

**UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
PROGRAMA DE PÓS-GRADUAÇÃO EM ZOOTECNIA**

ADRIELLE CARNEIRO DE ARAÚJO SANTOS

**PREDIÇÃO DE CATEGORIA DE PESO CORPORAL DE FRANGAS DE POSTURA
UTILIZANDO SENSORIAMENTO DE PROFUNDIDADE E APRENDIZADO DE
MÁQUINA**

**RECIFE
2025**

ADRIELLE CARNEIRO DE ARAÚJO SANTOS

**PREDIÇÃO DE CATEGORIA DE PESO CORPORAL DE FRANGAS DE
POSTURA UTILIZANDO SENSORIAMENTO DE PROFUNDIDADE E
APRENDIZADO DE MÁQUINA**

Dissertação apresentada ao Programa de
Pós-Graduação em Zootecnia da
Universidade Federal Rural de
Pernambuco para obtenção do título de
Mestre em Zootecnia

Área de concentração: Zootecnia

Orientadora: Profa. Dra. Lilian Francisco
Arantes de Souza

Coorientador: Prof. Dr. João Paulo Silva
do Monte Lima

**RECIFE
2025**

Dados Internacionais de Catalogação na Publicação
Sistema Integrado de Bibliotecas da UFRPE
Bibliotecário(a): Auxiliadora Cunha – CRB-4 1134

S237p Santos, Adrielle Carneiro de Araújo.
Predição de categoria de peso corporal de frangas de postura utilizando sensoriamento de profundidade e aprendizado de máquina / Adrielle Carneiro de Araújo Santos. – Recife, 2025.
53 f.; il.

Orientador(a): Lilian Francisco Arantes de Souza.
Co-orientador(a): João Paulo Silva do Monte Lima.

Dissertação (Mestrado) – Universidade Federal Rural de Pernambuco, Programa de Pós-Graduação em Zootecnia, Recife, BR-PE, 2025.

Inclui referências.

1. Processamento de imagens - Técnicas digitais.
2. Inteligência artificial. 3. Redes neurais (Computação). 4. *Visão computacional* I. Souza, Lilian Francisco Arantes de, orient. II. Lima, João Paulo Silva do Monte, coorient. III. Título

CDD 636



UNIVERSIDADE FEDERAL RURAL DE PERNAMBUCO
PROGRAMA DE PÓS-GRADUAÇÃO EM ZOOTECNIA

**PREDIÇÃO DE CATEGORIA DE PESO CORPORAL DE FRANGAS DE
POSTURA UTILIZANDO SENSORIAMENTO DE PROFUNDIDADE E
APRENDIZADO DE MÁQUINA**

Dissertação elaborada por

ADRIELLE CARNEIRO DE ARAÚJO SANTOS

Aprovado em 20/02/2025

BANCA EXAMINADORA

Documento assinado digitalmente
 LILIAN FRANCISCO ARANTES DE SOUZA
Data: 21/02/2025 16:01:33-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. Lilian Francisco Arantes de Souza
Universidade Federal Rural de Pernambuco (UFRPE)

Documento assinado digitalmente
 CARLOS BOA VIAGEM RABELLO
Data: 21/02/2025 15:54:07-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Carlos Bôa-Viagem Rabello
Universidade Federal Rural de Pernambuco (UFRPE)

Documento assinado digitalmente
 DENIS HENRIQUE PINHEIRO SALVADEO
Data: 21/02/2025 15:13:26-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Denis Henrique Pinheiro Salvadeo
Universidade Estadual Paulista (UNESP)

Dedico essa dissertação aos meus pais, Katia Maria Carneiro e André de Araújo Santos, que sempre me apoiaram em minhas escolhas e nunca deixaram de estar presentes em todos os meus momentos, inclusive meus estudos. Por isso, eu não estaria aqui se não fosse por vocês.

AGRADECIMENTOS

A Deus, por sempre me guiar e estar presente em todas minhas escolhas, sempre ao meu lado e me dando forças em todos esses anos da minha existência.

À minha família, em especial aos meus pais, Katia e André, meu irmão, John, e minha avó, Luzinete, por serem meu porto seguro, meu lugar de conforto e por me darem suporte ao longo da minha jornada.

À Universidade Federal Rural de Pernambuco, por ter me acolhido durante esses anos e pela oportunidade de realizar meu curso de graduação e pós-graduação.

Ao Departamento de Zootecnia, que me proporcionou vários momentos e oportunidades, conhecendo professores maravilhosos que agregaram conhecimentos profissionais e pessoais.

À CAPES, pelo consentimento da bolsa ao longo de 2 anos em que trabalhei com pesquisa durante o mestrado.

A minha orientadora, Profa. Lilian Francisco Arantes de Souza, por todos os ensinamentos, paciência, explicações, suporte, acolhimento durante minha jornada como sua orientanda. Seus incentivos foram fundamentais para o desenvolvimento deste trabalho e para o meu crescimento acadêmico e profissional.

A todos os envolvidos na realização desse trabalho, como meu coorientador Prof. João Paulo Silva do Monte Lima e profissionais da computação que ajudaram no trabalho. Também agradeço ao Prof. Carlos Bôa-Viagem Rabello por todo apoio, ensinamentos, conversas e suporte na realização da pesquisa, e ao grupo GEAVES por toda troca de experiências.

Aos meus amigos de graduação e irmãos de coração que a zootecnia me deu, Isla, Elton, Victoria e Vitória, e quem conheci ao longo da pós-graduação, Webert, Carolina, Leandra, Stephany, Maria Telma, Yasmin, Gabriela, por todas os dias que passamos compartilhando conhecimento, sempre se ajudando e auxiliando uns aos outros. Não consigo imaginar minha jornada de zootecnista sem vocês e obrigada pelo apoio, incentivo e companhia.

Ao meu marido, Lucas Amorim, pelo companheirismo, sempre me ajudando ao longo dos nossos anos de relacionamento, dando conselhos, encorajando e me incentivando a seguir o que eu amo. Você do meu lado tornou cada desafio mais fácil e cada conquista ainda mais especial.

A todos os amigos e profissionais da zootecnia que me ajudaram de alguma forma nesse caminho e trajetória da minha graduação, sou grata a todos.

“Em meio ao caos e ao mistério, a chave para a paz está na nossa capacidade de confiar.”

Diana Wynne Jones

O Castelo Animado

RESUMO

O acompanhamento do peso corporal de aves de postura é essencial para assegurar capacidade de produção de ovos. Porém, os métodos atuais de monitoramento têm se mostrado insuficientes para atender às necessidades do setor avícola, sendo necessárias alternativas para automatizar e facilitar esse processo. Assim, objetivou-se desenvolver e encontrar um modelo de aprendizado profundo para classificação de imagens de profundidade, utilizando métodos baseados em visão computacional, visando estimar a categoria de peso corporal de frangas de postura. Foram utilizadas 200 aves da linhagem Dekalb White com 7 e 15 semanas de idade, sendo pesadas e classificadas em três categorias de peso corporal: leves, médias e pesadas. Foram selecionadas 18 frangas por categoria para filmagem com uma câmera de profundidade e as capturas passaram por técnicas de pré-processamento de imagem. Para realização da classificação por aprendizado de máquina, foram utilizados 4 modelos: *Convolutional Neural Network* (CNN), *Visual Geometry Group 16-layer Network* (VGG16), *Residual Network with 50 layers* (ResNet50) e *Convolutional Neural Network Next* (ConvNeXt). Os modelos foram testados para: acurácia, precisão, recall, escore F-1, ROC AUC, especificidade, coeficiente de correlação de Matthews e escore de Kappa. As CNNs apresentaram melhor desempenho em comparação às demais arquiteturas utilizadas em relação à acurácia (95,4%), precisão (95,5%), recall (95,4%), escore F1 (0,954), ROC AUC (0,96), especificidade (96,4%), coeficiente de correlação de Matthews (MCC) (0,93) e escore de Kappa (0,93) às 15 semanas. Às 7 semanas também foi superior na acurácia (80,9%), precisão (83,7%), *recall* (80,9%), escore F1 (0,81), ROC AUC (0,86), especificidade (73%), MCC (0,726) e escore de Kappa (0,715). Os modelos VGG16, ConvNeXt e ResNet50 tiveram escores F1 de 0,636, 0,625 e 0,30 às 15 semanas, e 0,577, 0,545 e 0,263 às 7 semanas, respectivamente. Dessa forma, as CNNs foram capazes de estimar com êxito a categoria de peso corporal das aves com 7 e 15 semanas de idade, por meio da utilização de imagens de profundidade, permitindo extração de características tridimensionais e demonstrando grande potencial para aplicações práticas.

Palavras-chave: classificação; imagens de profundidade; inteligência artificial; redes neurais convolucionais; visão computacional.

ABSTRACT

Monitoring the body weight of laying hens is essential to ensure egg production capacity. However, current monitoring methods have proved insufficient to meet the needs of the poultry sector, and alternatives are needed to automate and facilitate this process. The aim was therefore to develop and find a deep learning model for classifying depth images, using methods based on computer vision, in order to estimate the body weight category of laying pullets. Two hundred birds of the Dekalb White strain aged between 7 and 15 weeks were weighed and classified into three body weight categories: light, medium and heavy. Eighteen pullets per category were selected for filming with a depth camera and the captures were subjected to image pre-processing techniques. Four models were used for machine learning classification: Convolutional Neural Network (CNN), Visual Geometry Group 16-layer Network (VGG16), Residual Network with 50 layers (ResNet50) and Convolutional Neural Network Next (ConvNeXt). The models were tested for: accuracy, precision, recall, F-1 score, ROC AUC, specificity, Matthews correlation coefficient and Kappa score. CNNs performed better than the other architectures used in terms of accuracy (95.4%), precision (95.5%), recall (95.4%), F1 score (0.954), ROC AUC (0.96), specificity (96.4%), Matthews correlation coefficient (MCC) (0.93) and Kappa score (0.93) at 15 weeks. At 7 weeks it was also superior in accuracy (80.9%), precision (83.7%), recall (80.9%), F1 score (0.81), ROC AUC (0.86), specificity (73%), MCC (0.726) and Kappa score (0.715). The VGG16, ConvNeXt and ResNet50 models had F1 scores of 0.636, 0.625 and 0.30 at 15 weeks, and 0.577, 0.545 and 0.263 at 7 weeks, respectively. Thus, the CNNs were able to successfully estimate the body weight category of laying pullets at 7 and 15 weeks of age using depth images, allowing for the extraction of three-dimensional characteristics and demonstrating great potential for practical applications.

Keywords: artificial intelligence; classification; computer vision; convolutional neural networks; depth images.

LISTA DE TABELAS

Tabela 1. Média, mínimo, máximo e desvio padrão do peso corporal das aves, de acordo com a classe durante a 7 ^a e 15 ^a semana de idade.....	29
Tabela 2. Número de imagens capturadas e destinadas para treinamento, validação e teste de acordo com a classe de peso corporal das aves durante a 7 ^a e 15 ^a semana de idade.....	32
Tabela 3. Hiperparâmetros e configurações de treinamento das arquiteturas de redes neurais convolucionais.....	33
Tabela 4. Matriz de confusão para análise de desempenho da classificação.....	35
Tabela 5. Desempenho dos modelos de classificação da categoria do peso corporal de frangas de postura com 7 e 15 semanas de idade para as métricas de precisão, recall, especificidade e folds.....	38
Tabela 6. Desempenho dos modelos de classificação da categoria do peso corporal de frangas de postura com 7 e 15 semanas de idade para as métricas de escore de Kappa, coeficiente de correlação de Matthews, ROC AUC e folds.....	43

LISTA DE ABREVIATURAS E SIGLAS

%	Porcentagem
AM	Aprendizado de máquina
AP	Aprendizado profundo
AS	Aprendizado supervisionado
CNN	Convolutional Neural Network
ConvNeXt	Convolutional Neural Network Next
EM	Energia metabolizável
g	Gramas
kcal	Quilocaloria
kg	Quilograma
PB	Proteína bruta
PDI	Processamento digital de imagens
ResNet50	Residual Network with 50 layers
RNA	Rede neural artificial
VC	Visão computacional
VGG16	Visual Geometry Group 16-layer Network

LISTA DE ILUSTRAÇÕES

Figura 1. Estrutura básica de uma rede neural artificial.....	18
Figura 2. Categorização dos tipos de aprendizado de máquina.....	19
Figura 3. Diagrama esquemático da arquitetura de uma rede neural convolucional básica.....	22
Figura 4. Representação de imagem digital. (a) Imagem lógica com valores de 1 para branco e 0 para preto; (a) imagem em tons de cinza com profundidade de 24 bits (valores variando entre 0 e 255); (c) imagem colorida no espaço de cores RGB.....	24
Figura 5. (a) Imagem RGB capturada lateralmente dos animais, (b) imagem de profundidade pré-processada.....	29
Figura 6. (a) Imagem original tipo ONI, (b) 8 bits, (c) 16 bits, (d) imagem após erosão, escala de cinza, desfoque gaussiano e limiarização por método de Otsu.....	30
Figura 7. Acurácia das arquiteturas CNN, ConvNeXt, ResNet50 e VGG16 ao longo das épocas utilizando imagens de frangas de postura com 7 semanas de idade.....	35
Figura 8. Acurácia das arquiteturas CNN, ConvNeXt, ResNet50 e VGG16 ao longo das épocas utilizando imagens de frangas de postura com 15 semanas de idade.....	36
Figura 9. Especificidade das arquiteturas CNN, ConvNeXt, ResNet50 e VGG16 ao longo das épocas utilizando imagens de frangas de postura com 7 semanas de idade.....	39
Figura 10. Especificidade das arquiteturas CNN, ConvNeXt, ResNet50 e VGG16 ao longo das épocas utilizando imagens de frangas de postura com 15 semanas de idade.....	39
Figura 11. Matriz de confusão para a classificação de imagens de frangas de postura com 7 semanas de idade do modelo com CNNs.....	41
Figura 12. Matriz de confusão para a classificação de imagens de frangas de postura com 15 semanas de idade do modelo com CNNs.....	42

SUMÁRIO

1. INTRODUÇÃO	13
2. REVISÃO DE LITERATURA	15
2.1 Importância da composição e do peso corporal na avicultura de postura	15
2.2 Aprendizado de máquina	17
2.2.1 Tipos de aprendizado	19
2.2.2 Aprendizado profundo	21
2.3 Visão computacional.....	23
2.4 Aplicação da visão computacional e aprendizado de máquina.....	26
3. MATERIAL E MÉTODOS.....	28
3.1 Local do experimento e delineamento experimental	28
3.2 Obtenção das imagens de profundidade	29
3.3 Pré-processamento e aprendizado de máquina	30
3.3.1 Coleta dos dados	31
3.3.2 Pré-processamento	31
3.3.3 Construção do modelo	31
3.3.4 Avaliação do modelo.....	33
4. RESULTADOS E DISCUSSÃO	35
5. CONCLUSÃO	45
REFERÊNCIAS BIBLIOGRÁFICAS	46
GLOSSÁRIO	53

1. INTRODUÇÃO

Os ovos são fontes de nutrientes essenciais à população mundial, contendo aminoácidos, vitaminas e minerais. Na última década, a produção brasileira de ovos apresentou crescimento superior a 50%, com cerca de 52 bilhões de unidades em 2023, em comparativo com 34 bilhões no ano de 2013. Nesse contexto, Pernambuco ocupa a quarta posição no ranking de alojamento de aves no país, sendo o maior da região Nordeste (ABPA, 2024). Dessa forma, a avicultura de postura é um importante setor do agronegócio brasileiro e pernambucano, uma vez que é responsável pela produção de um dos alimentos mais completos, além da geração de emprego e renda.

As aves de postura apresentam curva de ganho de peso de forma a constituir estrutura corporal que assegure a capacidade de produção de ovos. No início do período de postura, o peso corporal na idade da maturidade sexual é um dos fatores mais importantes na determinação do peso do ovo (Sanz et al., 2023). Da mesma forma, a composição química corporal das frangas no início da postura também é relevante, uma vez que, durante o pico de postura, as aves utilizam reservas corporais para manter a produção de ovos, evidenciando a importância de formar frangas de boa qualidade até a idade da maturidade sexual (Leeson e Summers, 1987).

Nesse sentido, as aves podem ser pesadas semanalmente para monitorar seu crescimento e desenvolvimento, além da identificação de aves que estão abaixo ou acima do peso ideal de acordo com a linhagem, permitindo que sejam separadas e manejadas conforme sua classificação, possibilitando a correção desses desvios. Apesar de ser uma etapa determinante, os métodos atuais de monitoramento de peso corporal geralmente são manuais, sendo propensos a erros, além de exigir elevada mão de obra, demonstrando-se insuficientes para atender às necessidades atuais do setor avícola (Wang et al., 2017). A negligência desse manejo nas primeiras semanas de vida pode impactar negativamente a produção de ovos. El-Sagheer e Hassanein (2006) avaliaram os impactos da diferença de peso corporal em poedeiras comerciais semi-pesadas e observaram que aves leves e pesadas apresentam menor produção de ovos e pior eficiência econômica em relação às aves com peso corporal médio. Já Ekinci et al. (2023) dividiram poedeiras Lohmann White de acordo com o peso corporal e observaram que a produção de ovos das aves pesadas foi 8,04% inferior à das aves leves, além de apresentarem menor eficiência econômica, com a pior margem de lucro bruto por ovo.

Devido a esse desafio, atualmente buscam-se alternativas para facilitar esse processo, visando tornar o acompanhamento do peso corporal mais prático, eficiente e automatizado. Assim, tecnologias baseadas em visão computacional (VC) vem se provando serem adequadas

para atingir esse objetivo, já que são eficientes para estimar e classificar tamanho e peso na avicultura, uma vez que são precisos e rápidos (Nyalala et al., 2021). Uma grande vantagem deste tipo de monitoramento automatizado do peso é que pode ser realizado de forma não invasiva, sem a necessidade de manipulação das aves, contribuindo para melhorar índices produtivos sem prejudicar o bem-estar animal.

Por conta do seu baixo custo e fácil transporte, câmeras com sensores de profundidade vêm sendo utilizadas para a realização desse tipo de classificação. A partir delas, imagens digitais são geradas e definidas como um conjunto de pontos denominados “pixels”, contendo informações da distância entre os objetos da cena, onde cada ponto apresenta uma informação referente às características da imagem (Gonzalez e Woods, 2013).

A partir das informações disponibilizadas pelas imagens adquiridas, o aprendizado de máquina (AM) também pode ser utilizado para realizar a estimativa da categoria de peso das aves, a partir da construção de sistemas inteligentes capazes de aprender a partir da base de dados, sem a necessidade de serem explicitamente programados, aprendendo através da experiência (Müller e Guido, 2016). Sendo assim, é possível treinar redes neurais para realizar tarefas de classificação, reconhecendo particularidades em imagens, e realizar inferências, desde que, um conjunto de informações esteja previamente disponível para treinamento (Sousa et al., 2023). No aprendizado supervisionado, o algoritmo recebe como entrada uma base de dados na qual a saída desejada está previamente definida, ou seja, os dados de treinamento incluem a solução esperada, conhecida como rótulo (Faceli et al., 2021).

Por meio desse processo, é possível estimar o peso das aves, através das dimensões corporais, que podem ser medidas automaticamente ou através de uma função de predição estabelecida utilizando a relação entre essas dimensões e características corporais pré-definidas. Wang et al. (2017) desenvolveram um modelo de estimativa do peso corporal de frangos de corte baseado em imagens de profundidade e rede neural de retropropagação, onde os resultados mostraram erro relativo máximo de 11%, demonstrando a viabilidade de utilizar o modelo para a predição. Mortensen et al. (2016) desenvolveram um sistema de pesagem voluntário baseado em câmeras 3D para frangos de corte e concluíram que o sistema se mostrou vantajoso em relação à pesagem convencional, utilizando rede neural artificial bayesiana para prever o peso individual dos frangos. Entretanto, estudos com aves de postura ainda são escassos.

Dessa forma, objetivou-se desenvolver e identificar um modelo de aprendizado profundo para a classificação de imagens de profundidade, por meio do teste de diferentes modelos, utilizando métodos baseados em visão computacional e técnicas de aprendizado de máquina, com o propósito de estimar a categoria de peso corporal de frangas de postura com 7

e 15 semanas de idade. Hipotetizou-se que a utilização de câmeras com sensoriamento de profundidade, aliada ao aprendizado de máquina, permite prever a categoria de peso corporal de aves de postura de forma precisa e automatizada, reduzindo a necessidade de pesagem manual e minimizando erros.

2. REVISÃO DE LITERATURA

2.1 Importância da composição e do peso corporal na avicultura de postura

Aves de postura apresentam um ciclo de vida que pode chegar a até 100 semanas, começando a produção de ovos por volta das 20 semanas de idade (Bain et al., 2016). O ciclo de criação é dividido em fases de cria, recria e produção ou postura, sendo as fases iniciais responsáveis pela formação corporal das aves. Embora mais curtas do que a fase de postura, essas fases iniciais da vida das poedeiras comerciais são críticas. Esse período pode influenciar significativamente o desempenho das aves, uma vez que ocorrem os principais desenvolvimentos fisiológicos, como a formação dos órgãos reprodutivos e digestivos, fortalecimento do sistema imunológico e crescimento esquelético (Zuidhof, 2020).

O desenvolvimento corporal, abrangendo a formação da estrutura óssea e muscular das frangas, ocorre até aproximadamente a 12^a e 13^a semanas de idade. Posteriormente, desenvolvem-se os órgãos reprodutores, aumento de peso de órgãos metabólicos, como o fígado, além da formação de reservas energéticas até o final do período da recria, por volta de 16 a 18 semanas. Dessa forma, mostra-se essencial assegurar os aportes proteicos e energéticos durante essas fases, permitindo crescimento adequado, especialmente no período que antecede a postura, uma vez que o estado metabólico e a composição corporal podem influenciar a produção e qualidade dos ovos (Van Eck et al., 2023; Kwakkel et al., 2017).

O tecido adiposo atua como uma reserva energética para as poedeiras em situações críticas e de estresse, como a transição da franga para a fase de postura, durante o pico de produção ou em manejos como vacinações e debicagem, quando o consumo de ração pode ser reduzido e a ingestão de nutrientes não supre a demanda necessária (Barboza e Hume, 2006). Além dessa função, o tecido adiposo também pode ter uma ação endócrina, através da produção de moléculas de sinalização celular, como as adipocinas (Ceciliani et al., 2018). Nas aves, essas proteínas influenciam processos relacionados ao consumo de ração e peso corporal, possuindo efeito mais significativo na reprodução, garantindo crescimento folicular ovariano, mediando a ovulação, e conseqüentemente, representando um componente importante na produção de ovos (Bornelöv et al., 2018).

Sendo assim, no início e durante a postura, o tecido adiposo pode ser benéfico para sustentar a produção, enquanto aves mais leves, com menores reservas, podem ser tardias ou apresentarem baixa produtividade. Segundo Noetzold et al. (2025) aves que sofreram restrição alimentar apresentaram folículos amarelos (número e peso) e ovário (peso e porcentagem) menores quando comparados a poedeiras alimentadas *ad libitum*.

Por outro lado, aves mais pesadas, com maior reserva energética, entram em produção rapidamente e tem ovos mais pesados, refletindo em 1,2 g no peso do ovo a cada aumento de 100 g no peso corporal (Pérez-Bolinna et al., 2012; Summers e Leeson, 1994). O maior peso corporal associado à deposição de gordura garante suprimento de nutrientes e, após atender aos requisitos de manutenção e crescimento, os nutrientes excedentes são direcionados para desenvolvimento do sistema reprodutivo.

No entanto, em longo prazo, frangas com elevado teor de gordura corporal no início da postura produzem menos ovos em comparação com aquelas que possuem baixo ou médio teor de gordura (Milisits et al., 2015). Rodrigues et al. (2024) observaram que, ao atingirem 65 semanas de vida, poedeiras pesadas da linhagem híbrida Embrapa 51 apresentaram uma produção de ovos inferior à das aves leves e médias, com 61%, 65% e 67% de produção, respectivamente, além de uma queda mais acentuada ao longo do ciclo produtivo avaliado. Dessa forma, nas aves pesadas, o excesso de gordura na composição corporal pode impactar negativamente o sistema reprodutivo, causando distúrbios nas concentrações de adipocinas, que afetam as gônadas e a liberação de óvulos, além de provocar alterações hormonais e na taxa de maturação sexual (Mintziori et al., 2020). Isso demonstra que há um limite para a quantidade de gordura corporal antes que a produção de ovos seja prejudicada, ou seja, uma quantidade mínima é necessária para o início da postura, enquanto um excesso pode atrasá-la (Bahry et al., 2023).

Portanto, é essencial que as frangas atinjam peso ideal para garantir desempenho produtivo satisfatório e peso adequado dos ovos, conforme destacado pelas empresas de genéticas em relação às suas linhagens, possibilitando que expressem o máximo da sua capacidade produtiva de acordo com sua potencialidade (Dekalb, 2025; Hy-Line, 2025; Isa, 2025). Problemas na uniformidade durante as fases de cria e recria resultam em aves com diferentes pesos na fase de postura, o que leva à presença de frangas precoces e tardias no mesmo lote. De acordo com Lara et al. (2019), é recomendado que a variabilidade de peso no lote não ultrapasse 10%, a fim de evitar consequências ao longo da vida produtiva. Segundo os autores, galinhas pesadas (10% acima do peso pré-estabelecido no manual da linhagem) podem prejudicar a rentabilidade do lote devido ao maior consumo de ração, o que nem sempre resulta

em um maior número de ovos. Por outro lado, galinhas leves tendem a apresentar menor produção de ovos, redução do pico de produção e atraso na maturidade sexual.

Assim, esse atraso gera impacto econômico negativo para o setor, visto que parte das aves dispostas no galpão vão consumir mais recursos, voltados para a sua manutenção e crescimento, não direcionados à produção (El-Sagheer e Hassanein, 2006). Além disso, o peso corporal pode afetar a qualidade dos ovos. Ekinçi et al. (2023) verificaram que aves pesadas da linhagem Lohmann White apresentaram menor resistência de casca e maior proporção de ovos trincados do que aves leves e com peso médio.

Em vista disso, é fundamental realizar o acompanhamento do peso corporal das frangas de postura, obtendo o peso médio do lote, e comparando-o aos valores de peso padrão para a idade da ave. Esse monitoramento permite corrigir o peso corporal antes do início da fase de postura, garantindo, principalmente, a uniformidade e a alta produtividade do lote. Porém, atualmente, pesar aves de postura é um desafio devido ao manejo intensivo em galpões de alta densidade e criação em gaiolas, que dificultam a manipulação individual sem causar estresse ao lote. Além disso, o tempo e a mão de obra necessários tornam o processo pouco prático.

Por isso, é essencial desenvolver e implementar novas técnicas, como sistemas automatizados de pesagem, que permitam monitorar o peso corporal de forma precisa, rápida e com menor impacto no bem-estar das aves. Tecnologias como o aprendizado de máquina e visão computacional desempenham papel fundamental nesse processo, permitindo a análise de dados coletados por sensores e câmeras para estimar o peso corporal com precisão sem manipulação física. Com o uso de algoritmos avançados é possível identificar padrões em imagens ou vídeos das aves, transformando características como tamanho e proporções em informações úteis de forma automatizada, reduzindo o estresse e promovendo práticas mais éticas e eficientes na avicultura.

2.2 Aprendizado de máquina

Em 1959, o aprendizado de máquina foi definido preliminarmente como um método que torna os computadores capazes de aprender sem programação explícita (Samuel, 1959). Atualmente, concretizado como um ramo da inteligência artificial, permite que computadores aprendam a partir de dados, identificando padrões e melhorando seu desempenho em tarefas específicas com base em experiências anteriores. Esse processo, que minimiza a necessidade de intervenção humana direta, capacita os computadores a coletarem informações, analisar dados, detectar tendências e tomar decisões automatizadas dentro do escopo definido pelos algoritmos utilizados (Mahadevkar et al., 2022).

Em suma, permite "aprender" as características mais relevantes relacionadas a um problema predefinido, analisando exemplos de entrada e realizando um processo de "treinamento". Em termos matemáticos, o principal papel do aprendizado de máquina é encontrar uma função objetivo f que forme o melhor mapeamento entre uma variável de entrada \mathbf{X} e uma variável de saída \mathbf{Y} , ou seja, $\mathbf{Y} = f(\mathbf{X})$, gerando previsões de dados não observados e julgamentos mais precisos dos resultados (Cheng e Yu, 2019).

Para a realização desses processos, o aprendizado de máquina utiliza ferramentas chamadas redes neurais artificiais (RNAs), que são projetadas para lidar com o processamento de dados complexos e não estruturados. Inspiradas no funcionamento da unidade básica do cérebro humano, o neurônio, elas se baseiam principalmente em sua alta conectividade, permitindo que um neurônio receba entradas de muitos outros e transmita sinais ou "potenciais de ação" para outros neurônios na rede (Vodrahalli e Bhowmik, 2017).

De forma estrutural, uma rede neural artificial é composta por camadas sequenciais (Figura 1), em que cada camada realiza operações fixas, mas ajusta seus parâmetros durante o treinamento. A primeira camada recebe os dados de entrada em formato vetorizado, enquanto a última gera a previsão desejada, e as camadas intermediárias, chamadas de "ocultas", transformam a entrada em saída. Cada neurônio em uma camada produz uma única saída, recebendo combinações das saídas de vários neurônios da camada anterior e influenciando muitos neurônios na camada seguinte, replicando a alta conectividade presente no modelo biológico (Vodrahalli e Bhowmik, 2017).

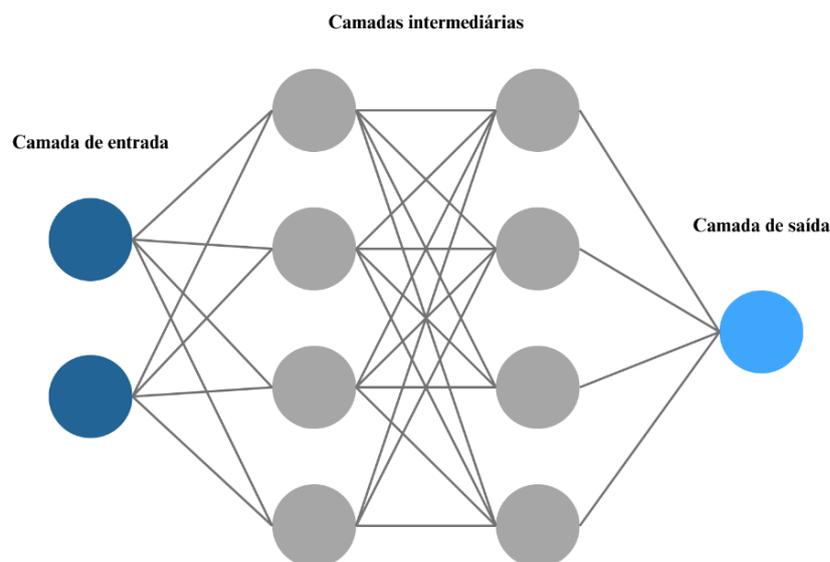


Figura 1. Estrutura básica de uma rede neural artificial. Adaptado de Bre et al. (2018).

O treinamento das RNAs envolve a otimização dos parâmetros internos, como pesos nas camadas ocultas, com o objetivo de minimizar uma função de erro predefinida. Isso é

realizado através de ajustes de hiperparâmetros, que são configurações que controlam o comportamento do algoritmo de aprendizado, como a taxa de aprendizado e o número de camadas, e não são adaptados automaticamente pelo modelo. Uma parte crítica desse processo é a divisão dos dados em três conjuntos: treinamento, validação e teste. A rede é treinada apenas com o conjunto de treinamento, enquanto os conjuntos de validação e teste são usados para avaliar o desempenho do modelo em dados não vistos, garantindo que ele consiga generalizar para novas situações (Bengio et al., 2015).

Em suma, conjunto de treinamento é usado para aprender os parâmetros, enquanto o conjunto de validação é utilizado para estimar o erro de generalização durante ou após o treinamento, permitindo que os hiperparâmetros sejam ajustados de acordo com a necessidade (Bengio et al., 2015). Esse ajuste e a divisão correta dos dados são fundamentais para que o modelo aprenda de forma eficaz, não memorize os dados e seja capaz de oferecer previsões precisas em dados desconhecidos, visando evitar problemas, como o sobreajuste.

2.2.1 Tipos de aprendizado

Para realizar tarefas de previsão e análise de dados, o aprendizado de máquina é dividido em três grandes categorias (Figura 2): primárias, que representam as principais abordagens utilizadas para treinar modelos, incluindo aprendizado supervisionado, não supervisionado e por reforço; híbridas, que combinam características das categorias primárias para aproveitar o melhor de cada abordagem, como o aprendizado semi-supervisionado, entre outros; e avançadas, que lidam com dados escassos ou desbalanceados e exploram métodos para resolver problemas mais complexos e específicos, como o aprendizado por transferência (Mahadevkar et al., 2022).

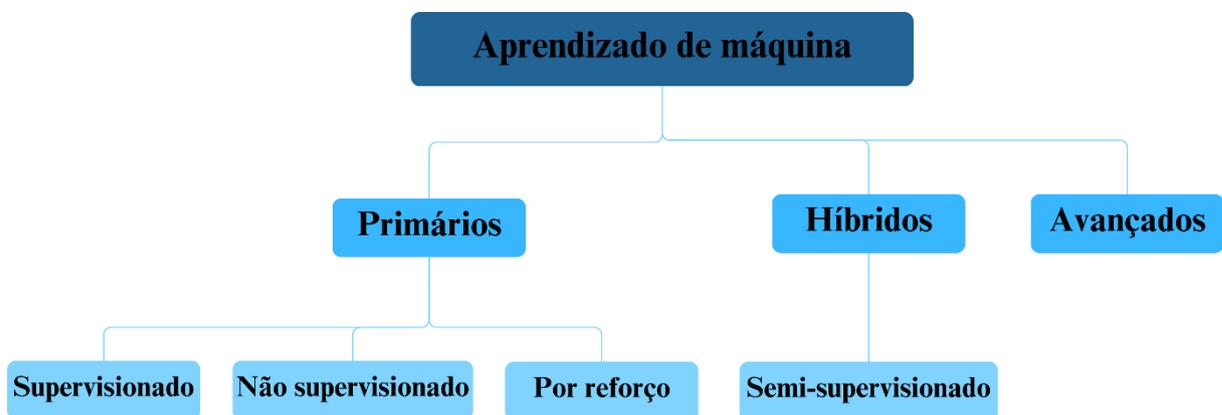


Figura 2. Categorização dos tipos de aprendizado de máquina. Adaptado de Mahadevkar et al. (2022).

No aprendizado supervisionado (AS), o algoritmo é treinado utilizando dados rotulados, ou seja, em situações em que o resultado correto é previamente conhecido. Nesse contexto, o

algoritmo converte cada item de entrada no valor correspondente ao rótulo da classe desejada. Assim, a saída esperada funciona como um sinal de supervisão, enquanto a entrada é representada como um vetor (Nasteski, 2017). Em termos matemáticos, a amostra i tem um vetor de atributos de entrada x_i e um rótulo de saída correspondente y_i (Shang et al., 2018).

Esse aprendizado é dividido em duas subcategorias: classificação e regressão. Na classificação, os objetos e dados de entrada são categorizados com base em classes previamente definidas, permitindo que os algoritmos determinem a classe que melhor se adapta aos dados fornecidos (Osisanwo et al., 2017). Já na regressão, os algoritmos buscam encontrar a função ideal que corresponda aos pontos do conjunto de dados de treinamento, calculando a relação entre variáveis dependentes e independentes, geralmente representada por meio de gráficos de dispersão (Khan et al., 2021). Assim, quando a saída é discreta, pode ser criada uma função classificadora e, quando é contínua, uma função de regressão é gerada a partir dos dados de treinamento. Dessa forma, a função aprendida prevê com precisão a saída correspondente a qualquer entrada, realizando generalizações a partir dos dados de treinamento para novos dados de entrada. Entre os exemplos de algoritmos de classificação, estão as máquinas de vetores de suporte e árvores de decisão. Para problemas de regressão, utilizam-se algoritmos como regressão linear, regressão linear múltipla e regressão polinomial (Kumari e Yadav, 2018).

O aprendizado não supervisionado é normalmente utilizado para resolver problemas de agrupamento ou associação, sendo aplicado em conjuntos de dados que não possuem saídas rotuladas, ou seja, para cada item de entrada não há uma saída correta ou errada, nem envolvimento humano para correção (Karhunen et al., 2015). Nesse contexto, o algoritmo tenta identificar e aprender, por conta própria, um padrão de distribuição nos dados, e, como resultado, agrupa as entradas com base nas características extraídas. Esse tipo de aprendizado é frequentemente empregado para extração de características, identificação de padrões e correspondência de objetos relacionados (Yang et al., 2019). Em termos matemáticos, a amostra i tem apenas um vetor de atributo de entrada x_i . Não existe nenhum rótulo de saída y_i (Shang et al., 2018).

Outro tipo de aprendizado primário é o aprendizado por reforço. Utilizando informações de suas ações e experiências, um agente é treinado em um ambiente interativo para alcançar recompensas por tentativas bem-sucedidas e punições por ações malsucedidas. Dessa forma, o agente aprende com base nas suas experiências, tentando minimizar as ações inadequadas e maximizar as apropriadas (Shafiee e Karimi, 2007). Nesse tipo de aprendizado, o algoritmo não é informado sobre como aprender; ao contrário, ele deve descobrir como fazer isso por conta própria (Arulkumaran et al., 2017).

Outra categoria de aprendizado de máquina é o semi-supervisionado, que utiliza tanto dados rotulados quanto não rotulados para o treinamento de seus algoritmos, justificando sua característica híbrida. Ele combina atributos e rótulos parciais e pode incluir métodos de classificação, regressão e agrupamento, enquanto apenas um desses métodos estão presentes no aprendizado supervisionado ou no não supervisionado (Yu et al., 2017). Sua abordagem envolve o uso de um método de aprendizado não supervisionado para agrupar dados semelhantes; em seguida, os dados restantes, que não são rotulados, são rotulados com base em dados de treinamento já rotulados (Sarker, 2021).

Essas abordagens de aprendizado de máquina, com suas diferentes técnicas e métodos, fornecem ferramentas poderosas para lidar com uma ampla variedade de problemas, desde a análise de dados até a criação de sistemas inteligentes. O uso de categorias primárias, híbridas e avançadas permite que os modelos sejam treinados de maneira mais eficiente, seja com dados rotulados ou não rotulados, adaptando-se a cenários cada vez mais complexos.

2.2.2 Aprendizado profundo

Sendo caracterizado como um subconjunto do AM, o aprendizado profundo (AP) vem realizando avanços nas áreas de processamento e classificação de imagens, reconhecimento de sons e objetos, extração de atributos, seleção de parâmetros e reconhecimento de comportamento (Cheng e Yu, 2019). Caracterizado por redes neurais profundas compostas por várias camadas ocultas, e por meio de estruturas multicamadas e transformações não lineares, o AP revela representações distribuídas e características complexas dos dados, permitindo a resolução de problemas mais sofisticados (Lecun et al., 2015).

Ele combina as características extraídas por camadas inferiores para formar representações mais abstratas em camadas superiores. Dessa forma, as primeiras camadas podem aprender aspectos de baixo nível sobre os dados, enquanto as camadas posteriores capturam conceitos mais complexos e abstratos, culminando na geração da saída final. Para dados de imagem, por exemplo, as primeiras camadas podem atuar como um detector de bordas, enquanto as camadas subsequentes combinam essas bordas para identificar formas e, por fim, objetos completos (Vodrahalli e Bhowmik, 2017). Diferentes camadas são comumente utilizadas para construir redes profundas, como as totalmente conectadas, recorrentes, convolucionais, entre outras.

Um dos mais populares algoritmos de aprendizado profundo, sendo amplamente utilizadas para resolver problemas de análise e processamento de imagens, são as redes neurais convolucionais (CNNs) (Figura 3), onde ao contrário das tradicionais, suas camadas consistem

em neurônios dispostos em três dimensões de largura, altura e profundidade (Nasiri et al., 2019). Formadas pelas camadas convolucionais, são implementadas convoluções utilizando *kernels*, onde cada nó aplica seu *kernel* à imagem de entrada, gerando uma imagem convoluída. Essas camadas também podem ser utilizadas para transformar a imagem, reduzindo seu tamanho por meio de passos (*strides*) que geram imagens de saída menores do que a entrada, ou aumentando o tamanho por meio de convoluções transpostas, que criam imagens de saída maiores (Oliveira, et al., 2021).

O processo de agrupamento (*pooling*) e as camadas de amostragem desempenham papéis complementares, agregando ou interpolando valores para reduzir ou aumentar o tamanho das imagens. De forma simples, uma imagem é inserida no sistema, passando-a por várias camadas de convoluções seguidas e totalmente conectadas, resultando na extração de recursos altamente otimizados para reconhecimento de objetos (Goodfellow et al., 2016). Dessa forma, o processo de separação do objeto do fundo não é necessário antes do processamento, uma vez que essas redes são capazes de aprender as propriedades da imagem automaticamente (Lecun et al., 2015).

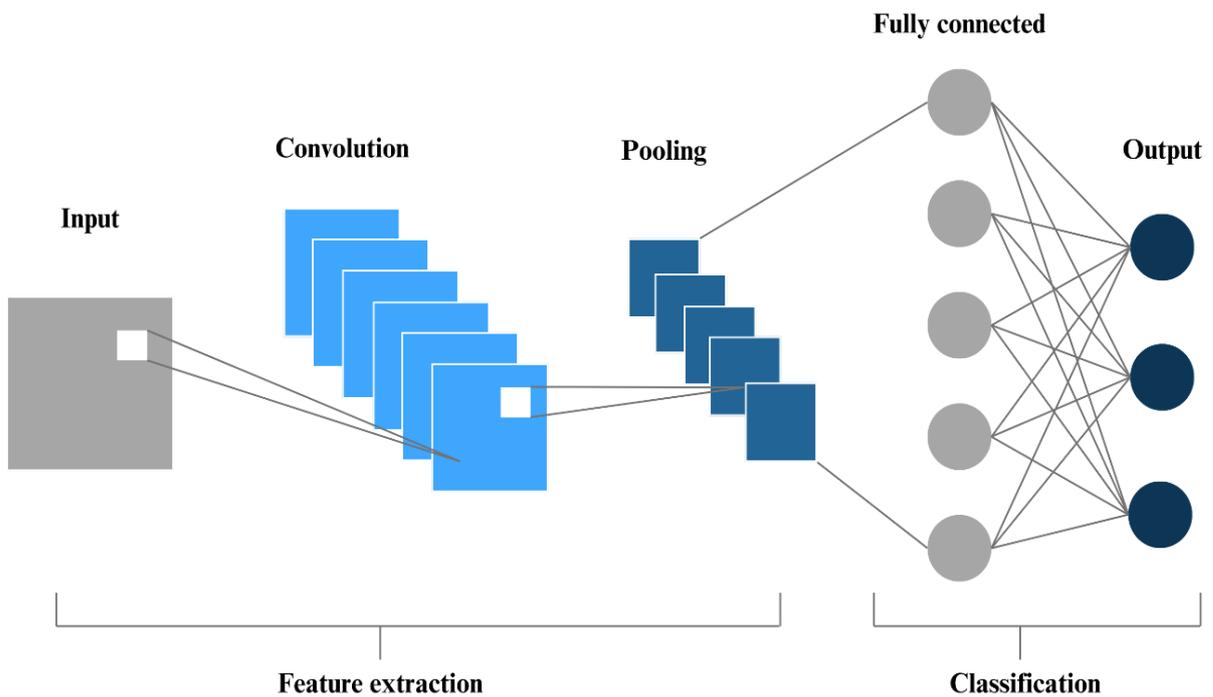


Figura 3. Diagrama esquemático da arquitetura de uma rede neural convolucional básica. Adaptado de Phung e Rhee (2018).

2.3 Visão computacional

A visão computacional é um campo de estudo que busca descrever o mundo por meio de imagens, interpretando-as, reconstruindo-as e extraindo suas propriedades, como formas, texturas, densidades e distâncias (Szelisk, 2022). É caracterizada pela possibilidade de replicação da complexidade do sistema de visão humana, permitindo que os computadores processem e identifiquem objetos em imagem e vídeos da mesma maneira, tal qual os seres humanos fazem (Mihajlovic, 2019). Esse campo concentra-se principalmente na implementação de sistemas artificiais capazes de resolver problemas visuais, utilizando técnicas de processamento de imagens e análise de dados (Dorea et al., 2021).

Ela é dividida em duas etapas, o processamento digital (PDI) e a análise de imagens. O PDI é caracterizado por técnicas visando capturar, representar e transformar imagens, permitindo extrair e identificar informações, além de melhorar a qualidade visual através de suas propriedades, como formato, brilho ou cor, facilitando a obtenção de características que serão utilizadas posteriormente. Já para a análise de imagens, é necessário um conjunto de algoritmos específicos, que envolve técnicas como segmentação em regiões de interesse, filtros de contrastes, descrições dos objetos, reconhecimento e classificação, utilizando imagens como entrada e produzindo outro tipo de saída (Conci et al., 2008; Pedrini e Schwartz, 2008).

Nos últimos anos, a visão computacional tem passado por mudanças significativas, impulsionadas principalmente por sua associação com o aprendizado de máquina, especialmente o aprendizado profundo. Uma das primeiras arquiteturas de aprendizado profundo propostas, empregou camadas convolucionais e totalmente conectadas para lidar com extração e classificação de atributos em um único modelo, trazendo um salto na performance que desencadeou uma revolução na análise de imagens (Oliveira et al., 2021). Com o desenvolvimento e a adaptação de algoritmos projetados especificamente para resolver problemas visuais, esses métodos têm demonstrado desempenho superior em relação às técnicas clássicas, aplicando-se a tarefas como segmentação de imagens, reconhecimento de padrões e classificação de objetos (Lecun et al., 2015).

Dentre as tarefas realizadas pela visão computacional, a classificação de imagens é uma das mais populares e aplicadas, tendo como principal objetivo associar uma categoria (classe) a uma determinada imagem. Já o reconhecimento de padrões, no contexto de imagens, realiza a análise por meio do desenvolvimento de métodos matemáticos para identificar estruturas geométricas simples, como linhas e círculos (Atherton e Kerbyson, 1999), ou características

como pontos-chave, que podem ser combinadas para reconhecer objetos ou padrões mais complexos (Murphy, 2012).

Um aspecto importante para o sucesso na realização de tarefas é a forma como a imagem digital é adquirida, já que diferentes tipos de equipamentos são mais adequados para distintas aplicações. Na formação da imagem, os sinais luminosos são capturados pelo sensor, codificados e armazenados em matrizes de dados, que podem ser interpretadas e manipuladas por algoritmos computacionais (Szeliski, 2022). Para um computador, a imagem é representada como valores numéricos em uma matriz estruturada de dados, que codifica luz e cores para cada ponto da imagem (Figura 4). Essa matriz pode ser única, contendo valores que correspondem ao preto ou branco (imagem binária) ou diferentes tons de cinza (imagem em escala de cinza) (Fernandes et al., 2020). Além disso, podem ser imagens coloridas representadas por três matrizes, correspondendo às intensidades de vermelho, verde e azul, como no modelo RGB.

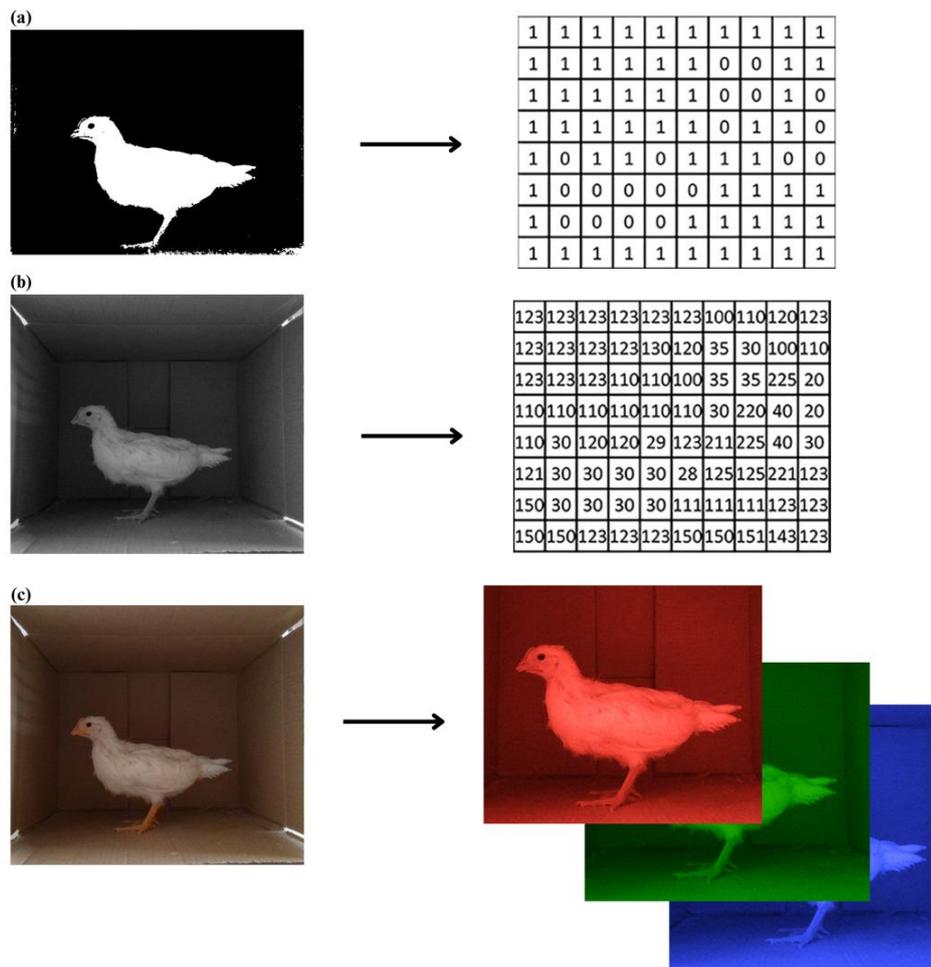


Figura 4. Representação de imagem digital. (a) Imagem lógica com valores de 1 para branco e 0 para preto; (a) imagem em tons de cinza com profundidade de 24 bits (valores variando entre 0 e 255); (c) imagem colorida no espaço de cores RGB. Adaptado de Fernandes et al. (2020).

Os dispositivos com sensores de imagens mais utilizados são as câmeras digitais padrão, no entanto, as câmeras 3D comerciais (Microsoft Kinect[®], Intel RealSense[®]) vêm ganhando atenção devido a sua capacidade de gerar imagens tridimensionais (Keselman et al., 2017). As câmeras híbridas, com sensores RGB-D, combinam sensores RGB com os de profundidade, sendo capazes de gerar matrizes mais complexas, a partir da incorporação das informações de profundidade à imagem colorida (Fernandes et al., 2020). Algumas delas são baseadas em estereoscopia ativa, associando imagens estéreo com luz estruturada para melhorar a estimativa da profundidade (Intel, 2025).

Além da aquisição de imagens estáticas para análises, a exploração de recursos de vídeos, especialmente por meio da extração de informações temporais, permite a integração de dados de múltiplos quadros, possibilitando a construção mais abrangente do objeto e superando as limitações das análises baseada em imagens únicas. Em aplicações, como na produção animal, esse processo não apenas captura variações específicas no corpo do animal em diferentes momentos, mas também considera a consistência e as características dinâmicas do movimento, resultando em um conjunto de informações mais detalhado, sutis e contextualmente relevantes (Fernandes et al., 2019).

A associação do AP e da VC também são utilizados em conjunto para construir codificadores e decodificadores, sendo especialmente úteis em tarefas como segmentação semântica de imagens, classificando os pixels individuais, e realizando o particionamento de imagens em vários segmentos ou objetivos e faz a rotulagem de tais segmentos com classe conhecidas (Fernandes et al., 2020). Ao utilizar uma CNN em dados RGB-D, a rede envolve dois caminhos paralelos: primeiro, é realizada a classificação dos objetos da cena utilizando as informações de profundidade; em seguida, é aplicada uma função para segmentar a cena. Antes de ser inserida na rede, a imagem passa por um pré-processamento para normalizar os pixels, forçando média zero e desvio padrão unitário em regiões vizinhas. As informações de profundidade são então adicionadas como um quarto canal aos três canais RGB da imagem, formando uma entrada com quatro camadas, que é posteriormente inserida na CNN (Couprie et al., 2013).

Na pecuária, especialmente na avicultura, o uso de sensores RGB-D aliado às CNNs tem se mostrado robusto para a identificação individual de animais, medição de volume e superfície, além do reconhecimento de partes do corpo. Essas técnicas são amplamente exploradas para o monitoramento automatizado, permitindo a análise do comportamento animal e a avaliação de características corporais, como peso e conformação. Além disso, a segmentação

precisa das aves em ambientes complexos auxilia no manejo, na detecção de anomalias e na melhoria do bem-estar animal, otimizando a produção e a tomada de decisões na granja.

2.4 Aplicação da visão computacional e aprendizado de máquina na avicultura

Antes do advento de sistemas de aprendizado profundo associados a visão computacional, muitas das aplicações na avicultura exigiam elevada mão de obra e uso do olho treinado para classificação visual de características em animais, como escore de condição corporal, comportamento, detecção de doenças, deposição de gordura na carcaça e classificação da qualidade da casca do ovo (Fernandes et al., 2020). A maioria dos métodos ainda utilizados demandam por pessoal especializado, para treinamentos e monitoramentos periódicos visando garantir a qualidade das avaliações. Além disso, os processos relacionados ao manejo são frequentemente demorados, custosos para os produtores e podem causar estresse nos animais, tornando sua aplicação limitada tanto por questões econômicas quanto pelo bem-estar animal.

A zootecnia de precisão tem sido usada como solução para esses desafios, fornecendo sistemas automatizados eficientes, e ao mesmo tempo, mantendo o bem-estar animal, servindo como sistema de apoio aos produtores para monitorar bioprocessos, biorespostas e produtividade, de forma eficaz, objetiva e não invasiva (Lehr, 2014; Berckmans, 2017). Na produção avícola, técnicas de visão computacional têm sido usadas para as aves e seus produtos (Okinda et al. 2020). Na inspeção de segurança, para detectar contaminantes fecais em carcaças de frangos (Park et al., 2003); classificação de maciez de cortes comerciais, como filés de peito de frango (Jiang et al., 2018); detecção de sujidades, defeitos e rachaduras, estimativa de frescor, peso e classificação de ovos (Wang, 2014; Sun et al., 2015; Nasiri et al., 2020); além da estimativa de peso de carcaças de frangos de corte e peso vivo de aves (Chen et al., 2017; Amraei et al., 2017).

Entre os parâmetros monitorados na avicultura, como mencionado anteriormente, o peso corporal das aves é um dos mais relevantes, pois está diretamente relacionado ao desempenho produtivo (Nyalala et al., 2021). O monitoramento automatizado do peso permite a detecção precoce de desvios no crescimento, possibilitando ajustes na nutrição e no manejo para otimizar a produção. Muitos dos trabalhos que aplicam o aprendizado de máquina para essa finalidade, utilizam características geométricas 2D de imagens RGB, como a circunferência, área projetada, e perímetro, ou medidas morfométricas dos animais, como comprimento de canela, altura da crista e largura de cabeça, para realizar a predição de peso corporal. Amraei et al. (2018) extraíram de imagens de frangos de corte, seis características 2D (área, área convexa, perímetro, excentricidade, comprimento do eixo maior e menor), através de software, para

utilizar como dados de entrada em um modelo de regressão para predição de peso dos animais. Tyasi et al. (2020) utilizaram medidas corporais de poedeiras obtidas com um auxílio de uma fita métrica para prever o peso através de árvores de classificação e regressão. Esses métodos, embora eficazes, apresentam algumas limitações. A extração de características geométricas a partir de imagens RGB pode estar sujeita a variações na iluminação, posicionamento do animal e qualidade da imagem, o que pode comprometer a precisão das medições. Além disso, o uso de fitas métricas para obtenção de medidas corporais demanda contato direto com os animais, o que pode gerar estresse e influenciar seu comportamento.

Nesse contexto, o uso de aprendizado profundo aplicado a imagens de profundidade surge como uma alternativa mais robusta e menos invasiva. Diferente das imagens RGB, as imagens de profundidade capturam a estrutura tridimensional do animal, permitindo uma estimativa mais precisa do volume corporal sem a necessidade de contato físico. Através da utilização do aprendizado profundo, imagens específicas ou vídeos das aves são utilizados como entrada para um modelo, que gera o peso, a classificação corporal ou outros parâmetros desejados na camada de saída, por meio do treinamento de redes neurais profundas, como as CNNs (Zhao et al., 2023). Esse processo permite a extração automática de características por meio de redes neurais convolucionais, projetadas para identificar os atributos mais relevantes na distinção dos animais em imagens pré-processadas, evitando a necessidade de extração manual de recursos. Dessa forma, características, como o padrão corporal, são analisadas e comparadas, possibilitando a determinação da categoria do animal por meio de um algoritmo de classificação (Chen et al., 2021).

Os métodos de reconhecimento baseados em aparências visuais 3D superam desafios relacionados à variação de tamanho devido a mudanças de postura e distância do animal, permitindo sua aplicação em grandes aviários sem depender da distribuição de cores e diferenciando efetivamente animais semelhantes. Arslan et al. (2014) propuseram um sistema baseado no Kinect, uma câmera que utiliza tecnologia 3D, capaz de identificar animais individualmente com base em suas aparências visuais, tendo sua solução dependente apenas das informações da forma corporal. Em comparação aos modelos tradicionais de pesagem, os métodos baseados em aprendizado profundo oferecem maior automatização, reduzindo o trabalho manual e aumentando a acurácia da predição, mesmo em condições variáveis de iluminação e posicionamento dos animais.

3. MATERIAL E MÉTODOS

3.1 Local do experimento e delineamento experimental

A pesquisa teve aprovação do Comitê de Ética no Uso dos Animais da Universidade Federal Rural de Pernambuco (UFRPE), com o número de protocolo 7395050922. O experimento foi conduzido no Laboratório de Pesquisa com Aves do Departamento de Zootecnia da Universidade Federal Rural de Pernambuco, no município de Recife-PE situado a 4,5 m de altitude em relação ao nível do mar e coordenadas geográficas 8°3'14" de latitude S e 34°52'52" de longitude W.

Foram utilizadas 200 aves poedeiras da linhagem Dekalb White com idade entre 1 dia e 16 semanas. Durante a fase de cria (1 a 5 semanas) e recria (6 a 16 semanas), as aves foram criadas em gaiolas metálicas equipadas com comedouro tipo calha e bebedouro automático com copinho acoplado, com água e ração *ad libitum*. Foram fornecidas rações de acordo com a idade das aves, sendo uma ração na fase de cria, de 1 a 5 semanas de idade (PB: 22,69%; EM: 2975 kcal/kg), e duas na fase de recria, de 6 a 10 semanas (PB: 19%; EM: 2852 kcal/kg) e de 10 a 15 semanas (PB: 16%; EM: 2800 kcal/kg), atendendo as exigências nutricionais de cada fase de criação, conforme as recomendações do manual da linhagem. O programa de luz adotado durante essas fases foi decrescente, ou seja, na primeira semana de vida foram fornecidas 24 horas de luz, reduzindo posteriormente 1 hora por dia até não receberem mais luz artificial.

Durante a 7ª semana de idade, as aves foram pesadas e classificadas em três categorias de peso corporal: leves, médias e pesadas e divididas igualmente (30 aves por categoria), de acordo com o padrão de peso da linhagem Dekalb White para essa idade. Aves com peso inferior a 439 g foram classificadas como leves; aquelas entre 440 e 498 g foram consideradas médias, e as com peso superior a 499 g foram classificadas como pesadas.

Na 15ª semana de idade, as aves foram novamente pesadas e classificadas em três categorias de peso corporal: leves, médias e pesadas e divididas igualmente (30 aves por categoria), de acordo com o padrão de peso da linhagem Dekalb White para essa idade. Aves com peso inferior a 1053 g foram classificadas como leves; aquelas entre 1054 e 1210 g foram consideradas médias, e as com peso superior a 1211 g foram classificadas como pesadas.

Os pesos médios, mínimos, máximos e desvio padrão das aves durante a 7ª e 15ª semanas estão apresentados na Tabela 1.

Tabela 1. Média, mínimo, máximo e desvio padrão do peso corporal das aves, de acordo com a classe durante a 7ª e 15ª semana de idade

Classe	7 semanas de idade			
	Médio	Mínimo	Máximo	Desvio padrão
Leve	384,78	303,2	409,7	27,35
Média	460,02	430,9	483,9	13,88
Pesada	530,33	510,2	575,4	17,01
15 semanas de idade				
Leve	950,04	842,3	1006,4	49,16
Média	1110,43	1054,7	1207,4	46,08
Pesada	1274,52	1216,4	1347,0	40,98

3.2 Obtenção das imagens de profundidade

Foram selecionadas aleatoriamente 18 aves por categoria de peso corporal às 7 e 15 semanas de idade para a realização da captura das imagens, de forma individual, pela manhã, em uma sala com presença de luz natural e artificial, sendo a câmera direcionada para o corpo inteiro da ave. As imagens de profundidade foram adquiridas por meio da câmera Intel RealSense D455[®], com resolução de 1280 x 720 pixels a uma taxa de quadros de 30 fps. O equipamento foi calibrado, e as filmagens tiveram duração aproximada de 10 a 20 segundos. As capturas foram realizadas a partir de uma visão frontal, com a câmera posicionada para captar a lateral dos animais (Figura 5). Para isso, foi utilizado um suporte metálico ajustado a cerca de 110 cm do chão. Foram respeitados os valores mínimos e máximos de distância necessários para garantir uma estimativa precisa da profundidade, com as distâncias entre a câmera e as aves variando de 0,8 a 1,2 m.

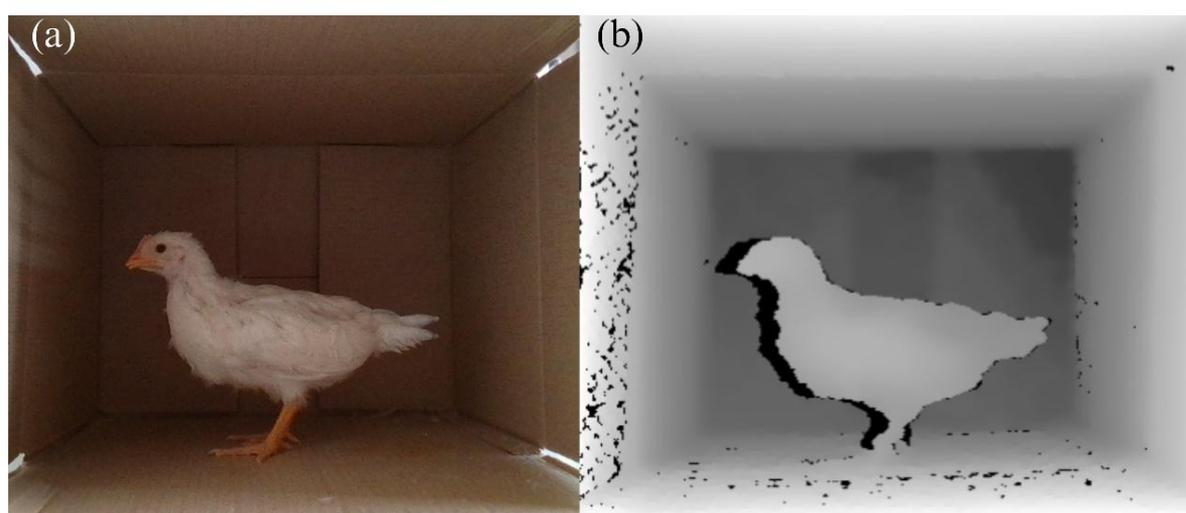


Figura 5. (a) Imagem RGB capturada lateralmente dos animais, (b) imagem de profundidade pré-processada.

3.3 Pré-processamento e aprendizado de máquina

As filmagens foram processadas por meio de um algoritmo de extração de frames para arquivos em formato ONI, utilizando o OpenNI2[®], uma biblioteca de código aberto, para a aquisição de imagens em 8 bits e 16 bits. Foram utilizadas as imagens de 16 bits, devido à sua maior capacidade de armazenar informações em cada pixel. Com filmagem entre 10 e 20 segundos de duração, foi possível obter cerca de 350 a 450 capturas.

Foram empregadas técnicas de espelhamento horizontal e pequenas rotações, introduzindo variações nos dados e melhorando a capacidade do modelo de generalizar para novas situações. As imagens passaram por técnicas de transformação e pré-processamento (Figura 6), incluindo erosão, fechamento morfológico, conversão para escala de cinza e aplicação de desfoque gaussiano, visando a redução de ruído (Szeliski, 2022). Em seguida, foi realizada uma limiarização utilizando o método de Otsu, que binariza a imagem, separando os objetos de interesse do fundo (Otsu et al., 1975). Posteriormente, uma segmentação de componentes conectados foi aplicada para identificar objetos distintos na imagem, e cada objeto foi colorido aleatoriamente, facilitando a visualização e análise. Já dentro do modelo, foram redimensionadas para um tamanho fixo de 224 x 224 pixels, assegurando uniformidade e compatibilidade com modelos padronizados.

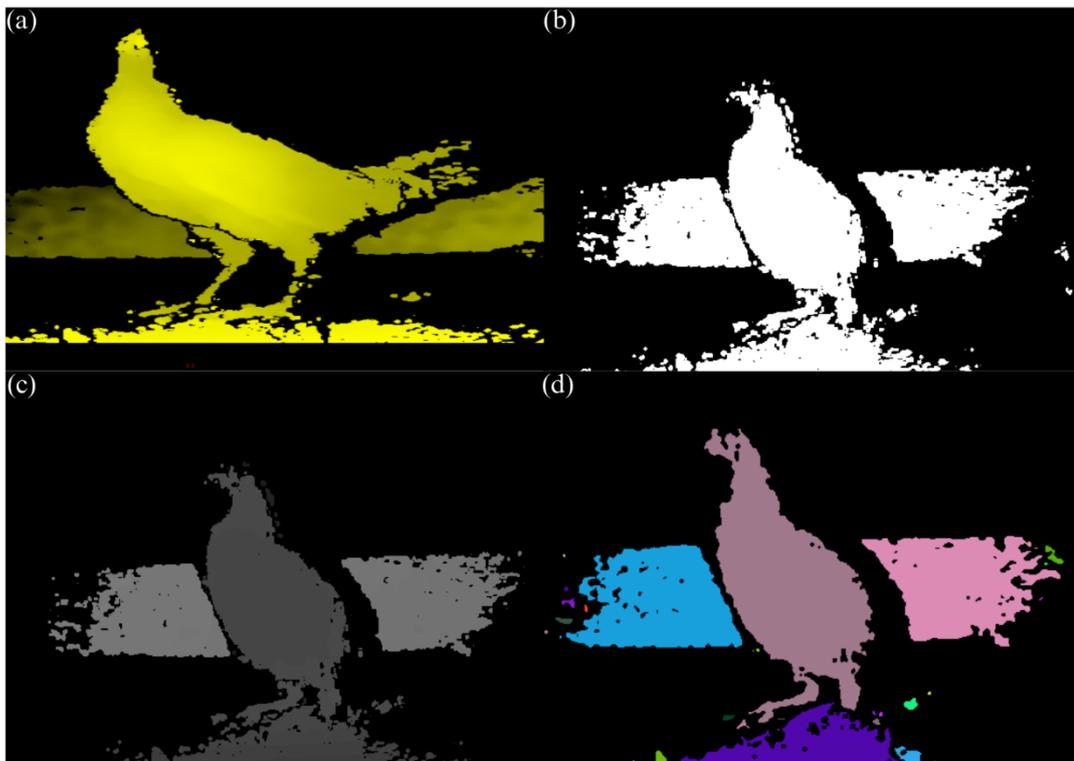


Figura 6. (a) Imagem original tipo ONI, (b) 8 bits, (c) 16 bits, (d) imagem após erosão, escala de cinza, desfoque gaussiano e limiarização por método de Otsu.

Em relação às técnicas de aprendizado de máquina, foi utilizado o aprendizado supervisionado, seguindo o modelo clássico composto por coleta dos dados, pré-processamento, construção do modelo e avaliação do modelo.

3.3.1 Coleta dos dados

Foi gerada uma base de dados a partir das imagens capturadas das aves, utilizando-as diretamente como dados de entrada para o aprendizado profundo, sendo empregada para o treinamento e validação dos modelos de classificação.

3.3.2 Pré-processamento

Foi realizado o pré-processamento dos dados de entrada, com etapas de limpeza e tratamento dos dados faltantes e com possibilidade de erro de coleta. Posteriormente, os valores de profundidade foram normalizados para o intervalo entre 0 e 1 e padronizados com média 0 e desvio padrão 1, garantindo que os dados estejam escalonados de forma adequada para o treinamento. Foram analisados e selecionados arquiteturas de redes neurais para classificação de imagens, visando identificar os padrões complexos e mais relevantes para o modelo, com o objetivo de determinar quais informações nas imagens eram mais significativas para a tarefa de reconhecimento.

3.3.3 Construção do modelo

Nesta etapa foram construídos e explorados quatro algoritmos de classificação:

- **CNN (*Convolutional Neural Network*):** Composta por 4 camadas treináveis, sendo 2 convolucionais e 2 totalmente conectadas. Ela começa com camadas convolucionais que utilizam filtros de 3×3 e *padding* igual, seguidas de camadas de *max-pooling* 2×2 para redução de dimensionalidade. A rede inclui blocos de camadas convolucionais com 16 e 32 filtros e termina com duas camadas totalmente conectadas que utilizam ReLU, além de uma camada de saída com 3 neurônios para classificação. A rede também incorpora *dropout* para regularização (Lecun et al., 1989).
- **VGG16 (*Visual Geometry Group 16-layer network*):** Composta por 16 camadas treináveis, sendo 13 convolucionais e 3 totalmente conectadas. Ela começa com camadas convolucionais que utilizam filtros de 3×3 e *padding* igual, seguidas de camadas de *max-pooling* 2×2 para redução de dimensionalidade. A rede inclui blocos de camadas convolucionais

com 64, 128, 256 e 512 filtros, e termina com três camadas totalmente conectadas que utilizam ReLU e uma saída com *softmax* para classificação (Simonyan e Zisserman, 2015).

- **ResNet50 (*Residual Network with 50 layers*):** Possui 49 camadas convolucionais e uma camada totalmente conectada na saída, com uma camada inicial de convolução e *pooling*, seguida por blocos estruturados em quatro estágios, onde os filtros de 64, 128, 256 e 512 são aplicados. Esses blocos empregam convoluções 1×1 e 3×3 , seguidas da ativação ReLU, finalizando com uma camada de *pooling* global e uma saída que utiliza *softmax* (He et al., 2016).

- **ConvNeXt (*Convolutional Neural Network Next*):** Composta por 15 camadas treináveis, sendo 12 convolucionais e 3 totalmente conectadas. Ela começa com camadas convolucionais que utilizam *kernels* de 7×7 e *layer normalization*, seguidas de camadas de *downsampling* para redução de dimensionalidade. A rede inclui blocos de camadas convolucionais com 96, 192, 384 e 768 filtros, e termina com três camadas totalmente conectadas, que utilizam ReLU e *dropout*, além de uma camada de saída com *softmax* para classificação (Liu et al., 2022).

A amostra de dados foi dividida em três grupos: conjunto de treinamento, com 60% das amostras; validação, com 20% das amostras; e testes, com 20% das amostras (Tabela 2). Foi utilizado a técnica de validação cruzada *k-fold* (dobra dos dados), servindo para avaliar a capacidade de generalização do modelo (Arlot e Celisse, 2010). O conjunto de dados foi dividido em 2 *folds*, e o modelo foi treinado 2 vezes, cada vez utilizando 1 *fold* para treino e o restante para validação. O resultado foi obtido através da média das 2 execuções dos *folds*.

Tabela 2. Número de imagens capturadas e destinadas para treinamento, validação e teste de acordo com a classe de peso corporal das aves durante a 7ª e 15ª semana de idade

Classe	7ª semana			
	Capturadas	Treinamento	Validação	Teste
Leve	8748	5248	1750	1750
Média	8000	4678	1661	1661
Pesada	7452	4470	1491	1491
Total	24200	14396	4902	4902
15ª Semana				
Leve	6768	4060	1354	1354
Média	7288	4372	1458	1458
Pesada	5120	3072	1024	1024
Total	19176	11504	3836	3836

A Tabela 3 apresenta os principais hiperparâmetros utilizados no modelo, juntamente com seus valores específicos. Estes incluem o tamanho do *batch*, o número de *epochs* de treinamento, a taxa de aprendizado, *weight decay*, a taxa de *dropout*, o tamanho do *kernel* das

camadas convolucionais, o número de *folds* para validação cruzada, além do *stride* e do *padding* utilizados nas convoluções. Os hiperparâmetros foram ajustados manualmente para otimizar a performance do modelo, balanceando a precisão e a capacidade de generalização durante o treinamento e validação.

Tabela 3. Hiperparâmetros e configurações de treinamento das arquiteturas de redes neurais convolucionais

Parâmetros do modelo	Valores
<i>Batch size</i>	128
<i>Epochs</i>	50
<i>Learning rate</i>	0,0001
<i>Weight decay</i>	0,0001
<i>Dropout</i>	0,2
<i>Kernel size</i>	3
<i>Folds</i>	2
<i>Stride</i>	1
<i>Padding</i>	1

Todos os modelos foram gerados utilizando a linguagem de programação *Python*, empregando bibliotecas específicas para as funções utilizadas, como o *Scikit-learn* para modelagem e avaliação, o *PyTorch* para o desenvolvimento das redes neurais, o *Pandas* para manipulação e análise dos dados, o *Matplotlib* para visualização dos gráficos dos resultados da classificação e o *OpenCV* para processamento de imagens e manipulação de dados visuais. Em relação a parte de hardware, foi utilizado um computador equipado com uma GPU RTX 4060TI, um processador Intel I9 da 12ª geração, 32 GB de memória RAM e com o auxílio de um SSD de 1TB de armazenamento.

3.3.4 Avaliação do modelo

Todos os modelos testados foram avaliados pelas métricas de acurácia, precisão, recall, escore F-1, ROC AUC, especificidade, coeficiente de correlação de Matthews e escore de Kappa (Kappa de Cohen), juntamente com suas respectivas fórmulas (Van Rijsbergen, 1979):

- **Acurácia:** Proporção de predições corretas em relação ao total de exemplos.

$$\frac{TP + TN}{TP + TN + FP + FN}$$

- **Precisão:** Proporção de exemplos classificados como positivos que são realmente positivos.

$$\frac{TP}{TP + FP}$$

- **Recall:** Proporção de exemplos realmente positivos que foram corretamente classificados.

$$\frac{TP}{TP + FN}$$

- **Score F1:** Média harmônica entre a precisão e recall.

$$2 * \frac{\text{Precisão} * \text{Recall}}{\text{Precisão} + \text{Recall}}$$

- **Coefficiente de correlação de Matthews (MCC):** Avalia a qualidade das predições considerando todas as categorias (TP, TN, FP, FN).

$$\frac{(TP * TN) - (FP * FN)}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$$

- **Especificidade:** Proporção de exemplos realmente negativos que foram corretamente classificados.

$$\frac{TN}{TN + FP}$$

- **Score de Kappa (Kappa de Cohen):** Avalia o grau de concordância entre as predições e os valores reais, ajustado para concordância por acaso.

$$\frac{Po - Pe}{1 - Pe}$$

- **ROC AUC:** A AUC representa a área sob a curva ROC, indicando a capacidade geral do modelo em classificar corretamente

$$TPR = \frac{TP}{TP + FN} \quad FPR = \frac{FP}{FP + TN} \quad ROC AUC = \frac{TPR}{FPR}$$

Sendo: **TP** a quantidade de verdadeiros positivos, **TN** a quantidade de verdadeiros negativos, **FP** a quantidade de falsos positivos, **FN** a quantidade de falsos negativos, **TPR** a taxa de verdadeiros positivos, **FPR** a taxa de falsos positivos, **Po** a proporção de concordância observada e **Pe** a proporção de concordância esperada por acaso.

Também foi avaliada a matriz de confusão (Tabela 4) para medir o desempenho dos modelos, fornecendo informações sobre as classificações corretas e incorretas de amostras positivas, bem como as classificações corretas e incorretas de amostras negativas (Sokolova e Lapalme, 2009).

Tabela 4. Matriz de confusão para análise de desempenho da classificação

		Classe prevista	
		Positivo	Negativo
Classe atual	Positivo	TP ¹	FN ³
	Negativo	FP ²	TN ⁴

¹Verdadeiro positivo, ²Falso positivo, ³Falso negativo, ⁴Verdadeiro negativo.

4. RESULTADOS E DISCUSSÃO

A acurácia é uma das principais e mais simples métricas para avaliar um modelo de classificação, principalmente porque leva em consideração as previsões corretas em relação ao número total. Sendo assim, é eficiente ao demonstrar a capacidade do modelo em aprender através de dados não vistos e classificá-los corretamente em suas devidas classes (Mariano, 2021). Ao analisar o desempenho dos modelos que utilizaram imagens das aves com 7 semanas de idade, as CNNs apresentaram os melhores resultados de acurácia, com uma média de 80,9% de previsões corretas, seguidas pelo modelo VGG16, com 58,5%, pelo ConvNeXt, com 54,9%, e pelo ResNet50, com 39,4% (Figura 7).

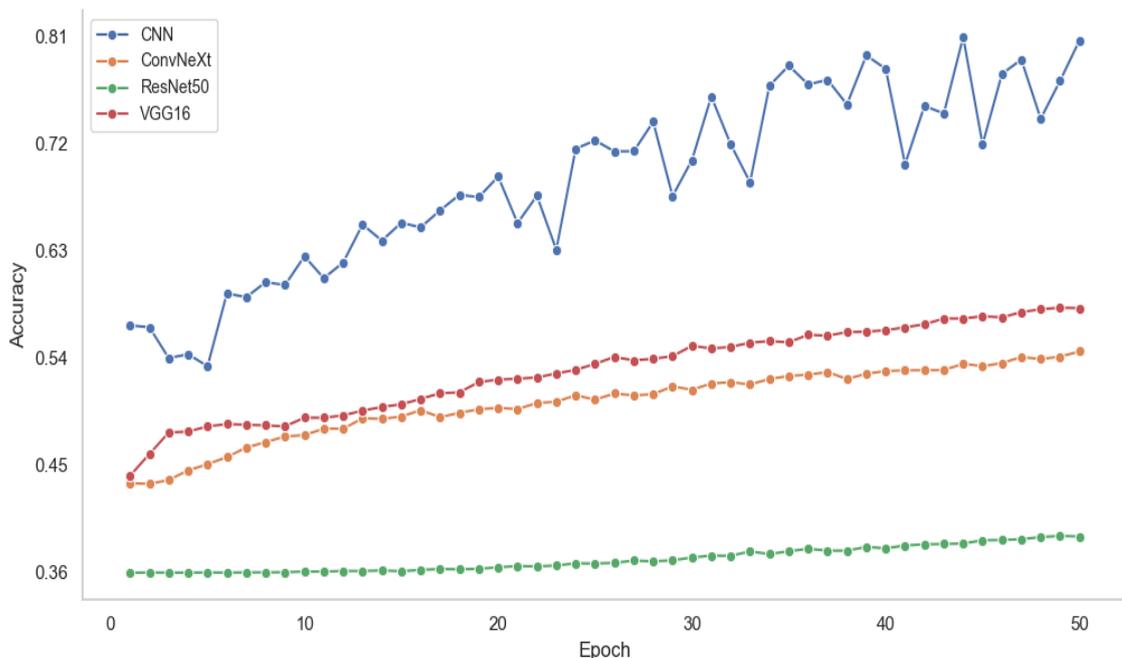


Figura 7. Acurácia das arquiteturas CNN, ConvNeXt, ResNet50 e VGG16 ao longo das épocas utilizando imagens de frangas de postura com 7 semanas de idade.

Por outro lado, ao utilizarem imagens de aves com 15 semanas de idade, todas as arquiteturas apresentaram desempenho superior. As CNNs obtiveram o melhor resultado, com 95,4% de acurácia, superando o VGG16 (64,3%), o ConvNeXt (63,6%) e o ResNet50 (42,3%) (Figura 8).

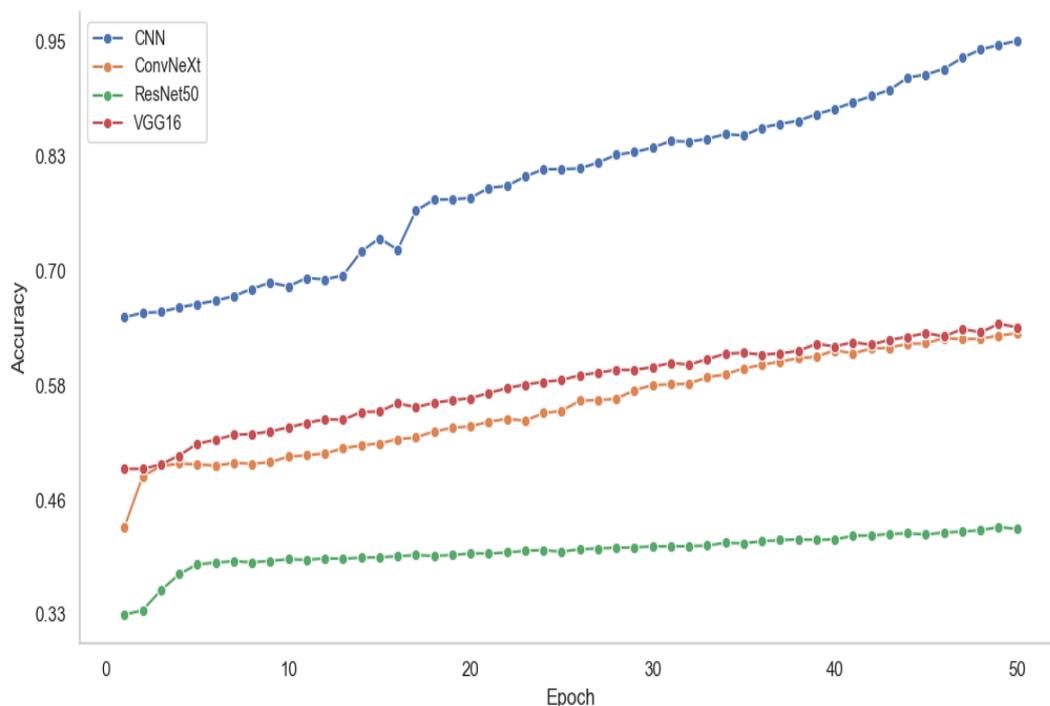


Figura 8. Acurácia das arquiteturas CNN, ConvNeXt, ResNet50 e VGG16 ao longo das épocas utilizando imagens de frangas de postura com 15 semanas de idade.

O melhor desempenho dos modelos utilizando imagens de aves mais velhas pode estar associado ao desenvolvimento das características físicas ao longo do tempo. Com o avanço da idade, estruturas como a crista e penas tornam-se mais desenvolvidas e proeminentes, proporcionando características visuais mais distintas (Jönsson et al., 2011). Essas mudanças podem ter facilitado a extração de padrões pelos modelos, permitindo uma diferenciação mais eficiente entre as classes e, conseqüentemente, um aumento na precisão das previsões. Além disso, a maior definição dos contornos corporais e das feições das aves podem ter contribuído para um melhor reconhecimento pelos algoritmos de aprendizado profundo.

Embora o modelo com CNNs apresente desempenho superior com frangas mais velhas, sua aplicação em aves mais jovens é fundamental para possibilitar a correção do peso corporal, exercendo um papel crucial na produção de ovos. Ao intervir precocemente, é possível ajustar o desenvolvimento das aves, garantindo que atinjam a maturidade sexual no momento adequado e iniciem a postura de forma uniforme, o que se reflete em uma produção mais consistente e de melhor qualidade. Essa correção permite não apenas otimizar o manejo e a nutrição, prevenindo

desvios no crescimento, mas também maximizar os ganhos econômicos e a sustentabilidade do processo produtivo avícola. Resultado semelhante foi encontrado por Anuprabha et al. (2024), ao utilizarem filmagens com uma câmera de profundidade de frangos de corte, de um ângulo superior, como dado de entrada para modelos de redes neurais convolucionais 3D, atingindo valor de acurácia de 95% de acerto na predição do peso, demonstrando como a arquitetura desse algoritmo se adequa à captura e frames através de suas camadas, sendo um método eficiente para esse tipo de estimativa.

Já Khojastehkey et al. (2021) utilizaram redes neurais artificiais (do tipo *Feed-forward*) e imagens RGB, para estimar o peso de pintos de corte comerciais, tanto machos quanto fêmeas, das linhagens Ross 308, Cobb e Arbor Acres, alcançando valores de acurácia de 98,5%, 99,6% e 99,7%, respectivamente. Ao comparar esses resultados com os aqui apresentados, utilizando poedeiras de 7 semanas de idade, os autores encontraram maiores escores em relação às redes neurais convolucionais (CNN). Essa diferença pode ser atribuída ao fato de que frangos de corte, machos e fêmeas, apresentam características físicas mais evidentes, facilitando a classificação. Em contrapartida, as frangas de postura mais novas (7 semanas) podem estar em uma fase de transição morfológica, com características ainda não totalmente definidas ou que se sobrepõem entre as categorias, aumentando a dificuldade do modelo em classificar corretamente.

Em casos em que a acurácia possa ser tendenciosa, quando os modelos podem simplesmente prever a classe majoritária com boa precisão, obtendo valor alto de acurácia, mas sem realmente aprender a identificar a classe minoritária, o escore F1, que representa a média harmônica entre a precisão e o recall, se torna uma métrica fundamental no aprendizado de máquina (Holzmann e Klar, 2024). No presente estudo, o modelo com CNNs apresentou elevado valor de acurácia, que foi confirmado pelo valor de F1, com 81% às 7 semanas e 95,4% às 15 semanas (Tabela 5), indicando bom equilíbrio e demonstrando que o modelo consegue minimizar os erros. Por outro lado, quando comparados ao CNN, os modelos VGG16, ConvNeXt e ResNet50 apresentaram resultados inferiores, com 57,7%, 54,5% e 26,3% às 7 semanas, e 63,6%, 62,5% e 30% às 15 semanas, respectivamente (Tabela 5).

Fang et al. (2022) projetaram um sistema para estimar a postura de frangos e galinhas, com o objetivo de analisar seus movimentos e comportamentos por meio das dimensões corporais. Os autores utilizaram a arquitetura pré-treinada ResNet50 para a extração de recursos das imagens e, posteriormente, redes neurais convolucionais para a detecção de objetos por meio do Fast R-CNN. Dessa forma, obtiveram um F1-score de 77% e uma precisão de 84% para esse modelo, resultados semelhantes aos das redes neurais utilizadas no presente estudo.

Embora o ResNet50 não tenha apresentado resultados satisfatórios para essas métricas, uma abordagem relevante seria sua associação com as CNNs para a extração de características essenciais na classificação da categoria do peso corporal.

Em relação à precisão dos modelos, ou seja, o quanto de previsões positivas realizadas realmente pertenciam à classe positiva, utilizando imagens de poedeiras com 7 semanas de idade, o modelo com CNNs demonstrou a maior precisão, atingindo uma média de 83,7%, o que representa uma superioridade de 43,97% em relação ao VGG16, 53,06% ao ConvNeXt e 292,01% à ResNet50 (Tabela 5). Já com imagens de 15 semanas, o desempenho do CNN foi ainda mais expressivo, com uma média de 95,5%, apresentando uma superioridade de 47,44% sobre o VGG16, 50,16% sobre o ConvNeXt e 137,21% sobre a ResNet50 (Tabela 5).

Tabela 5. Desempenho dos modelos de classificação da categoria do peso corporal de frangas de postura com 7 e 15 semanas de idade para as métricas de precisão, recall, escore f1 e folds

7 semanas de idade				
Algoritmo		Precisão	Recall	Escore F1
CNN ¹	Fold 1	0,769	0,725	0,723
	Fold 2	0,904	0,893	0,893
ResNet50 ²	Fold 1	0,131	0,361	0,192
	Fold 2	0,296	0,428	0,335
VGG16 ³	Fold 1	0,533	0,538	0,526
	Fold 2	0,629	0,632	0,628
ConvNeXt ⁴	Fold 1	0,516	0,520	0,513
	Fold 2	0,577	0,579	0,577
15 semanas de idade				
Algoritmo		Precisão	Recall	Escore F1
CNN ¹	Fold 1	0,918	0,916	0,916
	Fold 2	0,992	0,992	0,992
ResNet50 ²	Fold 1	0,432	0,391	0,234
	Fold 2	0,374	0,456	0,366
VGG16 ³	Fold 1	0,609	0,601	0,591
	Fold 2	0,687	0,685	0,682
ConvNeXt ⁴	Fold 1	0,589	0,592	0,575
	Fold 2	0,683	0,680	0,675

¹Convolutional Neural Network, ²Visual Geometry Group 16-layer network, ³Residual Network with 50 layers, ⁴Convolutional Neural Network Next.

Por outro lado, a especificidade, métrica intimamente associada à precisão, mas ao contrário dela, avalia a proporção de previsões negativas corretas (Mariano, 2021), com imagens das aves às 7 semanas de idade (Figura 9), as CNNs e o VGG16 obtiveram valores de especificidade, com 73% em ambas, seguido pelo ConvNeXt com 66,3%, enquanto o ResNet50 apresentou valor de 92%. Ao utilizar como dados de entrada as capturas dos animais com 15 semanas, as CNNs também apresentaram resultados para um modelo de classificação

satisfatório (Figura 10), com o maior valor (96,4%) em relação ao VGG16 (64,8%), ConvNeXt (64,2%) e ResNet50 (17,5%) (Figura 10).

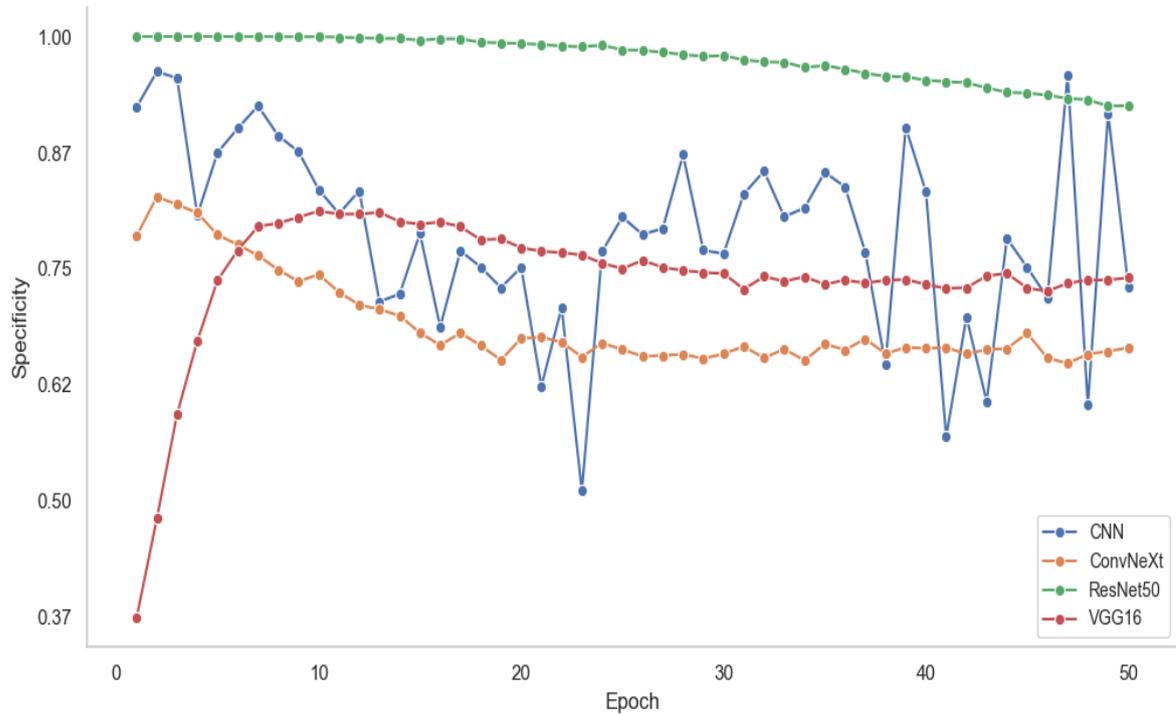


Figura 9. Especificidade das arquiteturas CNN, ConvNeXt, ResNet50 e VGG16 ao longo das épocas utilizando imagens de frangas de postura com 7 semanas de idade.

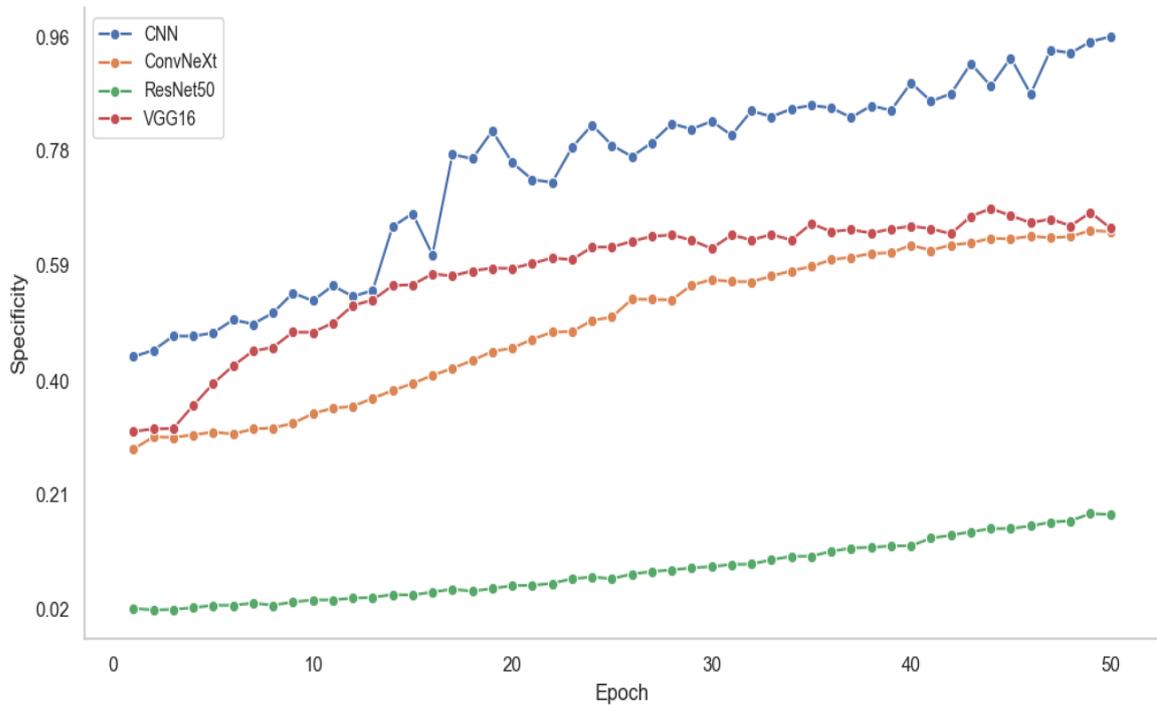


Figura 10. Especificidade das arquiteturas CNN, ConvNeXt, ResNet50 e VGG16 ao longo das épocas utilizando imagens de frangas de postura com 15 semanas de idade.

Esses resultados evidenciam que a maior parte das previsões positivas (precisão) e previsões negativas (especificidade), realizadas pelas CNNs, independentemente da idade da ave, correspondem corretamente às classes designadas, identificando de forma precisa as categorias de frangas leves, médias e pesadas, destacando-se especialmente com aves mais velhas (15 semanas) com um aumento significativo na precisão em relação aos outros modelos. Em contraste, o ResNet50 apresentou o pior desempenho com imagens de poedeiras com 15 semanas, demonstrando dificuldades em distinguir corretamente, gerando valores elevados de falsos positivos, indicando que esse modelo não capturou adequadamente as características corporais específicas das imagens para diferenciar as categorias (Mishra et al., 2023).

Por outro lado, o valor elevado de especificidade desse modelo, o ResNet50, com as imagens de 7 semanas, pode ser atribuído à possível presença de desbalanceamento de classes, em que a maioria é negativa e ela tende a apresentar alta taxa de acertos nessa classe. Contudo, ao falhar em identificar os casos positivos, apresenta baixo valor de recall (Tabela 5) e a acurácia é comprometida (Gan et al., 2022). Dessa forma, as diferenças entre aves mais velhas e mais jovens evidenciam como a variabilidade visual e a distribuição das classes podem impactar de forma distinta os indicadores de desempenho do modelo.

A visualização da matriz de confusão do modelo CNN para a classificação de aves em categorias (leves, médias e pesadas), comprova os resultados obtidos na métrica de score F1 para ambas as idades das frangas de postura, evidenciando desempenho superior do modelo em comparação aos demais, especialmente na distinção entre as classes, com menores valores para erros de confusão entre elas. Os modelos apresentam alta precisão geral, especialmente ao utilizar as capturas das aves às 15 semanas de idade, com os valores diagonais representando as classificações corretas.

Em relação a animais com 7 semanas, para aves leves, houve 4.017 classificações corretas e 394 erros (60 confundidas como médias e 333 como pesadas). Para aves médias, 3.070 foram corretamente classificadas, com 188 erros como leves e 586 como pesadas. Para aves pesadas, o modelo classificou corretamente 3.629 casos, com 115 erros no total (61 para leves e 54 para médias) (Figura 11).

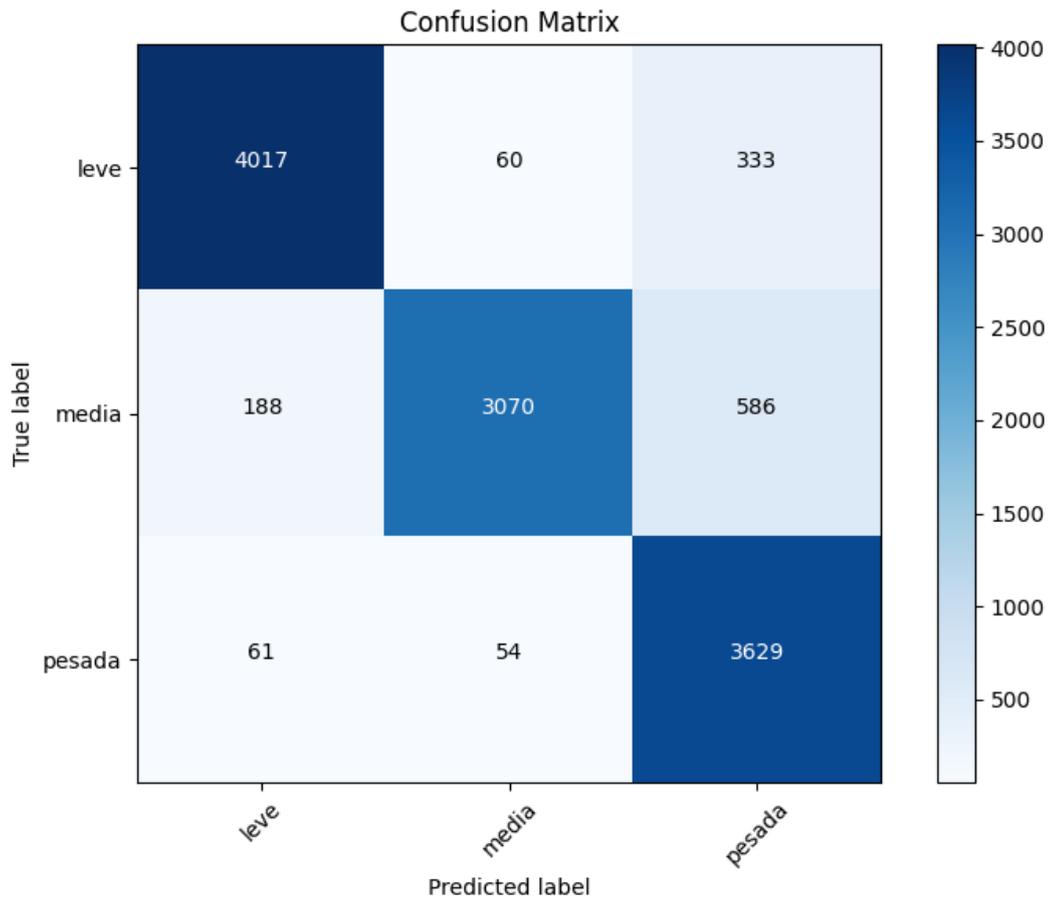


Figura 11. Matriz de confusão para a classificação de imagens de frangas de postura com 7 semanas de idade do modelo com CNNs.

Já em relação as frangas com 15 semanas de idade, para aves leves, houve 3.341 classificações corretas e 47 erros (43 confundidas como médias e 4 como pesadas). Para aves médias, 3.625 foram corretamente classificadas, com somente 12 erros como leves e 1 como pesada. Para aves pesadas, o modelo classificou corretamente 2.544 casos, com apenas 18 erros no total (8 para leves e 10 para médias) (Figura 12). O maior número de previsões corretas na classificação de aves pesadas em ambas as idades avaliadas pode ser atribuído, em grande parte, à presença de características visuais mais distintivas. A conformação corporal mais robusta das aves pesadas, traduzida em um maior número de pixels nas imagens, facilita a extração de padrões relevantes para a classificação. Por outro lado, as classes de aves leves e médias, com diferenças visuais mais sutis, podem ter gerado maior dificuldade na distinção, uma vez que a extração de características discriminativas se torna mais desafiadora.

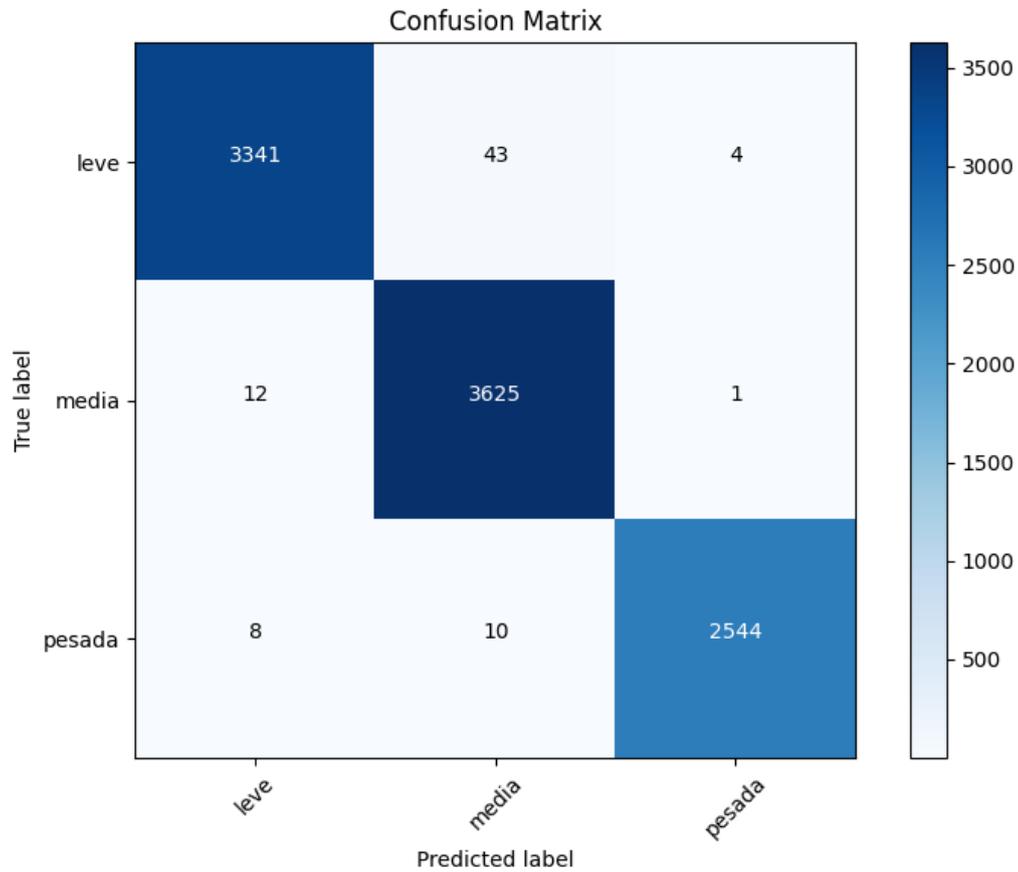


Figura 12. Matriz de confusão para a classificação de imagens de frangas de postura com 15 semanas de idade do modelo com CNNs.

Visando evitar problemas de desbalanceamento entre as previsões positivas e negativas, a métrica ROC AUC ajudar a visualizar tendências em casos em que as classes não estão igualmente distribuídas. Assim, valores próximos de 1 indicam que o modelo possui um desempenho superior, conseguindo separar efetivamente as classes positivas e negativas. Por outro lado, valores abaixo de 0,5 sugerem que o modelo tem um poder preditivo próximo do aleatório, possivelmente invertendo as classes (Kim et al., 2018). Diante disso, os algoritmos propostos não apresentaram valores inferiores a 0,5, demonstrando que possuem poder discriminativo entre as classes. No entanto, com resultados elevados, o modelo CNN atingiu valores de 0,86 e 0,96, para 7 e 15 semanas de idade, respectivamente (Tabela 6), evidenciando sua maior capacidade de distinguir características inerentes às aves.

Çelik e Tekin (2024) separaram uma base de dados de ovos em 3 classes: pequenos, médios e grandes, utilizando de um sistema de câmera RGB montado sobre bandejas. Também aplicaram um algoritmo de classificação de classes, o SVM (*Support Vector Machine*), além de

técnicas de processamento similares às usadas nesse estudo, como remoção de ruído e erosão. Os autores encontraram valor médio de 0,98 entre as classes para ROC AUC.

Tabela 6. Desempenho dos modelos de classificação da categoria do peso corporal de frangas de postura com 7 e 15 semanas de idade para as métricas de escore de Kappa, coeficiente de correlação de Matthews, ROC AUC e folds

7 semanas de idade				
Algoritmo		Escore de Kappa	MCC*	ROC AUC
CNN ¹	Fold 1	0,591	0,608	0,799
	Fold 2	0,840	0,844	0,920
ResNet50 ²	Fold 1	0,01	0,01	0,50
	Fold 2	0,113	0,143	0,554
VGG16 ³	Fold 1	0,301	0,306	0,648
	Fold 2	0,445	0,447	0,720
ConvNeXt ⁴	Fold 1	0,274	0,276	0,635
	Fold 2	0,336	0,366	0,681
15 semanas de idade				
Algoritmo		Escore de Kappa	MCC*	ROC AUC
CNN ¹	Fold 1	0,872	0,873	0,936
	Fold 2	0,988	0,988	0,994
ResNet50 ²	Fold 1	0,018	0,079	0,508
	Fold 2	0,130	0,183	0,559
VGG16 ³	Fold 1	0,383	0,391	0,686
	Fold 2	0,517	0,520	0,755
ConvNeXt ⁴	Fold 1	0,368	0,377	0,676
	Fold 2	0,510	0,514	0,749

*Coeficiente de correlação de Matthews, ¹Convolutional Neural Network, ²Visual Geometry Group 16-layer network, ³Residual Network with 50 layers, ⁴Convolutional Neural Network Next.

O desempenho satisfatório de determinadas métricas de avaliação, especialmente para o CNN, se deve também às características 3D presentes nas imagens de profundidade. Através dela, foi possível obter informações sobre a estrutura e o contorno das aves, permitindo que o modelo capturasse nuances que não são visíveis em imagens 2D, como a distância do pixel do fundo ao animal. Isso é crucial, pois as características tridimensionais ajudam a identificar a forma e a postura das aves, aspectos que são essenciais para estimar o peso das aves.

Além disso, o número de pixels em uma imagem digital está diretamente correlacionado com o tamanho e o volume dos objetos, como os animais, variando de acordo com as mudanças em suas dimensões (Souza et al., 2013). Dessa forma, à medida que o tamanho e o peso corporal das poedeiras aumentam durante o período de desenvolvimento fisiológico, ocorre uma relação significativa com o aumento das dimensões corporais das aves (Khojastehkey et al., 2021).

Mortensen et al. (2016), previram o peso de frangos de corte Ross 308 através de capturas realizadas com a câmera de profundidade (Kinect®) e da extração de características corporais relevantes, utilizando quatro tipos de redes neurais artificiais de regressão, obtendo um erro relativo médio de 7,8% entre os pesos reais e previstos. Sutapun e Sampanporn (2023) utilizaram aprendizado profundo para realizar regressão com imagens de profundidade de frangos de corte, através de modelos pré-treinados avaliados também no presente estudo, como o ResNet50 e ResNet101, revelando menores desempenhos quando comparado com outro algoritmo, o Xception, uma evolução das redes neurais convolucionais, porém com arquiteturas mais simples do que os ResNet.

Apesar de serem arquiteturas de redes neurais baseadas em CNNs, os modelos com menores desempenhos (VGG16, ResNet50 e ConvNeXt) não conseguiram se ajustar de forma satisfatória à base de dados. Isso se deve, principalmente, à sua complexidade estrutural e ao maior número de camadas convolucionais, o que pode causar problemas de sobreajuste. Nessa situação, o modelo ajusta-se aos dados de treinamento, mas apresenta desempenho inferior quando exposto a novos dados, resultando em previsões imprecisas (Goodfellow et al., 2016). Dessa forma, uma CNN personalizada especificamente desenhada, com hiperparâmetros ajustados às necessidades do modelo, consegue capturar padrões relevantes nas imagens de profundidade, como a conformação corporal, formato de bico, tamanho de canela e cabeça, conseguindo classificar se as aves estão leves, pesadas ou com peso corporal adequado.

Segundo Shalini e Ravkiran (2024), mesmo utilizando uma base de dados menor, com 1010 imagens de diferentes raças avícolas para classificação, após a realização da técnica de procura aleatória (*random search*) com a arquitetura do VGG16, obtiveram acurácia 16% superior à CNN tradicional, demonstrando a importância da otimização dos hiperparâmetros para cada caso individual. Sendo assim, arquiteturas como o ResNet50, o ConvNeXt e o VGG16, são pré-treinadas por com grande número de imagens rotuladas, como o ImageNet, com mais de 1000 classes (Russakovsky et al., 2015). Isso significa que o processo de treinamento já começa com pesos existentes e ajustados, com filtros otimizados para características gerais baseados em dados genéricos, distintas do conjunto de dados aqui utilizados (imagens de aves com diferentes idades e pesos corporais) podendo não ser viável para determinadas classificações (Sa et al., 2016).

Uma alternativa para superar essa restrição em trabalhos futuros seria realizar um processo de ajuste fino, como o conceito de transferência de aprendizado (Raschka e Kaufman et al., 2020). Apesar dessas arquiteturas não apresentarem resultados satisfatórios no presente estudo, Nasiri et al. (2020), ao utilizarem o VGG16 em um modelo de aprendizado profundo,

aplicando validação cruzada, alcançaram valores de acurácia, precisão, sensibilidade, especificidade e ROC AUC de 96,55%, 95,59%, 94,92%, 97,39% e 96,16%, respectivamente, na classificação de ovos com sangue, com rachaduras e quebrados, através de um método de preparação com pesos pré-treinados em vez de pesos aleatórios, evidenciando a importância da utilização delas em situações diferentes na avicultura.

Além disso, para identificar o padrão corporal das aves, é fundamental diferenciar piso, ave e fundo, de modo que galinhas em repouso sejam distinguidas daquelas em pé. Embora haja uma padronização e um bom contraste entre o fundo e o objeto de interesse, essa distinção torna-se ainda mais evidente ao analisar os resultados obtidos, especialmente as métricas do CNN em diferentes fases de vida. Isso ocorre porque a abordagem baseada em CNN capta com precisão as nuances das posturas e das características físicas das aves, independentemente de variações ambientais ou de iluminação (De Wet et al., 2003). Todavia, as ações físicas das aves provocam mudanças constantes de postura e orientação, influenciando as medidas corporais, principalmente devido à frequente alteração da posição da cabeça. Em galinhas muito ativas, alguns movimentos, como o esticar das asas, por exemplo, podem resultar em imagens de baixa qualidade, comprometendo a eficácia da classificação.

Uma abordagem alternativa seria empregar um modelo baseado nas propriedades físicas do animal, ajustado para incorporar informações bidimensionais e, assim, melhorar o reconhecimento dos objetos (De Wet et al., 2003). Essa abordagem utilizaria o conhecimento prévio sobre a estrutura e as propriedades físicas do animal, passando a considerar medidas, proporções e formas presentes na imagem, o que auxiliaria no reconhecimento e na classificação dos objetos, neste caso, as aves. Dessa forma, mesmo diante de variações na postura, na orientação ou na qualidade das imagens, o modelo poderia combinar dados visuais e geométricos para oferecer uma identificação mais robusta e precisa dos padrões corporais.

5. CONCLUSÃO

O modelo de redes neurais convolucionais (CNNs) demonstrou desempenho superior em comparação com arquiteturas como ConvNeXt, VGG16 e ResNet50 na estimativa da categoria de peso corporal das frangas de postura com 7 e 15 semanas de idade. As CNNs se destacaram especialmente nas aves mais velhas, sendo eficaz na extração de características relevantes, tanto padrões complexos quanto sutis. Além disso, a utilização de imagens de profundidade associadas a esse modelo mostrou-se uma excelente alternativa para a predição precisa da categoria de peso corporal das aves, evidenciando seu potencial em aplicações práticas.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABPA - ASSOCIAÇÃO BRASILEIRA DE PROTEÍNA ANIMAL. Relatório Anual, 2024. Disponível em: <https://abpa-br.org/relatorios/>. Acesso em: 30 jan. 2025.
- AMRAEI, S.; MEHDIZADEH, S. A.; NÄÄS, I. A. Development of a transfer function for weight prediction of live broiler chicken using machine vision. **Engenharia Agrícola**, v. 38, n. 5, p. 776-782, 2018.
- AMRAEI, S.; MEHDIZADEH, S. A.; SALLARY, S. Application of computer vision and support vector regression for weight prediction of live broiler chicken. **Engineering in Agriculture, Environment and Food**, v. 10, n. 4, p. 266-271, 2017.
- ANUPRABHA, K.; KALIAPPAN, V. K.; HIREMATH, G. B. Transformative Technology in Poultry Management: 3D CNNs for Broiler Chicken Weight Prediction. In: **2024 International Conference on Cognitive Robotics and Intelligent Systems (ICC-ROBINS)**. IEEE, 2024. p. 432-436.
- ARLOT, S.; CELISSE, A. A survey of cross-validation procedures for model selection. **Statistics Surveys**, v. 4, p. 40-79, 2010.
- ARSLAN, A. C.; AKAR, M.; ALAGÖZ, F. 3D cow identification in cattle farms. In: **2014 22nd Signal Processing and Communications Applications Conference (SIU)**. IEEE, 2014. p. 1347-1350.
- ARULKUMARAN, Kai et al. Deep reinforcement learning: A brief survey. **IEEE Signal Processing Magazine**, v. 34, n. 6, p. 26-38, 2017.
- ATHERTON, T. J.; KERBYSON, D. J. Size invariant circle detection. **Image and Vision Computing**, v. 17, n. 11, p. 795-803, 1999.
- BAIN, M. M.; NYS, Y.; DUNN, I. C. Increasing persistency in lay and stabilising egg quality in longer laying cycles. What are the challenges?. **British Poultry Science**, v. 57, n. 3, p. 330-338, 2016.
- BAHRY, M. A. et al. Impact of growth trajectory on sexual maturation in layer chickens. **Frontiers in Physiology**, v. 14, p. 1174238, 2023.
- BARBOZA, P. S.; HUME, I. D. Physiology of intermittent feeding: integrating responses of vertebrates to nutritional deficit and excess. **Physiological and Biochemical Zoology**, v. 79, n. 2, p. 250-264, 2006.
- BENGIO, Y.; GOODFELLOW, I.; COURVILLE, A. **Deep learning**. Cambridge, MA, USA: MIT press, 2015.
- BERCKMANS, D. General introduction to precision livestock farming. **Animal Frontiers**, v. 7, n. 1, p. 6-11, 2017.
- BRE, F.; GIMENEZ, J. M.; FACHINOTTI, V. D. Prediction of wind pressure coefficients on building surfaces using artificial neural networks. **Energy and Buildings**, v. 158, p. 1429-1441, 2018.

- BORNELÖV, S. et al. Comparative omics and feeding manipulations in chicken indicate a shift of the endocrine role of visceral fat towards reproduction. **BMC Genomics**, v. 19, p. 1-15, 2018.
- CECILIANI, F. et al. Proteomics research in the adipose tissue. **Proteomics in domestic animals: from farm to systems biology**, p. 233-254, 2018.
- ÇELIK, A.; TEKIN, E. Classification of Hatchery Eggs Using a Machine Learning Algorithm Based on Image Processing Methods: A Comparative Study. **Brazilian Journal of Poultry Science**, v. 26, n. 2, p. eRBCA-2023-1882, 2024.
- CHEN, K. et al. Grading of chicken carcass weight based on machine vision. **Trans. Chin. Soc. Agric. Mach**, v. 48, n. 6, p. 290-295, 2017.
- CHEN, L. et al. Review of image classification algorithms based on convolutional neural networks. **Remote Sensing**, v. 13, n. 22, p. 4712, 2021.
- CHENG, L.; YU, T. A new generation of AI: A review and perspective on machine learning technologies applied to smart energy and electric power systems. **International Journal of Energy Research**, v. 43, n. 6, p. 1928-1973, 2019.
- CONCI, A.; AZEVEDO, E.; LETA, F. R. “**Computação Gráfica: Teoria e Prática (Livro) – Volume 2**”. Ed. Elsevier. Rio de Janeiro, 2008.
- COUPRIE, C. et al. Indoor Semantic Segmentation using depth information. In: **First International Conference on Learning Representations (ICLR 2013)**. 2013. p. 1-8.
- DE WET, L. et al. Computer-assisted image analysis to quantify daily growth rates of broiler chickens. **British Poultry Science**, v. 44, n. 4, p. 524-532, 2003.
- DEKALB. Guia de Manejo – Dekalb White Cage System. Hendrix Genetics, 2021. Disponível em: https://www.dekalb.poultry.com/documents/1160/Dekalb_White_CS_product_guide_cage_L1211-1-BRPT.pdf. Acesso em: 6 fev. 2025.
- DOREA, J. R. R. et al. Computer vision and image analysis in livestock production. In: **O papel da inovação no enfrentamento das incertezas da bovinocultura leiteira contemporânea**. Canoas: Mérida Publishers, 2021. p. 42-54.
- EKINCI, O.; ESENBUGA, N.; DAGDEMIR, V. The effects of body weight and age on performance, egg quality, blood parameters, and economic production of laying hens. **Journal of the Hellenic Veterinary Medical Society**, v. 74, n. 2, p. 5809-5816, 2023.
- EL-SAGHEER, M.; HASSANEIN, H. H. Productive performance of Bovans brown and Hi-sex brown laying hens as affected by body weight at 20 weeks of age. **Egyptian Poult. Sci. J**, v. 26, p. 731-748, 2006
- FACELLI, K. et al. **Inteligência artificial: uma abordagem de aprendizado de máquina**. Rio de Janeiro: LTC, 2021. Disponível em: <https://repositorio.usp.br/directbitstream/ff933d41-4c3d-4b57-80c2b4f1c805b1dc/3128493.pdf>. Acesso em: 3 fev. 2025.

- FANG, C. et al. Study on poultry pose estimation based on multi-parts detection. **Animals**, v. 12, n. 10, p. 1322, 2022.
- FERNANDES, A. F. A. et al. A novel automated system to acquire biometric and morphological measurements and predict body weight of pigs via 3D computer vision. **Journal of animal science**, v. 97, n. 1, p. 496-508, 2019.
- FERNANDES, A. F. A.; DÓREA, J. R. R.; ROSA, G. J. M. Image analysis and computer vision applications in animal sciences: an overview. **Frontiers in Veterinary Science**, v. 7, p. 551269, 2020. Science & Business Media.
- GAN, M.; YÜCEL, Z.; MONDEN, A. Neg/pos-normalized accuracy measures for software defect prediction. **IEEE Access**, v. 10, p. 134580-134591, 2022.
- GONZALES, R. C.; WOODS, R. E. **Processamento de imagens digitais**. Tradução; Roberto Marcondes Cesar Junior, Luciano da Fontoura Costa. São Paulo, Editora: Blucher, 2013. ISBN: 978-85-212-0264-7.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. MIT press, 2016.
- HE, K. et al. Deep residual learning for image recognition. In: **Proceedings of the IEEE conference on computer vision and pattern recognition**. 2016. p. 770-778.
- HOLZMANN, H.; KLAR, B. Robust performance metrics for imbalanced classification problems. **arXiv preprint arXiv:2404.07661**, 2024.
- HY-LINE. Guia de Manejo – Hy-Line W-36. Hy-Line International, 2025. Disponível em: <https://www.hyline.com/filesimages/Hy-Line-Products/Hy-Line-Product-PDFs/W-36/36%20COM%20POR.pdf>. Acesso em: 6 fev. 2025.
- INTEL. Intel RealSense Overview. Intel, 2025. Disponível em: <https://www.intel.com.br/content/www/br/pt/architecture-and-technology/realsense-overview.html>. Acesso em: 30 jan. 2025.
- ISA. Guia de Manejo – ISA White Cage System. Hendrix Genetics, 2025. Disponível em: https://www.isa-poultry.com/documents/1174/ISA_White_CS_product_guide_cage_L1211-1-PTBR-a.pdf. Acesso em: 6 fev. 2025.
- JIANG, H. et al. Tenderness classification of fresh broiler breast fillets using visible and near-infrared hyperspectral imaging. **Meat Science**, v. 139, p. 82-90, 2018.
- JÖNSSON, L.; WALL, H.; TAUSON, R. Production and egg quality in layers fed organic diets with mussel meal. **Animal**, v. 5, n. 3, p. 387-393, 2011.
- KARHUNEN, J.; RAIKO, T.; CHO, K. Unsupervised deep learning: A short review. **Advances in Independent Component Analysis and Learning Machines**, p. 125-142, 2015.
- KESELMAN, L. et al. Intel realsense stereoscopic depth cameras. In: **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops**. 2017. p. 1-10.

- KHAN, A. A.; LAGHARI, A. A.; AWAN, S. A. Machine learning in computer vision: a review. **EAI Endorsed Transactions on Scalable Information Systems**, v. 8, n. 32, p. e4-e4, 2021.
- KHOJASTEKEY, M. et al. Comparing the Accuracy of Artificial Neural Networks in Estimating the Weight of Cobb, Ross, and Arbor Acres Chicks using Video Image Processing Technology. **Poultry Science Journal**, v. 9, n. 1, p. 19-26, 2021.
- KIM, J. H.; SHIN, S. H.; KANG, H. C. A case study on the use of ROC curve and AUC in the evaluation of discriminant model. **J Korean Data Analysis Society**, v. 20, p. 609-19, 2018.
- KUMARI, K.; YADAV, S. Linear regression analysis study. **Journal of the Practice of Cardiovascular Sciences**, v. 4, n. 1, p. 33-36, 2018.
- KWAKKEL, R. P.; ELLING-STAATS, M. L.; VAN KRIMPEN, M. M. How to survive a 'challenging childhood': rearing the laying hen!. In: **Proceedings of the 21st European Symposium on Poultry Nutrition**. Wageningen Academic, 2017. p. 70-82.
- LARA, L.J.C; AMARAL, L. M. M.; TRIGINELLI, M.V. Nutrição e alimentação nas fases de cria e recria. In: **Produção e processamento de ovos de poedeiras comerciais**. Campinas: FACTA, 2019. p.205-220.
- LECUN, Y. et al. Backpropagation applied to handwritten zip code recognition. **Neural Computation**, v. 1, n. 4, p. 541-551, 1989.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436-444, 2015.
- LEESON, S.; SUMMERS, J. D. Effect of immature body weight on laying performance. **Poultry Science**, v. 66, n. 12, p. 1924-1928, 1987.
- LEHR, H. Recent advances in precision livestock farming. **Int. Anim. Heal. J**, v. 2, n. 1, p. 44-49, 2014.
- LIU, Z. et al. A convnet for the 2020s. In: **Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition**. 2022. p. 11976-11986.
- MAHADEVKAR, S. V. et al. A review on machine learning styles in computer vision—techniques and future directions. **IEEE Access**, v. 10, p. 107293-107329, 2022.
- MARIANO, D. Métricas de avaliação em Machine Learning: acurácia, sensibilidade, precisão, especificidade e F-score. In: **BIOINFO-Revista Brasileira de Bioinformática e Biologia Computacional**, 2021.
- MIHAJLOVIC, L. Everything You Ever Wanted To Know About Computer Vision. 2019. Disponível em: <https://towardsdatascience.com/everything-you-ever-wanted-to-know-about-computer-vision-heres-a-look-whyit-s-so-awesome-e8a58dfb641e>. Acesso em: 22 dez. 2024.
- MILISITS, G. et al. Effect of starting body fat content and genotype of laying hens on the changes in their live weight, body fat content, egg production and egg composition during the first egg-laying period. **British Poultry Science**, v. 56, n. 6, p. 666-672, 2015.

- MINTZIORI, G. et al. The effect of excess body fat on female and male reproduction. **Metabolism**, v. 107, p. 154193, 2020.
- MISHRA, N. et al. A comparative study of ResNet50, EfficientNetB7, InceptionV3, VGG16 models in crop and weed classification. In: **2023 4th International Conference on Intelligent Engineering and Management (ICIEM)**. IEEE, 2023. p.1-5.
- MORTENSEN, A. K.; LISOUSKI, P.; AHRENDT, P. Weight prediction of broiler chickens using 3D computer vision. **Computers and Electronics in Agriculture**, v. 123, p. 319-326, 2016.
- MÜLLER, A. C.; GUIDO, S. **Introduction to machine learning with Python: a guide for data scientists**. O'Reilly Media, Inc., 2016.
- MURPHY, K. P. **Machine learning: a probabilistic perspective**. MIT press, 2012.
- NASIRI, A.; OMID, M.; TAHERI-GARAVAND, A. An automatic sorting system for unwashed eggs using deep learning. **Journal of Food Engineering**, v. 283, p. 110036, 2020.
- NASIRI, A.; TAHERI-GARAVAND, A.; ZHANG, Y. Image-based deep learning automated sorting of date fruit. **Postharvest Biology and Technology**, v. 153, p. 133-141, 2019.
- NASTESKI, V. An overview of the supervised machine learning methods. **Horizons**. **b**, v. 4, n. 51-62, p. 56, 2017.
- NOETZOLD, T. L. et al. Effects of metabolizable energy intake and body weight restriction on layer pullets: 2-Body composition and onset of lay. **Poultry Science**, v. 104, n. 1, p. 104640, 2025.
- NYALALA, I. et al. Weight and volume estimation of poultry and products based on computer vision systems: a review. **Poultry Science**, v. 100, n. 5, p. 101072, 2021.
- OKINDA, C. et al. A review on computer vision systems in monitoring of poultry: A welfare perspective. **Artificial Intelligence in Agriculture**, v. 4, p. 184-208, 2020.
- OLIVEIRA, D. A. B. et al. A review of deep learning algorithms for computer vision systems in livestock. **Livestock Science**, v. 253, p. 104700, 2021.
- OSISANWO, F. Y. et al. Supervised machine learning algorithms: classification and comparison. **International Journal of Computer Trends and Technology (IJCTT)**, v. 48, n. 3, p. 128-138, 2017.
- OTSU, N. et al. A threshold selection method from gray-level histograms. **Automatica**, v. 11, n. 285-296, p. 23-27, 1975.
- PARK, B. et al. Assessment of hyperspectral imaging system for poultry safety inspection. In: **Remote Sensing for Agriculture, Ecosystems, and Hydrology IV**. SPIE, 2003. p. 269-279.
- PEDRINI, H.; SCHWARTZ, W. R. **Análise de imagens digitais: princípios, algoritmos e aplicações**. Cengage Learning, 2008.

PÉREZ-BONILLA, A. et al. Effect of crude protein and fat content of diet on productive performance and egg quality traits of brown egg-laying hens with different initial body weight. **Poultry Science**, v. 91, n. 6, p. 1400-1405, 2012.

PHUNG, V. H.; RHEE, E. J. A Deep Learning Approach for Classification of Cloud Image Patches on Small Datasets. **Journal of information and communication convergence engineering**, v. 16, n. 3, p. 173-178, 2018.

RASCHKA, S.; KAUFMAN, B. Machine learning and AI-based approaches for bioactive ligand discovery and GPCR-ligand recognition. **Methods**, v. 180, p. 89-110, 2020.

RODRIGUES, T. A. et al. Impact of body weight at 19 weeks of Embrapa 051 layers on performance, nest utilization, and egg quality throughout the laying cycle. **Ciência Rural**, v. 55, p. e20240115, 2024.

RUSSAKOVSKY, O. et al. Imagenet large scale visual recognition challenge. **International Journal of Computer Vision**, v. 115, p. 211-252, 2015.

SA, I. et al. Deepfruits: A fruit detection system using deep neural networks. **Sensors**, v. 16, n. 8, p. 1222, 2016.

SAMUEL, A. L. Some studies in machine learning using the game of checkers. **IBM Journal of Research and Development**, v. 3, n. 3, p. 210-229, 1959.

SANZ, S. P. et al. Edad de postura y peso del huevo de dos genotipos de gallinas reproductoras camperas bajo dos programas de alimentación durante la recría: Laying age and egg weight of two genotypes of free range hens under two nutrient allocation programs during rearing. **Brazilian Journal of Animal and Environmental Research**, v. 6, n. 3, p. 2508-2516, 2023.

SARKER, I. H. Machine learning: Algorithms, real-world applications and research directions. **SN Computer Science**, v. 2, n. 3, p. 160, 2021.

SHAFIEE, A.; KARIMI, M. On the Relationship between Entropy and Information. **Physics Essays**, v. 20, n. 3, p. 487, 2007.

SHANG, R. et al. SAR targets classification based on deep memory convolution neural networks and transfer parameters. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 11, n. 8, p. 2834-2846, 2018.

SHALINI, I. S.; RAVIKIRAN, H. K. Random search Based Hyperparameter tuned VGG16 Architecture for Poultry Breed Image Classification. In: **2024 International Conference on Intelligent Algorithms for Computational Intelligence Systems (IACIS)**. IEEE, 2024. p. 1-7.

SIMONYAN, K.; ZISSERMAN, A. Very deep convolutional networks for large-scale image recognition. In: **3rd International Conference on Learning Representations (ICLR 2015)**. Computational and Biological Learning Society, 2015.

SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. **Information Processing & Management**, v. 45, n. 4, p. 427-437, 2009.

- SOUZA, C. F. et al. Methodology for determination of body mass gain of broilers in commercial aviaries via digital image analysis. In: **American Society of Agricultural and Biological Engineers**, 2013. p. 1.
- SOUZA, L. H. N.; FERRANDIN, M.; MORATELLI, C. Inferring Broiler Chicken Weight through Machine Learning. In: **Anais do XX Encontro Nacional de Inteligência Artificial e Computacional**. SBC, 2023. p. 374-388.
- SUMMERS, J. D.; LEESON, S. Laying hen performance as influenced by protein intake to sixteen weeks of age and body weight at point of lay. **Poultry Science**, v. 73, n. 4, p. 495-501, 1994.
- SUN, L. et al. Egg freshness on-line estimation using machine vision and dynamic weighing. **Food Analytical Methods**, v. 8, p. 922-928, 2015.
- SUTAPUN, B.; SAMPANPORN, L. Chicken weight estimation using deep learning. In: **Applications of Machine Learning 2023**. SPIE, 2023. p. 263-268.
- SZELISKI, R. **Computer vision: algorithms and applications**. Springer Nature, 2022.
- TYASI, T. L. et al. Classification and regression tree (CRT) analysis to predict body weight of Potchefstroom koekoek laying hens. **Adv. Anim. Vet. Sci**, v. 8, n. 4, p. 354-359, 2020.
- VAN ECK, L. M. et al. Lipid metabolism and body composition in long-term producing hens. **World's Poultry Science Journal**, v. 79, n. 2, p. 243-264, 2023.
- VAN RIJSBERGEN, C. J. **Information Retrieval**. 2. ed. London: Butterworth-Heinemann, 1979.
- VODRAHALLI, K.; BHOWMIK, A. K. 3D computer vision based on machine learning with deep neural networks: A review. **Journal of the Society for Information Display**, v. 25, n. 11, p. 676-694, 2017.
- WANG, L. et al. Establishment of broiler quality estimation model based on depth image and BP neural network. **Transactions of the Chinese Society of Agricultural Engineering**, v. 33, n. 13, p. 199-205, 2017.
- WANG, Y. Research on the computer vision cracked eggs detecting method. **International Journal of Computer Applications in Technology**, v. 50, n. 3-4, p. 215-219, 2014.
- YANG, J. et al. Information extraction from electronic medical records using multitask recurrent neural network with contextual word embedding. **Applied Sciences**, v. 9, n. 18, p. 3658, 2019.
- YU, Z. et al. Progressive semisupervised learning of multiple classifiers. **IEEE Transactions on Cybernetics**, v. 48, n. 2, p. 689-702, 2017.
- ZHAO, Y. et al. Review on image-based animals weight weighing. **Computers and Electronics in Agriculture**, v. 215, p. 108456, 2023.
- ZUIDHOF, M. J. Multiphasic poultry growth models: method and application. **Poultry Science**, v. 99, n. 11, p. 5607-5614, 2020.

GLOSSÁRIO

<i>Batch size</i>	Número de amostras processadas antes de atualizar os pesos do modelo.
<i>Epochs</i>	Passagens completas pelo conjunto de dados de treinamento durante o treinamento.
<i>Learning rate</i>	Controla o quanto ajustar os pesos do modelo por atualização para minimizar a função de perda.
<i>Weight decay</i>	Técnica de regularização que penaliza pesos grandes para evitar overfitting.
<i>Dropout</i>	Desativa aleatoriamente neurônios durante o treinamento para melhorar a generalização.
<i>Kernel size</i>	Dimensões do filtro nas camadas convolucionais para extração de características.
<i>Folds</i>	Divisões do conjunto de dados na validação cruzada para avaliar o desempenho do modelo em diferentes subconjuntos.
<i>Stride</i>	Tamanho do deslocamento do kernel/filtro sobre a entrada em uma convolução.
<i>Padding</i>	Pixels adicionados ao redor da entrada para manter ou controlar as dimensões da saída após a convolução.