

UNIVERSIDADE FEDERAL DE OURO PRETO
INSTITUTO DE CIÊNCIAS EXATAS E BIOLÓGICAS
DEPARTAMENTO DE COMPUTAÇÃO

ANA LAURA SIQUEIRA MENDES

**APLICAÇÃO DE REDES NEURAIS CONVOLUCIONAIS NO
RECONHECIMENTO DE GÊNERO EM CALOPSITAS**

Ouro Preto
2026

ANA LAURA SIQUEIRA MENDES

**APLICAÇÃO DE REDES NEURAIS CONVOLUCIONAIS NO RECONHECIMENTO
DE GÊNERO EM CALOPSITAS**

Monografia apresentada ao Curso de Ciência da Computação da Universidade Federal de Ouro Preto como parte dos requisitos necessários para a obtenção do grau de Bacharel em Ciência da Computação.

Orientador: Jadson Castro Gertrudes

Ouro Preto
2026



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE OURO PRETO
REITORIA
INSTITUTO DE CIÊNCIAS EXATAS E BIOLÓGICAS
DEPARTAMENTO DE COMPUTAÇÃO



FOLHA DE APROVAÇÃO

Ana Laura Siqueira Mendes

Aplicação de Redes Neurais Convolucionais no Reconhecimento de Gênero em Calopsitas

Monografia apresentada ao Curso de Ciência da Computação da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Bacharel em Ciência da Computação

Aprovada em 20 de Julho de 2026.

Membros da banca

Jadson Castro Gertrudes (Orientador) - Doutor - Universidade Federal de Ouro Preto
Arthur Negrão Costa (Examinador) - Bacharel - Programa de Pós-Graduação em Ciência da Computação - UFOP
Hugo Eduardo Ziviani (Examinador) - Mestre - Universidade Federal de Ouro Preto

Jadson Castro Gertrudes, Orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 20/07/2026.



Documento assinado eletronicamente por **Jadson Castro Gertrudes, PROFESSOR DE MAGISTERIO SUPERIOR**, em 28/07/2026, às 22:06, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **1142651** e o código CRC **12EE816F**.

Todos esses que aí estão
Atravancando meu caminho,
Eles passarão...
Eu passarinho!
(QUINTANA, 1978)

Resumo

As calopsitas (*Nymphicus hollandicus*) são aves que, em sua variação silvestre, apresentam dimorfismo sexual visível, sendo os machos e as fêmeas distinguíveis principalmente pela coloração das penas. Ao longo dos séculos, porém, as calopsitas sofreram mutações genéticas que deram origem a novos padrões de plumagem, tornando sutil a diferenciação de gênero entre elas. Neste trabalho, investiga-se a aplicação de técnicas de aprendizado profundo para a identificação não invasiva do gênero de calopsitas a partir de imagens. Para isso, foi construída uma base de dados composta por 159 fotografias obtidas em redes sociais e por meio da participação voluntária de tutores de calopsitas. Foram desenvolvidos e avaliados dois modelos baseados na arquitetura ResNet50 pré-treinada na ImageNet. O primeiro experimento utilizou uma estratégia convencional de treinamento, enquanto o segundo incorporou validação cruzada estratificada, arquitetura multiescala e um processo de fine tuning mais refinado. Os resultados demonstraram que o primeiro modelo apresentou desempenho limitado, alcançando acurácia de 56,52% e forte tendência à classificação predominante da classe masculina. Em contrapartida, o segundo experimento obteve acurácia de 78,26%, precisão de 83,33%, recall de 76,92% e F1-score de 80,00%, evidenciando melhor capacidade de generalização e maior equilíbrio entre as classes. Os resultados indicam que redes neurais convolucionais constituem uma abordagem promissora para o problema, embora a disponibilidade limitada de dados ainda represente um desafio importante.

Palavras-chave: calopsita; aprendizado profundo; redes neurais convolucionais; ResNet50; classificação de imagens; visão computacional.

Abstract

Cockatiels (*Nymphicus hollandicus*) are birds that exhibit visible sexual dimorphism in their wild phenotype, with males and females being distinguished primarily by their plumage coloration. Over the centuries, however, genetic mutations have given rise to new plumage patterns, making gender differentiation considerably more subtle. This study investigates the application of deep learning techniques for the non-invasive identification of cockatiel gender from images. To this end, a dataset consisting of 159 photographs was assembled from social media platforms and through the voluntary participation of cockatiel owners. Two models based on the ImageNet pre-trained ResNet50 architecture were developed and evaluated. The first experiment employed a conventional training strategy, whereas the second incorporated stratified cross-validation, a multi-scale architecture, and a more refined fine-tuning process. The results showed that the first model achieved limited performance, reaching an accuracy of 56.52% and exhibiting a strong bias toward the male class. In contrast, the second experiment achieved an accuracy of 78.26%, a precision of 83.33%, a recall of 76.92%, and an F1-score of 80.00%, demonstrating improved generalization and a more balanced performance across both classes. The results indicate that convolutional neural networks constitute a promising approach to this problem, although the limited availability of labeled data remains a significant challenge.

Keywords: cockatiel; deep learning; convolutional neural networks; ResNet50; image classification; computer vision.

Lista de Figuras

Figura 2.1 – Calopsitas selvagens na Austrália.	3
Figura 2.2 – Exemplos de mutações e suas combinações em calopsitas.	4
Figura 2.3 – Esquema representativo de uma rede neural artificial.	5
Figura 2.4 – Diagrama ilustrando um bloco residual da arquitetura <i>ResNet</i>	6
Figura 3.1 – Exemplos de imagens contidas no <i>dataset</i> após segmentação.	11
Figura 3.2 – Arquitetura utilizada no Experimento 1.	14
Figura 3.3 – Arquitetura multiescala utilizada no Experimento 2.	16
Figura 4.1 – Matriz de confusão obtida no Experimento 1.	18
Figura 4.2 – Matriz de confusão obtida no Experimento 2.	19

Lista de Tabelas

Tabela 4.1 – Resultados do Experimento 1.	17
Tabela 4.2 – Resultados do Experimento 2.	18
Tabela 4.3 – Comparação entre os experimentos realizados.	19

Sumário

1	Introdução	1
1.1	Justificativa	1
1.2	Objetivos	2
1.3	Organização do Trabalho	2
2	Revisão Bibliográfica	3
2.1	Características da Calopsita	3
2.2	Redes Neurais Artificiais	5
2.2.1	Arquitetura <i>ResNet-50</i>	6
2.2.2	Problemas <i>few-shot</i> para classificação de imagens	7
2.2.3	Validação cruzada com <i>k-folds</i>	8
2.3	Trabalhos Relacionados	8
3	Desenvolvimento	10
3.1	Metodologia	10
3.1.1	Base de dados para treinamento	10
3.1.1.1	Coleta de imagens	10
3.1.1.2	Organização do <i>dataset</i>	11
3.1.1.3	Tratamento das imagens	12
3.1.2	Treinamento dos modelos	12
3.1.2.1	Ambiente de execução	12
3.1.2.2	Experimento 1	13
3.1.2.3	Experimento 2	14
3.1.2.4	Avaliação dos modelos	16
4	Resultados	17
4.1	Experimento 1	17
4.2	Experimento 2	18
4.3	Comparação entre os experimentos	19
5	Considerações Finais	21
5.1	Conclusão	21
5.2	Trabalhos Futuros	21
	Referências	23

1 Introdução

As calopsitas (*Nymphicus hollandicus*) são aves nativas da Austrália que conquistaram grande popularidade devido à sua natureza dócil (GRESPLAN et al., 2014). Os psitacídeos, família de pássaros à qual pertencem as calopsitas, possuem a característica de dimorfismo sexual, onde machos e fêmeas exibem características físicas distintas. No caso das calopsitas, esta diferença se dá principalmente pela coloração das penas e pelo comportamento apresentado pelas aves (THOMPSON, 1982).

Ao longo dos séculos, as calopsitas passaram por mutações genéticas que deram origem a novos padrões de plumagem (RUBIN, 1997). Nesse cenário evolutivo, em algumas mutações, as diferenças entre machos e fêmeas tornaram-se sutis ou até mesmo imperceptíveis por um observador menos experiente. Sendo assim, para determinar o gênero da ave, é necessário realizar exames de sexagem em laboratório, que envolvem a coleta de sangue ou penas. Esse procedimento é considerado invasivo, custoso e requer mão de obra especializada (TURCU et al., 2025).

Observando essa complexidade genética, tecnologias avançadas de *deep learning* apresentam-se como ferramentas promissoras para a identificação dos gêneros das calopsitas. Com o uso adequado de algoritmos de aprendizagem, podemos evitar métodos invasivos de sexagem e reduzir a necessidade de exames laboratoriais, independentemente das variações de plumagem que possam influenciar o dimorfismo sexual.

Este estudo, portanto, propõe explorar e desenvolver um modelo de classificação de imagens baseado em técnicas de *deep learning* a fim de discernir calopsitas machos e fêmeas com alta precisão, proporcionando uma ferramenta valiosa para criadores de pássaros e entusiastas interessados na determinação do sexo dessas aves.

1.1 Justificativa

A identificação precisa do gênero das calopsitas é um desafio devido às variações genéticas que podem tornar o dimorfismo sexual sutil ou imperceptível a um observador inexperiente. Atualmente, a sexagem das aves é realizada por meio de exames laboratoriais que envolvem a coleta de sangue ou penas, sendo um procedimento invasivo, custoso e que requer mão de obra especializada. Neste contexto, a aplicação de técnicas de aprendizado profundo surge como uma solução acessível, eficaz e de resultado imediato para automatizar e aprimorar a identificação do gênero das calopsitas, evitando métodos que causam sofrimento animal e reduzindo custos com exames laboratoriais.

A motivação pessoal para este estudo surgiu a partir da experiência com uma calopsita que, por muito tempo, foi tratada como um macho devido às suas características físicas, mas

que posteriormente foi identificada como fêmea. Esse caso levanta a hipótese de que um modelo baseado em aprendizado profundo pode identificar padrões visuais que diferenciam machos e fêmeas de maneira mais precisa do que a percepção humana. Assim, o desenvolvimento de uma ferramenta inteligente para a sexagem de calopsitas pode contribuir significativamente para criadores, veterinários e pesquisadores, além de agregar novos conhecimentos sobre os padrões visuais utilizados na distinção entre os gêneros dessas aves.

1.2 Objetivos

O objetivo principal desta pesquisa é desenvolver um método preciso e não invasivo para a sexagem de calopsitas. Para tanto, são definidos os seguintes objetivos específicos:

- Construir uma base de dados com imagens de calopsitas previamente classificadas entre machos e fêmeas, garantindo a diversidade e a qualidade dos dados para o treinamento do modelo;
- Desenvolver e treinar um algoritmo de aprendizado profundo capaz de analisar as imagens e identificar padrões visuais que diferenciem os gêneros das aves.

1.3 Organização do Trabalho

O presente trabalho se organiza na forma de capítulos, onde o Capítulo 1 apresenta a contextualização do problema e os objetivos da pesquisa. O Capítulo 2 traz a revisão bibliográfica e o embasamento teórico, abordando as características das calopsitas e os fundamentos sobre redes neurais convolucionais. No Capítulo 3, são descritas a metodologia empregada no desenvolvimento do modelo, as etapas de construção da base de dados e as técnicas utilizadas para o treinamento da rede neural. O Capítulo 4 apresenta os resultados obtidos nos experimentos, analisando o desempenho do modelo e as dificuldades encontradas. Por fim, o Capítulo 5 discute as conclusões do estudo e propõe direções para trabalhos futuros.

2 Revisão Bibliográfica

2.1 Características da Calopsita

Os primeiros registros da exportação de calopsitas da Austrália datam do século XIX ([Cockatiel World, 2024](#)). Desde então, essas aves ganharam popularidade em diversos países devido ao seu temperamento dócil e à sua capacidade de socialização.

Em sua forma silvestre, os machos apresentam uma coloração acinzentada no corpo, enquanto a cabeça é amarela com bochechas alaranjadas vibrantes. As fêmeas, por sua vez, possuem tons mais suaves, cabeça acinzentada com alguns tons amarelos e uma cauda rajada, evidenciando um forte dimorfismo sexual ([Nancy A. Reed, 1978](#)). A [Figura 2.1](#) ilustra um bando de calopsitas silvestres, exemplificando a coloração típica da mutação cinza-normal e o dimorfismo sexual presente nessa variedade.

Figura 2.1 – Calopsitas selvagens na Austrália.



Fonte: [Wikipedia contributors \(2023\)](#).

Quando trazidas para o ambiente doméstico, as calopsitas sofreram mutações que impactaram fortemente a variedade de plumagens. De acordo com [American Cockatiel Society \(2024\)](#), atualmente, existem dez mutações além da calopsita cinza-normal. São elas: Cinnamon, Pearl, Lutino, Yellowface, Pied, Silver, Fallow, Whiteface, Dominant Silver e Pastel. O cruzamento entre essas mutações pode resultar em combinações ainda mais variadas, aumentando a complexidade e a riqueza das características visuais dessas aves. A imagem a seguir ilustra algumas dessas mutações, bem como exemplos de misturas genéticas, destacando a ampla variação fenotípica das calopsitas.

Figura 2.2 – Exemplos de mutações e suas combinações em calopsitas.



Fonte: Avian Awareness (2014).


2.2 Redes Neurais Artificiais

As redes neurais artificiais são modelos computacionais de aprendizado de máquina inspirados no funcionamento do cérebro humano, projetados para identificar padrões complexos e realizar previsões com base em grandes volumes de dados (IBM, 2025).

Dentre os modelos de redes neurais artificiais, destacam-se as redes neurais convolucionais (*Convolutional Neural Networks, CNNs*). Essas redes se mostram eficientes na identificação de padrões visuais, sendo amplamente utilizadas em tarefas como reconhecimento de objetos e classificação de imagens (KRICHEN, 2023). A arquitetura convolucional opera por meio de camadas de “neurônios” que aplicam filtros sobre a imagem, extraindo características em diferentes níveis de abstração. Nas camadas iniciais, esses filtros identificam padrões simples, como bordas e formas geométricas. À medida que a rede se aprofunda, os filtros tornam-se mais sofisticados, permitindo a detecção de estruturas complexas, como texturas, objetos, feições humanas e até mesmo categorias inteiras, como espécies de animais.

Além das camadas convolucionais, as CNNs utilizam o algoritmo de *pooling* para reduzir a dimensionalidade dos mapas de características, preservando as informações mais relevantes da imagem. O *max pooling*, por exemplo, seleciona o valor máximo dentro de uma região específica, ajudando a destacar as características mais significativas e tornando a rede mais robusta a variações na posição dos objetos. Esse processo aumenta a eficiência computacional da rede, reduzindo a quantidade de informações a serem processadas pelas camadas subsequentes (GOODFELLOW; BENGIO; COURVILLE, 2016).

Figura 2.3 – Esquema representativo de uma rede neural artificial.



A camada de entrada, destacada em amarelo, recebe os dados brutos e os transmite às camadas ocultas, representadas em azul, responsáveis pelo processamento e extração de características. Por fim, a camada de saída, em laranja, gera a previsão ou classificação do modelo. Cada conexão entre os neurônios simboliza a aplicação de pesos e funções de ativação que permitem à rede aprender padrões complexos.

Fonte: Adaptado de Coelho (2017).

2.2.1 Arquitetura *ResNet-50*


As redes de aprendizagem residual (*Residual Neural Networks – ResNet*) foram propostas por He et al. (2016) com o objetivo de solucionar um dos principais desafios do treinamento de redes neurais profundas: a degradação do desempenho à medida que novas camadas são adicionadas à arquitetura. Embora o aumento da profundidade da rede permita a extração de características cada vez mais refinadas, arquiteturas muito profundas tornam-se mais difíceis de otimizar, sofrendo com problemas como a dissipação do gradiente (*vanishing gradient*) e a degradação da acurácia durante o treinamento.

A principal contribuição da arquitetura *ResNet* consiste na introdução das conexões residuais (*skip connections* ou *shortcuts*), que permitem que a entrada de um bloco seja propagada diretamente para sua saída, contornando uma ou mais camadas convolucionais. Essa abordagem facilita a propagação dos gradientes durante o processo de retropropagação, reduzindo os efeitos do desaparecimento do gradiente e permitindo o treinamento de redes significativamente mais profundas (HE et al., 2016).

Dentre as arquiteturas dessa família, destaca-se a *ResNet-50*, composta por 50 camadas profundas organizadas em blocos residuais do tipo *bottleneck*. Esses blocos são formados por três camadas convolucionais (1×1 , 3×3 e 1×1), responsáveis, respectivamente, pela redução da dimensionalidade, extração de características e restauração do número de canais. Essa organização reduz o custo computacional da arquitetura sem comprometer sua capacidade de representação.

Devido ao seu elevado desempenho em tarefas de classificação de imagens e à disponibilidade de modelos pré-treinados no conjunto de dados *ImageNet*, a *ResNet-50* tornou-se uma das arquiteturas mais utilizadas em aplicações de visão computacional baseadas em aprendizado por transferência (*transfer learning*) (SHAFIQ; GU, 2022).

Figura 2.4 – Diagrama ilustrando um bloco residual da arquitetura *ResNet*.



O bloco recebe um mapa de características como entrada e aplica uma sequência de camadas convolucionais para aprender uma função residual. Em paralelo, uma conexão residual (*shortcut*) propaga diretamente o mapa de características de entrada para a saída do bloco, permitindo sua combinação com as características aprendidas. Esse mecanismo facilita a propagação do gradiente durante o treinamento e possibilita a construção de redes neurais significativamente mais profundas.

Fonte: Adaptado de Mahajan (2020).

2.2.2 Problemas *few-shot* para classificação de imagens

Devido a sua característica pioneira, um dos principais desafios encontrados no desenvolvimento deste trabalho está relacionado à inexistência de bases de dados públicas para a classificação de gênero em calopsitas. Conforme destacado por [Sun et al. \(2017\)](#), a eficiência de treinamento em modelos de visão computacional está fortemente ligada a grandes volumes de dados. A coleta de amostras, porém, pode ser difícil e custosa; além disso, o processo de rotulação demanda esforço significativo.

Quando treinadas com conjuntos reduzidos, as arquiteturas tradicionais de aprendizagem tornam-se mais suscetíveis a problemas como *overfitting* ([LIU et al., 2022](#)), isto é, o aprendizado excessivo das características específicas do conjunto de treino, comprometendo o desempenho em imagens inéditas. Além da limitação quantitativa, as diferentes mutações genéticas das calopsitas alteram significativamente os padrões de plumagem, coloração e distribuição de manchas, tornando ainda mais complexa a identificação de características entre machos e fêmeas.

Nesse contexto, surge o paradigma de *Few-Shot Learning* (FSL), uma abordagem de aprendizado de máquina voltada para cenários em que há um número extremamente reduzido de exemplos rotulados por classe. Diferentemente dos modelos tradicionais de aprendizado profundo, que frequentemente necessitam de milhares de imagens para alcançar desempenho satisfatório, o FSL tem por objetivo fornecer métodos que permitam que modelos aprendam padrões relevantes a partir de poucas amostras disponíveis ([LIU et al., 2022](#)).

Como alternativa para minimizar os impactos da escassez de dados, técnicas como *data augmentation* e *transfer learning* tornam-se fundamentais. O aumento artificial da base de dados permite gerar novas amostras a partir de transformações geométricas aplicadas às imagens originais. Complementarmente, o uso de modelos pré-treinados, como a *ResNet50*, possibilita o reaproveitamento de características aprendidas previamente em grandes bases de imagens, como o *ImageNet*. Dessa forma, em vez de aprender desde o início padrões visuais básicos, como bordas, texturas, penas e bicos, o modelo pode concentrar o processo de treinamento na identificação das características mais relevantes para a distinção entre calopsitas machos e fêmeas.

Além dessas estratégias, a literatura também apresenta abordagens baseadas em aprendizado por similaridade (*metric-based learning*), nas quais o modelo aprende relações de proximidade entre imagens em vez de depender exclusivamente da classificação direta. Nesses métodos, imagens visualmente semelhantes tendem a ser representadas de forma próxima no espaço de características, favorecendo a classificação mesmo diante de poucas amostras disponíveis. Arquiteturas como *Siamese Networks*, *Matching Networks* e *Prototypical Networks* destacam-se nesse contexto ([VINYALS et al., 2016](#); [SNELL](#); [SWERSKY](#); [ZEMEL, 2017](#)).

2.2.3 Validação cruzada com *k-folds*

Em problemas de aprendizado supervisionado, é comum dividir o conjunto de dados em três subconjuntos: treinamento, validação e teste. O conjunto de treinamento é utilizado para o ajuste dos parâmetros da rede neural, enquanto o conjunto de validação auxilia na escolha de hiperparâmetros e no monitoramento do processo de treinamento. Por fim, o conjunto de teste permanece isolado durante todo o desenvolvimento do modelo e é utilizado exclusivamente para estimar sua capacidade de generalização.

Embora essa estratégia seja amplamente empregada, ela apresenta limitações quando aplicada a bases de dados reduzidas. A separação de parte das amostras para validação diminui a quantidade de exemplos disponíveis para treinamento, podendo comprometer a capacidade de aprendizado do modelo. Além disso, o desempenho obtido pode depender fortemente da partição escolhida, especialmente quando o número de amostras é pequeno.

Uma alternativa para minimizar esse problema é a validação cruzada com *k-folds* (*k-fold cross-validation*) ([scikit-learn developers, 2026a](#)). Nessa técnica, o conjunto de dados é dividido em k subconjuntos aproximadamente do mesmo tamanho. Em cada iteração, um desses subconjuntos é utilizado para validação, enquanto os demais são empregados para treinamento. Esse procedimento é repetido k vezes, de modo que todas as amostras sejam utilizadas tanto para treinamento quanto para validação em diferentes iterações.

Ao final do processo, as métricas obtidas em cada iteração são agregadas para produzir uma estimativa mais robusta do desempenho do modelo. Dessa forma, reduz-se a influência de uma única divisão dos dados, permitindo uma avaliação mais confiável da capacidade de generalização da rede neural, especialmente em problemas caracterizados por conjuntos de dados reduzidos.

2.3 Trabalhos Relacionados

Diversos estudos exploram a identificação de espécies e a classificação de gênero em animais por meio de técnicas de visão computacional e aprendizado profundo. [Soundarya, Pawan et al. \(2024\)](#) comparam a precisão de diferentes modelos no reconhecimento de espécies, incluindo aves, vida marinha e animais terrestres, utilizando *Vision Transformers (ViT)*, *ResNet-50* e *VGG-16*. Seus resultados demonstraram a superioridade do ViT em métricas como acurácia, precisão, recall e F1-score.

O problema da escassez de dados em tarefas de classificação de imagens foi abordado por [Zhang et al. \(2023\)](#), que investigaram a identificação de espécies raras da fauna silvestre a partir de imagens obtidas por armadilhas fotográficas. Os autores destacam que a obtenção de grandes conjuntos de dados é dificultada pela baixa frequência de aparição das espécies-alvo. Para contornar essa limitação, foi proposta uma estratégia de aumento de dados em duas

etapas: inicialmente, aplicaram-se técnicas convencionais de *data augmentation*; posteriormente, utilizou-se uma rede generativa do tipo *CycleGAN* para produzir novas imagens por meio de transferência de estilo, ampliando artificialmente a diversidade do conjunto de treinamento. As imagens geradas foram então utilizadas para treinar uma arquitetura ResNet50, que alcançou 92,2% de acurácia e 93,3% de F1-score. Os resultados demonstraram que técnicas avançadas de aumento de dados podem representar uma alternativa eficaz para problemas de classificação em cenários com poucas amostras (*few-shot datasets*), situação semelhante à encontrada na classificação de gênero em calopsitas.

Interessados em auxiliar fazendeiros na identificação de aves em criações avícolas, Wu et al. (2023) propuseram um algoritmo baseado na arquitetura *ResNet-50* para distinguir entre galos e galinhas. O estudo revelou que os principais pontos examinados pelo modelo foram a cabeça e a cauda das aves, resultando em uma acurácia de 98,42%.

Outra abordagem para a classificação de gênero em galináceos foi proposta por Cuan et al. (2022), que utilizou a vocalização das aves como critério de distinção. No estudo, áudios de 300 pintinhos foram submetidos a três modelos de *deep learning*, incluindo redes neurais convolucionais, redes neurais de memória de curto e longo prazo e *Gated Recurrent Unit* (GRU). Os resultados apontaram acurácias de 74,55%, 75,73% e 76,15%, respectivamente.

Zheng et al. (2022) aplicaram detecção de objetos para classificar patos e patas, sendo pioneiros na disponibilização de um banco de imagens desses animais com distinção de gênero. Utilizando o algoritmo *YOLOv5* e *data augmentation*, o modelo atingiu 98,68% de acurácia.

No contexto da identificação de gênero em insetos, Tuda e Luna-Maldonado (2020) exploraram diferentes abordagens, como regressão logística, floresta aleatória, perceptron de multicamadas e *AdaBoost*. Os modelos foram testados em três espécies distintas de besouros, atingindo uma taxa de verdadeiros positivos de 93,3%.

Até o momento, não foram identificados trabalhos específicos sobre a classificação de gênero em calopsitas, evidenciando uma lacuna a ser explorada por pesquisas futuras. A presente pesquisa busca preencher essa ausência, desenvolvendo um modelo de aprendizado profundo capaz de diferenciar machos e fêmeas dessa espécie.

3 Desenvolvimento

Este capítulo apresenta a metodologia adotada para o desenvolvimento dos modelos de classificação de gênero em calopsitas a partir de imagens. Inicialmente, descrevem-se as etapas de construção e preparação da base de dados, incluindo a coleta, organização e pré-processamento das imagens utilizadas no treinamento. Em seguida, são apresentadas as arquiteturas empregadas, as estratégias de treinamento e as técnicas utilizadas para melhorar a capacidade de generalização dos modelos, como *data augmentation*, *fine tuning* e validação cruzada estratificada. Por fim, são detalhados os experimentos realizados e os procedimentos adotados para avaliação do desempenho dos modelos, permitindo a comparação entre as diferentes abordagens investigadas neste trabalho.

3.1 Metodologia

Este estudo adota uma abordagem baseada em aprendizado profundo para o desenvolvimento de um modelo capaz de identificar o gênero de calopsitas a partir de imagens. A metodologia foi estruturada nas etapas descritas a seguir.

3.1.1 Base de dados para treinamento

Nesta seção são apresentadas as etapas de construção, organização e preparação da base de dados utilizada no treinamento e na avaliação dos modelos propostos.

3.1.1.1 Coleta de imagens

Inicialmente, foi construída uma base de dados composta por imagens de calopsitas previamente classificadas quanto ao gênero (macho ou fêmea). A obtenção dessas imagens ocorreu por meio de duas estratégias complementares. A primeira consistiu na coleta de imagens disponibilizadas publicamente em redes sociais, principalmente nas plataformas *Instagram* e *Facebook*. A segunda estratégia envolveu a realização de um chamado público para participação na pesquisa, mediante a divulgação de um formulário eletrônico destinado a tutores de calopsitas.

As imagens provenientes das redes sociais foram rotuladas com base nas informações fornecidas pelos próprios autores das publicações. Em diversos casos, as imagens foram obtidas em anúncios de venda de calopsitas, nos quais os criadores informavam explicitamente o sexo da ave, permitindo sua utilização como dado rotulado para o treinamento do modelo.

A coleta realizada através do formulário eletrônico foi previamente submetida e aprovada pelo Comitê de Ética em Pesquisa (CEP) da Universidade Federal de Ouro Preto (UFOP). O formulário foi direcionado a tutores de calopsitas cujo gênero já havia sido determinado por

métodos considerados confiáveis, como exame de DNA, postura de ovos ou avaliação realizada por médico veterinário. Além das fotografias da ave e seu gênero, coletamos também informações sobre o método utilizado para a determinação do sexo e a idade aproximada do animal. Após a divulgação do formulário, foram obtidas informações referentes a 20 indivíduos, distribuídos em aproximadamente 60% machos e 40% fêmeas.

Terminada a etapa de coleta, a base de dados foi composta por 159 imagens, sendo 87 de calopsitas machos e 72 de calopsitas fêmeas. Embora apresente uma distribuição relativamente equilibrada entre as classes, o conjunto de dados possui um número reduzido de amostras, caracterizando o problema como um cenário de *few-shot learning*.

3.1.1.2 Organização do *dataset*

Após a etapa de coleta, as imagens passaram por um processo de organização e padronização. Todas as imagens foram segmentadas, preservando apenas a região correspondente à calopsita e removendo elementos do ambiente, como gaiolas, poleiros, comedouros e demais objetos presentes no fundo da imagem. Essa fase teve como objetivo reduzir a influência de características irrelevantes durante o treinamento, direcionando o processo de aprendizagem para atributos morfológicos da ave.

Figura 3.1 – Exemplos de imagens contidas no *dataset* após segmentação.



Outro aspecto considerado na organização da base foi a presença de múltiplas imagens do mesmo indivíduo. Para evitar viés na avaliação do modelo, os conjuntos de treinamento, validação e teste foram manualmente particionados de forma que uma mesma calopsita estivesse

presente em apenas um desses conjuntos. Isso impede que o modelo memorize características específicas de um indivíduo, favorecendo a aprendizagem de padrões relacionados ao gênero e proporcionando uma avaliação mais realista da capacidade de generalização da rede neural.

3.1.1.3 Tratamento das imagens

Antes do treinamento, todas as imagens foram redimensionadas para a resolução exigida pela arquitetura da rede neural e submetidas à normalização dos valores dos pixels. Em seguida, aplicaram-se técnicas de aumento de dados (*data augmentation*) com o objetivo de ampliar artificialmente a variabilidade do conjunto de treinamento e reduzir o risco de *overfitting*. Entre as transformações empregadas destacam-se rotações, zoom aleatório, espelhamento horizontal, escala de cinza e ajustes aleatório de cor.

Após a aplicação das técnicas de *data augmentation*, o conjunto de treinamento passou a conter 1.000 imagens, distribuídas proporcionalmente entre machos fêmeas. Apesar de as novas amostras serem derivadas das imagens originais, a geração desses dados permitiu aumentar a diversidade visual do conjunto de treinamento, contribuindo para uma melhor capacidade de generalização do modelo.

3.1.2 Treinamento dos modelos

Com a base de dados devidamente organizada, foram conduzidos dois experimentos utilizando a arquitetura *ResNet50*, ambos baseados em aprendizado por transferência (*transfer learning*). Empregou-se como *backbone* o modelo pré-treinado no conjunto de dados *ImageNet*, removendo-se a camada de classificação original e adicionando uma nova cabeça de classificação adaptada ao problema de identificação do gênero de calopsitas.

O treinamento foi realizado em duas etapas. Inicialmente, todas as camadas convolucionais da *ResNet50* permaneceram congeladas, sendo treinadas apenas as camadas adicionadas ao final da arquitetura. Essa estratégia permite aproveitar os descritores visuais previamente aprendidos pela rede, reduzindo o risco de *overfitting* em cenários com poucos exemplos. Em uma segunda etapa, realizou-se o *fine tuning*, descongelando parte das camadas convolucionais mais profundas da rede e utilizando uma taxa de aprendizado reduzida, permitindo que o modelo adaptasse seus filtros às características específicas das imagens de calopsitas.

3.1.2.1 Ambiente de execução

Os experimentos foram realizados em um computador portátil executando o sistema operacional Windows 11 (64 bits), equipado com processador Intel Core i7-1255U de 12ª geração, 16 GB de memória RAM e GPU integrada Intel Iris Xe Graphics.

O desenvolvimento foi realizado em Python 3.12.9, utilizando o TensorFlow 2.19.0 e sua API Keras para implementação e treinamento das redes neurais. A biblioteca scikit-learn 1.6.1

foi empregada na validação cruzada, cálculo das métricas de desempenho e geração das matrizes de confusão. Para manipulação dos dados foram utilizadas as bibliotecas NumPy 1.26.4 e pandas 2.2.3, enquanto a geração de gráficos foi realizada com Matplotlib 3.10.1. A obtenção do conjunto de dados foi automatizada com a biblioteca gdown 5.2.0, e as técnicas de aumento artificial da base de dados (*data augmentation*) foram implementadas com a biblioteca Augmentor 0.2.12.


3.1.2.2 Experimento 1

O primeiro experimento teve como objetivo estabelecer um modelo de referência (*baseline*) para o problema. Para isso, foi utilizada a arquitetura *ResNet50* pré-treinada no *ImageNet*, com remoção da camada de classificação original (*include_top=False*). Como cabeça de classificação, adicionaram-se uma camada de *Global Average Pooling*, seguida por uma camada de *Dropout* com taxa de 0,3, uma camada totalmente conectada com 32 neurônios e função de ativação *ReLU*, uma segunda camada de *Dropout* com taxa de 0,2 e, por fim, uma camada de saída composta por um único neurônio com função de ativação *sigmoid*, apropriada para classificação binária.

As imagens foram redimensionadas para resolução de 224×224 pixels e normalizadas para o intervalo $[0, 1]$. O treinamento inicial foi realizado durante 10 épocas utilizando o otimizador *Adam* com taxa de aprendizado de 10^{-3} , mantendo toda a base convolucional congelada. Posteriormente, realizou-se o *fine tuning*, descongelando as 30 últimas camadas da *ResNet50* e reduzindo a taxa de aprendizado para 10^{-5} . Em ambas as fases utilizou-se a função de perda *binary cross-entropy* e pesos de classe (*class weights*) para reduzir possíveis efeitos do desbalanceamento entre machos e fêmeas.

Como a saída do modelo representa probabilidades, o limiar utilizado para converter probabilidades em classes foi determinado automaticamente a partir da curva *Precisão-Recall* obtida no conjunto de validação.

Figura 3.2 – Arquitetura utilizada no Experimento 1.



3.1.2.3 Experimento 2

O segundo experimento teve como objetivo aumentar a capacidade de generalização do modelo por meio de modificações tanto na arquitetura quanto na estratégia de treinamento.

A principal alteração consistiu na utilização de validação cruzada estratificada (*Stratified K-Fold*) ([scikit-learn developers, 2026b](#)) com cinco partições. Nessa estratégia, os conjuntos originalmente destinados ao treinamento e validação foram reunidos em um único conjunto, sendo posteriormente divididos em cinco subconjuntos estratificados, preservando-se a proporção entre machos e fêmeas em cada partição. Em cada iteração, quatro subconjuntos foram utilizados para treinamento e um para validação, permanecendo o conjunto de teste completamente separado durante todo o processo experimental.

Outra modificação importante foi a adoção de uma arquitetura multiescala. Além das características extraídas na saída final da *ResNet50*, foram também utilizadas características pro-


venientes da camada intermediária `conv4_block6_out`. Após a aplicação de camadas de *Global Average Pooling* em ambas as representações, os vetores de características foram concatenados e encaminhados para uma camada totalmente conectada contendo 128 neurônios com ativação ReLU, seguida de uma camada de *Dropout* com taxa de 0,4 e uma camada de saída composta por dois neurônios com ativação *softmax*.

Durante o treinamento de cada *fold*, foram aplicadas técnicas de *data augmentation* em tempo real, incluindo rotações de até 10° , espelhamento horizontal, pequenas translações, zoom e variações de brilho, ampliando artificialmente a diversidade das imagens de treinamento.

Assim como no primeiro experimento, o treinamento foi dividido em duas etapas. Na primeira fase, toda a base convolucional permaneceu congelada, sendo treinadas apenas as camadas finais durante até 15 épocas utilizando o otimizador Adam com taxa de aprendizado de 10^{-3} e função de perda *sparse categorical cross-entropy*. Na segunda etapa, realizou-se o *fine tuning*, mantendo congeladas apenas as 100 primeiras camadas da rede e reduzindo a taxa de aprendizado para 5×10^{-6} , durante até 30 épocas.

Em ambas as etapas foram utilizados os algoritmos *Early Stopping*, para interromper automaticamente o treinamento quando não houvesse melhoria na validação, e *ReduceLROnPlateau*, responsável por reduzir dinamicamente a taxa de aprendizado ao detectar estagnação no desempenho do modelo.

Figura 3.3 – Arquitetura multiescala utilizada no Experimento 2.



3.1.2.4 Avaliação dos modelos

Os modelos foram avaliados por meio de matrizes de confusão e das métricas de acurácia, precisão, revocação (*recall*) e medida- F_1 , permitindo uma análise detalhada do comportamento da rede para ambas as classes. No primeiro experimento, a avaliação foi realizada sobre uma única divisão entre treinamento, validação e teste. Já no segundo experimento, além da avaliação final no conjunto de teste, analisou-se também o desempenho médio obtido durante a validação cruzada, proporcionando uma estimativa mais robusta da capacidade de generalização do modelo.

4 Resultados

Este capítulo apresenta os resultados obtidos nos experimentos realizados para a identificação do gênero de calopsitas utilizando redes neurais convolucionais baseadas na arquitetura *ResNet50*. O primeiro experimento foi desenvolvido como um modelo de referência (*baseline*), utilizando uma arquitetura simples e uma única divisão entre os conjuntos de treinamento, validação e teste. O segundo experimento introduziu melhorias na estratégia de treinamento, incluindo validação cruzada estratificada, arquitetura multiescala e um processo de *fine tuning* mais refinado.

Para ambos os experimentos, o desempenho foi avaliado por meio das métricas de acurácia, precisão (*precision*), revocação (*recall*) e medida- F_1 , além da análise das respectivas matrizes de confusão. Consideram-se a classe "macho" como classe positiva para os cálculos de métricas de precisão e revocação.

4.1 Experimento 1


O primeiro experimento teve como objetivo estabelecer uma linha de base para o problema de classificação. Embora o modelo tenha utilizado uma arquitetura consolidada na literatura, observou-se um desempenho limitado na generalização para o conjunto de teste.

Tabela 4.1 – Resultados do Experimento 1.

Métrica	Valor
Acurácia	56,52%
Precisão	54,55%
Recall	92,31%
F1-score	68,57%

Observa-se que, apesar do elevado valor de *recall*, indicando boa capacidade de identificar amostras pertencentes à classe positiva, o modelo apresentou baixa precisão e acurácia. Esse comportamento evidencia uma elevada quantidade de classificações incorretas, refletindo um viés para a classe *male*. Na prática, o modelo tendeu a classificar a maior parte das imagens como machos, comprometendo significativamente sua capacidade de reconhecer corretamente as fêmeas.

Figura 4.1 – Matriz de confusão obtida no Experimento 1.



A matriz de confusão evidencia esse comportamento. Das dez imagens de fêmeas presentes no conjunto de teste, nenhuma foi corretamente classificada, enquanto praticamente todas as imagens de machos foram identificadas corretamente. Esse resultado demonstra que o modelo não foi capaz de generalizar as diferenças de características entre os sexos das calopsitas, apresentando forte tendência a classificar todas como "macho".

4.2 Experimento 2

O segundo experimento buscou superar as limitações observadas no modelo inicial. Para isso, foram incorporadas uma arquitetura multiescala baseada na *ResNet50*, validação cruzada estratificada, técnicas de *data augmentation* durante o treinamento e um processo de *fine tuning* mais controlado.

Tabela 4.2 – Resultados do Experimento 2.


Métrica	Valor
Acurácia	78,26%
Precisão	83,33%
Recall	76,92%
F1-score	80,00%

Comparativamente ao primeiro experimento, observa-se uma melhoria consistente em todas as métricas avaliadas. A precisão superior a 83% indica que a maioria das classificações

positivas realizadas pelo modelo corresponde efetivamente à classe correta, enquanto o valor de F1-score demonstra um melhor equilíbrio entre precisão e revocação.

A Figura 4.2 apresenta a matriz de confusão obtida.

Figura 4.2 – Matriz de confusão obtida no Experimento 2.



Observa-se que o modelo passou a apresentar desempenho equilibrado entre as duas classes. Das dez imagens de fêmeas presentes no conjunto de teste, sete foram corretamente classificadas, enquanto onze das treze imagens de machos também foram reconhecidas corretamente. Diferentemente do experimento anterior, não se observa um viés pronunciado para nenhuma das classes, indicando melhor capacidade de generalização.

4.3 Comparação entre os experimentos

A Tabela 4.3 resume os resultados obtidos pelos dois experimentos.

Tabela 4.3 – Comparação entre os experimentos realizados.

Métrica	Experimento 1	Experimento 2
Acurácia	56,52%	78,26%
Precisão	54,55%	83,33%
Recall	92,31%	76,92%
F1-score	68,57%	80,00%

Embora o primeiro experimento tenha apresentado um valor elevado de *recall*, essa métrica isoladamente não representa um bom desempenho global do modelo. A baixa precisão e

a análise da matriz de confusão mostram que esse resultado decorre do forte viés da rede para uma das classes, ocasionando elevado número de classificações incorretas.

Por outro lado, o segundo experimento apresentou melhora significativa em praticamente todas as métricas de avaliação, especialmente em acurácia, precisão e F1-score. Esses resultados sugerem que a combinação entre validação cruzada estratificada, arquitetura multiescala e um processo de *fine tuning* mais cuidadoso permitiu uma melhor exploração do conjunto de treinamento e maior capacidade de generalização.

Os resultados obtidos demonstram que a arquitetura *ResNet50* constitui uma alternativa promissora para o problema de identificação automática do gênero de calopsitas. Entretanto, também evidenciam que o desempenho do modelo depende fortemente da estratégia de treinamento adotada, especialmente em cenários caracterizados por bases de dados reduzidas (*few-shot datasets*), nos quais pequenas alterações metodológicas podem produzir ganhos significativos de desempenho.

5 Considerações Finais

5.1 Conclusão

Este trabalho teve como objetivo investigar a viabilidade da utilização de técnicas de aprendizado profundo para a identificação automática do gênero de calopsitas (*Nymphicus hollandicus*) a partir de imagens. Esse problema apresenta desafios significativos devido à elevada diversidade de plumagens resultante das mutações genéticas desenvolvidas ao longo da domesticação da espécie, tornando a diferenciação visual entre machos e fêmeas uma tarefa complexa, mesmo para criadores experientes.

Inicialmente, foi construída uma base de dados composta por imagens provenientes de redes sociais e de uma campanha pública de coleta de dados, permitindo a realização dos experimentos descritos neste trabalho.

Dois experimentos utilizando a arquitetura *ResNet50* foram desenvolvidos e comparados. O primeiro experimento empregou uma estratégia tradicional de treinamento, utilizando uma única divisão entre os conjuntos de treinamento, validação e teste, apresentando desempenho limitado, com acurácia de aproximadamente 56% e forte tendência à classificação predominante da classe *male*. Em seguida, introduziram-se melhorias metodológicas, incluindo validação cruzada estratificada, uma arquitetura multiescala para extração de características e um processo mais refinado de *fine tuning*. Essas modificações elevaram a acurácia para aproximadamente 78%, além de produzirem um modelo significativamente mais equilibrado entre as duas classes avaliadas.

Os resultados obtidos demonstram que a arquitetura *ResNet50* constitui uma boa alternativa para o problema de identificação automática do gênero de calopsitas. Entretanto, também evidenciam que o sucesso da abordagem depende fortemente da qualidade da base de dados e das estratégias empregadas durante o treinamento.

5.2 Trabalhos Futuros

Diversas oportunidades de aprimoramento podem ser exploradas em trabalhos futuros. A principal delas consiste na ampliação da base de dados utilizada no treinamento dos modelos. Considerando que o desempenho de redes neurais está diretamente relacionado à quantidade e à diversidade das amostras disponíveis, pretende-se ampliar coleta de imagens, divulgando o formulário para um número maior de tutores de calopsitas e estabelecendo parcerias com criadores, clínicas veterinárias, hospitais veterinários e associações de avicultura. Espera-se que uma base mais representativa permita melhorar a capacidade de generalização dos modelos,

especialmente para mutações menos frequentes.

Outra possibilidade consiste na utilização de vídeos em conjunto com às imagens estáticas. Além das informações visuais, vídeos permitem explorar características comportamentais das aves, como postura, movimentação da crista, batidas de asas e, principalmente, aspectos relacionados à vocalização. Como o canto constitui uma das principais formas de diferenciação entre machos e fêmeas, a incorporação de informações sonoras poderá fornecer características complementares às imagens, aumentando a robustez do processo de classificação.

Também pretende-se incorporar técnicas de interpretabilidade baseadas em mapas de ativação, como *Grad-CAM* e métodos semelhantes, capazes de destacar as regiões da imagem que mais influenciam a decisão da rede neural. Essa abordagem permitirá verificar se o modelo está concentrando sua atenção em características biologicamente relevantes, como coloração da face, padrão das penas ou cauda, fornecendo maior transparência ao processo de tomada de decisão da inteligência artificial.

Por fim, propõe-se investigar uma estratégia de treinamento em duas etapas, explorando explicitamente as mutações das calopsitas. Na primeira etapa, um modelo seria treinado para identificar a mutação da ave (como Cinza-Normal, Lutino, Pérola, Cara Branca, entre outras). Em seguida, um segundo modelo especializado realizaria a identificação do gênero considerando especificamente as características relevantes daquela mutação. Essa abordagem hierárquica pode permitir que a extração de características seja adaptada às particularidades de cada padrão de plumagem, reduzindo ambiguidades causadas pela elevada diversidade genética da espécie e aumentando a capacidade discriminativa do sistema.

A implementação dessas melhorias poderá aumentar a confiabilidade dos modelos desenvolvidos, contribuindo para a construção de ferramentas computacionais capazes de realizar a identificação automática, não invasiva e precisa do gênero de calopsitas.

Referências

- American Cockatiel Society. *Sex-Linked and Recessive Mutations*. 2024. Acesso em: 19 mar. 2025. Disponível em: <<https://www.acstiels.com/sex-linked-and-recessive-mutations>>.
- Avian Awareness. *Cockatiel Mutations and Color Variations*. 2014. Acesso em: 21 mar. 2025. Disponível em: <<https://avianawareness.tumblr.com/image/102453221668>>.
- Cockatiel World. *Cockatiel History*. 2024. Acesso em: 21 mar. 2025. Disponível em: <<https://cockatielworld.co.uk/cockatiel-history/>>.
- COELHO, M. *Fundamentos de Redes Neurais*. 2017. Acesso em: 22 mar. 2025. Disponível em: <<https://www2.decom.ufop.br/imobilis/fundamentos-de-redes-neurais/>>.
- CUAN, K.; LI, Z.; ZHANG, T.; QU, H. Gender determination of domestic chicks based on vocalization signals. *Computers and Electronics in Agriculture*, v. 199, 2022. ISSN 0168-1699. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0168169922004896>>.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. MIT Press, 2016. Disponível em: <<http://www.deeplearningbook.org>>.
- GRESPLAN, A.; RASO, T.; CUBAS, Z.; SILVA, J.; CATÃO-DIAS, J. *Tratado de Animais Selvagens: medicina veterinária*. 2014.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. [S.l.]: IEEE, 2016. p. 770–778.
- IBM. *What is a neural network?* 2025. Acesso em: 22 mar. 2025. Disponível em: <<https://www.ibm.com/think/topics/neural-networks>>.
- KRICHEN, M. Convolutional neural networks: A survey. *Computers*, v. 12, n. 8, 2023. ISSN 2073-431X. Disponível em: <<https://www.mdpi.com/2073-431X/12/8/151>>.
- LIU, Y.; ZHANG, H.; ZHANG, W.; LU, G.; TIAN, Q.; LING, N. Few-shot image classification: Current status and research trends. *Electronics*, v. 11, n. 11, 2022. ISSN 2079-9292. Disponível em: <<https://www.mdpi.com/2079-9292/11/11/1752>>.
- MAHAJAN, P. *Understanding Residual Network (ResNet) Architecture*. 2020. Acesso em: 22 mar. 2025. Disponível em: <<https://medium.com/analytics-vidhya/understanding-resnet-architecture-869915cc2a98>>.
- Nancy A. Reed. *The Cockatiel*. 1978. Acesso em: 21 mar. 2025. Disponível em: <<https://watchbird-ojs-tamu.tdl.org/watchbird/index.php/watchbird/article/view/2977>>.
- QUINTANA, M. *Poeminho do Contra*. 1978. Disponível em diversas coletâneas e fontes online.
- RUBIN, L. S. Recent mutations in cockatiels. *GENETICS FOR AVICULTURISTS*, 1997.
- scikit-learn developers. *Cross-validation: Evaluating Estimator Performance*. 2026. <https://scikit-learn.org/stable/modules/cross_validation.html>. Documentação oficial do scikit-learn. Acesso em: 30 maio 2026.

scikit-learn developers. *StratifiedKfold*. 2026. <https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.StratifiedKfold.html>. Documentação oficial do scikit-learn. Acesso em: 30 maio 2026.

SHAFIQ, M.; GU, Z. Deep residual learning for image recognition: A survey. *Applied Sciences*, v. 12, n. 18, 2022. ISSN 2076-3417. Disponível em: <<https://www.mdpi.com/2076-3417/12/18/8972>>.

SNELL, J.; SWERSKY, K.; ZEMEL, R. Prototypical networks for few-shot learning. In: *Advances in Neural Information Processing Systems*. [S.l.: s.n.], 2017. v. 30.

SOUNDARYA, M.; PAWAN, S. P. et al. Improving the precise identification of animal species through the use of vision transformers. In: IEEE. *2024 3rd International Conference on Automation, Computing and Renewable Systems (ICACRS)*. [S.l.], 2024. p. 1287–1293.

SUN, C.; SHRIVASTAVA, A.; SINGH, S.; GUPTA, A. *Revisiting Unreasonable Effectiveness of Data in Deep Learning Era*. 2017. Disponível em: <<https://arxiv.org/abs/1707.02968>>.

THOMPSON, D. R. Cockatiel mutations. *GENETICS FOR AVICULTURISTS*, v. 9, 1982.

TUDA, M.; LUNA-MALDONADO, A. I. Image-based insect species and gender classification by trained supervised machine learning algorithms. *Ecological Informatics*, v. 60, p. 101135, 2020. ISSN 1574-9541. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1574954120300856>>.

TURCU, M.-C.; PAȘTIU, A. I.; BEL, L.-V.; DOBOȘI, A.-A.; PUSTA, D. L. Application of minimally invasive oral swab samples for qpcr-based sexing in neognathae birds. *Veterinary Sciences*, MDPI, v. 12, n. 1, p. 73, 2025.

VINYALS, O.; BLUNDELL, C.; LILLICRAP, T.; KAVUKCUOĞLU, K.; WIERSTRA, D. Matching networks for one shot learning. *Advances in Neural Information Processing Systems*, v. 29, 2016.

Wikipedia contributors. *Normal grey cockatiel* — *Wikipedia, The Free Encyclopedia*. 2023. [Online; accessed 20-March-2025]. Disponível em: <https://en.wikipedia.org/w/index.php?title=Normal_grey_cockatiel&oldid=1187689524>.

WU, D.; YING, Y.; ZHOU, M.; PAN, J.; CUI, D. Improved resnet-50 deep learning algorithm for identifying chicken gender. *Computers and Electronics in Agriculture*, v. 205, 2023.

ZHANG, Q.; YI, X.; GUO, J.; TANG, Y.; FENG, T.; LIU, R. A few-shot rare wildlife image classification method based on style migration data augmentation. *Ecological Informatics*, v. 77, p. 102237, 2023. ISSN 1574-9541. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1574954123002662>>.

ZHENG, X.; LI, F.; LIN, B.; XIE, D.; LIU, Y.; JIANG, K.; GONG, X.; JIANG, H.; PENG, R.; DUAN, X. A two-stage method to detect the sex ratio of hemp ducks based on object detection and classification networks. 2022. Disponível em: <<https://www.mdpi.com/2076-2615/12/9/1177>>.

Durante a preparação deste documento, eu, Ana Laura Siqueira Mendes, estudante de graduação em Ciência da Computação da Universidade Federal de Ouro Preto, declaro o uso do **ChatGPT (OpenAI)**, baseado no modelo **GPT-5.5**, como ferramenta de inteligência artificial generativa para apoio à revisão textual, aprimoramento da redação acadêmica, elaboração de códigos em $\text{\LaTeX}$ e geração de referências bibliográficas em formato $\text{\BibTeX}$. Declaro ainda o uso do **GitHub Copilot** como ferramenta de assistência à programação, empregada para acelerar a implementação dos experimentos computacionais, sugerindo trechos de código, estruturas de funções e adaptações durante o desenvolvimento dos modelos de aprendizado profundo.

Após a utilização dessas ferramentas, revisei criticamente todo o conteúdo produzido, incluindo os textos e os códigos-fonte empregados nos experimentos, realizando as adaptações e validações necessárias para garantir sua correção técnica e científica, em conformidade com os princípios éticos para o uso de Inteligência Artificial Generativa estabelecidos pela Resolução CONPEP nº 144 e com as orientações acordadas com o orientador desta pesquisa. Dessa forma, assumo integral responsabilidade pelo conteúdo apresentado nesta publicação.