



Concórdia, SC / Maio, 2026

OBJETIVOS DE  
DESENVOLVIMENTO  
SUSTENTÁVEL



## O marco da Inteligência Artificial (IA) na pesquisa animal da Embrapa Suínos e Aves



**Empresa Brasileira de Pesquisa Agropecuária  
Embrapa Suínos e Aves  
Ministério da Agricultura e Pecuária**

e-ISSN 2965-8047

## **Documentos 268**

Maio, 2026

**O marco da Inteligência Artificial (IA) na  
pesquisa animal da Embrapa Suínos e Aves**

*Joseane Padilha da Silva  
Jane de Oliveira Peixoto  
Ana Carolina Broch  
Edenilse Gopinger  
Cintia Carla Niva  
Estela Oliveira Nunes  
Everton Luis Krabbe*

**Embrapa Suínos e Aves  
Concórdia, SC  
2026**

**Embrapa Suínos e Aves**  
Rodovia BR 153 - KM 110  
89.715-899, Concórdia, SC  
www.embrapa.br/fale-conosco/sac

Comitê Local de Publicações  
Presidente  
*Jean Carlos Porto Vilas Boas Souza*

Secretário-executivo  
*Tânia Maria Biavatti Celant*

Membros  
*Clarissa Silveira Luiz Vaz*  
*Catia Silene Klein*  
*Gerson Neudi Scheuermann*  
*Jane de Oliveira Peixoto*  
*Joel Antonio Boff*

Membros suplentes  
*Estela de Oliveira Nunes*  
*Fernando Tavernari*

Revisão de texto  
*Monalisa Leal Pereira*

Projeto gráfico  
*Leandro Sousa Fazio*

Diagramação  
*Vivian Fracasso*

Foto da capa  
*Joseane Padilha da Silva*

Publicação digital: PDF

#### **Todos os direitos reservados**

A reprodução não autorizada desta publicação, no todo ou em parte,  
constitui violação dos direitos autorais (Lei nº 9.610).

#### **Dados Internacionais de Catalogação na Publicação (CIP)**

Embrapa Suínos e Aves

---

O marco da Inteligência Artificial (IA) na pesquisa animal da Embrapa Suínos e Aves /  
Joseane Padilha da Silva [et al.] – Concórdia: Embrapa Suínos e Aves, 2026.

PDF (40 p.) : il. color. – (Documentos / Embrapa Suínos e Aves, e-ISSN 2965-8047;  
268)

1. Pesquisa agropecuária. 2. Embrapa Suínos e Aves. 3. Tecnologia. 4. Inovação. 5.  
Inteligência artificial. 6. Sistemas operacionais. 7. Agricultura digital. 8. Sustentabilidade.  
I. Peixoto, Joseane Padilha da. II. Alves, Jane de Oliveira. III. Broch, Ana Carolina.  
IV. Gopinger, Edenilse. V. Niva, Cintia Carla. VI. Nunes, Estela Oliveira. VII. Krabbe,  
Everton Luis. VIII. Título. IX. Série.

---

CDD (21. ed.) 636

*Claudia Antunez Arrieche* (CRB-14/880)

© 2026 Embrapa

## Autores

---

### **Ana Carolina Broch**

Estudante de graduação do Instituto Federal Catarinense, bolsista na Embrapa Suínos e Aves, Concórdia, SC

### **Cintia Carla Niva**

Bióloga, doutora em Molecular Science, pesquisadora da Embrapa Suínos e Aves, Concórdia, SC

### **Edenilse Gopinger**

Zootecnista, doutora em Zootecnia, (pós-doutorado Empresarial CNPq pelo programa PDI) na Embrapa Suínos e Aves, Concórdia, SC

### **Estela Oliveira Nunes**

Farmacêutica, doutora em Engenharia Química, pesquisador da Embrapa Suínos e Aves, Concórdia, SC

### **Everton Luis Krabbe**

Engenheiro Agrônomo, doutor em Zootecnia, pesquisador da Embrapa Suínos e Aves, Concórdia, SC

### **Jane de Oliveira Peixoto**

Zootecnista, doutora em Zootecnia, pesquisadora da Embrapa Suínos e Aves, Concórdia, SC

### **Joseane Padilha da Silva**

Estatística, doutora em Ciências Animais e Lácteas, pesquisadora da Embrapa Suínos e Aves, Concórdia, SC



Os autores agradecem a Alexandre Tessmann, Edson Somensi, Lucas Scherer Cardoso, Márcio Saatkamp e Neide Simon pelo apoio na condução do experimento de ovoscopia automatizada; a Idair Pedro Piccinin, Neudir Vilson Gatsmann, Valdir Hegler, Adilson Shell, Hedo Haupt e Edio Klein pelo apoio no manejo dos animais no experimento de palatabilidade em leitões; e especialmente a Paulo Pinto Júnior pelo suporte técnico essencial em instalação de câmeras, configuração de sistemas de gravação e gerenciamento de dados de vídeo que viabilizaram os experimentos de palatabilidade em leitões e movimento dos frangos.



## Apresentação

---

Este documento marca o início formal da aplicação sistemática de visão computacional e aprendizado de máquina à pesquisa animal na Embrapa Suínos e Aves. As três aplicações apresentadas são: detecção automatizada de fertilidade em ovos, análise de preferência alimentar em leitões e rastreamento de mobilidade em frangos de corte. Com essas aplicações demonstra-se que transformação tecnológica na pecuária brasileira é viável, replicável e pode ser iniciada com investimentos acessíveis.

Cada projeto alcançou objetivos científicos robustos utilizando metodologias transparentes: câmeras comerciais, computadores convencionais e software de código aberto. Esta escolha metodológica foi estratégica, validando que inovação em Inteligência Artificial (IA) pode ser implementada imediatamente por instituições de pesquisa e pelo setor produtivo com recursos disponíveis no mercado brasileiro.

A expertise crítica para aplicar IA já existe nos pesquisadores que conhecem profundamente seus sistemas de produção. A capacidade de identificar variáveis relevantes e formular perguntas científicas claras é mais determinante que acesso a supercomputadores. IA amplifica conhecimento zootécnico, veterinário, nutricional e genético - não o substitui. A máquina aprende o que o especialista ensina. Os métodos documentados aqui são intencionalmente detalhados para facilitar replicação em outras unidades da Embrapa e instituições de pesquisa, empresas de Tecnologia de Informação (TI), estudantes, entre outros.

As aplicações descritas sinalizam oportunidades concretas para o setor produtivo. Rastreabilidade objetiva, certificação de bem-estar e eficiência produtiva documentada são diferenciais competitivos

crecentes em mercados sofisticados. Parcerias estratégicas podem acelerar a transformação de protótipos cientificamente validados em soluções comerciais que agreguem valor à cadeia produtiva.

Este trabalho demonstra a capacidade instalada e a visão estratégica da Embrapa em agricultura digital. Investimento continuado em infraestrutura especializada e formação de equipes ampliará significativamente a escala e velocidade de inovação, fortalecendo a posição competitiva da pecuária nacional em cenário global cada vez mais tecnológico.

Após esta apresentação, o documento contextualiza IA na produção animal e apresenta o CLADIA - Comitê Local de Aplicação e Desenvolvimento de Inteligência Artificial, formalizado em 2025 para coordenar esforços da Unidade. As três seções seguintes detalham metodologias, resultados e lições de cada aplicação. Documentamos sucessos, desafios e decisões metodológicas com transparência essencial para que outros pesquisadores aprendam com nossa experiência e avancem mais rapidamente.

Alinhado aos Objetivos de Desenvolvimento Sustentável da ONU - particularmente ODS 2 (Fome Zero e Agricultura Sustentável), ODS 9 (Indústria, Inovação e Infraestrutura) e ODS 12 (Consumo e Produção Responsáveis) - este trabalho reafirma o compromisso da Embrapa com inovação responsável, rigor científico e impacto real para a sociedade brasileira.

Este documento oferece exemplos concretos de aplicação de IA à pesquisa animal, servindo como ponto de partida para que outros visualizem oportunidades em seus próprios contextos e acelerem a transformação digital da pecuária brasileira.

*Joseane Padilha da Silva*  
Pesquisadora da Embrapa Suínos e Aves



# Sumário

---

<b>Introdução</b>	11
<b>Detecção automatizada de fertilidade em ovos</b>	13
<b>Análise automatizada de palatabilidade em leitões</b>	19
Ranking de preferência	21
Quando os leitões preferem comer?	23
As preferências mudam ao longo do experimento?	23
Animais dominantes impõem suas preferências?	24
O potencial inexplorado: muitas análises possíveis	25
<b>Rastreamento automatizado de mobilidade em frangos</b>	26
Monitoramento contínuo de atividade locomotora (vista superior)	28
Delineamento experimental e coleta de dados	28
Desenvolvimento do sistema de detecção e <i>tracking</i>	28
Métricas comportamentais extraídas	29
Resultados do monitoramento contínuo	30
Análises possíveis com as trajetórias	30
Onde os frangos passam seu tempo?	30
Como os frangos se movem? Tortuosidade das trajetórias	31
Teste de resposta comportamental com provocação controlada (Vista Frontal)	32
Protocolo de provocação padronizado	32
Sistema de detecção para vista frontal	32
<i>Tracking</i> e cálculo de métricas de movimento induzido	33
Resultados do teste de provocação	34
Lições metodológicas e recomendações	35
Perspectivas e aplicações futuras	37
<b>Ferramentas e infraestrutura computacional</b>	37
<b>Considerações finais</b>	37
<b>Referências</b>	39



## Introdução

A produção animal brasileira enfrenta o constante desafio de conciliar eficiência produtiva, sustentabilidade ambiental e bem-estar animal. Neste cenário, a transformação digital emerge como ferramenta estratégica, possibilitando monitoramento preciso, análise objetiva e tomada de decisão baseada em dados. A Inteligência Artificial, especialmente através de visão computacional e aprendizado de máquina<sup>1</sup>, oferece oportunidades sem precedentes para compreender, quantificar e otimizar processos que historicamente dependiam de observação humana subjetiva, métodos invasivos ou que simplesmente permaneciam inexplorados por limitações práticas de escala e tempo.

Inteligência Artificial é termo que abrange múltiplas técnicas computacionais capazes de realizar tarefas que tradicionalmente exigiriam inteligência humana: reconhecer padrões, tomar decisões, aprender com exemplos e adaptar-se a novas situações. Entre as diversas aplicações de IA, a visão computacional - capacidade de extrair informação significativa de imagens e vídeos através de algoritmos de aprendizado profundo<sup>2</sup> - emerge como particularmente relevante para produção animal, onde observação visual sempre foi o principal método de monitoramento e avaliação. Câmeras capturam dados importantes e multidimensionais sobre animais, ambientes e comportamentos de forma não invasiva e escalável, tornando visão computacional a porta de entrada natural para implementação de IA em pesquisa zootécnica.

Reconhecendo este potencial transformador, a Embrapa Suínos e Aves instituiu formalmente, em 18 de fevereiro de 2025, por meio da Ordem de Serviço nº SEI 11755652, o Comitê Local de Aplicação e Desenvolvimento de Inteligência Artificial - CLADIA. Este comitê, composto por oito profissionais da Unidade, foi criado com mandato abrangente que inclui identificação de oportunidades em bases de

dados existentes, prospecção de parcerias público-privadas, estruturação de laboratórios aplicados e fomento interno ao uso de soluções de IA que aumentem o potencial produtivo das equipes de pesquisa. A criação do CLADIA marca compromisso institucional de longo prazo com a modernização da pesquisa agropecuária através de tecnologias emergentes e este documento representa seu primeiro produto oficial.

As aplicações aqui apresentadas foram desenvolvidas durante 2025 e marcam a entrada da Embrapa Suínos e Aves na aplicação sistemática de IA à pesquisa animal. Este desenvolvimento foi possibilitado pela convergência de fatores complementares: a chegada à Unidade de pesquisadora com formação avançada em visão computacional obtida através de colaboração internacional, a disposição institucional de investir em novas competências técnicas, e a decisão estratégica de iniciar com projetos demonstrativos que validassem viabilidade metodológica.

Um princípio norteador permeou os três projetos desde sua concepção: validar soluções baseadas em IA utilizando infraestrutura acessível, ferramentas de código aberto e metodologias cientificamente rigorosas. Os projetos foram desenvolvidos com câmeras comerciais, computadores disponíveis na Unidade ou plataformas gratuitas de processamento em nuvem, demonstrando que é possível iniciar aplicações de IA sem investimentos proibitivos. Simultaneamente, cada aplicação demandou expertise técnica especializada em visão computacional, aprendizado de máquina e programação - competência que se consolida como o componente crítico e insubstituível. A Unidade encontra-se em fase de estruturação gradual de infraestrutura especializada que ampliará dramaticamente as capacidades analíticas e viabilizará aplicações de escala comercial.

A primeira aplicação, focada em detecção e classificação de fertilidade em ovos, demonstra como processos tradicionalmente manuais podem ser automatizados: um setup construído com materiais

<sup>1</sup> **Aprendizado de Máquina (*Machine Learning*):** subcampo da Inteligência Artificial focado em desenvolver algoritmos que aprendem padrões a partir de dados, sem serem explicitamente programados para cada situação.

<sup>2</sup> **Aprendizado Profundo (*Deep Learning*):** tipo de aprendizado de máquina que utiliza redes neurais com múltiplas camadas (profundas) para aprender representações hierárquicas de dados.

simples e smartphone alcançou quase 100% de acurácia em validação final. O mesmo pipeline metodológico pode ser estendido para detectar trincas invisíveis, estimar tamanho e peso para classificação comercial, ou realizar sexagem não invasiva por análise de padrões de vascularização (Zhu et al., 2019) - funcionalidade que revolucionaria a indústria de postura. As aplicações práticas atravessam múltiplas escalas: desde produtores rurais de pequena escala até incubatórios comerciais que processam milhões de ovos anualmente, além de oferecer aos pesquisadores ferramenta objetiva e escalável para quantificar impactos de nutrição, genética ou manejo sobre viabilidade reprodutiva.

A segunda aplicação, de análise de palatabilidade em suínos através de monitoramento automatizado de preferência alimentar, complementa métodos convencionais de pesagem de consumo com informações adicionais sobre dinâmica temporal e comportamento individual. Enquanto pesagem diária revela preferências gerais e consumo total, análise automatizada de vídeo adiciona camadas de informação: padrões circadianos mostrando que 85% da atividade alimentar concentra-se entre 7h às 16h, com pico às 8h coincidindo com reabastecimento; identificação de divergências individuais revelando que 20 a 60% das gaiolas apresentavam animais com escolhas diferentes do grupo; e, principalmente, capacidade de reanalisar os mesmos vídeos para dezenas de perguntas científicas futuras sobre comportamento agonístico, padrões de descanso, detecção precoce de claudicação - multiplicando exponencialmente o retorno científico do investimento experimental sem novos animais ou experimentos.

A terceira aplicação, de avaliação de mobilidade em frangos de corte através de *tracking*<sup>3</sup> automatizado, demonstra abordagens complementares: monitoramento contínuo de padrões naturais de locomoção e testes de resposta comportamental com provocação controlada. Problemas locomotores representam uma das principais preocupações em bem-estar de frangos de corte e têm impacto econômico direto através de condenações no abate e perdas de conversão alimentar. A capacidade de quantificar objetivamente mobilidade em larga escala oferece ferramenta para mensurar o que atualmente depende de avaliação manual: melhoramento genético usa gait scoring visual; certificações de bem-estar usam auditorias pontuais; pesquisa enfrenta limitações de escala ao observar milhares de animais. Automação não cria essas aplicações

- elas já existem - mas as torna mais escaláveis, objetivas e economicamente viáveis.

A seleção destas três aplicações não foi fortuita: elas representam deliberadamente os três pilares produtivos da Embrapa Suínos e Aves - suinocultura, avicultura de corte e produção de ovos. Esta cobertura intencional demonstra que IA não é ferramenta restrita a nichos específicos, mas abordagem metodológica transversal aplicável a virtualmente qualquer questão científica que envolva dados visuais, padrões comportamentais ou processos quantificáveis. O objetivo transcende a solução dos problemas técnicos específicos aqui documentados. Estas aplicações servem como inspiração e referência metodológica para que pesquisadores visualizem oportunidades em seus próprios projetos, tanto na Embrapa Suínos e Aves quanto em outras unidades da instituição trabalhando com diferentes sistemas produtivos.

Os experimentos compartilham características transformadoras: demonstram que barreiras de entrada para IA são menores que se presumia anteriormente; têm aplicabilidade que atravessa múltiplas escalas desde agricultura familiar até operações comerciais; estabelecem metodologias que podem ser expandidas e integradas com outras tecnologias. Os dois experimentos baseados em vigilância por vídeo compartilham adicionalmente característica revolucionária que é a observação contínua de 24 horas por dia, algo fisicamente impossível para pesquisadores humanos. Esta vigilância ininterrupta não apenas aumenta drasticamente o tamanho amostral, mas revela padrões comportamentais sutis e variações temporais que permaneceriam imperceptíveis em protocolos de amostragem pontual.

Este documento apresenta nas próximas três seções os experimentos em detalhe: metodologias desenvolvidas, resultados alcançados, limitações encontradas e lições aprendidas. A documentação inclui não apenas sucessos, mas também desafios técnicos e adaptações necessárias durante o desenvolvimento. Esta transparência metodológica visa servir como referência prática para futuras iniciativas na Unidade, bem como em outras Unidades da Embrapa, e potencialmente para empresas privadas, oferecendo caminhos já validados e alertando sobre desafios no estabelecimento de pipelines de pesquisa baseados em IA. A seção final discute perspectivas de expansão, integração com outras tecnologias e próximos passos para consolidar a Embrapa Suínos e Aves como referência em aplicação de IA à produção animal no Brasil

<sup>3</sup> **Tracking:** processo de acompanhar objetos ao longo de *frames* consecutivos em vídeos, mantendo identidades consistentes.

## Detecção automatizada de fertilidade em ovos


O Brasil é um dos maiores produtores e consumidores de ovos do mundo, com produção anual de 57,6 bilhões de unidades e consumo per capita de 269 ovos por ano (Associação Brasileira de Proteína Animal, 2024). Enquanto a maior parte destina-se ao consumo humano direto, como ovos de mesa, uma parcela significativa é direcionada a incubatórios para produção de pintos de corte e de postura. A distinção entre ovos férteis e inférteis é crítica para ambos os segmentos, mas por razões opostas. Para o mercado de consumo, ovos inférteis são preferíveis, pois apresentam maior tempo de prateleira, menor risco microbiológico e ausência de desenvolvimento embrionário durante armazenamento. Para incubatórios comerciais, a presença de ovos inférteis representa desperdício direto de recursos, uma vez que cada ovo infértil que entra na incubadora ocupa espaço que poderia ser usado por um ovo viável, consome energia elétrica para manutenção de temperatura e umidade durante 21 dias e demanda mão de obra para manejo, sem gerar qualquer retorno produtivo. Com taxas de infertilidade que podem variar entre 5 e 15% dependendo da idade e manejo das matrizes (Wilson, 1991; Tona et al., 2003), a identificação precoce destes ovos antes da incubação tem impacto econômico substancial. Adicionalmente, pequenos produtores rurais, criadores de raças específicas e projetos de agricultura familiar frequentemente necessitam de ovos férteis para estabelecer ou expandir seus plantéis, constituindo um nicho de mercado específico onde a identificação de ovos férteis agrega valor comercial direto, diferenciando-os de ovos de consumo, que são inférteis.

A determinação precoce da fertilidade de ovos é tradicionalmente realizada por meio da "ovoscopia", um método que consiste em observar o ovo contra uma fonte de luz para identificar o desenvolvimento embrionário. Embora eficaz quando realizada por operadores experientes, a ovoscopia convencional apresenta limitações importantes relacionadas à subjetividade da interpretação visual, que depende da experiência do avaliador e gera variabilidade entre diferentes operadores. Além disso, a avaliação de grandes volumes de ovos é fisicamente cansativa, o que reduz a acurácia ao longo do tempo, e formar operadores qualificados demanda tempo e prática supervisionada. Além disso, o método tradicional não gera registro permanente das avaliações,

uma vez que o ovo é classificado visualmente e separado fisicamente. Assim, não há imagem ou documentação que permita auditar a decisão ou realizar análises retrospectivas dos resultados. A aplicação de Inteligência Artificial para automação da ovoscopia oferece uma solução que combina praticidade, precisão e escalabilidade. Quando implementada com infraestrutura simples, como uma fonte de luz padronizada e um smartphone, a tecnologia torna-se acessível até mesmo para pequenos produtores ou instalações de pesquisa com recursos limitados.

Diante deste potencial e da necessidade de estabelecer competências internas em IA aplicada à produção animal, o ovo foi selecionado como modelo experimental inicial por reunir características ideais para validação metodológica: infraestrutura simples e controlável, custos operacionais reduzidos, aplicabilidade prática imediata em um mercado relevante e possibilidade de verificação definitiva do *ground truth* através da abertura dos ovos ao final do período experimental. Adicionalmente, o desenvolvimento de um sistema automatizado de ovoscopia serviria múltiplos propósitos estratégicos: demonstrar viabilidade técnica de soluções de IA com recursos limitados, estabelecer pipeline completo desde coleta de dados até aplicação prática, e gerar uma ferramenta potencialmente transferível tanto para pesquisa quanto para o setor produtivo. Este foi, portanto, o primeiro projeto de IA desenvolvido na Embrapa Suínos e Aves.

O experimento foi aprovado pela Comissão de Ética no Uso de Animais (CEUA), sob protocolo CON-CEA/MCTI/0300202025/PESQUISA/000000/2026, e conduzido no laboratório da Embrapa Suínos e Aves com 105 ovos de galinhas poedeiras de casca marrom, incluindo ovos fertilizados e não fertilizados. Os ovos foram mantidos em incubadora com temperatura controlada de 37,5°C e umidade relativa de aproximadamente 60%, seguindo protocolo padrão de incubação para a espécie. A captura de imagens foi realizada do 10º ao 20º dia de incubação. No 20º dia, os ovos foram abertos para verificação visual do status de desenvolvimento embrionário (Figura 1), procedimento necessário para categorizar com precisão ovos que apresentavam fertilização mas pararam desenvolvimento precocemente - distinção impossível de determinar apenas pela eclosão. Três categorias foram identificadas: ovos inférteis, caracterizados pela ausência completa de desenvolvimento embrionário; ovos férteis sem desenvolvimento, onde a fertilização ocorreu mas o embrião parou de se desenvolver precocemente; e ovos férteis viáveis, com desenvolvimento embrionário progredindo normalmente.



Fotos: Joseane Padilha da Silva


**Figura 1.** Verificação final (dia 20) mostrando exemplos das três categorias.

O protocolo de coleta de dados envolveu a captura de fotografias diariamente durante dez dias consecutivos, do 10º ao 20º dia de incubação. Durante o período experimental, quatro ovos quebraram, resultando em 101 ovos acompanhados fotograficamente ao longo dos dez dias. Utilizando uma única bandeja física com capacidade de 15 ovos, os ovos eram fotografados em lotes sequenciais: a bandeja era preenchida com até 15 ovos, fotografada, esvaziada e novamente preenchida com o próximo lote, repetindo o processo até que todos os ovos fossem registrados. Este procedimento resultava em sete fotografias por dia, totalizando 70 fotografias de bandejas ao longo do período experimental (7 fotos/dia × 10 dias). O conjunto de dados (*dataset*) resultante compreende 1.010 registros fotográficos dos 101 ovos que completaram os dez dias (101 ovos × 10 dias), além de registros parciais dos quatro ovos que quebraram durante o experimento.

Para permitir o rastreamento individual de cada ovo ao longo dos dez dias de acompanhamento, foi realizada marcação numérica sequencial (ovos 01 a 105) com lápis na região mais estreita da base do ovo. Esta localização foi estrategicamente escolhida por não interferir na área de interesse para captura de imagens - a região central e superior do ovo, onde o desenvolvimento embrionário é mais visível durante a ovoscopia - garantindo que a marcação não prejudicasse a

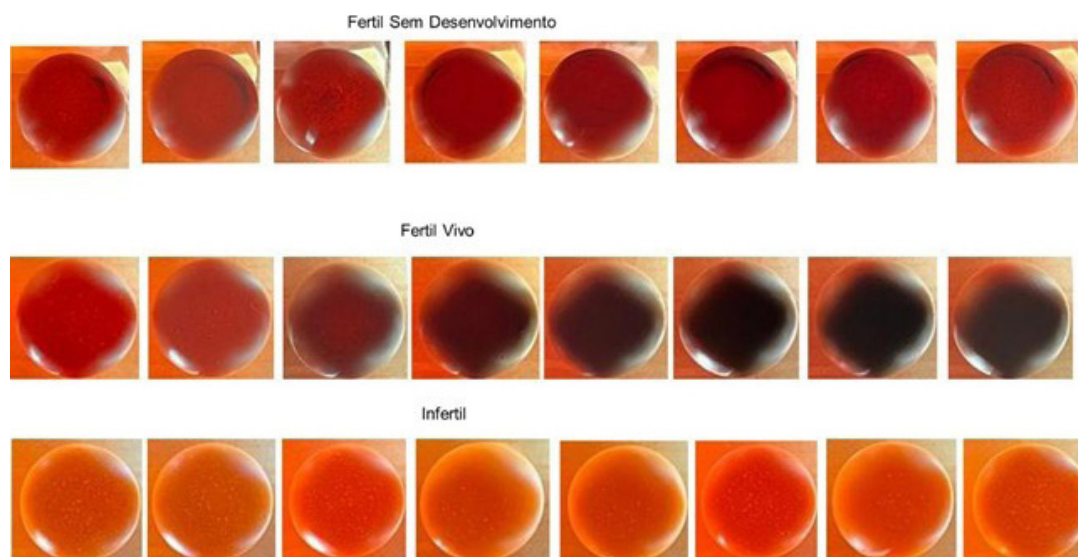
qualidade ou interpretação das fotografias. O setup de fotografia (Figura 2) desenvolvido consistiu em uma caixa de isopor revestida com papel alumínio servindo como câmara de iluminação, com uma lâmpada LED branca de 150 watts e temperatura de cor de 6000K (luz branca fria, equivalente à luz do dia) posicionada na base. As bandejas eram posicionadas diretamente sobre a fonte de luz, permitindo que a iluminação atravessasse os ovos de baixo para cima, projetando a silhueta do conteúdo interno. Um smartphone, montado em tripé a uma altura fixa de aproximadamente 50 cm acima das bandejas, capturava as imagens em posição perpendicular. Este design assegurou iluminação consistente entre diferentes capturas, posicionamento reproduzível das bandejas, minimização de sombras ou reflexos e um custo de construção extremamente baixo utilizando materiais facilmente disponíveis.

As análises das imagens capturadas revelaram padrões visuais distintos que permitiram a diferenciação entre as categorias (Figura 3). Ovos inférteis



Fotos: Joseane Padilha da Silva

**Figura 2.** Setup mostrando caixa, iluminação, tripé e smartphone.



Fotos: Joseane Padilha da Silva

**Figura 3.** Sequências de oito dias consecutivos mostrando a evolução visual de um ovo de cada categoria.

mantiveram uma aparência translúcida alaranjada ao longo de todos os dias, sem escurecimento significativo. Ovos férteis sem desenvolvimento apresentaram inicialmente sinais muito sutis de desenvolvimento que logo estacionaram, mantendo aparência similar aos inférteis nos dias subsequentes. Já os ovos férteis vivos exibiram escurecimento progressivo e nítido conforme o embrião crescia, tornando-se progressivamente opacos até as fases finais de desenvolvimento. Estas diferenças visuais observadas ao longo da série temporal de dez dias formaram a base para o desenvolvimento do sistema automatizado de detecção e classificação.

O sistema desenvolvido combina duas tecnologias complementares de Inteligência Artificial que trabalham em sequência: um detector de objetos que identifica e localiza cada ovo na bandeja, seguido de um classificador que determina o status de fertilidade de cada ovo individualizado. Esta arquitetura modular permite processar bandejas completas automaticamente, sem necessidade de fotografar ovos isoladamente. Para o desenvolvimento do detector, utilizou-se o algoritmo YOLO (*You Only Look Once*)<sup>4</sup>(Redmon et al., 2016), uma das arquiteturas mais eficientes para detecção de objetos<sup>5</sup> em tempo real. Das 70 fotografias de bandejas disponíveis, foram selecionadas 34 imagens de forma aleatória

para anotação no CVAT (Computer Vision Annotation Tool)<sup>6</sup> (Sekachev et al., 2020), uma plataforma especializada para preparação de dados de visão computacional disponível em código aberto. O processo de anotação (Figura 4) consistiu em desenhar caixas delimitadoras (*bounding boxes*)<sup>7</sup> ao redor de cada ovo visível nas imagens, totalizando aproximadamente 510 ovos marcados manualmente. Este trabalho de anotação, embora trabalhoso, é etapa essencial para treinar o modelo a reconhecer o que constitui um "ovo" nas imagens de bandejas.

O treinamento do YOLO foi realizado por 47 épocas<sup>8</sup>, utilizando a plataforma Google Colab com acesso gratuito a *Graphics Processing Unit* (GPUs)<sup>9</sup>, sendo interrompido automaticamente no momento em que o modelo parou de melhorar seu desempenho através de técnica conhecida como *early stopping* (o melhor modelo foi salvo na época 27). O modelo final alcançou performance excepcional na tarefa de detecção: precisão de 99,9%, recall

<sup>4</sup> **YOLO (You Only Look Once):** família de algoritmos de detecção de objetos em tempo real, conhecidos por velocidade e eficiência.


<sup>5</sup> **Detecção de Objetos:** tarefa de identificar e localizar objetos específicos em imagens ou vídeos, geralmente retornando *bounding boxes* e classes.

<sup>6</sup> **CVAT (Computer Vision Annotation Tool):** ferramenta open-source para anotação de imagens e vídeos, amplamente utilizada para preparar *datasets* de treinamento.

<sup>7</sup> **Bounding Box:** caixa delimitadora retangular que envolve um objeto de interesse em uma imagem, definida por coordenadas (x, y, largura, altura).

<sup>8</sup> **Épocas (Epochs):** número de vezes que o algoritmo de treinamento percorre o *dataset* completo durante o aprendizado.

<sup>9</sup> **GPU (Graphics Processing Unit):** unidade de processamento gráfico; *hardware* especializado que acelera significativamente treinamento e inferência de modelos de IA.



**Figura 4.** Anotação de ovos na bandeja utilizando CVAT para treinamento do detector YOLO.

de 100%, e mAP50 (*mean Average Precision*)<sup>10</sup> de 99,5%. Em termos práticos, isto significa que o modelo identifica corretamente praticamente todos os ovos nas bandejas, com mínima taxa de falsos positivos (detectar algo que não é ovo) ou falsos negativos (não detectar um ovo presente). A arquitetura final possui aproximadamente três milhões de parâmetros e é capaz de processar uma imagem em menos de um segundo, viabilizando uso em tempo real.

Para o desenvolvimento do classificador, já na etapa de anotação do YOLO foi realizada seleção intencional e balanceada: das 70 bandejas disponíveis, escolheram-se 34 que continham representantes equilibrados das três categorias de fertilidade identificadas no *ground truth* (abertura no dia 20). As aproximadamente 510 imagens de ovos detectados pelo YOLO nessas bandejas foram processadas para remoção de fundo e isolamento, resultando em *dataset* balanceado: 170 imagens de cada categoria (infértil, fértil vivo e fértil sem desenvolvimento). Este balanceamento intencional entre as classes é importante para evitar que o modelo desenvolva viés em favor da categoria mais numerosa. Uma vez que cada ovo foi fotografado múltiplas vezes ao longo dos dez dias, o *dataset* naturalmente contém exemplos da mesma categoria em diferentes estágios visuais, o que enriquece a capacidade do modelo de generalizar para novos casos. Adicionalmente, foram aplicadas técnicas padrão de aumento de

dados (*data augmentation*)<sup>11</sup> disponíveis nos *frameworks* de *deep learning*: o algoritmo cria automaticamente variações de cada imagem através de rotações, ajustes de brilho e contraste e espelhamentos. Esta prática, comum em aprendizado de máquina, funciona como uma forma de multiplicar artificialmente os exemplos de treino sem precisar coletar novas fotos, tornando o modelo mais robusto a variações naturais de iluminação, ângulo e posicionamento.

A área de Inteligência Artificial oferece múltiplas abordagens para classificação de imagens, cada uma com vantagens e desvantagens em termos de precisão, velocidade, necessidade de dados e custo computacional. Para este experimento, optou-se por uma arquitetura de rede neural siamesa baseada em aprendizado métrico (Koch et al., 2015), particularmente adequada para contextos com quantidade limitada de dados. Ao contrário de classificadores convencionais que exigem milhares de exemplos por categoria, redes siamesas aprendem por comparação entre pares de imagens, reconhecendo relações de similaridade e diferença entre exemplos. Neste tipo de modelo, a rede neural aprende a transformar cada imagem em uma representação numérica de forma que imagens da mesma categoria sejam posicionadas próximas umas das outras em um espaço matemático. Durante o treinamento calcula-se o ponto médio (centroide) das representações de cada categoria. Para classificar um novo ovo, o modelo gera sua representação e calcula qual centroide está mais próximo, atribuindo a categoria correspondente. Esta escolha técnica apresenta vantagens importantes para o contexto da Embrapa: possibilita treinar um modelo eficaz com apenas 170 exemplos de cada categoria, requer menos poder computacional durante o uso do que arquiteturas mais complexas, viabilizando treinamento e uso em equipamentos convencionais, e permite interpretabilidade através das distâncias calculadas facilitando identificação de casos ambíguos.

<sup>10</sup> **mAP (mean Average Precision):** métrica de avaliação de modelos de detecção de objetos que considera tanto precisão quanto recall em diferentes limiares de confiança.

<sup>11</sup> **Aumento de Dados (Data Augmentation):** técnica de criar variações artificiais de imagens de treinamento (rotação, espelhamento, mudanças de brilho) para aumentar robustez do modelo.

A divisão dos dados respeitou a independência entre ovos, com 70% destinados ao treinamento, 15% à validação e 15% ao teste. Aspecto fundamental da metodologia: quando um ovo era selecionado para compor determinado conjunto (treinamento, validação ou teste), todas as suas dez fotografias correspondentes eram incluídas no mesmo conjunto, garantindo que não houvesse vazamento de informação entre as etapas. Esta abordagem permite que o modelo aprenda os padrões visuais característicos de cada categoria sem "ver" antecipadamente ovos que serão usados para validar ou testar sua performance, assegurando avaliação justa de sua capacidade de generalização. O treinamento foi realizado utilizando TensorFlow<sup>12</sup> (Abadi et al., 2015), um *framework* de código aberto amplamente utilizado na comunidade científica, com otimizador Adam. Toda a implementação foi desenvolvida em Python (Van Rossum; Drake, 2009), linguagem de código aberto amplamente utilizada em ciência de dados e aprendizado de máquina. A escolha de ferramentas gratuitas e código aberto foi intencional, garantindo que a metodologia possa ser replicada por outros grupos de pesquisa sem necessidade de licenças comerciais de software.

Para tornar o sistema imediatamente acessível a usuários sem conhecimento técnico em programação, foi desenvolvida uma interface web interativa hospedada no Google Colab. A interface é disponibilizada como notebook público, compartilhável via link direto. O usuário abre o link no navegador, clica em "Executar todas" para inicializar o sistema (processo que leva aproximadamente 30 segundos) e a interface gráfica é apresentada automaticamente. O usuário então carrega uma foto de uma bandeja completa de ovos, o YOLO detecta e numera automaticamente cada ovo em ordem lógica (organizados por linha e coluna, da esquerda para direita, de cima para baixo), cada ovo detectado é recortado e processado individualmente pelo classificador e os resultados são apresentados visualmente com caixas coloridas ao redor de cada ovo indicando sua categoria: verde para fértil vivo; laranja para fértil indeterminado; e vermelho para infértil. A interface mantém contadores em tempo real do total de ovos detectados, distribuição por categoria de fertilidade e calcula automaticamente a taxa de fertilidade do lote. Esta implementação no Google Colab oferece vantagens práticas importantes como acesso via navegador de qualquer dispositivo sem necessidade de instalação de software, disponibilidade de

GPU gratuita para processamento rápido das imagens e facilidade para demonstrações e testes piloto em diferentes contextos (Figura 5).

No conjunto de teste original, o modelo alcançou acurácia de aproximadamente 90%, precisão próxima a 100%, recall de 90% e F1-score de 90% quando utilizado o limiar de decisão otimizado. A precisão de 100% é particularmente relevante, pois indica que quando o modelo classifica um ovo como pertencente a determinada categoria essa predição é altamente confiável, minimizando falsos positivos.

Para validar a capacidade de generalização do modelo em condições rigorosas, foi realizada avaliação final com 90 ovos (30 de cada categoria): 60 ovos que fizeram parte do experimento, mas não participaram do treinamento (conjuntos de validação e teste), e 30 ovos também de casca marrom, completamente novos que não participaram de nenhuma etapa do experimento original. O classificador

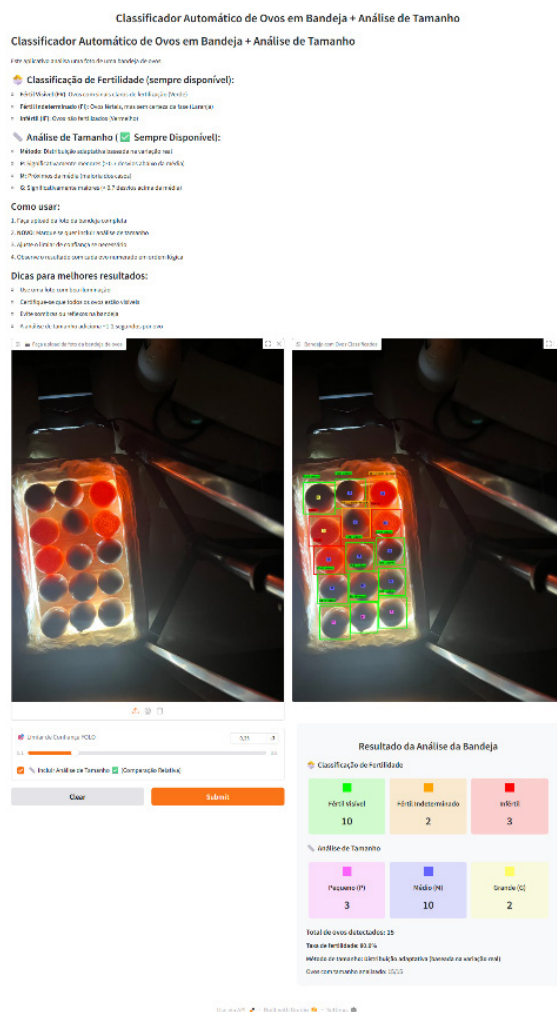


Figura 5. Capturas de telas (screenshots) da interface mostrando bandeja processada com ovos numerados e classificados.

Fotos: Joseane Padilha da Silva

<sup>12</sup> TensorFlow / PyTorch: bibliotecas de software populares para desenvolvimento de modelos de aprendizado profundo.

alcançou acurácia de 100% neste conjunto, classificando corretamente todos os 90 ovos sem nenhum erro. Esta performance perfeita demonstra que o modelo não apenas memorizou os exemplos de treinamento, mas genuinamente aprendeu os padrões visuais característicos de cada categoria, sendo capaz de reconhecê-los tanto em ovos do experimento original quanto em ovos completamente novos de forma robusta e confiável. Este resultado valida a metodologia desenvolvida e reforça o potencial de aplicação prática do sistema.

A detecção automática de ovos pelo YOLO eliminou a necessidade de fotografar ovos isoladamente, permitindo análise de lotes completos em questão de segundos. A integração entre detector e classificador mostrou-se eficiente e robusta, oferecendo não apenas a categoria prevista, mas também as distâncias calculadas aos centroides de cada classe, o que fornece uma medida de confiança da predição. Esta informação de confiança é particularmente útil para identificar casos limítrofes que podem beneficiar-se de inspeção humana adicional.

Adicionalmente, ao classificador de fertilidade, foi desenvolvido um módulo experimental para classificação de tamanho dos ovos (pequeno, médio, grande) baseado em medidas morfométricas extraídas automaticamente das imagens: eixo maior (comprimento), eixo menor (largura) e contorno. O volume aproximado de cada ovo foi estimado utilizando a fórmula matemática de um elipsoide e os ovos foram então categorizados em três faixas de tamanho dividindo o *dataset* em terços. O modelo treinado para esta tarefa alcançou acurácia de 72%, performance consideravelmente inferior à obtida na classificação de fertilidade. Esta diferença se explica pelo fato de que os 105 ovos do experimento apresentavam tamanhos muito homogêneos - com coeficiente de variação de apenas 12,1%, característica comum em lotes experimentais de aves da mesma idade e linhagem - fazendo com que a distinção entre as categorias pequeno, médio e grande fosse sutilmente pequena para permitir aprendizado robusto pelo modelo. Esta limitação é específica do *dataset* utilizado e não da abordagem metodológica: em contextos industriais onde há maior heterogeneidade natural de tamanhos de ovos provenientes de múltiplas origens, matrizes de diferentes idades e linhagens variadas, espera-se que o mesmo método apresente performance satisfatória quando treinado com *dataset* mais representativo dessa variabilidade. Para aplicações futuras envolvendo classificação de tamanho, recomenda-se coleta intencional de ovos com maior amplitude de variação dimensional.

No contexto de pesquisa, a automação da ovoscopia traz benefícios diretos para experimentos conduzidos na Embrapa. A padronização metodológica elimina variabilidade entre avaliadores humanos, permitindo comparações mais confiáveis entre experimentos realizados em momentos diferentes ou por equipes distintas. A documentação automática de todas as imagens, as coordenadas de detecção e as classificações facilitam auditorias e possibilitam reanálises futuras com modelos aprimorados. A numeração automática e ordenação lógica dos ovos nas bandejas simplifica o rastreamento e a correlação com outras medidas experimentais. Estas capacidades abrem possibilidades para estudos de fertilidade em diferentes linhagens, avaliação de efeitos de dieta das matrizes sobre desenvolvimento embrionário, impacto de condições de armazenamento de ovos e otimização de protocolos de incubação.

O potencial de transferência desta tecnologia para o setor produtivo varia conforme o porte e contexto da operação. Para pequenos produtores e granjas de reprodução, a simplicidade da infraestrutura necessária (smartphone e caixa com lâmpada LED) torna a tecnologia tecnicamente viável, embora o benefício prático para operações de pequena escala familiar - onde volumes são reduzidos - possa ser limitado, dado que o esforço de ovoscopia individual de poucas dezenas de ovos nem sempre justifica a economia marginal nos dias restantes de incubação.

Para incubatórios comerciais, a tecnologia apresenta potencial substancial como alternativa ou complemento aos sistemas de ovoscopia já utilizados atualmente. Incubatórios de escala industrial rotineiramente realizam ovoscopia para remoção de ovos inférteis, tipicamente entre o 5º e 7º dia de incubação, utilizando métodos manuais com ovoscópios tradicionais ou sistemas semi-automatizados. Quanto mais precoce a identificação, maior o retorno econômico. Cada dia adicional que um ovo infértil permanece na incubadora representa desperdício de espaço, energia elétrica e mão de obra. Este experimento iniciou a captura de imagens no 10º dia de incubação devido a limitações práticas de infraestrutura durante o desenvolvimento inicial, demonstrando que o modelo atinge acurácia robusta neste ponto. No entanto, o objetivo de longo prazo é substancialmente mais ambicioso: investigar se visão computacional por *deep learning* pode detectar infertilidade em estágios ainda mais precoces que os cinco ou sete dias atualmente praticados na indústria. Se viável tecnicamente, detecção aos três ou quatro dias de incubação - ou potencialmente ainda antes - representaria avanço significativo com

impacto econômico direto, permitindo descarte mais precoce e maximizando eficiência de uso de incubadoras. Trabalhos futuros expandirão a metodologia capturando imagens diariamente desde os primeiros dias de incubação, investigando sistematicamente o ponto temporal ótimo onde diferenças visuais entre ovos férteis e inférteis tornam-se detectáveis por redes neurais com confiabilidade suficiente para aplicação comercial.

A implementação em ambiente industrial envolveria estação de processamento onde ovos são temporariamente retirados da incubadora no dia determinado como ótimo, fotografados individualmente sob iluminação padronizada, classificados automaticamente, com ovos férteis retornando à incubadora e inférteis sendo descartados. Dada a diferença entre condições experimentais e ambientes industriais de alta velocidade, recomenda-se ajuste fino do modelo utilizando entre 50 a 100 ovos do ambiente de produção com *ground truth* conhecido - processo significativamente mais rápido que treinamento completo do zero. Este experimento demonstrou que é possível desenvolver soluções tecnologicamente avançadas sem infraestrutura complexa, princípio que norteou o trabalho e viabilizou esta primeira aplicação de IA na Unidade.


## Análise automatizada de palatabilidade em leitões

Métodos convencionais para avaliar palatabilidade em suínos apresentam limitações críticas que restringem a profundidade das análises possíveis. A pesagem de comedouros, técnica mais utilizada na prática, fornece apenas dados de consumo total ao final de períodos experimentais, sem informações sobre dinâmica temporal, padrões comportamentais ou variações individuais (Lawrence; Appleby, 1996; Forbes, 2007). A observação manual de vídeos, embora permita captura de informações comportamentais mais detalhadas, demanda centenas de horas de trabalho, está sujeita à fadiga do observador e inconsistências na interpretação e inevitavelmente perde eventos em situações de movimento

rápido ou sobreposição de animais (Martin; Bateson, 2007).

Mais importante que as limitações operacionais, os métodos convencionais desperdiçam oportunidades científicas. A pesagem descarta completamente a possibilidade de análise comportamental. A anotação manual limita-se ao objetivo específico do estudo - o mesmo vídeo que levou horas para anotar preferências não pode ser facilmente observado novamente para avaliar interações sociais, brigas, padrões de descanso ou mudanças físicas dos animais. Esta aplicação demonstra como Inteligência Artificial não apenas supera essas limitações, mas multiplica exponencialmente o valor dos dados coletados e mostra como experimentos convencionais podem ser aperfeiçoados com visão computacional.

Vinte câmeras no topo das gaiolas, sob iluminação controlada (Figura 6), capturaram 14 dias de comportamento contínuo. Para este trabalho, o sistema processou automaticamente mais de 500 mil eventos de escolha alimentar, revelando ranking de preferências ( $r=0,92$  com pesagem física), padrões circadianos, dinâmica hierárquica, equilíbrio nas escolhas e estabilidade temporal. Mas o mesmo conjunto de vídeos permanece disponível para análises futuras: detecção de comportamentos agonísticos, avaliação de bem-estar, monitoramento de crescimento, identificação de claudicação, análise de interações sociais - cada nova pergunta científica pode ser respondida sem coletar novos dados, simplesmente retreinando modelos de Inteligência Artificial sobre o material já existente. Um único experimento filmado se transforma em dezenas de estudos potenciais.



Fotos: Joseane Padilha da Silva

**Figura 6.** Configuração do sistema de vídeo para monitoramento contínuo das gaiolas experimentais com leitões.

O experimento gerou um total de 9.921 vídeos distribuídos ao longo dos 14 dias, com gravações programadas a cada 30 minutos durante 24 horas por dia. Este volume de material bruto seria impraticável de processar manualmente, mas serviu como base para treinamento de um modelo de visão computacional capaz de automatizar completamente a análise.

Para treinar o modelo, aproximadamente mil *frames*<sup>13</sup> foram selecionados aleatoriamente do conjunto total de vídeos, garantindo diversidade de horários, condições de iluminação (dia, noite, transições) e comportamentos. O critério de seleção foi específico: apenas *frames* onde o animal tinha a cabeça completamente inserida dentro do comedouro, garantindo que o modelo aprendesse a identificar alimentação ativa, não apenas proximidade no comedouro.

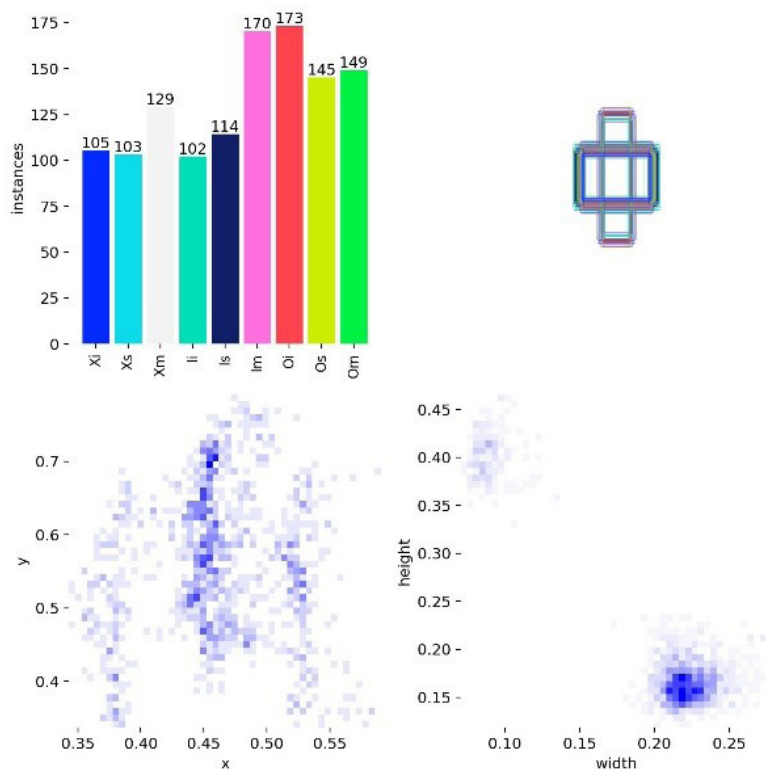
Cada *frame* selecionado foi manualmente anotado utilizando a plataforma CVAT (Computer Vision Annotation Tool) (Sekachev et al., 2020), onde caixas delimitadoras foram desenhadas ao redor de cada animal detectado. O sistema de classes captura simultaneamente identidade do animal (I, O ou X, conforme marcação física) e localização do comedouro (s=superior, m=médio, i=inferior), resultando em nove classes combinadas: Xs, Xm, Xi, Is, Im, Ii, Os, Om, Oi. Por exemplo, "Xs" identifica o animal X alimentando-se no comedouro superior. Esta estratégia permitiu rastrear preferências individuais e espaciais ao mesmo tempo.

A Figura 7 apresenta uma análise do conjunto de anotações do *dataset* de treinamento. O gráfico de barras (superior esquerdo) mostra a distribuição das aproximadamente 1.190 anotações entre as nove classes de identificação dos leitões, com cada classe apresentando entre 102 e 173 instâncias, indicando balanceamento adequado. O ícone à direita ilustra o formato padrão dos *bounding boxes* utilizados nas anotações. Os gráficos de dispersão inferiores revelam, respectivamente, a distribuição espacial das detecções no *frame* (posição normalizada X, Y) — com maior

concentração na região do comedouro — e a distribuição das dimensões dos *bounding boxes* (altura × largura), evidenciando que os leitões apresentam tamanho relativamente uniforme nas imagens capturadas. O *dataset* contemplou imagens em diferentes condições — luz natural diurna, iluminação artificial noturna, múltiplos animais simultâneos e diversos ângulos de aproximação ao comedouro —, diversidade essencial para a generalização do modelo.

Utilizou-se a arquitetura YOLOv8 (*You Only Look Once*, versão 8) (Jocher et al., 2023), referência atual em detecção de objetos em tempo real, conhecida por equilibrar precisão e velocidade de processamento. O *dataset* anotado foi dividido em conjuntos de treinamento (80%), validação (10%) e teste (10%), seguindo boas práticas de aprendizado de máquina. O treinamento foi conduzido por 80 épocas com técnicas de *data augmentation* (rotações, ajustes de brilho, variações de escala) para aumentar a robustez.

O modelo final alcançou desempenho excepcional com precisão de 99% (o modelo raramente identifica algo que não existe) e recall de 100% (o modelo detecta todos os eventos reais sem perder nenhum). A métrica mAP@0.5 (*mean Average Precision*), padrão internacional para avaliar detectores de objetos, atingiu 99,4% (Padilla et al., 2020). Para



<sup>13</sup> **Frame:** uma imagem individual de um vídeo. Vídeos são sequências de *frames* exibidos rapidamente.

**Figura 7.** Distribuição das anotações por classe de identificação dos leitões e análise espacial do *dataset* de treinamento.

contextualizar, os valores acima de 90% já são considerados excelentes; 99% indica desempenho de nível profissional.

A Figura 8 mostra exemplos de previsões do modelo em vídeos nunca vistos durante o treinamento. Observa-se que o modelo identifica corretamente cada animal (cores diferentes das caixas), localiza o comedouro correto e atribui confiança superior a 90% mesmo em situações desafiadoras como baixa iluminação noturna, sobreposições parciais entre animais e reflexos na superfície. Esta robustez garantiu confiabilidade nas análises posteriores.

Uma vez treinado e validado, o modelo foi aplicado aos 9.921 vídeos completos, processando *frame por frame* e gerando detecções automáticas. A saída estruturada em formato de planilha contém identificação da gaiola, data e hora, animal detectado (I/O/X), zona do comedouro (correspondendo aos tratamentos), duração da detecção e confiança do modelo (0-1).

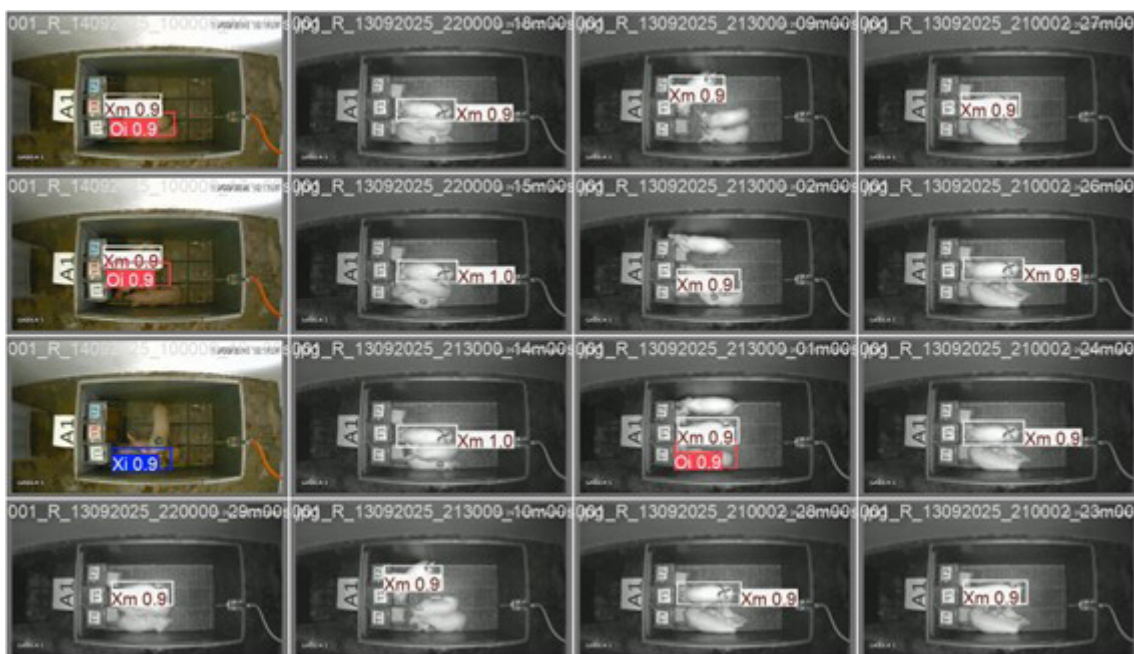
Este processamento gerou a base inicial de 5.398.829 detecções, posteriormente padronizada e filtrada resultando em 513.299 eventos válidos para análise. Todo o pipeline — do vídeo bruto à planilha estruturada pronta para análise estatística — operou de forma totalmente automatizada, eliminando intervenção humana e garantindo consistência, objetividade e replicabilidade impossíveis de alcançar por observação manual. O que demandaria milhares de horas de trabalho humano foi concluído

em algumas horas de processamento computacional. Abaixo apresentamos alguns dos resultados explorados.

## Ranking de preferência

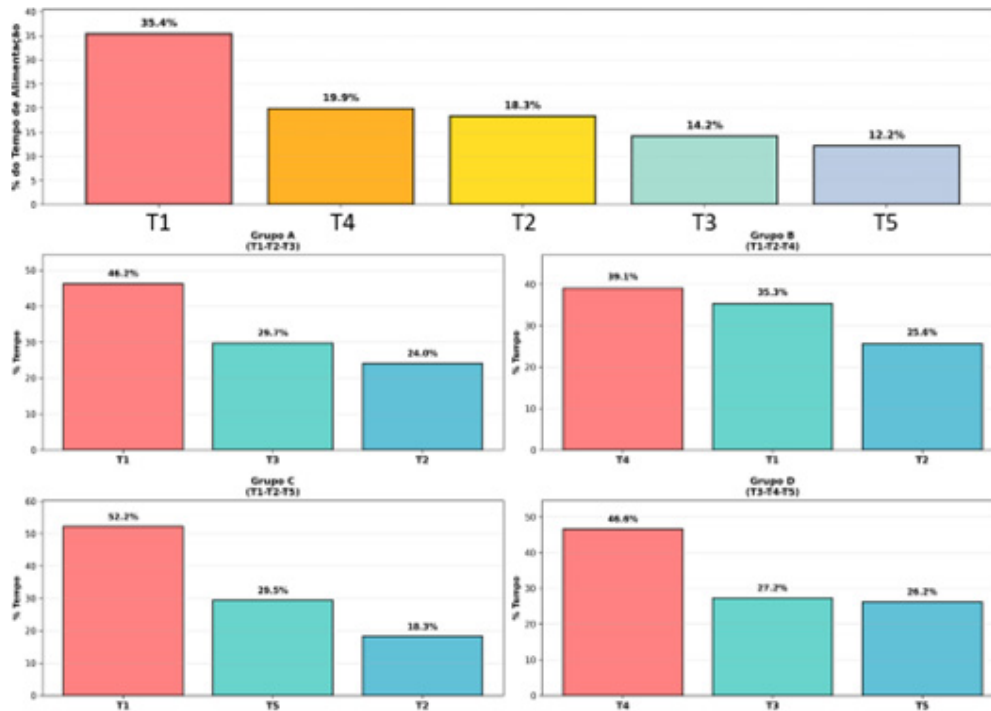
A análise automatizada revelou clara hierarquia de preferências entre as cinco dietas avaliadas (Figura 9). O ranking geral de escolha foi T1 (35,4%) > T4 (19,9%) > T2 (18,3%) > T3 (14,2%) > T5 (12,2%). A dieta T1 foi a preferida pelos leitões, seguido por T4. A análise por grupos experimentais confirmou a dominância de T1 nos grupos onde estava presente (Grupos A, B e C), com preferências variando entre 35,3% e 52,2%. Nos grupos sem T1, a dieta T4 emergiu como preferida: no Grupo B, T4 (39,1%) competiu fortemente com T1 (35,3%), enquanto no Grupo D, T4 (46,6%) foi claramente dominante sobre T3 (27,2%) e T5 (26,2%). As dietas T3 e T5 apresentaram consistentemente as menores preferências em seus respectivos grupos.

Para validar o método automatizado, os resultados de preferência detectados pela IA foram comparados com o consumo real medido por pesagem ao final do experimento (Figura 10). A correlação entre detecções automáticas e consumo físico foi alta ( $r=0,917$ ) e o ranking predito pela IA (T1 > T4 > T2 > T3 > T5) correspondeu ao ranking obtido por pesagem física - resultado que apoia a validade do método para discriminar preferências entre tratamentos

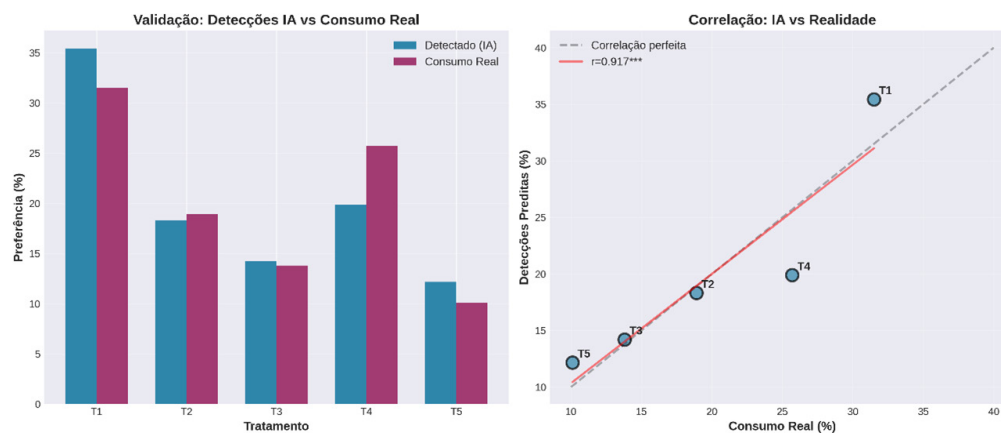


Fotos: Joseane Padilha da Silva

**Figura 8.** Previsões do modelo em conjunto de validação demonstrando robustez na identificação individual dos leitões sob diferentes condições de iluminação e posicionamento.



**Figura 9.** Distribuição de preferências alimentares dos leitões por dieta, ranking geral e detalhamento por grupo experimental.



**Figura 10.** Validação das detecções automáticas de preferência alimentar: comparação com consumo real por pesagem e análise de correlação ( $r=0,917$ ).

com diferenças de palatabilidade expressivas. É importante, no entanto, contextualizar essa validação: a análise foi conduzida no nível de médias de tratamento ( $n=5$ ), o que restringe os graus de liberdade e limita a robustez estatística da estimativa. O consumo real em gramas permanece o indicador mais direto de palatabilidade; a abordagem por visão computacional não o substitui, mas oferece uma alternativa operacionalmente viável quando a pesagem contínua não é praticável. Uma questão em aberto é se o método seria suficientemente sensível para discriminar tratamentos com diferenças de

palatabilidade mais sutis, algo que estudos futuros poderão investigar.

Em vez de substituir métodos tradicionais, a Inteligência Artificial os complementa com uma vantagem operacional decisiva: o mesmo conjunto de dados que validou o ranking de preferências permite responder perguntas adicionais sem custo adicional de coleta. As seções seguintes apresentam três exemplos dessas análises complementares.

### Quando os leitões preferem comer?

O monitoramento contínuo revelou padrão claro de atividade ao longo do dia (Figura 11, painel superior). O pico de visitas ocorreu às 8h (aproximadamente 70 mil detecções), coincidindo com o horário de reabastecimento dos comedouros pela equipe (entre 8h e 9h30). A atividade manteve-se elevada durante o período diurno (7h às 16h) e reduziu drasticamente no período noturno, com a madrugada (0h às 6h) registrando menos do que 15% da atividade diurna. Embora o pico matinal seja parcialmente atribuível à renovação da oferta de ração, o padrão geral demonstra preferência clara dos leitões por alimentação diurna, consistente com o comportamento natural da espécie (Feddes; Fraser, 1994), com atividade concentrada entre 7h e 16h independentemente do momento de reabastecimento.

A questão mais relevante, entretanto, está no heatmap<sup>14</sup> inferior: as preferências entre tratamentos mudam ao longo do dia? A resposta é não. T1 dominou consistentemente em todos os horários (23-45%), sem inversões no ranking. Embora a intensidade da atividade alimentar varie substancialmente entre períodos diurnos e noturnos, as

proporções relativas de escolha entre os tratamentos disponíveis permaneceram estáveis ao longo de 24 horas. Em condições de acesso livre e contínuo às dietas (*ad libitum*), os leitões mantiveram suas preferências independentemente do momento do dia, demonstrando que as escolhas refletem genuinamente a palatabilidade intrínseca de cada tratamento. Esta informação valida que testes de palatabilidade podem ser conduzidos em qualquer horário do dia sem comprometer a confiabilidade dos resultados e confirma que os protocolos de manejo alimentar devem concentrar-se no período entre 7h e 16h para máxima eficiência operacional, aproveitando os picos naturais de atividade.

### As preferências mudam ao longo do experimento?

A análise temporal permitiu avaliar se as preferências se mantêm estáveis ou se leitões "se acostumam" com sabores inicialmente rejeitados ou "se cansam" de escolhas inicialmente preferidas (Figura 7). Com 12 dias de observação (excluindo primeiro e último dia parcial), a análise visual sugere estabilidade geral nas preferências. T1 manteve-se consistentemente dominante em todos os dias (média 29,1%, CV=10,9%), demonstrando baixa variabilidade e clara superioridade. Os coeficientes

<sup>14</sup> Heatmap (Mapa de Calor): representação visual onde cores indicam intensidade de uma variável (ex: regiões mais frequentadas em uma arena).



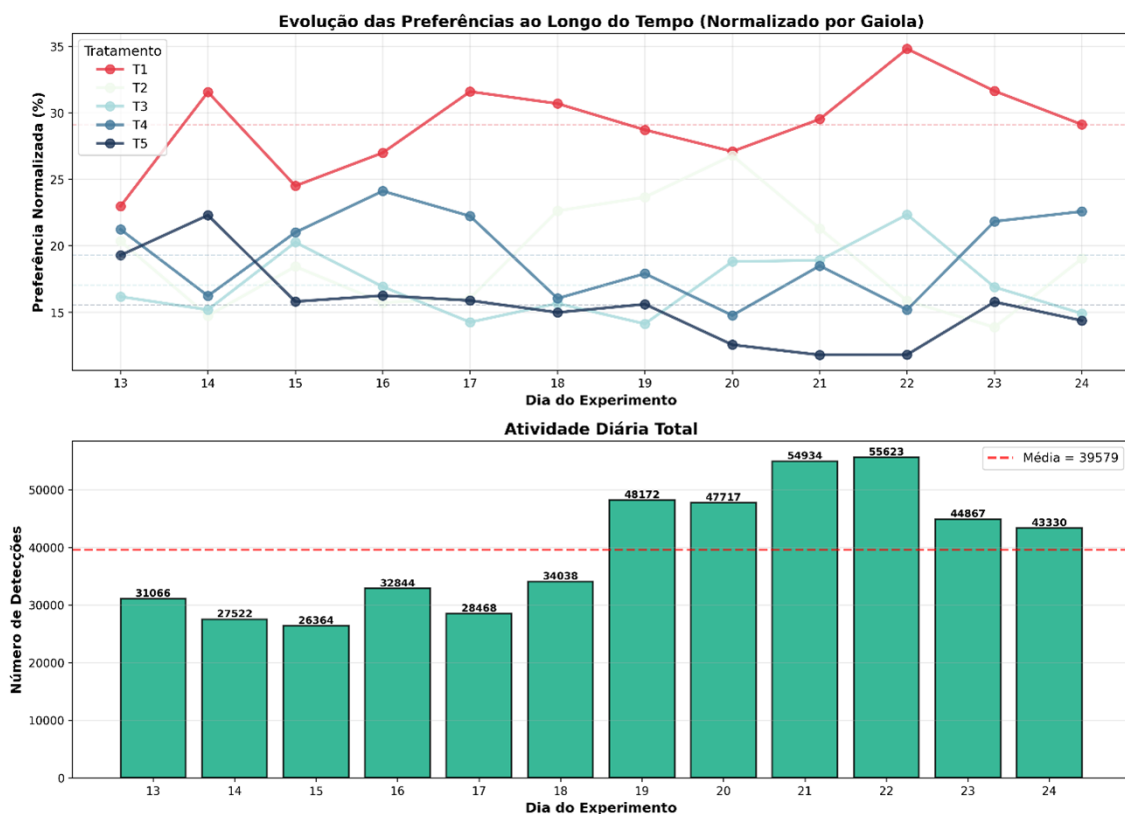
**Figura 11.** Análise temporal da atividade alimentar, distribuição horária do número de detecções e variação das preferências por tratamento ao longo do dia.

de variação moderados (14-20%) para as demais rações indicam flutuações naturais esperadas em dados comportamentais, embora o tamanho amostral de 12 pontos temporais limite conclusões estatísticas definitivas sobre tendências.

Na Figura 12, o painel inferior mostra que a atividade alimentar total aumentou progressivamente ao longo do período experimental (de aproximadamente 26 mil detecções no segundo dia para picos de 55 mil detecções entre o 10º e 11º dias), padrão esperado dado o crescimento corporal dos leitões e consequente aumento na demanda alimentar diária (Close; Cole, 2000). O ponto relevante é que, apesar de comerem progressivamente mais em termos absolutos conforme crescem, as preferências relativas entre tratamentos permaneceram estáveis. Em outras palavras, mesmo quando o volume total consumido dobrou entre o início e o final do experimento, a distribuição percentual das escolhas entre os cinco tratamentos manteve-se consistente. Isto confirma que as escolhas refletem preferências genuínas de palatabilidade, não sendo distorcidas pelo aumento do consumo total associado ao crescimento.

## Animais dominantes impõem suas preferências?

Uma questão central em estudos de comportamento alimentar é se as escolhas observadas refletem preferências genuínas de todos os animais ou se resultam de imposição hierárquica, onde animais dominantes controlam o acesso aos recursos e subordinados simplesmente seguem (Held et al., 2000; D'eath; Pickup, 2002). Para avaliar isso, analisamos o consenso entre os três animais de cada gaiola. Para cada leitão (I, O ou X) calculamos a proporção de suas visitas ao comedouro destinadas a cada dieta disponível na gaiola. Consideramos que um animal tinha "preferência definida" por um tratamento apenas se este representasse mais de 40% de suas visitas - este limiar garante que a preferência não seja marginal ou acidental, mas sim uma escolha consistente e majoritária. Após aplicar este critério aos três animais de cada gaiola, comparamos suas preferências: se os três animais tinham preferência definida pela mesma dieta, classificamos como "consenso total"; se dois animais concordavam, "consenso parcial"; se não havia acordo (discordância, apenas um com opinião forte, ou ninguém acima do limiar) classificamos como "divergente".



**Figura 12.** Evolução temporal das preferências por tratamento e da atividade alimentar total ao longo do período experimental.

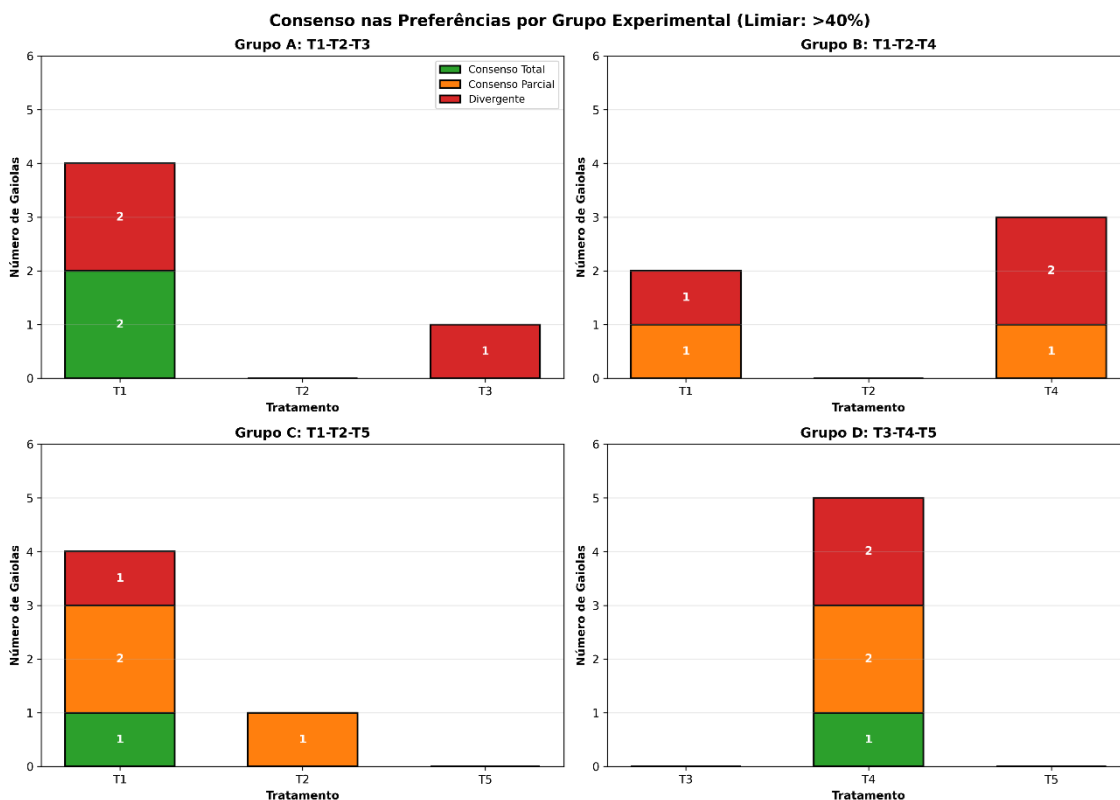
A Figura 13 apresenta a análise por grupo experimental, revelando padrões distintos. No Grupo A (T1-T2-T3), quatro das cinco gaiolas convergiram para T1, sendo duas com consenso total (os três animais visitaram T1 em >40% das ocasiões) e duas divergentes (preferências individuais fracas ou em desacordo). T2 não foi escolhido por nenhuma gaiola e T3 apareceu apenas em uma gaiola sem consenso. No Grupo B (T1-T2-T4), observou-se competição entre T1 e T4, em que duas gaiolas convergiram para T1 (um parcial, um divergente) enquanto três gaiolas escolheram T4 (um parcial, dois divergentes). T2 novamente não foi escolhido. No Grupo C (T1-T2-T5), T1 dominou em quatro das cinco gaiolas (um total, dois parciais, um divergente), com T2 aparecendo em apenas uma gaiola com consenso parcial. T5 não foi escolhido por nenhuma gaiola. O resultado mais revelador está no Grupo D (T3-T4-T5), único sem acesso a T1, no qual todas as cinco gaiolas convergiram para T4 (um total, dois parciais, dois divergentes), enquanto T3 e T5 não receberam nenhuma escolha consensual. Este resultado confirma que T4 é genuinamente a segunda dieta mais palatável, assumindo protagonismo total na ausência de T1. Já T2, T3 e T5 foram

consistentemente evitados em todos os grupos onde estavam disponíveis.

A presença consistente de gaiolas classificadas como "divergentes" (barras vermelhas) em todos os grupos - variando de 20% a 60% das gaiolas por tratamento - é crucial para interpretar esses resultados. Se houvesse dominância social forte impondo escolhas, esperaríamos consenso total em todas ou quase todas as gaiolas. A variabilidade observada indica que as preferências refletem escolhas individuais genuínas, não coerção. Quando uma dieta é verdadeiramente palatável (T1 e T4), múltiplos animais na mesma gaiola convergem independentemente para ele; quando não é palatável (T2, T3, T5), nem mesmo pressão social potencial consegue gerar consenso.

### O potencial inexplorado: muitas análises possíveis

As cinco análises apresentadas - ranking de preferências, validação com consumo real, padrões circadianos, estabilidade temporal e consenso social - representam apenas uma fração do potencial analítico contido nos mesmos vídeos coletados.



**Figura 13.** Distribuição das gaiolas por nível de consenso entre leitões (total, parcial ou divergente) quanto à preferência por tratamento nos quatro grupos experimentais (limiar de preferência definida: >40% das visitas ao comedouro).

Cada nova pergunta científica pode ser respondida retreinando modelos de Inteligência Artificial sobre o material já existente, sem necessidade de novos experimentos, novos animais ou trabalho de campo adicional.

Os mesmos 14 dias de gravação permitem investigar dinâmicas de dominância (quais animais controlam acesso aos comedouros e em que horários?), padrões de descanso (quanto tempo passam deitados vs. ativos?), comportamentos agonísticos (frequência e intensidade de brigas, mordidas, empurrões), movimentação espacial (animais mais ativos exploram mais o ambiente?), interações sociais (quais pares de animais interagem mais? há formação de "duplas"?), resposta a estressores (como reagem a barulhos externos, entrada de pessoas, mudanças no ambiente?), sequência de escolhas alimentares (após visitar T1, qual a probabilidade de ir para T2 vs. T4?), duração de episódios (T1 gera visitas mais longas que T5?), velocidade de aproximação (animais correm para T1 mas caminham para T5?), postura corporal (diferenças na linguagem corporal entre tratamentos preferidos e rejeitados?), uso do espaço (preferem comedouros próximos às paredes ou centralizados?), mudanças de peso estimadas visualmente (crescimento diferencial entre animais?), claudicação ou problemas de locomoção e até mesmo sinais precoces de doenças através de mudanças súbitas no comportamento.

Dependendo da qualidade das câmeras e do ângulo de filmagem, análises ainda mais sofisticadas são viáveis como estimativa de peso corporal por visão computacional (eliminando necessidade de pesagens manuais estressantes) (Pezzuolo et al., 2018), detecção de lesões cutâneas, avaliação de escore corporal, monitoramento de crescimento de cauda ou orelhas e identificação automática de animais doentes antes mesmo de sintomas óbvios aparecerem (Matthews et al., 2016).

Cada uma dessas análises, por métodos tradicionais, exigiria um experimento separado, com protocolos específicos, observadores dedicados e custos independentes. Com Inteligência Artificial aplicada a vídeos, todas essas perguntas podem ser respondidas a partir do mesmo conjunto de dados, transformando radicalmente a relação custo-benefício da pesquisa em produção animal. Este trabalho interrompe a exploração aqui não por limitação técnica, mas para ilustrar o ponto central: Inteligência Artificial não substitui experimentos, ela multiplica o conhecimento extraível de cada experimento realizado.

## Rastreamento automatizado de mobilidade em frangos

A mobilidade em frangos de corte é um indicador importante de saúde, bem-estar e mortalidade, podendo revelar precocemente problemas locomotores, doenças metabólicas ou respostas a diferentes condições de criação. Tradicionalmente, a avaliação de movimento depende da observação humana através de escores subjetivos de marcha ou registros pontuais de atividade - métodos trabalhosos, sujeitos a variabilidade entre observadores, e impraticáveis para monitoramento contínuo em larga escala. O avanço recente em Visão Computacional e Inteligência Artificial, particularmente através de algoritmos de *deep learning* como YOLO (*You Only Look Once*), transformou radicalmente as possibilidades de quantificação comportamental. Estes sistemas conseguem detectar, rastrear e analisar movimento de múltiplos animais simultaneamente a partir de vídeos, extraindo métricas objetivas e contínuas que eram anteriormente inviáveis de obter.

Sistemas de monitoramento automatizado de movimento têm potencial para revolucionar múltiplas dimensões da cadeia avícola. Na produção comercial, aplicações práticas incluem identificação de lotes com alterações comportamentais antes da manifestação clínica de doenças, detecção de problemas ambientais como temperatura inadequada ou falhas de ventilação, e monitoramento quantitativo de bem-estar animal e mortalidade no lote. Sistemas de alerta automático podem sinalizar quando padrões de movimento desviam significativamente do esperado para idade ou linhagem, permitindo intervenções precoces. A otimização de densidade populacional também se beneficia desta tecnologia em uma perspectiva de longo prazo. Embora a densidade seja definida antes do alojamento e não possa ser ajustada mid-lote na produção convencional, o monitoramento contínuo por IA pode gerar dados históricos que informem decisões de alojamento em lotes futuros. No horizonte de sistemas de produção mais integrados, a detecção precoce de sinais de estresse locomotor poderia ainda acionar respostas automáticas de manejo ambiental - ventilação, temperatura, iluminação - mesmo sem alteração da densidade.

Na pesquisa experimental, as possibilidades são igualmente vastas. A quantificação objetiva de efeitos de grupos sobre vigor locomotor, a comparação de linhagens genéticas quanto a capacidade

de movimento e resistência a problemas de pernas, e a validação de intervenções de manejo (programas de luz, enriquecimento ambiental, estratégias de alimentação) tornam-se mais precisas e menos dependentes da subjetividade humana. Estudos de interação entre genótipo e ambiente podem avaliar como diferentes linhagens respondem a condições variadas através de métricas comportamentais contínuas. O estabelecimento de curvas de referência de atividade normal para diferentes idades, sexos e sistemas de criação cria *baseline* essencial para detectar desvios anormais.

Em programas de melhoramento genético a mobilidade pode servir como fenótipo comportamental para seleção, complementando critérios tradicionais como ganho de peso e conversão alimentar. A possibilidade de fenotipar automaticamente milhares de aves sem escores manuais trabalhosos pode acelerar ganhos genéticos para robustez locomotora, característica historicamente difícil de selecionar em larga escala. Correlações entre padrões de movimento e desempenho produtivo podem revelar relações genéticas não evidentes através de métodos convencionais.

No contexto de certificação e rastreabilidade, sistemas automatizados oferecem documentação objetiva e auditável de condições de bem-estar ao longo do ciclo produtivo, atendendo demandas crescentes de consumidores e reguladores por transparência. Geração de "assinaturas comportamentais" de lotes - perfis quantitativos de atividade locomotora - pode ser correlacionada com qualidade de produto final, potencialmente identificando práticas de manejo que otimizam simultaneamente bem-estar animal e características de carcaça desejáveis pelo mercado.

Existem vários estudos que apresentam a viabilidade técnica de sistemas baseados em visão computacional para *tracking* de aves. Aydin (2013) desenvolveu algoritmos para detectar velocidade, frequência de passos e oscilação lateral em frangos, encontrando

correlações significativas com escores de marcha. Dawkins et al. (2009) utilizaram técnicas de *optical flow* para quantificar movimento em massa de frangos, demonstrando correlação entre fluxo óptico e taxa de passos. Mais recentemente, Van der Sluis et al. (2023) aplicaram combinação de segmentação de aves e *optical flow* para prever distribuição de escores de marcha em ambientes comerciais, obtendo forte correlação ( $R^2 = 0,97$ ) entre escores preditos e observados.

Para demonstrar essas possibilidades e fomentar novas aplicações, esta seção documenta experimento de comparação de dois grupos experimentais em frangos de corte utilizando câmeras de vigilância comerciais para quantificar o movimento. Dois estudos piloto complementares foram desenvolvidos: monitoramento contínuo com filmagem superior (Figura 14) para quantificar padrões naturais de atividade ao longo de múltiplos dias, e teste de provocação controlada com filmagem frontal (Figuras 15 A,B) para avaliar capacidade de resposta locomotora a estímulo externo.



Foto: Joseane Padilha da Silva

**Figura 14.** Configuração experimental do monitoramento contínuo com filmagem superior. Câmera instalada no teto do galpão captura toda a área de movimentação dos animais.



Fotos: Joseane Padilha da Silva

**Figura 15.** Teste de provocação com filmagem frontal. (A) Vista frontal durante teste de resposta locomotora. (B) Barreira removível utilizada no protocolo de estímulo.

O objetivo central não está nas conclusões específicas sobre os grupos G1 e G2 comparados, mas sim em estabelecer se sistemas baseados em câmeras convencionais conseguem quantificar movimento com precisão suficiente, quais métricas podem ser extraídas e que tipos de análises são viáveis. A documentação detalhada dos métodos e resultados serve como referência metodológica para pesquisadores e produtores interessados em implementações futuras.

## Monitoramento contínuo de atividade locomotora (vista superior)

### Delineamento experimental e coleta de dados

O experimento comparou dois grupos (G1 e G2) com três repetições cada, totalizando seis boxes experimentais sobre cama de maravalha, com 27 frangos por box. Uma câmera de segurança de alta resolução foi instalada dois metros acima de cada box (total de seis câmeras), com gravação em DVR (Digital Video Recorder), capturando imagens zenitais de toda a área disponível aos animais durante período de sete dias consecutivos. Os vídeos foram gravados a cada hora no período diurno (6h às 17h), sob iluminação LED comercial padrão para criação de frangos de corte, gerando um total de 366 vídeos de 60 minutos que totalizaram aproximadamente 300 GB. Dos 27 frangos, 12 foram marcados individualmente com tintas atóxicas Raidex em três cores (vermelho, azul e verde) aplicadas em quatro regiões corporais (cauda, dorso, laterais das asas e cabeça), resultando em combinações únicas de cor e localização para identificação visual.

### Desenvolvimento do sistema de detecção e tracking

O sistema de detecção foi desenvolvido utilizando arquitetura YOLO (*You Only Look Once*) de *deep learning* para reconhecimento e localização automática de frangos nas imagens. Para treinamento do modelo, foram extraídos 500 *frames* aleatórios dos vídeos coletados, nos quais cada frango foi manualmente anotado com *bounding boxes* delimitando sua posição, conforme mostra a Figura 16, totalizando 2.599 instâncias anotadas. O modelo foi treinado por

50 épocas até convergência, alcançando métricas de desempenho excepcionais no conjunto de validação: precisão de 98,2%, recall de 99,3%, mAP50 (*mean Average Precision* ao *threshold* de IoU 0,5) de 98,8% e mAP50-95 de 80,4%. Estas métricas indicam que o modelo detecta corretamente praticamente todos os frangos presentes nas imagens (recall >99%) com altíssima confiança nas detecções realizadas (precisão >98%), mesmo sob variações de iluminação natural ao longo do dia e diferentes níveis de agrupamento dos animais.


Após a detecção (Figura 17A), foi implementado algoritmo de *tracking* para rastreamento individual dos animais ao longo do tempo, permitindo reconstruir trajetórias de movimento de cada frango dentro de períodos contínuos de gravação (Figura 17B). A identificação individual permanente através de marcação com tinta atóxica Raidex nas cores azul, verde e vermelho marcadas na cabeça, dorso, lateral das asas e cauda, inicialmente testada, não apresentou resultado satisfatório devido ao rápido apagamento das marcas e dificuldade de visualização na filmagem superior.

Consequentemente, adotou-se estratégia de *tracking* por associação temporal baseada em proximidade espacial entre *frames* consecutivos, onde cada detecção é vinculada à detecção mais próxima no *frame* seguinte, mantendo assim a identidade do animal ao longo de sua trajetória dentro de um mesmo vídeo. Esta abordagem permite rastreamento individual eficaz durante cada sessão de gravação,



Foto: Joseane Padilha da Silva

**Figura 16.** Anotação manual dos frangos com *bounding boxes* (retângulos verdes) na plataforma CVAT para treinamento do modelo de detecção da ave.



**Figura 17.** Rastreamento individual de frangos. (A) Identificação automática com IDs únicos por vídeo. (b) Exemplo de trajetórias acumuladas nos primeiros 141 segundos de gravação, mostrando padrões individuais de deslocamento.

gerando identificadores únicos (ID:1, ID:2, etc) e reconstruindo trajetórias completas de cada frango ao longo do período filmado, conforme visto na Figura 17B. Entretanto, os identificadores são reiniciados a cada novo vídeo, impossibilitando reconhecer o mesmo indivíduo entre diferentes sessões de gravação ou ao longo de múltiplos dias. Apesar desta limitação, o método é suficiente para quantificar padrões de movimento em períodos contínuos e detectar variações comportamentais ao nível de grupo.

### Métricas comportamentais extraídas

Para cada ave, em cada vídeo, foram calculadas três métricas comportamentais:

- 1. Movimento mediano:** definido como a mediana das distâncias percorridas (em pixels) entre *frames* consecutivos, refletindo a intensidade geral de atividade locomotora.
- 2. Porcentagem de tempo parado:** calculada como a proporção de *frames* onde o deslocamento foi inferior ao *threshold* mínimo, indicando comportamento de repouso.

- 3. Dispersão espacial:** mensurada através do desvio padrão das posições ocupadas pelo animal ao longo do vídeo, quantificando o quanto cada frango explorou o espaço disponível no galpão.

### Resultados do monitoramento contínuo

Os resultados indicaram ausência de diferenças significativas entre os grupos para todas as métricas avaliadas (Tabela 1). O movimento mediano apresentou efeito trivial ( $p = 0,404$ ; Cohen's  $d = 0,089$ ), assim como a porcentagem de tempo parado ( $p = 0,151$ ;  $d = -0,154$ ) e a dispersão espacial ( $p = 0,510$ ;  $d = 0,070$ ). A análise considerou 205 trajetórias individuais para G1 e 161 para G2, totalizando 366 animais rastreados ao longo de múltiplos vídeos. A ausência de diferenças sugere que, nas condições avaliadas, os grupos não impactaram significativamente os padrões naturais de movimento e exploração espacial dos frangos durante o período monitorado.

**Tabela 1.** Estatísticas descritivas das métricas comportamentais de movimento por grupo.

Métrica	G1 (n=205)	G2 (n=161)	p	Cohen's d
Movimento mediano	295,4 ± 92,9	303,1 ± 82,3	0,404	0,089
% Tempo parado	20,4 ± 21,1	17,5 ± 17,0	0,151	-0,154
Dispersão espacial	175,9 ± 65,0	180,2 ± 56,0	0,510	0,070

## Análises possíveis com as trajetórias

O rastreamento individual dos frangos ao longo do tempo gera dados ricos que vão muito além das métricas básicas de movimento. Cada trajetória reconstruída é, essencialmente, um registro completo da história espacial do animal - onde esteve, quando esteve, por quanto tempo, e como se moveu de um ponto a outro. Este tipo de informação era simplesmente inviável de se obter por observação humana. Imaginar um pesquisador tentando anotar posições de 27 frangos a cada segundo durante 60 minutos ilustra a impossibilidade prática. A tecnologia automatizada torna isso trivial.

Para ilustrar o potencial analítico, processamos seis vídeos (três de cada grupo) e extraímos dois tipos de análises que exemplificam possibilidades metodológicas: mapas de ocupação espacial e quantificação de tortuosidade das trajetórias. Importante ressaltar que esta demonstração se baseia em amostra reduzida com objetivo didático - não para estabelecer conclusões sobre os grupos, mas para mostrar concretamente que tipos de perguntas científicas se tornam respondíveis quando se tem acesso a trajetórias completas.

## Onde os frangos passam seu tempo?

A Figura 18 apresenta mapas de calor mostrando onde os frangos de cada grupo concentraram sua atividade. Regiões mais claras (amarelo/branco) indicam zonas intensamente utilizadas, enquanto áreas escuras representam espaços evitados ou raramente visitados. O padrão que emerge é biologicamente coerente: forte concentração na região periférica ao comedouro central, com a área do próprio comedouro aparecendo escura (animais não ficam em cima dele, obviamente). Este tipo de visualização permite responder questões práticas:

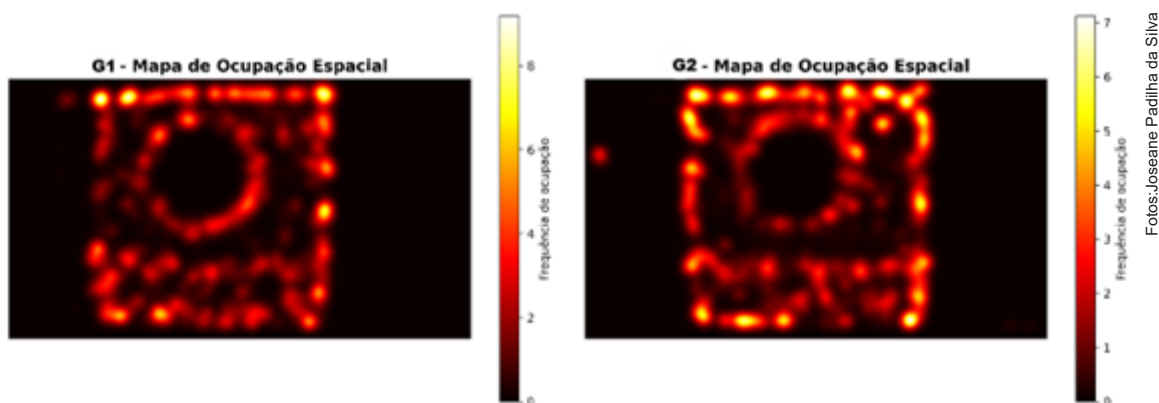
há zonas do galpão sistematicamente subutilizadas? Animais se distribuem uniformemente ou formam agregações? Grupos diferentes resultam em padrões distintos de uso do espaço?

Embora nesta amostra exploratória os padrões tenham sido similares entre G1 e G2, o método está demonstrado. Aplicações futuras são evidentes: comparar linhagens quanto a comportamento espacial (algumas preferem proximidade ao comedouro, outras exploram mais?); detectar problemas ambientais localizados (se uma área do galpão é evitada, pode haver problema de ventilação, umidade ou cama naquela região); avaliar efeitos de enriquecimento ambiental (poleiros, brinquedos); ou quantificar impactos de densidade populacional (em lotação alta, animais conseguem acessar todas as áreas ou há zonas de exclusão?)

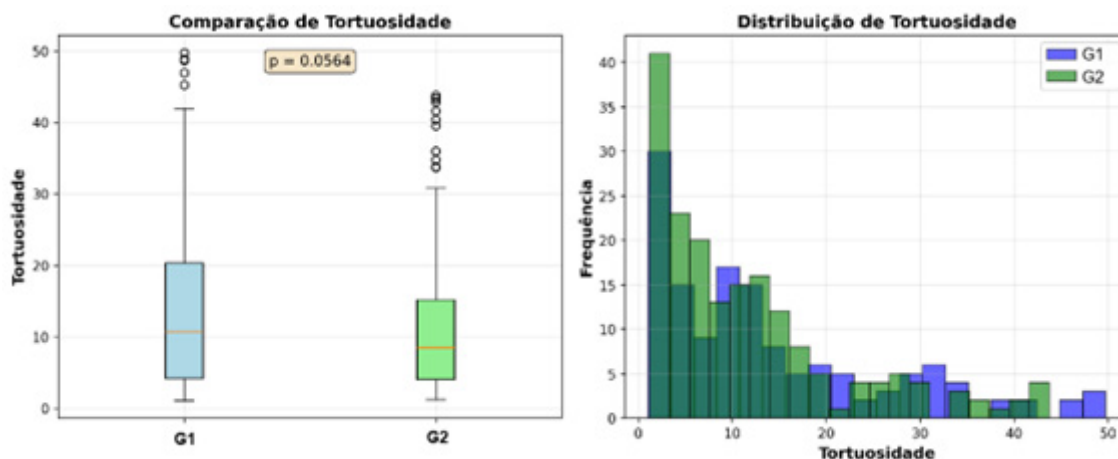
## Como os frangos se movem? Tortuosidade das trajetórias

A Figura 19 analisa não apenas o quanto os frangos se movem, mas a forma como se movem. Tortuosidade quantifica sinuosidade do caminho: valores próximos a 1,0 indicam deslocamentos em linha reta (animal vai diretamente de A para B), enquanto valores altos revelam trajetórias erráticas com múltiplas mudanças de direção. Retornando à Figura 17B, é possível visualizar este conceito: algumas trajetórias são linhas relativamente suaves, outras formam zigue-zagues complexos.

O resultado surpreendente foi que, mesmo numa pequena amostra aleatória, valores de tortuosidade foram consistentemente elevados (médias acima de dez, com muitos casos acima de 20 a 40), em ambos os grupos. Isto revela padrão comportamental fundamental: frangos não "caminham" no sentido de deslocamento direcionado típico de



**Figura 18.** Mapas de ocupação espacial (amostra exploratória) do box com comedouro central? Regiões claras indicam maior frequência de ocupação.



**Figura 19.** Análise de tortuosidade. (a) Comparação entre grupos segundo teste de Mann-Whitney U ( $p = 0,056$ ). (b) Distribuição de frequências.

animais explorando ativamente, eles "perambulam". Este comportamento errático levanta questões científicas fascinantes e relevância prática.

- **Primeiro, implicações energéticas:** animais que ficam mais tempo em pé movendo-se continuamente (mesmo que sem direção clara) presumivelmente gastam mais energia que aqueles que permanecem deitados. Esta diferença no custo energético da postura e locomoção poderia impactar eficiência alimentar e desempenho produtivo - aspecto ainda pouco quantificado na literatura avícola. Sistemas automatizados de *tracking* permitem pela primeira vez correlacionar objetivamente tempo em movimento com ganho de peso ou conversão alimentar ao nível individual, viabilizando estudos sobre o custo energético real da atividade locomotora.
- **Segundo, heterogeneidade individual:** a variação observada foi relativamente grande (tortuosidade de ~5 até >40). O que explica que alguns frangos fiquem significativamente mais ativos e em pé do que outros? Peso corporal (aves mais pesadas tendo maior dificuldade locomotora), conformação anatômica das pernas, predisposição genética ou variação temperamental? A capacidade de estratificar automaticamente a população por perfis comportamentais abre caminho para estudos que correlacionem tortuosidade com características morfométricas, genéticas e de desempenho produtivo. Há potencial até para seleção genética se a tortuosidade for um traço herdável associado a robustez locomotora.

- **Terceiro, indicador de bem-estar:** embora valores elevados possam simplesmente refletir comportamento exploratório normal, extremos muito altos poderiam sinalizar dificuldade locomotora, claudicação ou problemas posturais que levam a correções constantes de trajetória. Inversamente, uma tortuosidade muito baixa (animal quase não se move, e quando se move é apenas em linha reta) poderia indicar letargia ou evitar de movimento por desconforto. Estabelecer faixas de referência do que é "normal" para diferentes idades, linhagens e sistemas de criação é um passo essencial para transformar esta métrica em ferramenta de monitoramento de bem-estar aplicável em escala comercial.

Os exemplos aqui apresentados - ocupação espacial e tortuosidade - representam apenas duas entre muitas análises possíveis quando se tem trajetórias completas. Outras incluem:

- Velocidade instantânea ao longo do dia (frangos são mais ativos em que horários?).
- Análise de proximidade social (quanto tempo passam perto de congêneres?).
- Padrões de visita ao comedouro/bebedouro.
- Sincronização de atividade entre indivíduos.
- Identificação automática de comportamentos específicos (descanso, alimentação, exploração) através de *machine learning* treinado nas trajetórias.

A limitação não é técnica, é de imaginação dos pesquisadores em formular perguntas respondíveis com estes dados.

## Teste de resposta comportamental com provocação controlada (Vista Frontal)

### Protocolo de provocação padronizado

A mesma população experimental (G1 e G2, 27 frangos cada) foi testada ao longo de três dias consecutivos. O protocolo consistiu em posicionar grupos de frangos em área delimitada por barreira frontal enquanto a filmagem era iniciada, capturando o campo de visão completo da área de teste. Após três segundos de gravação inicial (*baseline* pré-estímulo), a barreira era removida rapidamente, permitindo movimentação livre dos animais. O movimento resultante foi registrado durante dezessete segundos subsequentes, totalizando vídeos de vinte segundos por sessão. Os três segundos iniciais foram posteriormente excluídos da análise para evitar contabilização de movimento anterior ao estímulo propriamente dito, garantindo que as métricas refletissem exclusivamente a resposta à remoção da barreira.

Foram gerados três vídeos por dia para cada grupo, totalizando 18 vídeos ao longo dos três dias de teste (2 grupos  $\times$  3 dias  $\times$  3 vídeos/dia = 18 vídeos de 20 segundos cada, equivalente a seis minutos de gravação total). A filmagem foi realizada com câmera iPhone 11 em resolução 4K em relação ao solo e à área de teste para garantir consistência na perspectiva entre todas as sessões. Devido à curta duração dos vídeos, o armazenamento demandou espaço mínimo (aproximadamente 200-300 MB para o conjunto completo), demonstrando viabilidade operacional mesmo com recursos limitados.


O horário de cada teste foi sistematicamente registrado para permitir controle de possíveis efeitos circadianos sobre reatividade, aspecto relevante dado que ritmos biológicos podem influenciar substancialmente respostas comportamentais e locomotoras em aves. Esta padronização temporal também facilita replicação futura do protocolo em outros contextos experimentais.

### Sistema de detecção para vista frontal

Um novo modelo YOLO foi treinado especificamente para detecção de frangos em vista frontal, utilizando imagens anotadas capturadas nesta perspectiva. A filmagem frontal, diferentemente da vista zenital utilizada no monitoramento contínuo, facilita a visualização de movimentos direcionais, além de capturar comportamentos adicionais como hesitação ou orientação preferencial que não seriam evidentes em vista superior. Entretanto, a vista frontal apresenta maior desafio para o *tracking* devido a oclusões quando múltiplos animais se sobrepõem na perspectiva da câmera. O modelo alcançou desempenho robusto: 690 detecções corretas de frangos, apenas 29 falsos positivos (classificação incorreta de background como frango) e 18 falsos negativos (frangos não detectados), resultando em precisão superior a 95% conforme demonstrado pela matriz de confusão (Figura 20).

### Tracking e cálculo de métricas de movimento induzido

Após detecção, foi implementado algoritmo BoT-SORT (*Byte-On-Track with Simple Online Realtime Tracking*) para rastreamento individual dos animais ao longo dos vídeos, escolhido por sua robustez em cenários com oclusões frequentes. Somente trajetórias com duração mínima de dez segundos foram



**Figura 20.** Desempenho do modelo YOLO para predição de frangos com vista frontal demonstrado por matriz de confusão.

consideradas na análise final, eliminando detecções espúrias ou *tracking* incompleto. Para cada frango rastreado foram calculadas:

- 1. Velocidade média:** obtida através da distância percorrida entre *frames* consecutivos multiplicada pela taxa de aquisição em *frames* por segundo.
- 2. Distância total percorrida:** soma acumulada de todos os deslocamentos durante o período de teste.
- 3. Tempo em movimento vs parado:** determinado por *threshold* de velocidade mínima (15 px/s) abaixo do qual o animal foi considerado parado.
- 4. Porcentagem de tempo parado:** proporção do tempo total em que a velocidade foi inferior ao *threshold*.

Adicionalmente, com base na distribuição de velocidades médias, os frangos foram classificados em três categorias de atividade utilizando percentis da própria amostra:

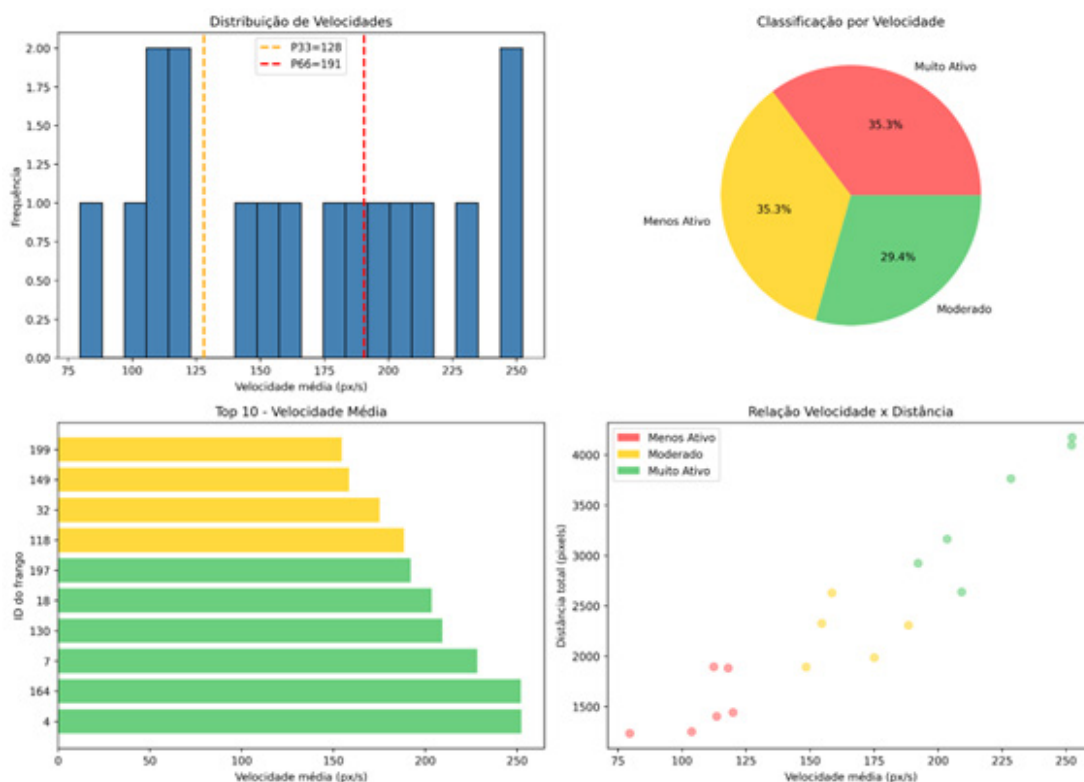
- **Menos ativo:** (velocidade < 128 px/s, correspondente ao 33º percentil),
- **Moderado:** (velocidade entre 128-191 px/s, entre 33º e 66º percentis) e

- **Muito ativo:** (velocidade > 191 px/s, acima do 66º percentil). Esta classificação baseada em percentis (em vez de *thresholds* absolutos) tem vantagem de ser adaptável a diferentes contextos experimentais, idades dos animais ou condições ambientais, sempre identificando os terços superior, médio e inferior da distribuição de reatividade.

## Resultados do teste de provocação

A Figura 21 apresenta análise integrada da variabilidade individual em resposta locomotora ao teste de provocação. O painel superior esquerdo mostra a distribuição de velocidades médias, evidenciando um espectro contínuo de aproximadamente 75 a 250 px/s sem grupos discretos aparentes, sugerindo que a reatividade representa característica graduada da população. As linhas tracejadas indicam os limites utilizados para classificação em terços: P33 = 128 px/s (menos ativos vs moderados) e P66 = 191 px/s (moderados vs muito ativos).

O painel superior direito apresenta a proporção de animais em cada categoria de atividade: 35,3% muito ativos, 29,4% moderados e 35,3% menos ativos. A distribuição relativamente equilibrada entre



**Figura 21.** Variabilidade individual em reatividade locomotora. (a) Distribuição de velocidades e critérios de classificação. (b) Proporção por categoria. (c) Top 10 mais reativos. (d) Correlação velocidade x distância.

as três categorias indica ausência de concentração extrema em um único perfil comportamental, sugerindo heterogeneidade individual na reatividade locomotora da população estudada. Afirmar sobre normalidade da distribuição subjacente requer análise complementar - histograma com curva ajustada e testes formais como Shapiro-Wilk - e não podem ser inferidas diretamente da proporção em tercís.

O painel inferior esquerdo destaca os dez indivíduos mais reativos, com velocidades entre 180-250 px/s. A coloração distingue animais muito ativos (verde) de moderados (amarelo), ilustrando que os animais mais rápidos excedem substancialmente os *thresholds* de classificação. Os menos ativos (não mostrados) apresentaram velocidades inferiores a 100 px/s - diferença de magnitude superior a 2,5 vezes em relação aos mais reativos.

O painel inferior direito demonstra correlação positiva entre a velocidade média e a distância total percorrida, validando consistência interna das métricas: animais mais rápidos efetivamente exploraram maior área espacial, não apenas se moveram mais intensamente em distâncias curtas. A estratificação por cores confirma que as três categorias ocupam regiões distintas do espaço velocidade-distância.

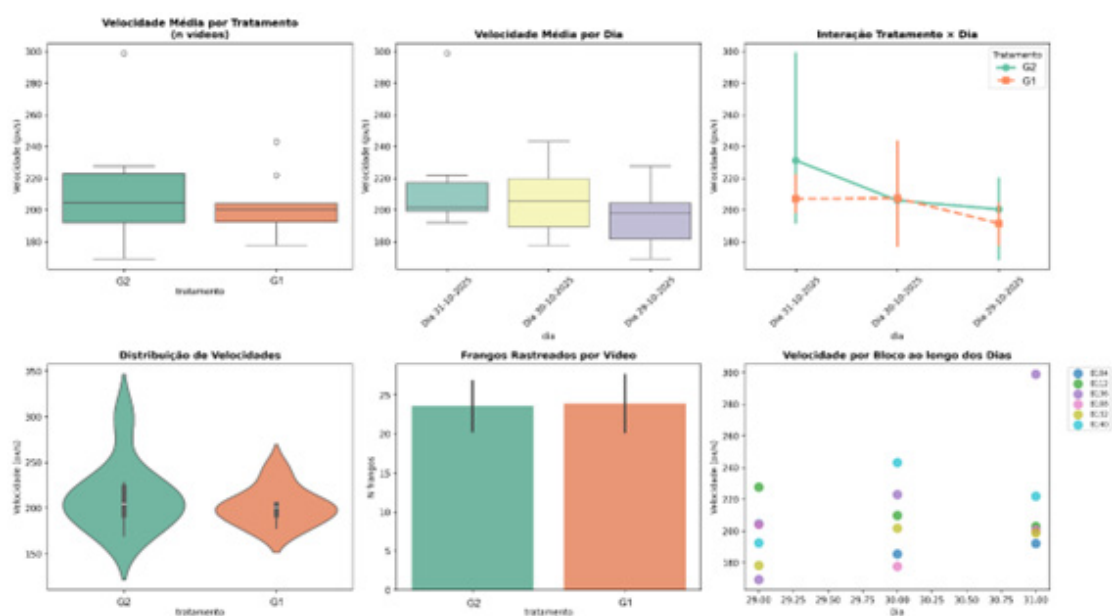
Esta heterogeneidade natural é biologicamente relevante, podendo refletir diferenças temperamentais intrínsecas, capacidade física ou vigor individual. Do ponto de vista prático, conhecer esta distribuição *baseline* permite identificar *outliers* anormalmente

lentos que poderiam sinalizar problemas locomotores ou sanitários individuais em sistemas automatizados de monitoramento.

A Figura 22 apresenta análise comparativa entre grupos no teste de provocação. Consistente com os resultados do monitoramento contínuo (vista superior), os grupos G2 e G1 não diferiram substancialmente em resposta locomotora: as distribuições de velocidade médias apresentaram ampla sobreposição (painel superior esquerdo), com G2 ligeiramente mais rápido (~205 px/s) que G1 (~195 px/s), mas com variabilidade individual dominando sobre possíveis diferenças entre grupos.

Um resultado não antecipado foi a aparente redução de velocidade ao longo dos três dias consecutivos de teste (painel superior central): de ~215 px/s no primeiro dia para ~195 px/s no terceiro. Embora este padrão possa sugerir habituação ao protocolo - animais inicialmente mais reativos ao estímulo novo, tornando-se progressivamente menos responsivos - a natureza piloto deste experimento com amostragem limitada impede conclusões definitivas. Alternativamente, esta variação pode refletir efeitos acumulativos de manuseio, variações ambientais não controladas entre dias, ou simplesmente ruído amostral. A análise de interação (painel superior direito) revela que este padrão temporal foi similar em ambos os grupos, descartando que a redução seja específica de um grupo.

A visualização em violino (painel inferior esquerdo) evidencia uma característica importante: mesmo



**Figura 22.** Comparação entre grupos G1 e G2. (a) Velocidade por grupo. (b) Velocidade por dia. (c) Interação grupo  $\times$  dia. (d) Distribuição de velocidades. (e) Número de animais rastreados. (f) Velocidade por bloco experimental.

dentro de grupos homogêneos, existe considerável variação individual, onde alguns frangos movem-se de duas a três vezes mais rápido que outros. Esta heterogeneidade natural representa tanto um desafio metodológico (requer amostras maiores para detectar efeitos de grupo) quanto uma oportunidade prática (sistemas automatizados poderiam estratificar indivíduos por perfil de reatividade).

O painel inferior direito revela que a variabilidade entre galpões (blocos) é substancial: alguns blocos apresentam velocidades consistentemente elevadas enquanto outros permanecem mais baixos, independente de grupo. Como os blocos foram formados por animais com peso corporal inicial similar, essa heterogeneidade não é atribuível a diferenças de peso entre grupos e pode refletir microambientes distintos (temperatura, qualidade de cama, densidade efetiva), diferenças genéticas entre lotes ou variações sutis no timing/execução do protocolo. Do ponto de vista experimental, este resultado ressalta a importância de estruturas hierárquicas na análise estatística, onde efeitos de bloco devem ser modelados adequadamente.

O equilíbrio no número de animais rastreados (painel inferior central, aproximadamente 24 por grupo dos 27 presentes) demonstra robustez do sistema de *tracking* mesmo em testes curtos e dinâmicos. A ausência de rastreamento de alguns indivíduos decorreu de limitação no campo de visão da câmera: animais posicionados em zonas periféricas fora do enquadramento ou ocultos por elementos estruturais não puderam ser detectados. Este aspecto técnico ressalta importância do posicionamento criterioso de câmeras em implementações futuras - idealmente com ângulo e altura que maximizem cobertura da área de interesse ou sistemas multicâmera para eliminar pontos cegos.

## Lições metodológicas e recomendações

Como estudos piloto, estas aplicações geraram aprendizados metodológicos importantes para pesquisadores interessados em implementar sistemas semelhantes. A detecção automatizada via YOLO mostrou-se robusta em ambas as perspectivas de filmagem (zenital e frontal), mantendo alta precisão mesmo sob variações de iluminação natural e diferentes densidades ou configurações espaciais dos animais. O *tracking* de curto prazo funcionou adequadamente para períodos contínuos, permitindo reconstruir trajetórias individuais suficientes para calcular métricas de movimento em ambas as abordagens.

As aplicações piloto demonstraram viabilidade técnica de quantificação automatizada de mobilidade em frangos de corte sob condições práticas de criação. Um aspecto crucial merece destaque: os sistemas desenvolvidos utilizaram câmeras convencionais de segurança, equipamentos de baixo custo já amplamente disponíveis em instalações avícolas para fins de vigilância patrimonial. Este fato desmistifica a implementação de inteligência artificial em granjas comerciais - não se trata de tecnologia inacessível ou que demanda investimentos proibitivos, mas sim de aproveitar infraestrutura existente através de software adequado.

Os sistemas mostraram-se capazes de processar tanto vídeos longos quanto curtos, detectar animais com alta precisão em diferentes perspectivas e extrair métricas comportamentais objetivas que seriam impraticáveis de obter por observação humana. A detecção automatizada via YOLO manteve robustez em ambas as perspectivas de filmagem, mesmo sob variações de iluminação natural e diferentes densidades ou configurações espaciais dos animais. O *tracking* de curto prazo funcionou adequadamente para períodos contínuos, permitindo reconstruir trajetórias individuais suficientes para calcular métricas de movimento em ambas as abordagens.

Naturalmente, produtores ou pesquisadores com maior capacidade de investimento podem explorar tecnologias mais avançadas que ampliam as possibilidades analíticas. Câmeras termográficas, por exemplo, permitiriam monitoramento simultâneo de temperatura corporal e movimento, integrando indicadores fisiológicos e comportamentais para detecção ainda mais precoce de problemas sanitários. Câmeras inteligentes equipadas com algoritmos de *pose estimation* (estimação de postura esquelética) possibilitariam análises biomecânicas sofisticadas, detectando alterações sutis em postura e marcha que precedem claudicação visível. Sistemas multicâmera com visão estereoscópica viabilizariam reconstrução tridimensional de movimentos, quantificando parâmetros como altura de passos, oscilação lateral ou assimetria de marcha. Sensores de profundidade (como RealSense ou LiDAR) agregariam informação volumétrica, permitindo estimativas de peso e conformação corporal integradas ao monitoramento comportamental. A convergência destas tecnologias com inteligência artificial representa fronteira promissora, mas a mensagem central destas aplicações é que resultados úteis já são alcançáveis com tecnologia acessível.

Uma preocupação prática frequente envolve o armazenamento de dados. Vídeos brutos de alta resolução ocupam espaço considerável - no presente

estudo, os 366 vídeos de 60 minutos totalizaram aproximadamente 300 GB para o experimento de visão superior. Entretanto, esta demanda pode ser gerenciada através de estratégias flexíveis conforme objetivos e recursos disponíveis.

A abordagem mais leve consiste em processar vídeos imediatamente após captura e armazenar apenas as métricas extraídas em formato tabular (CSV ou banco de dados), descartando os vídeos originais. Um experimento inteiro com milhares de trajetórias e dezenas de métricas comportamentais pode ser armazenado em poucos *megabytes*, representando redução de mais de mil vezes no espaço necessário. Esta estratégia é especialmente adequada para o monitoramento comercial contínuo onde o interesse reside nas tendências e alertas e não na revisão visual dos vídeos.

Para contextos de pesquisa que demandam revisão posterior ou validação, soluções intermediárias mostram-se viáveis. Armazenar apenas *frames-chave* (por exemplo, um *frame* por minuto) ao invés de vídeos completos reduz espaço em 95 a 98% mantendo capacidade de verificação visual. Alternativamente, guardar as coordenadas das trajetórias permite reconstruir animações dos movimentos sem necessidade dos vídeos originais, ocupando espaço mínimo enquanto preserva informação espaciotemporal completa. *Snapshots* de momentos específicos (como exemplos de comportamentos anômalos detectados automaticamente) podem ser salvos para documentação sem comprometer todo o arquivo de vídeo.

Do ponto de vista de infraestrutura, o custo de armazenamento caiu dramaticamente nas últimas décadas. Discos rígidos de um a dois *terabytes* custam hoje centenas de reais, suficientes para armazenar dezenas de milhares de vídeos processados ou centenas de milhares de horas de métricas comportamentais. Para operações de maior escala, soluções em nuvem com armazenamento elástico (paga-se apenas pelo que se usa) oferecem flexibilidade sem investimento inicial em *hardware*. Servidores locais *Network Attached Storage* (NAS) representam meio-termo, com controle total dos dados e custos previsíveis.

Em implementações mais sofisticadas, o processamento pode ocorrer em tempo real conforme vídeo é capturado, com métricas sendo enviadas diretamente para *dashboards* ou sistemas de alerta sem necessidade de armazenar vídeo em nenhum momento. Este modelo "*edge computing*"

(computação na borda)<sup>15</sup> é particularmente atrativo para granjas comerciais onde apenas alertas e tendências são relevantes. A decisão sobre estratégia de armazenamento deve considerar objetivos específicos, recursos disponíveis e requisitos regulatórios ou de auditoria, mas, em todos os casos, soluções viáveis existem dentro de orçamentos realistas.

A identificação individual permanente permanece como desafio técnico relevante, especialmente para monitoramento longitudinal. A marcação com tinta atóxica, estratégia bem-sucedida em estudos com suínos e bovinos, não se mostrou viável para frangos devido à combinação de tamanho reduzido dos animais (resultando em marcações visualmente pequenas de um a dois centímetros), alta densidade populacional levando a frequente sobreposição visual, crescimento rápido da plumagem cobrindo e apagando as marcações e, em vista zenital, marcações dorsais ficando frequentemente ocultas. Em contraste, bovinos e suínos permitem marcações maiores (dez a 30 centímetros), apresentam menor densidade por área e são frequentemente filmados lateralmente onde números permanecem visíveis. Alternativas como microchips RFID apresentam custo ainda proibitivo para aplicação experimental em larga escala, especialmente em estudos envolvendo centenas ou milhares de aves.

Pesquisas que requerem monitoramento longitudinal individual devem considerar abordagens emergentes como reidentificação por padrões de plumagem via *deep learning* (ainda em desenvolvimento), sistemas multicâmera que reduzam oclusões através de triangulação ou aguardar tecnologias de identificação que se tornem comercialmente viáveis a baixo custo. Entretanto, para muitas aplicações práticas, a análise ao nível de grupo (médias ou distribuições de lote) pode ser suficiente e mais viável economicamente do que *tracking* individual contínuo. Sistemas de alerta baseados em desvios do padrão esperado de movimento do lote podem identificar problemas sanitários ou ambientais precocemente sem a necessidade de identificação individual, atendendo demandas da produção comercial por soluções escaláveis e de baixa manutenção.

A escolha entre monitoramento contínuo com vista superior versus testes de provocação com vista frontal depende fundamentalmente do objetivo de estudo ou monitoramento. O monitoramento contínuo é particularmente adequado para comparação de padrões de atividade natural entre grupos

<sup>15</sup> **Edge Computing:** processamento de dados realizado localmente (no "edge", ou ponta da rede), próximo à fonte dos dados, em vez de enviar para servidores remotos (nuvem).

ou grupos ao longo de dias, detecção de alterações temporais em mobilidade (circadianas, progressão de doenças), análise de uso de espaço e distribuição espacial, e quantificação de comportamento espontâneo sem interferência humana. Esta abordagem captura o repertório comportamental natural dos animais em seu ambiente de criação habitual, sendo especialmente valiosa para estudos de bem-estar ou quando intervenções frequentes são indesejáveis.

Por outro lado, os testes de provocação são recomendados quando o objetivo envolve a avaliação de capacidade de resposta e o vigor em teste funcional padronizado, comparação de reatividade a estímulos entre grupos, detecção de problemas locomotores que comprometem resposta rápida ou estudos onde variação individual em reatividade é a variável de interesse. Estes testes funcionais condensam a avaliação locomotora em períodos curtos, facilitando a implementação em rotinas de manejo e permitindo comparações diretas sob condições controladas. A combinação de ambas as abordagens oferece avaliação complementar particularmente poderosa: o monitoramento passivo captura o comportamento natural ao longo do tempo, enquanto testes ativos avaliam a capacidade funcional em resposta a um desafio padronizado.

## Perspectivas e aplicações futuras

Estes resultados validam as tecnologias como ferramentas promissoras tanto para pesquisa experimental quanto para futuras aplicações em monitoramento de bem-estar e detecção precoce de problemas sanitários em escala comercial. À medida que os algoritmos de inteligência artificial se tornam mais acessíveis e o *hardware* computacional mais barato, a implementação de sistemas similares em granjas comerciais torna-se progressivamente viável. A integração com outras fontes de dados — consumo de ração e água, temperatura e umidade ambiental, registros sanitários — potencializa ainda mais o valor destes sistemas, permitindo modelos preditivos que antecipam problemas antes de impactos produtivos mensuráveis. O caminho está pavimentado, resta ampliar a adoção e refinar as aplicações conforme demandas específicas de cada contexto produtivo ou experimental.

## Ferramentas e infraestrutura computacional

Os três experimentos utilizaram Python 3.x como linguagem de programação, Ultralytics YOLOv8 para detecção de objetos, OpenCV para processamento de imagens e vídeos e algoritmos DeepSORT e ByteTrack para rastreamento multi-objeto. Anotação de dados foi realizada em CVAT (Computer Vision Annotation Tool). Treinamento de modelos utilizou Google Colab com acesso gratuito a GPUs; processamento de vídeos foi executado em computadores locais da Embrapa Suínos e Aves; armazenamento de *datasets* e quando necessário Google Drive.

## Considerações finais

A aplicação sistemática de visão computacional e aprendizado de máquina à pesquisa animal na Embrapa Suínos e Aves, iniciada com os três experimentos aqui documentados, representa os primeiros passos de uma jornada de transformação tecnológica. Os resultados alcançados - detecção automatizada de fertilidade em ovos com 100% de acurácia, quantificação objetiva de preferência alimentar em leitões processando centenas de milhares de eventos comportamentais e rastreamento contínuo de mobilidade em frangos - validam que com expertise científica, criatividade metodológica e disposição para experimentar é possível desenvolver aplicações de IA que geram conhecimento valioso e demonstram caminhos replicáveis para implementações futuras de maior escala.

A transição de protótipos científicos para sistemas operacionais robustos em ambientes comerciais representa salto que pode ser percorrido pela própria Embrapa ou, estrategicamente, através de parcerias que multipliquem impacto. Enquanto instituição pública de pesquisa, a Embrapa tem capacidade de desenvolver e validar metodologias científicas rigorosas, treinar modelos com dados de qualidade e disponibilizar tecnologias que múltiplas empresas podem adaptar aos seus contextos específicos, potencialmente gerando impacto mais amplo no setor produtivo do que soluções proprietárias isoladas. Parcerias estratégicas entre Embrapa, empresas de tecnologia e setor produtivo aceleram

a transformação de protótipos validados cientificamente em soluções comerciais acessíveis.

Esta transição, entretanto, demanda clareza sobre desafios práticos e investimentos necessários. Processamento de grandes volumes de vídeo demanda infraestrutura computacional adequada; gestão eficiente de dados requer conectividade moderna; *tracking* individual ainda enfrenta limitações técnicas específicas para cada espécie. Entretanto, mesmo reconhecendo estas limitações práticas, os benefícios potenciais justificam investimentos necessários para próximos passos. Detecção precoce de doenças, monitoramento objetivo de bem-estar, otimização de eficiência produtiva e rastreabilidade completa representam vantagens competitivas reais em mercados cada vez mais exigentes.

A lição mais valiosa dos experimentos baseados em vídeo transcende aplicações iniciais: conjuntos de dados coletados para responder uma pergunta científica permanecem disponíveis para múltiplas análises futuras completamente diferentes. Os mesmos 14 dias de gravação do experimento de palatabilidade podem responder questões sobre comportamento agonístico, padrões de descanso, detecção precoce de claudicação ou sinais comportamentais de doenças simplesmente retraindo modelos sobre material já existente. Um único investimento experimental se transforma em múltiplos estudos potenciais. A possibilidade de correlacionar dados de vídeo com outros sensores - comedouros automatizados, balanças contínuas, sensores ambientais - viabiliza compreensão integrada onde nutricionistas, geneticistas, especialistas em bem-estar, veterinários e engenheiros podem extrair valor dos mesmos dados, cada um formulando perguntas específicas de suas expertises.

Os próximos passos para a Embrapa Suínos e Aves envolvem simultaneamente consolidação do que já está realizado e expansão estratégica. Consolidação através de publicações científicas validando metodologias e resultados, refinamento contínuo dos modelos com *datasets* expandidos e validação em condições comerciais através de parcerias. Expansão através de novas aplicações identificadas como prioritárias, capacitação progressiva de membros da equipe e colaborações com universidades e setor produtivo. Mais fundamentalmente, este documento serve como catalisador para discussão sobre projeto de maior escala que empregue as tecnologias e competências adquiridas de forma coordenada: quais são os grandes desafios da suinocultura e avicultura brasileira onde IA pode fazer diferença real? Bem-estar animal monitorado objetivamente? Detecção ultra-precoce de doenças?

Rastreabilidade completa para mercados internacionais? Otimização de eficiência produtiva reduzindo impacto ambiental? O CLADIA existe para facilitar esta articulação, garantindo que conhecimento em IA se difunda transversalmente.

Para pesquisadores da Unidade: IA não é território exclusivo de cientistas da computação. Se você conhece profundamente seu sistema de produção, identifica o que é importante observar e quantificar e formula perguntas científicas claras então tem a expertise essencial. A máquina aprende o que se ensina; você traz o conhecimento zootécnico, veterinário, nutricional e genético que dá sentido aos dados. Parcerias internas entre áreas multiplicam potencial: seus vídeos podem servir simultaneamente para estudos de bem-estar, nutrição, genética e sanidade.

Para empresas do setor produtivo: rastreabilidade, bem-estar certificado e produção sustentável tornaram-se requisitos crescentes de mercados consumidores sofisticados. IA viabiliza documentar objetivamente práticas que agregam valor comercial. Empresas que dominarem estas tecnologias primeiro terão vantagens competitivas significativas. Parcerias com Embrapa permitem acessar expertise científica e validação rigorosa que podem acelerar desenvolvimento e reduzir riscos de investimento.

Para gestores e formuladores de política científica: este trabalho demonstra capacidade da Embrapa de entregar inovação relevante. Investimento estratégico em infraestrutura especializada - servidores com GPUs dedicadas, câmeras de qualidade, sistemas de armazenamento robusto e recursos humanos especializados - multiplicaria a capacidade de execução. É importante que nossa pesquisa agropecuária, área onde somos globalmente competitivos, acompanhe ou posicione-se tecnologicamente à frente de concorrentes que investem massivamente em agricultura e pecuária de precisão.

Este documento registra não uma conclusão, mas um início que valida que o caminho é viável, os desafios são superáveis e os retornos justificam os investimentos. As aplicações apresentadas representam apenas pequena fração do potencial. O ritmo e profundidade da transformação que virá dependerão do comprometimento coletivo, investimento institucional adequado e capacidade de articular parcerias estratégicas. A infraestrutura está sendo construída, metodologias foram validadas, competências estão sendo desenvolvidas. O que se segue é processo sustentado ao longo de anos que demanda visão de longo prazo, resiliência diante de obstáculos inevitáveis e convicção de que modernização tecnológica da pesquisa agropecuária é imperativo estratégico para o Brasil.

## Referências

- ABADI, M. et al. **TensorFlow**: large-scale machine learning on heterogeneous systems. 2015. Disponível em: <https://www.tensorflow.org/>. Acesso em: 28 nov. 2024.
- ASSOCIAÇÃO BRASILEIRA DE PROTEÍNA ANIMAL. **Sectoral statistics**: production and export. São Paulo: ABPA, 2024. Disponível em: <https://abpa-br.org/mercados/#sectoral-statistics>. Acesso em: 27 nov. 2024.
- AYDIN, A. Automatic identification of activity and spatial use of broiler chickens with different gait scores. **Transactions of the ASABE**, v. 56, n. 3, p. 1123-1135, 2013.
- CLOSE, W. H.; COLE, D. J. A. **Nutrition of sows and boars**. Nottingham: Nottingham University Press, 2000.
- DAWKINS, M.S.; CAIN, R.; ROBERTS, S.J. *Optical flow*, flock behaviour and chicken welfare. **Animal Behaviour**, v. 84, n. 1, p. 219-223, 2009.
- D'EATH, R. B.; PICKUP, H. E. Behaviour of young growing pigs in a resident-intruder test designed to measure aggressiveness. **Aggressive Behavior**, v. 28, n. 5, p. 401-415, 2002.
- FEDDES, J. J. R.; FRASER, D. Non-nutritive chewing by pigs: implications for tail-biting and behavioral enrichment. **Transactions of the ASAE**, v. 37, n. 3, p. 947-950, 1994.
- FORBES, J. M. **Voluntary food intake and diet selection in farm animals**. 2nd ed. Wallingford: CABI, 2007.
- HELD, S.; MENDEL, M.; DEVEREUX, C.; BYRNE, R. W. Social tactics of pigs in a competitive foraging task: the 'informed forager' paradigm. **Animal Behaviour**, v. 59, n. 3, p. 569-576, 2000.
- JOCHER, G. et al. **Ultralytics YOLOv8**. 2023. Disponível em: <https://github.com/ultralytics/ultralytics>. Acesso em: 28 nov. 2024.
- KOCH, G.; ZEMEL, R.; SALAKHUTDINOV, R. Siamese neural networks for one-shot image recognition. In: ICML *Deep learning* WORKSHOP, 2015. **Proceedings....** [S.l.: s.n.], 2015. v. 2.
- LAWRENCE, A. B.; APPLEBY, M. C. Welfare of extensively farmed animals: pigs. **Applied Animal Behaviour Science**, v. 49, n. 1, p. 233-245, 1996.
- MARTIN, P.; BATESON, P. **Measuring behaviour**: an introductory guide. 3rd ed. Cambridge: Cambridge University Press, 2007.
- MATTHEWS, S. G.; MILLER, A. L.; CLAPP, J.; PLÖTZ, T.; KYRIAZAKIS, I. Early detection of health and welfare compromises through automated detection of behavioural changes in pigs. **The Veterinary Journal**, v. 217, p. 43-51, 2016.
- PADILLA, R.; LIMA NETO, S.; SILVA, E. A. B. da. A survey on performance metrics for object-detection algorithms. In: INTERNATIONAL CONFERENCE ON SYSTEMS, SIGNALS AND IMAGE PROCESSING, 2020. **Proceedings....** Piscataway: IEEE, 2020. p. 237-242.
- PEZZUOLO, A.; GUARINO, M.; SARTORI, L.; GONZÁLEZ, L. A.; MARINELLO, F. On-barn pig weight estimation based on body measurements by a Kinect v1 depth camera. **Computers and Electronics in Agriculture**, v. 148, p. 29-36, 2018.
- REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. *You Only Look Once*: unified, real-time object detection. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2016, Las Vegas. **Proceedings....** Piscataway: IEEE, 2016. p. 779-788.
- SEKACHEV, B. et al. **Computer Vision Annotation Tool (CVAT)**. Zenodo, 2020. Disponível em: <https://github.com/opencv/cvat>. Acesso em: 28 nov. 2024.
- TONA, K.; BAMELIS, F.; DE KETELAERE, B.; BRUGGEMAN, V.; MORAES, V. M.; BUYSE, J.; ONAGBESAN, O.; DECUYPERE, E. Effects of egg storage time on spread of hatch, chick quality, and chick juvenile growth. **Poultry Science**, v. 82, n. 5, p. 736-741, 2003. DOI: 10.1093/ps/82.5.736.
- VAN DER SLUIS, M.; ELLEN, E.D.; DE KLERK, B.; SIEGFORD, J.; RODENBURG, T.B. Individuality of a group: detailed walking ability analysis of broiler flocks using *optical flow* approach. **Smart Agricultural Technology**, v. 5, p. 100272, 2023.
- VAN ROSSUM, G.; DRAKE, F. L. **Python 3 reference manual**. Scotts Valley: CreateSpace, 2009.
- WILSON, H. R. Physiological requirements of the developing embryo: temperature and turning. In: TULLETT, S. G. (ed.). **Avian incubation**. London: Butterworth-Heinemann, 1991. p. 145-156.
- ZHU, Z. H.; YE, Z. F.; TANG, Y. Nondestructive identification for gender of chicken eggs based on GA-BPNN with double hidden layers. **Journal of Applied Poultry Research**, v. 30, 100203, 2021. DOI: <https://doi.org/10.1016/j.japr.2021.100203>.

