

# Classificação de Deficiências em Cafeeiros por Inteligência Artificial

Daniel Hideo Matunoshita<sup>1</sup>

Lucas Pandian Pereira<sup>1</sup>

Prof. Dra. Marisa S.A. Renaud Faulin<sup>2</sup>

Prof. Dr. João Ricardo Favan<sup>2</sup>

**RESUMO:** A adequada nutrição mineral é essencial para o desenvolvimento saudável do cafeeiro, influenciando diretamente sua produtividade e qualidade. Deficiências nutricionais podem comprometer o crescimento das plantas e manifestar-se por alterações visuais nas folhas, como mudanças de coloração, textura e formato. Nesse contexto, a identificação precoce desses sintomas é fundamental para apoiar o manejo agrícola e reduzir prejuízos na produção. Com o avanço da visão computacional e do uso de tecnologias na agricultura, o aprendizado de máquina tem se mostrado uma alternativa promissora para automatizar o diagnóstico agrícola por meio da análise de imagens. Assim, este trabalho tem como objetivo aplicar técnicas de aprendizado de máquina na classificação de deficiências nutricionais em folhas de cafeeiro, utilizando imagens do *dataset CoLeaf-DB* (Tuesta-Monteza et al., 2023). Para isso, foram realizadas etapas de pré-processamento dos dados e a avaliação de diferentes modelos de classificação, buscando analisar seu desempenho, limitações e potencial de aplicação em cenários com restrições computacionais.

---

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

<sup>2</sup> Docente em *Big Data* no Agronegócio na FATEC Pompeia, Pompeia-SP.

**Palavras-chaves:** Cafeicultura; Diagnóstico nutricional; Aprendizado de máquina; Visão computacional; Regressão logística; *CoLeaf-DB*.


## 1. INTRODUÇÃO

O Brasil é o maior produtor e exportador de café do mundo, de acordo com a Companhia Nacional de Abastecimento (CONAB) a produção nacional atingiu cerca de 66 milhões de sacas de 60 kg, que representa aproximadamente 35% da produção global (CONAB, 2026; USDA, 2026). Nesse contexto, a cafeicultura destaca-se como uma atividade de grande relevância para a economia brasileira, sendo responsável pela geração de aproximadamente 8,4 milhões de empregos diretos e indiretos em 2025 (COSTA, 2025). Além de sua importância econômica, a cultura do café exerce papel significativo nos aspectos sociais e culturais do país.

Entretanto, a produtividade do cafeeiro, assim como de outras culturas agrícolas, pode ser afetada por diversos fatores, tais como doenças, pragas e deficiências nutricionais. Nesse contexto, destaca-se a Lei do Mínimo de Liebig, a qual estabelece que o crescimento e o desenvolvimento das plantas são limitados pelo nutriente que se encontra em menor disponibilidade em relação às suas necessidades (Ruela, 2020). Assim, mesmo que outros nutrientes estejam presentes em quantidades adequadas, a ausência ou insuficiência de apenas um elemento essencial pode comprometer significativamente o desempenho da cultura (Taiz; Zeiger, 2013). A deficiência de nutrientes é altamente prejudicial, impactando tanto a produtividade quanto a qualidade dos grãos, além de elevar os custos de produção e reduzir a competitividade no mercado internacional (Malavolta, 2006).

Entre os principais nutrientes essenciais ao desenvolvimento do cafeeiro, destacam-se o boro (B), cálcio (Ca), Ferro (Fe), magnésio (Mg), manganês (Mn), nitrogênio (N), fósforo (P) e potássio (K), cujos sintomas de deficiência são apresentados na Figura 1 (Pennacchi, 2022).

**Figura 1:** Sintomas de deficiências nutricionais em folhas de cafeeiro (B, Ca, Fe, Mg, Mn, N, P e K)



**Fonte:** Adaptado de TUESTA-MONTEZA (2023).

Entre as deficiências nutricionais mais recorrentes, a deficiência de nitrogênio (N) destaca-se por provocar o amarelecimento das folhas e reduzir o crescimento vegetal. A carência de fósforo (P) está associada à coloração arroxeada ou avermelhada na face inferior das folhas, além de comprometer o desenvolvimento da planta. Já a deficiência de potássio (K) manifesta-se por meio de queimaduras e necroses nas bordas foliares (Ruela, 2020).

No caso do cálcio (Ca), sua ausência pode causar necrose nas extremidades das folhas, bem como deformações estruturais. A deficiência de magnésio (Mg) caracteriza-se pela clorose interveinal em folhas mais velhas, mantendo-se as nervuras verdes. Por sua vez, a deficiência de boro (B) resulta em distorções nos meristemas apicais e necrose em brotações jovens (Ruela, 2020).

A deficiência de ferro (Fe) também provoca clorose interveinal, porém em folhas mais novas, preservando a coloração das nervuras. Por fim, a deficiência de manganês (Mn) manifesta-se por clorose interveinal associada ao surgimento de pequenas manchas necróticas ao longo da lâmina foliar (Pennacchi, 2022).

Nesse contexto, a identificação precoce de deficiências nutricionais no cafeeiro torna-se essencial para a adoção de práticas de manejo adequadas, visando

minimizar perdas produtivas e garantir a qualidade dos grãos. A análise visual das folhas é amplamente utilizada como método de diagnóstico, uma vez que os sintomas associados à deficiência de nutrientes manifestam-se de forma característica na coloração, estrutura e padrão das folhas (Malavolta, 2006; Taiz; Zeiger, 2013).

Entretanto, apesar de sua ampla utilização, os métodos tradicionais baseados na observação humana apresentam limitações, sendo frequentemente subjetivos e dependentes do nível de experiência do avaliador. Ademais, esse tipo de análise pode demandar tempo considerável, especialmente em grandes áreas de cultivo, e está sujeito a erros humanos, o que pode comprometer a precisão do diagnóstico (Mohanty; Hughes; Salathé, 2016).

Diante dessas limitações, observa-se um crescente interesse na aplicação de técnicas de aprendizado de máquina e visão computacional para a identificação automática de deficiências nutricionais em plantas, utilizando imagens de folhas como principal fonte de informação (Szeliski, 2010). Essas abordagens permitem maior rapidez, padronização e potencial aumento na acurácia dos diagnósticos, contribuindo para a tomada de decisão no manejo agrícola.

## **2. MATERIAL E MÉTODOS**

Diante desse cenário, o presente trabalho propõe a utilização de técnicas de visão computacional aliadas a modelos de aprendizado de máquina, com o objetivo de classificar automaticamente deficiências nutricionais no cafeeiro a partir de imagens de folhas. Para isso, é utilizada uma base de dados composta por imagens de folhas de cafeeiro, sobre a qual é aplicado um modelo de regressão logística para modelar e classificar padrões associados às diferentes deficiências nutricionais. A metodologia adotada envolve etapas de coleta de dados, pré-processamento das imagens e aplicação dos modelos de Inteligência Artificial conforme descrito na seção a seguir.

### **2.1. COLETA DE DADOS**

Inicialmente, considerou-se a coleta de imagens de folhas de cafeeiro localizadas na Faculdade de Tecnologia “Shunji Nishimura” (Fatec Pompeia – Shunji Nishimura). No entanto, observou-se uma limitação significativa na diversidade de amostras, uma vez que predominavam folhas saudáveis e com deficiência de ferro, dificultando a obtenção de outras classes de deficiência nutricional. Cabe destacar que a utilização

de imagens provenientes de diferentes fontes poderia comprometer a padronização do conjunto de dados, especialmente em relação a fatores como iluminação, resolução e condições de captura. Diante dessas limitações, optou-se pela utilização do *dataset CoLeaf-DB*, proposto por Victor A. Tuesta-Monteza, composto por imagens de folhas de cafeeiro provenientes da província de Jaén, Cajamarca, Peru, abrangendo diferentes condições fitossanitárias, incluindo amostras saudáveis e com diversas deficiências nutricionais. Esse conjunto de dados apresenta maior diversidade e padronização, sendo adequado para o treinamento e a avaliação do modelo proposto (Tuesta-Monteza, 2023).

A Tabela 1 apresenta a distribuição das imagens por classe (tipo de deficiência), bem como o número de amostras em cada categoria.

**Tabela 1** – Deficiências nutricionais (classes) e quantidade de imagens (amostras)

<b>Classes</b>	<b>Números de amostras</b>
Boro (B)	101
Calcio (Ca)	162
Ferro (Fe)	65
Magnésio (Mg)	79
Manganês (Mn)	83
Nitrogênio (N)	64
Fósforo (P)	246
Potássio (K)	96
Saudáveis	6

**Fonte:** Adaptado de Tuesta-Monteza (2023)

## 2.2. PRÉ-PROCESSAMENTO DAS IMAGENS

O pré-processamento dos dados foi dividido em três etapas principais: (i) padronização inicial das imagens e remoção de duplicatas, (ii) recorte e remoção do fundo das imagens e (iii) balanceamento e padronização da quantidade de amostras por classe.

Na etapa de padronização inicial, realizou-se a exclusão da classe de folhas saudáveis, devido à baixa quantidade de amostras disponíveis (apenas seis imagens),

o que poderia comprometer o treinamento do modelo, uma vez que conjuntos de dados desbalanceados tendem a prejudicar o desempenho de algoritmos de classificação (De Vargas et al., 2022). Além do mais, foram removidas imagens duplicadas, considerando que a presença de dados redundantes pode impactar negativamente a eficiência e a generalização dos modelos (Li et al., 2025). Também foi realizada a padronização da orientação das imagens, de modo que todas estivessem alinhadas verticalmente, etapa importante no pré-processamento para garantir maior consistência dos dados e melhor desempenho do modelo (Maharana et al., 2022). Essa etapa foi conduzida de forma manual.

Na segunda etapa, correspondente ao recorte e à remoção do fundo das imagens, utilizou-se o *software ImageJ* (versão 1.54s) com o objetivo de isolar as regiões de interesse e reduzir a influência de ruídos no plano de fundo (IMAGEJ, 2026). A Figura 2 mostra o *software* realizando o recorte de uma amostra.

**Figura 2:** Processo de recorte e remoção do fundo de uma folha de Mg utilizando o *software ImageJ*.



**Fonte:** Elaborado pelos autores (2026)

Por fim, na etapa de balanceamento dos dados, utilizou-se a ferramenta *Orange*, versão 3.40.0, para padronizar a quantidade de imagens por classe (Orange, 2026). Foram selecionadas 57 imagens para cada categoria, correspondendo à menor quantidade de amostras disponível após a remoção das duplicatas, sendo esta referente à classe de deficiência de ferro (He; Garcia, 2009; James et al., 2013).

### 2.3. APLICAÇÃO DOS MODELOS DE INTELIGENCIA ARTIFICIAL

Foram avaliados quatro modelos de classificação com o objetivo de identificar a abordagem mais adequada para a tarefa proposta, contemplando diferentes paradigmas de aprendizado supervisionado. Os modelos analisados foram: modelo constante (*baseline*), utilizado como referência mínima de desempenho; Regressão Logística, amplamente empregada em problemas de classificação supervisionada; *Random Forest*, método de *ensemble* baseado em árvores de decisão; e Rede Neural Artificial do tipo *Multilayer Perceptron (MLP)*, amplamente utilizada em tarefas de reconhecimento de padrões. Todos os modelos foram implementados por meio da ferramenta *Orange*.

O modelo constante foi utilizado como referência mínima de desempenho (*baseline*), realizando previsões com base na classe mais frequente do conjunto de dados. Essa abordagem permite estabelecer um limite inferior de desempenho, servindo como critério comparativo para avaliar a efetividade dos demais modelos (James et al., 2013).

A Regressão Logística foi empregada por sua simplicidade, interpretabilidade e ampla utilização em problemas de classificação supervisionada (Hastie; Tibshirani; Friedman, 2009; James et al., 2013). O modelo foi configurado com regularização do tipo *Ridge (L2)*, utilizando parâmetro de penalização  $C = 1$ , sem aplicação de balanceamento automático das classes. Essa técnica permite controlar o risco de sobreajuste (*overfitting*), promovendo maior capacidade de generalização (Hastie; Tibshirani; Friedman, 2009).

O modelo *Random Forest* foi selecionado por sua robustez e capacidade de modelar relações não lineares, sendo um método de *ensemble* baseado na construção de múltiplas árvores de decisão. Para este estudo, o modelo foi configurado com 10 árvores de decisão, sem limitação da profundidade máxima e com restrição mínima de 5 amostras por subdivisão (*split*), buscando reduzir a variância do modelo e mitigar o risco de sobreajuste (Breiman, 2001).

A Rede Neural Artificial do tipo *Multilayer Perceptron (MLP)* foi incluída devido à sua reconhecida capacidade de modelagem de padrões complexos e não lineares (Rumelhart; Hinton; Williams, 1986; Goodfellow; Bengio; Courville, 2016). A arquitetura adotada consistiu em duas camadas ocultas, com 50 neurônios cada, utilizando função de ativação *ReLU* e o otimizador *Adam*. Foi aplicado parâmetro de regularização  $\alpha = 0,0001$ , com número máximo de 200 iterações. A configuração do

treinamento foi definida de forma replicável, garantindo a reprodutibilidade dos experimentos (Goodfellow; Bengio; Courville, 2016).

Para avaliação do desempenho dos modelos, foram utilizadas as métricas *AUC* (*Area Under the Curve*), acurácia (*CA*), precisão (*Precision*), *recall* e *F1-score*, amplamente empregadas em problemas de classificação (Hastie; Tibshirani; Friedman, 2009; Fawcett, 2006; Sokolova; Lapalme, 2009). A métrica *AUC* avalia a capacidade discriminativa do modelo entre as classes (Fawcett, 2006). A acurácia representa a proporção de classificações corretas em relação ao total de amostras (Hastie; Tibshirani; Friedman, 2009). A precisão indica a proporção de verdadeiros positivos entre as predições positivas realizadas pelo modelo, enquanto o *recall* mede a capacidade de identificar corretamente os exemplos positivos (Sokolova; Lapalme, 2009). O *F1-score* corresponde à média harmônica entre precisão e *recall*, sendo uma métrica balanceada para avaliação geral do modelo (Sokolova; Lapalme, 2009).

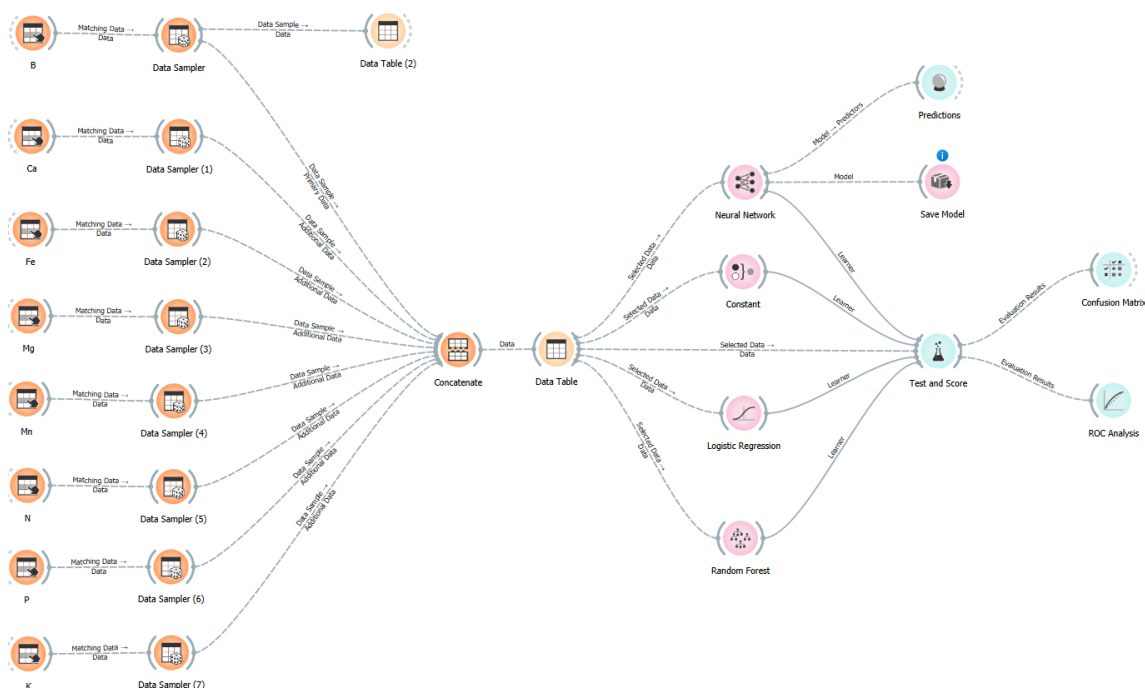
Na etapa de refinamento, a Regressão Logística foi selecionada com base no equilíbrio observado entre desempenho e eficiência computacional durante o treinamento. Foram conduzidos experimentos variando a intensidade do parâmetro de regularização (*C*) do tipo *Ridge* (*L2*). Os resultados indicaram melhor desempenho com o valor de  $C = 0,001$ , evidenciando maior capacidade de generalização do modelo sob maior penalização (Hastie; Tibshirani; Friedman, 2009).

Para validação dos modelos, o conjunto de dados foi dividido em 80% para treinamento e 20% para teste, assegurando a avaliação do desempenho em dados não utilizados durante o processo de treinamento (James et al., 2013).

### 3. RESULTADOS E DISCUSSÃO

Como resultado, foi estruturado um fluxo de processamento na ferramenta *Orange*, conforme apresentado na Figura 3. Esse fluxo contempla as etapas de preparação dos dados, integração das amostras, aplicação dos modelos de classificação e avaliação de desempenho. A construção desse *pipeline* foi fundamental para garantir a consistência experimental, permitindo que todos os modelos fossem treinados e avaliados sob as mesmas condições, o que assegura maior confiabilidade na comparação dos resultados obtidos.

**Figura 3:** Fluxo de processamento do modelo no software Orange.



**Fonte:** Elaborado pelos autores (2026)

A avaliação comparativa dos modelos evidenciou diferenças relevantes de desempenho entre as abordagens testadas. Conforme apresentado na Tabela 2, o modelo constante apresentou o pior resultado, com acurácia de 12%, conforme esperado para um classificador baseado na classe majoritária. Em contrapartida, a Rede Neural Artificial (MLP) obteve o melhor desempenho geral, com acurácia de 59,6%, além dos maiores valores de AUC (0,8915) e F1-score (0,5943).

**Tabela 2:** Resultados gerais dos modelos avaliados

Modelo	<i>AUC</i>	<i>CA</i>	<i>F1</i>	<i>Prec</i>	<i>Recall</i>
<i>Neural Network</i>	0.8915	0.5964	0.5943	0.5941	0.5964
<i>Logistic Regression</i>	0.8871	0.5876	0.5881	0.5913	0.5876
<i>Random Forest</i>	0.8344	0.5189	0.5137	0.5120	0.5189
<i>Constant</i>	0.4900	0.1200	0.1050	0.1040	0.1200


**Fonte:** Elaborado pelos autores (2026)

A Regressão Logística apresentou desempenho muito próximo ao da Rede Neural, com acurácia de 58,7% e AUC de 0,8871, demonstrando elevada capacidade

discriminativa mesmo utilizando um modelo linear (Hastie; Tibshirani; Friedman, 2009; JameS et al., 2013). Para verificar se essa diferença de desempenho era estatisticamente significativa, foi aplicado o teste de normalidade de Shapiro-Wilk, cujo resultado indicou violação da normalidade dos dados ( $p = 0,023$ ) (Shapiro; Wilk, 1965). Dessa forma, optou-se pela utilização do teste não paramétrico de Kruskal-Wallis (Kruskal; Wallis, 1952), que indicou diferenças estatisticamente significativas entre os modelos avaliados para todas as métricas analisadas ( $p < 0,001$ ).

Nas comparações múltiplas realizadas pelo teste Dwass-Steel-Critchlow-Fligner, observou-se que a Regressão Logística e a Rede Neural Artificial não apresentaram diferença estatisticamente significativa entre si, enquanto ambas apresentaram desempenho superior ao Random Forest e ao modelo constante. Essa relação também pode ser visualmente observada no *boxplot* da métrica F1-score apresentado na Figura 4, no qual se verifica maior proximidade entre os desempenhos da Regressão Logística e da Rede Neural, em contraste com os demais modelos (Hollander; Wolfe; Chicken, 2013).

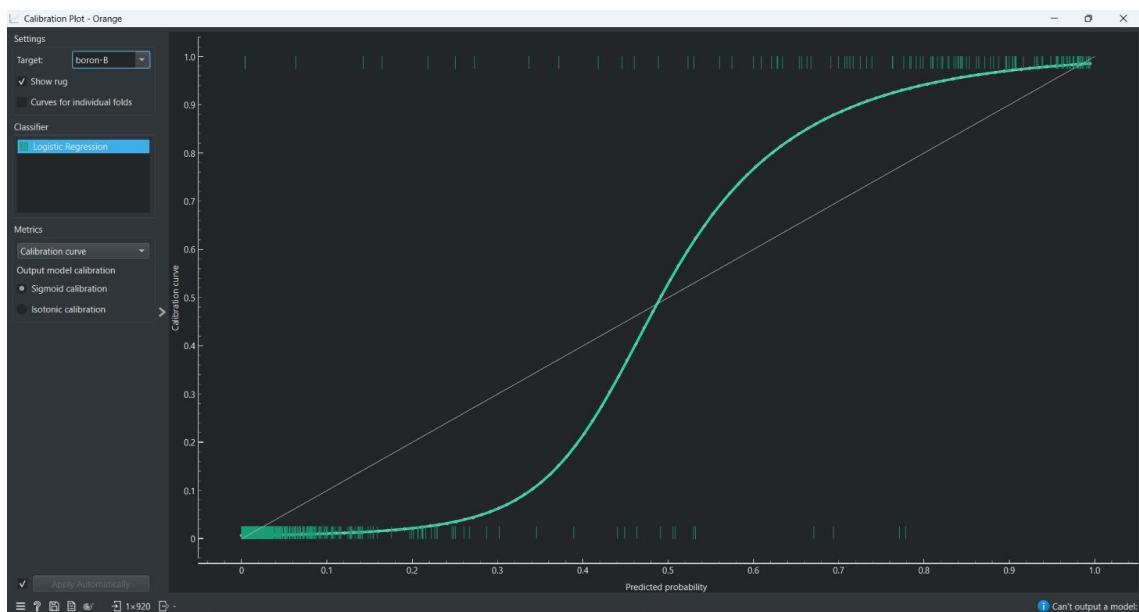
**Figura 4:** *Boxplot* da métrica F1-score para os modelos avaliados.



Fonte: Elaborado pelos autores (2026).

Para aprofundar a compreensão do desempenho do modelo preditivo para a classe do elemento Boro (B), o qual apresentou os melhores resultados de classificação, foram analisadas as curvas de diagnóstico específicas geradas no software Orange. A primeira análise detalhada refere-se à calibração das probabilidades previstas pelo modelo de Regressão Logística, conforme ilustrado na Figura 5.

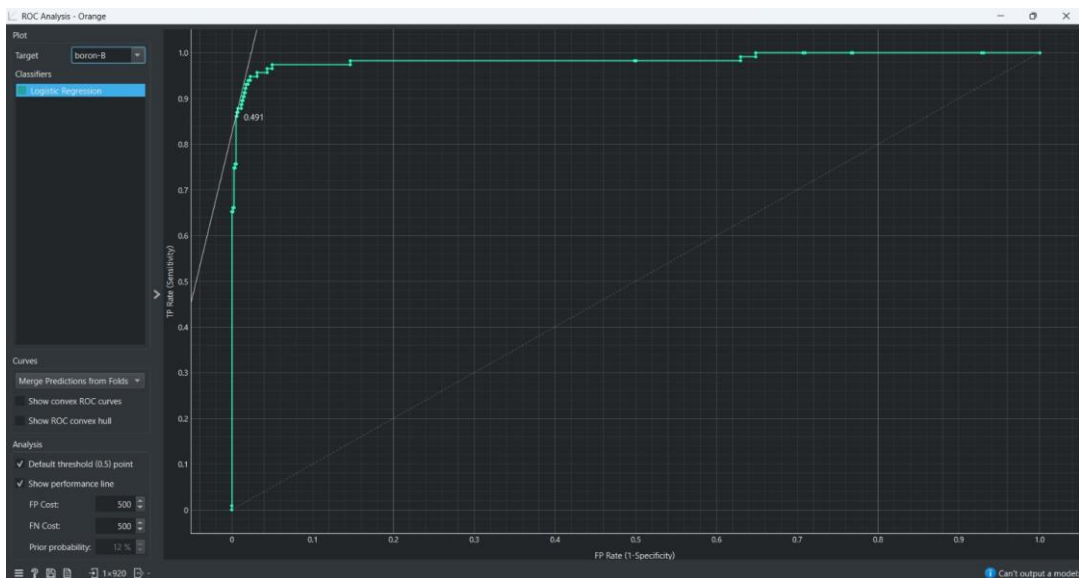
Figura 5: Gráfico de calibração (*Calibration Plot*) para o elemento Boro no software Orange.



Fonte: Elaborado pelos autores (2026)

O gráfico de calibração permite avaliar o quão próximas as probabilidades previstas pelo classificador estão das frequências reais observadas. Nota-se que a curva de calibração assume um formato sigmoide bem definido, cruzando a linha ideal de referência (diagonal de 45°). Nas extremidades próximas a 0 e 1, o modelo demonstra forte convergência com as frequências reais, embora apresente um desvio característico na faixa intermediária de probabilidade predita, o que indica uma transição bem marcada na separação das amostras ligadas ao Boro. Complementarmente, a capacidade discriminativa e a sensibilidade do classificador foram avaliadas por meio da análise ROC, apresentada na Figura 6.

Figura 6: Gráfico de análise ROC (ROC Analysis) para o elemento Boro no software Orange.




Elaborado pelos autores (2026)

A curva ROC confirma a excelente performance da Regressão Logística para o alvo do Boro, evidenciando uma curva que se aproxima rapidamente do canto superior esquerdo do gráfico, o que reflete uma elevada taxa de verdadeiros positivos (sensibilidade) combinada a uma baixa taxa de falsos positivos. Destaca-se o ponto de limiar padrão de 0,5, assinalado no gráfico com sensibilidade de 0,491 antes de atingir o patamar de estabilização próximo à taxa máxima de verdadeiros positivos (1,0). Esse comportamento visual corrobora o alto valor de AUC (área sob a curva) obtido nas tabelas gerais.

Por fim, para entender o ganho de eficiência obtido pelo modelo em comparação com uma escolha puramente aleatória, avaliou-se a curva de performance através do gráfico de *Lift*, exposto na Figura 7.

Figura 7: Gráfico de curva de performance (Performance Curve - *Lift*) para o elemento Boro no software Orange.



Fonte: Elaborado pelos autores (2026)

O gráfico de *Lift* revela que a Regressão Logística entrega um ganho de desempenho expressivo, atingindo um fator de *Lift* máximo próximo a 8 nas faixas iniciais de taxa de positivos (*P Rate*). A curva decresce de forma suave à medida que a taxa de positivos avança, mantendo o indicador acima de 1 durante quase toda a extensão do espaço amostral. Com uma área total sob a curva de *Lift* calculada em 3.016 e um limiar de probabilidade crítico destacado em 0,009, consolida-se que a utilização do Boro como variável preditora permite ao modelo identificar os alvos com uma eficiência muito superior a um classificador basal ou aleatório.

Considerando o desempenho competitivo da Regressão Logística, aliado à sua menor complexidade computacional, menor consumo de memória e maior interpretabilidade, optou-se por sua utilização como modelo principal para as etapas subsequentes do estudo. Essa escolha permite um melhor equilíbrio entre desempenho e eficiência computacional, sendo especialmente relevante em cenários de aplicação prática (Domingos, 2012; Ribeiro; Singh; Guestrin, 2016).

A partir dessa definição, procedeu-se à análise detalhada do desempenho da Regressão Logística por classe, com base na matriz de confusão. Os resultados obtidos demonstraram desempenho moderado na tarefa de classificação das deficiências nutricionais em folhas de cafeeiro. A análise evidencia que o modelo apresentou melhor desempenho em classes como boro (83,5%), cálcio (73,0%) e fósforo (73,7%), enquanto classes como magnésio (42,7%) e manganês (39,7%) apresentaram maior dificuldade de identificação, conforme apresentado na Tabela 3.

**Tabela 3:** Matriz de Confusão do Modelo

Classe Real ↓ / Classe Prevista →	Boro (B)	Cálcio (Ca)	Ferro (Fe)	Magnésio (Mg)	Manganês (Mn)	Nitrogênio (N)	Fósforo (P)	Potássio (K)
<b>Boro (B)</b>	83,5%	1,7%	0,0%	1,7%	4,3%	1,7%	1,7%	5,2%
<b>Cálcio (Ca)</b>	9,0%	73,0%	4,5%	0,9%	4,5%	2,7%	0,9%	4,5%
<b>Ferro (Fe)</b>	0,0%	6,0%	58,6%	15,5%	14,7%	4,3%	0,0%	0,9%
<b>Magnésio (Mg)</b>	2,6%	1,7%	21,4%	42,7%	9,4%	5,1%	2,6%	14,5%
<b>Manganês (Mn)</b>	0,9%	6,9%	19,0%	19,8%	39,7%	6,9%	2,6%	4,3%
<b>Nitrogênio (N)</b>	0,0%	0,9%	2,6%	7,0%	3,5%	59,1%	22,6%	4,3%
<b>Fósforo (P)</b>	0,0%	0,0%	1,7%	0,0%	4,2%	7,6%	73,7%	12,7%
<b>Potássio (K)</b>	5,4%	3,6%	0,0%	9,8%	7,1%	5,4%	3,6%	65,2%

Fonte: Elaborado pelos autores (2026).

Por sua vez, foi observado uma confusão significativa entre algumas classes, especialmente entre ferro, magnésio e manganês, indicando que essas deficiências apresentam padrões visuais semelhantes, o que dificulta sua separação por modelos lineares.

O presente trabalho utilizou o modelo de Regressão Logística para a classificação de deficiências nutricionais em folhas de cafeeiro, considerando um conjunto de dados com 8 classes. O modelo alcançou acurácia global de 58,7% e AUC de 0,8871, indicando boa capacidade discriminativa, mesmo tratando-se de um modelo linear.

Quando comparado aos trabalhos baseados em *deep learning*, observa-se que o desempenho do modelo proposto é inferior em termos de acurácia. Calderón-Mosilot et al. (2025) utilizaram modelos da família YOLO, uma arquitetura de rede neural voltada à detecção de objetos em imagens, capaz de localizar e classificar regiões de interesse de forma automática (Redmon, J. et al., 2016). Ahammed et al. (2025) aplicaram o modelo Inception V3, uma rede neural convolucional profunda que utiliza diferentes filtros para extrair características visuais em múltiplas escalas (Szegedy et al., 2016). Já Tenaye, Diriba e Bedaso (2022) utilizaram o MobileNet, uma arquitetura de *deep learning* projetada para ser mais leve e eficiente, especialmente em aplicações com menor capacidade computacional (Howard et al., 2017).

Esses modelos apresentam vantagem por realizarem extração automática de características complexas das imagens, o que contribui para maior desempenho em

tarefas de classificação visual (Le Cun; Bengio; Hinton, 2015). No entanto, também tendem a exigir maior volume de dados e maior capacidade de processamento (Goodfellow; Bengio; Courville, 2016), além de apresentarem menor transparência na interpretação dos resultados, sendo frequentemente considerados modelos de “caixa-preta” (Ribeiro; Singh; Guestrin, 2016).

Em relação aos modelos tradicionais, Monsalve, Trujillo e Chaves (2015) utilizaram o *Random Forest*, um método baseado na combinação de várias árvores de decisão, capaz de capturar relações não lineares entre os dados (Breiman, 2001). Vassallo-Barco et al. (2016), por sua vez, utilizaram descritores de forma e textura combinados ao classificador *Naive Bayes*, um modelo probabilístico simples que estima a classe mais provável com base nas características observadas (Russell; Norvig, 2010).

Dessa forma, o desempenho do presente estudo mostra-se compatível com abordagens mais simples da literatura, ainda que inferior aos modelos baseados em deep learning. A utilização de 8 classes também aumenta a complexidade da tarefa, uma vez que problemas multiclasse tendem a apresentar maior dificuldade de classificação (James et al., 2013), especialmente quando algumas deficiências apresentam padrões visuais semelhantes, o que pode gerar sobreposição entre as classes e dificultar sua separação (Bishop, 2006).

Com o objetivo de sintetizar e facilitar a comparação entre os diferentes estudos apresentados na literatura e o modelo proposto neste trabalho, a Tabela 4 apresenta um resumo dos principais resultados, considerando os modelos utilizados, o número de classes, o tamanho do conjunto de dados e as métricas de desempenho obtidas. Essa comparação permite uma análise mais clara das diferenças entre as abordagens, evidenciando o impacto da complexidade dos modelos, da quantidade de dados e da estrutura do problema nos resultados alcançados.

**Tabela 4:** Comparação entre os trabalhos relacionados e o modelo proposto

Referência	Modelo	Nº de Classes	Classes usadas	Desempenho
Vassallo-Barco et al. (2016)	Naive Bayes + descritores	4	B, Fe, K e Ca	F1 = 64,9%

Monsalve, Trujillo e Chaves (2015)	Random Forest	8	B, N, Ca, Fe, Mg, Mn, P e K	Acurácia = 67,5%
Tenaye, Diriba e Bedaso (2022)	MobileNet	4	P, Ca, B e Fe	Acurácia = 98,8%
Ahammed et al. (2025)	Inception V3	10	B, Ca, Fe, MG, Mn, N, P, K, Saudáveis e outras deficiências	Acurácia = 83,32%
Calderón-Mosilot et al. (2025)	YOLO	6	N, P, K, Ca, Mg e Fe	F1 = 88,76%
<b>Modelo Proposto</b>	Regressão Logística	8	B, N, Ca, Fe, Mg, Mn, P e K	Acurácia = 58,7% / AUC = 0,8871

**Fonte:** Elaborado pelos autores (2026)

Conforme apresentado na Tabela 4, observa-se que os modelos baseados em *deep learning*, como *YOLO*, *Inception V3* e *MobileNet*, apresentam os melhores resultados em termos de desempenho, especialmente em cenários com maior volume de dados e menor número de classes. Esses modelos se destacam pela capacidade de extrair automaticamente características complexas das imagens, favorecendo a classificação (Lecun; Bengio; Hinton, 2015; Goodfellow; Bengio; Courville, 2016).

Por outro lado, modelos tradicionais, como *Random Forest* e *Naive Bayes*, apresentam desempenho intermediário, sendo mais dependentes das características previamente extraídas dos dados (Bishop, 2006; James et al., 2013). O modelo proposto, baseado em Regressão Logística, apresentou desempenho inferior em termos de acurácia quando comparado aos demais estudos, o que pode ser explicado tanto pela menor complexidade do modelo quanto pelo maior número de classes considerado.

No entanto, destaca-se que o modelo proposto apresentou elevada capacidade discriminativa (AUC = 0,8871), além de vantagens importantes relacionadas à interpretabilidade e ao menor custo computacional no processo de treinamento. Dessa

forma, observa-se que, embora modelos mais complexos apresentem maior desempenho, abordagens mais simples podem ser viáveis, especialmente em cenários com restrições de recursos ou quando se busca maior transparência nas decisões do modelo (James et al., 2013; Ribeiro; Singh; Guestrin, 2016).

#### 4. CONSIDERAÇÕES FINAIS

O presente trabalho cumpriu o objetivo de aplicar e avaliar técnicas de aprendizado de máquina na classificação multiclasse de deficiências nutricionais em folhas de cafeeiro utilizando o *dataset CoLeaf-DB*. Diante da proposta de analisar abordagens viáveis para cenários com restrições computacionais, os resultados demonstraram que o modelo de Regressão Logística, apesar de sua simplicidade linear, apresentou uma capacidade discriminativa global robusta ( $AUC = 0,8871$ ), consolidando-se como uma alternativa de baixo custo computacional, alta interpretabilidade e reduzido consumo de memória em comparação com arquiteturas de *deep learning*.

No que tange ao desempenho por classe, o objetivo de identificação automatizada foi alcançado com alto índice de acerto para os elementos Boro (83,5%), Fósforo (73,7%) e Cálcio (73,0%). Em contrapartida, constatou-se que o modelo encontrou limitações severas na distinção de Magnésio (42,7%) e Manganês (39,7%), cujas taxas de acerto ficaram abaixo do patamar aceitável para diagnósticos de campo seguros. Essa fragilidade específica aponta que sintomas com sobreposição visual severa e padrões de clorose intervernal semelhantes desafiam a capacidade de separação de fronteiras lineares, sugerindo que tais classes demandam ou a extração prévia de descritores de textura mais complexos ou a reavaliação de sua permanência em modelos simplificados. Ademais, a redução do tamanho amostral para 57 imagens por classe na etapa de balanceamento configurou-se como um fator limitante para a generalização do classificador.

Em suma, conclui-se que a automação do diagnóstico via Regressão Logística é parcialmente viável e promissora para aplicação em dispositivos de processamento limitado (como aplicativos mobile em campo ou sistemas embarcados), contanto que o escopo de alvos seja otimizado ou integrado a rotinas híbridas de extração de características. Como perspectivas para trabalhos futuros, recomenda-se expressamente a ampliação do banco de dados (*Data Augmentation*) para mitigar a

escassez de amostras, o desenvolvimento de algoritmos avançados para a segmentação automática de lesões foliares na etapa de pré-processamento e a investigação de técnicas de comitês de modelos (*ensembles*) leves, buscando elevar a acurácia global sem abdicar da eficiência computacional requerida pela realidade do produtor rural.

## AGRADECIMENTOS

Gostaríamos de agradecer, primeiramente, a Deus por mais esta etapa concluída em nossas vidas. Agradecemos também à Prof.<sup>a</sup> Marisa S. A. Renaud Faulin, pela orientação e pelos valiosos conhecimentos compartilhados na área de estudo, fundamentais para o desenvolvimento deste trabalho.

Estendemos nossos agradecimentos ao Prof. Dr. João Ricardo Favan, pela coorientação e pelo suporte técnico oferecido ao longo do projeto, contribuindo significativamente para a construção e implementação da proposta apresentada.

## REFERÊNCIAS

- AHAMMED, F. et al. *Classifying nutritional deficiencies in coffee leaf using transfer learning and Grad-CAM visualization*. EPJ Web of Conferences, 2025. DOI: <https://doi.org/10.1109/ICCCT63501.2025.11019090>. Acesso em: 25 abr. 2026.
- BISHOP, Christopher M. *Pattern Recognition and Machine Learning*. New York: Springer, 2006. p. 1-4.
- BREIMAN, L. *Random forests*. *Machine Learning*, v. 45, n. 1, p. 5-32, 2001. Disponível em: <https://doi.org/10.1023/A:1010933404324>. Acesso em: 22 abr. 2026.
- CALDERÓN-MOSILOT, C.; TAPIA-GÁLVEZ, U.; ARCILA-DÍAZ, J.; MEJIA-CABRERA, H. I. *Diagnosis of nutritional deficiencies in coffee plants through automated analysis of digital images using deep learning in uncontrolled agricultural environments*. *AgriEngineering*, v. 7, n. 12, p. 421, 2025. Disponível em: <https://doi.org/10.3390/agriengineering7120421>. Acesso em: 15 abr. 2026.
- COMPANHIA NACIONAL DE ABASTECIMENTO (CONAB). *1º levantamento de café - safra 2026*. Brasília, DF, 2026. Disponível em: <https://www.gov.br/conab/pt-br/atuacao/informacoes-agropecuarias/safras/safra-de-cafe/1o-levantamento-de-afe-safra-2026/1o-levantamento-de-cafe-safra-2026>. Acesso em: 22 abr. 2026.

COSTA, A. *VBP: café gera R\$ 116 bilhões para a economia brasileira e protagoniza um avanço de 46% em um ano*. Conselho Nacional do Café, 28 fev. 2025. Disponível em: <https://cncafe.com.br/vbp-cafe-gera-r116-bilhoes-para-a-economia-brasileira-e-protagoniza-um-avanco-de-46-em-um-ano/>. Acesso em: 6 abr. 2026.

DE VARGAS, V. W. et al. *Imbalanced data preprocessing techniques for machine learning*. 2022. Disponível em: <https://doi.org/10.1007/s10115-022-01772-8>. Acesso em: 22 abr. 2026.

DOMINGOS, P. A few useful things to know about machine learning. *Communications of the ACM*, 2012. Disponível em: <https://doi.org/10.1145/2347736.2347755>. Acesso em: 24 abr. 2026.

FAWCETT, T. *An introduction to ROC analysis*. *Pattern Recognition Letters*, v. 27, n. 8, p. 861–874, 2006. Disponível em: <https://doi.org/10.1016/j.patrec.2005.10.010>. Acesso em: 23 abr. 2026.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*. Cambridge: MIT Press, 2016. Disponível em: <https://doi.org/10.1007/s10710-017-9314-z>. Acesso em: 22 abr. 2026.

HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. *The elements of statistical learning: data mining, inference and prediction*. New York: Springer, 2009.

HE, H.; GARCIA, E. A. *Learning from imbalanced data*. *IEEE Transactions on Knowledge and Data Engineering*, 2009. Disponível em: <https://doi.org/10.1109/TKDE.2008.239>. Acesso em: 23 abr. 2026.

HOWARD, Andrew G. et al. *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications*. arXiv preprint arXiv:1704.04861, 2017. Disponível em: <https://doi.org/10.48550/arXiv.1512.00567>. Acesso em: 29 abr. 2026.

HOLLANDER, M.; WOLFE, D. A.; CHICKEN, E. *Nonparametric statistical methods*. 3. ed. Wiley, 2013. Disponível em: <https://doi.org/10.1002/9781119196037>. Acesso em: 28 abr. 2026.

IMAGEJ. In: *ImageJ*. 1.54s. [S. l.], 2026. Disponível em: <https://wsr.imagej.net/notes.html>. Acesso em: 22 abr. 2026.

JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. *An introduction to statistical learning: with applications in R*. New York: Springer, 2013. p. 127–129.

KRUSKAL, W. H.; WALLIS, W. A. *Use of ranks in one-criterion variance analysis*.

Journal of the American Statistical Association, 1952. Disponível em: <https://doi.org/10.2307/2280779>. Acesso em: 28 abr. 2026.

LE CUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. *Deep learning*. *Nature*, v. 521, p. 436–444, 2015. Disponível em: <https://doi.org/10.1038/nature14539>. Acesso em: 29 abr. 2026.

MAHARANA, K. et al. *Data preprocessing and data augmentation techniques in machine learning*. 2022. Disponível em: <https://doi.org/10.1016/j.gltp.2022.04.020>. Acesso em: 22 abr. 2026.

MALAVOLTA, E. *Manual de nutrição mineral de plantas*. São Paulo: Agronômica Ceres, 2006.

MOHANTY, S. P.; HUGHES, D. P.; SALATHÉ, M. *Using deep learning for image-based plant disease detection*. *Frontiers in Plant Science*, v. 7, p. 1419, 2016. Disponível em: <https://doi.org/10.3389/fpls.2016.01419>. Acesso em: 22 abr. 2026.

MONSALVE, D.; TRUJILLO, M.; CHAVES, D. *Automatic classification of nutritional deficiencies in coffee plants*. In: LATIN-AMERICAN CONFERENCE ON NETWORKED AND ELECTRONIC MEDIA (LACNEM), 2015. DOI: <https://doi.org/10.1049/ic.2015.0317>. Acesso em: 26 abr. 2026

ORANGE. In: Orange Data Mining. Versão 3.40.0. [S. I.], 2026. Disponível em: <https://orangedatamining.com/download/>. Acesso em: 23 abr. 2026.

PENNACCHI, J. P. *Deficiência nutricional no cafeeiro: como identificar e corrigir*. Aegro, 2022. Disponível em: <https://page-institucional.staging.aegro.io/blog/deficiencia-nutricional-do-cafeeiro/>. Acesso em: 9 abr. 2026.

REDMON, Joseph et al. *You Only Look Once: Unified, Real-Time Object Detection*. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016. Disponível em: <https://doi.org/10.48550/arXiv.1506.02640>. Acesso em: 29 abr. 2026.

RIBEIRO, M. T.; SINGH, S.; GUESTRIN, C. “Why Should I Trust You?”: Explaining the Predictions of Any Classifier. 2016. Disponível em: <https://doi.org/10.48550/arXiv.1602.04938>. Acesso em: 24 abr. 2026.

RUELA, V. *Guia completo sobre a deficiência de nutrição e suas consequências no cafeeiro*. [S.I.]: Terra de Cultivo, 2020. Disponível em: <https://www.terradecultivo.com.br/wp-content/uploads/2020/08/EBOOK->

[DEFICI%C3%8ANCIA-DE-NUTRI%C3%87%C3%83O-NO-CAFEIRO.pdf](#). Acesso em: 9 abr. 2026.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. *Nature*, v. 323, p. 533-536, 1986.

RUSSELL, Stuart; NORVIG, Peter. *Artificial Intelligence: A Modern Approach*. 3. ed. Upper Saddle River: Prentice Hall, 2010. p. 499.

SHAPIRO, S. S.; WILK, M. B. *An analysis of variance test for normality (complete samples)*. *Biometrika*, v. 52, n. 3/4, p. 591–611, 1965. Disponível em: <https://doi.org/10.2307/2333709>. Acesso em: 28 abr. 2026.

SOKOLOVA, M.; LAPALME, G. *A systematic analysis of performance measures for classification tasks*. *Information Processing & Management*, v. 45, n. 4, p. 427–437, 2009. Disponível em: <https://doi.org/10.1016/j.ipm.2009.03.002>. Acesso em: 23 abr. 2026.

SZEGEDY, Christian et al. *Rethinking the Inception Architecture for Computer Vision*. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016. Disponível em: <https://doi.org/10.48550/arXiv.1512.00567>. Acesso em: 29 abr. 2026.

SZELISKI, R. *Computer vision: algorithms and applications*. London: Springer, 2010.

TAIZ, L.; ZEIGER, E. *Fisiologia vegetal*. 5. ed. Porto Alegre: Artmed, 2013.

TENAYE, F.; DIRIBA, C.; BEDASO, M. *Coffee Arabica nutrient deficiency detection system using image processing techniques*. *Biomedical Journal of Scientific & Technical Research*, v. 46, n. 4, 2022. Disponível em: <http://dx.doi.org/10.26717/BJSTR.2022.46.007374>. Acesso em: 26 abr. 2026

TUESTA-MONTEZA, V. A.; MEJIA-CABRERA, H. I.; ARCILA-DIAZ, J. *CoLeaf-DB: Peruvian coffee leaf images dataset for coffee leaf nutritional deficiencies detection and classification*. *Data in Brief*, v. 48, 2023. Disponível em: <https://doi.org/10.1016/j.dib.2023.109226>. Acesso em: 9 abr. 2026.

UNITED STATES DEPARTMENT OF AGRICULTURE (USDA). *Foreign Agricultural Service. Production, Supply and Distribution Database – Coffee*. Disponível em: <https://www.fas.usda.gov/data/production/commodity/0711100>. Acesso em: 6 abr. 2026.

VASSALLO-BARCO, M.; VIVES-GARNIQUE, L.; TUESTA-MONTEZA, V.; MEJÍA-CABRERA, H. I.; TOLEDO, R. Y. Automatic detection of nutritional deficiencies in coffee tree leaves through shape and texture descriptors. *Journal of Digital Information Management*, v. 14, n. 5, p. 347-354, 2016. Disponível em: <https://www.scopus.com/pages/publications/85016474670>. Acesso em: 28 abr. 2026