

# Classificação de Requeima e Mancha Bacteriana do Tomateiro Utilizando ResNet-50 com Aprendizagem por Transferência.

Jeferson Giovanni de Melo Jesus<sup>1</sup>  
Prof. Dr. Luis Hilário Tobler Garcia<sup>2</sup>  
Prof. Dra. Eloíza Martins Primo Capeloci<sup>2</sup>

## Resumo

As doenças foliares, como a Requeima (*Phytophthora infestans*) e a Mancha Bacteriana (*Xanthomonas vesicatoria*), ameaçam a produtividade da cultura do tomate, resultando em perdas econômicas. A sua detecção precoce é fundamental para um manejo eficaz. Este trabalho propõe um modelo de classificação de doenças foliares do tomateiro utilizando *Deep Learning*. O modelo emprega a arquitetura de rede neural convolucional *ResNet-50*, com aprendizagem por transferência a partir de um modelo pré-treinado na base de dados ImageNet. A arquitetura foi adaptada pela substituição da camada classificadora final por uma nova camada linear com três neurônios de saída para as classes de interesse (Requeima, Mancha Bacteriana e Saudável). O conjunto de dados, construído a partir do repositório *PlantVillage*, passou por um processo de limpeza manual, onde imagens borradas, com iluminação inadequada, sombras ou foco no fruto foram descartadas para reduzir o ruído. O conjunto filtrado foi dividido em 3 partes, 80% para o treino, 10% para a validação e 10% para os testes finais, totalizando em 550 imagens de plantas saudáveis, 550 imagens de plantas com Requeima e 550 imagens de plantas com Mancha Bacteriana, especificamente para o treino. Técnicas de data *augmentation*, como rotação e alteração de cor, foram aplicadas apenas ao treino para evitar *overfitting*. No treino, os parâmetros das camadas convolucionais foram congelados, restringindo-se o ajuste apenas à nova camada classificadora com o otimizador *Adam*. Os resultados indicam que a limpeza de dados foi um fator determinante para o alto desempenho. O treinamento, realizado por 24 épocas, mostrou boa generalização, o modelo treinado obteve uma acurácia de 95,76% nos testes de validação, demonstrando alta eficácia para a tarefa proposta permitindo a integração em aplicações para auxiliar na tomada de decisão.

**Palavras-chave:** Tomate, Deep Learning; Aprendizagem Por Transferência; Doenças do Tomate; ResNet-50.

## 1 INTRODUÇÃO

O tomate (*Solanum lycopersicum*) é uma cultura de grande importância para agronegócio brasileiro sendo o 9º país produtor mundial, no ano de 2019 atingiu quase 4 milhões de toneladas, obtendo um valor considerável para economia. Os fatores produtivos compreendem tanto para o consumo in natura quanto o processamento industrial (Agrishow Digital, 2021).

---

<sup>1</sup>Discente em Big Data no Agronegócio na FATEC de Pompeia, Pompeia, SP,

<sup>2</sup>Docentes do curso Big Data no Agronegócio, FATEC Pompeia, Pompeia-SP

No entanto, o setor enfrenta desafios como oscilações de preços, influência por fatores climáticos de sazonalidades e a ausência de organização que reduz a lucratividade dos produtores. As práticas de tecnologias avançadas como, *Big Data* tem visibilidade como uma solução para aprimorar a produção, reduzir riscos na tomada de decisão e aumentar a competitividade da produção do tomate no mercado brasileiro (Pedroso, Michereff, Ferreira, Mello, 2023).

Os preços no mercado hortigranjeiro brasileiro, analisada pelo 9º Boletim Prohort da Companhia Nacional de Abastecimento (Conab), informou uma tendência de deflação para o tomate no início de Setembro de 2025, consolidando o comportamento de Agosto. Nesse período, o fruto registrou uma redução de 19,86% na média considerada de suas cotações em comparação a julho de 2025, um movimento incomum, ocorrendo simultaneamente uma retração na oferta (Gov.br, 2025).

Em paralelo à queda de preços no mercado interno, as exportações brasileiras de tomate cresceram significativamente em 2024, atingindo 6,3 mil toneladas de Janeiro a Julho sendo o maior volume desde 2001 (HF Brasil, 2024). Esse aumento dos últimos cinco anos e destinado principalmente ao Paraguai (65%) e Argentina (30%) ajudou a reduzir o excesso de oferta.

A sucessão de abastecimento do tomate é ampla e inclui atividades que vão desde os exigentes processos de plantio e colheita até a distribuição dos produtos em diversos pontos de venda. A produção industrial de tomate está concentrada em algumas regiões importantes, como o Triângulo Mineiro e Goiás, sendo este último o maior produtor do país, com aproximadamente 14.600 hectares de área plantada. O êxito em Goiás se deve principalmente à adaptabilidade das cultivares ao clima local (Embrapa, 2022).

O sistema de produção do tomateiro é confrontado por uma série de fatores limitantes, sendo a principal a sua suscetibilidade a pragas e doenças, como a requeima e mancha bacteriana causando problemas econômicos. Em contrapartida, os fatores abióticos, sobretudo o manejo hídrico, também representam um entrave significativo; tanto o estresse hídrico por déficit quanto o excesso de irrigação podem induzir o abortamento de flores, a fissura dos frutos e favorecer a disseminação de patógenos, comprometendo a qualidade e a comercialização do produto final (Mais Agro, 2025).

A requeima é uma doença causada pelo fungo *Phytophthora infestans* capaz de atacar o tomateiro em qualquer etapa de seu crescimento, causando danos a todas as partes da planta acima do solo. Inicialmente, surgem pequenas manchas esverdeadas nas folhas da parte

superior, que rapidamente se espalham, escurecem e levam ao murchamento e necrose do tecido foliar (Revista Cultivar, 2016).

Por outro lado, a Mancha Bacteriana (*Xanthomonas vesicatoria*), causada por diversas espécies de bactérias do gênero *Xanthomonas*, é uma doença que afeta as folhas, caules e frutos do tomateiro em todos os estágios de desenvolvimento. Os sintomas iniciais nas folhas aparecem como pequenas manchas irregulares e encharcadas que com o tempo se tornam marrom-escuras e necróticas (Agrolink, 2025).

Contudo nesse cenário, as redes neurais convolucionais (CNNs), um subconjunto de aprendizado de máquina otimizado para tarefas de visão computacional que transforma a imagens em valores numéricos para extrair padrões e importantes para a classificação de imagens (IBM,2025).

Através desse processamento, a CNNs aprende características como textura, cor e forma das lesões das doenças foliares constituindo uma abordagem promissora para o diagnóstico automatizado de doenças do tomateiro. Diferentemente de métodos tradicionais, as CNNs são capazes de extrair e identificar padrões visuais complexos nas lesões das folhas, como mudanças na cor e na textura, que podem ser difíceis de serem percebidas pelo olho humano. Ao ser treinada com um vasto conjunto de dados de imagens de folhas saudáveis e doentes, as redes neurais aprendem a distinguir as características únicas, permitindo um diagnóstico rápido e consistente. Isso automatiza a detecção e auxilia na tomada de decisões em campo para o controle da doença. (Quieregato,2024).

Para a classificação das doenças foliares do tomate, especificamente Requeima e Mancha Bacteriana, empregou-se um modelo baseado na arquitetura de rede neural convolucional ResNet-50. A metodologia utilizada foi a de aprendizagem por transferência que consiste em uma técnica de *Machine Learning* (ML) que permite adaptar um modelo existente, pré-treinado em uma tarefa, para uma nova aplicação relacionada em vez de enfrentar o processo demorado de treinar um novo modelo que exige muitos dados e grande processamento de computação. Essa é uma técnica consiste em obter um modelo já pré-treinado para uma tarefa e ajustar usando novos dados, para que ele possa executar uma nova tarefa relacionada (Neto, 2017).

A arquitetura original foi adaptada para esta aplicação, com a substituição da camada classificadora final por uma nova camada linear contendo três neurônios de saída, correspondentes às classes de interesse (Requeima, Mancha Bacteriana e Saudável).

Durante o processo de treinamento, os parâmetros das camadas convolucionais pré-treinadas foram mantidos congelados, sendo que o ajuste se restringiu aos parâmetros da nova

camada classificadora, utilizando o otimizador Adam para essa finalidade. O parâmetro Adam é fundamentado na técnica da descida de gradiente estocástico, associando a variância para ajustar a taxa de aprendizagem de cada parâmetro do modelo conforme o treinamento (Montanari, 2025).

Diante desse cenário, este estudo tem como problema de pesquisa investigar em que medida técnicas de aprendizado profundo, especificamente por meio da arquitetura ResNet-50 com aprendizagem por transferência, podem ser aplicadas de forma eficiente na classificação automática de doenças foliares do tomateiro. Assim, o objetivo deste trabalho consiste em desenvolver e avaliar um modelo computacional capaz de identificar as patologias foliares da Requeima e Mancha Bacteriana da cultura do tomate, contribuindo para o avanço de soluções tecnológicas aplicadas à agricultura de precisão.

## **2 MATERIAL E MÉTODOS**

A metodologia adotada neste estudo foi estruturada em etapas sequenciais, compreendendo a seleção e curadoria dos dados, o pré-processamento das imagens, a definição do modelo de aprendizado profundo, o treinamento supervisionado e a avaliação de desempenho.

A implementação computacional deste estudo foi conduzida em ambiente de nuvem por meio do *Google Colaboratory*, plataforma que possibilita o desenvolvimento e a execução de códigos diretamente em navegador web. A escolha desse ambiente deve-se, sobretudo, à disponibilidade de recursos computacionais com acesso a Unidades de Processamento Gráfico (GPUs), o que contribui significativamente para a redução do tempo de treinamento de modelos de aprendizado profundo. Além disso, o ambiente permite a integração entre código, visualizações e documentação em notebooks interativos, favorecendo a reprodutibilidade dos experimentos (Google Colab, 2025).

A modelagem foi realizada utilizando a linguagem de programação Python, adotada em aplicações de ciência de dados e aprendizado de máquina. Foram empregadas bibliotecas especializadas para diferentes etapas do processo: PyTorch e Torchvision para a construção, treinamento e validação do modelo de rede neural convolucional; Scikit-learn para a divisão estratificada dos dados; NumPy para manipulação de estruturas numéricas; e Matplotlib e Pillow (PIL) para visualização e pré-processamento de imagens. A escolha dessas bibliotecas fundamenta-se em sua ampla documentação e consolidação em aplicações científicas (Borges, 2014; Silva, 2019).

O conjunto de dados utilizado foi obtido a partir do repositório público PlantVillage (TensorFlow, 2024), amplamente empregado em estudos de detecção de doenças em plantas. A base original contém 38 classes de diferentes culturas agrícolas, sendo selecionado, para este estudo, um subconjunto específico composto por imagens de folhas de tomateiro (*Solanum lycopersicum*) em três condições: Requeima (*Phytophthora infestans*), Mancha Bacteriana (*Xanthomonas vesicatoria*) e folhas saudáveis.

Essa seleção foi realizada com o objetivo de adequar o conjunto de dados à problemática proposta e garantir consistência na tarefa de classificação supervisionada (Oneda, 2025).

Para a modelagem, adotou-se a arquitetura de rede neural convolucional ResNet-50, reconhecida por sua eficiência em tarefas de visão computacional e vencedora do desafio ImageNet Large Scale Visual Recognition Challenge em 2015. Essa arquitetura utiliza conexões residuais que permitem a propagação direta de informações entre camadas não consecutivas, mitigando o problema do desaparecimento do gradiente e viabilizando o treinamento de redes profundas com elevado número de camadas (Souza *et al.*, 2020). No presente estudo, a ResNet-50 foi utilizada por meio da técnica de aprendizagem por transferência, aproveitando pesos previamente treinados na base ImageNet.

Embora arquiteturas clássicas de aprendizagem profundo também sejam relevantes no contexto das redes neurais convolucionais, caracterizando-se por sua estrutura composta por camadas convolucionais e totalmente conectadas, optou-se pela ResNet-50 devido ao seu melhor desempenho em tarefas mais complexas e maior capacidade de generalização (Oliveira; Castro, 2021)

Os dados foram armazenados em ambiente de nuvem por meio do Google Drive, possibilitando acesso remoto e organização estruturada dos arquivos. As imagens foram organizadas em diretórios por classe, o que facilitou a implementação do pipeline de treinamento supervisionado e a integração com o ambiente de execução adotado (Arnold; Zanella, 2019).

### **3 RESULTADOS E DISCUSSÃO**

Este estudo foca na estruturação de fluxo de trabalho que priorizou a qualidade dos dados de entrada, foi realizado a limpeza de dados, para assegurar a qualidade do conjunto de treinamento e evitar que o algoritmo aprendesse o ruído como um padrão informativo, podendo prejudicar a capacidade de generalizar de forma eficaz para novas instâncias.

O conjunto de dados foi extraído do repositório do *PlantVillage* e, a partir dele, foi selecionado um subconjunto específico da pasta *Plant\_leaf\_diseases\_dataset\_with\_augmentation* para esta pesquisa. Foram escolhidas imagens organizadas em três classes relacionadas a doenças foliares do tomateiro: Requeima (Late Blight), Mancha Bacteriana (Bacterial Spot) e Saudável (Healthy), conforme ilustrado na Figura 1 (Silva; Barros; Santos; Regis, 2022).

As imagens foram selecionadas manualmente, descartando aquelas que apresentavam problemas significativos e que comprometeriam a qualidade do treinamento. Os critérios para exclusão incluíram imagens borradas, com falhas de foco, condições de iluminação inadequadas, alta exposição à luz, áreas com sombras, folhas descentralizadas e segmentadas. Para garantir que o modelo se especializasse na análise de patologias foliares, foram removidas as imagens no qual o foco principal era o fruto do tomate em vez da folha.

Os dados foram armazenados no *Google Drive* para praticidade e fácil integração com o Google Colab, permitindo o acesso remoto e organizado aos dados durante a execução do processamento diretamente da nuvem sem a necessidade de armazenamento local. As imagens estão estruturadas e organizadas por classes em pastas separadas conforme o tipo de doença e à condição saudável, assim, facilitando a aplicação da técnica de aprendizado supervisionado.

**Figura 1.** Apresentação de exemplos de imagens removidas do conjunto de dados.



Fonte: Elaborado pelo autor (2026)

Esse procedimento reforça a importância da qualidade dos dados no desempenho de modelos de aprendizado profundo, uma vez que a presença de ruídos pode comprometer significativamente a capacidade de generalização e a confiabilidade dos resultados.

O conjunto de dados foi submetido a uma divisão em três subconjuntos utilizando a função *train\_test\_split* da biblioteca *Scikit-learn*: 80% para treino (550 imagens por classe) para o aprendizado dos pesos da rede neural, 10% para validação (55 imagens por classe) para monitorar o desempenho do modelo durante o treinamento e evitar *overfitting* (AWS, 2025) e 10% para teste (55 imagens por classe) usado para a avaliação final e imparcial do desempenho do modelo. A divisão estratificada assegura que a proporção de imagens de cada classe seja mantida em todos os subconjuntos.

No conjunto de treinamento, foram aplicadas técnicas de aumento de dados (*data augmentation*), para aumentar a variabilidade dos dados e reduzir o risco de sobreajuste. Entre os algoritmos de transformação aplicados temos o algoritmo: *RandomResizedCrop*, responsável por recortar uma região aleatória da imagem e redimensionar a mesma para 224x224 pixels, o algoritmo *ColorJitter*, responsável por alterar aleatoriamente o brilho, contraste, saturação e matiz, o algoritmo *RandomRotation*, responsável por rotacionar a imagem em até 30 graus e o algoritmo *RandomHorizontalFlip*, responsável por inverter a imagem horizontalmente.

Para os conjuntos de validação e teste, foram aplicadas apenas transformações usadas para padronizar o tamanho das imagens, através dos algoritmos *Resize* e *CenterCrop* responsável por redimensionar e cortar a imagem para o tamanho de 224x224 pixels. Finalmente, todas as imagens foram convertidas para o formato de tensor e normalizadas utilizando a média e o desvio padrão do conjunto de dados ImageNet (média = [0.485, 0.456, 0.406] e desvio padrão = [0.229, 0.224, 0.225]).

Dessa forma, para cada uma das três classes, a distribuição final foi de 440 imagens para treino, 55 para validação e 55 para teste. Esse processo foi realizado de forma programática, criando-se uma nova estrutura de diretórios (/processed) para alocar as imagens já separadas, garantindo que o modelo seja avaliado com dados não vistos durante a fase de treinamento.

Para a atualização dos pesos da camada classificadora durante o treinamento, foi selecionado o otimizador *Adam* (*Adaptive Moment Estimation*). Este método, proposto por Kingman e Ba (2014), é amplamente adotado em aplicações de aprendizado profundo por sua eficiência e capacidade de ajustar a taxa de aprendizado de forma adaptativa para cada parâmetro. O Adam combina as vantagens de outros dois algoritmos de otimização, *AdaGrad* e *RMSProp*, para convergir de forma mais rápida e estável, tornando-o uma escolha robusta para a otimização de modelos de redes neurais complexas.

O treinamento foi executado em uma GPU para otimizar o tempo de processamento. A otimização dos pesos foi realizada com o otimizador Adam, utilizando uma taxa de aprendizado de [0.001], e a função de perda de Entropia Cruzada (*CrossEntropyLoss*). O modelo foi treinado por 24 épocas, com um tamanho de lote (*batch size*) de 32 imagens. Ao final de cada época, o desempenho do modelo foi avaliado no conjunto de validação, e a versão que apresentou a maior acurácia de validação foi salva com 95.76% como o modelo final.

Para elaboração de implementação prática desse estudo foi utilizado uma estrutura rede neural convolucional (IBM, 2025), empregando a arquitetura ResNet50 um modelo de visão computacional, utilizado principalmente para classificação de imagens (Carrera; Almeida 2024). Foi utilizada a técnica de aprendizagem por transferência (*transfer learning*), utilizando a arquitetura ResNet-50, pré-treinada no grande conjunto de dados ImageNet (Krizhevsk, 2012).

A ResNet-50 foi carregada com seus pesos pré-treinados e todas as camadas convolucionais tiveram seus pesos congelados (`requires_grad = False`) para guardar o conhecimento adquirido na extração de características visuais genéricas. A camada de classificação final foi substituída por uma nova camada totalmente conectada (`nn.Linear`) com três neurônios de saída, correspondendo às três classes do estudo (Requeima, Mancha Bacteriana e Folha Saudável). Apenas os pesos desta nova camada foram configurados para serem treináveis.

O treinamento do modelo foi configurado com os hiperparâmetros: Função de Perda (*Loss Function*): *CrossEntropyLoss*. Otimizador: Adam, com uma taxa de aprendizado de 0.001, configurado para atualizar apenas os parâmetros da nova camada de classificação. O tamanho do Lote (*Batch Size*) foi de 32 imagens e o número de épocas foi de 24. Durante o treinamento, o modelo que apresentou a maior acurácia de 95,76% no conjunto de validação e foi salvo para a etapa de avaliação final.

Após o treinamento o desempenho do melhor modelo foi salvo utilizando o conjunto de teste, a métrica principal para avaliação foi a acurácia, calculada como a porcentagem de imagens do conjunto de teste classificadas corretamente. Este procedimento assegura uma avaliação imparcial da generalização em dados nunca vistos.

A execução do teste de acurácia para esse estudo, mostrou que o modelo acertou em 95,76% da vezes, demonstrando eficácia em classificar corretamente as doenças foliares do tomateiro.

Apesar da elevada acurácia obtida (95,76%), é importante destacar que a performance do modelo pode ser impactada em ambientes reais, nos quais fatores como variação de iluminação, presença de ruídos visuais, oclusões e diferentes estágios fenológicos das plantas podem comprometer a precisão das classificações. Assim, a validação do modelo em condições não controladas constitui uma etapa essencial para sua aplicação prática. Contudo, é importante destacar que este resultado não deve ser atribuído apenas à escolha do modelo, mas ao método de seleção dos dados conforme explicado na metodologia.

O desempenho da validação e teste é definitivo descrever as limitações deste estudo que se originam do conjunto de dados do *PlantVillage*. Este repositório, apesar de extenso, consiste grande parte de imagens capturadas em ambientes controlados com folhas isoladas e fundos uniformes.

Essa característica limita a variabilidade das imagens, reduzindo a presença de elementos típicos de campo, como sobreposição de folhas, variações de iluminação natural e interferências do ambiente, o que pode influenciar diretamente na robustez do modelo em aplicações reais.

Ao realizar a limpeza manual, foram descartadas imagens que apresentavam os desafios de um cenário real, condições de iluminação inadequadas, alta exposição à luz, áreas com sombras e folhas descentralizadas. Essa filtragem foi importante para minimizar o ruído e permitir que o modelo aprendesse os padrões patológicos corretos e criar um conjunto de dados de treinamento estruturado.

Esta etapa foi importante para evitar o que o modelo poderia interpretar como ruído, garantindo que o conjunto de treino fosse variado por exemplos claros e apropriados. Com isso, o modelo foi capaz de aprender a extrair os padrões visuais corretos das patologias como a textura e forma das lesões, ao invés de aprender associações supostas baseadas em itens das imagens. Portanto, demonstra-se que essa limpeza de dados foi um fator determinante para que o modelo alcançasse um desempenho de classificação elevado.

A acurácia final de 95,76% válida a eficácia da arquitetura *ResNet-50* com aprendizagem por transferência para este estudo. Contudo, é importante destacar que este resultado não deve ser atribuído apenas à escolha do modelo, mas ao método de seleção dos dados conforme explicado na metodologia.


A otimização do desempenho do modelo ao longo do treinamento, apresentada no gráfico da Figura 2, que exibem, respectivamente, as curvas de erro e de acurácia para os conjuntos de treino e validação. Observa-se uma redução progressiva e consistente do erro e aumento contínuo da acurácia, indicando que o modelo aprimorou sua capacidade de

distinguir as classes de doenças. Essa tendência demonstra que o processo de aprendizagem ocorreu de forma estável e controlada, sem evidências de *overfitting*.

Este progresso é o resultado direto do ciclo de treinamento executado por 24 épocas conforme definido nos hiperparâmetros do código, em cada época, o modelo executou em modo de treino para o conjunto de treinamento e em seguida em modo de avaliação para o conjunto de validação, utilizando a função de perda *nn.CrossEntropyLoss* para quantificar o erro. O script salvou o estado do modelo apenas quando a acurácia de validação superava a melhor acurácia anterior, garantindo que o resultado final representasse o ponto de melhor generalização.

O processo foi aprimorado com o uso do *scheduler* (Agendador) *ReduceLROnPlateau*, que faz o monitoramento na precisão de validação. Quando a métrica parava de melhorar o Agendador reduzia a taxa de aprendizado. Isso ajuda o treinamento a ficar mais estável para obter resultados mais precisos.

**Figura 2** - Progresso da acurácia e perda aplicando o método curva de aprendizado.



Fonte: Elaborado pelo autor (2026)

A proximidade entre as curvas de treino e validação confirma que o modelo apresentou boa capacidade de generalização, sendo capaz de manter o desempenho mesmo diante de dados não vistos durante o treinamento. Esse comportamento reforça a eficácia das técnicas de data *augmentation* aplicadas, que ampliaram a variabilidade do conjunto de treinamento, e evidencia a adequação da arquitetura ResNet-50 com transferência de aprendizagem para a tarefa de classificação das doenças foliares.

A técnica de data *augmentation*, que consiste em aumentar a quantidade de dados, foi aplicada no conjunto de treinamento para ajudar o modelo a ficar estável. Após a filtragem, cada classe ficou com 440 imagens, sem esse aumento de dados, o risco era que o modelo se adaptasse às imagens específicas ocasionando a memorização dessas 440 imagens em vez de

aprender as características das doenças. Para evitar essa ocorrência, foram aplicadas transformações como *RandomResizedCrop*, *ColorJitter* e *RandomHorizontalFlip*, que criaram variações artificiais nas imagens e aumento da diversidade dos dados disponíveis para o treinamento.

Essas transformações ajuda o modelo a aprender as características das doenças. A transformação aplicada pelo *ColorJitter*, por exemplo, ao alterar brilho e saturação, simular a variabilidade de luz, assim, o modelo não se sujeita a associar a doença a uma cor específica, mas aprende reconhecer padrões de textura e forma. Já a transformação aplicada pelos *RandomRotation* e o *RandomHorizontalFlip*, certifica que o modelo fosse capaz de identificar a Requeima ou a Mancha Bacteriana sem depender de como a folha estiver posicionada na imagem. *Resize* e *CenterCrop*, assegura que a avaliação do desempenho fosse consistente e padronizada. Sobretudo, possibilitando um aumento no volume dos dados que permitiu ao modelo aprender o que é uma folha saudável e uma folha doente.

Atribui-se o sucesso da técnica adotada pela escolha da aprendizagem por *transfer learning*, arquitetura ResNet-50 pré-treinada na base de dados ImageNet e congelar os pesos das camadas convolucionais. O estudo desenvolveu a detecção de características visuais genéricas, executando todo o processo de treinamento através o modelo *models.resnet50* da biblioteca *PyTorch*. Ao final, o último classificador foi substituído por uma nova camada linear com o número de saídas adaptado para as três classes de interesse.

A decisão de treinar apenas a nova camada classificadora final, adaptada para três neurônios foi uma abordagem computacional eficiente, permitiu que o otimizador *Adam* focasse a aplicação de ajuste e não na extração de características para mapear os atributos para as três classes. Isso foi feito por meio do uso do otimizador *Adam*, passando os parâmetros da camada final para serem otimizados, usando uma taxa de aprendizado de 0,001.

Além da acurácia de 95,76% o desempenho do modelo também foi avaliado pelas métricas Precision, Recall e F1-score representada na Figura 3, obtidas na classificação do conjunto de teste. A métrica F1-score é importante pois ela aponta precisão e exatidão, permitindo avaliar entre acertos e erros do modelo durante a classificação.

**Figura 3** - Desempenho do modelo de classificação das classes avaliadas sob as métricas Precision, Recall e F1-Score

```

=====
MÉTRICAS DE AVALIAÇÃO DETALHADAS (TESTE)
=====

```

|                   | precision | recall | f1-score | support |
|-------------------|-----------|--------|----------|---------|
| Mancha_Bacteriana | 0.94      | 0.93   | 0.94     | 55      |
| Requeima          | 0.93      | 0.95   | 0.94     | 55      |
| Saudavel          | 1.00      | 1.00   | 1.00     | 55      |
| accuracy          |           |        | 0.96     | 165     |
| macro avg         | 0.96      | 0.96   | 0.96     | 165     |
| weighted avg      | 0.96      | 0.96   | 0.96     | 165     |

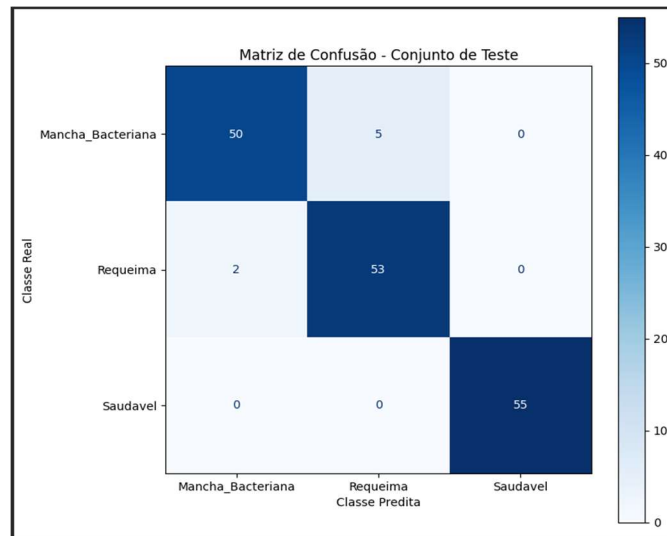
Fonte: Elaborado pelo autor (2026)

O resultado demonstra f1-score de 0.94 para as classes Requeima e Mancha Bacteriana e para a classe Saudável 1.00. Esses valores indicam que o modelo apresentou forte capacidade de reconhecer corretamente as doenças. As médias macro avg e weighted atingiu 0.96 indicando a consistência no desempenho entre todas as classes analisadas.(Status; Júnior, Ferreira, 2022)

A análise do desempenho do modelo *ResNet-50* é detalhada e validada pela Matriz de Confusão, conforme representado na figura 4. Esse resultado excede a métrica agregada de acurácia (95,76%) ao fornecer uma avaliação da classificação por classe no conjunto de testes. Para gerar esta matriz, o melhor modelo salvo foi carregado e executado sobre o conjunto de teste que continha 10% dos dados mantidos inéditos durante o treino e a validação.

As previsões e os rótulos reais foram coletados após a passagem dos dados e processados pelas funções *confusion\_matrix* e *classification\_report* da biblioteca Scikit-learn, fornecendo a base quantitativa para a acurácia final e para a visualização dos Verdadeiros Positivos.

**Figura 4** - Gráfico Matriz de Confusão



Fonte: Elaborada pelo autor (2026)

O gráfico visualiza a distribuição das predições, onde os valores concentrados na diagonal principal representam os Verdadeiros Positivos (VP) que são as ocorrências em que o modelo acertou a classificação de cada patologia (Requeima, Mancha Bacteriana e Saudável), demonstrando a alta capacidade de reconhecimento. Os valores organizados que estão fora dessa diagonal indicam os erros de classificação (Falsos Positivos e Falsos Negativos), sendo importante para a identificação de qualquer confusão interclasse específica (Franceschi, 2019).

A baixa existência desses erros dada a acurácia elevada, atesta a assertividade do modelo em distinguir as características visuais das doenças, fornecendo evidências práticas da sua capacidade de discriminação e generalização em um cenário adequado de diagnóstico de doenças foliares do tomateiro.

A capacidade do modelo em manter a alta performance com novos dados, evidenciada pela baixa discrepância entre as curvas de treino e validação, atesta que as transformações geradas pela data *augmentation* foram eficazes em simular a variabilidade de condições de campo como iluminação e posicionamento, avaliando a resistência para ser utilizada futuramente em aplicações de agricultura de precisão. A clareza da Matriz de Confusão (Figura 3) reforça esta assertividade e validando o modelo como uma ferramenta de apoio decisório eficaz para o manejo precoce e localizado da Requeima e Mancha Bacteriana.

Dessa forma, os resultados obtidos e as análises realizadas evidenciam a eficiência do modelo proposto na detecção automática de doenças foliares Requeima e Mancha Bacteriana do tomateiro, com uso da arquitetura ResNet-50 no reconhecimento de padrões visuais. As

métricas de desempenho apresentadas indicam uma alta capacidade de generalização do modelo, refletindo sua aplicação prática em sistemas de monitoramento.

## CONCLUSÃO

A utilização da arquitetura ResNet-50, com aprendizado por transferência, consolidou como uma estratégia para a identificação de patologias no tomateiro, atingindo uma acurácia de 95,76%. Este resultado reflete não apenas a eficiência computacional, mas o cuidado metodológico na curadoria e expansão dos dados, elementos importantes para a confiabilidade do modelo.

Além da acurácia de 95,76% o gráfico da Matriz de Confusão demonstrou um elevado nível de acerto nas classificações, demonstrando os resultados na diagonal principal. Para a classe Mancha Bacteriana, o modelo classificou corretamente 50 das 55 imagens, registrando apenas 5 erros. Na classe Requeima, foram obtidos 53 acertos das 55 imagens e apenas 2 classificações incorretas. Já a classe Saudável apresentou desempenho perfeito, com 55 acertos e nenhum erro. Esse resultado mostra a elevada capacidade do modelo reconhecer as diferentes classes analisadas, demonstrando a confiabilidade para a identificação de doenças foliares do tomateiro.

No entanto, o estudo com imagens em ambientes controlados é apenas o primeiro passo; o real desafio reside na transição para o campo, onde as variáveis são imprevisíveis. Assim, auxiliar o agricultor na proteção e produção na promoção de um manejo rápido e sustentável.

## REFERÊNCIAS

AGRISHOW DIGITAL. **Cenário do tomate no Brasil: tendências e dificuldades de cultivo**. 2021. Disponível em: <https://digital.agrishow.com.br/artigos/cenrio-do-tomate-no-brasil-tendncias-e-dificuldades-de-cultivo/>. Acesso em: 03 set.2025.

PEDROSO, Maria Tereza Macedo; MICHEREFF, Miguel Filho; FERREIRA, Zenaide Rodrigues; MELLO, Paulo Freire. **Adoção de tecnologias na tomaticultura do Distrito Federal**.2023. Disponível em: <https://rpa.sede.embrapa.br/RPA/article/view/1893>.

GOV.BR. **Boletim da Conab verifica queda acentuada de preços do tomate no atacado nos primeiros dias de Setembro**. 2025. Disponível em: <https://www.gov.br/conab/pt->

br/assuntos/noticias/boletim-da-conab-verifica-queda-acentuada-de-precos-do-tomate-no-atacado-nos-primeiros-dias-de-setembro?utm\_source=chatgpt.com. Acesso em: 17.jun.2026.

AGROLINK. **Mancha bacteriana**. 2025. Disponível em: [https://www.agrolink.com.br/problemas/mancha-bacteriana\\_1666.html](https://www.agrolink.com.br/problemas/mancha-bacteriana_1666.html). Acesso em: 11 set. 2025.

NETO, Décio Gonçalves de Aguiar. **Transferência de conhecimento utilizando aprendizado profundo para classificação de imagens histopatológicas**. 2017. Disponível em: [https://repositorio.ufc.br/bitstream/riufc/29515/1/2017\\_tcc\\_dganaguiar.pdf](https://repositorio.ufc.br/bitstream/riufc/29515/1/2017_tcc_dganaguiar.pdf). Acesso em: 14 mar. 2026.

AGRISHOW DIGITAL. **Cenário do tomate no Brasil: tendências e dificuldades de cultivo**. 2021. Disponível em: <https://digital.agrishow.com.br/artigos/cenrio-do-tomate-no-brasil-tendencias-e-dificuldades-de-cultivo/>. Acesso em: 03 set. 2025.

ARAUJO FILHO, Aurino Guilherme Xavier; SOQUEIRA NETO, Odael Lopes de; AMARANTE, Yann Silva. **Redes neurais convolucionais AlexNet, GoogLeNet e ResNet aplicadas ao reconhecimento de expressões faciais**. 2026. Disponível em: [https://scholar.google.com/scholar?hl=pt-BR&as\\_sdt=0%2C5&q=Redes+neurais+convolucionais+AlexNet%2C+GoogLeNet+e+ResNet+aplicadas+ao+reconhecimento+de+express%C3%B5es+faciais&btnG=](https://scholar.google.com/scholar?hl=pt-BR&as_sdt=0%2C5&q=Redes+neurais+convolucionais+AlexNet%2C+GoogLeNet+e+ResNet+aplicadas+ao+reconhecimento+de+express%C3%B5es+faciais&btnG=). Acesso em: 17 jun. 2026.

ARNOLD, Felipe Matheus Wüst; ZANELLA, Renata. **Computação em nuvem: um estudo sobre o Google Drive como ferramenta colaborativa aplicada à educação Trajetória Multicursos**. 2019. Disponível em: <https://cientifica.cnec.br/index.php/trajetoria-multicursos/article/view/290/291>. Acesso em: 16 mar. 2026.

AWS. **What is overfitting?** 2024. Disponível em: <https://aws.amazon.com/pt/what-is/overfitting/>. Acesso em: 15 set. 2025.

BORGES, Luiz Eduardo. **Python para desenvolvedores**. 2014. Disponível em: [https://books.google.com.br/books/about/Python\\_para\\_Desenvolvedores.html?id=eZmtBAAAQBAJ&redir\\_esc=y](https://books.google.com.br/books/about/Python_para_Desenvolvedores.html?id=eZmtBAAAQBAJ&redir_esc=y). Acesso em: 17 jun. 2026.

BRASIL. Governo Federal. **Boletim da CONAB verifica queda acentuada de preços do tomate no atacado nos primeiros dias de setembro**. 2025. Disponível em: <https://www.gov.br/conab/pt-br/assuntos/noticias/boletim-da-conab-verifica-queda-acentuada-de-precos-do-tomate-no-atacado-nos-primeiros-dias-de-setembro>. Acesso em: 11 nov. 2025.

DEEP CHECKS. **Noise in machine learning**. 2025. Disponível em: <https://www.deepchecks.com/glossary/noise-in-machine-learning/>. Acesso em: 16 set. 2025.

EMBRAPA. **Tomate**. 2022. Disponível em: <https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/tomate/pre-producao/socioeconomia/importancia>. Acesso em: 07 set. 2025.

GOOGLE COLAB. **Google Colaboratory**. 2025. Disponível em: <https://colab.google/>. Acesso em: 11 set. 2025.

HF BRASIL. **Tomate CEPEA: apesar de exportações crescentes, mercado segue com excesso de oferta**. 2024. Disponível em: <https://www.hfbrasil.org.br/br/tomate-cepea-apesar-de-exportacoes-crescentes-mercado-segue-com-excesso-de-oferta.aspx>. Acesso em: 11 nov. 2025.

IBM. **O que são redes neurais convolucionais?** 2025. Disponível em: <https://www.ibm.com>. Acesso em: 15 set. 2025.

CARRERA, Augusto Esteves ; ALMEIDA, Gabriel Marques G. **Estudo comparativo de modelos de Deep Learning para classificação de lesões cutâneas**. 2024. Disponível em: [https://scholar.google.com.br/scholar?hl=pt-BR&as\\_sdt=0%2C5&q=Resnet50+para+classifica%C3%A7%C3%A3o+&btnG=#d=gs\\_qabs&t=1777753072798&u=%23p%3DZM6D8pBdiHkJ](https://scholar.google.com.br/scholar?hl=pt-BR&as_sdt=0%2C5&q=Resnet50+para+classifica%C3%A7%C3%A3o+&btnG=#d=gs_qabs&t=1777753072798&u=%23p%3DZM6D8pBdiHkJ). Acesso em: 2 mai.2026.

KINGMA, Diederik P.; BA, Jimmy. **Adam: a method for stochastic optimization**. 2015. Disponível em: <https://arxiv.org/abs/1412.6980>. Acesso em: 15 set. 2025.

KRIZHEVSKY, Alex; SUTSKEVER, Ilya; HINTON, Geoffrey E. **ImageNet classification with deep convolutional neural networks**. 2012. Disponível em: <https://papers.nips.cc>. Acesso em: 15 set. 2025.

MAIS AGRO. **Cultivo do tomate: variedades, manejo e comercialização no Brasil**. 2025. Disponível em: <https://maisagro.syngenta.com.br/tudo-sobre-agro/cultivo-do-tomate-variedades-manejo-e-comercializacao-no-brasil/>. Acesso em: 11 set. 2025.

MONTANARI, Juan Vinícius da Silva. **Uma proposta de algoritmo para treinamento de redes neurais artificiais: primeiros resultados em uma comparação com SGD, Adam e AdaGrad**. *Revista de Sistemas e Computação*. 2025. Disponível em: <https://revistasc.com.br/ojs/index.php/rsc/article/view/62/116>. Acesso em: 14 mar. 2026.

TENSORFLOW. **plant\_village**. 2024. Disponível em: [https://www.tensorflow.org/datasets/catalog/plant\\_village](https://www.tensorflow.org/datasets/catalog/plant_village). Acesso em: 12.abr.2026.

OLIVEIRA, Danielly O. A. de; CASTRO, Josué Pereira de. **Um estudo comparativo entre as arquiteturas de redes neurais profundas AlexNet e YOLO aplicadas ao problema de visão computacional em ambientes agrícolas**. In: CONGRESSO BRASILEIRO DE AGROINFORMÁTICA, 2021. Disponível em: <https://sol.sbc.org.br/index.php/sbiagro/article/view/18405/18238>. Acesso em: 22 mar. 2026.

SILVA, Leonardo Marçal; BARROS, Luana Rodrigues; SANTOS, Máisa Lauriane F; REGIS, Carlos Danilo Miranda. **Deteção de Patologias em Folhas de Tomateiros**

**Utilizando Dois Classificadores.** 2022. Disponível em:

[https://scholar.google.com.br/scholar?hl=pt-](https://scholar.google.com.br/scholar?hl=pt-BR&as_sdt=0%2C5&q=limpeza+de+dados+para+classifica%C3%A7%C3%A3o+de+doen%C3%A7a+tomateiro&btnG=#d=gs_qabs&t=1777742488674&u=%23p%3DDJBe0QpoXM8J)

[BR&as\\_sdt=0%2C5&q=limpeza+de+dados+para+classifica%C3%A7%C3%A3o+de+doen%C3%A7a+tomateiro&btnG=#d=gs\\_qabs&t=1777742488674&u=%23p%3DDJBe0QpoXM8J](https://scholar.google.com.br/scholar?hl=pt-BR&as_sdt=0%2C5&q=limpeza+de+dados+para+classifica%C3%A7%C3%A3o+de+doen%C3%A7a+tomateiro&btnG=#d=gs_qabs&t=1777742488674&u=%23p%3DDJBe0QpoXM8J). Acesso em: 15 set.2025.

ONEDA, Angelo Henrique. **Detecção automática de doenças em plantas utilizando redes neurais convolucionais e transfer learning com ResNet50.** 2026. Disponível em:

<https://iguazu.uniguacu.com.br/index.php/iguazu/article/view/148/127>. Acesso em: 15 mar. 2026.

PYTHON SOFTWARE FOUNDATION. **Python.** 2025. Disponível em:

<https://www.python.org/>. Acesso em: 15 set. 2025.

QUIEREGATO, Gustavo Silva. **Uso de redes convolucionais para extração de características na busca de padrões de cores e texturas em folhas de oliveira.** 2024.

Disponível em:

<https://www.proquest.com/openview/f9ac3679a85519aa28dbd3ccfd90d4a8/1>. Acesso em: 14 mar. 2026.

REVISTA CULTIVAR. **Requeima no tomate: Vilã temida.** 2016. Disponível em:

<https://revistacultivar.com.br/artigos/requeima-no-tomate-vila-temida>. Acesso em: 11 set. 2025.

SILVA, Rodrigues Sousa. Linguagem de programação Python. **Revista Projeção, Ciência e Tecnologia**, [S. l.], 2019. Disponível em:

<https://www.projecaociencia.com.br/index.php/Projecao4/article/view/1359/1064>. Acesso em: 14 mar. 2026.

SOUZA, Victor et al. **Análise comparativa de redes neurais convolucionais no**

**reconhecimento de cenas.** 2020. Disponível em: <https://scholar.google.com.br>. Acesso em: 15 mar. 2026.

STRAUSS, Edilberto; JÚNIOR, Manuel Villas Bôas; FERREIRA, Wagner Luiz Lobo. 2022.

**A importância de Utilizar métricas Adequadas de Avaliação de Performance em Modelos Preditivos de Machine Learning.** Disponível em:

[https://scholar.google.com.br/scholar?hl=pt-](https://scholar.google.com.br/scholar?hl=pt-BR&as_sdt=0%2C5&q=m%C3%A9tricas+de+a+alia%C3%A7ao+F1score&btnG=#d=gs_qabs&t=1779815974801&u=%23p%3D01sgfE_-38cJ)

[BR&as\\_sdt=0%2C5&q=m%C3%A9tricas+de+a+alia%C3%A7ao+F1score&btnG=#d=gs\\_qabs&t=1779815974801&u=%23p%3D01sgfE\\_-38cJ](https://scholar.google.com.br/scholar?hl=pt-BR&as_sdt=0%2C5&q=m%C3%A9tricas+de+a+alia%C3%A7ao+F1score&btnG=#d=gs_qabs&t=1779815974801&u=%23p%3D01sgfE_-38cJ). Acesso em: 26.mai.2026.

FRANCESCHI, Pietro Reinheimer. **Modelagens preditivas de churn: o caso do Banco do Brasil.** 2025. Disponível em: <https://repositorio.jesuita.org.br>. Acesso em: 13 nov. 2025.