Além disso, no estádio cereja, os frutos se desprendem com maior facilidade, corroborando com SILVA et al. (2010).

GRACIANO et al. (2019), buscando relacionar estádios de maturação com características sensoriais em cultivares de *Coffea arábica* L. no município de Monte Carmelo-MG, observaram que onde havia maior número de frutos verdes e menor de frutos passa, a classificação de bebida por análise sensorial foi “dura verde”, já onde teve mais frutos secos e passa a amostra foi classificada como apenas “mole”, mostrando que o estádio passa e seco influenciaram diretamente na qualidade da bebida.

2.3 Qualidade do café de acordo com a classificação de bebida

A classificação de bebida do café é o que determina a qualidade do lote, essa classificação é importante para diferenciar cafés de qualidade elevada dos cafés comuns. Existem dois tipos de classificação de bebida, por tipo de bebida e pela prova da xícara (EMBRAPA CAFÉ, 2021).

A classificação por tipo de bebida leva em consideração características como variedade, aspecto, cor, formato dos grãos e peneira (Tabela 1).

Tabela 1 – Classificação de bebida de acordo com a metodologia por Tipo de Bebida.

Bebida Estritamente Mole	bebida de aroma muito agradável, suave e doce, podendo ser ingerida sem qualquer adição de açúcar. É considerada a melhor versão do café.
Bebida Mole	apresenta as características da bebida estritamente mole de forma menos intensa.
Bebida Apenas Mole	sabor levemente doce e suave, mas sem adstringência ou aspereza de paladar.
Bebida Dura	apresenta um travo na língua, transmitindo uma sensação de adstringência, como de comer uma fruta verde, porém, sem gostos estranhos à bebida.
Bebida Riada	leve aroma e sabor químico, que lembra o iodo ou ácido fênico.
Bebida Rio	tem aroma e sabor químico e medicinal mais acentuado que a bebida riada, com gosto de iodo ou ácido fênico.
Bebida Rio Zona	aroma e sabor químicos e medicinais muito presentes e percebidos com facilidade. Possui gosto marcante de iodo, sendo quase intolerável ao olfato e ao paladar.

Fonte: Blog Café com Excelência. <https://blog.cafeexcelencia.com.br/degustacao-de-cafe/> acesso em: 21/06/2021.

Já a classificação pela prova da xícara usa como parâmetro de classificação somente a prova da xícara, que recebe uma nota de 0 a 100 de acordo com a bebida, conforme a metodologia da Associação dos Cafés Especiais do Brasil-SCA (Tabela 2).

Tabela 2 – Classificação pela metodologia da Associação dos Cafés Especiais do Brasil – SCA.

85 pontos ou acima	Bebida estritamente mole – cafés especiais.
80 a 84 pontos	Bebida mole – cafés especiais.
75 a 79 pontos	Bebida apenas mole – cafés comerciais finos.
71 a 75 pontos	Bebida dura limpa – cafés comerciais.

Fonte: Associação dos Cafés Especiais do Brasil – SCA. Disponível em:

<http://siteantigo.bsca.com.br/classificacao-tipo-bebida.php>. Acesso em: 21/06/2021.

Neste sentido, de acordo com FERRAZ et al. (2017), o índice de maturação permite definir o período de colheita de um determinado talhão. Quando o talhão apresenta em suas plantas de 20 a 25% de frutos verdes indica que é o momento ideal para o início da colheita. Para MESQUITA et al. (2016a) este valor é de 20%; se estiver entre 10 e 15% de frutos verdes representa que a colheita está na metade de sua realização e menos que 5% caracteriza o fim da colheita. Portanto, este índice pode variar dentro do talhão, evidenciando a importância do monitoramento do índice de maturação no gerenciamento da colheita de frutos de cafeiro (FERRAZ et al., 2017).

A percentagem de frutos cereja no volume de café colhido indica se a colheita foi total ou seletiva (FERRAZ et al., 2017). Assim, determinar o momento para iniciar a colheita é um grande desafio ao cafeicultor, bem como o desenvolvimento de uma metodologia que seja rápida e precisa para auxiliar na tomada de decisão em relação ao momento certo para iniciar a derricha.

A colheita antecipada, efetuada com grande percentual de frutos verdes, é depreciativa a qualidade do café, pois além de exigir maior área para secagem do café em terreiros, também ocasiona bebida com sabor adstringente. Outro agravante é o prejuízo quantitativo, pois maior será o volume de café da roça necessário para obtenção de uma saca de 60 kg de café beneficiado (MESQUITA et al., 2016a).

2.4 Coloração dos frutos

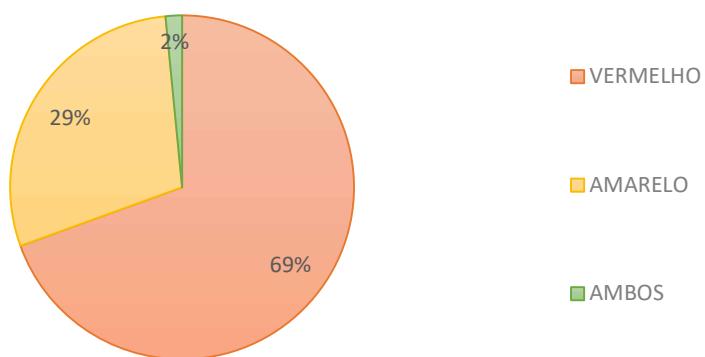
Existem até a data de 20 de julho de 2021, 131 cultivares de Coffea arábica L. e 41 cultivares de Coffea canéfora (conilon) com registro no Ministério da Agricultura, Pecuária e Abastecimento (MAPA), acesso disponível no site Cultivar Web, com base de dados RNC- Registro Nacional de Cultivares (MAPA, 2021). Apesar da diversidade de cultivares, as que se destacam em quantidade de área plantada são poucas.

Estima-se que a cultivar mais plantada no Brasil, 90% de todo café arábica cultivado no território nacional, são das cultivares Mundo Novo e Catuaí, os outros 10% das lavouras de café arábica são de cultivares variadas, destacando Paraíso, Topázio e Ouro Verde (CONSORCIO PESQUISA CAFÉ, 2021).

Esta é a realidade dos cafeeiros do cerrado. Na macrorregião de Monte Carmelo por exemplo, local onde a maioria das imagens utilizadas para construir o banco de dados deste trabalho foram obtidas, a maioria das imagens são das cultivares Mundo novo, Topázio e Paraíso.

Observando as 131 cultivares de Coffea arábica das 133 registradas no MAPA, aproximadamente 91 (69,5%) apresentam frutos na cor vermelho, 38 (29%) apresentam frutos de cor amarelo e 2 (1,5%) das cultivares apresentam cor dos frutos vermelho e/ou amarelo (Gráfico 2), das cultivares de Coffea canephora, frutos amarelos são raros, a cor que predomina é o vermelho diferindo entre si apenas na tonalidade, sendo alguns mais claros e outros mais escuros, tendendo ao vinho (MAPA, 2021).

Gráfico 2 – Cor dos frutos em relação as cultivares de Coffea arábica.



Fonte:<<http://www.consortiopesquisacafe.com.br/index.php/tecnologias/cultivares>; <http://www.iac.sp.gov.br/cultivares/inicio/resultados.php>; <https://www.fundacaoprocafe.com.br/cultivares>; https://blog.ucoffee.com.br/cor-do-cafe/#A_cor_dos_frutos_de_cafe>. Elaboração: O autor, 2021.

2.5 Colheita do café

Alguns fatores devem ser levados em consideração antes do início da colheita, o gerenciamento da colheita envolve a alocação de máquinas e implementos, no caso da colheita manual, a contratação de mão de obra, a disponibilidade de terreiros para secagem, transporte entre outros fatores, contribuem para a manutenção/preservação da qualidade do café colhido (MESQUITA et al., 2016b).

Existem duas modalidades principais na colheita do café, a colheita manual e a colheita mecanizada. O tipo de colheita a ser implementado depende das características de cada região, regiões montanhosas com declividade mais acentuada dificultam a utilização de máquinas pesadas, sendo assim, outros meios para se colher o café devem ser utilizados, como a colheita manual e a utilização de colhedoras mecânicas de pequeno porte com braços vibratórios (MESQUITA et al., 2016b).

A colheita deve iniciar quando maior parte dos frutos estão no estádio cereja, evitando colher uma quantidade muito grande de frutos verdes ou frutos em estádios mais avançados de maturação (KAZAMA et al., 2020).

A colheita manual seletiva (Figura 4) é a remoção dos frutos a mão. Essa era a principal forma de colheita utilizada antes da implementação de colhedoras mecânicas ou derriadoras, cafés de montanha ou em áreas de difícil mecanização geralmente são colhidos dessa forma (MESQUITA et al., 2016b; SILVEIRA et al., 2020).

Figura 4 – Colheita manual seletiva do café.



Fonte: <https://agropos.com.br/colheita-de-cafe/>

A colheita manual ocorre principalmente em regiões de baixa tecnificação ou onde a mecanização se torna dificultada. A colheita manual seletiva, grão a grão, realizada quando a

intenção é produzir um café com qualidade superior está crescendo em várias propriedades brasileiras, café especiais que alcançam valores de comercialização recordes vem ganhando conhecimento mundialmente (MESQUITA et al., 2016a).

Deve-se ficar atento aos danos que a colheita manual pode ocasionar aos ramos do cafeiro, como por exemplo evitar a desfolha excessiva e ferimentos aos ramos, que podem servir de porta de entrada a doenças, comprometendo a capacidade produtiva da safra seguinte (MESQUITA et al., 2016b).

A colheita mecânica realizada por máquinas autopropelidas e de arrasto é uma das mais utilizadas em grandes propriedades na região do Cerrado, além do ganho em tempo, representa um incremento a qualidade final do café por realizar a transferência do fruto colhido diretamente para carretas ou BIG bags, evitando o contato do fruto com o solo (MESQUITA et al., 2016b), a Figura 5 apresenta dois dos principais modelos de colhedoras mais utilizados.

Figura 5 – Colhedoras de arrasto e autopropelida para a derriça de frutos de café.



Fonte: <https://www.bing.com/images/search?q=tipos+de+colhedoras+de+café>

A colhedora de café do tipo arrasto ou tracionada é acoplada à barra de tração e na tomada de potência do trator. Já a colhedora automotriz apresenta propulsão própria, sendo que algumas possuem bica lateral para transferência do grão colhido. Devido a expansão da produção agrícola no cerrado e em regiões de relevo mais plano, o uso de tecnologias que contribuem com a agilidade das operações no campo é de grande importância para o produtor, o uso de colhedoras contribuiu com a expansão da cafeicultura no cerrado (MESQUITA et al., 2016b).

A velocidade de trabalho, a intensidade de vibração, força inercial e distribuição das varetas vibratórias, são regulagens que podem ser alteradas para atender situações diversas no momento da colheita, podendo realizar a colheita total ou seletiva, removendo parte das varetas da colhedora (KAZAMA et al., 2020; MESQUITA et al., 2016a).

Devido a inconsistência da maturação dos frutos, pode-se optar por fazer a colheita seletiva do café com mais de uma operação da colhedora, que colhe o café em etapas, conforme o amadurecimento dos frutos (DA SILVA et al., 2013). O número de operações na colheita mecanizada pode ser parte da solução para este problema, cafés com carga intermediária (50,78 sacas de café beneficiado ha^{-1}), realidade da maioria dos produtores do cerrado, demonstrou resultado satisfatório com duas operações, não sendo necessário o repasse manual (SANTINATO et al., 2017).

Ainda assim é necessário que se faça mais pesquisas nesse sentido, realizar a colheita de apenas parte da planta, ou seja, colheita seletiva dos terços do cafeiro, pode não ser possível devido ao custo operacional. No entanto, colher primeiramente os frutos do terço superior da planta resultam em melhor classificação de bebida por colher poucos grãos verdes, mas para Kazama et al. (2020) os custos superam a receita.

Outro fator a ser considerado é a força de trabalho exercido sobre a planta, deve se atentar para a velocidade de trabalho para que a planta não sofra danos, na colheita seletiva essa regulagem pode permitir que apenas os frutos maduros sejam colhidos (Silva et al., 2017).

O efeito do tempo na força de desprendimento dos frutos foi observado em avaliação realizada com diferenças de 28 e 32 dias uma da outra. BARROS et al. (2018) e CORREA et al. (2017) correlacionam tais oscilações na força de desprendimento dos frutos do cafeiro com variáveis climáticas, precipitação, umidade de solo e umidade dos frutos ao longo do período de maturação, também puderam observar decréscimo nos valores de força de desprendimento para frutos de café em estádios verde e cereja de acordo com o intervalo de tempo.

2.6 Visão computacional

A visão computacional, por meio do processamento de imagens, apresenta uma grande capacidade de distinguir cores. Já a visão humana apresenta uma capacidade limitada de observar as diferentes tonalidades de cor.

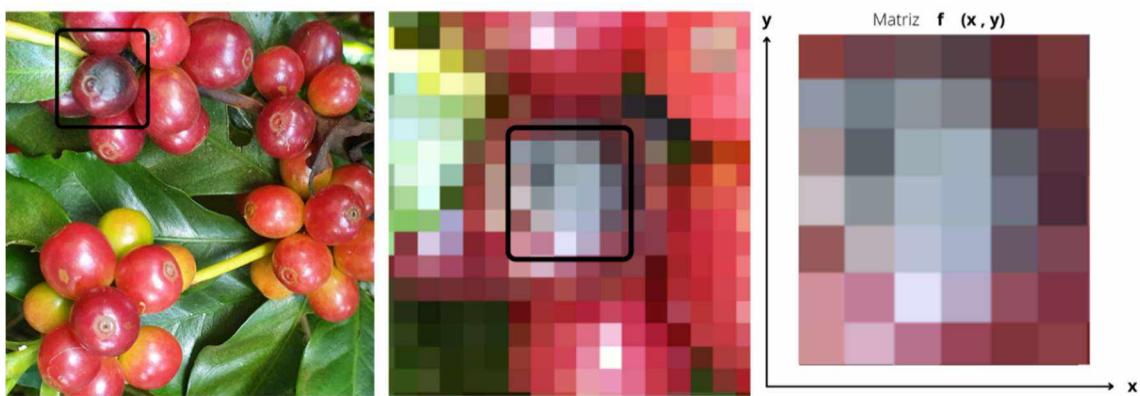
Essa restrição, associada às condições de gerenciamento das atividades agrícolas que envolvem o planejamento do momento da colheita do café, podem interferir na avaliação do observador e influenciar sua decisão em relação ao momento ideal para iniciar a colheita (SHAPIRO; STOCKMAN, 2000).

Desta forma, o uso da visão computacional permite uma avaliação mais precisa da tonalidade dos frutos e, com auxílio de um algoritmo matemático, tem potencial de reduzir a

influência de fatores externos à maturação dos frutos, permitindo decidir sobre o momento de iniciar a colheita, beneficiando a qualidade da bebida (HAMUDA; GLAVIN; JONES, 2016).

Uma Figura Digital é composta por elementos chamados de pontos ou pixels, distribuídos no formato de uma matriz de tamanho (x y) (Figura 6). Diferentemente da Figura Analógica, em uma Figura Digital os valores da função são finitos e discretos (GONZALES; WOODS, 2010).

Figura 6 – Exemplo de uma Figura Digital.



Fonte: O autor.

O processamento digital de imagens tem sido bastante empregado na agricultura com fins diversos, entre eles destacam-se a mensuração de nutrientes das plantas, análise de plantio (JI; QI, 2011), identificação e classificação de pragas (WEN; ZHU, 2010), doenças (ABD EL-GHANY; ABD EL-AZIZ; MAREI, 2020) e plantas daninhas (MESAS-CARRASCOSA et al., 2020), estimativa de produção (PAYNE et al., 2013), produção e mapeamento da cultura cafeeira (MARUJO et al., 2017), levantamento topográfico (SILVEIRA; MENDES; FERRARI, 2017), entre outras.

2.7 Machine Learning

O Machine Learning já vem sendo estudado para que possa ser utilizado em diversos setores, alguns já em funcionamento, funções que demandam respostas simples como sim ou não já funcionam com êxito, outros mais complexos como por exemplo indicadores de sinais precoce para diagnósticos diversos, automação da produção em fábricas (fármacos, automóveis, têxtil, alimentos etc.) e controle de tráfego, são algumas aplicações promissoras (LUDERMIR, 2021).

O aprendizado de máquina consiste na ideia de que a máquina aprenda a identificar padrões e tomar decisões a partir de um banco de dados com a mínima intervenção humana. O aprendizado de máquina utiliza um algoritmo de Inteligência Artificial para analisar dados e encontrar padrões, podendo assim ser utilizado de forma aplicada (KHAN et al., 2021), podendo ser considerado a base para o desenvolvimento de redes neurais artificiais.

2.8 Rede neural artificial

O conceito de rede neural artificial foi elaborado através da observação do funcionamento do cérebro biológico em 1943, pelo neurofisiologista Warren McCulloch e o matemático Walter Pitts, eles escreveram um artigo sobre o funcionamento do cérebro e desenvolveram um algoritmo denominado lógica limiar (HAYKIN, 2001, 2015).

Basicamente, o neurônio biológico é composto por um corpo celular onde a informação é processada, o axônio é por onde o impulso nervoso é deslocado para chegar em outra célula, os dendritos transmissores são responsáveis pela transferência do estímulo nervoso aos dendritos receptores que levarão a informação ao corpo celular (SOARES FILHO, 2018; HAYKIN, 2001).

Figura 7 – Representação Simplificada do Neurônio Biológico.



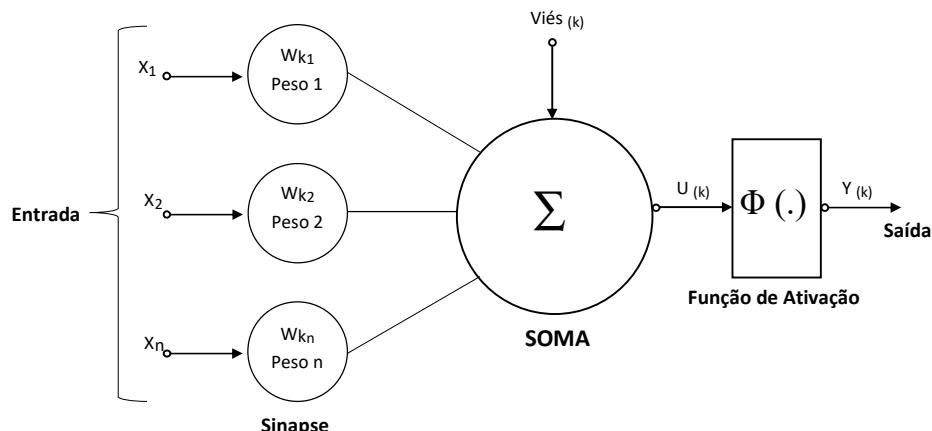
Fonte: O autor. Adaptado, disponível em: <https://mundoeducacao.uol.com.br/biologia/neuronios.htm> - acesso em 24/07/2020

Após vários avanços no desenvolvimento de redes neurais, em 1956, com a criação do projeto de pesquisa de verão de Dartmouth sobre inteligência artificial - IA, o neurobiólogo Frank Rosenblatt iniciou o desenvolvimento do perceptron, este modelo faz a soma das entradas e depois aplica um limitador (bias), se a soma do resultado for positiva o limitador gera uma saída +1, caso contrário gera uma saída -1 (Figura 8) (HAYKIN, 2015).

- Sinais de entrada $\{X_1, X_2, \dots, X_n\}$: São os dados que alimentam seu modelo preditivo, fotos, dígitos numéricos etc.
- Pesos sinápticos $\{W_1, W_2, \dots, W_n\}$: São valores que atuam sobre os dados de entrada. Esses valores são aprendidos durante o treinamento.
- Combinador linear $\{ \Sigma \}$: Esta função reúne os resultados obtidos através das imagens de entrada para definir um potencial de ativação.
- Limiar de ativação $\{ \Theta \}$: Irá julgar o resultado produzido para que o combinador linear possa gerar um valor de disparo de ativação.
- Potencial de ativação $\{ u \}$: É a diferença entre o combinador linear e o limiar de ativação. Para valores de $u \geq 0$ o resultado receberá um estímulo positivo e vice-versa.
- Função de ativação $\{ g \}$: Seu objetivo é limitar a saída de um neurônio em um intervalo de valores.
- Sinal de saída $\{ y \}$: É o valor de saída, no caso de a rede neural possuir camadas ocultas, este valor não necessariamente será da última camada.

A rede neural descrita acima corresponde ao perceptron (Figura 8), uma das primeiras arquiteturas de rede neural desenvolvida, após o perceptron novas arquiteturas foram desenvolvidas, uma delas foi a rede Neural Convolucional, que utiliza camadas ocultas entre as camadas de entrada e de saída (DATA SCIENCE ACADEMY, 2021; FILHO, 2018).

Figura 8 – Representação Simplificada do Neurônio Matemático.



Fonte: Disponível em: <https://deeplearningbook.com.br/o-neuronio-biologico-e-matematico>

2.9 Rede Neural Convolucional - RNC

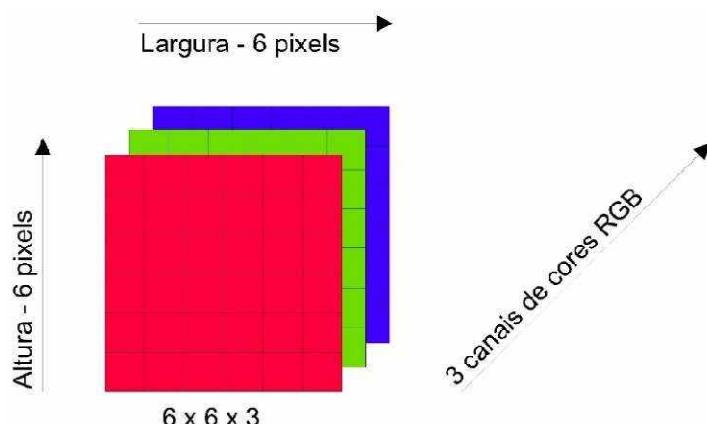
As redes neurais convolucionais fazem parte de um campo do Machine Learning. Elas foram bioinspiradas tendo como base o córtex visual de mamíferos, assim como a fonte de inspiração as Redes Neurais Convencionais - CNNs respondem muito bem a solução de problemas relacionados a classificação de imagens, a área de visão computacional foi uma das que mais se beneficiaram, tendo aplicações em diversos setores que empregam esse campo (DATA SCIENCE ACADEMY, 2021; SOARES FILHO, 2018; HAYKIN, 2001, 2015).

Existem diversas arquiteturas de RNAs, cada uma com suas particularidades, essas diferenças na construção das arquiteturas influenciam na escolha de qual rede será mais adequada para solucionar um dado problema, redes de camada única, redes multicamadas e redes recorrentes são exemplos de arquiteturas que se diferem por exemplo em número de camadas e a forma de realimentação dos neurônios (SOARES FILHO, 2018; HAYKIN, 2001).

Uma Rede Neural Convolucional possui em sua construção camadas de neurônios matemáticos, cada neurônio recebe como entrada uma figura que serão processadas e alimentarão a camada subsequente (DATA SCIENCE ACADEMY, 2021), as imagens de entrada podem possuir uma ou mais dimensões, uma figura de uma dimensão é processada e transformada em tons de cinza, cada pixel receberá uma valor entre 0 e 1 dependendo do tom de cinza que ele possuir, partindo do 0 que é totalmente branco até 1 que é totalmente preto.

A figura também pode conter mais de uma dimensão. Imagens coloridas possuem três dimensões representáveis, o vermelho, o verde e o azul, essas imagens são representadas por uma matriz de três dimensões (altura, largura e profundidade), o processo de convolução irá transformar a figura em uma matriz $6 \times 6 \times 3$, como exemplificado na Figura 9 (KERAS, 2021; MUNDIM FILHO, 2021).

Figura 9 - Estrutura básica de uma matriz RGB de 3 dimensões.

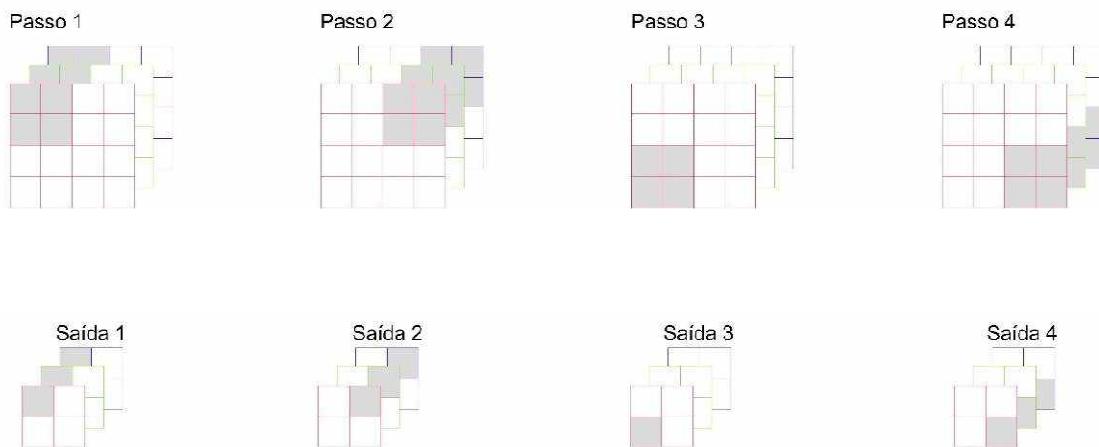


Fonte: O autor (2022).

Além da camada de entrada, uma rede neural convolucional possui camadas intermediárias, estas por sua vez também são denominadas camadas ocultas. Após a figura passar pela camada de entrada ela passa por um filtro para reduzir as dimensões da matriz gerada, essa etapa ocorre na camada denominada Pooling, após isso a matriz gerada será convoluída nas camadas ocultas através de cálculos e multiplicação de matrizes (função peso), uma convolução em profundidade possui também o fator espacial, assim, no modelo acima, teremos 3 convoluções espaciais (KERAS, 2021; MUNDIM FILHO, 2021).

Definindo os parâmetros de cada etapa da convolução temos o stride, que significa passo ou o número de pixels que o filtro de convolução irá se locomover (Figura 10).

Figura 10 - Processo de convolução de uma matriz de tamanho 4x4, passo de tamanho 2 e suas respectivas saídas reduzidas em uma matriz 2x2.



Fonte: O autor (2022).

A função padding é utilizada quando as dimensões da Figura não correspondem ao filtro utilizado, dessa maneira essa função irá deletar ou preencher os espaços da matriz para que as dimensões sejam coincidentes, ajustando os valores para o objetivo desejado (DATA SCIENCE ACADEMY, 2021; KERAS, 2021; MUNDIM FILHO, 2021).

A função ReLU - Não Linearidade tem a finalidade de retirar os números negativos quando surgirem, utilizando a expressão $f(x) = \max(0, x)$, mantendo os números positivos e zerando os negativos (Figura 11) (DATA SCIENCE ACADEMY, 2021; MUNDIM FILHO, 2021).

Figura 11 - Função de ativação ReLU.

-4	4	3	-1
2	2	-2	-6
-2	-1	4	-5
4	5	3	-1

0	4	3	0
2	2	0	0
0	0	4	0
4	5	3	0

Fonte: O autor (2022).

A camada de agrupamento Pooling é utilizada para reduzir o tamanho da matriz de saída da convolução, ela agrupa os pixels mantendo o pixel de maior valor ou a média da soma dos valores na matriz de saída, isso irá ajudar na redução do custo operacional. O mais conhecido é o Max Pooling, esta camada, assim como a camada de convolução, pode ser aplicada diversas vezes dentro da rede, dependendo do objetivo ou do tamanho dos dados de entrada ou número de camadas ocultas, assim o cientista de dados pode optar por usar mais vezes reduzindo e agrupando os valores para reduzir o tamanho da matriz gerada (Figura 12) (DATA SCIENCE ACADEMY, 2021; MUNDIM FILHO, 2021).

Figura 12 - Exemplo de camada Max Pooling.

5	4	3	1
2	2	1	6
8	3	4	5
4	5	3	1

Max Pool →

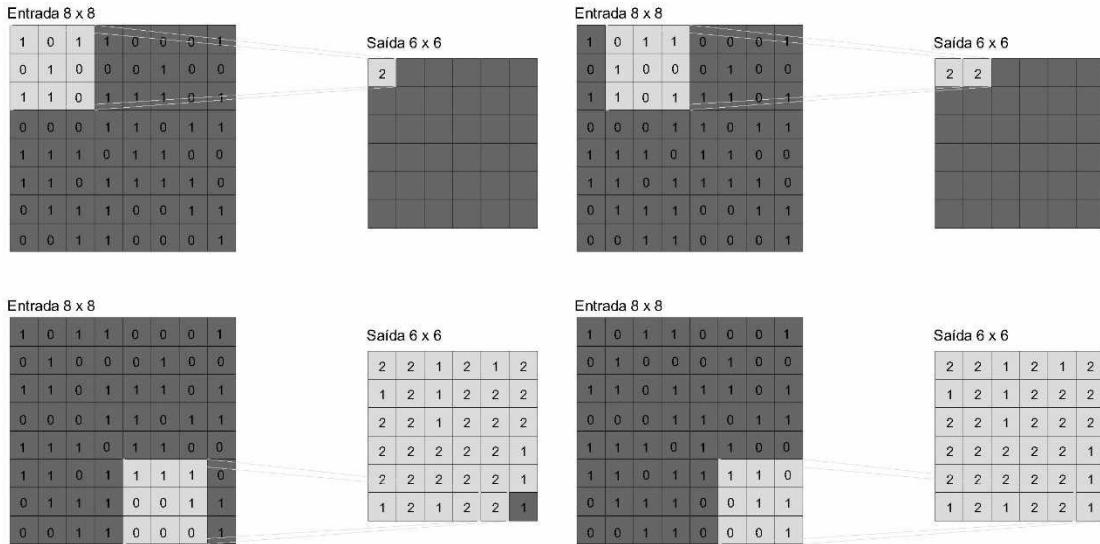
Filtro - (2 x 2)
Passo - (2 x 2)

5	6
8	5

Fonte: O autor (2022).

A camada totalmente conectada (Fully Connected Layer-FC) é a última camada antes da saída, ela faz um achatamento da matriz gerando através desse processo um vetor, esse vetor irá passar pela camada FC na qual irá passar pelos pesos Soft Max ou Sigmoide, que irão realizar a predição. Nesta, cada camada de entrada possui um peso para cada camada de saída, além disso cada nó das camadas de saída possui um bias, fornecendo assim valores diferentes para cada camada de saída (Figura 13) (DATA SCIENCE ACADEMY, 2021; KERAS, 2021).

Figura 13 - Processo de convolução completa com um filtro 3x3 de valores 1,0,1,0,1,0,1,0,1.



Fonte: O autor (2022).

As redes neurais convolucionais possuem em sua arquitetura três camadas predominantes (convolucional, Pooling e totalmente conectadas), outras camadas podem compor a arquitetura das CNNs dependendo do objetivo (SOARES FILHO, 2018; KERAS, 2021; LI et al., 2016; MUNDIM FILHO, 2021), veremos uma delas mais adiante.

As principais arquiteturas de redes neurais convolucionais são: LeNet, utilizada na leitura de códigos postais, dígitos, letra cursiva, etc.; AlexNet, desenvolvido por Alex Krizhevsky, Ilya Sutskever e Geoff Hinton, se difere da LeNet em profundidade, tamanho e arranjo das camadas de convolução e Pooling; ZF Net, desenvolvida por Matthew Zeiler e Rob Fergus, foi um aprimoramento da AlexNet, camadas convolucionais intermediárias, diminuição do passo e do filtro da primeira camada; GoogLeNet, desenvolvimento de um Inception Module que reduz o número de parâmetros da rede; VGGNet, foi desenvolvida por Karen Simonyan e Andrew Zisserman, do Visual Geometry Group do Department of Engineering Science, da Universidade de Oxford; ResNet, desenvolvida por Kaiming He e seu grupo, considerado o estado da arte em modelos de redes neurais convolucionais (DATA SCIENCE ACADEMY, 2021; SOARES FILHO, 2018; IAN GOODFELLOW; BENGIO; COURVILLE, 2016; LI et al., 2016). Alguns desses modelos foram precursores para o desenvolvimento das Mobile Nets que veremos mais adiante, essas “novas arquiteturas” podem ser encontradas em plataformas de desenvolvimento como veremos no tópico a seguir.

2.10 TensorFlow

A plataforma TensorFlow é uma biblioteca digital para desenvolvedores de modelos de aprendizado de máquina em linguagem computacional Javascript e Python, nesse ambiente o usuário pode encontrar diversos modelos disponíveis, estes modelos já foram pré treinados em bancos de dados como o ImageNet, podendo o usuário selecionar o melhor modelo para o seu problema, tendo como base o tamanho, a precisão, quantidade de parâmetros utilizados e a profundidade do modelo (ARAÚJO et al., 2017; KERAS, 2021; “TENSORFLOW”, 2021).

Essa plataforma de código aberto possui diversas interfaces de programação de aplicação (API) para facilitar sua aplicabilidade no desenvolvimento de novos produtos. A API Keras.io acentua quatro características que tornam sua usabilidade mais acessível: 1) execução eficiente de operações de tensor de baixo nível na CPU, GPU ou TPU; 2) calcular o gradiente de expressões diferenciáveis arbitrárias; 3) escalar a computação para muitos dispositivos, como clusters de centenas de GPUs e; 4) exportar programas (“gráficos”) para tempos de execução externos, como servidores, navegadores, dispositivos móveis e incorporados (KERAS, 2021).

Além dessas características, o TensorFlow oferece informações que dão suporte a engenheiros e cientistas de dados em todo o processo de desenvolvimento do projeto, na tabela 4 apresentamos os principais modelos disponíveis.

Tabela 4 - Principais modelos de rede neurais disponíveis na plataforma Keras.

Modelo	Tamanho	Precisão principal	5 principais precisões	Parâmetros	Profundidade
<u>Xception</u>	88 MB	0,790	0,945	22.910.480	126
<u>VGG16</u>	528 MB	0,713	0,901	138.357.544	23
<u>ResNet50</u>	98 MB	0,749	0,921	25.636.712	-
<u>ResNet152V2</u>	232 MB	0,780	0,942	60.380.648	-
<u>InceptionV3</u>	92 MB	0,779	0,937	23.851.784	159
<u>InceptionResNetV2</u>	215 MB	0,803	0,953	55.873.736	572
<u>MobileNet</u>	16 MB	0,704	0,895	4.253.864	88
<u>MobileNetV2</u>	14 MB	0,713	0,901	3.538.984	88
<u>DenseNet121</u>	33 MB	0,750	0,923	8.062.504	121
<u>DenseNet169</u>	57 MB	0,762	0,932	14.307.880	169
<u>DenseNet201</u>	80 MB	0,773	0,936	20.242.984	201
<u>NASNetMobile</u>	23 MB	0,744	0,919	5.326.716	-
<u>EfficientNetB0</u>	29 MB	-	-	5.330.571	-
<u>EfficientNetB1</u>	31 MB	-	-	7.856.239	-
<u>EfficientNetB2</u>	36 MB	-	-	9.177.569	-

Modelo	Tamanho	Precisão principal	5 principais precisões	Parâmetros	Profundidade
<u>EfficientNetB3</u>	48 MB	-	-	12.320.535	-
<u>EfficientNetB4</u>	75 MB	-	-	19.466.823	-

Fonte: <https://keras.io/api/applications/>

2.11 MobileNet

As MobileNets são arquiteturas simplificadas das redes neurais convolucionais clássicas, foram criadas pensando em simplificar a etapa de convolução, comprimindo essa etapa, fazendo com que a arquitetura ocupe menos espaço. Foram selecionadas três arquiteturas de redes neurais disponíveis na biblioteca Keras: a MobileNet, a MobileNetV2 e a NASNetMobile (KERAS, 2021).

Um tipo diferente de convolução pode ser empregado nas arquiteturas mobile, abaixo é descrito esta convolução e comparado com a convolução padrão. Uma camada de convolução padrão possui em sua estrutura uma única unidade de convolução padrão, a estrutura fica disposta na configuração camada convolucional padrão (Conv) e canal de saída (BN) seguida pela função de não linearidade (ReLU).

Figura 14 - Bloco definindo a convolução pontual (padrão).



Fonte: Howard et al. (2017).

A camada de convolução separável em profundidade possui uma única unidade de convolução separável em profundidade e possui a seguinte configuração: camada de convolução separável (Depthwise conv), canal de saída (BN), função de não linearidade (ReLU), camada convolucional padrão (Conv) e canal de saída (BN) seguida pela função de não linearidade (ReLU) (HOWARD et al., 2017; KERAS, 2021; MUNDIM FILHO, 2021; TSANG, 2021).

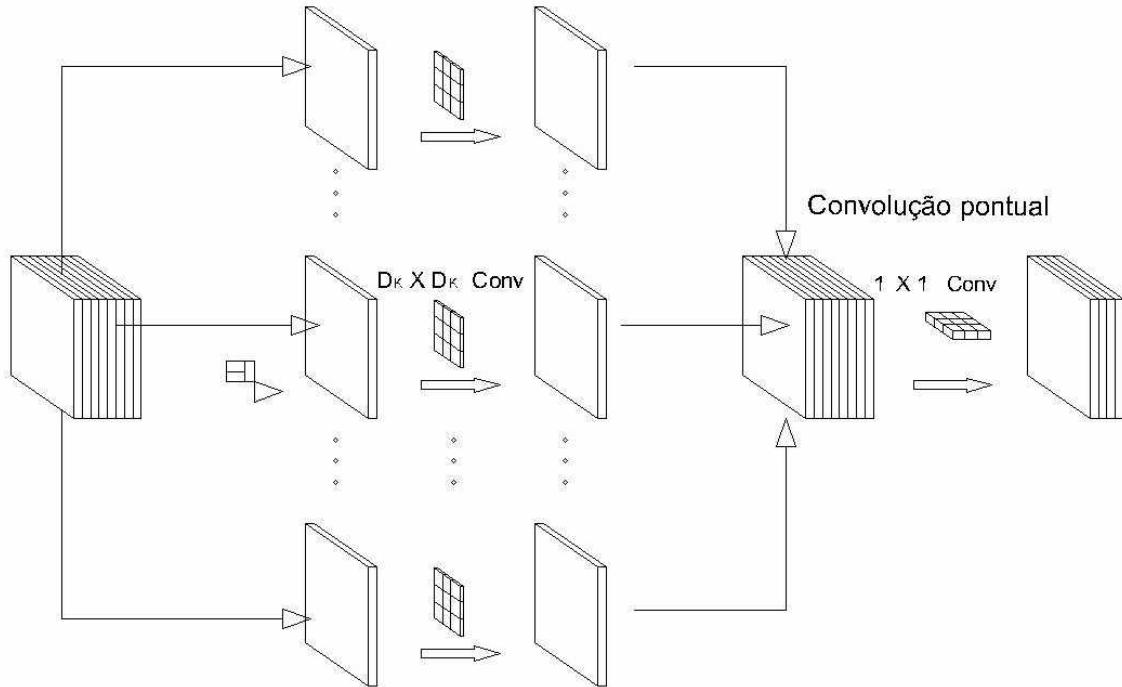
Figura 15 - Bloco definindo a convolução separável.



Fonte: Howard et al. (2017).

Abaixo temos a arquitetura completa da uma MobileNet com convolução separável e convolução pontual (padrão).

Figura 16 - Arquitetura completa da uma MobileNet.
Convolução em profundidade



Fonte: Adaptado de : Sic-Ho-Tsang, disponível em: <https://towardsdatascience.com/review-mobilenetv1-depthwise-separable-convolution-light-weight-model-a382df364b69>

Os dados de entrada, após passar pelo filtro, passarão primeiramente por uma convolução separável e por todos os seus nós e neurônios, posteriormente por uma convolução pontual 1x1 para redução da dimensão e custo operacional, gerando assim uma matriz de saída de menor dimensão que a entrada (HOWARD et al., 2017; KERAS, 2021; TSANG, 2021).

A fórmula abaixo representa estas duas convoluções, da esquerda para a direita, convolução separável e convolução pontual (Equação 1).

$$D_K \cdot D_K \cdot M \cdot D_F \cdot D_F + M \cdot N \cdot D_F \cdot D_F \quad (1)$$

Onde M representa o número de canais de entrada, N representa o número de canais de saída, D_K representa o tamanho do kernel (função que transforma um algoritmo linear em não linear) e D_F que representa o tamanho do mapa de características que será plotado.

A partir dessas operações teremos como resultado uma convolução pontual e seu custo de processamento para a máquina (Equação 2).

$$D_K \cdot D_K \cdot M \cdot N \cdot D_F \cdot D_F \quad (2)$$

Finalmente teremos como resultado a redução do cálculo custo composto, ou seja, da convolução separável em profundidade/custo de convolução padrão (Equação 3).

$$\frac{D_K \cdot D_K \cdot M \cdot D_F \cdot D_F + M \cdot N \cdot D_F \cdot D_F}{D_K \cdot D_K \cdot M \cdot N \cdot D_F \cdot D_F} = \frac{1}{N} + \frac{1}{D_K^2} \quad (3)$$

Após a convolução poderemos aplicar o comando de normalização em lote e ReLU, quando comparamos a convolução padrão com a convolução separável temos um ganho computacional devido à redução na quantidade de parâmetros necessários para obter precisão similar entre elas (DATA SCIENCE ACADEMY, 2021; HOWARD et al., 2017; KERAS, 2021).

Tabela 5: Comparaçāo convolução separável em profundidade e convolução padrão.

Modelo	ImageNet Acurácia	Million Mult-Adds	Million Parameters
Conv MobileNet	71.7%	4866	29.3
MobileNet	70.6%	569	4.2

Fonte: Howard et al. (2017); Keras (2021).

Tabela 6: Arquitetura completa de Rede Neural MobileNet diferenciando o Kernel, tamanho de entrada, passo e tipo de convolução em cada camada.

Modelo	Passo	Forma do Kernel	Tamanho de entrada
Conv	2	$3 \times 3 \times 3 \times 32$	$224 \times 224 \times 3$
Conv dw	1	$3 \times 3 \times 32$	$112 \times 112 \times 32$
Conv	1	$1 \times 1 \times 32 \times 64$	$112 \times 112 \times 32$
Conv dw	2	$3 \times 3 \times 64$	$112 \times 112 \times 64$
Conv	1	$1 \times 1 \times 64 \times 128$	$56 \times 56 \times 64$
Conv dw	1	$3 \times 3 \times 128$	$56 \times 56 \times 128$
Conv	1	$1 \times 1 \times 128 \times 128$	$56 \times 56 \times 128$
Conv dw	2	$3 \times 3 \times 128$	$56 \times 56 \times 128$
Conv	1	$1 \times 1 \times 128 \times 256$	$56 \times 56 \times 128$
Conv dw	1	$3 \times 3 \times 256$	$28 \times 28 \times 256$
Conv	1	$1 \times 1 \times 256 \times 256$	$28 \times 28 \times 256$
Conv dw	2	$3 \times 3 \times 256$	$28 \times 28 \times 256$
Conv	1	$1 \times 1 \times 256 \times 512$	$14 \times 14 \times 256$
Conv dw	1	$3 \times 3 \times 512$	$14 \times 14 \times 512$
Conv	1	$1 \times 1 \times 512 \times 512$	$14 \times 14 \times 512$
Conv dw	1	$3 \times 3 \times 512$	$14 \times 14 \times 512$
Conv	1	$1 \times 1 \times 512 \times 512$	$14 \times 14 \times 512$
Conv dw	1	$3 \times 3 \times 512$	$14 \times 14 \times 512$
Conv	1	$1 \times 1 \times 512 \times 512$	$14 \times 14 \times 512$

Conv dw	1	$3 \times 3 \times 512$	$14 \times 14 \times 512$
Conv	1	$1 \times 1 \times 512 \times 512$	$14 \times 14 \times 512$
Conv dw	1	$3 \times 3 \times 512$	$14 \times 14 \times 512$
Conv	1	$1 \times 1 \times 512 \times 512$	$14 \times 14 \times 512$
Conv dw	2	$3 \times 3 \times 512$	$14 \times 14 \times 512$
Conv	1	$1 \times 1 \times 512 \times 1024$	$7 \times 7 \times 512$
Conv dw	2	$3 \times 3 \times 1024$	$7 \times 7 \times 1024$
Conv	1	$1 \times 1 \times 1024 \times 1024$	$7 \times 7 \times 1024$
Pool médio	1	Pool 7×7	$7 \times 7 \times 1024$
Totalmente conectado	1	1024×1000	$1 \times 1 \times 1024$
Softmax	1	Classificador	$1 \times 1 \times 1000$

Fonte: Howard et al. (2017); Keras (2021).

2.12 MobileNetV2

Algumas mudanças significativas foram feitas na arquitetura MobileNetV1 que resultou em um aumento considerável na precisão do modelo. As principais mudanças feitas na arquitetura foram a introdução de blocos residuais invertidos e gargalos lineares e o uso da função de ativação ReLU6 no local de ReLU (HOWARD et al., 2017; KERAS, 2021; MUNDIM FILHO, 2021; TSANG, 2021).

Conforme pode ser observado, as alterações realizadas em relação a MobileNetV1 proporcionaram uma redução no tamanho do modelo, além de um ganho na precisão e uma redução no número de parâmetros, além desses ganhos o número de camadas ocultas permaneceu igual.

Tabela 7 - Principais características dos modelos MobileNet v1 e v2.

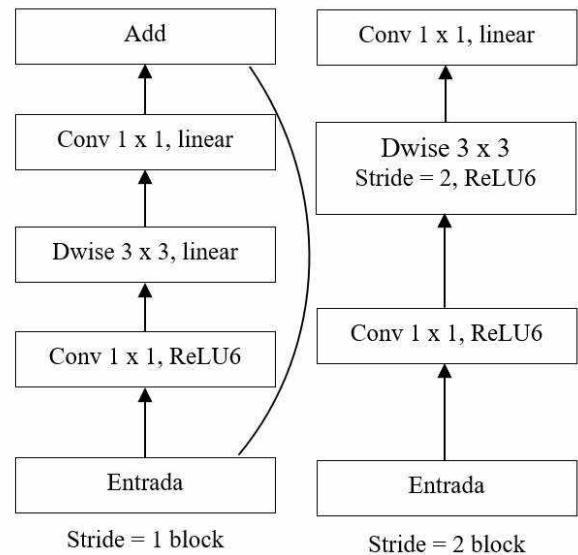
Modelo	Tamanho	Precisão principal	5 principais precisões	Parâmetros	Profundidade
MobileNet	16 MB	0,704	0,895	4.253.864	88
MobileNetV2	14 MB	0,713	0,901	3.538.984	88

Fonte: Howard et al. (2017); Keras (2021).

Na arquitetura do MobileNetV2, 'c' é o número de canais de saída (ou número de filtros), 't' é o fator de expansão, 'n' é o número de vezes que o bloco é repetido e 's' é o passo. As mudanças na arquitetura podem ser observadas na Figura 17.

Figura 17 - Arquitetura do MobileNetV2.

<u>Imput</u>	<u>Operator</u>	<i>t</i>	<i>c</i>	<i>n</i>	<i>s</i>
$224^2 \times 3$	Conv2d	-	32	1	2
$112^2 \times 32$	bottleneck	1	16	1	1
$112^2 \times 16$	Bottleneck	6	24	2	2
$56^2 \times 24$	Bottleneck	6	32	3	2
$28^2 \times 32$	Bottleneck	6	64	4	2
$14^2 \times 64$	Bottleneck	6	96	3	1
$14^2 \times 96$	Bottleneck	6	160	3	2
$7^2 \times 160$	Bottleneck	6	320	1	1
$7^2 \times 320$	Conv2d 1 x 1	-	1280	1	1
$7^2 \times 1280$	Avgpool 7 x 7	-	-	1	-
$1 \times 1 \times 1280$	Conv2d 1 x 1	-	k	-	-



Fonte: Howard et al. (2017); Keras (2021).

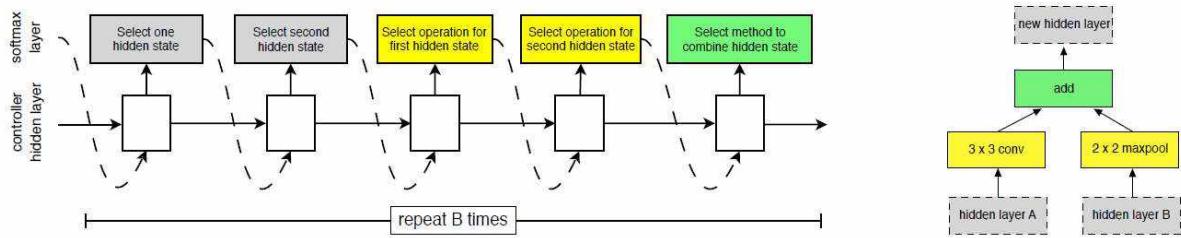
2.13 NasNet Mobile - Neural Architecture Search (NAS)

A NasNet é uma arquitetura de rede neural recorrente com aprendizado por reforço, diferentemente das arquiteturas anteriores no seu desenvolvimento ela utiliza este modelo de aprendizado para fazer uma busca em bases de dados de redes neurais a partir dos parâmetros iniciais para então testar diversas camadas e chegar a um equilíbrio na sua arquitetura (KERAS, 2021; ZOPH et al., 2018).

As células que são adicionadas a arquitetura através da pesquisa são chamadas de célula normal e célula de redução. As células normais são células convolucionais que produzem mapas de recursos da mesma dimensão, as células de redução são células convolucionais que produzem mapas de feições em que a altura e a largura do mapa de feições sofrem uma redução de duas vezes o seu valor.

Apenas os componentes internos das células normais e de redução são pesquisados pelo controlador RNN - Rede Neural Recorrente (Figura 18) (KERAS, 2021; MUNDIM FILHO, 2021; ZOPH et al., 2018).

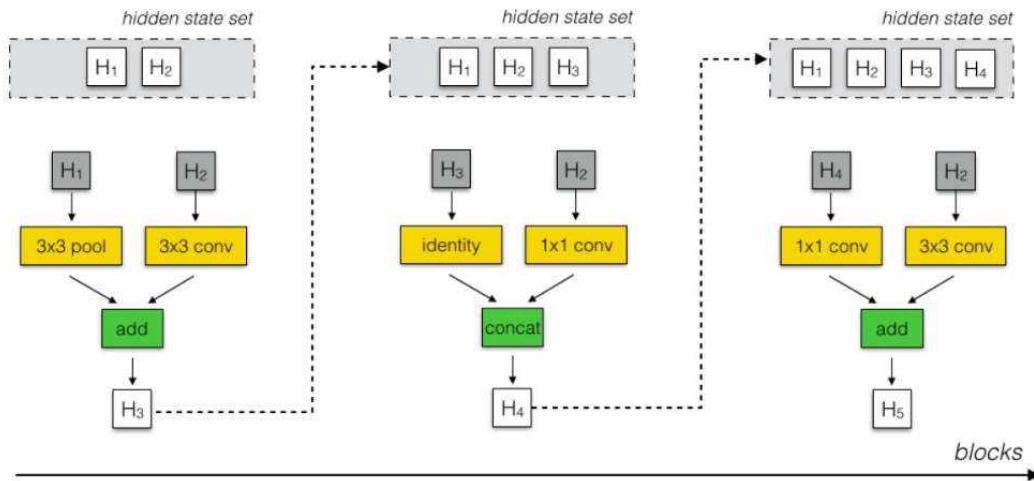
Figura 18 - Arquitetura do modelo de controlador para construir recursivamente um bloco de uma célula convolucional.



Fonte: Zoph (2018).

Na arquitetura NasNet o controlador irá selecionar um par de blocos de estados ocultos, no segundo passo ele irá definir qual a melhor operação deve ser executada nesses blocos e por fim irá definir uma operação que, combinada aos parâmetros definidos antes, resulte em algum benefício ao mapa de saída, esta saída será retida no conjunto de estados ocultos para ser utilizado nos blocos seguintes, conforme Figura 19 (KERAS, 2021; ZOPH et al., 2018).

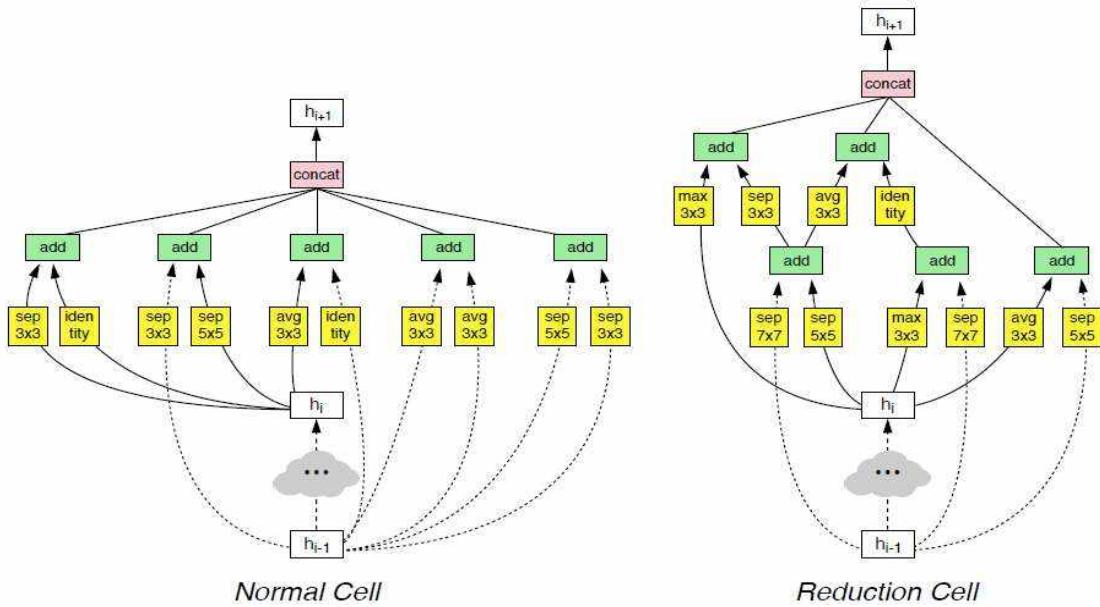
Figura 19 - Esquema sequencial da distribuição do espaço de pesquisa NASNet.



Fonte: Zoph (2018).

Após concluir a busca serão disponibilizadas diversas células convolucionais, estas poderão compor a arquitetura da rede neural utilizando células normais e de redução, com a arquitetura montada realiza-se o treinamento que deve ter um ganho de aprendizado linear, as células adicionadas podem ser descartadas no decorrer do treino seguindo de forma linear os incrementos na taxa de aprendizado (HOWARD et al., 2017; ZOPH et al., 2018).

Figura 20 - Modelo da arquitetura de uma rede neural NasNet completa.



Fonte: Zoph (2018).

Segundo ZOPH et al. (2018), os modelos NASNets possuem grande flexibilidade na construção, alcançaram desempenhos de última geração com menos operações e parâmetros, os bons resultados abrem espaço para estes modelos de arquiteturas que demandam poucos dados para treinamento, o modelo final será menor e a acurácia não apresentou perdas significativas quando comparadas a arquiteturas mais robustas ou com configuração restrita (Figura 21).

Figura 21 - Comparaçao com modelos com configuração computacional restrita.

Modelo	# Parâmetros	Mult-Adds	Top 1 Acc. (%)	Top 5 Acc. (%)
Inception V1 [59]	6.6 M	1,448 M	69.8 †	89.9
MobileNet-334 [24]	4.2 M	569 M	70.6	89.5
ShuffleNet (2x) [70]	~ 5 M	524 M	70.9	89.8
NASNet-A (4@1056)	5.3 M	564 M	74.0	91.6
NASNet-B (4@1536)	5.3 M	488 M	72.8	91.3
NASNet-C (3@960)	4.9 M	558 M	72.5	91.0

Fonte: Zoph (2018).

2.14 Trabalhos Relacionados

A identificação do momento ideal para iniciar a colheita não é tarefa fácil, envolve inúmeras variáveis que devem ser consideradas, porém essa informação obtida de uma forma segura irá fornecer um índice de maturação confiável pelo qual será possível ponderar quando e por qual talhão a colheita deverá ser iniciada.

RODRÍGUEZ et al. (2020) utilizaram um sistema de visão computacional clássica (CV) para identificar frutos de café no estádio cereja, os autores correlacionaram os melhores resultados com características da variedade (Bourbon: 0,594) e menor quantidade de folhas, assim expondo mais os frutos; em suma o uso da CV obteve resultados que auxiliam a tomada de decisão, entretanto, o sistema de visão computacional foi influenciado por fatores externos, principalmente a luminosidade.

Algumas variações em condições como luminosidade, posição e coloração dos frutos podem influenciar na classificação, portanto, definir uma metodologia para captura das imagens é fundamental para desenvolver um modelo de inteligência artificial robusto e capaz de apresentar boa capacidade preditiva (RODRÍGUEZ et al., 2020). Comparando a CV com uma Rede Neural Convolucional (CNN), utilizando o mesmo conjunto de dados da CNN, obteve-se melhores resultados, entretanto, o tempo de treinamento foi maior.

KAZAMA et al. (2020) desenvolveram um trabalho onde utilizaram CNN para classificar os frutos em estádios de maturação. Foram abordados três modelos de captura das imagens e retiradas fotos dos frutos na planta, no ramo destacado e em frutos isolados em lona, os frutos no estádio seco são mais difíceis de serem capturados pois pela cor existe uma baixa reflexão da luz, reduzindo assim o foco, frutos verdes e verde cana foram influenciados pela luz, os frutos no estádio cereja obtiveram as melhores classificações, independente dessas variáveis o modelo proposto para classificação teve boa classificação ($R^2 = 0,92$) fornecendo um bom indicativo do estádio de maturação.

O uso de CNN para reconhecimento de imagens é abordado em diferentes situações (RISDIN; MONDAL; HASSAN, 2020). Eles obtiveram precisão de 99,89% para classificação de quatro tipos de frutas (limão, maçã, uva e lichia) com imagens tiradas por aparelho móvel. Este resultado mostra o potencial das CNN para a aplicação nos diversos setores da agricultura que se baseiam em imagens. Entretanto, o cafeeiro no momento que antecede a colheita tem bastante folha, além da variação na coloração dos frutos também representar um desafio.

Além do reconhecimento de imagens e classificação de frutos outros setores vêm demonstrando o potencial da inteligência artificial. APOLO-APOLO et al. (2020) e MA et al.

(2019) utilizaram um veículo aéreo não tripulado (RPA) para estimar a produção e o tamanho de frutos em pomar de laranja, os resultados de produção obtidos pelo modelo proposto superaram a avaliação dos especialistas, para o tamanho da fruta nem todas puderam ser calculadas, pois algumas tiveram partes encobertas por folhas ou galhos.

SANTOS (2017), utilizando redes neurais convolucionais e máquinas de vetores de suporte para o reconhecimento de marcas de gado por imagens, obteve os seguintes resultados: método bag-of-features, acurácia geral (86,02%) e tempo de processamento do algoritmo de 56,705s; método rede neural convolucional, acurácia geral (93,28%) e tempo de processamento do algoritmo 12,716s; também foram avaliados recall, precisão e coeficiente Kappa, nos quais a rede neural convolucional obteve os melhores resultados.

SLADOJEVIC et al. (2016) desenvolveram um modelo de rede neural convolucional para reconhecimento de doenças de plantas baseadas em imagens de folhas, os resultados alcançados ficaram entre 91% e 98% de precisão, o modelo desenvolvido se mostrou eficiente, sendo capaz de reconhecer 13 doenças de plantas e distinguir entre folhas doentes e sadias.

É inegável a importância do uso da inteligência artificial na agricultura, apesar de ser relativamente nova o seu uso se difundiu rapidamente para diversos setores, principalmente no monitoramento da safra, no solo e na predição de variáveis de interesse agronômico, a projeção é de que até os anos 2030 e 2050 seu entendimento esteja mais difundido e haja uma maior dinâmica dos impactos gerados pelos trabalhos que envolvam IA (PAL et al., 2020).

3 MATERIAIS E MÉTODOS

O trabalho foi desenvolvido através de uma parceria entre o grupo de pesquisa Artificial and Intelligence in Networks (AINET) e o Centro de Excelência em Mecanização Agrícola (CEMA) vinculados respectivamente à Faculdade de Computação e ao Instituto de Ciências Agrárias da Universidade Federal de Uberlândia, campus Monte Carmelo.

O teste do aplicativo foi realizado na Fazenda Canjerana, município de Romaria-MG, também foram utilizadas imagens do banco de imagens que não foram utilizadas no desenvolvimento da rede neural.

3.1 Coleta das imagens para criação do banco de imagens

Foram utilizados diferentes aparelhos móveis para a captura das imagens, simulando a ampla variedade de aparelhos disponíveis, com diferentes especificações técnicas, buscando dar robustez ao banco de imagens, alguns aparelhos possuem resolução do conjunto de câmeras diferentes, variando entre os modelos disponíveis no mercado, com a utilização de vários modelos de aparelhos móveis evita-se que pequenas variações de brilho, contraste, nitidez ou resolução se tornem um impedimento para o funcionamento do modelo.

Figura 22 – Orientação para captura das imagens.



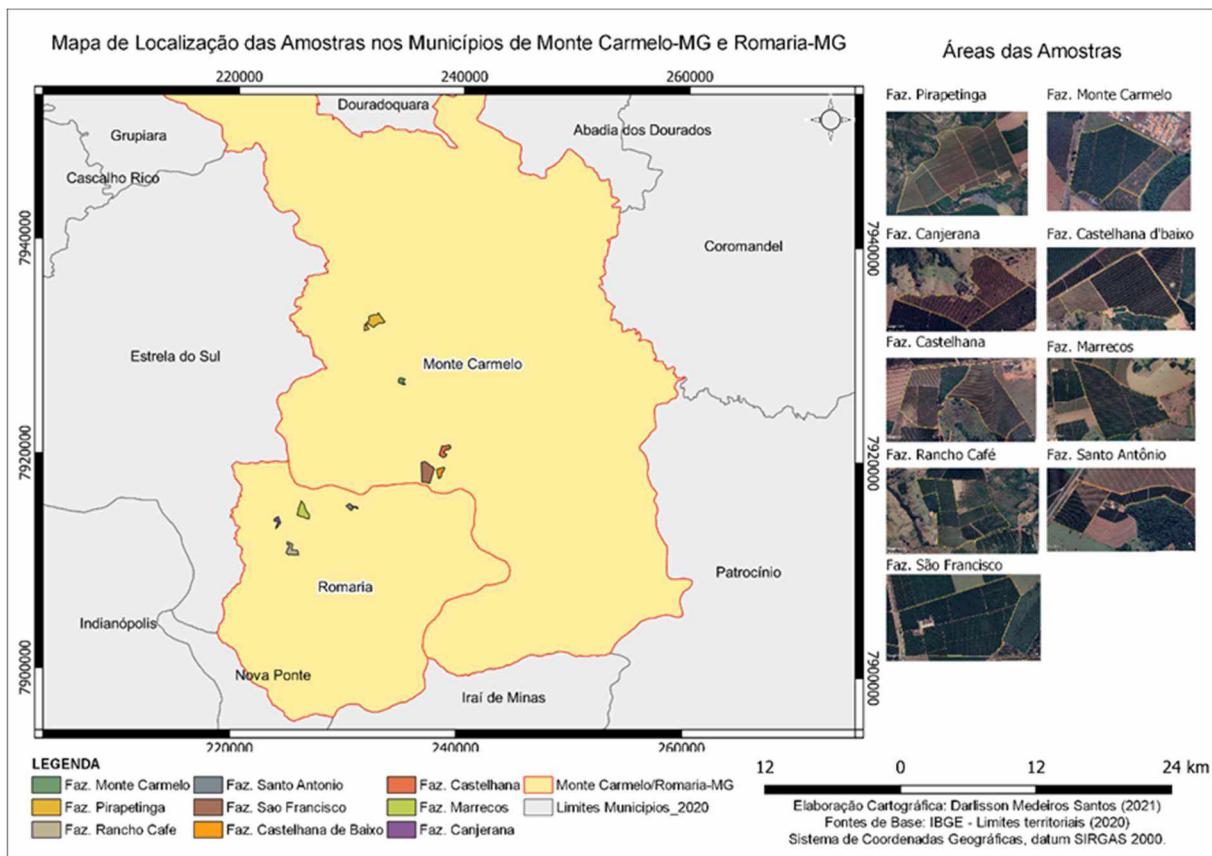
Fonte: O autor.

Para a captura das imagens obteve-se o apoio de colaboradores que foram instruídos de como proceder para a retirada das fotos (Figura 22), inicialmente define a posição do dossel que será capturada (terço superior, médio ou inferior), após o posicionamento abre a copa para expor a maior quantidade de frutos possível, aproxima o aparelho na posição que capture a maior quantidade de frutos (como um parâmetro de posicionamento, deve ser adotado uma distância próxima a 0,8 m em relação a planta de café), finalizando com a captura da figura.

Este processo deve ser realizado o máximo de vezes possível, buscando frutos em todos os estádios de maturação.

Para garantir o maior número de imagens nos cinco estádios de maturação da cultura, em propriedades próximas ao município de Monte Carmelo e Romaria fez-se vistorias semanais, acompanhando a maturação fisiológica dos frutos do cafeeiro até o fim do ciclo (Figura 23).

Figura 23 - Áreas produtoras de café onde foram capturadas as imagens.



Fonte: O autor.

3.2 Rotulagem, classificação e seleção das imagens

Ao final da safra 2020/2021 o banco de dados continha 10.251 imagens. A partir deste, foram separadas aleatoriamente 2.500 fotos, entre as quais estavam representados os cinco estádios de maturação: verde, verde-cana, cereja, passa e seco.

Posteriormente as 2.500 imagens passaram por uma classificação realizada por cinco especialistas, cada um anotou uma classe de maturação pré-definida, dessa classificação obteve-se as classes representativas de cada estádio de maturação (Tabela 8).

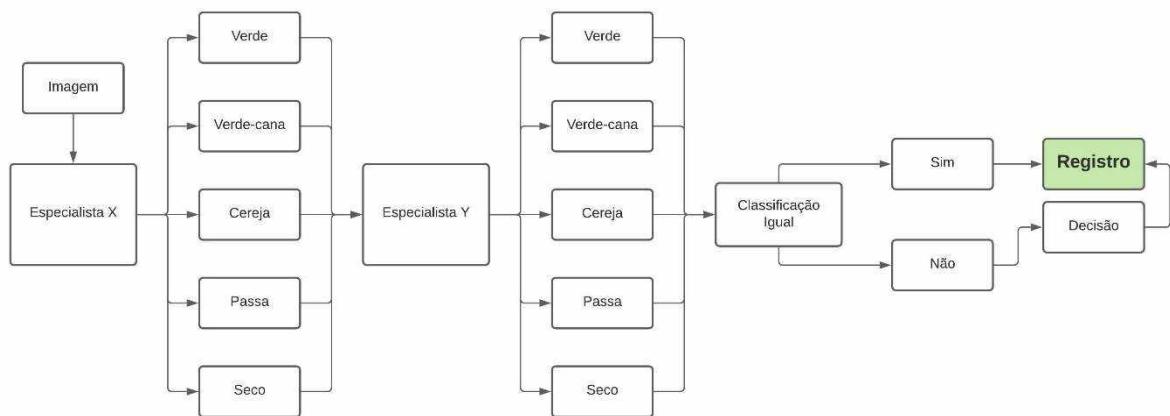
Tabela 8 - Banco de Imagens Representativas Original.

Classes	Imagens (Treino)	Imagens (Teste)	Total (Teste e Treino)
Verde	233	20	253
Verde-Cana	177	20	197
Cereja	137	20	157
Passa	145	20	165
Seco	193	20	213
Total	885	100	985

Fonte: O autor.

Após as imagens serem anotadas foram passadas para outro especialista que procedeu com a validação. Caso a classificação resultante fosse igual, a Figura era registrada; imagens com classificações distintas passaram por uma terceira etapa, analisadas por todos os cinco especialistas, que por critério de maioria atribuíram uma classe para o registro da Figura (Fluxograma 1).

Fluxograma 1 - Etapas para registro das imagens representativas.



Fonte: O autor.

As classes das imagens anotadas na etapa anterior constituíram o banco de imagens representativas, em cultivares pertencentes à espécie *Coffea arábica L.*

3.3 Preparação dos dados para treinamento

O volume de dados para treino pode interferir nos resultados caso o número de dados utilizados no treinamento do modelo seja insuficiente, podendo causar falsos resultados de precisão e de acurácia.

Antes do treinamento foi realizado o aumento dos dados para reduzir o risco do algoritmo se acostumar com os dados pela falta de variáveis nas imagens e aumentar o desempenho do modelo, o número das imagens foi aumentada em três vezes (Figura 24).

Figura 24 - Processamento das imagens para aumentar o volume dos dados de treino do modelo, da esquerda para a direita: Figura original, flip vertical, flip horizontal e flip vertical mais flip horizontal.



Fonte: O autor.

3.4 Seleção do algoritmo da rede neural

Os modelos foram treinados simultaneamente para que pudessem identificar qual se ajustava melhor ao problema, após encontrar o melhor modelo, foi desenvolvido o aplicativo para dispositivos móveis utilizando a ferramenta Android Studio e a biblioteca TensorFlow Lite.

A seleção do modelo de arquitetura para implementar o projeto foi feito buscando atender algumas particularidades, uma delas foi o tamanho, para que pudesse ser embarcada em plataformas de aparelhos mobile, esse primeiro requisito implica diretamente no segundo, o aplicativo não deveria ocupar muito espaço no armazenamento do dispositivo visto que há uma preferência por aplicativos de tamanho menor.

A rede neural também não deveria ser muito robusta, para não demandar maior capacidade computacional e levar mais tempo de processamento para retornar uma classificação.

Outros aspectos também foram observados e tomados como critério de seleção, modelos do estado da arte, que trazem inovação ao modo de como são feitas e construídas as arquiteturas, inovações que permitem o aprimoramento de técnicas e parâmetros dos modelos clássicos.

Após a aplicação destes filtros foram selecionados três modelos, a MobileNet, a MobileNetV2 e a NASNet Mobile, todas arquiteturas voltadas para dispositivos mobile. Para o objetivo proposto utilizou-se a biblioteca Keras.io, que disponibiliza modelos de aprendizado profundo treinados para alguma função (KERAS, 2021).

3.5 Parâmetros de ajuste aplicados para treinamento

Os ajustes dos parâmetros para o treinamento dos modelos são decisões que mudam para cada modelo e conjunto de dados, são feitos de forma empírica, ou seja, treinando e observando os resultados, ajustando os pesos, até chegar no melhor resultado (MUNDIM FILHO, 2021). Os ajustes dos modelos desenvolvidos alcançaram o melhor resultado com os ajustes abaixo:

- a) As imagens de entrada tinham as dimensões de 224x224.
- b) Foi definido 15 épocas de treino, com 55 passos por época e com tamanho do batch de 64.
- c) Foi utilizado o optimizador Adam Learning rate = 0.0001 (este valor também foi definido de forma empírica, isto é, vários valores foram utilizados até que a curva de aprendizado alcançasse o seu máximo valor).
- d) O tamanho do lote de imagens de treinamento foi de 3.540.
- e) Para a classificação binária, foi inserido o comando de quais classes/imagens representavam a resposta colher. Resposta de saída: Colher = Cafés nos estádios cereja, passa e seco, onde deve haver menos de 20% de cafés verdes, segundo a metodologia para definição do índice de maturação (Mesquita et al., 2016), para esta classe foram fornecidos um total de 1.540 imagens como exemplos.
- f) Para a resposta não colher (Resposta de saída: Não colher (Cafés nos estádios verde e verde-cana)) foram utilizadas 1.900 imagens de exemplos.

Estes são ajustes técnicos que dependem principalmente da experiência do cientista de dados, podendo influenciar diretamente o resultado da classificação alcançada pelo modelo desenvolvido.

4 RESULTADOS E DISCUSSÃO

4.1 Banco de imagens

O banco de imagens geral conta atualmente com 11.538 imagens de frutos de café de coloração vermelha, a obtenção de novas imagens deve ser feita anualmente para manter o banco de imagens atualizado com as novas variedades de café e suas diversas tonalidades de coloração.

Já o banco de imagens representativas, ou seja, aquele que foi classificado e rotulado pelos especialistas, conta com 985 imagens (Tabela 9), este é um número consideravelmente pequeno quando se leva em consideração os estádios de maturação dos frutos e suas tonalidades, para isso utilizou-se da técnica de aumento de dados por processamento das 985 imagens.

Tabela 9 - Banco de dados de treino após o aumento de dados.

Classes	Imagens (Treino)	Imagens (Teste)	Total (Teste e Treino)
Verde	233	20	253
Verde-Cana	177	20	197
Cereja	137	20	157
Passa	145	20	165
Seco	193	20	213
Total	885	100	985

Fonte: O autor.

Após o aumento dos dados alcançou-se uma quantidade de imagens que poderá fornecer um número de amostras suficientes para treinamento, com a aplicação da técnica de aumento

de dados o banco de imagens de treino e teste dos modelos aumentou para 3.540 imagens no total (Tabela 10).

O volume de imagens alcançado é superior a alguns trabalhos relacionados. APOLO-APOLO et al. (2020) e KAZAMA et al. (2020) utilizaram um conjunto de imagens para treinamento de 720 e 900 imagens respectivamente, com isso reduz o risco de o modelo se acostumar rapidamente com o conjunto de imagens, processo denominado overfitting, isso faz com que o aprendizado seja mais eficiente com capacidade de generalizar melhor as classificações.

Tabela 10 - Banco de dados de treino após o aumento de dados.

Classes	Imagens (Treino)	Imagens (Teste)	Total (Teste e Treino)
Verde	912	20	932
Verde-Cana	688	20	708
Cereja	528	20	548
Passa	560	20	580
Seco	752	20	772
Total	3.440	100	3.540

Fonte: O autor.

4.2 Resultado após treinamento das modelos (MobileNet, MobileNet V2 e NASNets)

As arquiteturas MobileNet e MobileNetV2 obtiveram melhores valores de classificação em comparação a NASNet Mobile, o aumento do número de amostras se mostrou vantajoso para os três modelos, propiciando um ganho nos valores de acurácia e F1 Score.

A acurácia diz respeito a capacidade de acerto geral de classificação de uma determinada classe, ou seja, a capacidade de distinguir entre um valor verdadeiro e um valor falso, separando indivíduos que possuem classificação distinta. O F1 score é uma métrica que traz os valores de precisão e recall em um único valor, essa métrica indica a qualidade geral do modelo, valores mais altos representam um resultado mais preciso e confiável.

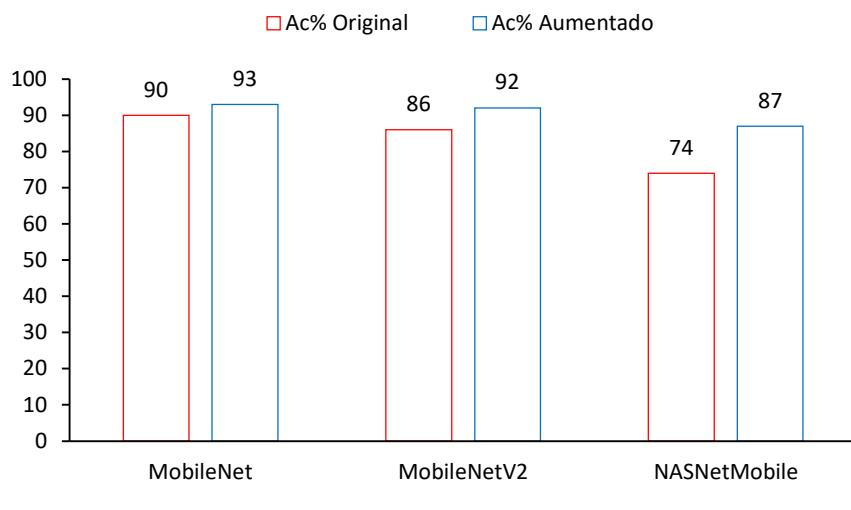
Os modelos desenvolvidos obtiveram resultados de acurácia de 0.99%, com média de 0.00032% de perda, esses valores demonstram uma boa média de classificação e de desempenho. O modelo NASNet Mobile foi o que teve a performance mais baixa. ZOPH et al. (2018)

encontraram melhores resultados comparando este com outras arquiteturas de relevância no ImageNet, apesar de os valores de acurácia terem sido satisfatórios para um primeiro momento.

O NASNet Mobile possui uma arquitetura diferente dos outros dois modelos testados. ZOPH et al. (2018) compararam o volume de dados utilizado, essa arquitetura se saiu bem e sua demanda foi a menor entre os modelos testados, entretanto, em seu trabalho o banco de dados continha milhões de imagens (ImageNet), assim poderia ser possível melhorar os resultados para esse modelo aumentando a quantidade de amostras para treino.

Para os valores de acurácia com os dados originais e com o aumento de dados os modelos MobileNet (0,93%) e MobileNet V2 (0,92%) tiveram os maiores valores de acurácia, seguidos pela arquitetura NASNet Mobile com 0,87% de acurácia. Apesar de este último apresentar menores valores de acerto, foi o que mais se beneficiou com o aumento dos dados, com um ganho de 0,13% nos valores de acurácia, seguido por MobileNetV2 com um ganho de 0,06% e MobileNet com ganho de 0,03% (Figura 25).

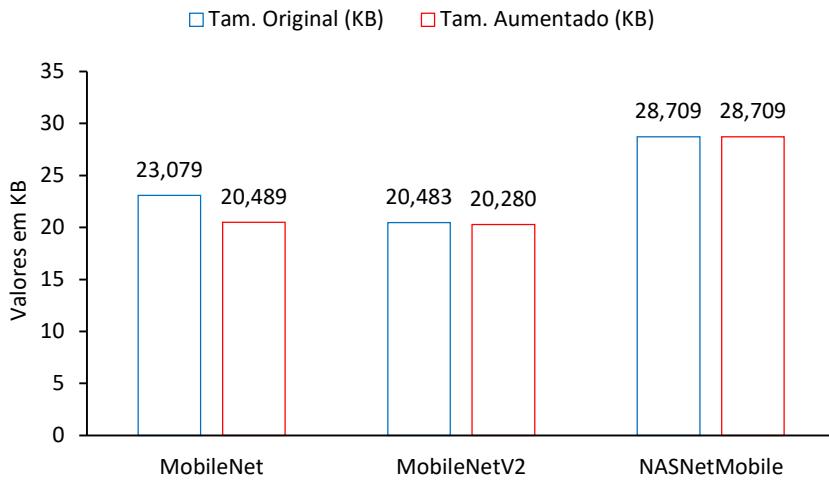
Figura 25 - Acurácia obtida pelos modelos após treinamento.



Fonte: O autor.

Quanto ao tamanho dos modelos, podemos observar que as arquiteturas MobileNet e MobileNetV2 tiveram decréscimo de tamanho após o aumento dos dados de treino, o NASNet Mobile se manteve estável. Estes resultados não eram esperados uma vez que com o aumento dos dados de treino a tendência é ter um ganho de tamanho. O tamanho dos modelos é compatível com a maioria dos aplicativos voltados para smartphones, como o espaço de armazenamento é um fator decisivo na hora de instalar aplicativos o tamanho dos modelos se faz satisfatório (Figura 26).

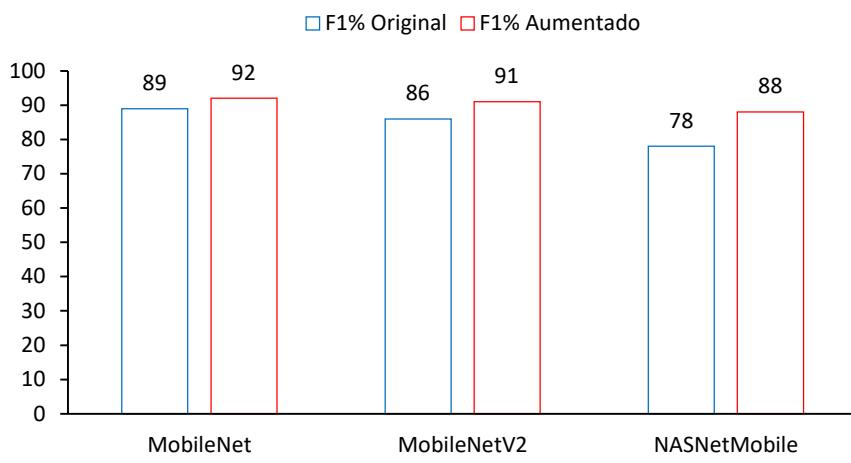
Figura 26 - Tamanho dos Modelos antes e após aumento dos dados de treino.



Fonte: O autor.

Os três modelos obtiveram aumento nos valores de F1 score após o aumento dos dados de treino, novamente o NASNet Mobile foi o modelo que obteve melhor resposta, com um acréscimo de 0,1% após os dados serem aumentados, seguido por MobileNetV2 com ganho de 0,05% e MobileNet com ganho de 0,03% (Figura 27).

Figura 27 - Valores de F1 Score dos treinos para os modelos escolhidos.



Fonte: O autor.

O modelo MobileNet foi o que melhor se ajustou ao problema, apresentando resultados superiores mesmo com os dados originais. Após os dados serem aumentados o modelo que teve maior ganho de desempenho foi o NASNet Mobile, apesar de ser o que teve menores valores

de acurácia e F1 score, com um aumento maior dos dados de treino este modelo poderia apresentar melhor valor de F1 score e acurácia, se mostrando promissor para novos trabalhos.

Diante dos resultados, o modelo selecionado para a etapa seguinte foi o MobileNet, sendo o que melhor se ajustou ao problema com os dados de treino apresentados.

4.3 Teste do protótipo em campo

4.3.1 Protótipo 1 – Resposta de saída com valores binários

Foram desenvolvidos dois protótipos utilizando as ferramentas Android Studio e a biblioteca TensorFlow Lite, essa é uma plataforma voltada para a aplicação de inteligência artificial em dispositivos Mobile, o que torna o processo de uso mais fluido e leve, pois, reduz a necessidade de máquinas potentes para o uso das arquiteturas.

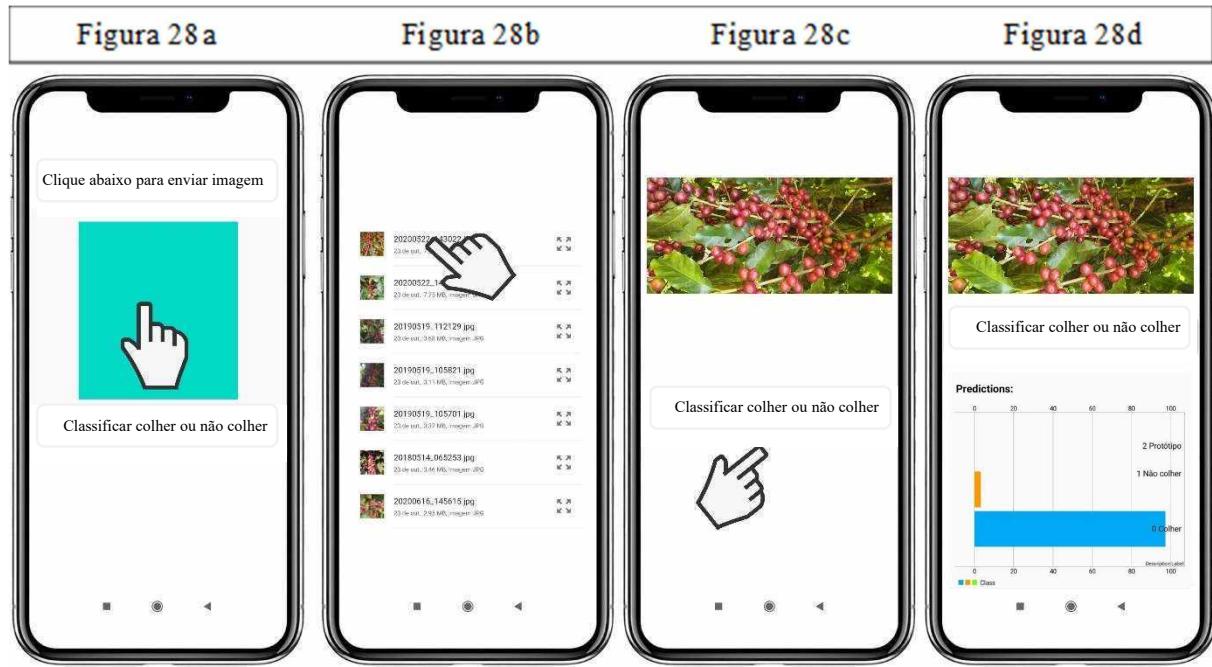
O desenvolvimento desse modelo pode contribuir grandemente na gestão da lavoura, os resultados de classificação alcançados dão segurança ao produtor, o tempo gasto para definir momento de iniciar a colheita reduz grandemente com a utilização do aplicativo.

Tecnologias mobile possuem grande adaptabilidade de acordo com a necessidade do usuário, a forma como cada indivíduo irá empregar a ferramenta pode gerar novas aplicações para os modelos desenvolvidos.

A utilização das imagens capturadas na câmera do dispositivo mobile e o posterior carregamento no aplicativo pode gerar resistência aos usuários, dessa forma, desenvolver um modelo que interaja com outros softwares nativos dos dispositivos poderá gerar mais aceitabilidade.

A integração com outras funcionalidades, como por exemplo o uso do GPS do aparelho, ou a inserção de novas funcionalidades como a geração de mapas de maturação e poder exportar os resultados de forma fácil, são outros recursos que enriquecem a usabilidade do aplicativo, tornando-o mais atrativo para produtores e consultores técnicos.

A Figura 28 apresenta a interface do aplicativo e as etapas para classificação e seu funcionamento. Ao abrir o aplicativo será visualizado a tela inicial (Figura 28a), ao clicar no quadro azul o usuário irá acessar a galeria de imagens do dispositivo móvel (Figura 28b), escolhe uma Figura clicando sobre ela, após isso irá abrir a tela de classificação (Figura 28c), nessa janela ao clicar no botão classificar colher ou não colher poderá ser visto no gráfico a avaliação da Figura (Figura 28d).



Fonte: O autor.

Este modelo alcançou resultados de campo superiores aos resultados do treinamento (92%). As classificações foram levemente influenciadas pela luminosidade, este é um problema comum em arquiteturas de classificação de imagens, pois a luz pode interferir na cor dos frutos, é recomendado que a captura das imagens, preferencialmente, seja realizada nos horários de menor incidência solar.

4.3.2 Protótipo 2 - Classificação multiclasse

Após a conclusão do primeiro teste, foi realizado o teste do protótipo de classificação das cinco classes de maturação, neste modelo a precisão média foi de 63%, se manteve com uma boa performance na classificação do cafeeiro verde e cereja, já em relação aos frutos secos os resultados tiveram menor acerto.

Os valores mais baixos (< 60% de F1) para as classes verde-cana e passa também se mantiveram, em alguns casos classificando errado o estádio de maturação. Estes estádios possuem grau de classificação complicado devido serem estádios transitivos, ou seja, frutos em mais de dois estádios na mesma Figura, já os testes de classificação do estádio seco possuem variação de cor e brilho mais acentuado que outros estádios, dependendo da hora do dia e da

incidência de radiação solar. Os valores de entrada e as configurações do modelo seguiram os mesmos utilizados no primeiro teste.

Figura 29 - Resultados treinamento modelo multiclasse.

Classe	Precisão	Recall	F1-Score
Verde	0.79	0.95	0.86
Verde-cana	0.67	0.50	0.57
Cereja	0.56	0.70	0.62
Passa	0.45	0.45	0.45
Seco	0.69	0.55	0.61

Fonte: Mundim Filho (2021).

De modo geral o modelo teve um desempenho mediano, mantendo-se próximos aos resultados durante o treinamento e teste dos modelos, as classes com mais dificuldades são a verde-cana e a passa, acredita-se que esses valores se devem pelo fato de os frutos apresentarem estádios de maturação transitivos (Figura 30).

Figura 30 - Interface do aplicativo no modelo de classificação por estádio de maturação.



Fonte: O autor.

Algumas classificações erradas podem ter sido por conta da iluminação, é possível observar que as imagens classificadas erradas são do estádio anterior ou posterior a classe correta, como no caso da cereja que classificou uma Figura como verde-cana e uma como passa,

as imagens classificadas erradas também possuem mais frutos e diferentes estádios, o que também pode ter contribuído para o erro.

Fotos menos ou mais iluminadas também apresentaram alguma diferença na classificação, imagens mais escuras em alguns pontos pode ter favorecido a classificação de frutos no estádio passa como frutos no estádio secos.

O uso desse modelo para classificação de estádios de maturação isolados pode ser uma saída, criando máscaras de seleção de frutos, reduzindo a área analisada e não analisando a Figura como um todo. A redução das variáveis analisadas pode reduzir a propagação do erro, aumentando a acurácia.

5 CONSIDERAÇÕES FINAIS

As redes neurais convolucionais são uma boa alternativa para a classificação dos estádios de maturação de frutos de café.

O uso de dispositivos móveis torna simples o processo de obtenção das imagens durante a maturação dos frutos em diferentes áreas da propriedade.

O protótipo 1 (resposta binária) obteve resultado de classificação condizentes com os modelos atuais, alcançando 92% de acurácia.

O modelo de classificação em classes de maturação teve resultados inferiores, classificação média de 60%.

O modelo de classificação em classes de maturação possui grande potencial de aplicação, mas trabalhos devem ser realizados para que os resultados de classificação possam ser melhorados.

O banco de dados possui um volume de imagens suficientes para apoiar trabalhos futuros, desde que o número de imagens rotuladas seja aumentado.

REFERÊNCIAS

ABD EL-GHANY, N. M.; ABD EL-AZIZ, S. E.; MAREI, S. S. A review: application of remote sensing as a promising strategy for insect pests and diseases management. **Environmental Science and Pollution Research**, v. 27, n. 27, p. 33503–33515, 2020. DOI: 10.1007/s11356-020-09517-2

ABIC. Origem do Café - Associação Brasileira da Indústria de Café - ABIC. Disponível em: <<https://www.abic.com.br/tudo-de-cafe/origem-do-cafe/>>. Acesso em: 17 jan. 2022.

ALVES, E. A., DE SOUZA, C. A., ROCHA, R. B., PEREIRA, L. L., DE LIMA, P. P., & LOURENÇO, J. L. R. Efeito da fermentação sobre qualidade da bebida do café robusta (*Coffea canephora*) cultivado na amazônia ocidental. **Revista Ifes Ciência**, v. 6, n. 3, p. 159–170, 23 dez. 2020. Disponível em: <<https://ojs.ifes.edu.br/index.php/ric/article/view/875>>

APOLO-APOLO, O. E., PÉREZ-RUIZ, M., MARTÍNEZ-GUANTER, J., & VALENTE, J. A Cloud-Based Environment for Generating Yield Estimation Maps From Apple Orchards Using UAV Imagery and a Deep Learning Technique. **Frontiers in Plant Science**, v. 11, n. July, p. 1–15, 2020. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fpls.2020.01086/full>>

ARAÚJO, F. H., CARNEIRO, A. C., SILVA, R. R., MEDEIROS, F. N., & USHIZIMA, D. M. Redes Neurais Convolucionais com Tensorflow. Teoria e prática. **SOCIEDADE BRASILEIRA DE COMPUTAÇÃO. III Escola Regional de Informática do Piauí. Livro Anais-Artigos e Minicursos**, v. 1, n. 1, p. 382-406, jun, 2017.
www.eripi.com.br/2017 - ISBN: 978-85-7669-395-6. Disponível em: <<https://docplayer.com.br/57119969-Redes-neurais-convolucionais-com-tensorflow-teoria-e-pratica.html>>

BATISTA, L. A. **Características Morfofisiológicas de Cafeeiros Coffea arabica L.** 2010. Tese (doutorado) – Universidade Federal de Lavras, 2010.
 Orientador: Rubens José Guimarães. Programa de Pós-

Graduação em Agronomia/Fitotecnia, Universidade Federal de Lavras, Lavras, 2010. Disponível em: <<http://www.sbicafe.ufv.br/handle/123456789/6656>>

CAMARGO, Ângelo Paes de; CAMARGO, Marcelo Bento Paes de. Definição e esquematização das fases fenológicas do cafeiro arábica nas condições tropicais do Brasil. **Bragantia**, v. 60, p. 65-68, 2001. Disponível em: <<https://www.scielo.br/j/brag/a/DHJFXMkTxK5wJX5q74xhw3p/abstract/?lang=pt>>

CONAB. Acompanhamento da Safra Brasileira-jan 2021. **Companhia Nacional de Abastecimento - CONAB**, v. 8, n. 1, 2021. Disponível em: <<https://www.conab.gov.br/info-agro/safras/cafe>>

CONSORCIO PESQUISA CAFÉ.Cultivares de Café. Disponível em: <<http://www.consortiopesquisacafe.com.br/index.php/tecnologias/cultivares>>. Acesso em: 14 jan. 2022.

CONSÓRCIO PESQUISA CAFÉ. **Produtividade média dos Cafés do Brasil equivale a 25 sacas por hectare em 2021.** Disponível em: <<http://www.consortiopesquisacafe.com.br/index.php/imprensa/noticias/1064-2021-06-23-18-08-01>>.

SILVA, FLÁVIO CASTRO DA ; SILVA, FÁBIO MOREIRA DA ; SILVA, ANTÔNIO CARLOS DA ; BARROS, MURILO MACHADO DE ; PALMA, MARCOS ANTÔNIO ZAMBILLO. Desempenho operacional da colheita mecanizada e seletiva do café em função da força de desprendimento dos frutos. **Coffee Science**, Lavras, v. 8, n. 1, p. 53-60, jan./mar. 2013. Disponível em: <<http://www.sbicafe.ufv.br:80/handle/123456789/7947>>

SILVA, F. C. D., SILVA, F. M. D., SALES, R. S., FERRAZ, G. A., & BARROS, M. M. D. Variáveis meteorológicas e da umidade do solo na força de desprendimento dos frutos do café. **Coffee Science**, Lavras, v. 12, n. 4, p. 480 - 485, out./dez. 2017. Disponível em: <<http://hdl.handle.net/123456789/9242>>

DATA SCIENCE ACADEMY. Início - Deep Learning Book. Disponível em: <<https://www.deeplearningbook.com.br/>>. Acesso em: 21 jul. 2021.

BARROS, M. M. D., SILVA, F. M. D., COSTA, A. G., FERRAZ, G. A., & SILVA, F. C. D. Use of classifier to determine coffee harvest time by detachment force. **Revista Brasileira de Engenharia Agricola e Ambiental**, v. 22, p. 366-370, 2018. Disponível em: <<https://doi.org/10.1590/1807-1929/agriambi.v22n5p366-370>>

EMBRAPA CAFÉ. **Neurociência investiga percepção multissensorial do sabor café - Portal Embrapa.** Disponível em: <<https://www.embrapa.br/busca-de-noticias/noticia/39049558/neurociencia-investiga-percepcao-multissensorial-do-sabor-cafe>>. Acesso em: 20 jul. 2021.

MOREIRA DA SILVA, F., SILVA DE OLIVEIRA, M., PAIVA CUSTÓDIO, A. A., & FERREIRA PONCIANO FERRAZ, P. Variabilidade espacial dos atributos da planta de uma lavoura cafeeira. **Revista Ciencia Agronomica**, v. 48, n. 1, p. 81–91, 2017. Disponível em: <<http://ccarevista.ufc.br/seer/index.php/ccarevista/article/view/3303>>

SOARES FILHO, MAURÍCIO MARQUES. **Redes neurais artificiais: do neurônio artificial à convolução.** 2018. Trabalho de Conclusão de Curso – (TCC). (Graduação em Tecnologia de Sistemas de Computação)-Universidade Federal Fluminense, Escola de Engenharia, Niterói, 2018. Disponível em: <<https://app.uff.br/riuff/handle/1/8926>>

GONZALES, R. C.; WOODS, R. E. **Processamento Digital De Imagens.** 3^a edição ed. São Paulo: Editora Pearson Pretence Hall, 2010.

GRACIANO, P. D., SIQUIEROLI, A. C. S., ASSIS, G. A., JUNIOR, L. D. F., FERNANDES, M. I. S., & PAIVA, C. R. Estádios de maturação de cultivares de *Coffea arabica L.* em Monte Carmelo-MG e suas características sensoriais. **Revista Ciência Agrícola**, v. 17, n. 1, p. 7, 25 jul. 2019. DOI:10.28998/rca.v17i1.5608. Disponível em: <<https://www.researchgate.net/publication/334860571>>

HAMUDA, Esmael; GLAVIN, Martin; JONES, Edward. A survey of image processing techniques for plant extraction and segmentation in the field. **Computers and Electronics in Agriculture**, v. 125, p. 184-199, 2016. <https://doi.org/10.1016/j.compag.2016.04.024>.

Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0168169916301557?via%3Dihub>>

HAYKIN, Simon. **Redes neurais: princípios e prática.** Bookman Editora, 2007. Disponível em: <<https://docero.com.br/doc/es0e11>>

MACHADO, A. H. R., PUIA, J. D., MENEZES, K. C., & MACHADO, W. A Cultura do Café (Coffeaarabica) em Sistema Agroflorestal. **Brazilian Journal of Animal and Environmental Research Braz. J. Anim. Environ. Res.**, v. 3, n. 3, p. 1357–1369, 7 ago. 2020. DOI: <https://doi.org/10.34188/bjaerv3n3-053>. Disponível em: <<https://www.brazilianjournals.com/index.php/BJAER/article/view/14443>>

HOWARD, A. G., ZHU, M., CHEN, B., KALENICHENKO, D., WANG, W., WEYAND, T., ... & ADAM, H. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. **arXiv preprint arXiv:1704.04861.** 2017. Disponível em: <<https://arxiv.org/abs/1704.04861>>

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep learning.** MIT press, 2016. Disponível em: <http://www.deeplearningbook.org/front_matter.pdf>.

ISPA. International Society of Precision Agriculture. Disponível em: <<https://www.ispag.org/>>. Acesso em: 16 jan. 2022.

JACINTHO, J. L., FERRAZ, G. A., SILVA, F. M. D., & SANTOS, S. A. Management zones in coffee cultivation. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 21, n. 2, p. 94–99, fev. 2017. <https://doi.org/10.1590/1807-1929/agriambi.v21n2p94-99>. Disponível em: <<https://www.scielo.br/j/rbeaa/a/dS6tB9GMGsdDmzSS6V35yYd/abstract/?lang=en&format=html>>

JI, R.; QI, L. Crop-row detection algorithm based on Random Hough Transformation. **Mathematical and Computer Modelling**, v. 54, n. 3–4, p. 1016–1020, 2011. <https://doi.org/10.1016/j.mcm.2010.11.030>. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0895717710005212>>

CORREA, J. M., VIEIRA, G. H. S., BAITELLE, D. C., LOSS, J. B., MONACO, P. A. V. L., HADDADE, I. R., ... & MADALON, F. Z. Controlled water stress in uniformity of maturity and productivity of conilon coffee. **African Journal of Agricultural Research**, v. 12, n. 3, p. 192–199, 2017. <https://doi.org/10.5897/AJAR2016.11995>. Disponível em: <<https://academicjournals.org/journal/AJAR/article-abstract/4DC29D962475>>

KAZAMA, E. H., DA SILVA, R. P., DE OLIVEIRA TAVARES, T., CORREA, L. N., DE LIMA ESTEVAM, F. N., DE ARAÚJO NICOLAU, F. E., & JÚNIOR, W. M. Methodology for selective coffee harvesting in management zones of yield and maturation. **Precision Agriculture**, n. 0123456789, 2020. <https://doi.org/10.1007/s11119-020-09751-1>. Disponível em: <<https://link.springer.com/article/10.1007/s11119-020-09751-1>>

KERAS. Keras Applications. **Keras Applications**, p. 1–3, 2021. Disponível em: <<https://keras.io/api/applications/>>

KHAN, J. Y. et al. A benchmark study of machine learning models for online fake news detection. **Machine Learning with Applications**, v. 4, n. March, p. 100032, 2021. DOI: 10.1016/j.mlwa.2021.100032. Disponível em: <<https://arxiv.org/abs/1905.04749>>

LI, J. et al. Deep reinforcement learning for dialogue generation. **EMNLP 2016 - Conference on Empirical Methods in Natural Language Processing, Proceedings**, n. 4, p. 1192–1202, 2016. Disponível em: <<https://arxiv.org/abs/1606.01541>>

LUDERMIR, Teresa Bernarda. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. **Estudos Avançados**, v. 35, p. 85-94, 2021. <https://doi.org/10.1590/s0103-4014.2021.35101.007>. Disponível em: <<https://www.scielo.br/j/ea/a/wXBdv8yHBV9xHz8qG5RCgZd/?lang=pt&format=html>>

MA, J., LI, Y., CHEN, Y., DU, K., ZHENG, F., ZHANG, L., & SUN, Z. Estimating above ground biomass of winter wheat at early growth stages using digital images and deep convolutional neural network. **European Journal of Agronomy**, v. 103, n. June 2018, p. 117–129, fev. 2019. <https://doi.org/10.1016/j.eja.2018.12.004>. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S1161030118301977>>

MACHADO, A. H. R., PUIA, J. D., MENEZES, K. C., & MACHADO, W. A Cultura do Café (Coffeaarabica) em Sistema Agroflorestal. **Brazilian Journal of Animal and Environmental Research**, v. 3, n. 3, p. 1357–1369, 2020. DOI: <https://doi.org/10.34188/bjaerv3n3-053>. Disponível em: <<https://www.brazilianjournals.com/index.php/BJAER/article/view/14443>>

DE OLIVEIRA PELUZIO, T. M., PELUZIO, J. B. E., FERRARI, J. L., STURIÃO, A. P., & DA COSTA JAEGGI, M. E. P. Uso da geotecnologia para o mapeamento da cafeicultura no Caparaó Capixaba. **Revista Ifes Ciência**, v. 6, n. 4, p. 92-104, 2020. DOI: <https://doi.org/10.36524/ric.v6i4.733>. Disponível em: <<https://ojs.ifes.edu.br/index.php/ric/article/view/733>>

MAPA. **Registro Nacional de Cultivares - RNC — Português (Brasil)**. Disponível em: <<https://www.gov.br/agricultura/pt-br/guia-de-servicos/registro-nacional-de-cultivares-rnc>>. Acesso em: 20 jul. 2021.

MARUJO, R. de F. B.; MOREIRA, M. A.; VOLPATO, M. M. L.; ALVES, H. M. R. Coffee crop detection by automatic classification using spectral and textural attributes and illumination factor. **Coffee Science - ISSN 1984-3909**, [S. l.], v. 12, n. 2, p. 164–175, 2017. Disponível em: <http://www.coffeescience.ufla.br/index.php/Coffeescience/article/view/1176>. Acesso em: 18 jan. 2022.

MEDEIROS, R. DE V. V.; RODRIGUES, P. M. A. A ECONOMIA CAFEEIRA NO BRASIL E A IMPORTÂNCIA DAS INOVAÇÕES PARA ESSA CADEIA. **A Economia em Revista - AERE**, v. 25, n. 1, p. 1-12, 5 out. 2017. DOI:<https://doi.org/10.4025/aere.v25i1.35511>. Disponível em: <<https://periodicos.uem.br/ojs/index.php/EconRev/article/view/59013>>

MEIRELES, E. J. L., CAMARGO, M. B. P. D., PEZZOPANE, J. R. M., THOMAZIELLO, R. A., FAHL, J. I., BARDIN, L., ... & FERREIRA, R. A. Fenologia do Cafeiro: Condições Agrometeorológicas e Balanço Hídrico do Ano Agrícola 2004–2005. **Embrapa-Documents**. ISSN 1678-1694. Brasilia-DF: 2009. Disponível em: <<http://www.sbicafe.ufv.br:80/handle/123456789/3381>>.

MESAS-CARRASCOSA, F. J., DE CASTRO, A. I., TORRES-SÁNCHEZ, J., TRIVIÑO-TARRADAS, P., JIMÉNEZ-BRENES, F. M., GARCÍA-FERRER, A., & LÓPEZ-GRANADOS, F. Classification of 3D point clouds using color vegetation indices for precision viticulture and digitizing applications. **Remote Sensing**, v. 12, n. 2, p. 317, 2020. <https://doi.org/10.3390/rs12020317>. Disponível em: <<https://www.mdpi.com/620404>>

MESQUITA, C. M. D., REZENDE, J. E., CARVALHO, J. S., FABRI JÚNIOR, M. A., MORAES, N. C., DIAS, P. T., ... & ARAÚJO, W. G. MESQUITA, Carlos Magno de et al. Manual do café: manejo de cafezais em produção. **Belo Horizonte: EMATER-MG**, 2016a.

MESQUITA, C. D., REZENDE, J. E., CARVALHO, J. S., FABRI JÚNIOR, M. A., MORAES, N. C., DIAS, P. T., ... & ARAÚJO, W. G. Manual do café: colheita e preparo (*Coffea arabica* L.). **Belo Horizonte: EMATER-MG**, p. 1-56, 2016.

MEYERS, J. M., DOKOOZLIAN, N., RYAN, C., BONI, C., & VANDEN HEUVEL, J. E. A new, satellite NDVI-based sampling protocol for grape maturation monitoring. **Remote Sensing**, v. 12, n. 7, p. 1159, 2020. <https://doi.org/10.3390/rs12071159>

PAL, SOURAV & MISHRA, AADYA & SINGH, GURMAIL & SINGH, PRABHAT. PAL, Sourav et al. A Comprehensive Study of Remote Sensing Applications in Agriculture. **International Journal of Advance Science and Technology**, Vol. 29, No. 10S, (2020), pp.4781-4790. Disponível em: <https://www.researchgate.net/publication/342153825_A_Comprehensive_Study_of_Remote_Sensing_Applications_in_Agriculture>

MUNDIM FILHO, A. C. Redes neurais convolucionais para classificação e avaliação da maturação de frutos de café. **Repositório Universidade Federal de Uberlândia**, 18 jun. 2021. Trabalho de Conclusão de Curso – (TCC). (Graduação em Sistemas de Informação)-Universidade Federal de Uberlândia – UFU), Monte Carmelo - MG, 2021. Disponível em: <<https://repositorio.ufu.br/handle/123456789/32319>>

OLIVEIRA, A. J., DA SILVA, G. F., DA SILVA, G. R., DOS SANTOS, A. A. C., CALDEIRA, D. S. A., VILARINHO, M. K. C., ... & DE OLIVEIRA, T. C. Potencialidades Da Utilização De Drones Na Agricultura De Precisão / Drones Potentiality Use in Precision

Agriculture. **Brazilian Journal of Development**, v. 6, n. 9, p. 64140–64149, 2020. DOI: <https://doi.org/10.34117/bjdv6n9-010>. Disponível em: <<https://www.brazilianjournals.com/index.php/BRJD/article/view/15976>>

PAYNE, A. B., WALSH, K. B., SUBEDI, P. P., & JARVIS, D. Estimation of mango crop yield using image analysis - Segmentation method. **Computers and Electronics in Agriculture**, v. 91, p. 57–64, 2013. DOI: <https://doi.org/10.1016/j.compag.2012.11.009>. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0168169912002669>>

PEREIRA, D. R., ADAMS, M. S., COSTA, R. M. D. S., BONO, J. A. M., PEDRINHO, D. R., RODRIGUES, E. C., ... & FERREIRA, A. D. Comparação entre métodos não destrutivos de estimativa da área foliar em café arábica. **Brazilian Journal of Animal and Environmental Research**, v. 3, n. 4, p. 2819–2828, 2020. Disponível em: <<http://www.sbicafe.ufv.br/handle/123456789/12537>>

PONGNUMKUL, Suporn; CHAOVALIT, Pimwadee; SURASVADI, Navaporn. Applications of smartphone-based sensors in agriculture: a systematic review of research. **Journal of Sensors**, v. 2015, 2015. DOI: <https://doi.org/10.1155/2015/195308>. Disponível em: <<https://www.hindawi.com/journals/js/2015/195308/>>

POURDARBANI, R., SABZI, S., KALANTARI, D., KARIMZADEH, R., ILBEYGI, E., & ARRIBAS, J. I. Automatic non-destructive video estimation of maturation levels in Fuji apple (*Malus Malus pumila*) fruit in orchard based on colour (Vis) and spectral (NIR) data. **Biosystems Engineering**, v. 195, p. 136-151, 2020. DOI: <https://doi.org/10.1016/j.biosystemseng.2020.04.015>. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S1537511020301148>>

MACHADO, A. H. R., PUIA, J. D., MENEZES, K. C., & MACHADO, W. A Cultura do Café (*Coffeaarabica*) em Sistema Agroflorestal. **Brazilian Journal of Animal and Environmental Research**, v. 3, n. 3, p. 1357-1369, 2020. DOI: <https://doi.org/10.34188/bjaerv3n3-053>. Disponível em: <<https://www.brazilianjournals.com/index.php/BJAER/article/view/14443>>

RISDIN, Fouzia; MONDAL, Pronab Kumar; HASSAN, Kazi Mahmudul. Convolutional Neural Networks (CNN) for Detecting Fruit Information Using Machine Learning Techniques. **IOSR J. Comput. Eng.**, v. 22, p. 1-13, 2020. DOI: 10.9790/0661-2202010113

RODRÍGUEZ, J. P., CORRALES, D. C., AUBERTOT, J. N., & CORRALES, J. C. A computer vision system for automatic cherry beans detection on coffee trees. **Pattern Recognition Letters**, v. 136, p. 142-153, 2020. DOI: <https://doi.org/10.1016/j.patrec.2020.05.034>. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0167865520302117>>

RUFINO, JL dos S. **Programa Nacional de Pesquisa e Desenvolvimento do Café: antecedentes, criação e evolução**. Embrapa Informação Tecnológica: EMBRAPA Café, 2006. Disponível em: <<https://www.bdpa.cnptia.embrapa.br/consulta/busca?b=ad&biblioteca=vazio&busca=autoria: %22RUFINO,%20J.%20L.%20dos%20S.%22>>

SANTI, A. L. et al. **Agricultura de Precisão no Rio Grande do Sul**. 1^a edição. Santa Maria, RS: Editora: CESPOL Publicações. 309p.; il.; 25cm. 2016.

SANTINATO, F., DE OLIVEIRA TAVARES, T., DA SILVA, R. P., DA SILVA, C. D., & ORMOND, A. T. S. Estratégia para uniformização da maturação de frutos do cafeiro. **Agrarian**, v. 10, n. 38, p. 321-327, 2017. Disponível em: <<https://www.semanticscholar.org/paper/Estrat%C3%A9gia-para-uniformiza%C3%A7%C3%A3o-da-matura%C3%A7%C3%A3o-de-do-Santinato-Tavares/f34664eda2058534983293a92e319ab5bd0f1969>>

SANTOS, CARLOS ALEXANDRE SILVA DOS. **Reconhecimento de Imagens de Marcas de Gado utilizando Redes Neurais Convolucionais e Máquinas de Vetores de Suporte /** Carlos Alexandre Silva dos Santos. 135 p. Dissertação (Mestrado)-- Universidade Federal do Pampa, Alegrete – RS. Mestrado em engenharia elétrica, 2017.

SHAPIRO, LINDA G, AND GEORGE C. STOCKMAN. **Computer Vision**. Upper Saddle River, NJ: Prentice Hall, 2001

SILVA, F. C. D., SILVA, F. M. D., ALVES, M. D. C., BARROS, M. M. D., & SALES, R. D. S. Comportamento da força de desprendimento dos frutos de cafeeiros ao longo do período de colheita. **Ciência e Agrotecnologia**, v. 34, p. 468-474, 2010. DOI: <https://doi.org/10.1590/S1413-70542010000200028>. Disponível em: <<https://www.scielo.br/j/cagro/a/y5HyNYdyyHstbRcMvrQp8Fv/abstract/?format=html&lang=pt>>

SILVEIRA , L. .; TSUTSUI ESPERANCINI, M. S.; DE SOUZA BARBOSA, F.; PERES SORATTO, R. . Colheita do café de qualidade: custo e retorno para os produtores da região de mantiqueira de minas - MG. **Energia na Agricultura**, [S. l.], v. 35, n. 3, p. 437–446, 2020. DOI: 10.17224/EnergAgric.2020v35n3p437-446. Disponível em: <https://200.145.140.50/index.php/energia/article/view/4048>. Acesso em: 18 jan. 2022.

SILVEIRA, P. D. N.; MENDES, V. F.; FERRARI, J. L. Aplicativo com processamento em tempo real para levantamento topográfico testado em área de produção cafeeira. **Coffee Science**, v. 12, n. 3, p. 297, 2017. Disponível em: <<http://hdl.handle.net/123456789/9120>>

SLADOJEVIC, S., ARSENOVIC, M., ANDERLA, A., CULIBRK, D., & STEFANOVIC, D. Deep neural networks based recognition of plant diseases by leaf image classification. **Computational intelligence and neuroscience**, v. 2016, 2016. DOI: <https://doi.org/10.1155/2016/3289801>. Disponível em: <<https://www.hindawi.com/journals/cin/2016/3289801/>>

TENSORFLOW. Disponível em: <<https://www.tensorflow.org/learn?hl=pt-br>>. Acesso em: 21 jul. 2021.

TSANG, Sik-Ho. Review: **MobileNetV1—Depthwise Separable Convolution (Light Weight Model). Towards Data Science**, 2020. Disponível em: <<https://towardsdatascience.com/review-mobilenetv1-depthwise-separable-convolution-light-weight-model-a382df364b69>>. Acesso em: 21 jul. 2021.

VIANNA, Carlos. Alberto. Fonseca. Jardim. **O café no Brasil do Século XIX a Partie do Peródico “ O Auxiliador da Indústria Nacional” (1833-1896)**. 2020.Tese (Doutorado)

Universidade Estadual de Campinas, Faculdade de Educação, Campinas-SP, 2020. Disponível em:<<http://repositorio.unicamp.br/jspui/handle/REPOSIP/339352>>

WEN, Chenglu; ZHU, Qingyuan. Dimension reduction analysis in image-based species classification. In: **2010 IEEE International Conference on Intelligent Computing and Intelligent Systems**. IEEE, 2010. p. 731-734. DOI: 10.1109/ICICISYS.2010.5658294. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/5658294>>

ZOPH, B., VASUDEVAN, V., SHLENS, J., & LE, Q. V. Learning transferable architectures for scalable image recognition. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2018. p. 8697-8710. Disponível em: <<https://arxiv.org/abs/1707.07012v4>>