


UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
FACULDADE DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA
MESTRADO EM COMPUTAÇÃO APLICADA



Identificação de Cultivares *Brachiaria* e *Panicum maximum* Utilizando Aprendizado Profundo

Leonardo Lazarino Crivellaro

Campo Grande - MS
27 de Outubro de 2024



UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL
FACULDADE DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA
MESTRADO EM COMPUTAÇÃO APLICADA



Identificação de Cultivares *Brachiaria* e *Panicum maximum* Utilizando Aprendizado Profundo

Leonardo Lazarino Crivellaro

Dissertação de mestrado apresentada como exigência para obtenção do título de Mestrado em Computação Aplicada na Universidade Federal de Mato Grosso do Sul – UFMS.

Orientador: Prof. Dr. Edson Takashi Matsubara

Campo Grande - MS
27 de Outubro de 2024

Identificação de Cultivares *Brachiaria* e *Panicum maximum* Utilizando Aprendizado Profundo

Dissertação de mestrado apresentada como exigência para obtenção do título de
Mestrado em Computação Aplicada na Universidade Federal de Mato Grosso do Sul –
UFMS.

Banca Examinadora:

Prof. Dr. Edson Takashi Matsubara

Prof. Dr. Jonathan de Andrade Silva

Dr. Sanzio Carvalho Lima Barrios

Campo Grande - MS
27 de Outubro de 2024

Agradecimentos

Gostaria de expressar minha gratidão ao meu orientador, Prof. Dr. Edson Takashi Matsubara, pela sua orientação constante e apoio durante o desenvolvimento desta pesquisa. Agradeço também à minha família e amigos, que, com suas palavras de incentivo e presença, me proporcionaram a força necessária para superar os desafios ao longo desta jornada. Sem o carinho, a compreensão e o apoio de vocês, este trabalho não seria possível.

Sou igualmente grato à equipe do Laboratório de Inteligência Artificial da Universidade Federal de Mato Grosso do Sul (UFMS) pelo suporte técnico e infraestrutura disponibilizada. Por fim, sou grato à Embrapa Gado de Corte e a todos que colaboraram com a coleta de imagens e os dados utilizados neste trabalho, em especial ao pesquisador Sanzio Barrios e ao analista Camilo Carromeu.

Este trabalho é o resultado não apenas de estudo e esforço, mas também de laços formados, de momentos de superação e de uma imensa gratidão por todos que, de alguma forma, estiveram ao meu lado. Cada página escrita aqui carrega a marca de todos que contribuíram para esta realização.

Resumo

Forrageiras tropicais são plantas que cobrem o solo das pastagens e são a principal fonte de nutrição para bovinos criados em pastos, regime responsável por 81,8% da produção da carne bovina brasileira em 2023 (ABIEC, 2023). Cada variedade de forrageira, chamada cultivar, possui qualidades nutricionais distintas e exigências de clima, solo e manejo específico. Para assegurar que a pastagem está coberta por forrageiras com valores nutritivos, potencial produtivo e finalidades de uso adequadas e apropriadas às condições regionais, é fundamental identificar corretamente o gênero, a espécie e a cultivar da planta. No entanto, a identificação automatizada e precisa de cultivares forrageiras ainda é um desafio não superado, embora modelos de redes neurais já apresentem bons resultados no reconhecimento de gêneros e espécies. Este trabalho apresenta uma abordagem baseada no uso de modelos de aprendizado profundo para a identificação de cultivares *Brachiaria* e *Panicum maximum*, utilizando imagens coletadas em diferentes estádios de desenvolvimento das plantas afim de aproveitar-se de características morfológicas distintas na diferentes fases de desenvolvimento de planta. A pesquisa foi realizada em uma área experimental da Embrapa Gado de Corte, onde foram plantadas 18 cultivares cujas imagens foram capturadas durante seus primeiros 8 meses de crescimento. As redes neurais analisadas e testadas foram a MobileNet v3 e a MobileViT pois era pré-requisito o baixo custo computacional para execução, afim de integrar essa tecnologia ao aplicativo para dispositivos móveis Pasto Certo®. As redes foram testadas em diferentes combinações de conjuntos por período de crescimento das plantas, os melhores resultados foram no estágio reprodutivo das plantas por meio de diferenças na inflorescência, onde a arquitetura MobileNet v3 apresentou acurácia 82% e a Mobile ViT, 87%, com a última possuindo um melhor grau de generalização. Os datasets construídos apresentam uma contribuição para estudos na área, enquanto os modelos treinados possuem o potencial de se tornar uma ferramenta importante para auxiliar produtores e técnicos na gestão de pastagens.

Palavras-chaves: Redes Neurais, Classificação de forrageiras, Aprendizado Profundo, Forrageiras Tropicais, *Brachiaria*, *Panicum*.

Abstract

Tropical forages are plants that cover pasturelands and are the main source of nutrition for cattle raised on grazing systems, which accounted for 81.8% of Brazilian beef production in 2023 (ABIEC, 2023). Each forage variety, known as a cultivar, has distinct nutritional qualities and specific climate, soil, and management requirements. Ensuring that pastures are covered with forages of adequate nutritive value, productive potential, and appropriate usage suited to regional conditions requires the acknowledgment of the plant's genus, species, and cultivar. However, the automated and precise identification of forage cultivars remains an unsolved challenge, although neural network models have already shown good results in recognizing genera and species. This work presents an approach based on deep learning models for identifying *Brachiaria* and *Panicum maximum* cultivars using images collected at different stages of plant development to leverage distinct morphological characteristics across developmental phases. The research was conducted in an experimental area at Embrapa Beef Cattle, where 18 cultivars were planted, and images were captured during their first 8 months of growth. The neural networks analyzed and tested were MobileNet v3 and MobileViT, as low computational cost for execution was a prerequisite to integrate this technology into the Pasto Certo® mobile application. The networks were tested with different combinations of datasets by plant growth stages. The best results were achieved in the reproductive stage due to differences in inflorescence, where the MobileNet v3 architecture achieved 82% accuracy, and MobileViT achieved 87%, with the latter showing better generalization capabilities. The constructed datasets contribute to research in the field, while the trained models have the potential to become important tools for assisting producers and technicians in pasture management.

Keywords: Neural Networks, Cultivar Classification, Deep Learning, Tropical Forages, *Brachiaria*, *Panicum*.

Lista de ilustrações

Figura 1 –	Comparação entre as cultivares Marandu e BRS Piatã com três meses (a), três meses e uma semana (b) e quatro meses (c) de idade	17
Figura 2 –	Cultivares Marandu (a) e BRS Piatã (b) com inflorescência aparente	18
Figura 3 –	Morfologia das forrageiras tropicais (FONTANELI; SANTOS, 2012)	20
Figura 4 –	Cultivares do gênero <i>Brachiaria</i>	21
Figura 5 –	Cultivares do gênero <i>Panicum</i>	22
Figura 6 –	Arquitetura alto nível de uma CNN (reprodução de (PATTERSON; GIBSON, 2017) pág.128)	24
Figura 7 –	Um exemplo de convolução 2D, as setas ilustram como o elemento superior esquerdo da saída é formado pela aplicação do <i>kernel</i> na região correspondente no canto superior esquerdo da entrada. Nesse caso, não há preenchimento de bordas (<i>padding</i>), o que significa que a saída tem um tamanho menor que a entrada, pois a operação de convolução é realizada apenas nas regiões onde o <i>kernel</i> cabe inteiramente dentro da imagem, também conhecido como convolução “válida” em alguns contextos (reprodução de (GOODFELLOW; BENGIO; COURVILLE, 2016). pág.350)	25
Figura 8 –	A função de ativação de unidade linear retificada, conhecida como ReLU (<i>Rectified Linear Unit</i>), é a função de ativação padrão recomendada para a maioria das redes neurais <i>feedforward</i> (GOODFELLOW; BENGIO; COURVILLE, 2016). pág.191	26
Figura 9 –	Visão geral do modelo: a imagem é dividida em blocos de tamanho fixo, faz-se a incorporação linear (<i>linear embedding</i>) de cada bloco, adiciona-se <i>embeddings</i> de posição e a sequência resultante de vetores é alimentada para um codificador padrão de <i>Transformer</i> . Para realizar a classificação, utiliza-se a abordagem padrão de adicionar um “ <i>token</i> ” aprendível extra à sequência (DOSOVITSKIY et al., 2021). pág.3	28
Figura 10 –	Bloco residual de <i>bottleneck</i> transforma de k canais para k’ canais, com <i>stride</i> s, e fator de expansão t (SANDLER et al., 2019). pág.4	29

Figura 11 –	MobileNetV2: Cada linha descreve uma sequência de uma ou mais camadas idênticas (com exceção do <i>stride</i>), repetidas n vezes. Todas as camadas dentro da mesma sequência têm o mesmo número de canais de saída. A primeira camada de cada sequência utiliza um <i>stride</i> s , enquanto todas as outras camadas da sequência usam um <i>stride</i> de 1. Todas as convoluções espaciais utilizam <i>kernels</i> de tamanho 3×3 . O fator de expansão é sempre aplicado ao tamanho da entrada, conforme descrito na Tabela 1 do artigo de MobileNetV2 (SANDLER et al., 2019). pág.5	30
Figura 12 –	Especificações de ambas as arquiteturas da MobileNetV3. SE indica se há um módulo <i>Squeeze-and-Excite</i> no bloco correspondente. NL refere-se ao tipo de função de ativação utilizada. HS denota a função de ativação <i>h-swish</i> , enquanto RE denota a ReLU (<i>Rectified Linear Unit</i>). NBN indica que não há <i>batch normalization</i> aplicada nesse bloco, e s denota o <i>sstride</i> utilizado para aquela camada (HOWARD et al., 2019). pág.5	32
Figura 13 –	MobileViT: Conv- $n \times n$ no bloco MobileViT representa uma convolução padrão de $n \times n$, enquanto MV2 refere-se ao bloco MobileNetV2. Os blocos que realizam <i>down-sampling</i> (redução da resolução espacial) são indicados com $\downarrow 2$, sinalizando uma diminuição no tamanho da entrada por um fator de 2 (MEHTA; RASTEGARI, 2021). pág.2	33
Figura 14 –	No bloco MobileViT, cada pixel é capaz de enxergar todos os outros <i>pixels</i> . Nesse exemplo, o pixel vermelho atende aos <i>pixels</i> azuis (ou seja, <i>pixels</i> na mesma posição em outros blocos) por meio de <i>transformers</i> . Como os <i>pixels</i> azuis já codificaram informações sobre seus vizinhos usando convoluções, isso permite que o pixel vermelho codifique informações de todos os <i>pixels</i> na imagem. Cada célula nas grades pretas representa um bloco, enquanto cada célula nas grades cinzas representa um pixel individual. Essa abordagem combina convoluções para capturar informações locais e <i>transformers</i> para modelar dependências globais, garantindo que cada pixel carregue informações contextuais de toda a imagem (MEHTA; RASTEGARI, 2021). pág.5	34
Figura 15 –	A comparação entre MobileViT e CNNs no conjunto de validação do ImageNet-1k. Todos os modelos utilizando apenas aumentos básicos de dados (MEHTA; RASTEGARI, 2021). pág.7	35
Figura 16 –	Procedimento para a construção do banco de imagens (FAZAN, 2020)	37

Figura 17 –	Gráficos das taxas de acerto médias obtidas pelos modelos na classificação de gênero, espécie e cultivar no período da seca (FAZAN, 2020)	38
Figura 18 –	Taxa de acerto dos modelos na região geral no período de chuva para classificação por gênero (A), por espécie (B) e por cultivar (C) (FAZAN, 2020)	39
Figura 19 –	Gráfico comparativo de <i>F1-Scores</i> na classificação de cultivares da Área 56 na seca em dois períodos, onde a linha azul representa o modelo treinado com imagens entre setembro e novembro de 2019 e a vermelha, o modelo MobileNetV2 treinado com imagens entre junho e agosto de 2019	42
Figura 20 –	Disposição das parcelas de cultivares plantadas na área da Embrapa Gado de Corte	44
Figura 21 –	Aplicação para visualização dos dados coletados	46
Figura 22 –	Ilustração do procedimento de recorte e redimensionamento das imagens do dataset durante o treinamento	51
Figura 23 –	Comparação entre as cultivares <i>Brachiaria humidicola</i> cv. Llanero (parcela 107) e a <i>Brachiaria brizantha</i> cv. Xaraés (parcela 205) nos dias 29/03/2022 e 21/05/2022	56
Figura 24 –	Comparação entre as cultivares <i>Brachiaria humidicola</i> cv. Humidicola comum (parcela 307) e <i>Brachiaria humidicola</i> cv. BRS Tupi (parcela 404) nos dias 23/04/2022, 22/07/2022 e 09/09/2022	56
Figura 25 –	Taxa de loss de treinamento e validação para o modelo classificando em idade e cultivar, onde a curva inferior é a taxa de loss do treino e a curva superior é a taxa de loss da validação por época	58
Figura 26 –	Taxa de <i>loss</i> de treinamento e validação para o modelo classificando em cultivar, onde a curva inferior é a taxa de <i>loss</i> do treino e a curva superior é a taxa de perda da validação por época	60
Figura 27 –	Comparação de <i>precision</i> entre os modelos MobileNet V3 treinados nos <i>datasets</i> por Período	62
Figura 28 –	Comparação de <i>recall</i> entre os modelos MobileNet V3 treinados nos <i>datasets</i> por Período	63
Figura 29 –	Comparação de <i>f1-score</i> entre os modelos MobileNet V3 treinados nos <i>datasets</i> por Período	63
Figura 30 –	Taxas de <i>loss</i> de Treino e validação do modelo MobileNet V3 treinado no <i>dataset</i> Mesclado-Compatível	65
Figura 31 –	Taxas de <i>loss</i> de Treino e validação do modelo MobileNet V3 treinado no <i>dataset</i> Mesclado-Todo	67

Figura 32	–	Loss de treino do modelo MobileNet no <i>dataset</i> Meclado-Inflorescência	69
Figura 33	–	Loss de treino do modelo MobileVIT no <i>dataset</i> Geral	72
Figura 34	–	Comparação de <i>precision</i> dos modelos MobileVIT treinados nos <i>datasets</i> separados por período	74
Figura 35	–	Comparação de <i>recall</i> dos modelos MobileVIT treinados nos <i>datasets</i> separados por período	75
Figura 36	–	Comparação de <i>f1-score</i> dos modelos MobileVIT treinados nos <i>datasets</i> separados por período	76
Figura 37	–	Loss de treino do modelo MobileVIT no <i>dataset</i> Mesclado-Compatível	77
Figura 38	–	Taxa de <i>loss</i> de treino de validação do modelo MobileVIT no <i>dataset</i> Mesclado-Todo	79
Figura 39	–	Taxa de <i>loss</i> de treino de validação do modelo MobileVIT no <i>dataset</i> Mesclado-Inflorescência	81
Figura 40	–	Comparação de exemplares de BRS Paiaguás (parcela 312) e BRS Ipyporã (parcela 304)	84
Figura 41	–	Comparação de taxa de acerto entre MobileNet e MobileVIT nos <i>datasets</i> separados por períodos	85

Lista de tabelas

Tabela 1	–	Características morfológicas de cultivares de <i>Panicum maximum</i> .	23
Tabela 2	–	Matriz de confusão	35
Tabela 3	–	Compilado dos resultados dos experimentos realizados no trabalho (FAZAN, 2020)	40
Tabela 4	–	Área 56 período de seca - métricas por período de 3 meses	41
Tabela 5	–	Tabela de <i>datasets</i> Originais	47
Tabela 6	–	Disponibilidade de dados nos Datasets Original e Fazan	48
Tabela 7	–	<i>Dataset</i> mesclando imagens dos <i>Dataset</i> da Tabela 5 e da Tabela 3	49
Tabela 8	–	Relatório de classificação do modelo treinado para identificar idade e cultivar.	59
Tabela 9	–	Relatório de classificação do modelo treinado para identificar cultivares.	61
Tabela 10	–	Matriz de confusão do modelo para identificação de cultivares.	61
Tabela 11	–	Comparação entre as médias de acurácia e <i>f1</i> dos modelos MobileNet treinados por período	64
Tabela 12	–	Relatório de classificação do modelo MobileNet V3 treinado no <i>dataset</i> Mesclado-Compatível	66
Tabela 13	–	Relatório de classificação do modelo MobileNet V3 treinado no <i>dataset</i> Mesclado-Compatível separando o conjunto de testes pelos <i>datasets</i> de origem	66
Tabela 14	–	Relatório de classificação do modelo MobileNet V3 treinado no <i>dataset</i> Mesclado-Todo	68
Tabela 15	–	Relatório de classificação do modelo MobileNet V3 treinado no <i>dataset</i> Mesclado-Todo separando o conjunto de testes pelos <i>datasets</i> de origem	68
Tabela 16	–	Relatório de classificação do modelo MobileNet treinado no <i>dataset</i> Mesclado-Inflorescência	70
Tabela 17	–	Relatório de classificação do modelo MobileNet treinado no <i>dataset</i> Mesclado-Inflorescência separando o conjunto de testes pelos <i>datasets</i> de origem.	70
Tabela 18	–	Relatório de classificação do modelo MobileVIT treinado no <i>dataset</i> Geral	73
Tabela 19	–		76
Tabela 20	–	Relatório de classificação do modelo MobileVIT treinado no <i>dataset</i> Mesclado-Compatível	78

Tabela 21	–	Relatório de classificação do modelo MobileVIT treinado no <i>dataset</i> Mesclado-Compatível separando o conjunto de testes pelos <i>datasets</i> de origem	78
Tabela 22	–	Relatório de classificação do modelo MobileVIT treinado no <i>dataset</i> Mesclado- <i>Todo</i>	80
Tabela 23	–	Relatório de classificação do modelo MobileVIT treinado no <i>dataset</i> Mesclado- <i>Todo</i> separando o conjunto de testes pelos <i>datasets</i> de origem	80
Tabela 24	–	Relatório de classificação do modelo MobileVIT treinado no <i>dataset</i> Mesclado-Inflorescência	82
Tabela 25	–	Relatório de classificação do modelo MobileVIT treinado no <i>dataset</i> Mesclado-Inflorescência separando o conjunto de testes pelos <i>datasets</i> de origem.	82
Tabela 26	–	Comparação entre a melhor taxa de acerto de modelos MobileNet e MobileVIT treinados por período e geral	86
Tabela 27	–	Comparação de taxas de acerto entre todos os modelos treinados nos <i>datasets</i> Mesclados	87
Tabela 28	–	Classification Report da MobileNet V3 treinada no dataset Período 1	94
Tabela 29	–	Classification Report da MobileNet V3 treinada no dataset Período 2	95
Tabela 30	–	Classification Report da MobileNet V3 treinada no dataset Período 3	96
Tabela 31	–	Classification Report da MobileNet V3 treinada no dataset Período 4	97
Tabela 32	–	Classification Report da MobileNet V3 treinada no dataset Período 5	98
Tabela 33	–	Classification Report do modelo Mesclado compatível para o conjunto de teste retirado do dataset Original	99
Tabela 34	–	Classification Report do modelo Mesclado compatível para o conjunto de teste retirado do dataset Fazan	99
Tabela 35	–	Classification Report do modelo Mesclado compatível para o conjunto de teste retirado do dataset Original	100
Tabela 36	–	Classification Report do modelo Mesclado compatível para o conjunto de teste retirado do dataset Fazan	101
Tabela 37	–	Classification Report do modelo Mesclado Inflorescência para o conjunto de teste retirado do dataset Original	103
Tabela 38	–	Classification Report do modelo Mesclado Inflorescência para o conjunto de teste retirado do dataset Fazan	104
Tabela 39	–	Classification Report da MobileVIT treinada no dataset Período 1	105
Tabela 40	–	Classification Report da MobileVIT treinada no dataset Período 2	106
Tabela 41	–	Classification Report da MobileVIT treinada no dataset Período 3	107
Tabela 42	–	Classification Report da MobileVIT treinada no dataset Período 4	108

Tabela 43 –	Classification Report da MobileViT treinada no dataset Período 5 .	109
Tabela 44 –	Classification Report do modelo Mesclado-Compatível para o conjunto de teste retirado do dataset Original	110
Tabela 45 –	Classification Report do modelo Mesclado-Compatível para o conjunto de teste retirado do dataset Fazan	110
Tabela 46 –	Classification Report do modelo Mesclado-Todo para o conjunto de teste retirado do dataset Original	111
Tabela 47 –	Classification Report do modelo Mesclado-Todo para o conjunto de teste retirado do dataset Fazan	112
Tabela 48 –	Classification Report do modelo Mesclado Inflorescência para o conjunto de teste retirado do dataset Original	113
Tabela 49 –	Classification Report do modelo Mesclado Inflorescência para o conjunto de teste retirado do dataset Fazan	114

Sumário

1	Introdução	15
1.1	Contextualização	15
1.2	Objetivos	18
1.3	Hipótese e Perguntas Específicas	18
1.4	Organização do Trabalho	19
2	Revisão Bibliográfica	20
2.1	Fundamentação Teórica	20
2.1.1	Forrageiras Tropicais	20
2.1.2	Redes Neurais	23
2.1.2.1	Redes Neurais Convolucionais	23
2.1.2.2	Vision Transformers	27
2.1.2.3	Arquiteturas Leves do Estado da Arte	29
2.1.3	Medidas de Desempenho	35
2.2	Estado da Arte	36
3	Metodologia	43
3.1	Coleta de Imagens	43
3.2	Análise dos Dados	45
3.3	Construção dos Datasets	46
3.4	Treinamento de Modelos	49
3.4.1	Tratamento das imagens	50
3.4.2	MobileNet V3	51
3.4.2.1	Datasets Originais	51
3.4.2.2	Datasets Mesclados	52
3.4.3	MobileVit	53
3.4.3.1	Datasets Originais	53
3.4.3.2	Datasets Mesclados	54
4	Resultados	55
4.1	Análise dos Dados	55
4.2	Treinamento da MobileNet V3	57
4.2.1	Dataset por Datas	57
4.2.2	Dataset Geral	60
4.2.3	Datasets por Período	62
4.2.4	Dataset Mesclado-Compatível	65

4.2.5	Dataset Mesclado-todo	67
4.2.6	Dataset Mesclado-Inflorescência	69
4.3	Treinamento da MobileVIT	71
4.3.1	Dataset Geral	71
4.3.2	Datasets por Período	73
4.3.3	Dataset Mesclado-Compatível	76
4.3.4	Dataset Mesclado-Todo	78
4.3.5	Dataset Mesclado-Inflorescência	80
5	Discussão	83
6	Conclusão	88
6.1	Dificuldades e Limitações	88
6.2	Principais Contribuições	89
6.3	Trabalhos Futuros	89
	Referências	90
	 Apêndices	 93
	APÊNDICE A MobileNet V3	94
A.1	Apêndices - Classification Reports de treinamentos separados por períodos	94
A.2	Apêndices - Classification Reports do modelo Mesclado-Compatível separado por dataset de origem	99
A.3	Apêndices - Classification Reports do modelo Mesclado-Todo separado por dataset de origem	100
A.4	Apêndices - Classification Reports do modelo Mesclado-Inflorescência nos conjuntos separados pelo dataset de origem	103
	APÊNDICE B MobileVIT	105
B.1	Apêndices - Classification Reports de treinamentos separados por períodos	105
B.2	Apêndices - Classification Reports do modelo Mesclado-Compatível nos conjuntos separados pelo dataset de origem	110
B.3	Apêndices - Classification Reports do modelo Mesclado-Todo nos conjuntos separados pelo dataset de origem	111
B.4	Apêndices - Classification Reports do modelo Mesclado-Inflorescência nos conjuntos separados pelo dataset de origem	113

1 Introdução

A agricultura e a pecuária desempenham um papel central na economia brasileira, sendo responsáveis por grande parte do fornecimento de alimentos no país e no mundo. Dentro desse contexto, a produção de forrageiras é essencial para a alimentação do rebanho bovino, especialmente em regimes de pastagem (COSTA et al., 2004). Contudo, a correta identificação das forrageiras, principalmente ao nível de cultivares, é um desafio enfrentado por produtores e técnicos. A semelhança morfológica entre as espécies e cultivares, bem como as variações causadas por fatores como idade e condições climáticas, pode dificultar esse processo.

Nos últimos anos, o uso de tecnologias emergentes, como a inteligência artificial e redes neurais, tem oferecido soluções inovadoras para o setor agropecuário. Aplicações baseadas em processamento de imagens e aprendizado de máquina permitem uma identificação automatizada e precisa de diferentes gêneros de plantas. Entretanto, ainda existem lacunas na literatura quanto à eficácia dessas tecnologias em identificar cultivares com alta precisão, especialmente em diferentes estádios de desenvolvimento (FAZAN, 2020).

Diante dessa realidade, o presente trabalho busca explorar o potencial das redes neurais na identificação automatizada de cultivares de forrageiras tropicais. A pesquisa está alinhada com os esforços da Embrapa (Empresa Brasileira de Pesquisa Agropecuária) e da Unipasto (Associação para o Fomento à Pesquisa de Melhoramento de Forrageiras), que visam melhorar o manejo das pastagens brasileiras por meio de soluções tecnológicas.

1.1 Contextualização

As forrageiras são plantas que recebem esse nome por possuírem a característica de se estenderem pelo solo e cobrirem as áreas de pastagens, sendo estas a principal fonte de alimento para os bovinos brasileiros (COSTA et al., 2004). Estima-se que 81,8% da carne bovina produzida em território nacional em 2023 provém de regimes de pastagens (ABIEC, 2023), uma área total de cerca de 167 milhões de hectares (LOPES; BASSO, 2016). Nesse contexto, as forrageiras tropicais do gênero *Brachiaria* e *Panicum* se destacam por cobrir mais de 90% destas áreas de pastagens cultivadas (BARRIOS et al., 2017).

O mercado de forrageiras tropicais é promissor e movimentou R\$ 1,4 bilhão durante o ano de 2020 (OMOTE et al., 2021). No entanto, como todo mercado em ascensão, esse montante desperta o olhar dos oportunistas que viram nesses produtos uma chance para comercializar sementes ilegais e piratas. Estimou-se, em 2015, que 30% do mercado de sementes forrageiras tropicais já era ocupado por sementes piratas ou ilegais (LUCI-

MARA, 2015). Esse tipo de semente possui uma qualidade inferior que pode causar a má formação da pastagem e empobrecer os valores nutritivos esperados pelo produtor para seu gado. Uma escolha errada da cultivar forrageira para determinado local ou sistema de produção, pode estimular o processo de degradação da pastagem, diminuir o valor das terras e atrasar a idade do abate. O processo de recuperação do pasto degradado é caro e um fator determinante na sustentabilidade da produção (PERON; EVANGELISTA et al., 2004).

Para auxiliar produtores e técnicos na implantação e no manejo de pastagens tropicais, a Embrapa em parceria com a Unipasto desenvolveu o aplicativo web com foco no funcionamento em dispositivos móveis, chamado Pasto Certo®. A aplicação engloba diversas ferramentas como a sugestão de cultivares de acordo com características da área, do solo, do clima e do sistema de produção, um catálogo com características das forrageiras, catálogo de vendedores de sementes e mudas, calculadora de sementes, vídeos informativos e outras funcionalidades que simplificam o acesso a informação, tornando-a bastante popular entre os produtores de gado de corte no Brasil (BARRIOS et al., 2021).

As cultivares forrageiras são classificadas taxonomicamente através de suas características morfológicas vegetativas e reprodutivas, como inflorescência, bainha, lâmina folhar e colmo, sendo diferenciadas em três níveis de similaridade: gênero, espécie e cultivar; esta última apresenta as variações menos expressivas.

Outras características menos visuais também podem distinguir as cultivares, como a capacidade de adaptação à climas mais secos ou mais chuvosos, mais quentes ou mais frios, resistência a doenças e pragas ou diferenças no grau de exigência de nutrientes no solo. Essas, determinam diretamente o desempenho da planta para nutrição. Por isso, para validar as expectativas e evitar problemas com o rebanho, uma das medidas tomadas pelos produtores para iniciar o manejo de um pasto desconhecido é identificar com qual gênero, espécie ou cultivar de forrageira ele está lidando, em suas diferentes idades e estádios para adaptar seu tratamento e mitigar problemas.

De modo geral as forrageiras tropicais apresentam uma elevada semelhança entre si, principalmente quando são comparadas cultivares de uma mesma espécie e em pleno desenvolvimento. Além disso, fatores como a idade da planta, doenças, pragas, tipo de manejo e outros fatores desgastantes podem afetar sua morfologia e dificultar a identificação até mesmo para técnicos especializados.

O reconhecimento automatizado de forrageiras através de imagens coletadas por smartphones foi estudado e atingiu bons resultados para identificação nos níveis de gêneros e espécies (FAZAN, 2020), porém a identificação no nível de cultivar ainda não atingiu uma taxa de acerto satisfatória e ainda é um problema em aberto.

A Figura 1 apresenta as semelhanças entre cultivares da mesma espécie, utilizando

as cultivares *Brachiaria brizantha* cv. BRS Piatã e *Brachiaria brizantha* cv. Marandu em diferentes idades, em (a) com aproximadamente três meses de idade, em (b) sete dias após a anterior e em (c) com quatro meses. Percebe-se que a idade teve forte influência nas diferenças morfológicas das plantas, ao ponto de parecerem a mesma planta em (a) e (b) porém em (c) poderem ser distinguidas.




Figura 1 – Comparação entre as cultivares Marandu e BRS Piatã com três meses (a), três meses e uma semana (b) e quatro meses (c) de idade

Essa diferenciação se dá principalmente pelas características de suas inflorescências, como visto mais claramente na Figura 2 que, também, apresenta as cultivares Marandu e BRS Piatã mais de perto com 4 meses de idade.




Figura 2 – Cultivares Marandu (a) e BRS Piatã (b) com inflorescência aparente

1.2 Objetivos

Esta dissertação foi desenvolvida em colaboração com a Embrapa Gado de Corte e o objetivo geral, definido conjuntamente, é o desenvolvimento de modelos de aprendizado profundo para a identificação de cultivares considerando seu estágio de desenvolvimento. Enquanto os objetivos específicos são os seguintes:

1. Coletar dados de 18 cultivares de forrageiras tropicais em parcelas experimentais, registrando imagens ao longo de diferentes estádios de desenvolvimento;
2. Organizar essas imagens em um banco de dados estruturado, categorizando-as por cultivar e idade, o que facilita o treinamento de modelos de aprendizado de máquina;
3. Realizar o treinamento e ajuste fino de redes neurais MobileNet v3 e MobileViT pré-treinadas, buscando melhorar a precisão na identificação das cultivares;
4. Avaliar os resultados desses modelos quanto à acurácia e eficiência na classificação;
5. Redigir artigos científicos com base nos resultados da pesquisa, contribuindo para o avanço do conhecimento sobre o uso de redes neurais na identificação automatizada de cultivares.

1.3 Hipótese e Perguntas Específicas

A hipótese central deste trabalho é que as diferentes fases de desenvolvimento das cultivares revelam características morfológicas suficientes para torná-las mais distinguíveis

para os modelos de redes neurais. Para testar essa hipótese, foram formuladas perguntas específicas que guiaram a avaliação experimental:

1. Cultivares da mesma espécie, apesar de morfológicamente muito semelhantes no estágio adulto, apresentam diferenças significativas em uma determinada idade que possibilitam sua diferenciação?
2. As variações na inflorescência das cultivares no estágio adulto ocorrem em diferentes períodos e essas variações podem ser usadas para melhorar a acurácia na identificação das cultivares?
3. Novas arquiteturas de redes neurais proporcionam uma melhoria significativa na classificação das cultivares em relação às arquiteturas anteriores?
4. O modelo é capaz de aprender a classificar tanto as cultivares quanto suas idades de maneira eficiente?
5. O conhecimento da idade da cultivar contribui para uma melhoria na identificação e classificação dessas plantas?
6. A fase de inflorescência proporciona diferenças morfológicas suficientes para facilitar a distinção entre cultivares, aumentando a acurácia do modelo?
7. O aumento da quantidade e variedade de exemplares das cultivares nas classes de treinamento melhora o aprendizado dos modelos e a acurácia da classificação?
8. O modelo desenvolvido atinge um nível de acurácia aceitável e é suficientemente leve para ser implementado em um aplicativo web para dispositivos móveis?

1.4 Organização do Trabalho

Este trabalho está organizado em seis capítulos. O Capítulo 1 apresenta o contexto, os objetivos e a motivação para o uso de Inteligência Artificial na identificação de cultivares. O Capítulo 2 aborda as características das forrageiras, as técnicas de aprendizado de máquina aplicadas à classificação de imagens e trabalhos relacionados. O Capítulo 3 descreve os métodos, modelos e procedimentos experimentais adotados. O Capítulo 4 apresenta e analisa os dados obtidos. O Capítulo 5 interpreta os resultados e discute as limitações do estudo. Finalmente, a Conclusão resume as principais contribuições.

2 Revisão Bibliográfica

2.1 Fundamentação Teórica

Esta seção apresenta as teorias fundamentais necessárias para a compreensão deste trabalho. Cada Seção abordará um tópico diferente, sendo a Seção 2.1.1 dedicada às forrageiras tropicais, a Seção 2.1.2 tratará de redes neurais e, por fim, a Seção 2.1.3 abordará as medidas de desempenho de redes neurais.

2.1.1 Forrageiras Tropicais

A Figura 3 mostra a morfologia das cultivares gramíneas forrageiras, como as do gênero *Brachiaria* e *Panicum*, discutidas nessa seção. Nela podemos reconhecer características importantes para classificação taxonômica das forrageiras como sua inflorescência, bainha, lâmina foliar e colmo. Através dessas características, seguindo as normas da biotaxonomia, elas podem ser classificadas em diferentes gênero, espécie e cultivar, da forma mais generalizada para a mais específica.




Figura 3 – Morfologia das forrageiras tropicais (FONTANELI; SANTOS, 2012)

Esta seção oferece uma descrição concisa das características morfológicas que distinguem as forrageiras pertencentes aos gêneros *Brachiaria* e *Panicum*.

- Gênero *Brachiaria*

As gramíneas forrageiras do gênero *Brachiaria* desempenham um papel de grande importância econômica ao viabilizar a atividade pecuária em solos ácidos e de baixa fertilidade do cerrado brasileiro. Elas aumentam a produtividade por área e por animal em comparação com as forrageiras nativas (PIRES, 2010). A Figura 4 apresenta imagens de quatro cultivares desse gênero.




Figura 4 – Cultivares do gênero *Brachiaria*

As principais características que identificam *Brachiaria*, dentro da tribo *Paniceae*, são as espiguetas que podem ser ovais a oblongas, arrançadas em racemos unilaterais, com a gluma inferior adjacente à ráquis, isto é, em posição adaxial (PIRES, 2010). Chave para identificação das principais espécies do gênero *Brachiaria spp* (PIRES, 2010).

1. Gluma inferior com 2/3 do comprimento da espiguetas, multinervuras; lema inferior com nervuras reticuladas
 - a) Glumas separadas por um internódio curto;
 - b) Plantas entouceiradas, rizomatosas e estoloníferas; inflorescências com 2-3 racemos; folhas lineares nas touceiras, mas lanceoladas nos estolões (*Brachiaria humidicola*)
 - c) Plantas menos entouceiradas, cespitosas (sem estolões); inflorescências com 3-8 racemos; folhas lineares a lanceoladas (*Brachiaria dictyoneura*)
2. Glumas não separadas por internódio
 - a) Lâminas foliares planas ou enroladas
 - b) Ráquis 1-2 mm de largura; lâminas foliares 3-17 mm de largura (*Brachiaria jubata*)
 - c) Ráquis 0,5 mm de largura; lâminas foliares 2-6 mm de largura (*Brachiaria bovonei*)
 - d) Lâminas foliares filiformes e rígidas (*Brachiaria subulifolia*)

3. Gluma inferior com até 1/2 do comprimento da espiguetas

- a) Gluma inferior com até 1/2 do comprimento da espiguetas
- b) Ráquis em meia-lua na secção transversal, estreita, 1 a 1,5 mm de largura; plantas entouceiradas e cespitosas (*Brachiaria brizantha*)
- c) Ráquis na forma de fita, 1-3,5 de largura, plantas estoloníferas
- d) Ráquis de 1-1,7 mm de largura (*Brachiaria decumbens*)
- e) Ráquis de 2-3,5 mm de largura (*Brachiaria ruziziensis*)

Nesse trabalho buscou-se identificar cultivares de *Brachiaria ruziziensis* (Keneddy), *Brachiaria brizantha* (BRS Paiaguás, BRS Piatã, Marandu e Xaraés), *Brachiaria humidicola* (Comum e Llanero) e híbridos interespecíficos (Mavuno e Mulato II).

- Espécie *Panicum maximum*

A forrageira *Panicum maximum* Jacq. é mundialmente reconhecida por sua alta produtividade e qualidade de forragem, além de ser adaptada a climas tropicais e subtropicais. Trata-se da forrageira tropical propagada por sementes mais produtiva disponível no mercado, desempenhando um papel fundamental na engorda de bovinos no Brasil (PIRES, 2010). A Figura 5 apresenta imagens de quatro cultivares desse gênero.




Figura 5 – Cultivares do gênero *Panicum*

O *Panicum maximum* compartilha espaço no mercado de sementes no Brasil com as braquiárias. De modo geral, as cultivares de *P. maximum* são recomendadas para animais com maiores exigências nutricionais e para solos de melhor fertilidade, enquanto as braquiárias são mais utilizadas na cria e recria do rebanho, em solos mais pobres e ácidos, complementando-se como forrageiras essenciais nos sistemas brasileiros de produção de carne. Além disso, o *P. maximum* também desempenha um papel relevante na produção de leite, não apenas no Brasil, mas O *Panicum maximum* tem se mostrado uma forrageira importante, tanto para pastejo direto quanto para a produção de silagem e feno (PIRES, 2010).

Tabela 1 – Características morfológicas de cultivares de *Panicum maximum*.

Características	Tanzânia	Mombaça	Tobiatã	Colonião	Massai	Aruana	Atlas	Áries
Altura da planta (m)	1,2	1,7	1,6–1,4	0,6	0,8	1,1	0,9	–
Largura das folhas (cm)	2,7	3,0	4,6–2,9	0,9	2,0	2,5	1,8	–
Comprimento das folhas (cm)	77	97	90	99	70	38	55	39
Manchas roxas nas espiguetas	muitas	poucas	muitas	poucas	intermediárias	poucas	poucas	poucas
Pilosidade nas folhas	ausente	pouca	pouca	ausente	média	pouca	pouca	pouca
Pilosidade nos colmos	ausente	ausente	muita	ausente	média	média	ausente	média
Cerosidade nos colmos	ausente	ausente	ausente	presente	ausente	ausente	presente	presente
Porte das folhas	decumbentes	eretas/quebradiças	eretas/quebradiças	eretas/quebradiças	decumbentes	decumbentes	eretas	decumbentes

As características morfológicas das principais plantas do gênero *Panicum* podem ser vistas na Tabela 1.

As cultivares que foram utilizadas para esse trabalho foram: Tanzânia, BRS Zuri, Mombaça, BRS Tamani, Massai e BRS Quênia.

2.1.2 Redes Neurais

Rede neurais são modelos de aprendizado inspirado no funcionamento do cérebro humano, composto por unidades interconectadas chamadas de “neurônios artificiais”. Uma rede neural é uma rede de funções simples que podem adquirir conhecimento através da experiência, ajustando as forças das conexões entre essas unidades (MITCHELL, 1997).

O aprendizado profundo é um subcampo da aprendizado de máquinas de abordagens conexionistas, o termo “profundo” se refere às sucessivas camadas de neurônios artificiais ou perceptrons. Cada perceptron recebe dados, os transforma e passa para outros perceptrons até o final da rede (PATTERSON; GIBSON, 2017). Assim são construídas representações complexas a partir de representações mais simples, permitindo que o computador aprenda de maneira hierárquica e incremental, desenvolvendo conceitos mais elaborados a partir de conceitos básicos. Por exemplo, um modelo de aprendizado profundo pode representar o conceito de uma imagem de uma pessoa combinando outros conceitos como cantos e contornos, que por sua vez são definidos em termos de bordas (GOODFELLOW; BENGIO; COURVILLE, 2016).

Existem diversas arquiteturas de aprendizado profundo, as duas utilizadas nessa pesquisa são redes neurais convolucionais (CNN) e *vision transformers* (ViT). Suas principais características serão dadas a seguir.

2.1.2.1 Redes Neurais Convolucionais

As redes convolucionais, também conhecidas como redes neurais convolucionais ou CNNs, são um tipo especializado de rede neural projetada para processar dados com uma topologia em matriz. Exemplos disso incluem dados de imagem, que podem ser representados como uma grade bidimensional (2D) de *pixels*. O nome “rede neural convolucional” deriva do fato de a rede empregar uma operação matemática chamada convolução (GOODFELLOW; BENGIO; COURVILLE, 2016).

As CNNs transformam os dados de entrada da camada de entrada, passando por todas as camadas intermediárias, até um conjunto de pontuações de classes, fornecidas pela camada de saída. Algumas das arquiteturas de CNNs mais utilizadas tem-se LeNet (LECUN et al., 1998), AlexNet (KRIZHEVSKY; SUTSKEVER; HINTON, 2012), GoogLeNet (ZEILER; FERGUS, 2013), ResNet (HE et al., 2015), MobileNet (HOWARD et al., 2017).

Embora existam muitas variações da arquitetura das CNNs, todas elas se baseiam no padrão de camadas, como demonstrado na Figura 6 (PATTERSON; GIBSON, 2017).




Figura 6 – Arquitetura alto nível de uma CNN (reprodução de (PATTERSON; GIBSON, 2017) pág.128)

A primeira camada é a camada de entrada (*input layer*) que geralmente aceita entradas tridimensionais no formato espacial de tamanho (largura $\times$ altura) da imagem, com uma profundidade que representa os canais de cor (comumente três para os canais de cor RGB). (PATTERSON; GIBSON, 2017)

As camadas intermediárias são chamadas de camadas de extração de características e possuem um padrão de repetição na sequência: convolução, ReLU e agrupamento.

- Convolução

A convolução é uma operação essencial para o processamento de imagens. Ela é utilizada para detectar padrões, como bordas, texturas e formas em imagens, aplicando um filtro (*kernel*) à entrada para produzir uma saída, como uma imagem filtrada ou mapa de características. Esse processo pode ser visualizado na Figura 7, onde cada elemento da saída é dado pela sobreposição do *kernel* na entrada em diferentes posições (GOODFELLOW; BENGIO; COURVILLE, 2016).




Figura 7 – Um exemplo de convolução 2D, as setas ilustram como o elemento superior esquerdo da saída é formado pela aplicação do *kernel* na região correspondente no canto superior esquerdo da entrada. Nesse caso, não há preenchimento de bordas (*padding*), o que significa que a saída tem um tamanho menor que a entrada, pois a operação de convolução é realizada apenas nas regiões onde o *kernel* cabe inteiramente dentro da imagem, também conhecido como convolução “válida” em alguns contextos (reprodução de (GOODFELLOW; BENGIO; COURVILLE, 2016). pág.350)

No contexto do aprendizado de máquina, o algoritmo de aprendizado irá aprender os valores apropriados para o *kernel* nas posições corretas durante o processo de treinamento (GOODFELLOW; BENGIO; COURVILLE, 2016).

- Funções de ativação

Um neurônio pode estar ativado ou desativado em uma rede neural. A ativação acontece quando o produto escalar entre os pesos e as entradas são maiores que um valor pré determinado. Atualmente a função de ativação mais popular em redes convolucionais é a função de ativação de unidade linear retificada (ReLU).

A ReLU é definida pela função de ativação $g(z) = \max\{0, z\}$ ilustrada na Figura 8 (GOODFELLOW; BENGIO; COURVILLE, 2016).




Figura 8 – A função de ativação de unidade linear retificada, conhecida como ReLU (*Rectified Linear Unit*), é a função de ativação padrão recomendada para a maioria das redes neurais *feedforward* (GOODFELLOW; BENGIO; COURVILLE, 2016). pág.191

O que significa que ela zera os valores negativos e mantém os valores positivos inalterados. Uma das principais vantagens da ReLU sobre outras funções de ativação, como a sigmoide ou a tangente hiperbólica, é que ela ajuda a mitigar o problema do desaparecimento do gradiente, permitindo que redes neurais profundas sejam treinadas de maneira mais eficiente (GOODFELLOW; BENGIO; COURVILLE, 2016).

- *Pooling*

Uma função de *pooling* calcula um resumo estatístico de uma camada de característica. Por exemplo, a operação de *max pooling* reporta o valor máximo dentro de uma vizinhança retangular. O *pooling* desempenha um papel importante na redução da dimensionalidade dos dados, ajudando a resumir as informações importantes, ao mesmo tempo que torna o modelo mais robusto a variações menores na posição dos padrões visuais (GOODFELLOW; BENGIO; COURVILLE, 2016).

As camadas de classificação (*classification layers*) são responsáveis por calcular as pontuações de classe, que serão utilizadas como saída da rede (PATTERSON; GIBSON, 2017). Um exemplo de camada de classificação é a camada totalmente conectada, em que todos os seus perceptrons estão conectados a todos os perceptrons da camada anterior, dessa maneira cada peso decide a importância daquela característica na decisão da classe sendo representada (GOODFELLOW; BENGIO; COURVILLE, 2016).

O processo mencionado de ajuste de pesos para produzir previsões cada vez mais precisas sobre os dados é conhecido como *finetuning*. Cada conjunto de pesos representa uma hipótese específica sobre o significado das entradas; isto é, como elas se relacionam com os significados contidos nos rótulos. Os pesos representam conjecturas sobre as correlações entre as entradas da rede e os rótulos-alvo que ela busca prever (PATTERSON; GIBSON, 2017).

Entre os métodos de otimização, os dois mais populares são:

- Descida de gradiente estocástico em lotes (SGD)

No método de descida do gradiente em lote calcula-se o erro total em todos os exemplos de treinamento antes de calcular o gradiente e atualizar o vetor de parâmetros. No SGD, a atualização do vetor de parâmetros são calculados após cada amostra de treinamento. O SGD em lotes é uma aproximação da descida de gradiente, pois utiliza uma única amostra de cada vez para atualizar os parâmetros (PATTERSON; GIBSON, 2017).

- *Momentum adaptativo com decaimento de peso desacoplado* (AdamW)

No algoritmo de otimização Adam os gradientes são modificados de acordo com suas magnitudes históricas. Intuitivamente, quando o Adam é aplicado a uma função de perda com regularização L2, os pesos que tendem a ter gradientes grandes não são regularizados tanto quanto seriam com a redução de peso desacoplado (*decoupled weight decay*), uma vez que o gradiente do regularizador é escalado junto com o gradiente da função de perda. Ao separar o decaimento de peso e as atualizações baseadas no gradiente da perda no Adam tem-se a variante do Adam com *decoupled weight decay*, conhecida como AdamW(LOSHCHILOV; HUTTER, 2019).

2.1.2.2 Vision Transformers

As arquiteturas baseadas em *self-attention*, especialmente os *Transformers*, tornaram-se o modelo principal no processamento de linguagem natural (NLP). A abordagem dominante envolve pré-treinar o modelo em um grande corpus de texto e, em seguida, realizar um ajuste fino (*fine-tuning*) em um conjunto de dados menor e específico para uma tarefa (DOSOVITSKIY et al., 2021).

Para possibilitar a aplicação de *Transformers* em imagens é necessário dividir a imagem em blocos e formencar a sequência de *embeddings* lineares desses blocos como entrada para o *Transformer*. Os blocos de imagens são tratados como tokens de uma aplicação NLP. Em seguida, treina-se o modelo para a tarefa de classificação de imagens de forma supervisionada, permitindo que o *Transformer* aprenda as características visuais presentes nas imagens a partir dos blocos, similar ao aprendizado de sequências de palavras em textos (DOSOVITSKIY et al., 2021).




Figura 9 – Visão geral do modelo: a imagem é dividida em blocos de tamanho fixo, faz-se a incorporação linear (*linear embedding*) de cada bloco, adiciona-se *embeddings* de posição e a sequência resultante de vetores é alimentada para um codificador padrão de *Transformer*. Para realizar a classificação, utiliza-se a abordagem padrão de adicionar um “*token*” aprendível extra à sequência (DOSOVITSKIY et al., 2021). pág.3

O *Transformer* padrão recebe como entrada uma sequência unidimensional de *embeddings* de tokens. Para lidar com imagens bidimensionais, reformatamos a imagem em uma sequência de blocos 2D achatados. O *Transformer* mantém um tamanho constante do vetor latente em todas as suas camadas, portanto, achatamos os blocos e os mapeamos para as dimensões do *Transformer* utilizando uma projeção linear treinável. O resultado dessa projeção é chamado de *embeddings* de blocos (DOSOVITSKIY et al., 2021).

Adicionamos um *embeddings* aprendível no início da sequência de blocos incorporados, cujo estado na saída do codificador do *Transformer* serve como a representação da classe. Tanto durante o pré-treinamento quanto no ajuste fino, uma cabeça de classificação é anexada. A cabeça de classificação é implementada por uma MLP com uma camada oculta durante o pré-treinamento e por uma única camada linear durante o ajuste fino que recebe o *token* de classificação (DOSOVITSKIY et al., 2021).

Os *embeddings* de posição são somados aos *embeddings* de blocos para preservar a informação posicional. A sequência resultante de vetores de *embeddings* serve como entrada para o codificador do *Transformer* (DOSOVITSKIY et al., 2021).

O codificador do *Transformer* é composto por camadas alternadas de *self-attention multiheaded* e blocos MLP. Normalização de camada é aplicada antes de cada bloco, e conexões residuais são adicionadas após cada bloco, garantindo a estabilidade e eficiência do treinamento (DOSOVITSKIY et al., 2021).

2.1.2.3 Arquiteturas Leves do Estado da Arte

Como o objetivo da pesquisa é desenvolver uma aplicação que funcione em dispositivos móveis, foram realizados testes com arquiteturas projetadas especificamente para esse tipo de plataforma. Entre elas, a MobileNetV2 apresentou o melhor desempenho em testes que serão citados posteriormente, esta arquitetura foi atualizada para a MobileNetV3, que também será considerada neste estudo. Além disso, a MobileViT, uma arquitetura mais recente, será incluída na pesquisa por ainda não ter sido aplicada nesse contexto específico. A seguir, são detalhadas as características de cada uma dessas arquiteturas.

- MobileNetV2

A MobileNetV2 é uma arquitetura de modelos de rede neural convolucional para dispositivos móveis. A MobileNetV2 usa convolução *depthwise*, que realiza um filtragem leve ao aplicar um único filtro convolucional por canal de entrada e a convolução *1x1 pointwise*, que é responsável por construir novas características ao calcular combinações lineares dos canais de entrada (SANDLER et al., 2019).

Essas camadas são usadas nos blocos residuais de *bottleneck* como pode ser visto na Figura 10 (SANDLER et al., 2019).

Input	Operator	Output
$h \times w \times k$	1x1 conv2d, ReLU6	$h \times w \times (tk)$
$h \times w \times tk$	3x3 dwse s=s, ReLU6	$\frac{h}{s} \times \frac{w}{s} \times (tk)$
$\frac{h}{s} \times \frac{w}{s} \times tk$	linear 1x1 conv2d	$\frac{h}{s} \times \frac{w}{s} \times k'$

Figura 10 – Bloco residual de *bottleneck* transforma de k canais para k' canais, com *stride* s, e fator de expansão t (SANDLER et al., 2019). pág.4

A arquitetura da MobileNetV2 contém a camada de convolução completa com 32 filtros, seguida de 19 blocos residuais de *bottleneck*, uma camada de *pooling* global e uma camada totalmente conectada, como pode ser visto na Figura 11 (SANDLER et al., 2019).

Input	Operator	t	c	n	s
$224^2 \times 3$	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 1x1	-	1280	1	1
$7^2 \times 1280$	avgpool 7x7	-	-	1	-
$1 \times 1 \times 1280$	conv2d 1x1	-	k	-	-

Figura 11 – MobileNetV2: Cada linha descreve uma sequência de uma ou mais camadas idênticas (com exceção do *stride*), repetidas n vezes. Todas as camadas dentro da mesma sequência têm o mesmo número de canais de saída. A primeira camada de cada sequência utiliza um *stride* s , enquanto todas as outras camadas da sequência usam um *stride* de 1. Todas as convoluções espaciais utilizam *kernels* de tamanho 3x3. O fator de expansão é sempre aplicado ao tamanho da entrada, conforme descrito na Tabela 1 do artigo de MobileNetV2 (SANDLER et al., 2019). pág.5

Algumas das aplicações da MobileNetV2 incluem: Detecção em tempo real de doenças em tomates (QIU et al., 2024), Capacitando o diagnóstico de tumores no cérebro com aprendizado profundo explicável (LI; DIB, 2024) e Reconhecimento automatizado de ruas cobertas de neve e congeladas (LIU et al., 2024).

- MobileNetV3

Essa geração de MobileNet utiliza uma combinação de técnicas de busca complementares e uma nova arquitetura que podem trazer melhoras de taxa de acerto, latência e velocidade dependendo da aplicação (HOWARD et al., 2019).

Para alcançar essa arquitetura, utilizou-se o *Platform-Aware NAS* (*Neural Architecture Search*) para explorar os blocos comuns da rede. Em seguida, é aplicado o algoritmo *NetAdapt* para definir, camada por camada, o número ideal de filtros. Essas técnicas são complementares e, quando combinadas, permitem encontrar modelos otimizados de forma eficaz para uma determinada plataforma de hardware (HOWARD et al., 2019).

Para o *Platform-Aware NAS* usa-se uma abordagem de arquitetura neural *platform-aware* para identificar as estruturas globais da rede. Como traz resultados satisfatórios o modelo MnasNet-A1 é utilizado como modelo inicial para dispositivos móveis, aplicando em seguida o *NetAdapt* e outras otimizações para aprimorá-lo (HOWARD et al., 2019).

A segunda técnica que empregada na busca por arquitetura é o *NetAdapt*. Essa abordagem complementa a *platform-aware* NAS ao permitir o ajuste fino de camadas individuais de forma sequencial, em vez de tentar inferir uma arquitetura global mais ampla. Em resumo, a técnica funciona da seguinte maneira (HOWARD et al., 2019):

1. Inicia com uma arquitetura de rede inicial encontrada pela *platform-aware* NAS.
2. Para cada iteração:
 - a Gera um conjunto de novas propostas. Cada proposta representa uma modificação na arquitetura que gera, no mínimo, uma redução de na latência em comparação com a etapa anterior.
 - b Para cada proposta, utiliza-se o modelo pré-treinado da etapa anterior para popular a nova arquitetura proposta, truncando e inicializando aleatoriamente os pesos ausentes, conforme necessário. Em seguida, cada proposta é ajustada por T etapas para obter uma estimativa aproximada da *precision*.
 - c Seleciona-se a melhor proposta de acordo com alguma métrica de desempenho (minimizar mudança na taxa de acerto ou a razão entre mudança na latência e na taxa de acerto).
3. Repete-se o passo anterior até que a latência alvo seja atingida.

Algumas camadas com custo alto foram reprojatadas com a intenção de diminuir a latência. Primeiramente a última camada foi movida para depois da camada de *pooling* e diminuiu-se sua resolução espacial de 7x7 para 1x1, diminuindo sua latência enquanto mantêm as características de alta dimensão (HOWARD et al., 2019).

Outras camadas custosas na MobileNetV2 eram as camadas iniciais de filtragem. Na nova arquitetura foi diminuído o número dessas camadas e trocado a função de ativação para manter a taxa de acerto novamente diminuindo a latência (HOWARD et al., 2019).

A nova função de ativação citada é a *h-swish*, definida pela função 2.1 (HOWARD et al., 2019):

$$\text{h-swish}[x] = x \frac{\text{ReLU6}(x + 3)}{6} \quad (2.1)$$

A última grande mudança feita foi a adição de módulos *Squeeze-and-Excite* (SE) em algumas camadas. Essa é uma técnica utilizada para melhorar a qualidade das representações geradas pelas redes neurais, ajustando dinamicamente a importância de cada canal da saída das convoluções (IANDOLA et al., 2016).

Input	Operator	exp size	#out	SE	NL	s
$224^2 \times 3$	conv2d	-	16	-	HS	2
$112^2 \times 16$	bneck, 3x3	16	16	-	RE	1
$112^2 \times 16$	bneck, 3x3	64	24	-	RE	2
$56^2 \times 24$	bneck, 3x3	72	24	-	RE	1
$56^2 \times 24$	bneck, 5x5	72	40	✓	RE	2
$28^2 \times 40$	bneck, 5x5	120	40	✓	RE	1
$28^2 \times 40$	bneck, 5x5	120	40	✓	RE	1
$28^2 \times 40$	bneck, 3x3	240	80	-	HS	2
$14^2 \times 80$	bneck, 3x3	200	80	-	HS	1
$14^2 \times 80$	bneck, 3x3	184	80	-	HS	1
$14^2 \times 80$	bneck, 3x3	184	80	-	HS	1
$14^2 \times 80$	bneck, 3x3	480	112	✓	HS	1
$14^2 \times 112$	bneck, 3x3	672	112	✓	HS	1
$14^2 \times 112$	bneck, 5x5	672	160	✓	HS	2
$7^2 \times 160$	bneck, 5x5	960	160	✓	HS	1
$7^2 \times 160$	bneck, 5x5	960	160	✓	HS	1
$7^2 \times 160$	conv2d, 1x1	-	960	-	HS	1
$7^2 \times 960$	pool, 7x7	-	-	-	-	1
$1^2 \times 960$	conv2d 1x1, NBN	-	1280	-	HS	1
$1^2 \times 1280$	conv2d 1x1, NBN	-	k	-	-	1

Input	Operator	exp size	#out	SE	NL	s
$224^2 \times 3$	conv2d, 3x3	-	16	-	HS	2
$112^2 \times 16$	bneck, 3x3	16	16	✓	RE	2
$56^2 \times 16$	bneck, 3x3	72	24	-	RE	2
$28^2 \times 24$	bneck, 3x3	88	24	-	RE	1
$28^2 \times 24$	bneck, 5x5	96	40	✓	HS	2
$14^2 \times 40$	bneck, 5x5	240	40	✓	HS	1
$14^2 \times 40$	bneck, 5x5	240	40	✓	HS	1
$14^2 \times 40$	bneck, 5x5	120	48	✓	HS	1
$14^2 \times 48$	bneck, 5x5	144	48	✓	HS	1
$14^2 \times 48$	bneck, 5x5	288	96	✓	HS	2
$7^2 \times 96$	bneck, 5x5	576	96	✓	HS	1
$7^2 \times 96$	bneck, 5x5	576	96	✓	HS	1
$7^2 \times 96$	conv2d, 1x1	-	576	✓	HS	1
$7^2 \times 576$	pool, 7x7	-	-	-	-	1
$1^2 \times 576$	conv2d 1x1, NBN	-	1024	-	HS	1
$1^2 \times 1024$	conv2d 1x1, NBN	-	k	-	-	1

(a) Especificações de arquitetura da MobileNetV3-Large (HOWARD et al., 2019). (b) Especificações de arquitetura da MobileNetV3-Small (HOWARD et al., 2019).

Figura 12 – Especificações de ambas as arquiteturas da MobileNetV3. SE indica se há um módulo *Squeeze-and-Excite* no bloco correspondente. NL refere-se ao tipo de função de ativação utilizada. HS denota a função de ativação *h-swish*, enquanto RE denota a ReLU (*Rectified Linear Unit*). NBN indica que não há *batch normalization* aplicada nesse bloco, e s denota o *stride* utilizado para aquela camada (HOWARD et al., 2019). pág.5

Na Figura 12 temos as arquiteturas para os dois modelos da MobileNetV3: Grande e Pequeno. Apesar de terem escalas diferentes ambos aplicam todas as mudanças da versão (HOWARD et al., 2019).

Desde sua publicação a MobileNetV3 tem sido utilizada em várias aplicações relevantes, tais como: Técnicas de *deep learning* para classificar culturas agrícolas por meio de imagens de UAV (BOUGUETTAYA et al., 2022), Aprendizado de máquina para hardware de classe microcontrolador: Uma revisão (SAHA; SANDHA; SRIVASTAVA, 2022), Uma revisão sobre *deep learning* em sensoriamento remoto por UAV (OSCO et al., 2021).

- MobileViT

A MobileViT é uma arquitetura leve, com baixa latência e de propósito geral para dispositivos móveis baseada em *Vision Transformers*. Quando se tratam de arquiteturas baseadas em ViT a tendência geral é aumentar o número de parâmetros nas redes para melhorar o desempenho. No entanto, essas melhorias de desempenho têm o custo de aumentar o tamanho do modelo (parâmetros da rede) e a latência (MEHTA; RASTEGARI, 2021).

Para circundar essa falha crônica a MobileViT combina os benefícios das CNNs (como vieses indutivos espaciais e menor sensibilidade a aumentos de dados) e dos ViTs (como ponderação adaptativa à entrada e processamento global). Especificamente, introduz-se o bloco MobileViT, que codifica de maneira eficiente tanto in-

formações locais quanto globais em um tensor Figura 13 (MEHTA; RASTEGARI, 2021).




Figura 13 – MobileViT: Conv-nxn no bloco MobileViT representa uma convolução padrão de nxn, enquanto MV2 refere-se ao bloco MobileNetV2. Os blocos que realizam *down-sampling* (redução da resolução espacial) são indicados com $\downarrow 2$, sinalizando uma diminuição no tamanho da entrada por um fator de 2 (MEHTA; RASTEGARI, 2021). pág.2

Diferentemente do ViT e de suas variantes (com ou sem convoluções), o MobileViT apresenta uma perspectiva distinta para aprender representações globais. A convolução tradicional envolve três operações: *unfolding* (desdobramento), *local processing* (processamento local) e *folding* (reagrupamento). No bloco MobileViT, o processamento local das convoluções é substituído por processamento global utilizando *transformers*. Essa abordagem permite que o bloco MobileViT combine propriedades tanto de CNNs quanto de ViTs, facilitando o aprendizado de representações mais eficazes, com menos parâmetros e utilizando receitas de treinamento mais simples (MEHTA; RASTEGARI, 2021).

O bloco MobileViT tem como objetivo modelar tanto a informação local quanto global em um tensor de entrada utilizando menos parâmetros. Formalmente, para um tensor de entrada, o MobileViT aplica uma convolução padrão nxn, seguida por uma convolução *pointwise* (ou 1x1). A camada convolucional nxn codifica informações espaciais locais, enquanto a convolução *pointwise* projeta o tensor para um espaço de alta dimensão, aprendendo combinações lineares dos canais de entrada (MEHTA; RASTEGARI, 2021).

O objetivo do MobileViT é modelar dependências não-locais de longo alcance, mantendo um campo receptivo efetivo de $H \times W \times W$. Um dos métodos mais estudados para capturar essas dependências são as convoluções dilatadas. No entanto, essa abordagem exige uma seleção cuidadosa das taxas de dilatação; caso contrário, os pesos podem ser aplicados em zeros preenchidos em vez de na região espacial válida. Outra solução promissora é o *self-attention*. Embora os *transformers* de visão (ViTs) baseados em *multi-head self-attention* sejam eficazes para tarefas de reconhecimento visual, eles são pesados e apresentam dificuldades de otimização devido à falta de viés indutivo espacial (MEHTA; RASTEGARI, 2021).

Para que o MobileViT aprenda representações globais com viés indutivo espacial, após a camada de convolução *pointwise* é desdobrado em blocos achatados não sobrepostos. Para cada bloco, as relações entre blocos são modeladas aplicando-se *transformers* (MEHTA; RASTEGARI, 2021).

Diferentemente dos ViTs, que perdem a ordem espacial dos *pixels*, o MobileViT mantém tanto a ordem dos blocos quanto a ordem espacial dos *pixels* dentro de cada bloco. Assim, podemos projetar para um espaço de baixa dimensão C utilizando uma convolução *pointwise* e combinado com a entrada por meio de concatenação. Uma outra camada convolucional $n \times n$ é utilizada para fundir as características concatenadas (MEHTA; RASTEGARI, 2021).





Figura 14 – No bloco MobileViT, cada pixel é capaz de enxergar todos os outros *pixels*. Nesse exemplo, o pixel vermelho atende aos *pixels* azuis (ou seja, *pixels* na mesma posição em outros blocos) por meio de *transformers*. Como os *pixels* azuis já codificaram informações sobre seus vizinhos usando convoluções, isso permite que o pixel vermelho codifique informações de todos os *pixels* na imagem. Cada célula nas grades pretas representa um bloco, enquanto cada célula nas grades cinzas representa um pixel individual. Essa abordagem combina convoluções para capturar informações locais e *transformers* para modelar dependências globais, garantindo que cada pixel carregue informações contextuais de toda a imagem (MEHTA; RASTEGARI, 2021). pág.5

Como informações locais e globais são codificadas, cada pixel pode representar informações de todos os *pixels* da entrada, conforme mostrado na Figura 14 (MEHTA; RASTEGARI, 2021).

Desde que foi publicada, a MobileViT tem sido empregada em várias aplicações significativas, tais como: Combinando estruturas convolucionais e *transformers* de visão para o reconhecimento facial de ovelhas (LI; XIANG; LI, 2023), detecção de defeitos em pavimentos utilizando *deep learning* (FAN et al., 2023), uma perspectiva sobre o reconhecimento de atividades humanas a partir de dados de movimento inercial (GOMAA; KHAMIS, 2023).

Para termos de comparação foram feitos testes com várias arquiteturas para dispositivos móveis no conjunto de dados de validação ImageNet 1k, os resultados podem ser vistos na Figura 15 (MEHTA; RASTEGARI, 2021).



(a) Comparison with light-weight CNNs

Model	# Params. ↓	Top-1 ↑
MobileNetv1	2.6 M	68.4
MobileNetv2	2.6 M	69.8
MobileNetv3	2.5 M	67.4
ShuffleNetv2	2.3 M	69.4
ESPNetv2	2.3 M	69.2
MobileViT-XS (Ours)	2.3 M	74.8

(b) Comparison with light-weight CNNs (similar parameters)

Model	# Params. ↓	Top-1 ↑
DenseNet-169	14 M	76.2
EfficientNet-B0	5.3 M	76.3
ResNet-101	44.5 M	77.4
ResNet-101-SE	49.3 M	77.6
MobileViT-S (Ours)	5.6 M	78.4

(c) Comparison with heavy-weight CNNs

Figura 15 – A comparação entre MobileViT e CNNs no conjunto de validação do ImageNet-1k. Todos os modelos utilizando apenas aumentos básicos de dados (MEHTA; RASTEGARI, 2021). pág.7

2.1.3 Medidas de Desempenho

Determinar os objetivos, em termos de qual métrica de erro utilizar, é um passo fundamental, pois a métrica de erro escolhida irá orientar todas as suas ações futuras. A métrica de erro define como o desempenho do modelo será avaliado, e diferentes tarefas podem exigir métricas diferentes, como taxa de acerto, *precision*, *recall* ou *F1-score* (GO-ODFELLOW; BENGIO; COURVILLE, 2016).

Para definir as métricas de desempenho usaremos quantidade de verdadeiros positivos (VP), quantidade de verdadeiros negativos (VN), quantidade de falsos positivos (FP) e quantidade de falsos negativos (FN).

- Matriz de Confusão

A matriz de confusão (Tabela 2) é uma tabela com linhas e colunas que representa as previsões e os resultados reais de um classificador.

	Positivo (Predito)	Negativo (Predito)
Positivo (Real)	Verdadeiro Positivo	Falso Negativo
Negativo (Real)	Falso Positivo	Verdadeiro Negativo

Tabela 2 – Matriz de confusão

- Taxa de acerto

Razão entre o total de predições corretas e todos casos.

$$Taxadeacerto = \frac{VP + VN}{VP + VN + FP + FN} \quad (2.2)$$

- *precision*

Fração de detecções corretas reportadas.

$$precision = \frac{VP}{VP + FP} \quad (2.3)$$

- *Recall*

Fração de eventos verdadeiros detectados.

$$recall = \frac{VP}{VP + FN} \quad (2.4)$$

- *F1-score*

Média harmônica entre *precision* e *recall*.

$$F1\text{-score} = \frac{2 \cdot precision \cdot recall}{precision + recall} \quad (2.5)$$

2.2 Estado da Arte

Um potencial na utilização de redes neurais para a classificação de imagens de forrageiras foi encontrado na dissertação de mestrado intitulada “Exploração de arquiteturas de redes neurais para identificação de forrageiras do gênero *Brachiaria* e *Panicum maximum*” (FAZAN, 2020). Este trabalho apresentou resultados importantes que serão discutidos nesse capítulo e comparados ao longo do trabalho.

Um resultado de extrema relevância obtido em (FAZAN, 2020) foi o banco de imagens com mais de 27 mil imagens capturadas em quatro áreas da Embrapa Gado de Corte, em Campo Grande, MS, nos períodos de seca e chuva, entre junho de 2019 e fevereiro de 2020. Todas as imagens capturadas foram selecionadas, separadas por cultivar, espécie, gênero e, algumas delas, época do ano. O processo para construção desse banco pode ser observado na Figura 16.




Figura 16 – Procedimento para a construção do banco de imagens (FAZAN, 2020)

O banco de imagens possibilita a construção de um *dataset* detalhado e suficiente para os testes com as redes neurais. Porém, a maioria das imagens foram coletadas em áreas de pesquisa, essa é uma situação consideravelmente diferente de uma área sob pastagem animal, pois na última o bovino está constantemente pisoteando e comendo as plantas, o que altera sua morfologia. Além disso, três das quatro áreas possuíam forrageiras no estágio adulto, em somente uma foi possível coletar imagens das plantas em desenvolvimento. Por isso novas imagens das mesmas forrageiras em diferentes idades, época do ano e situações de pastejo deverão ser capturadas para complementar o banco de imagens existente.

Os testes de identificação de forrageiras foram executados utilizando quatro arquiteturas de redes neurais, a MobileNet V2 e a Resnet50, que são arquiteturas do estado da arte, e duas arquiteturas que foram implementadas pelo autor seguindo padrões da literatura. Foram realizados testes de classificação de toda a hierarquia taxonômica, ou seja, de gênero, espécie e cultivar, em todas elas a MobileNetV2 atingiu a melhor taxa de acerto dentre as arquiteturas escolhidas.

A MobileNet V2 ter atingido os melhores resultados é um fator importante pois essa é uma arquitetura leve e compacta, possui apenas 16 camadas em comparação à ResNet utilizada que possui 50. Por isso, é um modelo bastante adequado para o objetivo final da pesquisa, que seria implementá-lo em um aplicativo para dispositivos móveis, que

possuem recursos limitados.




Figura 17 – Gráficos das taxas de acerto médias obtidas pelos modelos na classificação de gênero, espécie e cultivar no período da seca (FAZAN, 2020)

A Figura 17 apresenta os resultados utilizando imagens de todas regiões somente no período da seca, cujo período de coleta foi entre junho e novembro de 2019. A MobileNet V2 teve uma taxa de acerto média excelente de 92% na classificação entre o gênero *Brachiaria* e a espécie *Panicum maximum*, e geral entre espécies de 71%. Porém quando se tratou da classificação de cultivares seu resultado foi de apenas 59% que deve ser melhorado para a implementação em um produto acessível e confiável ao produtor.

No período de chuva, cujas imagens foram coletadas entre dezembro de 2019 e fevereiro de 2020, utilizando-se imagens de todas as regiões para o treinamento do modelo, observou-se taxas de acerto como apresentadas nas Figura 18 (A), por gênero, Figura 18 (B), por espécie, e Figura 18 (C), por cultivar. Nesse caso, a MobileNet V2 apresentou uma taxa de acerto média de 87% na classificação de gêneros, 75% na classificação de espécies e 50% na classificação de cultivares.




Figura 18 – Taxa de acerto dos modelos na região geral no período de chuva para classificação por gênero (A), por espécie (B) e por cultivar (C) (FAZAN, 2020)

Analizados e comparados os resultados em ambos períodos é possível notar similaridades. Há uma diferença de apenas 3% na classificação de gêneros, de 4% na classificação de espécies, mas na classificação de cultivares é de 9%. Essas taxas de acerto tão próximas apontam para uma irrelevância no melhoramento da taxa de acerto se realizados treinamentos com ou sem separação por períodos do ano.

Um experimento foi realizado pelo autor, onde realizou-se o treinamento de um modelo MobileNet V2 com imagens de ambos períodos. Assim foi possível aferir que a taxa de acerto média da classificação de cultivares, nesse caso, foi de 53% um resultado que pouco foi afetado pela mistura de imagens de diferentes períodos (FAZAN, 2020).

Além dos treinamentos dos modelos separando as imagens em um *dataset* para o período de seca e outro para o período de chuva, houveram experimentos em que também se separou *datasets* por área e período. Um breve resumo dos resultados obtidos pelo modelo mobilenet V2 nesses experimentos pode ser analisado na Tabela 3.

Área	Período	Classes	Taxa de acerto
Dinapec	Seca	6	75%
Dinapec	Chuva	6	91%
Área 56	Seca	14	52%
Área 56	Chuva	14	63%
Área 43	Seca	8	56%
Geral	Seca	14	59%
Geral	Chuva	13	50%
Geral	Geral	11	53%

Tabela 3 – Compilado dos resultados dos experimentos realizados no trabalho (FAZAN, 2020)

Apesar da conclusão do autor apontar para a irrelevância do período do ano para melhoria na taxa de acerto dos modelos treinados, é necessário olhar para as peculiaridades e intersecções de cada *dataset*. Por exemplo, o *dataset* com imagens da região Dinapec possui apenas 6 classes de cultivares em estágio adulto podendo ser dividido em cultivares em estágio adulto na seca e cultivares em estágio adulto na chuva. O *dataset* da Área 56 possui imagens das plantas em fase de crescimento no período da seca até o estágio adulto já no período de chuvas. Portanto, os *datasets* da Dinapec no período da chuva e da Área 56 no período da chuva possuem exemplos similares para 6 classes de cultivares e ambos modelos treinados nesses *dataset* tiveram melhoria na taxa de acerto em relação ao período de seca.

Tabela 4 – Área 56 período de seca - métricas por período de 3 meses

Cultivar	precision	recall	f1-score	Support
Ipyporã de 06/19 até 08/19	0.82	0.77	0.79	104
Ipyporã de 09/19 até 11/19	0.73	0.56	0.63	105
Lhanero 06/19 até 08/19	0.61	0.55	0.58	75
Lhanero de 09/19 até 11/19	0.85	0.84	0.85	133
Marandu de 06/19 até 08/19	0.62	0.33	0.43	72
Marandu 09/19 até 11/19	0.42	0.60	0.50	138
Massai de 06/19 até 08/19	0.51	0.77	0.61	104
Massai de 09/19 até 11/19	0.75	0.60	0.67	105
Mombaça de 06/19 até 08/19	0.35	0.31	0.33	110
Mombaça de 09/19 até 11/19	0.60	0.51	0.55	99
Paiguás de 06/19 até 08/19	0.20	0.08	0.11	65
Paiguás de 09/19 até 11/19	0.57	0.60	0.58	144
Piatã de 06/19 até 08/19	0.28	0.58	0.38	118
Piatã 09/19 até 11/19	0.25	0.12	0.16	91
Quênia de 09/19 até 11/19	0.79	0.48	0.59	138
Quênia de 06/19 até 08/19	0.25	0.41	0.31	70
Ruziziensis de 06/19 até 08/19	0.31	0.26	0.28	86
Ruziziensis de 09 até 11/19	0.73	0.50	0.60	123
Tamani de 06/19 até 08/19	0.65	0.93	0.77	137
Tamani 09/19 até 11/19	0.45	0.90	0.60	72
Tupi de 06/19 até 08/19	0.57	0.23	0.33	108
Tupi de 09/19 até 11/19	0.82	0.94	0.87	103
Xaraés de 06/19 até 08/19	0.28	0.27	0.27	123
Xaraés de 09/19 até 11/19	0.51	0.45	0.48	85
Zuri de 06/19 até 08/19	0.22	0.08	0.12	77
Zuri de 09/19 até 11/19	0.63	0.62	0.63	132

Fonte: (FAZAN, 2020)




Figura 19 – Gráfico comparativo de *F1-Scores* na classificação de cultivares da Área 56 na seca em dois períodos, onde a linha azul representa o modelo treinado com imagens entre setembro e novembro de 2019 e a vermelha, o modelo MobileNetV2 treinado com imagens entre junho e agosto de 2019

Vale observar também que no caso do modelo MobileNetV2 treinado na Área 56 na seca, além de possuir 8 classes a mais que o *dataset* da área Dinapec, os exemplos das cultivares nessa área estavam em desenvolvimento e portanto visualmente diferentes das cultivares em estágio adulto da Dinapec. O que também dificulta a comparação entre os resultados. Porém o autor realizou um treinamento separando o *dataset* da Área 56 em dois períodos de 3 meses, o resultado desse experimento, presente na Tabela 4, pode também ser mais facilmente analisado através da comparação de *F1-scores* na Figura 19.

Através da Figura 19 observa-se que o segundo período conquistou melhoria na taxa de acerto para a maioria das classes com exceção da Ipyporã, Piatã e Tamani. Isso aponta que a idade da forrageira pode afetar a complexidade de sua identificação, visto que em ambos intervalos as cultivares estão em período de seca, diferenciando-se apenas pela idade, revelando a importância de se explorar características representativas durante os estágios de crescimento das cultivares para melhorar as taxas de acertos de modelos de rede neural.

3 Metodologia

O presente capítulo descreve a metodologia adotada para o desenvolvimento deste trabalho, abordando desde a coleta de imagens das cultivares até a construção dos *datasets* e os experimentos de treinamento de redes neurais. Inicialmente, apresenta-se o processo de plantio das 18 cultivares de forrageiras na Embrapa Gado de Corte, bem como o acompanhamento fotográfico realizado ao longo de oito meses para documentar o crescimento das plantas. A seguir, detalham-se as técnicas utilizadas para a análise dos dados coletados, como o desenvolvimento de uma aplicação web construída especificamente para facilitar a visualização comparativa das imagens.

Posteriormente, são explicados os critérios e procedimentos adotados para a construção dos diferentes datasets, segmentados por cultivar, datas de coleta, períodos específicos e fase de inflorescência. A seção também descreve as etapas de treinamento dos modelos de redes neurais, como MobileNet V3 e MobileViT, incluindo as técnicas de pré-processamento de imagens, as estratégias de divisão dos conjuntos de dados, e os parâmetros de treinamento utilizados.

3.1 Coleta de Imagens

Foram plantadas forrageiras em uma área localizada na sede da Embrapa Gado de Corte. Nesta área foram plantados quatro exemplares de cada uma das 18 cultivares diferentes em parcelas de 4x4 metros com 9 linhas plantadas espaçadas de 50 cm e um corredor de 3 m separando-as. Com exceção da cultivar Mavuno, plantada por mudas, todas foram plantadas por semente. A Figura 20 apresenta visualmente a disposição das parcelas e das cultivares plantadas na área citada.




Figura 20 – Disposição das parcelas de cultivares plantadas na área da Embrapa Gado de Corte

Em 25 de fevereiro de 2022, as sementes germinaram e as primeiras plântulas emergiram do solo. Logo iniciou-se o trabalho de coleta de imagens, acompanhando todo o desenvolvimento de cada uma das plantas, da emergência de plântulas ao estágio adulto, nos períodos de chuva e seca, até o final de outubro de 2022. As cultivares tiveram o desenvolvimento mais lento que o comum devido ao atraso no plantio ocasionado pela pandemia de covid-19. Algumas tiveram que ser replantadas devido a má formação no nascimento, porém o replantio foi ágil e notou-se pouca diferença morfológica no desenvolvimento dessas plantas.

Para a captura das imagens foram utilizados diferentes dispositivos móveis com variadas resoluções e tecnologias de câmera, smartphones próprios e disponíveis na Embrapa.

As imagens coletadas nesse período de oito meses viabilizaram a construção de *datasets* para o treinamento de redes neurais. O banco de imagens construído possui, aproximadamente, 7300 imagens com informações do Gênero, espécie e cultivar da planta apresentada, além da data da coleta, informação que possibilita o cálculo da idade da forrageira e pluviosidade do período. No total foram coletadas imagens em 18 datas, de 18 cultivares, sendo elas:

1. *Brachiaria* spp. cv. BRS Ipyporã
2. *Brachiaria brizantha* cv. BRS Paiaguás

3. *Brachiaria brizantha* cv. BRS Piatã
4. *Panicum maximum* cv. BRS Quênia
5. *Panicum maximum* cv. BRS Tamani
6. *Brachiaria humidicola* cv. BRS Tupi
7. *Panicum maximum* cv. BRS Zuri
8. *Brachiaria decumbens* cv. Basilisk
9. *Brachiaria humidicola* cv. comum
10. *Brachiaria humidicola* cv. Llanero
11. *Brachiaria brizantha* cv. Marandu
12. *Panicum maximum* cv. Massai
13. *Brachiaria* spp. cv. Mavuno
14. *Panicum maximum* cv. Mombaça
15. *Brachiaria* spp. cv. Mulato II
16. *Brachiaria ruziziensis* cv. Ruziziensis
17. *Panicum maximum* cv. Tanzânia
18. *Brachiaria brizantha* cv. Xaraés

3.2 Análise dos Dados

A grande quantidade de variações dos exemplos coletados dificultou a visualização e comparação entre as forrageiras. Havia-se, por exemplo, a necessidade de comparar visualmente o desenvolvimento das plantas ao longo do tempo para constatar se:

- Cultivares da mesma espécie, apesar de muito semelhantes no estágio adulto, possuem uma idade em comum em que apresentam diferenças morfológicas suficientes para a sua diferenciação?
- No estágio adulto, a inflorescência pode aparecer em diferentes períodos e apresentar características morfológicas importantes para identificação da cultivar?

Para superar esse desafio, foi desenvolvida uma aplicação web capaz de realizar filtragens e tabelar as imagens coletadas de acordo com as opções selecionadas. É possível selecionar as datas das imagens que aparecerão na linha e as parcelas coletadas nesse dia, no eixo vertical. A Figura 21 apresenta um exemplo da aplicação onde optou-se por exibir as imagens do dia 21/05/2022, 12/08/2022 e 23/09/2022 para as parcelas 305, 404 e 408, que são plantios das cultivares humídicola comum, Llanero e BRS Tupi, da espécie *Brachiaria humídicola*.




Figura 21 – Aplicação para visualização dos dados coletados

A aplicação foi desenvolvida utilizando javascript e os frameworks vue.js e vuexify, o primeiro para construção de aplicações web reativas e o segundo para componentes de interface, o projeto encontra-se público e disponível em https://github.com/leocrivels/visualizacao_dados. Além disso, também houve a necessidade de desenvolver uma API utilizando node.js para servir as imagens ao frontend, disponibilizado em https://github.com/leocrivels/host_images.

3.3 Construção dos Datasets

Em uma primeira rodada de experimentos buscou-se utilizar apenas dados coletados nesse trabalho separando-os em *datasets* para validar hipóteses. A partir das imagens coletadas foi possível construir nove datasets. Um *dataset* une as imagens das cultivares em todo o período, nele as classes são os nomes das cultivares. Outro *dataset* que separa as cultivares pelas datas das imagens, ou seja, onde as classes são uma junção da data com o nome da cultivar. Cinco *datasets* onde se uniu imagens de quatro datas consecutivas por

cultivar. Por fim, um *dataset* onde se reuniu imagens de todo o período com inflorescência aparente. Dessa forma podendo ser exemplificado como na Tabela 5.

Dataset	Classes	Segmentação
Geral	18	Por cultivar
Datas	311	Por cultivar e por data
Período 1	18	Por cultivar entre 25/02/2022 e 18/03/2022
Período 2	18	Por cultivar entre 29/03/2022 e 28/04/2022
Período 3	18	Por cultivar entre 21/05/2022 e 06/08/2022
Período 4	18	Por cultivar entre 12/08/2022 e 16/09/2022
Período 5	18	Por cultivar entre 09/09/2022 e 29/10/2022
Período de Inflorescência	18	Por cultivar entre 23/04/2022 e 16/09/2022

Tabela 5 – Tabela de *datasets* Originais

Vale observar que, no *dataset* por datas, algumas classes foram retiradas devido a falta de exemplares em idades específicas. Isso se deu ao fato de que, no começo da coleta, nem todas as cultivares já haviam emergido ou estavam com tamanho suficiente para coleta de imagens, o que também acarretou a falta de exemplares e desbalanceamento de algumas classes no *dataset* do Período 1.

A partir desses *datasets* pretende-se responder as seguintes perguntas sobre o comportamento no aprendizado de classificação de cultivares:

- Novas arquiteturas de redes neurais apresentam melhoria na classificação de cultivares em relação a Mobilenet V2?
- O modelo é capaz de aprender a classificar cultivares e suas idades?
- Sabendo a idade da cultivar o modelo apresenta melhoria na identificação das cultivares?
- A fase de inflorescência proporciona diferenças morfológicas significativas para facilitar que o modelo distinga melhor as cultivares e aumentar a taxa de acerto da classificação?

Em uma segunda rodada de experimentos, obteve-se o banco de imagens construído no trabalho Fazan (FAZAN, 2020) com o qual foi possível expandir exemplares das classes e unir os *datasets*. No decorrer dos capítulos o *dataset* oriundo do trabalho Fazan (FAZAN, 2020) será denominado *dataset* Fazan, enquanto o *dataset* oriundo desse trabalho será denominado *dataset* Original. Como o principal *dataset* do trabalho citado seria um *dataset* geral com plantas em idades e em épocas do ano variadas, foi possível mesclá-lo somente com o *dataset* geral da Tabela 5. Porém, como observado na Tabela 3 esse *dataset* possui somente 11 cultivares então optou-se por mesclar os *datasets* de duas

maneiras, unindo somente as classes semelhantes e unindo todas as classes. Resultando nos *datasets* “Mesclado-Compatível” e “Mesclado-Todo” representado na Tabela 7.

A Tabela 6 apresenta a disponibilidade de dados no *Dataset* Original e no *Dataset* Fazan, as linhas mais escuras representam onde há compatibilidade entre os exemplares das classes por ter representações dela em variados períodos e idades. Dessa maneira, as linhas mais escuras representam as classes presentes no *Dataset* “Mesclado-Compatível”.

		Dataset Original			Dataset Fazan		
		Estádio Chuva	Adulto Seca	Em Desenv.	Estádio Chuva	Adulto Seca	Em Desenv.
C1	BRS Ipyporã	✓	✓	✓	✓	✓	✓
C2	BRS Paiaguás	✓	✓	✓	✓	✓	✓
C3	BRS Piatã	✓	✓	✓	✓	✓	✓
C4	BRS Quênia	✓	✓	✓	✓	✓	✓
C5	BRS Tamani	✓	✓	✓	✓	✓	✓
C6	BRS Tupi	✓	✓	✓	✓	✓	✓
C7	BRS Zuri	✓	✓	✓	✓	✓	✓
C8	Basilisk	✓	✓	✓	✓		✓
C9	Humidicola comum	✓	✓	✓	✓	✓	✓
C10	Llanero	✓	✓	✓		✓	✓
C11	Marandu	✓	✓	✓	✓	✓	✓
C12	Massai	✓	✓	✓	✓		✓
C13	Mavuno	✓	✓	✓			
C14	Mombaça	✓	✓	✓	✓		✓
C15	Mulato II	✓	✓	✓			
C16	Ruziziensis	✓	✓	✓	✓	✓	✓
C17	Tanzânia	✓	✓	✓	✓		✓
C18	Xaraés	✓	✓	✓	✓	✓	✓

Tabela 6 – Disponibilidade de dados nos Datasets Original e Fazan

Um último *dataset* foi construído observando a fase de inflorescência aparente em ambos trabalhos. No *dataset* construído no presente trabalho há inflorescência aparente nas imagens coletadas entre 23/04/2022 e 16/09/2022 enquanto em *dataset* Fazan há inflorescência aparente nas imagens coletadas da Área 56 durante a época de chuvas, entre dezembro de 2019 e fevereiro de 2020.

Vale observar que a Área 56 foi a única região onde houve acompanhamento do crescimento das plantas nesse trabalho, porém o *dataset* fornecido não possui a data de registro das imagens, apenas sua separação em chuva e seca, e portanto não foi possível realizar outras formas de união desses datasets.

O *dataset* da Área 56 na época de chuvas possuía duas cultivares cujos exemplares foram descartados no treinamento devido ao seu desbalanceamento, as cultivares Tamani e Llanero. Porém, para a união dos datasets, elas foram incorporadas ao *dataset* original.

Para evitar o desbalanceamento, as cultivares Mavuno e Mulato II foram retiradas da união dos *dataset* por estarem presentes somente no *dataset* do presente trabalho. Dessa forma esse *dataset* possui imagens de 16 cultivares com inflorescência aparente, como apresentado na Tabela 7.

Dataset	Classes	Segmentação
Mesclado-Compatível	11	Une os <i>datasets</i> de ambos trabalhos a partir das classes compartilhadas
Mesclado-Todo	18	Une todas as classes de ambos trabalhos
Mesclado-Inflorescência	16	Une as classes Area 56-Chuva (FAZAN, 2020) e P. Inflorescência(Autor)

Tabela 7 – *Dataset* mesclando imagens dos *Dataset* da Tabela 5 e da Tabela 3

Essa mesclagem de *datasets* se deu para responder as seguintes perguntas:

1. Aumentar a quantidade e a variedade de exemplares das classes poderia melhorar o aprendizado dos modelos e aumentar a taxa de acerto da classificação?

A proporção da separação destes *datasets* em conjuntos de treino, validação e teste foi decidida durante a etapa de treinamento conforme observava-se necessidade de mais dados nessas rotinas. Além disso, também houveram aplicações de técnicas de tratamento nas imagens dos *datasets*.

3.4 Treinamento de Modelos

Após validar as hipóteses visualizando e comparando as imagens, construiu-se os *datasets* e posteriormente buscou-se realizar treinamentos de modelos de rede neural e analisar os seus comportamentos.

Os treinamentos dos modelos foram realizados em uma máquina remota com capacidade de processamento gráfico para que o processamento das imagens fosse paralelizado e, assim, a rotina acelerada. A máquina possuía um processador Intel® Core(TM) i7-13700F, 128 GB de memória e para processamento gráfico, uma placa NVIDIA® GeForce RTX® 4090 com 24 GB de memória dedicada.

Para as rotinas de treinamento, os *datasets* foram separados em conjuntos para treino, validação e teste. Além disso, foi utilizado como critério de loss a `crossEntropy`, o otimizador `SGD` (`Stochastic Gradient Descent`) ou `AdamW`, nos casos onde havia grande quantidade de dados, afim de economizar recursos e acelerar a convergência.

Afim de evitar *overfitting* e economizar recursos, aplicou-se a técnica de early-stop com paciência de épocas variadas. Essa técnica monitora o desempenho do modelo em

um conjunto de validação e interrompe o treinamento quando o erro de validação começa a aumentar (GOODFELLOW; BENGIO; COURVILLE, 2016), o parâmetro de paciência define por quantas épocas o treinamento pode seguir sem que haja redução na taxa de *loss* do conjunto de validação, assim evitando que o modelo fique “super-ajustado” aos dados de treinamento.

Após o treinamento, os modelos passaram pela fase de teste onde se gerou relatório de classificação contendo *precision*, *recall* e *f1-score* na identificação de cada classe. Para os modelos treinados nos *datasets* mesclados, também houve uma segunda separação no conjunto de teste separando-o em exemplares presentes nos *dataset* Originais e exemplares presentes nos *datasets* incorporados, gerando assim mais dois relatórios de classificação para esses cenários.

3.4.1 Tratamento das imagens

Durante as rotinas de treinamento, as imagens passaram por um pré-processamento no qual se cortou 50% do centro da imagem e redimensionou-as em 512x512. Como as assimetrias são muito discretas e podem acontecer em partes pequenas das plantas, buscou-se maximizar os menores detalhes das imagens. Com exceção do *dataset* separado por Inflorescência, onde optou-se por recortar 80% do centro das imagens e aplicar o mesmo redimensionamento. Essa decisão foi tomada devido a inflorescência da planta estar presente na sua parte mais alta, muitas vezes se apresentando no topo mais extremo das imagens, por isso, ao se recortar 50% do centro dessas imagens, essa característica poderia ser descartada.

A Figura 22 ilustra esse procedimento ao realizá-lo em uma imagem da cultivar Llanero em 21/05/2022. Nota-se que em (a) que o formato das laminas foliares e as cores ficam mais destacadas ao se recortar 50% da imagem, isso também remove partes menos relevantes como o solo presente nessa imagem. Porém em (a) houve um descarte e uma representação menor da imagem referente às inflorescências, o que em (b) ao se recortar 80% torna-se um fator mais visível e de maior destaque.




Figura 22 – Ilustração do procedimento de recorte e redimensionamento das imagens do dataset durante o treinamento

3.4.2 MobileNet V3

Para uma primeira análise, utilizou-se o modelo pré-treinado da arquitetura MobileNet V3 Large, por sua versão anterior apresentar os melhores resultados na literatura para esse domínio (FAZAN, 2020).

3.4.2.1 Datasets Originais

Os dados presentes nos *datasets* Originais, durante a rotina de treinamento da MobileNet, foram divididos em conjuntos para treino, teste e validação da seguinte forma:

- Por Datas: Devido ao número limitado de imagens diárias (entre 15 e 30 por cultivar), a divisão adotada foi:
 - 50% para treino;
 - 25% para teste;
 - 25% para validação;

- Por Período: A mesma proporção foi aplicada aos *datasets* classificados por períodos específicos.
- Geral: Este conjunto, contendo um maior número de exemplos, foi dividido em:
 - 80% para treino;
 - 10% para teste;
 - 10% para validação;
- Por Período de Inflorescência: Por conter mais exemplos que o restante dos períodos, buscando igualar as quantidades de exemplos de teste, foi dividido em:
 - 75% para treino;
 - 12.5% para teste;
 - 12.5% para validação;

O critério de loss e o otimizador escolhidos foram a `crossEntropy` e `SGD`, respectivamente, e Learning Rate de 0.01.

3.4.2.2 Datasets Mesclados

Para o treinamento dos modelos MobileNet V3 nos *datasets* mesclados foram utilizados os seguintes parâmetros e técnicas:

- Proporção do conjunto treino, validação e teste, respectivamente: 50%, 25% e 25%;
- Critério de Loss: `CrossEntropy`;
- Otimizador: `SGD`
- LR: 0.01
- Paciência do early-stop: 20 épocas;
- Tratamento das imagens: Recorte de 50% do centro e redimensionamento 512x512;

Para a proporção dos conjuntos de treino, teste e validação, optou-se por 50%, 25% e 25% respectivamente devido a grande quantidade de exemplares.

Com exceção do *Dataset* Mesclado na fase de inflorescência, no qual o treinamento do modelo no *dataset* onde se reuniu as imagens dos dois bancos em que havia inflorescência, optou-se por recortar 80% do centro das imagens ao invés de 50% como nos outros *datasets*. Essa decisão foi tomada devido à característica da inflorescência ser a parte mais alta da planta, muitas vezes podendo estar no topo das imagens.

Dessa forma o treinamento teve as seguintes características:

- Proporção do conjunto treino, validação e teste, respectivamente: 75%, 12.5% e 12.5%;
- Critério de Loss: CrossEntropy;
- Otimizador: SGD
- LR: 0.01
- Paciência do early-stop: 10 épocas;
- Tratamento das imagens: Recorte de 80% do centro e redimensionamento 512x512;

3.4.3 MobileVit

Um segundo experimento foi realizado utilizando os mesmos *datasets* para treinar modelos pré-treinados com arquitetura MobileVIT Small, que é mais recente e cuja camada de atenção apresenta vantagens em relação à MobileNet V3 como apresentado na Seção 2.1.2.3.

3.4.3.1 Datasets Originais

Observou-se o baixo desempenho do modelo treinado no *dataset* por Datas e se optou por não utilizá-lo nesse experimento. Para os demais *datasets* utilizou-se características:

- Proporção do conjunto treino, validação e teste, respectivamente: 50%, 25% e 25%;
- Critério de Loss: CrossEntropy;
- Otimizador: SGD
- LR: 0.001
- Paciência do early-stop: 10 épocas;
- Tratamento das imagens: Recorte de 50% do centro e redimensionamento 512x512;

No caso do *dataset* separado por Período com Inflorescência, foram adotadas configurações específicas para maximizar o desempenho:

- Proporção do conjunto treino, validação e teste, respectivamente: 75%, 12.5% e 12.5%;
- Critério de Loss: CrossEntropy;
- Otimizador: AdamW

- LR: 0.0002
- Paciência do early-stop: 10 épocas;
- Tratamento das imagens: Recorte de 80% do centro e redimensionamento 512x512;

3.4.3.2 Datasets Mesclados

Os parâmetros utilizados para o treinamento das redes mobileViT nos *dataset* com a mescla dos dados dos *datasets* Originais e Fazan (FAZAN, 2020), utilizaram os seguintes parâmetros:

- Proporção do conjunto treino, validação e teste, respectivamente: 75%, 12.5% e 12.5%;
- Critério de Loss: CrossEntropy;
- Otimizador: AdamW
- LR: 0.0002
- Paciência do early-stop: 10 épocas;
- Tratamento das imagens: Recorte de 80% do centro e redimensionamento 512x512;

Excepcionando-se pelo treinamento no *dataset* Mesclado-Compatível onde se usou o otimizador SGD, Learning Rate de 0.01 e paciência de 5 épocas para o early-stop.

4 Resultados

Este capítulo apresenta os resultados obtidos a partir da análise das cultivares e do desempenho dos modelos de redes neurais treinados. Primeiramente, explora-se a comparação das imagens das cultivares em diferentes estádios de desenvolvimento, utilizando o aplicativo web descrito anteriormente para a visualização dos dados. As subseções a seguir detalham os resultados das métricas de *precision*, *recall* e *f1-score*, bem como a análise das taxas de loss dos modelos MobileNet V3 e MobileViT, treinados com diferentes conjuntos de dados.

Além disso, também serão discutidas as variações no desempenho dos modelos ao longo dos períodos de coleta e as influências de fatores como a fase de inflorescência das plantas. Por fim, é apresentada uma avaliação dos resultados gerais e das dificuldades encontradas na classificação de certas cultivares.

4.1 Análise dos Dados

A partir do aplicativo web desenvolvido para a visualização dos dados como explicado na Seção 3.2, foi possível analisar e comparar as cultivares em diferentes idades. A Figura 23, apresenta uma comparação entre duas cultivares diferentes, de espécies diferentes e do mesmo gênero, a *Brachiaria humidicola* cv. Llanero (parcela 107) e a *Brachiaria brizantha* cv. Xaraés (parcela 205) nos dias 29/03/2022 e 21/05/2022. Enquanto a Figura 24, apresenta uma comparação entre duas cultivares diferentes da mesma espécie e gênero, a *Brachiaria humidicola* cv. Humidicola comum (parcela 307) e a *Brachiaria humidicola* cv. BRS Tupi (parcela 404) nos dias 23 de abril, 22 de julho e 09 de setembro de 2022. Na primeira comparação, observa-se uma clara diferença na morfologia das plantas, especialmente relacionadas à largura das folhas, a quantidade e a forma da inflorescência. Já na segunda comparação, embora as cultivares sejam semelhantes no estágio adulto, diferenças nos estádios de desenvolvimento são evidenciadas durante a fase de crescimento no dia 22 de julho.




Figura 23 – Comparação entre as cultivares *Brachiaria humidicola* cv. Llanero (parcela 107) e a *Brachiaria brizantha* cv. Xaraés (parcela 205) nos dias 29/03/2022 e 21/05/2022




Figura 24 – Comparação entre as cultivares *Brachiaria humidicola* cv. Humidicola comum (parcela 307) e *Brachiaria humidicola* cv. BRS Tupi (parcela 404) nos dias 23/04/2022, 22/07/2022 e 09/09/2022

Esse comparativo revela a importância de se buscar maneiras de usufruir das di-

ferenças morfológicas em determinadas idades para a identificação de cultivares, além de expor as claras assimetrias entre plantas de espécies distintas.

4.2 Treinamento da MobileNet V3

4.2.1 Dataset por Datas

Como mencionado anteriormente, acredita-se que existam períodos de crescimento das cultivares em que as características morfológicas que as diferenciam tornam-se mais evidentes. Assim, foi construído um *dataset* a partir das imagens coletadas, separando-as em 311 classes, que representam o dia da coleta da imagem e a cultivar. As imagens passaram por um pré-processamento no qual se recortou 50% do centro da imagem e redimensionou-as em 512x512. O *dataset* foi utilizado para treinar um modelo da rede neural MobileNet V3, no qual adotou-se o critério *crossEntropy* para o cálculo da loss e o otimizador *AdamW*. Neste treinamento, devido a pouca quantidade de imagens diárias por cultivar, foi necessário dividi-las em 50% para treino, 25% para teste e 25% para validação.

A rotina de treinamento produziu taxas de loss de treinamento e validação como exibido na Figura 25. Onde a curva inferior é a taxa de loss do treino e a curva superior é a taxa de loss da validação por época. Esta taxa nos sugere que pode haver poucos exemplos para as classes.




Figura 25 – Taxa de loss de treinamento e validação para o modelo classificando em idade e cultivar, onde a curva inferior é a taxa de loss do treino e a curva superior é a taxa de loss da validação por época

Como esperado a partir das taxas de *loss*, observando o relatório de classificação apresentado na Figura 8, o modelo atingiu uma *f1-score* muito baixa, de 24%. Devido a grande quantidade de classes, a Figura 8 abstraiu o relatório de algumas, porém exibe especificamente o relatório de classificações para as diferentes idades da cultivar Llanero.

	precision	recall	f1-score	support
2022-02-25/BRS Iypora	0.00	0.00	0.00	2
2022-02-25/BRS Paiaguas	0.25	0.50	0.33	2
2022-02-25/BRS Piata	0.00	0.00	0.00	2
2022-02-25/Basilisk	0.00	0.00	0.00	3
2022-02-25/Llanero	0.00	0.00	0.00	2
2022-02-25/Marandu	0.00	0.00	0.00	3
2022-02-25/Mulato II	0.33	0.33	0.33	3
...				
2022-03-05/Llanero	0.50	0.33	0.40	3
...				
2022-03-11/Llanero	0.00	0.00	0.00	1
...				
2022-03-18/Llanero	0.00	0.00	0.00	3
...				
2022-03-29/Llanero	0.00	0.00	0.00	5
...				
2022-04-09/Llanero	0.00	0.00	0.00	6
...				
2022-04-23/Llanero	0.00	0.00	0.00	7
...				
2022-04-28/Llanero	0.00	0.00	0.00	3
...				
2022-05-21/Llanero	0.25	0.12	0.17	8
...				
2022-07-15/Llanero	0.11	0.17	0.13	6
...				
2022-07-22/Llanero	0.00	0.00	0.00	4
...				
2022-08-06/Llanero	0.00	0.00	0.00	4
...				
2022-08-12/Llanero	0.00	0.00	0.00	5
...				
2022-08-20/Llanero	0.44	0.80	0.57	5
...				
2022-09-09/Llanero	0.12	0.20	0.15	5
...				
2022-09-16/Llanero	0.00	0.00	0.00	4
...				
2022-09-23/Llanero	0.00	0.00	0.00	4
...				
2022-10-29/Llanero	1.00	0.40	0.57	5
...				
accuracy			0.24	2504
macro avg	0.08	0.10	0.08	2504
weighted avg	0.18	0.24	0.20	2504

Tabela 8 – Relatório de classificação do modelo treinado para identificar idade e cultivar.

Uma alternativa para a melhoria desse resultado, observando a necessidade de mais exemplos, seria a utilização de intervalos de datas ao invés de datas pontuais. Dessa maneira, a Seção 4.2.3 apresenta uma segunda avaliação, utilizando imagens de um intervalo de datas.

4.2.2 Dataset Geral

Para superar a baixa quantidade de exemplos no *dataset* por Datas, dessa vez o *dataset* montado uniu imagens das cultivares em suas diferentes idades, ou seja, as classes passaram a ser apenas os nomes das cultivares, um total de 18 classes. Novamente para destacar os detalhes das plantas cortou-se 50% do centro da imagem e redimensionou-as em 512x512. Utilizou-se modelo da rede neural MobileNet V3, adotando o critério **crossEntropy** para o cálculo da *loss* e o otimizador SGD (Stochastic Gradient Descent). Neste treinamento, porém, foi possível dividir os exemplos em 80% para treino, 10% para teste e 10% para validação.

A Figura 26 apresenta uma melhora significativa nas taxas de *loss* de treino e validação em comparação ao treinamento com o *Dataset* por Datas. Consequentemente, é possível inferir que a probabilidade de ter ocorrido um “overfitting” crítico é baixa.




Figura 26 – Taxa de *loss* de treinamento e validação para o modelo classificando em cultivar, onde a curva inferior é a taxa de *loss* do treino e a curva superior é a taxa de perda da validação por época

Um relatório de classificação foi gerado para esse modelo e pode ser analisado na Tabela 9. Percebe-se uma taxa de acerto positiva de 69% com destaques para a *precision* da cultivar Llanero de 96% e uma *recall* de também 96% para a cultivar Humidicola comum.

	precision	recall	f1-score	support
C1:BRS Ipypora	0.75	0.64	0.69	33
C2:BRS Paiaguas	0.68	0.77	0.72	30
C3:BRS Piata	0.73	0.82	0.77	33
C4:BRS Quenia	0.80	0.55	0.65	22
C5:BRS Tamani	0.73	0.73	0.73	22
C6:BRS Tupi	0.81	0.75	0.78	28
C7:BRS Zuri	0.39	0.56	0.46	25
C8:Basilisk	0.82	0.72	0.77	32
C9:Humidicola comum	0.79	0.96	0.86	23
C10:Llanero	0.96	0.75	0.84	32
C11:Marandu	0.65	0.59	0.62	34
C12:Massai	0.72	0.78	0.75	23
C13:Mavuno	0.64	0.54	0.58	13
C14:Mombaca	0.41	0.33	0.37	27
C15:Mulato II	0.77	0.73	0.75	33
C16:Ruziziensis	0.70	0.79	0.74	33
C17:Tanzania	0.56	0.68	0.61	28
C18:Xaraes	0.68	0.70	0.69	33
accuracy			0.69	504
macro avg	0.70	0.69	0.69	504
weighted avg	0.70	0.69	0.69	504

Tabela 9 – Relatório de classificação do modelo treinado para identificar cultivares.

Para uma melhor análise dos resultados obtidos, extraiu-se uma matriz de confusão desse modelo, que pode ser vista na Tabela 10. Assim é possível observar em cada caso por qual cultivar o modelo está classificando de forma equivocada.

	C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	C12	C13	C14	C15	C16	C17	C18
C1	21	0	0	0	0	0	1	0	0	0	3	0	1	0	3	1	2	1
C2	1	23	1	0	0	0	0	0	0	0	1	1	0	0	1	0	0	2
C3	0	2	27	0	0	0	0	0	0	0	3	0	0	0	0	1	0	0
C4	0	1	0	12	2	1	1	0	0	0	0	1	0	1	0	0	2	1
C5	0	0	0	1	16	0	2	0	0	0	0	2	0	0	0	0	1	0
C6	0	1	0	0	0	21	0	0	4	0	0	0	0	0	0	1	1	0
C7	0	0	0	1	1	0	14	0	0	0	0	0	0	7	0	0	2	0
C8	0	1	2	0	0	0	0	23	1	1	1	0	0	0	0	3	0	0
C9	0	0	0	0	0	1	0	0	22	0	0	0	0	0	0	0	0	0
C10	1	1	1	0	0	3	0	1	0	24	0	0	0	0	0	0	0	1
C11	1	0	3	0	0	0	0	2	0	0	20	0	1	0	1	3	1	2
C12	0	1	1	1	1	0	0	0	0	0	0	18	0	0	0	0	1	0
C13	0	1	0	0	0	0	2	0	0	0	0	0	7	1	0	0	1	1
C14	0	0	2	0	0	0	12	0	0	0	0	1	1	9	0	0	2	0
C15	4	0	0	0	0	0	1	0	0	0	1	0	0	0	24	1	1	1
C16	0	1	0	0	0	0	0	2	1	0	1	0	0	0	0	26	0	2
C17	0	0	0	0	2	0	1	0	0	0	0	2	0	3	0	1	19	0
C18	0	2	0	0	0	0	2	0	0	0	1	0	1	1	2	0	1	23

Tabela 10 – Matriz de confusão do modelo para identificação de cultivares.

4.2.3 Datasets por Período

Para identificar se existem períodos onde as cultivares possuem características mais marcantes que outros, foram treinados seis modelos utilizando 5 *datasets* separados por períodos de 4 datas de imagens e um período onde havia inflorescência como descritos na Tabela 5. Os relatórios de classificação completos de cada um desses treinamentos podem ser analisados no Apêndice A. Esta Seção se dedicará em apresentar uma comparação entre a *precision*, *recall* e *f1-score* desses modelos.

Os gráficos presentes na Figura 27, Figura 28 e Figura 29 comparam a *precision*, *recall* e *f1-score* dos relatórios de classificação dos seis modelos treinados para cada uma das cultivares.




Figura 27 – Comparação de *precision* entre os modelos MobileNet V3 treinados nos *datasets* por Período

Nota-se na Figura 27 que os modelos treinados no Período 1 e no Período de Inflorescência não conquistaram a melhor *precision* em nenhuma cultivar em relação aos outros modelos. Já o modelo treinado no Período 2 teve a melhor *precision* da cultivar Ruziziensis. O modelo do Período 3 a *precision* mais alta da cultivar Mombaca e Mulato II. O modelo do Período 4 para a Quênia, Basilisk, Marandú, Massai e Mavuno e o modelo do período 5 teve a melhor *precision* para as demais 10 cultivares, mostrando que as cultivares de maior idade, nesses dois últimos períodos, aparentam ser mais discriminativas.




Figura 28 – Comparação de *recall* entre os modelos MobileNet V3 treinados nos *datasets* por Período

A partir do gráfico na Figura 28 observa-se que dessa vez o modelo no Período 1 conquista a melhor taxa de *recall* para a cultivar Basilisk e o modelo no Período de Inflorescência para as cultivares Tamani, Tupi, Massai e Tanzânia. Enquanto o modelo do Período 2 possui os melhores resultados para Quênia e Marandu e do Período 3 somente está acima dos outros modelos para as cultivares BRS Ipyporã e mombaca. O modelo do Período 4 possui a melhor *recall* para BRS Paiaguás, Zuri, Mavuno e ruziziensis e o modelo do Período 5 para as demais 5 cultivares.




Figura 29 – Comparação de *f1-score* entre os modelos MobileNet V3 treinados nos *datasets* por Período

A Tabela 11 compila o desempenho geral das taxas de acerto e médias de *f1 score* dos modelos treinados por período. A partir dela e do gráfico da Figura 29, observa-se uma evolução clara na taxa de acerto dos modelos ao longo dos seis períodos avaliados.

O Período 1 apresentou o pior desempenho, com uma taxa de acerto de 36%,

destacando-se apenas a cultivar Basilisk com *f1-Score* de 62%. No Período 2, o desempenho melhorou significativamente, alcançando uma taxa de acerto de 53%, com destaque para as cultivares Basilisk (78%) e Llanero (67%). No Período 3, o modelo continuou progredindo, atingindo uma taxa de acerto de 59%, sendo as cultivares BRS Ipyporã (81%) e Mulato II (67%) as mais destacadas.

O Período 4 apresentou uma melhora adicional, com taxa de acerto de 61%, e cultivares como Tupi (84%) e Ruziziensis (79%) obtendo excelente desempenho. No Período 5, o desempenho foi ainda mais robusto, com uma taxa de acerto de 66%, destacando-se as cultivares Humidicola Comum (93%) e Llanero (86%). Por fim, no Período de Inflorescência, o modelo alcançou uma taxa de acerto de 54%, com excelentes resultados para cultivares como Tupi (91%) e Massai (76%), indicando que a fase fenológica de inflorescência favoreceu a classificação de certas cultivares.

No geral, observa-se uma melhoria consistente na acurácia ao longo dos períodos, com os melhores resultados concentrados nos Períodos 4 e 5.

MobileNet V3	Accuracy	F1 - Macro avg	F1 - Weighted avg	support
Período 1	0,36	0,25	0,34	111
Período 2	0,53	0,5	0,52	314
Período 3	0,59	0,57	0,58	370
Período 4	0,61	0,61	0,61	292
Período 5	0,66	0,65	0,66	331
P. Inflorescência	0,54	0,52	0,52	409

Tabela 11 – Comparação entre as médias de acurácia e *f1* dos modelos MobileNet treinados por período

Os resultados dos modelos mostram que o desempenho na classificação das cultivares variou conforme os períodos analisados, revelando a influência das condições sazonais e fenológicas.

Porém, o Período 5 foi mais eficaz para as cultivares BRS Piatã (77%), Humidicola Comum (93%), Llanero (86%) e Xaraés (84%), indicando que as condições observadas nesse período foram ideais para a classificação dessas plantas. O Período 3 apresentou os melhores resultados para BRS Ipyporã (81%) e Mombaça (48%), demonstrando uma adaptação do modelo para essas cultivares em condições sazonais específicas. Já o Período 4 mostrou-se eficiente para cultivares como Massai (79%), Mavuno (67%) e Ruziziensis (79%).

O Período de Inflorescência teve um impacto positivo em cultivares como BRS Tupi, que atingiu um *f1-Score* de 91%, e Ruziziensis, também com 79%. No Período 2, destacaram-se Basilisk (78%) e Tanzânia (62%), reforçando a importância de diferentes períodos para a identificação precisa dessas cultivares.

Apesar disso, nenhum desses modelos foi capaz de superar a acurácia do modelo

treinado no *dataset* Geral que obteve 69% de acurácia e apresentou uma performance consistente para várias cultivares, como BRS Paiaguás (f1-Score de 72%), BRS Quênia (65%), BRS Tamani (73%), BRS Zuri (46%), Marandu (62%) e Mulato II (75%).

4.2.4 Dataset Mesclado-Compatível

O modelo treinado no *dataset* Mesclado-Compatível possuía uma tarefa menos complexa de ser executada em relação aos outros *datasets* pois nele só existem 11 classes para serem identificadas, conforme explicado na Seção 3.3 e exemplificado na Tabela 6.

A rotina de treinamento utilizou os parâmetros como descritos na Seção 3.4.2.2. O treinamento durou 28 épocas, como observado na Figura 30, a melhor taxa de *loss* de treino e validação ocorreu na época 8. Optou-se por um treinamento com parâmetro de paciência no early-stop de 20 épocas para esse modelo pois acreditava-se que ele teria mais dificuldades para convergir dadas as origens distintas das imagens, o que não ocorreu.




Figura 30 – Taxas de *loss* de Treino e validação do modelo MobileNet V3 treinado no *dataset* Mesclado-Compatível

O relatório de classificação obtido desse modelo, apresentado na Tabela 12, atinge uma acurácia de 78%, a maior em relação aos modelos anteriores. Esse comportamento não surpreende, dada a quantidade reduzida de classes, 11 nesse e 18 nas anteriores, e a quantidade maior de exemplos no dataset.

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0.88	0.89	0.89	556
C2:BRS Paiaguás	0.86	0.80	0.83	550
C3:BRS Piatã	0.67	0.80	0.73	564
C4:BRS Quênia	0.70	0.73	0.71	532
C5:BRS Tamani	0.83	0.82	0.83	534
C6:BRS Tupi	0.84	0.75	0.80	547
C7:BRS Zuri	0.72	0.74	0.73	538
C9:Humidicola comum	0.77	0.89	0.82	533
C11:Marandu	0.75	0.64	0.69	563
C16:Ruzizensis	0.85	0.86	0.86	558
C18:Xaraés	0.78	0.69	0.73	556
accuracy				0.78
macro avg				0.78
weighted avg				0.78

Tabela 12 – Relatório de classificação do modelo MobileNet V3 treinado no *dataset* Mesclado-Compatível

Porém ao separar o conjunto de teste pela origem dos dados e gerar novos relatórios de classificação para os exemplares de teste originais e os exemplares de teste de Fazan percebe-se que, na verdade, o modelo não atinge o melhor resultado para os dados do *dataset* original.

A Tabela 13 apresenta uma versão resumida comparando acurácia, *f1-score* macro e *f1-score* ponderado dos relatórios de classificação (presentes no Apêndice A.2). Nota-se que a acurácia desse modelo para o *dataset* original é de 67% contra 69% do modelo treinado no *dataset* Geral, mesmo esse modelo contendo apenas 11 classes.

Outro resultado notável é a melhoria de 27% na acurácia desse modelo em classificar o *dataset* Geral no Período Geral de Fazan. Enquanto esse modelo atinge acurácia de 80%, o modelo anterior atingia 53%, como observado na Tabela 3. Isso se deve ao fato da atualização da versão da arquitetura, ao tratamento de recorte de 50% das imagens, o redimensionamento em 512x512 ao invés de 224x224 e, claro, o incremento de novos exemplos do *dataset* original.

Conjunto de teste	Accuracy	F1 - Macro avg	F1 - weighted avg	support
Dataset Original	0.67	0.67	0.67	803
Dataset Fazan 2020	0.80	0.80	0.80	5228

Tabela 13 – Relatório de classificação do modelo MobileNet V3 treinado no *dataset* Mesclado-Compatível separando o conjunto de testes pelos *datasets* de origem

4.2.5 Dataset Mesclado-todo

O treinamento desse modelo seguiu os parâmetros definidos na Seção 3.4.2.2 e produziu taxas de *loss* de treino e validação como da Figura 31. A décima época desse modelo foi a última em que houve melhoria no aprendizado, após ela houveram mais 20 épocas de treinamento sem que houvesse incremento das taxas de *loss*.




Figura 31 – Taxas de *loss* de Treino e validação do modelo MobileNet V3 treinado no *dataset* Mesclado-Todo

É importante destacar que existe desbalanceamento nas classes desse dataset, uma vez que 7 de suas classes só possuíam exemplos no *dataset* Original, identifica-se essas classes a partir da Tabela 14, são as classes com os menores valores de support.

O cálculo de acurácia e *f1-score* ponderado levam em consideração a quantidade de exemplos presentes para cada classe no dataset, como observado na Seção 2.1.3. Dado o desbalanceamento de exemplares, isso é um problema pois para o domínio desse trabalho não deveria-se existir maiores importâncias para nenhuma das classes de cultivar, por isso é importante utilizar a métrica *f1-score Macro* como parâmetro de comparação.

Percebe-se um bom resultado para esse modelo cuja acurácia (75%) está somente 3% abaixo do modelo treinado no *dataset* Mesclado-Compatível que possuía apenas 11 classes. Porém, considerando o desbalanceamento das classes, utilizando a média de *f1-score* macro (68%) como comparação, nota-se um resultado importante para esse modelo, ele não superou ao menos o modelo treinado no *dataset* Geral (69%) que possui menos exemplares.

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0.87	0.87	0.87	556
C2:BRS Paiaguás	0.79	0.83	0.81	550
C3:BRS Piatã	0.71	0.71	0.71	564
C4:BRS Quênia	0.75	0.59	0.66	532
C5:BRS Tamani	0.77	0.85	0.81	535
C6:BRS Tupi	0.74	0.88	0.80	548
C7:BRS Zuri	0.66	0.74	0.70	539
C8:Basilisk	0.78	0.62	0.69	79
C9:Humidicola comum	0.87	0.79	0.83	533
C10:Llanero	0.74	0.61	0.67	79
C11:Marandu	0.65	0.69	0.67	564
C12:Massai	0.73	0.57	0.64	58
C13:Mavuno	0.55	0.34	0.42	32
C14:Mombaça	0.30	0.30	0.30	67
C15:Mulato II	0.61	0.64	0.63	81
C16:Ruziziensis	0.81	0.82	0.82	558
C17:Tanzânia	0.54	0.50	0.52	70
C18:Xaraés	0.80	0.68	0.74	556
accuracy			0.75	6501
macro avg	0.70	0.67	0.68	6501
weighted avg	0.75	0.75	0.75	6501

Tabela 14 – Relatório de classificação do modelo MobileNet V3 treinado no *dataset* Mesclado-Todo

Separou-se o conjunto de testes em dois *datasets* pela origem dos dados, onde um *dataset* possui dados originais e um *dataset* possui dados de Fazan (FAZAN, 2020). A Tabela 15 compara a acurácia e médias de *f1-score* dos relatórios de classificação gerados por esse modelo nesses datasets.

Como esperado, devido ao desbalanceamento das classes durante o treinamento, o *dataset* Original teve uma acurácia 57%, enquanto o *dataset* Fazan (FAZAN, 2020) atingiu 80%. Vale observar que não houve desbalanceamento das classes nesses conjuntos de teste, por isso a acurácia e *f1-score* também são relevantes nesses casos, porém devido a inexistência de 7 classes no conjunto Fazan (FAZAN, 2020) a *f1-score* macro desse conjunto teve seu valor prejudicado. Os relatórios completos podem ser analisados no Apendice A.3.

Conjunto de teste	Accuracy	F1 - Macro avg	F1 - weighted avg	support
Dataset Original	0.57	0.56	0.56	1250
Dataset Fazan 2020	0.80	0.58	0.79	5251

Tabela 15 – Relatório de classificação do modelo MobileNet V3 treinado no *dataset* Mesclado-Todo separando o conjunto de testes pelos *datasets* de origem

4.2.6 Dataset Mesclado-Inflorescência

Um último experimento utilizando a rede MobileNet V3 foi executado afim de testar o desempenho desse modelo em aprender e identificar cultivares no Período de Inflorescência, porém dessa vez unindo imagens do *dataset* Original e de Fazan (FAZAN, 2020) para aumentar a quantidade de exemplares. No caso do *dataset* incorporado, as imagens desse período são encontradas na Área 56 na época de chuvas com as quais foi possível realizar a mesclagens dos dados de 16 cultivares conforme explicado na Seção 3.4.2.2.

Assim como nos experimentos anteriores, os parâmetros utilizados para esse treinamento seguiram a definição da Seção 3.4.2.2. Diferentemente dos experimentos anteriores, dessa vez se utilizou um recorte de 80% do centro das imagens e apenas 10 épocas de paciência para o early-stop.

Na Figura 32 compara-se as taxas de *loss* de treino e validação produzidos pela rotina de treinamento desse modelo. A última época em que houve melhoria de ambas as taxas de *loss* foi a 12 e a rotina seguiu até a época 22 sem que houvesse incrementos.




Figura 32 – Loss de treino do modelo MobileNet no *dataset* Mesclado-Inflorescência

Os resultados desse modelo são apresentados na Tabela 16 que apresenta seu relatório de classificação com as medidas de desempenho *precision*, *recall* e *f1-score*. Nota-se melhor desempenho em termos de *f1-score* para a cultivar Basilisk (90%), BRS Ipyporã (93%) e Ruziziensis (89%), refletindo uma alta *precision* e *recall* consistentes. Por outro lado, as cultivares com os piores desempenhos foram a BRS Tamani (71%) e a Mombaça (69%), sugerindo dificuldades na classificação dessas cultivares. Em particular, a BRS Tamani apresentou uma *recall* de 74%, enquanto a Mombaça teve uma *precision* relativamente baixa de 64%, o que pode ter contribuído para a redução no *f1-score*. Essas variações destacam as disparidades na performance do modelo, dependendo da cultivar.

Apesar disso o modelo obteve uma acurácia bastante razoável, de 82%. A melhor acurácia dos modelos MobileNet, ganhando inclusive do modelo treinado no *dataset* Mesclado-Compatível, com 78%, que possui alta quantidade de exemplos e apenas 11 classes.

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,89	0,97	0,93	137
C2:BRS Paiguás	0,94	0,8	0,87	136
C3:BRS Piatã	0,85	0,78	0,81	143
C4:BRS Quênia	0,77	0,78	0,78	134
C5:BRS Tamani	0,69	0,74	0,71	77
C6:BRS Tupi	0,86	0,89	0,88	133
C7:BRS Zuri	0,81	0,65	0,72	134
C8:Basilisk	0,91	0,88	0,9	137
C9:Humidicola comum	0,92	0,81	0,87	134
C10:Llanero	0,71	0,86	0,78	79
C11:Marandu	0,78	0,78	0,78	138
C12:Massai	0,86	0,89	0,87	133
C14:Mombaça	0,64	0,75	0,69	135
C16:Ruziziensis	0,93	0,85	0,89	138
C17:Tanzânia	0,72	0,81	0,76	136
C18:Xaraés	0,84	0,86	0,85	138
accuracy				0,82
macro avg				0,82
weighted avg				0,82

Tabela 16 – Relatório de classificação do modelo MobileNet treinado no *dataset* Mesclado-Inflorescência

Separando os conjuntos de teste pelos *datasets* origem e gerando novos relatórios de classificação para eles (Apendice A.4) foi possível construir a Tabela 17 que compara o desempenho desse modelo por *datasets* de origem. Através da acurácia percebe-se que os dados originados do *dataset* Fazan tiveram grande influência sobre o desempenho geral do modelo, uma vez que ele atingiu acurácia de 87% enquanto o conjunto de dados Originais atingiu acurácia de 61%. Isso coloca a performance desse modelo abaixo do modelo treinado no *dataset* Mesclado-Compatível, o resultado pode ser justificado pela grande confusão que ocorre entre as classes Zuri e Mombaça, uma vez que a classe Mombaça inexistente no *dataset* Mesclado-Compatível, elevando a *f1-score* da cultivar Zuri.

	accuracy	f1 - macro avg	f1 - weighted avg
Dataset Original	0,61	0,61	0,6
Dataset Fazan	0,87	0,86	0,87

Tabela 17 – Relatório de classificação do modelo MobileNet treinado no *dataset* Mesclado-Inflorescência separando o conjunto de testes pelos *datasets* de origem.

4.3 Treinamento da MobileVIT

A Seção a seguir apresenta uma série de experimentos realizados utilizando a arquitetura MobileVIT, com o objetivo de avaliar seu desempenho na classificação de cultivares de forrageiras. O primeiro experimento, descrito na Seção 4.3.1, explora o treinamento do modelo MobileVIT com o *dataset* geral, contendo todas as imagens de cultivares independentemente do período de coleta. Em seguida, na Seção 4.3.2, o modelo foi treinado com *datasets* segmentados por períodos específicos de coleta de imagens, buscando identificar possíveis variações nas características das cultivares ao longo do tempo.

Por fim, a Seção 4.3.3, Seção 4.3.4 e Seção 4.3.5 abordam o uso de *datasets* mesclados, combinando imagens de diferentes origens, como o *dataset* original e o *dataset* Fazan. No primeiro, foi avaliado a utilização de todas as imagens das cultivares em comum entre os datasets, no segundo utilizou-se todas as cultivares independente de sua existência em ambos os datasets, e por último restringiu-se à imagens das cultivares em fase de inflorescência em ambas origens. Em cada seção, são apresentadas as métricas de desempenho dos modelos, como acurácia, *precision*, *recall* e *f1-score*, permitindo uma análise detalhada sobre a eficiência da MobileVIT na identificação das cultivares em diferentes condições.

Como o treinamento dos modelos MobileNet no *dataset* separado por Datas não obteve bons resultados devido a falta de exemplares das classes, esse *dataset* não foi utilizado para o treinamento de um modelo com arquitetura MobileVIT.

4.3.1 Dataset Geral

O primeiro experimento utilizando a rede MobileVIT foi o treinamento de um modelo utilizando o *Dataset* original Geral, com todas as imagens coletadas separadas apenas por cultivar. Os parâmetros utilizados para esse procedimento estão descritos na Seção 3.4.3.1.

Um gráfico das taxas de *loss* de treino é apresentado na Figura 33. É possível notar um pico na taxa de *loss* da época 17, esse valor, que não segue a tendência, ocorreu devido a uma interrupção e retomada da rotina de treinamento. O otimizador SGD (Stochastic Gradient Descent) atualiza os pesos do modelo com base nos gradientes calculados nas iterações anteriores, como o estado do otimizador não foi carregado para a retomada do treinamento, ele teve que recalibrar seus pesos de forma abrupta.




Figura 33 – Loss de treino do modelo MobileViT no *dataset* Geral

Observa-se, a partir do relatório de classificação na Tabela 18, que os melhores resultados em termos de *f1-Score* foram obtidos pelas cultivares Humidicola Comum (74%), Basilisk (73%) e Ruziziensis (0,70%), sugerindo que o modelo foi mais eficiente na classificação dessas classes. Além disso, Massai também apresentou um bom desempenho com F1-Score de 68%, reforçando sua capacidade de ser bem identificada pelo modelo. No entanto, os piores resultados foram observados para as cultivares Zuri (*f1-score* de 18%) e Mombaça (*f1-score* de 32%), o que indica uma baixa *precision* na classificação dessas classes. As cultivares Quênia (38%) e Mavuno (42%) também tiveram resultados abaixo do esperado, evidenciando dificuldade do modelo em diferenciá-las adequadamente. A acurácia global do modelo foi de 58%.

Novamente, o modelo demonstra dificuldade com as classes Mombaça e Zuri assim como o modelo MobileNet V3 treinado no mesmo *dataset* (Seção 4.2.2). Porém o modelo MobileNet atingiu resultados melhores de *f1-score* tanto para essas classes quanto para acurácia geral do modelo, 69% contra 58%.

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,64	0,58	0,61	81
C2:BRS Paiaguás	0,67	0,59	0,62	75
C3:BRS Piatã	0,74	0,43	0,54	82
C4:BRS Quênia	0,52	0,3	0,38	56
C5:BRS Tamani	0,68	0,55	0,61	55
C6:BRS Tupi	0,69	0,64	0,67	70
C7:BRS Zuri	0,24	0,14	0,18	63
C8:Basilisk	0,7	0,76	0,73	80
C9:Humidicola comum	0,67	0,83	0,74	58
C10:Llanero	0,65	0,64	0,65	80
C11:Marandu	0,49	0,44	0,46	85
C12:Massai	0,78	0,6	0,68	58
C13:Mavuno	0,35	0,53	0,42	32
C14:Mombaça	0,26	0,4	0,32	67
C15:Mulato II	0,59	0,66	0,62	82
C16:Ruziziensis	0,64	0,76	0,7	83
C17:Tanzânia	0,5	0,56	0,53	71
C18:Xaraés	0,56	0,8	0,66	81
accuracy			0,58	1259
macro avg	0,58	0,57	0,56	1259
weighted avg	0,59	0,58	0,57	1259

Tabela 18 – Relatório de classificação do modelo MobileViT treinado no *dataset* Geral

4.3.2 Datasets por Período

Nesta seção, serão apresentados os resultados do treinamento de seis modelos distintos utilizando a rede MobileViT. Cada modelo foi treinado seguindo os parâmetros definidos na Seção 3.4.3.1 com *datasets* divididos em cinco períodos de quatro datas consecutivas de imagens, além de um período específico em que as cultivares estavam em fase de inflorescência, conforme descrito na Tabela 5. O objetivo é identificar se as cultivares exibem características mais marcantes em determinados períodos. Os relatórios de classificação completos para cada um desses treinamentos estão disponíveis no Apêndice B.1. A seguir, será feita uma análise comparativa das métricas de *precision*, *recall* e *f1-score* para avaliar o desempenho dos modelos.

A Figura 34 apresenta uma comparação entre a *precision* desses modelos treinados em *datasets* de diferentes épocas de coleta. Nela observamos que o Período 5 foi o mais representativo, com 5 cultivares alcançando a maior *precision*, incluindo BRS Ipyporã (82%), BRS Tamani (86%), BRS Tupi (93%), Ruziziensis (92%) e Xaraés (83%), todas com desempenhos notáveis. O Período de Inflorescência (PI) foi o segundo com maior número de cultivares atingindo o pico de *precision*, com destaque para Humidicola Comum (93%) e Basilisk (80%), Marandu(62%) além de Mulato II (82%), que também obteve um

bom desempenho nesse período. O Período 4 apresentou o maior pico de *precision* para 5 cultivares, incluindo a Mulato II empatado com o período de inflorescência, enquanto o Período 3 teve 2 cultivares, com destaque para Llanero (89%). No Período 2, as cultivares Tanzânia(67%), BRS Quênia (60%) e Mavuno (100%) atingiram seu melhor desempenho.




Figura 34 – Comparação de *precision* dos modelos MobileVIT treinados nos *datasets* separados por período

Os melhores resultados foram observados para BRS Tupi (93% no P5), Humidicola Comum (93% no PI), Ruziziensis (92% no P5) e Mavuno, que obteve uma *precision* perfeita de 100% no Período 2. Em contrapartida, o pior resultado foi registrado para a cultivar Mombaca, com uma *precision* de apenas 45% no Período 4.

No que diz respeito ao *recall*, observado na Figura 35, é importante destacar que o Período 4 foi o que apresentou o maior número de cultivares atingindo seu melhor desempenho, com 5 delas se destacando, incluindo BRS Ipyporã (100%), BRS Quênia (61%) e Llanero (84%). O Período 5 também foi relevante, com 5 cultivares alcançando o pico de *recall*, como Humidicola Comum (100%), BRS Piatã (68%), BRS Zuri (63%) e Mulato II (80%).

O Período 3 foi eficaz para 4 cultivares, entre elas BRS Tamani (78%), Marandu (64%), e Xaraés (91%), além de BRS Tupi, que também se destacou nesse período, com *recall* de 95%. O Período de Inflorescência apresentou um ótimo desempenho para 3 cultivares, como BRS Paiaguás (83%) e Basilisk (83%), além de BRS Tupi, que manteve um *recall* de 95% também nesse período. Por outro lado, o pior resultado foi registrado para Mombaca, com um *recall* de apenas 42% no Período 5.




Figura 35 – Comparação de *recall* dos modelos MobileVIT treinados nos *datasets* separados por período

Já em relação ao *f1 score* podemos utilizar o gráfico comparativo da Figura 36. O Período 5 foi o mais representativo, com 6 cultivares alcançando seu melhor desempenho, incluindo BRS Piatã (62%), BRS Quênia (58%), BRS Zuri (59%), Mulato II (76%), Tanzânia (64%) e Mombaça (41%). O Período 4 também se destacou, com 4 cultivares atingindo os melhores resultados, como BRS Ipyporã (82%), Humidicola Comum (89%) e Ruziziensis (78%), refletindo um desempenho sólido do modelo nesse período.

O Período 3 foi eficaz para 5 cultivares, com destaque para BRS Tamani (68%), Llanero (85%), Massai (72%), BRS Tupi (78%) e Xaraés (83%). Já o Período de Inflorescência (PI) foi importante para cultivares como BRS Tupi, com a qual empatou com o Período 3, BRS Paiaguás (62%) e Basilisk (82%), que também obtiveram os melhores valores de *f1-score* nesse período. O Período 2, embora com menos cultivares, apresentou um pico de desempenho notável para Mavuno, com *f1-score* de 86%.

Em contraste, o pior resultado foi observado para Mombaça, com um *f1-score* de apenas 41% no Período 5, destacando-se como a cultivar com o menor desempenho entre todas.




Figura 36 – Comparação de *f1-score* dos modelos MobileViT treinados nos *datasets* separados por período

De modo geral o Período 5 foi o que apresentou o melhor conjunto de treino, com as cultivares sendo mais facilmente identificadas, atingindo uma acurácia de 65%, como observado na Tabela 19. Os períodos 3,4 e 5 conquistaram acurácia melhor que o modelo treinado em imagens de todos os períodos juntas (58%).

MobileViT	Accuracy	F1 - Macro avg	F1 - weighted avg	support
Período 1	0,08	0,04	0,06	111
Período 2	0,54	0,53	0,53	314
Período 3	0,63	0,62	0,62	370
Período 4	0,63	0,62	0,62	292
Período 5	0,65	0,65	0,65	331
P. Inflorescência	0,57	0,57	0,57	409

Tabela 19

4.3.3 Dataset Mesclado-Compatível

Após os experimentos com o treinamento de modelos com os *datasets* separados pelos períodos de coleta das imagens, realizou-se um novo experimento para avaliar o comportamento da rede mobileViT na identificação de padrões em um *dataset* que une exemplares do *datasets* original e do *dataset* utilizado por Fazan (FAZAN, 2020) a partir das classes semelhantes.

O treinamento desse modelo seguiu os padrões de parâmetros estabelecidos na Seção 3.4.3.2 e sua rotina de treinamento produziu as taxas de *loss* de treino e validação como apresentado na Figura 37. A última época em que houve incremento no aprendizado e diminuição da *loss* foi a 22^a e o treinamento seguiu por mais 5 épocas sem que houvesse melhorias.




Figura 37 – Loss de treino do modelo MobileViT no *dataset* Mesclado-Compatível

O desempenho do modelo apresentou variações entre as diferentes cultivares, conforme os valores de *precision*, *recall* e *f1-score*. O melhor resultado de *precision* foi obtido pela cultivar Ruziziensis, com 97%, demonstrando uma alta taxa de previsões corretas para essa classe. O *recall* mais elevado foi registrado para BRS Ipyorã, com 96%, evidenciando que quase todas as instâncias dessa cultivar foram corretamente identificadas pelo modelo. Em termos de *f1-score*, a cultivar BRS Tupi destacou-se com um valor de 91%, refletindo um ótimo equilíbrio entre *precision* e *recall*. Por outro lado, a cultivar Marandu apresentou os menores valores nas três métricas, com *precision*, *recall* e *f1-score* de 81%, indicando um desempenho mais limitado em comparação com as demais classes.

De forma geral, a acurácia do modelo foi de 88%, com uma *f1-score* média macro e ponderada de também 88%, demonstrando uma consistência satisfatória no desempenho do modelo para as diferentes cultivares. Um resultado geral bastante aceitável para a tarefa final, porém, vale destacar que esse modelo foi treinado para identificar somente 11 das 18 classes do *dataset* original as quais são compartilhadas entre os dois datasets.

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,84	0,96	0,9	278
C2:BRS Paiaguás	0,91	0,88	0,89	275
C3:BRS Piatã	0,86	0,83	0,84	282
C4:BRS Quênia	0,83	0,85	0,84	266
C5:BRS Tamani	0,9	0,9	0,9	267
C6:BRS Tupi	0,95	0,88	0,91	274
C7:BRS Zuri	0,86	0,88	0,87	269
C9:Humidicola comum	0,84	0,95	0,89	266
C11:Marandu	0,81	0,81	0,81	282
C16:Ruzizensis	0,97	0,83	0,89	279
C18:Xaraés	0,9	0,87	0,88	278
accuracy			0,88	3016
macro avg	0,88	0,88	0,88	3016
weighted avg	0,88	0,88	0,87	3016

Tabela 20 – Relatório de classificação do modelo MobileViT treinado no *dataset* Mesclado-Compatível

Separando o conjunto de teste pela origem dos exemplares, apresentada na Figura 13, percebe-se uma acurácia igualmente satisfatória para os dois conjuntos. O conjunto de teste Fazan, atingiu excelentes 89% de acurácia enquanto o conjunto de teste Original, 77%, são as melhores acurácias para ambos conjuntos até então.

A vantagem desse *dataset* é a grande quantidade e variedade de exemplares, pois ele possui imagens de todos os períodos do ano e em todos os níveis de chuva para 11 cultivares.

Conjunto de teste	accuracy	f1 - macro avg	f1 - weighted avg	support
Dataset Original	0,77	0,77	0,77	353
Dataset Fazan	0,89	0,89	0,89	1709

Tabela 21 – Relatório de classificação do modelo MobileViT treinado no *dataset* Mesclado-Compatível separando o conjunto de testes pelos *datasets* de origem

4.3.4 Dataset Mesclado-Todo

Os treinamentos procederam em uma nova rotina utilizando o modelo MobileViT em um *dataset* que une todas as imagens de todas as cultivares do *dataset* Original e do *dataset* Geral-Geral de Fazan (FAZAN, 2020). Nesse treinamento houve desbalanceamento das classes que só existiam no *dataset* original. As escolhas dos parâmetros e proporção do *dataset* utilizado para treino, teste e validação estão descritos na Seção 3.4.3.2.

As taxas de *loss* de treino e validação produzidas nas épocas desse treinamento podem ser observadas no gráfico da Figura 38. Onde se destaca as taxas da época 34, última época em que houve melhoria no aprendizado.




Figura 38 – Taxa de *loss* de treino de validação do modelo MobileViT no *dataset* Mesclado-Todo

O modelo apresentou uma acurácia geral de 82%, com desempenho variando entre as diferentes cultivares, conforme o relatório de classificação. A média macro das métricas *precision*, *recall* e *f1-score* foi de 75%, 78% e 75%, respectivamente, o que indica um bom equilíbrio entre a capacidade de identificar corretamente as cultivares e a capacidade de recuperar todas as instâncias positivas de cada cultivar. O relatório de classificação completo desse modelo pode ser analisado na Tabela 14.

Algumas cultivares, como BRS Tupi e BRS Ipyporã, obtiveram desempenhos importantes, com *f1-scores* de 82% e 91%, respectivamente. As Cultivares Humidicola comum, com 88% de *f1-score*, e Ruziziensis, com 89%, também se destacaram. Por outro lado, cultivares como Mombaça (*f1-score* de 45%) e Mavuno (42%) apresentaram os menores desempenhos, indicando dificuldades na identificação correta dessas classes. Isso pode ser explicado pela menor quantidade de exemplos disponíveis ou pelas semelhanças morfológicas dessas cultivares em comparação com as demais, principalmente as cultivares Mombaça e Zuri que já possuem alta semelhança conhecida.

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,87	0,95	0,91	278
C2:BRS Paiaguás	0,88	0,9	0,89	275
C3:BRS Piatã	0,85	0,76	0,8	282
C4:BRS Quênia	0,78	0,76	0,77	266
C5:BRS Tamani	0,82	0,87	0,84	266
C6:BRS Tupi	0,95	0,72	0,82	274
C7:BRS Zuri	0,88	0,68	0,77	269
C8:Basilisk	0,86	0,75	0,8	40
C9:Humidicola comum	0,81	0,95	0,88	266
C10:Llanero	0,67	0,85	0,75	39
C11:Marandu	0,78	0,72	0,75	281
C12:Massai	0,58	0,76	0,66	29
C13:Mavuno	0,62	0,31	0,42	16
C14:Mombaça	0,33	0,7	0,45	33
C15:Mulato II	0,54	0,83	0,65	41
C16:Ruziziensis	0,92	0,86	0,89	279
C17:Tanzânia	0,55	0,89	0,68	35
C18:Xaraés	0,81	0,86	0,83	278
accuracy			0,82	3247
macro avg			0,75	3247
weighted avg			0,83	3247

Tabela 22 – Relatório de classificação do modelo MobileVIT treinado no *dataset* Mesclado-Todo

Para entender a qualidade desse modelo ao classificar imagens de cada um dos *datasets* de origem, foram gerados dois novos relatórios de classificação que podem ser observados no Apêndice B.3. Aqui se comparará o resultado geral desses relatórios através de sua acurácia, média macro e ponderada de f-score, como apresentado na Tabela 23. Percebe-se que esse modelo atingiu uma acurácia melhor que a MobileVIT no *dataset* Original Geral (58%), *dataset* equiparável por possuir as mesmas cultivares em todo período, porém ele também foi melhor que todos os modelos MobileVIT treinados nos *datasets* separados por Período de coleta.

	accuracy	f1 - macro avg	f1 - weighted avg
Dataset Original	0,68	0,65	0,67
Dataset Fazan	0,85	0,52	0,85

Tabela 23 – Relatório de classificação do modelo MobileVIT treinado no *dataset* Mesclado-Todo separando o conjunto de testes pelos *datasets* de origem

4.3.5 Dataset Mesclado-Inflorescência

Um último experimento utilizando a arquitetura MobileVIT foi o treinamento de um modelo a partir do *dataset* que junta imagens das cultivares na fase de inflorescência

do *dataset* Original, Período de Inflorescência, que ocorre nas imagens coletadas entre 23/04/2022 e 16/09/2022, e do *dataset* Fazan, que ocorre na Área 56 no período de chuvas.

Os parâmetros para o treinamento desse modelo seguiram os definidos na Seção 3.4.3.2. O treinamento se deu por 45 épocas, nos quais o melhor modelo foi alcançado na época 35, como observado na Figura 39 que apresenta um gráfico comparativo das taxas de *loss* de treino e validação durante épocas.




Figura 39 – Taxa de *loss* de treino de validação do modelo MobileViT no *dataset* Mesclado-Inflorescência

É importante destacar que esse *dataset* possui somente 16 classes pois as cultivares Mavuno e Mulato II foram removidas para evitar o desbalanceamento dos conjuntos de dados, devido a sua existência somente no *dataset* Original. Por outro lado, nota-se leve desbalanceamento das classes BRS Tamani e Llanero que no trabalho de origem haviam sido descartadas, porém esse desbalanceamento não prejudicou o aprendizado dessas classes ou de outras, como observado na Tabela 24.

A Tabela 24 apresenta o relatório de classificação desse modelo que alcançou um balanceamento perfeito entre todas as métricas de média, com acurácia, média macro e ponderada de *precision*, *recall* e *f1-score* atingindo 87%. Um resultado excelente se comparado com os outros modelos.

Chamam a atenção as taxas de *f1-score* da cultivar Ruziziensis (96%) e Ipyporã (94%), as duas maiores taxas do relatório de classificação. A taxa de *f1-score* de sete das classes, quase metade do total, é superior ou igual a 90%. Mais uma vez as cultivares com mais dificuldade de identificação são a Mombaça (76%) e a Zuri (77%), um padrão que vem se repetindo em todos os modelos.

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,96	0,93	0,94	138
C2:BRS Paiaguás	0,93	0,9	0,92	136
C3:BRS Piatã	0,81	0,91	0,86	143
C4:BRS Quênia	0,88	0,75	0,81	134
C5:BRS Tamani	0,77	0,84	0,81	76
C6:BRS Tupi	0,86	0,9	0,88	134
C7:BRS Zuri	0,81	0,74	0,77	134
C8:Basilisk	0,84	0,96	0,89	137
C9:Humidicola comum	0,87	0,93	0,9	134
C10:Llanero	0,85	0,78	0,81	78
C11:Marandu	0,86	0,81	0,84	138
C12:Massai	0,9	0,89	0,9	133
C14:Mombaça	0,74	0,78	0,76	135
C16:Ruziziensis	0,98	0,93	0,96	138
C17:Tanzânia	0,9	0,92	0,91	136
C18:Xaraés	0,92	0,88	0,9	138
accuracy			0,87	2062
macro avg	0,87	0,87	0,87	2062
weighted avg	0,87	0,87	0,87	2062

Tabela 24 – Relatório de classificação do modelo MobileVIT treinado no *dataset* Mesclado-Inflorescência

Para analisar o comportamento desse modelo em cada um dos *datasets* que foram unidos, separou-se o conjunto de teste pela origem dos exemplares e realizou-se um novo relatório de classificação para cada um. O modelo atingiu uma acurácia de 90% para o conjunto de dados do *dataset* Fazan e 72% no *dataset* Original (Tabela 25). Isso demonstra que o aumento da quantidade e da variação de auxiliaram na melhoria da identificação das cultivares, uma vez que para a rede mobilevit no *dataset* separado nas mesmas condições (*dataset* Período de Inflorescência) a acurácia havia sido de apenas 57%, como apresentado na Tabela 19.

Conjunto de teste	Accuracy	F1 - Macro avg	F1 - weighted avg	support
Dataset Original	0,72	0,71	0,72	353
Dataset Fazan	0,9	0,89	0,9	1709

Tabela 25 – Relatório de classificação do modelo MobileVIT treinado no *dataset* Mesclado-Inflorescência separando o conjunto de testes pelos *datasets* de origem.

5 Discussão

Neste capítulo serão discutidas as hipóteses levantadas na Seção 3 que guiaram a pesquisa. Foram oito perguntas que serão analisadas e respondidas a partir dos resultados obtidos na Seção 4.

Pergunta 1: *Novas arquiteturas de redes neurais e o novo conjunto de dados apresentam melhoria na classificação de cultivares em relação a Mobilenet V2 e o conjunto de Fazan (FAZAN, 2020)?*

Para responder essa pergunta de forma justa, dadas as características de cada *dataset*, serão comparados os resultados da Área Geral em todos os períodos do trabalho Fazan (FAZAN, 2020) que utiliza MobileNet V2 e o resultado do Período Geral utilizando a MobileNet V3 e a MobileViT desse trabalho.

A Tabela 3 apresenta uma compilação das taxas de acerto de Fazan (FAZAN, 2020) na qual podemos observar que a taxa de acerto da MobileNet V2 no *dataset* Fazan Geral no período Geral foi de 53%. Enquanto isso a Tabela 9 mostra que o modelo MobileNet V3 treinado no *dataset* Geral original desse trabalho atingiu uma taxa de acerto de 69%. Por fim, a Tabela 18 apresenta a taxa de acerto de 58% do modelo MobileViT no mesmo *dataset*.

A partir dessa comparação, pode-se afirmar que o novo conjunto de dados e as novas arquiteturas utilizadas trouxeram melhorias nas taxas de acerto de identificação de cultivares, com o modelo MobileNET V3 conquistando a melhor taxa de acerto nos *datasets* que concatenam as imagens por cultivar. Esse resultado por si só já demonstra a melhora, porém vale destacar que o modelo Fazan (FAZAN, 2020) Geral-Geral foi treinado para identificar apenas 11 classes contra os outros modelos que foram treinados para 18.

Pergunta 2: *Cultivares da mesma espécie, apesar de muito semelhantes na fase adulta, possuem uma idade em comum em que apresentam diferenças morfológicas suficientes para a sua diferenciação?*

Analisando as cultivares da espécie *Brachiaria brizantha*, as cultivares BRS Paiaçuás, BRS Piatã, Marandu e Xaraés, no gráfico da Figura 29 pode-se afirmar que, para a rede MobileNet, sim.

As cultivares BRS Piatã e Xaraés possuem o período mais representativo como sendo o período 5, para a cultivar Paiaguás é o período 4 que também é próximo do 5 e possui duas datas de imagem em comum. Porém a cultivar Marandu possui *f1-score* baixa para esse período, representando que está sendo confundida nessa idade com outras cultivares o que não acontece tanto no período 1 já que possui *f1-score* melhor.

Uma situação similar ocorre nessas plantas com a rede MobileViT, enquanto as cultivares BRS Piatã e BRS Paiaguás possuem maior representatividade no período 5, a Xaraés possui no período 3 e a Marandu no período de inflorescência seguido também pelo período 3.

Pergunta 3: *No estágio adulto, a inflorescência pode aparecer em diferentes períodos e apresentar características morfológicas importantes para identificação da cultivar?*

As inflorescências podem começar a aparecer em períodos diferentes, como observado na Figura 40. Nela percebe-se que a cultivar BRS Paiaguás já apresenta inflorescência no dia 23/04/2022, data pertencente ao Período 2, enquanto a cultivar Ipyporã começou a apresentar inflorescência no dia 21/05/2022, data pertencente ao Período 3.



Figura 40 – Comparação de exemplares de BRS Paiaguás (parcela 312) e BRS Ipyporã (parcela 304)

Analisando a Figura 29, a Figura 36 e seus relatórios de classificação (Apêndice A.1 e Apêndice B.1) percebe-se que, tanto para os modelos treinados da MobileNet quanto para os modelos treinados da MobileViT, essa característica foi indiferente pois em ambos os casos a *f1-score* foi melhor no Período 3 para as duas cultivares.

Pergunta 4: *O modelo é capaz de aprender a classificar cultivares e suas idades?*

O primeiro experimento buscou treinar uma rede MobileNet V3 em um *dataset* onde as classes são as cultivares em diferentes idades, cujos resultados são apresentados na Tabela 8. Buscava-se classificar idade e cultivar mas se obteve uma baixa taxa de acerto (24%) para essas classes devido a baixa quantidade de exemplares. Apesar disso, o relatório consegue trazer informações relevantes sobre, por exemplo, as idades em que a cultivar Llanero pode ser melhor diferenciada de outras cultivares, como na data 29/10/2022 que a cultivar Llanero obteve 100% de *precision*.

Esse resultado aponta que dificilmente com os dados atuais o modelo poderá obter uma boa taxa de acerto para esse problema, porém comprova que existem idades em que as cultivares são mais representativas e fáceis de identificar.

Por isso, realizou-se o experimento em que se treinou modelos MobileNet e MobileViT em *datasets* separados por períodos de 4 datas consecutivas e por inflorescência aparente, assim aumentando a quantidade de exemplares e buscando aproveitar das idades mais representativas.

O gráfico da Figura 41 compara a taxa de acerto desses modelos nesses *datasets*. Analisando o gráfico é possível afirmar que para ambas arquiteturas houve melhor aprendizado das classes no *dataset* do Período 5, que possui imagens do dia 09/09/2022 a 29/10/2022.




Figura 41 – Comparação de taxa de acerto entre MobileNet e MobileViT nos *datasets* separados por períodos

Pergunta 5: *Sabendo a idade da cultivar, o modelo apresenta melhoria na identificação das cultivares?*

Para responder essa pergunta, é preciso analisar a Tabela 26 que compara a melhor taxa de acerto dos modelos MobileNet e MobileViT treinados nos *datasets* por Período e Geral.

É possível afirmar que, para a rede MobileNet, separar o *dataset* por idade não produziu melhores resultados. Pois no Período 5, onde a taxa de acerto atinge seu pico (66%) nos modelos por Período (Tabela 11), o modelo não foi capaz de superar a taxa de acerto de 69% do modelo treinado no *dataset* Geral.

O mesmo não pode ser dito da rede MobileViT, pois no Período 5 a taxa de acerto de 65% superou os 57% do modelo Geral. Isso pode ter acontecido devido a ineficiência

da Rede MobileVIT em classificar cultivares do período 1 (Tabela 19), onde atingiu taxa de acerto de 8%.

Essa taxa de acerto baixa no Período 1 da MobileVIT pode ocorrer devido a característica desses modelos de precisarem de mais dados para um melhor aprendizado (MEHTA; RASTEGARI, 2021) e como os estádios iniciais das cultivares apresentam mais alterações morfológicas dia a dia em relação aos estádios mais avançados, há assim poucos exemplares com semelhança elevada nesse período.

	Tx. de acerto do melhor Período	Tx. de acerto do <i>dataset</i> Geral
MobileNet	66% (P5)	69%
MobileVIT	65% (P5)	57%

Tabela 26 – Comparação entre a melhor taxa de acerto de modelos MobileNet e MobileVIT treinados por período e geral

Pergunta 6: *A fase de inflorescência proporciona diferenças morfológicas significativas para facilitar que o modelo distinga melhor as cultivares e aumentar a taxa de acerto da classificação?*

Os modelos MobileNet e MobileVIT não apresentaram melhorias de taxa de acerto quando treinados no *dataset* Original no Período de Inflorescência, afirmação que pode ser aferida ao analisar a Tabela 11 e a Tabela 19.

Pergunta 7: *Aumentar a quantidade e a variedade de exemplares das classes poderia melhorar o aprendizado dos modelos e aumentar a taxa de acerto da classificação?*

Buscou-se aumentar a quantidade e variedade de exemplares através da união do *dataset* Original e dos *datasets* concedidos por Fazan (FAZAN, 2020). Foi possível gerar três *datasets* a partir disso, o *dataset* Mesclado-Todo, o Mesclado-Compatível e o Mesclado Inflorescência.

O *dataset* Mesclado-Todo une todas as classes de ambos *datasets*, nele há desbalanceamento de 7 classes por existirem somente no *dataset* Original. O *dataset* Mesclado-Compatível une apenas as classes em comum entre os *dataset*, totalizando 11 classes. Enquanto o *dataset* Mesclado-Compatível utiliza somente imagens de uma das Áreas em um Período onde há Inflorescência do *dataset* Fazan (FAZAN, 2020) e as imagens do Período de Inflorescência do *dataset* Original, descartando 2 cultivares que existiam apenas no *dataset* Original.

Desse modo, o resultado do aprendizado desses modelos pode ser comparado através da Tabela 27 que utiliza como métrica a taxa de acerto. Utilizando a taxa de acerto dos modelos na classificação do *dataset* original, visto que o modelo treinado somente nesses dados (*Dataset* Geral) atingiu 69%, pode-se afirmar que para a MobileNet o aumento de exemplares não ajudou no aprendizado de padrões das cultivares. Porém, a MobileVIT

apresentou melhorias em todos os modelos treinados nesses *datasets*.

	<i>Dataset</i> Mesclado	<i>Dataset</i> Original	<i>Dataset</i> Fazan
MobileNet Mesclado- Todo	75%	56%	80%
MobileNet Mesclado Compatível	78%	67%	80%
MobileNet Mesclado- Inflorescência	82%	61%	87%
MobileViT Mesclado- Todo	82%	68%	85%
MobileViT Mesclado Compatível	88%	77%	89%
MobileViT Mesclado- Inflorescência	87%	72%	90%

Tabela 27 – Comparação de taxas de acerto entre todos os modelos treinados nos *datasets* Mesclados

Pergunta 8: *Foi alcançado um modelo com nível de taxa de acerto razoável e leve suficiente para implementação em um aplicativo web para dispositivos móveis?*

Sim, foi alcançado um modelo com nível de taxa de acerto satisfatório e leve o suficiente para implementação em um aplicativo web para dispositivos móveis. Dois modelos MobileViT foram obtidos a partir da mesclagem do *dataset* Original e do *dataset* Fazan (FAZAN, 2020), com resultados promissores tanto em termos de taxa de acerto quanto em generalização. O primeiro modelo, treinado para identificar 11 cultivares em qualquer época do ano e idade, atingiu 88% de taxa de acerto e demonstrou excelente capacidade de generalização para o *dataset* original, com uma taxa de acerto de 77%. Esse resultado evidencia que o modelo pode ser implementado eficientemente em dispositivos móveis, garantindo um desempenho razoável em diferentes condições.

O segundo modelo, focado na fase de inflorescência de 16 cultivares, alcançou uma taxa de acerto de 87%, o que também representa um desempenho significativo. No entanto, sua capacidade de generalização para o *dataset* original foi um pouco inferior, com uma taxa de acerto de 72%. Esse comportamento pode ser atribuído à quantidade de cultivares, aumentando a possibilidade de confusão entre elas, principalmente a existências das cultivares BRS Zuri e Mombaça que possuem a maior taxa de confusão (Tabela 10). Apesar disso, ambos os modelos demonstraram ser leves e precisos, adequados para a aplicação proposta.

6 Conclusão

Este estudo apresentou uma análise detalhada sobre a utilização de redes neurais para a classificação de imagens de cultivares de forrageiras tropicais, com foco na comparação de arquiteturas de redes, como MobileNet V3 e MobileViT, e a construção de novos conjuntos de dados. O desenvolvimento dos modelos foi orientado para fornecer uma solução prática e eficiente que possa ser implementada no aplicativo Pasto Certo, beneficiando produtores e especialistas no manejo de pastagens.

Através dos resultados obtidos, foi possível constatar que a MobileNet V3 apresentou uma melhoria significativa na identificação de cultivares em relação a taxa de acerto comparando ao modelo V2 (FAZAN, 2020). Os novos dados e a arquitetura MobileViT também trouxeram avanços, com a arquitetura MobileViT apresentando os melhores resultados nos conjuntos de dados maiores (mesclados).

Contudo, um desafio particular foi observado na distinção entre cultivares com alta similaridade morfológica, como as cultivares BRS Zuri e Mombaça. A análise da fase de inflorescência revelou que essa etapa proporciona diferenças morfológicas importantes para melhorar a taxa de acerto da classificação, embora os modelos ainda enfrentem dificuldades com a generalização, sobretudo quando há maior número de cultivares.

Com base nas questões levantadas, identificou-se que o estágio adulto e a inflorescência das cultivares são cruciais para melhorar o aprendizado dos modelos. Além disso, o aumento da quantidade e da variedade de exemplares nos conjuntos de dados apresentou melhorias na taxa de acerto, sendo mais efetivo para a MobileViT do que para a MobileNet.

6.1 Dificuldades e Limitações

A principal dificuldade e limitação desse trabalho foi formar um banco de imagens coletando imagens da área de experimentação por oito meses, de forma a categorizar a evolução do crescimento das cultivares antes que fosse possível realizar os experimentos para avaliar a hipótese. Além disso, vale destacar que o estudo sofreu as dificuldades impostas pela pandemia de covid-19 devido às medidas de segurança, como o plantio tardio das cultivares e o trânsito controlado na área de experimentação. Outro fator importante, foi a complexidade do domínio e a falta de estudos relacionados na literatura.

6.2 Principais Contribuições

As principais contribuições deste trabalho incluem :

- Construção de um banco de imagens contendo 18 cultivares em diferentes estádios de desenvolvimento, oferecendo um novo conjunto de dados para pesquisas futuras.
- Aplicação de arquiteturas modernas de redes neurais, como MobileNet V3 e MobileViT, que geraram melhorias significativas na taxa de acerto da classificação de cultivares.
- A MobileNet V3 apresentou um aumento de até 19% na taxa de acerto em comparação com a MobileNet V2 em *dataset* similar.
- Identificação da fase de inflorescência como crítica para melhorar a taxa de acerto, permitindo que a MobileViT atingisse até 87% de *precision* e *recall*.
- Desenvolvimento de modelos leves e eficientes, adequados para implementação em aplicativos web e mobile, facilitando a identificação automatizada de cultivares no campo.

6.3 Trabalhos Futuros

O banco de imagens construído proporciona oportunidades de estudos para melhorar ainda mais a tarefa de classificação automatizada de cultivares. Dentre as sugestões, está a exploração das características morfológicas dessas plantas, realizando um trabalho de segmentação e rotulação das imagens em, por exemplo, colmo, inflorescência, bainha e folhas das cultivares. Outra hipótese seria a utilização de mais de uma imagem para a classificação, como por exemplo, uma imagem com o colmo destacado e uma imagem com a inflorescência. Além, claro, de experimentos com novas arquiteturas de redes neurais e técnicas de *data augmentation*.

Referências

- ABIEC. *Beef Report 2023*. 2023. Acesso em: 26 de outubro de 2024. Disponível em: <https://www.abiec.com.br/publicacoes/beef-report-2023/>.
- BARRIOS, S. et al. Pasto certo-versão 3.0: aplicativo para dispositivos móveis e desktop sobre forrageiras tropicais. *Embrapa Gado de Corte-Comunicado Técnico (INFOTECA-E)*, Campo Grande, MS: Embrapa Gado de Corte, 2021., 2021.
- BARRIOS, S. et al. Pasto certo-versão 1.0® aplicativo para dispositivos móveis sobre forrageiras tropicais. *Embrapa Gado de Corte-Comunicado Técnico (INFOTECA-E)*, Brasília, DF: Embrapa, 2017., 2017.
- BOUGUETTAYA, A. et al. Deep learning techniques to classify agricultural crops through uav imagery: A review. *Neural computing and applications*, Springer, v. 34, n. 12, p. 9511–9536, 2022.
- COSTA, N. d. L. et al. Fisiologia e manejo de plantas forageiras. *Embrapa Rondônia-Documentos (INFOTECA-E)*, Porto Velho: Embrapa Rondônia, 2004., 2004.
- DOSOVITSKIY, A. et al. *An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale*. 2021. Disponível em: <https://arxiv.org/abs/2010.11929>.
- FAN, L. et al. Pavement defect detection with deep learning: A comprehensive survey. *IEEE Transactions on Intelligent Vehicles*, IEEE, 2023.
- FAZAN, L. G. Exploração de arquiteturas de redes neurais convolucionais para identificação de forrageiras do gênero bachiaria e panicum. Fundação Universidade Federal de Mato Grosso do Sul, 2020.
- FONTANELI, R. S.; SANTOS, H. P. dos. Forrageiras para integração lavoura-pecuária-floresta na região sul-brasileira. *Embrapa Trigo-Livro científico (ALICE)*, Passo Fundo: Embrapa Trigo, 2012., 2012.
- GOMAA, W.; KHAMIS, M. A. A perspective on human activity recognition from inertial motion data. *Neural Computing and Applications*, Springer, v. 35, n. 28, p. 20463–20568, 2023.
- GOODFELLOW, I. J.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016. <http://www.deeplearningbook.org>.
- HE, K. et al. *Deep Residual Learning for Image Recognition*. 2015. Disponível em: <https://arxiv.org/abs/1512.03385>.
- HOWARD, A. et al. *Searching for MobileNetV3*. 2019. Disponível em: <https://arxiv.org/abs/1905.02244>.
- HOWARD, A. G. et al. *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications*. 2017. Disponível em: <https://arxiv.org/abs/1704.04861>.

- LANDOLA, F. N. et al. *SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size*. 2016. Disponível em: <https://arxiv.org/abs/1602.07360>.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. In: PEREIRA, F. et al. (Ed.). *Advances in Neural Information Processing Systems*. Curran Associates, Inc., 2012. v. 25. Disponível em: https://proceedings.neurips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf.
- LECUN, Y. et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, v. 86, n. 11, p. 2278–2324, 1998.
- LI, X.; XIANG, Y.; LI, S. Combining convolutional and vision transformer structures for sheep face recognition. *Computers and Electronics in Agriculture*, Elsevier, v. 205, p. 107651, 2023.
- LI, Z.; DIB, O. Empowering brain tumor diagnosis through explainable deep learning. *Machine Learning and Knowledge Extraction*, MDPI, v. 6, n. 4, p. 2248–2281, 2024.
- LIU, J. et al. Automated recognition of snow-covered and icy road surfaces based on t-net of mount tianshan. *Remote Sensing*, MDPI, v. 16, n. 19, p. 3727, 2024.
- LOPES, I. D.; BASSO, D. Análise dos principais entraves para as exportações brasileiras de carne bovina. *Salão do Conhecimento*, 2016.
- LOSHCHILOV, I.; HUTTER, F. *Decoupled Weight Decay Regularization*. 2019. Disponível em: <https://arxiv.org/abs/1711.05101>.
- LUCIMARA, C. Mercado ilegal de sementes forrageiras: perda para toda a cadeia. Embrapa Gado de Corte, 2015.
- MEHTA, S.; RASTEGARI, M. Mobilevit: light-weight, general-purpose, and mobile-friendly vision transformer. *arXiv preprint arXiv:2110.02178*, 2021.
- MITCHELL, T. M. *Machine Learning*. [S.l.]: McGraw-Hill, 1997.
- OMOTE, H. d. S. G. et al. Monitoramento tecnológico de cultivares de forrageiras no brasil. Embrapa Southeast Livestock, 2021.
- OSCO, L. P. et al. A review on deep learning in uav remote sensing. *International Journal of Applied Earth Observation and Geoinformation*, Elsevier, v. 102, p. 102456, 2021.
- PATTERSON, J.; GIBSON, A. *Deep Learning: A Practitioner's Approach*. 1st. ed. [S.l.]: O'Reilly Media, Inc., 2017. ISBN 1491914254.
- PERON, A. J.; EVANGELISTA, A. R. et al. Degradação de pastagens em regiões de cerrado. *Ciência e Agrotecnologia*, v. 28, n. 3, p. 655–661, 2004.
- PIRES, A. V. E. Bovinocultura de corte. In: _____. Piracicaba: FEALQ, 2010. cap. 19, p. 375–419.
- QIU, H. et al. Mob-ppsp: modified mobilenet-v2 network for real-time detection of tomato diseases. *Journal of Real-Time Image Processing*, Springer, v. 21, n. 5, p. 181, 2024.

SAHA, S. S.; SANDHA, S. S.; SRIVASTAVA, M. Machine learning for microcontroller-class hardware: A review. *IEEE Sensors Journal*, IEEE, v. 22, n. 22, p. 21362–21390, 2022.

SANDLER, M. et al. *MobileNetV2: Inverted Residuals and Linear Bottlenecks*. 2019. Disponível em: <https://arxiv.org/abs/1801.04381>.

ZEILER, M. D.; FERGUS, R. *Visualizing and Understanding Convolutional Networks*. 2013. Disponível em: <https://arxiv.org/abs/1311.2901>.

Apêndices

APÊNDICE A – MobileNet V3

A.1 Apêndices - Classification Reports de treinamentos separados por períodos

class	precision	recall	f1-score	support
C1:BRS Ipyporã	0,67	0,4	0,5	10
C2:BRS Paiaguás	0,08	0,12	0,1	8
C3:BRS Piatã	0,31	0,4	0,35	10
C4:BRS Quênia	0	0	0	0
C5:BRS Tamani	0	0	0	0
C6:BRS Tupi	0	0	0	7
C7:BRS Zuri	0	0	0	2
C8:Basilisk	0,48	0,91	0,62	11
C9:Humidicola comum	0	0	0	2
C10:Llanero	0,15	0,2	0,17	10
C11:Marandu	0,5	0,5	0,5	10
C12:Massai	0	0	0	1
C13:Mavuno	0	0	0	0
C14:Mombaça	0	0	0	2
C15:Mulato II	0,71	0,45	0,56	11
C16:Ruziziensis	0,47	0,64	0,54	11
C17:Tanzânia	0,33	0,2	0,25	5
C18:Xaraés	0,2	0,09	0,12	11
accuracy			0,36	111
macro avg	0,26	0,26	0,25	111
weighted avg	0,35	0,36	0,34	111

Tabela 28 – Classification Report da MobileNet V3 treinada no dataset Período 1

class	precision	recall	f1-score	support
C1:BRS Ipyporã	0,56	0,67	0,61	21
C2:BRS Paiaguás	0,33	0,27	0,3	22
C3:BRS Piatã	0,5	0,53	0,51	19
C4:BRS Quênia	0,4	0,5	0,44	12
C5:BRS Tamani	0,29	0,18	0,22	11
C6:BRS Tupi	0,59	0,68	0,63	19
C7:BRS Zuri	0,09	0,07	0,08	15
C8:Basilisk	0,71	0,87	0,78	23
C9:Humidicola comum	0,5	0,4	0,44	10
C10:Llanero	0,67	0,67	0,67	21
C11:Marandu	0,47	0,61	0,53	23
C12:Massai	0,6	0,46	0,52	13
C13:Mavuno	0,5	0,5	0,5	4
C14:Mombaça	0,26	0,26	0,26	19
C15:Mulato II	0,62	0,62	0,62	21
C16:Ruziziensis	0,88	0,68	0,77	22
C17:Tanzânia	0,57	0,67	0,62	18
C18:Xaraés	0,59	0,48	0,53	21
accuracy			0,53	314
macro avg	0,51	0,51	0,5	314
weighted avg	0,53	0,53	0,52	314

Tabela 29 – Classification Report da MobileNet V3 treinada no dataset Período 2

class	precision	recall	f1-score	support
C1:BRS Ipyporã	0,75	0,88	0,81	24
C2:BRS Paiaguás	0,59	0,65	0,62	20
C3:BRS Piatã	0,5	0,79	0,61	24
C4:BRS Quênia	0,47	0,47	0,47	17
C5:BRS Tamani	0,22	0,11	0,15	18
C6:BRS Tupi	0,74	0,74	0,74	19
C7:BRS Zuri	0,33	0,21	0,26	19
C8:Basilisk	0,61	0,64	0,62	22
C9:Humidicola comum	0,61	0,74	0,67	19
C10:Llanero	0,81	0,62	0,7	21
C11:Marandu	0,44	0,56	0,49	25
C12:Massai	0,63	0,67	0,65	18
C13:Mavuno	0,5	0,5	0,5	10
C14:Mombaça	0,45	0,5	0,48	20
C15:Mulato II	0,87	0,54	0,67	24
C16:Ruziziensis	0,69	0,72	0,71	25
C17:Tanzânia	0,56	0,39	0,46	23
C18:Xaraés	0,65	0,68	0,67	22
accuracy			0,59	370
macro avg	0,58	0,58	0,57	370
weighted avg	0,59	0,59	0,58	370

Tabela 30 – Classification Report da MobileNet V3 treinada no dataset Período 3

class	precision	recall	f1-score	support
C1:BRS Ipyporã	0,52	0,71	0,6	17
C2:BRS Paiaguás	0,59	0,87	0,7	15
C3:BRS Piatã	0,68	0,65	0,67	20
C4:BRS Quênia	0,88	0,39	0,54	18
C5:BRS Tamani	0,46	0,67	0,55	18
C6:BRS Tupi	0,76	0,93	0,84	14
C7:BRS Zuri	0,24	0,33	0,28	15
C8:Basilisk	0,73	0,73	0,73	15
C9:Humidicola comum	0,81	0,76	0,79	17
C10:Llanero	0,86	0,63	0,73	19
C11:Marandu	0,62	0,28	0,38	18
C12:Massai	0,85	0,73	0,79	15
C13:Mavuno	0,75	0,6	0,67	10
C14:Mombaça	0,25	0,2	0,22	15
C15:Mulato II	0,54	0,44	0,48	16
C16:Ruziziensis	0,65	1	0,79	17
C17:Tanzânia	0,58	0,5	0,54	14
C18:Xaraés	0,63	0,63	0,63	19
accuracy			0,61	292
macro avg	0,63	0,61	0,61	292
weighted avg	0,64	0,61	0,61	292

Tabela 31 – Classification Report da MobileNet V3 treinada no dataset Período 4

class	precision	recall	f1-score	support
C1:BRS Ipyporã	0,83	0,79	0,81	19
C2:BRS Paiaguás	0,71	0,59	0,65	17
C3:BRS Piatã	0,75	0,79	0,77	19
C4:BRS Quênia	0,47	0,42	0,44	19
C5:BRS Tamani	0,61	0,65	0,63	17
C6:BRS Tupi	0,89	0,8	0,84	20
C7:BRS Zuri	0,31	0,22	0,26	18
C8:Basilisk	0,67	0,84	0,74	19
C9:Humidicola comum	0,86	1	0,93	19
C10:Llanero	0,89	0,84	0,86	19
C11:Marandu	0,5	0,33	0,4	18
C12:Massai	0,65	0,68	0,67	19
C13:Mavuno	0,47	0,56	0,51	16
C14:Mombaça	0,38	0,44	0,41	18
C15:Mulato II	0,61	0,7	0,65	20
C16:Ruziziensis	0,71	0,83	0,77	18
C17:Tanzânia	0,58	0,58	0,58	19
C18:Xaraés	0,93	0,76	0,84	17
accuracy			0,66	331
macro avg	0,66	0,66	0,65	331
weighted avg	0,66	0,66	0,66	331

Tabela 32 – Classification Report da MobileNet V3 treinada no dataset Período 5

A.2 Apêndices - Classification Reports do modelo Mesclado-Compatível separado por dataset de origem

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0.80	0.79	0.79	85
C2:BRS Paiaguás	0.80	0.70	0.75	82
C3:BRS Piatã	0.62	0.65	0.63	74
C4:BRS Quênia	0.48	0.56	0.51	63
C5:BRS Tamani	0.76	0.67	0.71	66
C6:BRS Tupi	0.90	0.60	0.72	77
C7:BRS Zuri	0.51	0.54	0.53	70
C9:Humidicola comum	0.56	0.92	0.70	48
C11:Marandu	0.61	0.57	0.59	83
C16:Ruziziensis	0.72	0.84	0.78	74
C18:Xaraés	0.70	0.63	0.66	81
accuracy			0.67	803
macro avg	0.68	0.68	0.67	803
weighted avg	0.69	0.67	0.67	803

Tabela 33 – Classification Report do modelo Mesclado compatível para o conjunto de teste retirado do dataset Original

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0.90	0.91	0.90	471
C2:BRS Paiaguás	0.87	0.82	0.85	468
C3:BRS Piatã	0.68	0.82	0.75	490
C4:BRS Quênia	0.73	0.76	0.74	469
C5:BRS Tamani	0.84	0.85	0.84	468
C6:BRS Tupi	0.84	0.78	0.81	470
C7:BRS Zuri	0.75	0.76	0.76	468
C9:Humidicola comum	0.80	0.88	0.84	485
C11:Marandu	0.77	0.65	0.71	480
C16:Ruziziensis	0.88	0.87	0.87	484
C18:Xaraés	0.79	0.70	0.74	475
accuracy			0.80	5228
macro avg	0.80	0.80	0.80	5228
weighted avg	0.80	0.80	0.80	5228

Tabela 34 – Classification Report do modelo Mesclado compatível para o conjunto de teste retirado do dataset Fazan

A.3 Apêndices - Classification Reports do modelo Mesclado-*Todo* separado por dataset de origem

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0.69	0.56	0.62	80
C2:BRS Paiaguás	0.51	0.54	0.53	74
C3:BRS Piatã	0.50	0.79	0.61	81
C4:BRS Quênia	0.60	0.60	0.60	55
C5:BRS Tamani	0.51	0.65	0.57	57
C6:BRS Tupi	0.47	0.89	0.61	65
C7:BRS Zuri	0.27	0.28	0.28	68
C8:Basilisk	0.79	0.62	0.70	79
C9:Humidicola comum	0.79	0.40	0.53	67
C10:Llanero	0.74	0.61	0.67	79
C11:Marandu	0.54	0.35	0.43	79
C12:Massai	0.77	0.57	0.65	58
C13:Mavuno	0.55	0.34	0.42	32
C14:Mombaça	0.30	0.30	0.30	67
C15:Mulato II	0.62	0.64	0.63	81
C16:Ruziziensis	0.65	0.76	0.70	86
C17:Tanzânia	0.56	0.50	0.53	70
C18:Xaraés	0.65	0.62	0.64	72
accuracy			0.57	1250
macro avg	0.58	0.56	0.56	1250
weighted avg	0.59	0.57	0.56	1250

Tabela 35 – Classification Report do modelo Mesclado compatível para o conjunto de teste retirado do dataset Original

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0.89	0.92	0.90	476
C2:BRS Paiaguás	0.83	0.87	0.85	476
C3:BRS Piatã	0.77	0.70	0.73	483
C4:BRS Quênia	0.78	0.59	0.67	477
C5:BRS Tamani	0.81	0.87	0.84	478
C6:BRS Tupi	0.80	0.88	0.84	483
C7:BRS Zuri	0.71	0.81	0.76	471
C8:Basilisk	0.00	0.00	0.00	0
C9:Humidicola comum	0.87	0.85	0.86	466
C10:Llanero	0.00	0.00	0.00	0
C11:Marandu	0.66	0.74	0.70	485
C12:Massai	0.00	0.00	0.00	0
C13:Mavuno	0.00	0.00	0.00	0
C14:Mombaça	0.00	0.00	0.00	0
C15:Mulato II	0.00	0.00	0.00	0
C16:Ruziziensis	0.85	0.84	0.84	472
C17:Tanzânia	0.00	0.00	0.00	0
C18:Xaraés	0.82	0.69	0.75	484
accuracy			0.80	5251
macro avg	0.59	0.58	0.58	5251
weighted avg	0.80	0.80	0.79	5251

Tabela 36 – Classification Report do modelo Mesclado compatível para o conjunto de teste retirado do dataset Fazan

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,64	0,36	0,46	25
C2:BRS Paiaguás	0,52	0,65	0,58	23
C3:BRS Piatã	0,46	0,73	0,57	26
C4:BRS Quênia	0,27	0,33	0,3	21
C5:BRS Tamani	0,47	0,76	0,58	21
C6:BRS Tupi	0,87	0,95	0,91	21
C7:BRS Zuri	0,32	0,32	0,32	22
C8:Basilisk	0,56	0,38	0,45	24
C9:Humidicola comum	0,78	0,86	0,82	21
C10:Llanero	0,67	0,72	0,69	25
C11:Marandu	0,43	0,35	0,38	26
C12:Massai	0,68	0,85	0,76	20
C13:Mavuno	0,33	0,42	0,37	12
C14:Mombaça	0,41	0,3	0,35	23
C15:Mulato II	0,56	0,21	0,3	24
C16:Ruziziensis	0,78	0,81	0,79	26
C17:Tanzânia	0,47	0,67	0,55	24
C18:Xaraés	0,67	0,16	0,26	25
accuracy			0,54	409
macro avg	0,55	0,55	0,52	409
weighted avg	0,56	0,54	0,52	409

A.4 Apêndices - Classification Reports do modelo Mesclado-Inflorescência nos conjuntos separados pelo dataset de origem

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,77	0,89	0,83	27
C2:BRS Paiaguás	0,73	0,57	0,64	28
C3:BRS Piatã	0,64	0,62	0,63	26
C4:BRS Quênia	0,35	0,35	0,35	20
C5:BRS Tamani	0,46	0,7	0,56	27
C6:BRS Tupi	0,86	0,82	0,84	22
C7:BRS Zuri	0,5	0,33	0,4	21
C8:Basilisk	0,82	0,86	0,84	21
C9:Humidicola comum	0,79	0,83	0,81	18
C10:Llanero	0,83	0,86	0,84	22
C11:Marandu	0,5	0,39	0,44	28
C12:Massai	0,68	0,87	0,76	15
C14:Mombaça	0,18	0,08	0,11	26
C16:Ruziziensis	0,89	0,57	0,7	28
C17:Tanzânia	0,3	0,57	0,39	23
C18:Xaraés	0,67	0,67	0,67	24
accuracy				0,61
macro avg				0,61
weighted avg				0,6

Tabela 37 – Classification Report do modelo Mesclado Inflorescência para o conjunto de teste retirado do dataset Original

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,92	0,99	0,95	110
C2:BRS Paiaguás	0,99	0,86	0,92	108
C3:BRS Piatã	0,9	0,81	0,85	117
C4:BRS Quênia	0,84	0,86	0,85	114
C5:BRS Tamani	0,88	0,76	0,82	50
C6:BRS Tupi	0,86	0,91	0,88	111
C7:BRS Zuri	0,87	0,71	0,78	113
C8:Basilisk	0,93	0,89	0,91	116
C9:Humidicola comum	0,95	0,81	0,87	116
C10:Llanero	0,67	0,86	0,75	57
C11:Marandu	0,83	0,88	0,85	110
C12:Massai	0,88	0,89	0,89	118
C14:Mombaça	0,68	0,91	0,78	109
C16:Ruziziensis	0,94	0,92	0,93	110
C17:Tanzânia	0,9	0,86	0,88	113
C18:Xaraés	0,87	0,89	0,88	114
accuracy				0,87
macro avg				0,87
weighted avg				0,87

Tabela 38 – Classification Report do modelo Mesclado Inflorescência para o conjunto de teste retirado do dataset Fazan

APÊNDICE B – MobileVIT

B.1 Apêndices - Classification Reports de treinamentos separados por períodos

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,08	0,2	0,12	10
C2:BRS Paiaguás	0	0	0	9
C3:BRS Piatã	0	0	0	9
C4:BRS Quênia	0	0	0	0
C5:BRS Tamani	0	0	0	0
C6:BRS Tupi	0	0	0	6
C7:BRS Zuri	0	0	0	2
C8:Basilisk	0,17	0,18	0,17	11
C9:Humidicola comum	0	0	0	2
C10:Llanero	0,05	0,2	0,08	10
C11:Marandu	0	0	0	11
C12:Massai	0	0	0	1
C13:Mavuno	0	0	0	0
C14:Mombaça	0	0	0	2
C15:Mulato II	0,08	0,09	0,08	11
C16:Ruziziensis	0	0	0	11
C17:Tanzânia	0	0	0	5
C18:Xaraés	0,15	0,18	0,17	11
accuracy			0,08	111
macro avg	0,04	0,06	0,04	111
weighted avg	0,05	0,08	0,06	111

Tabela 39 – Classification Report da MobileVIT treinada no dataset Período 1

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,55	0,52	0,54	21
C2:BRS Paiaguás	0,48	0,45	0,47	22
C3:BRS Piatã	0,61	0,58	0,59	19
C4:BRS Quênia	0,6	0,25	0,35	12
C5:BRS Tamani	0,5	0,45	0,48	11
C6:BRS Tupi	0,7	0,84	0,76	19
C7:BRS Zuri	0,1	0,07	0,08	15
C8:Basilisk	0,5	0,61	0,55	23
C9:Humidicola comum	0,38	0,3	0,33	10
C10:Llanero	0,47	0,67	0,55	21
C11:Marandu	0,43	0,43	0,43	23
C12:Massai	0,69	0,69	0,69	13
C13:Mavuno	1	0,75	0,86	4
C14:Mombaça	0,33	0,37	0,35	19
C15:Mulato II	0,62	0,71	0,67	21
C16:Ruzizensis	0,63	0,77	0,69	22
C17:Tanzânia	0,67	0,33	0,44	18
C18:Xaraés	0,71	0,71	0,71	21
accuracy			0,54	314
macro avg	0,55	0,53	0,53	314
weighted avg	0,54	0,54	0,53	314

Tabela 40 – Classification Report da MobileVIT treinada no dataset Período 2

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,65	0,71	0,68	24
C2:BRS Paiaguás	0,6	0,45	0,51	20
C3:BRS Piatã	0,5	0,5	0,5	24
C4:BRS Quênia	0,43	0,35	0,39	17
C5:BRS Tamani	0,61	0,78	0,68	18
C6:BRS Tupi	0,67	0,95	0,78	19
C7:BRS Zuri	0,38	0,26	0,31	19
C8:Basilisk	0,68	0,68	0,68	22
C9:Humidicola comum	0,81	0,65	0,72	20
C10:Llanero	0,89	0,81	0,85	21
C11:Marandu	0,5	0,64	0,56	25
C12:Massai	0,68	0,76	0,72	17
C13:Mavuno	0,62	0,5	0,56	10
C14:Mombaça	0,4	0,4	0,4	20
C15:Mulato II	0,74	0,68	0,71	25
C16:Ruziziensis	0,64	0,67	0,65	24
C17:Tanzânia	0,61	0,48	0,54	23
C18:Xaraés	0,77	0,91	0,83	22
accuracy			0,63	370
macro avg	0,62	0,62	0,62	370
weighted avg	0,62	0,63	0,62	370

Tabela 41 – Classification Report da MobileVIT treinada no dataset Período 3

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,7	1	0,82	16
C2:BRS Paiaguás	0,53	0,67	0,59	15
C3:BRS Piatã	0,69	0,55	0,61	20
C4:BRS Quênia	0,48	0,61	0,54	18
C5:BRS Tamani	0,5	0,28	0,36	18
C6:BRS Tupi	0,91	0,67	0,77	15
C7:BRS Zuri	0,67	0,53	0,59	15
C8:Basilisk	0,6	0,43	0,5	14
C9:Humidicola comum	0,84	0,94	0,89	17
C10:Llanero	0,8	0,84	0,82	19
C11:Marandu	0,44	0,39	0,41	18
C12:Massai	0,73	0,69	0,71	16
C13:Mavuno	0,47	0,8	0,59	10
C14:Mombaça	0,45	0,31	0,37	16
C15:Mulato II	0,82	0,56	0,67	16
C16:Ruziziensis	0,74	0,82	0,78	17
C17:Tanzânia	0,54	0,5	0,52	14
C18:Xaraés	0,56	0,83	0,67	18
accuracy			0,63	292
macro avg	0,64	0,63	0,62	292
weighted avg	0,64	0,63	0,62	292

Tabela 42 – Classification Report da MobileVIT treinada no dataset Período 4

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,82	0,74	0,78	19
C2:BRS Paiaguás	0,5	0,78	0,61	18
C3:BRS Piatã	0,57	0,68	0,62	19
C4:BRS Quênia	0,58	0,58	0,58	19
C5:BRS Tamani	0,86	0,38	0,52	16
C6:BRS Tupi	0,93	0,65	0,76	20
C7:BRS Zuri	0,48	0,63	0,55	19
C8:Basilisk	0,78	0,78	0,78	18
C9:Humidicola comum	0,75	1	0,86	18
C10:Llanero	0,83	0,83	0,83	18
C11:Marandu	0,54	0,37	0,44	19
C12:Massai	0,56	0,53	0,54	19
C13:Mavuno	0,6	0,56	0,58	16
C14:Mombaça	0,4	0,42	0,41	19
C15:Mulato II	0,73	0,8	0,76	20
C16:Ruziziensis	0,92	0,67	0,77	18
C17:Tanzânia	0,56	0,74	0,64	19
C18:Xaraés	0,83	0,59	0,69	17
accuracy			0,65	331
macro avg	0,68	0,65	0,65	331
weighted avg	0,68	0,65	0,65	331

Tabela 43 – Classification Report da MobileVIT treinada no dataset Período 5

B.2 Apêndices - Classification Reports do modelo Mesclado-Compatível nos conjuntos separados pelo dataset de origem

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,66	0,92	0,77	49
C2:BRS Paiaguás	0,75	0,71	0,73	34
C3:BRS Piatã	0,72	0,74	0,73	38
C4:BRS Quênia	0,77	0,69	0,73	29
C5:BRS Tamani	0,66	0,91	0,76	23
C6:BRS Tupi	0,84	0,86	0,85	37
C7:BRS Zuri	0,72	0,82	0,77	22
C9:Humidicola comum	0,81	0,76	0,79	34
C11:Marandu	0,77	0,64	0,7	42
C16:Ruziziensis	1	0,65	0,79	46
C18:Xaraés	0,86	0,79	0,82	38
accuracy			0,77	392
macro avg	0,78	0,77	0,77	392
weighted avg	0,79	0,77	0,77	392

Tabela 44 – Classification Report do modelo Mesclado-Compatível para o conjunto de teste retirado do dataset Original

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,88	0,97	0,93	229
C2:BRS Paiaguás	0,93	0,9	0,91	241
C3:BRS Piatã	0,88	0,84	0,86	244
C4:BRS Quênia	0,83	0,86	0,85	237
C5:BRS Tamani	0,93	0,9	0,91	244
C6:BRS Tupi	0,97	0,88	0,92	237
C7:BRS Zuri	0,88	0,88	0,88	247
C9:Humidicola comum	0,85	0,98	0,91	232
C11:Marandu	0,82	0,84	0,83	240
C16:Ruziziensis	0,96	0,86	0,91	233
C18:Xaraés	0,9	0,88	0,89	240
accuracy			0,89	2624
macro avg	0,89	0,89	0,89	2624
weighted avg	0,89	0,89	0,89	2624

Tabela 45 – Classification Report do modelo Mesclado-Compatível para o conjunto de teste retirado do dataset Fazan

B.3 Apêndices - Classification Reports do modelo Mesclado-Todo nos conjuntos separados pelo dataset de origem

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,66	0,88	0,75	33
C2:BRS Paiaguás	0,62	0,78	0,69	27
C3:BRS Piatã	0,68	0,52	0,59	33
C4:BRS Quênia	0,58	0,5	0,54	22
C5:BRS Tamani	0,68	0,54	0,6	24
C6:BRS Tupi	1	0,5	0,67	32
C7:BRS Zuri	0,36	0,19	0,25	26
C8:Basilisk	0,91	0,75	0,82	40
C9:Humidicola comum	0,63	0,88	0,73	25
C10:Llanero	0,82	0,85	0,84	39
C11:Marandu	0,66	0,46	0,54	46
C12:Massai	0,65	0,76	0,7	29
C13:Mavuno	1	0,31	0,48	16
C14:Mombaça	0,43	0,7	0,53	33
C15:Mulato II	0,62	0,83	0,71	41
C16:Ruzizensis	0,82	0,87	0,85	38
C17:Tanzânia	0,62	0,89	0,73	35
C18:Xaraés	0,87	0,7	0,78	47
accuracy				0,68
macro avg				0,65
weighted avg				0,67

Tabela 46 – Classification Report do modelo Mesclado-Todo para o conjunto de teste retirado do dataset Original

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,9	0,96	0,93	245
C2:BRS Paiaguás	0,91	0,92	0,91	248
C3:BRS Piatã	0,87	0,8	0,83	249
C4:BRS Quênia	0,79	0,78	0,79	244
C5:BRS Tamani	0,83	0,9	0,86	242
C6:BRS Tupi	0,95	0,74	0,83	242
C7:BRS Zuri	0,91	0,74	0,82	243
C8:Basilisk	0	0	0	0
C9:Humidicola comum	0,83	0,96	0,89	241
C10:Llanero	0	0	0	0
C11:Marandu	0,8	0,77	0,79	235
C12:Massai	0	0	0	0
C13:Mavuno	0	0	0	0
C14:Mombaça	0	0	0	0
C15:Mulato II	0	0	0	0
C16:Ruzizensis	0,93	0,86	0,9	241
C17:Tanzânia	0	0	0	0
C18:Xaraés	0,8	0,9	0,84	231
accuracy				0,85
macro avg				0,53
weighted avg				0,87

Tabela 47 – Classification Report do modelo Mesclado-Todo para o conjunto de teste retirado do dataset Fazan

B.4 Apêndices - Classification Reports do modelo Mesclado-Inflorescência nos conjuntos separados pelo dataset de origem

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	0,85	0,97	0,9	29
C2:BRS Paiaguás	0,75	0,75	0,75	16
C3:BRS Piatã	0,63	0,86	0,73	22
C4:BRS Quênia	0,73	0,4	0,52	20
C5:BRS Tamani	0,7	0,7	0,7	27
C6:BRS Tupi	0,71	0,8	0,75	15
C7:BRS Zuri	0,7	0,29	0,41	24
C8:Basilisk	0,74	0,91	0,82	22
C9:Humidicola comum	0,71	0,75	0,73	20
C10:Llanero	0,92	0,92	0,92	25
C11:Marandu	0,59	0,56	0,57	18
C12:Massai	0,71	0,88	0,79	17
C14:Mombaça	0,42	0,58	0,49	24
C16:Ruziziensis	1	0,77	0,87	22
C17:Tanzânia	0,61	0,58	0,6	24
C18:Xaraés	0,88	0,79	0,83	28
accuracy			0,72	353
macro avg	0,73	0,72	0,71	353
weighted avg	0,73	0,72	0,72	353

Tabela 48 – Classification Report do modelo Mesclado Inflorescência para o conjunto de teste retirado do dataset Original

classe	precision	recall	f1-score	support
C1:BRS Ipyporã	1	0,92	0,96	109
C2:BRS Paiaguás	0,96	0,93	0,94	120
C3:BRS Piatã	0,85	0,92	0,88	121
C4:BRS Quênia	0,9	0,81	0,85	114
C5:BRS Tamani	0,8	0,92	0,86	49
C6:BRS Tupi	0,89	0,91	0,9	119
C7:BRS Zuri	0,82	0,84	0,83	110
C8:Basilisk	0,85	0,97	0,91	115
C9:Humidicola comum	0,89	0,96	0,93	114
C10:Llanero	0,81	0,72	0,76	53
C11:Marandu	0,9	0,85	0,88	120
C12:Massai	0,94	0,9	0,92	116
C14:Mombaça	0,84	0,82	0,83	111
C16:Ruziziensis	0,97	0,97	0,97	116
C17:Tanzânia	0,96	0,99	0,97	112
C18:Xaraés	0,93	0,9	0,91	110
accuracy			0,9	1709
macro avg	0,89	0,89	0,89	1709
weighted avg	0,9	0,9	0,9	1709

Tabela 49 – Classification Report do modelo Mesclado Inflorescência para o conjunto de teste retirado do dataset Fazan