

VISÃO COMPUTACIONAL PARA IDENTIFICAR AGLOMERAÇÃO DE AVES CONFINADAS

Jhonny Mezzari Bif¹, Sergio Coral²

Resumo: A aglomeração de frangos em aviários representa um problema com impacto direto no bem-estar animal e na eficiência produtiva, exigindo soluções tecnológicas que permitam identificar e mitigar situações de risco. Este trabalho tem como objetivo desenvolver uma ferramenta de visão computacional baseada em inteligência artificial capaz de detectar e quantificar aglomerações de frangos confinados, fornecendo indicadores para apoio ao manejo preventivo. A metodologia emprega o modelo YOLO11 para detecção das aves e aplica homografia para projetar seus centros no plano real, agregando as ocorrências em uma malha espacial de 1 m^2 , comparada a limites de ocupação definidos por idade e peso. O sistema web desenvolvido recebe imagens e vídeos, processa os dados no *backend* e retorna sobreposições de malha e mapas de calor para interpretação visual imediata. A avaliação utilizou o conjunto público *Project M1 Poussins* (563 imagens) e registros reais de aviários, atingindo, no melhor modelo (YOLO11m treinado por 1000 épocas), métricas de mAP50 de 0,819, precisão de 0,817, *recall* de 0,768 e F1-Score de 0,791, demonstrando desempenho consistente na detecção das aves. Os resultados demonstram que a abordagem proposta avança além da simples contagem e rastreamento, ao estabelecer um critério operacional de aglomeração por área e oferecer uma interface aplicada para o monitoramento automatizado do bem-estar animal.

Palavras-chave: inteligência artificial; YOLO; avicultura; bem-estar animal; detecção de aglomeração; homografia.

¹Curso de Ciência da Computação, Universidade do Extremo Sul Catarinense (Unesc), jhonnybif@unesc.net

²Orientador. Curso de Ciência da Computação, Universidade do Extremo Sul Catarinense (Unesc), sergiocoral@unesc.net

ABSTRACT: The crowding of broiler chickens in poultry houses is a problem that directly impacts animal welfare and production efficiency, demanding technological solutions capable of identifying and mitigating risky situations. This work aims to develop an artificial intelligence–based computer vision tool capable of detecting and quantifying crowding among confined broilers, providing indicators to support preventive management. The methodology employs the YOLO11 model for bird detection and applies homography to project their centers onto the real plane, aggregating occurrences on a 1 m^2 spatial grid compared with occupancy limits defined by age and weight. The developed web system receives images and videos, processes the data on the backend, and returns grid overlays and heat-maps for immediate visual interpretation. Evaluation used the public *Project M1 Poussins* (563 images) and real poultry-house recordings, achieving, in the best-performing model (YOLO11m trained for 1000 epochs), mAP50 of 0.819, precision of 0.817, recall of 0.768, and F1-score of 0.791, evidencing robust performance in bird detection. The results show that the proposed approach goes beyond simple counting and tracking by establishing an operational area-based crowding criterion and providing an applied interface for automated monitoring of animal welfare.

Keywords: artificial intelligence; YOLO; poultry farming; animal welfare; crowding detection; homography.

1 INTRODUÇÃO

A produção avícola desempenha um papel de destaque na economia brasileira. Em 2023, o Brasil firmou-se como o segundo maior produtor de carne de frango do mundo, atrás apenas dos Estados Unidos, e liderou as exportações globais, chegando a ultrapassar os 5 milhões de toneladas comercializadas, gerando uma receita superior a 9 bilhões de dólares (ABPA, 2024). Este cenário reforça a importância de práticas que assegurem não apenas a produtividade, mas também o bem-estar dos animais.

Dentre os variados desafios enfrentados pela avicultura moderna, destaca-se a ocorrência de aglomerações de frangos nos ambientes confinados. No que pode resultar em sufocamento e mortalidade significativa, especialmente quando associado a fatores como pânico, superlotação em áreas ou repetições comportamentais recorrentes (Subedi et al., 2023). A detecção antecipada e o monitoramento eficiente desses eventos tornam-

se elementos fundamentais tanto para a redução de perdas econômicas quanto para a melhoria do bem-estar animal.

Com os recentes avanços da inteligência artificial (IA) e visão computacional, tornou-se viável desenvolver sistemas capazes de identificar padrões comportamentais anormais em tempo real. Tecnologias baseadas em redes neurais convolucionais (CNN), como as implementadas em arquiteturas do tipo YOLO, já demonstraram alto desempenho na detecção e classificação de objetos (Elmessery et al., 2023). Além disso, abordagens integradas à Internet das Coisas (IoT) têm sido aplicadas com sucesso no monitoramento de condições ambientais e na análise do comportamento das aves, com impactos positivos na produtividade e na saúde dos animais (Santos et al., 2023).

O uso de tecnologias de visão computacional associadas ao aprendizado profundo tem se destacado de forma promissora para o monitoramento automatizado de frangos em ambientes confinados. Sendo assim, é possível identificar comportamentos anormais, como a formação de aglomerações, que muitas vezes resultam em sufocamento e aumento na taxa de mortalidade dos frangos (Yang et al., 2024a). Esses comportamentos, geralmente relacionados ao estresse, preferência por zonas aquecidas ou reações de pânico, comprometem significativamente tanto o bem-estar animal quanto a produtividade das granjas. A aplicação de redes neurais convolucionais (CNN) nesse caso pode auxiliar na tomada de decisão baseada em evidências, minimizando falhas humanas e promovendo um manejo mais eficiente e ético (Neethirajan, 2022).

O objetivo principal deste trabalho é implementar um sistema de visão computacional para detectar aglomerações de aves, contribuindo para a melhoria do bem-estar animal e para a eficiência produtiva. Para atingir esse objetivo, busca-se compreender os comportamentos de aglomeração dos frangos, interpretar os resultados gerados pela inteligência artificial, analisar os testes realizados e avaliar a eficácia do modelo de detecção por meio de indicadores como acurácia, precisão e recall na identificação de aglomerações. Como também ele deve ser um modelo computacional capaz de analisar imagens e detectar áreas com ocorrência de aglomeração. Além disso, buscou-se que o processamento dos dados ocorresse de forma dinâmica, visando reduzir ou até eliminar a necessidade de armazenamento físico. Por fim, pretendeu-se apresentar ao produtor os resultados da análise de maneira simples e acessível.

O Deep Learning, um método de Machine Learning, está se tor-

nando uma ferramenta essencial para analisar e identificar padrões em conjuntos de dados grandes e complexos. Em estudos sobre o comportamento animal, o Deep Learning tem sido de grande ajuda ao fornecer uma compreensão detalhada das ações dos animais. Na avicultura, ele oferece uma ferramenta para observar e rastrear de perto as atividades. (Yang et al., 2024b).

A cadeia produtiva avícola está consolidada no mercado, com um avanço constante há mais de 10 anos. (Lamarca et al., 2018). Com isso, sistemas de medição automatizados se tornam cada vez mais essenciais para monitorar e promover o bem-estar na crescente indústria aviária. Os avanços tecnológicos das últimas décadas têm impulsionado o desenvolvimento de sistemas de rastreamento animal por meio de imagens digitais automatizadas e precisas, ampliando sua aplicação e eficácia. (Yang et al., 2024a).

Dessa forma, as granjas avícolas a atenção com os frangos em relação à saúde, atividades e padrões comportamentais é essencial. Com os recursos de detecção da inteligência artificial, podem identificar os sinais da aglomeração, chegando a reconhecer mudanças sutis em seus comportamentos, auxiliando os produtores a agir corretamente e também evitando falhas humanas ao não conseguir identificar e/ou não ter a necessidade de ficar observando os frangos. Dessa forma, além de prover um bem-estar melhor para as aves, a tecnologia também pode prevenir prejuízos econômicos significativos. O trabalho foi proposto pelo desenvolvimento de um sistema que utilizou inteligência artificial, com o objetivo de identificar de maneira automática as aglomerações dos frangos utilizando imagens de câmeras que estavam instaladas dentro de um aviário. Dessa forma, foi possível identificar as regiões com maior concentração de frangos, que contribuiu para a prevenção de situações que poderiam comprometer o bem-estar animal.

Este TCC organiza-se em cinco capítulos: (1) Introdução, que delimita o problema das aglomerações em aviários, sua relevância, objetivos e justificativa; (2) Trabalhos correlatos, com revisão crítica de pesquisas em visão computacional e IA aplicadas ao monitoramento de aves; (3) Materiais e Métodos, descrevendo o modelo empregado (YOLO11m), o conjunto de imagens (Project M1 Poussins), o ambiente de coleta, procedimentos de treinamento e as métricas utilizadas; (4) Resultados e Discussão, apresentando os resultados de treinamento, validação e testes, a lógica de detecção e agregação espacial (malha de 1 m² e homografia), ma-

pas de calor e comparação com trabalhos correlatos; e (5) Conclusão, que sintetiza as contribuições, limitações e sugestões para trabalhos futuros.

2 TRABALHOS CORRELATOS

O estudo (Paneru et al., 2025) aplicou métodos de deep learning para identificação automática de galos e galinhas, com foco em características fenotípicas como tamanho da crista e dimensões corporais. Foram utilizadas variantes dos modelos YOLOv5u e YOLOv11, treinadas com conjuntos de imagens coletadas em instalações de pesquisa com seis galos e duzentas galinhas. Os resultados mostraram que os modelos YOLOv5lu e YOLOv11x apresentaram os melhores resultados na detecção baseada no tamanho da crista, alcançando precisão de 87,7% e 86,7%, respectivamente, enquanto os modelos YOLOv5xu e YOLOv11m se destacaram na detecção baseada no tamanho corporal, com precisão de até 89% e mAP@0.50 superior a 82%. O estudo mostrou que as técnicas de visão computacional podem ser aplicadas com sucesso para o monitoramento automatizado do comportamento e seleção de reprodutores, contribuindo para práticas de manejo mais precisas e sustentáveis na avicultura.

A pesquisa de (Guo et al., 2025) apresenta o PCCNet, uma rede densa supervisionada por pontos para contagem de frangos de corte em ambientes de alta densidade, com o objetivo de aprimorar a eficiência produtiva e o bem-estar animal. Que propõe um modelo que utiliza pontos como alvos de aprendizado, permitindo identificar e quantificar aves com maior precisão, mesmo em condições de sobreposição e aglomeração. A arquitetura incorpora um módulo de fusão de informações contextuais (CIFI), que combina características em múltiplas escalas, e o KMO matcher, responsável por aprimorar o pareamento entre pontos previstos e reais, reduzindo ambiguidades e melhorando a convergência do modelo. Para validação, foi desenvolvido o Chicken Counting Dataset (CCD), dividido em dois subconjuntos conforme a idade das aves (CCD_A e CCD_B), contendo 827 imagens anotadas. Os resultados experimentais demonstraram alta acurácia, com 97,85% e 97,06% de precisão nos subconjuntos CCD_A e CCD_B, e erros médios absolutos (MAE) de 1,966 e 5,173, respectivamente, superando métodos recentes baseados em mapas de densidade e frameworks supervisionados por pontos. Além disso, o PCCNet manteve desempenho robusto sob diferentes condições de iluminação e densidade, mostrando potencial para aplicação em granjas comerciais e extensibilidade para outras espécies aviárias.

Segundo (Yang et al., 2024a) onde foram desenvolvidos modelos de redes neurais convolucionais (CNN) para monitorar o índice de atividade de galinhas poedeiras em sistemas livres de gaiola, com o objetivo de avaliar o bem-estar e a saúde do plantel. Utilizando um conjunto de 1.500 imagens de vista superior, foram treinados e comparados seis modelos baseados em YOLOv5, YOLOv8, ByteTrack, DeepSORT e StrongSORT. A combinação de YOLOv8 com DeepSORT apresentou o melhor desempenho, com precisão de rastreamento (MOTA) de 94%. O modelo permitiu quantificar a atividade das aves em três níveis (baixo, médio e alto) e detectar comportamentos anormais, como sufocamento e empilhamento, demonstrando o potencial da visão computacional no acompanhamento da saúde avícola.

3 MATERIAIS E MÉTODOS

A caracterização da pesquisa é de natureza quantitativa e aplicada, foi desenvolvida e validada uma ferramenta baseada em inteligência artificial, destinada à identificação de aglomerações de frangos confinados. O estudo propõe uma solução computacional voltada a um desafio do setor e avaliou sua efetividade com base em métricas comumente utilizada nas IA, como acurácia, precisão e recall.

Para a realização do trabalho, foi utilizado uma câmera para a captação de imagens, sendo uma XM535 X6E WEQ de 4 Megapixels, um computador equipado com processador Ryzen 7 5700x, 32 GB de memória RAM e uma placa de vídeo RTX 4060 Ti 8gb e Windows 11 Pro, destinado à execução do treinamento e dos testes. Na parte do software, utilizou-se o Visual Studio Code como interface para programação, além do Python 3.13.3 com Flask 3.1.0 para a utilização do YOLO para o backend, enquanto o frontend foi desenvolvido em Angular 17. Como ferramenta de inteligência artificial, utilizou-se o YOLO 11 na versão medium. Por fim, as imagens foram obtidas em uma granja aviária, que serviu como ambiente de captação dos dados.

A análise dos dados foi revisada de forma quantitativa com base nas métricas geradas pelo modelo de IA, como as matrizes de confusão e as curvas de aprendizado, para base de comparação com os resultados reais, permitindo, assim, a avaliação efetiva do desempenho do sistema.


O método de coleta de dados foi obtido com gravações de vídeos que foram retirados de aviários reais, com diferentes condições de densidade populacional e comportamentais. Foram utilizados vídeos previamente gravados para que houvesse uma amostragem com diferentes

níveis de idade, peso, horários, população e aglomeração.

Para validar a eficácia da ferramenta, foram realizados testes com diferentes registros do aviário. Os resultados foram avaliados com base nas métricas de acurácia, precisão e recall, a fim de medir o desempenho do YOLO.

A Figura 1 apresenta as etapas realizadas para o desenvolvimento desta pesquisa, sendo elas: aquisição do conjunto de imagens, treinamento do Yolo 11m, validação, aquisição das imagens reais, testes e, por fim, os resultados e comparações.

Figura 1 - Etapas da Pesquisa



Fonte: Do autor.


3.1 YOLO - YOU ONLY LOOK ONCE

Entre os principais avanços na detecção de objetos em tempo real está a arquitetura *YOLO* onde o desempenho está baseado no uso de CNN. Diferente dos métodos comuns de detecção, que dividem a tarefa em duas etapas, primeiro localizando regiões de interesse e depois classificando os objetos, já o *YOLO* reformulou o problema como uma única tarefa de regressão. Ele divide a imagem em uma grade e, para cada célula, prevê diretamente a presença de objetos, suas coordenadas e probabilidades de classe, tornando o processo rápido e eficiente. A base do *YOLO* é uma CNN profunda, que processa a imagem de entrada extraindo carac-

terísticas visuais relevantes, permitindo que o modelo identifique e localize objetos simultaneamente (Jocher; Qiu, 2024).

Com sucessivas melhorias, arquiteturas integraram técnicas mais avançadas, aprimoramento na normalização dos dados e uso de *anchor boxes*, garantindo maior precisão e robustez no reconhecimento de objetos. Neste trabalho foi utilizada a versão mais recente (primeiro semestre de 2025), o *YOLO11*, por apresentar aprimoramentos significativos em velocidade, precisão e estabilidade em relação às versões anteriores, e em sua versão *Medium* (M), pois ela está em equilíbrio com o custo de processamento e os resultados obtidos pela versão do modelo, como mostrado na Figura 2 (Jocher; Qiu, 2024).

Figura 2 - Comparação de performance Yolo 11



Fonte: Jocher e Qiu (2024).

3.2 CONJUNTO DE IMAGENS DO TREINAMENTO

O conjunto de imagens utilizado para o treinamento desta pesquisa foi Project M1 Poussins Computer Vision Model (projetM1Poussins, 2024), que possui a licença *Public Domain* no qual se trata de domínio público, está disponível na plataforma Roboflow Universe (Dwyer et al., 2024). O Conjunto é constituído de apenas uma classe e totaliza 563 imagens, sendo 438 para treinamento, 81 para validações e outras 44 para testes.


Com o conjunto pré-treinado na plataforma do Roboflow utilizando o yolov8s (Yolo version 8 small) ele obteve as seguintes métricas *MAP@50* de 84.7%, *Precisão* de 79.8% e *Recall* de 78.9%. Foi realizado localmente dois treinamentos, ambos utilizando o Yolo11m (*Yolo 11 medium*), utilizando conjunto de imagens previamente pré-processado na plataforma Roboflow e mantendo a configuração padrão de treinamento, alterando somente a quantidade de épocas, sendo 400 épocas com uma paciência de 80, ou seja caso ele não evolua em 80 épocas ele para o

treinamento, já o outro treinamento foi com 1000 épocas com 400 de paciência.

3.3 ARQUITETURA

A Figura 3 apresenta a arquitetura geral desenvolvida nesta pesquisa.


Figura 3 - Arquitetura simplificada da pesquisa



Fonte: Do autor.

O processo inicia-se na aplicação web, responsável por receber do usuário um arquivo de imagem ou vídeo, conforme a Figura 4.

Figura 4 - Tela Inicial



Fonte: Do autor.

Em seguida, é selecionado o método de detecção desejado e, após a confirmação do envio, um modal é exibido para inserção das dimensões reais da área captada pela câmera (em metros) e da idade das aves, como na Figura 5.

Figura 5 - Inserção das dimensões

Selecionar Pontos

Ex: 1.5, corresponderá a 150cm

Superior: 1,5

Esquerda 1,5

Direita 1,5

Inferior 1,5

Superior*

13

Lateral Direita*

6.6

Inferior*

3.8

Lateral Esquerda*

5.1

Selecione para calcular aglomeração

☐ Enviar Data de entrada dos frangos e Data do vídeo

☒ Enviar idade dos frangos em dias

Idade dos frangos*

28

Em caso de data será feito o calculo para saber os dias

Fonte: Do autor.

Esses dados são então enviados para a *API*, onde ocorre o processamento das informações. A etapa inicial do processamento consiste na detecção das aves por meio de um modelo de visão computacional baseado em redes neurais, responsável por identificar os frangos e retornar as respectivas *bounding boxes*.

A homografia é então aplicada para relacionar os pontos detectados na imagem com suas posições correspondentes no plano real. A partir de valores de referência fornecidos pelo usuário, essa transformação permite converter as coordenadas da câmera em medidas físicas, corrigindo a perspectiva e possibilitando que a análise seja realizada em escala métrica.


A partir dessas delimitações, calcula-se o ponto central de cada ave e aplica-se a transformação de homografia para projetar esses pon-

tos no plano real, possibilitando a criação de uma malha espacial dividida em áreas equivalentes a $1m^2$. Em cada célula dessa malha é realizada a contagem de aves, sendo os valores comparados aos limites máximos de frangos por $1m^2$ de ocupação estabelecidos de acordo com a idade e o peso das aves, conforme diretrizes da Embrapa (Figueredo, 2022).

Quando o número de aves em uma célula ultrapassa o valor limite, que varia conforme a idade das aves e corresponde à quantidade de frangos por $1m^2$ definida pela Embrapa (ABPA, 2024), essa área é marcada como aglomeração. Paralelamente, é gerado um mapa de calor para representar visualmente o grau de densidade das aves, utilizando uma escala cromática que varia do verde (baixa densidade) ao vermelho (alta aglomeração).

Ao final do processamento, a *API* retorna à aplicação web os vídeos com a malha de distribuição espacial e o mapa de calor, acompanhados das métricas calculadas, conforme a Figura 6.

Figura 6 - Tela de resultados



Fonte: Do autor.

4 RESULTADOS E DISCUSSÃO

Para Avaliação dos resultados obtidos nesta pesquisa, partiremos de dois pontos sobre o modelo desenvolvido, primeiramente foram avaliados os resultados do conjunto de imagens, onde são apresentados as métricas de detecção das aves, posteriormente será exibido do desempenho da ferramenta completa.

4.1 TREINAMENTO DO CONJUNTO DE IMAGENS PROJECT M1 POUS-SINS

O treinamento conduzido localmente do conjunto de imagens *Project M1 Poussins* obteve os seguintes resultados, o melhor desempenho no treinamento de 400 épocas ocorreu na época 150, fazendo com que ele parasse na 230, como não houve evolução durante as 80 épocas seguintes, o treinamento foi encerrado neste ponto, portanto, trataremos como 230 épocas. Já no treinamento de 1000 épocas, o melhor resultado atingido foi na época 990, conforme os resultados apresentados do treinamento na Tabela 1.

Tabela 1 - Treinamento do conjunto de imagens

Treinamento do conjunto de imagens M1 poussins					
Épocas	F1 Score	mAP50	Recall	Precisão	mAP50-95
230	0.783	0.833	0.773	0.794	0.430
1000	0.778	0.830	0.735	0.828	0.444

Fonte: Do autor.

As Figuras 7 e 8 apresentam, as métricas de de precisão e mAP50, levando em consideração a métrica de mAP50, no treinamento de 230 épocas ele estabilizou a cima de 0.800 após a época 80 e precisão a cima de 0.750 após a época 63. Já no treinamento de 1000 épocas ele estabilizou a 0.800 também após a época 80, e precisão a cima de 0.750 após a época 52, mostra que método de treinamento do Yolo consegue se manter constante no seu treinamento.





Figura 8 - Métricas de mAP50 e mAP50-95 geradas no Treinamento



Fonte: Do autor.

Após o treinamento realizado, foi utilizado o método de validação que o Yolo nos proporciona juntamente com as 81 imagens que o conjunto de imagens nos fornece, segue a Tabela 2.

Tabela 2 - Validação do conjunto de imagens
Validação do conjunto de imagens M1 poussins

Épocas	F1 Score	mAP50	Recall	Precisão	mAP50-95
230	0.773	0.804	0.720	0.835	0.450
1000	0.780	0.811	0.735	0.827	0.466

Fonte: Do autor.

Com a validação concluída, foi realizado o método de teste que o Yolo nos fornece, com as 41 imagens de testes que o conjunto de imagens nos disponibiliza. Segue a Tabela 3 com os resultados.

Tabela 3 - Teste do conjunto de imagens
Teste do conjunto de imagens M1 poussins

Épocas	F1 Score	mAP50	Recall	Precisão	mAP50-95
230	0.788	0.808	0.746	0.837	0.450
1000	0.791	0.819	0.768	0.817	0.450

Fonte: Do autor.

Após a análise dos resultados de treinamento, validação e teste do conjunto, foi escolhido dar prosseguimento a pesquisa com o conjunto de imagens que foi treinado por 1000 épocas.

4.2 LÓGICA DA AGLOMERAÇÃO

Como base para a lógica da detecção de aglomeração foi utilizado o modo *predict* do Yolo 11, onde este método apenas localiza e nos entrega a localização dos frangos, a Figura 9, foi extraída do aviário, a partir de um vídeo com 22 frames, onde ele detectou uma média de 229 frangos, estando configurado para detectar apenas frangos com a confiança acima de 0.7.

Figura 9 - Utilizando apenas a detecção




Fonte: Do autor.

Para realizar as métricas utilizamos a seguinte Figura 10, sendo

definidos seis quadrados aleatoriamente na imagem de tamanho 400x400 px cada, deste modo pode-se estimar métricas aproximadas.

Figura 10 - Utilizando apenas a detecção



Fonte: Do autor.

Como foi realizado essa contagem, cada quadrado foram dividido em métricas, Total que é a quantidade total de frangos dentro do quadrado, Encontrado que é o que o Yolo identificou, Falsos o que o Yolo identificou e não era frango, dados na Tabela 4.

Tabela 4 - Métricas aproximadas dos quadrados de contagem

Métricas aproximadas dos quadrados de contagem				
Quadrado	Total (Real)	Encontrado(TP)	Falsos(FP)	FN
Q1	79	37	0	42
Q2	39	23	1	16
Q3	35	21	0	14
Q4	17	7	0	10
Q5	7	5	0	2
Q6	14	10	0	4
Total	191	103	1	88

Fonte: Do autor.

A precisão indica a proporção de detecções corretas (TP) entre todas as detecções feitas (TP + FP). No exemplo, 103 detecções corretas de 104 totais resultaram em 0.990, mostrando alta confiabilidade nas pre-

dições positivas.

$$Precision = \frac{TP}{TP + FP} = \frac{103}{103 + 1} = \frac{103}{104} = 0.990$$

O recall mede a proporção de frangos corretamente identificados (TP) sobre todos os frangos reais (TP + FN). Aqui, 103 frangos detectados corretamente de 191 totais deram 0.539, indicando que nem todos os frangos foram capturados.

$$Recall = \frac{TP}{TP + FN} = \frac{103}{103 + 88} = \frac{103}{191} = 0.539$$

A acurácia amostral mostra a fração de predições corretas em relação ao total de casos avaliados. Com 103 acertos em 191 frangos, obtém-se 0.539, refletindo o desempenho geral do modelo na amostra.

$$Acurcia\ Amostr\ al = \frac{TP}{TP + FP + FN} = \frac{103}{103 + 1 + 88} = \frac{103}{192} = 0.536$$

O F1-Score combina precisão e recall numa única métrica balanceada, usando a média harmônica. Com os valores de precisão 0.990 e recall 0.539, o resultado de 0.695 mostra um equilíbrio entre acertos e cobertura.


$$F1-Score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} = 2 \cdot \frac{0.990 \cdot 0.539}{0.990 + 0.539} = 0.698$$

Os resultados apresentados são aproximados e refletem o desempenho do modelo na amostra avaliada: a alta precisão (0.990) indica confiabilidade nas detecções positivas, enquanto o recall e a acurácia amostral (0.539) evidenciam que o modelo apresenta baixa capacidade de recuperar todas as aves presentes caso elas estejam sobrepostas, resultando em subdetecção. O F1-Score (0.695) fornece uma medida balanceada entre precisão e cobertura.

Na Figura 11, observa-se a malha utilizada para definição de aglomeração, em que cada quadrado representa aproximadamente $1m^2$. No canto superior esquerdo de cada célula é exibida a quantidade de frangos detectados e, caso o valor ultrapasse o limite estabelecido com base na idade, a marcação “AGLOMERAÇÃO” é exibida. A contagem é realizada a partir do ponto central de detecção, representado por um ponto azul. Esse critério, embora simples e eficiente, apresenta uma limitação: quando a ave aparece na região de divisão entre duas células, o centro é atribuído apenas a uma delas, o que pode gerar pequenas variações na distribuição

espacial.


Figura 11 - Malha



Fonte: Do autor.

A Figura 12 que é o mapa de calor, ele funciona com a base da malha, quando não houver frangos ele não pintará, a partir de um frango ele começará a pintar, sendo abaixo de 60% ele pintará o quadro de verde, acima de 60% ele vai evoluindo o degradê do verde até o vermelho onde o é o limite da aglomeração, caso ele ultrapasse este limite ele ficará vermelho forte.

Figura 12 - Mapa de calor



Fonte: Do autor.

4.3 DISCUSSÃO

Nesta seção são discutidos os resultados obtidos em comparação com os trabalhos correlatos. Observa-se que pesquisas relacionadas, como as de (Yang et al., 2024a) e (Guo et al., 2025), têm explorado técnicas de visão computacional na avicultura, porém com enfoques distintos do deste estudo. Enquanto (Yang et al., 2024a) utilizam detecção para rastreamento e análise comportamental individual, seu modelo apresentou desempenho limitado em cenários de alta densidade, com precisão média próxima de 93%, evidenciando dificuldades na sobreposição de objetos. De maneira semelhante, (Guo et al., 2025) propuseram a PCCNet para contagem de aves, alcançando erro médio absoluto (MAE) de 5,17 aves por quadro e foco exclusivo na contagem populacional, sem propor uma métrica para identificar aglomeração. De contra forma essa pesquisa aplica uma detecção com análise de densidade por área como critério de risco, sendo capaz de identificar regiões críticas no aviário, mantendo alta precisão mesmo em agrupamentos maiores (mAP de aproximadamente 0,990).

Além disso, diferentemente do estudo de (Paneru et al., 2025), que utiliza detecção de objetos exclusivamente para diferenciação entre machos e fêmeas com taxa de acurácia de 95,40%, este estudo direciona a aplicação da IA para análise coletiva e comportamental, com foco explícito no bem-estar animal. Ao integrar detecção com análise espacial, o sistema desenvolvido foi capaz de identificar automaticamente áreas com alta densidade, caracterizando aglomerações, um parâmetro ausente nos trabalhos correlatos. Com precisão aproximada de 99% e taxa de falsos positivos reduzida, os resultados demonstram que a abordagem aqui proposta representa um avanço aplicado em relação às soluções existentes, permitindo não apenas detectar aves, mas gerar um diagnóstico situacional do ambiente, contribuindo para intervenções preventivas no manejo.

5 CONCLUSÃO

O desenvolvimento deste trabalho teve como objetivo propor uma solução baseada em inteligência artificial para detecção de aglomeração de frangos em aviários. Os resultados mostraram que o sistema identificou, com elevada precisão ($mAP \approx 0,990$), regiões de alta densidade de aves por meio da análise espacial em metros quadrados. Contudo, embora o modelo apresente alta precisão ($\approx 0,99$), o recall obtido em imagens reais permaneceu baixo ($\approx 0,54$), indicando que parte das aves não é detectada devido à sobreposição e à perspectiva da câmera. Essa limitação re-

duz a confiabilidade da malha de aglomeração, pois algumas áreas podem parecer menos densas do que realmente são. Ainda assim, foi possível identificar situações de risco ao bem-estar animal, como mortalidade por esmagamento associada a calor excessivo.

Comparado à literatura, este trabalho avançou ao não se limitar à detecção ou contagem, mas ao fornecer uma interpretação mais ampla do comportamento coletivo. Enquanto estudos anteriores focaram em rastreamento individual ou contagem populacional, a abordagem proposta destaca-se por oferecer uma métrica objetiva de aglomeração em tempo real. Entretanto, o baixo *recall* evidencia a necessidade de aprimorar a robustez da detecção, já que a subdetecção pode levar à subestimação de áreas críticas. Ainda assim, a solução contribui para a avicultura moderna ao integrar monitoramento automatizado e bem-estar animal, oferecendo indicadores relevantes ao manejo.

Por fim, conclui-se que, embora os resultados tenham sido satisfatórios, trabalhos futuros podem aprimorar a abordagem com detecção dinâmica além da malha fixa, integração de sensores e alertas automáticos. Além disso, elevar o *recall* dado seu impacto direto na consistência da análise espacial. Assim, esta pesquisa abre caminhos para novas aplicações de visão computacional na avicultura, reforçando seu papel na inovação tecnológica e na melhoria contínua das condições de produção.

REFERÊNCIAS

ABPA. **Relatório Anual 2024**. 2024. Acesso em: 26 maio. 2025. Disponível em: <https://abpa-br.org/wp-content/uploads/2024/04/ABPA-Relatorio-Anual-2024_capa_frango.pdf>.

DWYER, B. et al. **Roboflow (Version 1.0) [Software]**. Roboflow, 2024. Acesso em: 19 set. 2025. Disponível em: <<https://roboflow.com>>.

ELMESSERY, W. M. et al. **Yolo-based model for automatic detection of broiler pathological phenomena through visual and thermal images in intensive poultry houses**. Agriculture, 2023, v. 13, n. 8. ISSN 2077-0472.

FIGUEREDO, E. A. P. d. **Metas de desempenho para frangos de corte: Embrapa 021**. Concórdia, 2022. 24 p. Acesso em: 11 out. 2025. Disponível em: <<http://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/1148818>>.

GUO, Y. et al. **Pccnet: A point supervised dense chickens flock counting network**. Smart Agricultural Technology, 2025, v. 10, p. 100795. ISSN 2772-3755. Acesso em: 17 set. 2025. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2772375525000292>>.

JOCHER, G.; QIU, J. **Ultralytics YOLO11**. 2024. Acesso em: 17 set. 2025. Disponível em: <<https://github.com/ultralytics/ultralytics>>.

LAMARCA, D. et al. **Climate change in layer poultry farming: Impact of heat waves in region of bastos, brazil**. Brazilian Journal of Poultry Science, 2018, Fundação de Apoio à Ciência e Tecnologia Avícolas, v. 20, n. 4, p. 657–664. ISSN 1516-635X.

NEETHIRAJAN, S. **Affective state recognition in livestock—artificial intelligence approaches**. Animals, 2022, v. 12, n. 6. ISSN 2076-2615.

PANERU, B. et al. **Deep learning methods for automatic identification of male and female chickens in a cage-free flock**. Animals, 2025, v. 15, n. 13. ISSN 2076-2615. Acesso em: 13 jul. 2025. Disponível em: <<https://www.mdpi.com/2076-2615/15/13/1862>>.

PROJTM1POUSSINS. Open Source Dataset, **projet M1 poussins Dataset**. Roboflow, 2024. Acesso em: 17 set. 2025. Disponível em: <https://universe.roboflow.com/projetm1poussins/projet_m1_poussins>.

SANTOS, I. et al. **Aplicação de Internet das Coisas (IOT) e Inteligência Artificial (IA) para gestão de aviários e melhorias do desempenho produtivo: um estudo de caso em produtores de uma cooperativa agroindustrial**. Porto Alegre, RS, Brasil: SBC, 2023. 151–158 p. ISSN 2177-9724.

SUBEDI, S. et al. **Tracking pecking behaviors and damages of cage-free laying hens with machine vision technologies**. Computers and Electronics in Agriculture, 2023, v. 204, p. 107545. ISSN 0168-1699.

YANG, X. et al. **Monitoring activity index and behaviors of cage-free hens with advanced deep learning technologies**. Poultry Science, 2024, v. 103, n. 11, p. 104193. ISSN 0032-5791.

YANG, X. et al. **Deep learning methods for tracking the locomotion of individual chickens**. Animals, 2024, v. 14, n. 6. ISSN 2076-2615.