

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”

FACULDADE DE CIÊNCIAS E ENGENHARIA

Programa de Pós-Graduação em Agronegócio e Desenvolvimento

**PREFERÊNCIA DE GALINHAS PARA DIFERENTES COMPRIMENTOS DE ONDA
DE LUZ USANDO DEEP LEARNING**

ALLAN LINCOLN RODRIGUES SIRIANI

Tupã - SP

2022

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”

FACULDADE DE CIÊNCIAS E ENGENHARIA

Programa de Pós-Graduação em Agronegócio e Desenvolvimento

**PREFERÊNCIA DE GALINHAS PARA DIFERENTES COMPRIMENTOS DE ONDA
DE LUZ USANDO DEEP LEARNING**

ALLAN LINCOLN RODRIGUES SIRIANI

Dissertação apresentada ao Programa de Pós-Graduação em Agronegócio e Desenvolvimento da Universidade Estadual Paulista “Júlio de Mesquita Filho”, Câmpus de Tupã, como requisito para a obtenção do título de Mestre em Agronegócio e Desenvolvimento.

Área de concentração: Agronegócio e Desenvolvimento

Linha de pesquisa: Desenvolvimento e Meio Ambiente

Orientador: Prof. Dr. Danilo Florentino Pereira

Coorientadores: Dr. Luiz Roberto A. Gabriel Filho
Dr. Reinaldo de Bernardi

Tupã - SP

2022

Ficha catalográfica elaborada pela Seção Técnica de Biblioteca e Documentação da FCE – Unesp, Câmpus Tupã:

S78p	Siriani, Allan Lincoln Rodrigues. Preferência de galinhas para diferentes comprimentos de onda de luz usando deep learning. / Allan Lincoln Rodrigues Siriani. – Tupã: [s.n.],2022. 63 f. : il. Dissertação (Mestrado em Agronegócio e Desenvolvimento) – Universidade Estadual Paulista UNESP – Faculdade de Ciências e Engenharia, 2022. Orientador: Danilo Florentino Pereira Coorientador: Luiz Roberto A. Gabriel Filho Coorientador: Reinaldo de Bernardi 1. Análise de Imagens. 2. Aprendizado de Máquina. 3. Comportamento Animal. 4. Filtro de Kalman. 5. YOLO. 6. Zootecnia de Precisão. I. Título. II. Autor.
------	--

Fonte: Eliana Kátia Pupim, bibliotecária CRB 8 – 6202.


CERTIFICADO DE APROVAÇÃO


**TÍTULO DA DISSERTAÇÃO: PREFERÊNCIA DE GALINHAS PARA DIFERENTES
COMPRIMENTOS DE ONDA DE LUZ USANDO DEEP
LEARNING**

AUTOR: ALLAN LINCOLN RODRIGUES SIRIANI
ORIENTADOR: DANILO FLORENTINO PEREIRA
COORIENTADOR: LUIZ ROBERTO A. GABRIEL FILHO
COORIENTADOR: REINALDO DE BERNARDI

Aprovada como parte das exigências para obtenção do Título de Mestre em
AGRONEGÓCIO E DESENVOLVIMENTO, pela Comissão Examinadora:


Prof. Dr. DANILO FLORENTINO PEREIRA (Participação Virtual)
Departamento de Gestão Desenvolvimento e Tecnologia / Faculdade de Ciências e Engenharia - FCE - UNESP
- Tupã/SP


Prof. Dr. MARIO MOLLO NETO (Participação Virtual)
Departamento de Engenharia de Biossistemas / Faculdade de Ciências e Engenharia - FCE - UNESP -
Tupã/SP


Profa. Dra. KÉSIA OLIVEIRA DA SILVA MIRANDA (Participação Virtual)
Departamento de Engenharia de Biossistemas / Escola Superior de Agricultura Luiz de Queiróz - ESALQ - USP
- Piracicaba/SP

Tupã, 28 de janeiro de 2022.

DEDICATÓRIA

À minha amada esposa Tatiana e a meus filhos, Beatriz, João e Isis por todo amor, incentivo, apoio e compreensão. Nada disso teria sentido se vocês não existissem na minha vida.

AGRADECIMENTOS

Agradeço a minha esposa, Tatiana, pelo apoio na contagem das aves.

Agradeço a Prof. Dra. Daniella Jorge de Moura e Vanessa Kodaira e pela ajuda, compartilhamento dos experimentos e orientação nos vídeos.

Agradeço a meus filhos, Beatriz, João e Isis por entender a minha ausência em muitas horas de processamento dos vídeos.

Agradeço ao comitê de coorientação: Prof. Dr. Luiz Roberto A. Gabriel Filho e Prof. Dr. Reinaldo de Bernardi, por todo auxílio e contribuição para este trabalho.

Agradeço ao Centro de Inovação no Agronegócio pelo apoio e ajuda na execução desse trabalho.

SIRIANI, A.L.R. Preferência de galinhas para diferentes comprimentos de onda de luz usando deep learning. 2022.63f. Dissertação (Mestrado em Agronegócio e Desenvolvimento) – Faculdade de Ciências e Engenharia, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Tupã, 2022.

RESUMO

O objetivo deste trabalho foi desenvolver um modelo de rede neural convolucional utilizando *Deep Learning* e *Framework* YOLO para identificar e localizar galinhas em vídeos gravados em ambientes com baixa iluminação e pouco contraste e desenvolver um algoritmo para rastrear a movimentação das aves nessas condições. O modelo foi gerado e posteriormente aplicado em vídeos de um experimento de comportamento de preferência de galinhas da linhagem H&N Brown Nick por três ambientes de iluminação monocromática (branco, vermelho e verde). As aves tinham livre acesso e trânsito a esses compartimentos. Além dos tratamentos de iluminação, foram testados três tratamentos de temperatura: calor (35°C), termoneutro (24°C) e frio (17°C). Os vídeos foram gravados em baixa iluminação (~5 lx) com auxílio de fonte de iluminação *near infrared* da própria câmera, resultando em imagens em escala de cinza de baixa qualidade e baixo contraste das aves com o restante do ambiente. O modelo gerado apresentou resultados de 99,9% de acurácia para a identificação e localização das aves nos compartimentos da câmara de preferência. A partir da identificação das aves, foi possível identificar o tempo de permanência das aves em 648 horas de vídeo. A análise dos resultados indicou que as galinhas têm preferência em permanecer no ambiente com luz branca, seguida da vermelha e verde. Na condição de calor foi observado uma distribuição mais igualitária das aves entre os compartimentos, de modo que essa dispersão das aves é indício de que a condição térmica sobrepõe a preferência das aves pelo ambiente luminoso. A partir da localização das aves, foi desenvolvido um algoritmo para análise da movimentação (rastreamento) das aves usando filtro de Kalman, onde foi possível seguir as aves individualmente e medir a distância percorrida de cada indivíduo. As técnicas de visão computacional aplicadas nesta pesquisa podem vir a ser aperfeiçoadas e aplicadas futuramente em condições comerciais, contribuindo para a melhoria da produção e bem-estar das aves.

Palavras-chave: Análise de imagens. Estresse térmico. Comportamento animal. Filtro de Kalman. YOLO. Zootecnia de precisão.

SIRIANI, A.L.R. Chicken preference for different wavelengths of light using deep learning. 2022.63p. Dissertation (Master in Agribusiness and Development) - Faculty of Science and Engineering, Universidade Estadual Paulista "Júlio de Mesquita Filho", Tupã, 2022.

ABSTRACT

The objective of this work was to develop a convolutional neural network model using Deep Learning and YOLO *framework* to identify and locate chickens in videos recorded in low-light and low-contrast environments and to develop an algorithm to track the movement of birds in these conditions. The model was generated and later applied to videos of a preference behavior experiment of H&N Brown Nick hens by three monochromatic lighting environments (white, red and green). The birds had free access and transit to these compartments. In addition to the lighting treatments, three temperature treatments were tested: heat (35°C), thermoneutral (24°C) and cold (17°C). The videos were recorded in low lighting (~5 lx) with the aid of the camera's own near infrared light source, resulting in low quality grayscale images and low contrast of the birds with the rest of the environment. The generated model presented results of 99.9% of accuracy for the identification and location of birds in the compartments of the chamber of preference. From the identification of the birds, it was possible to identify the length of stay of the birds in 648 hours of video. The analysis of the results indicated that the chickens prefer to remain in the environment with white light, followed by red and green. In the heat condition, a more egalitarian distribution of birds between the compartments was observed, so that this dispersion of birds is an indication that the thermal condition overrides the preference of birds for the bright environment. From the location of the birds, an algorithm was developed to analyze the movement (tracking) of the birds using a Kalman filter, where it was possible to follow the birds individually and measure the distance traveled by each individual. The computer vision techniques applied in this research can be improved and applied in the future under commercial conditions, contributing to birds' production improvement and welfare.

Keywords: Image analysis. Machine learning. Animal behavior. Kalman filter. YOLO. Precision Livestock Farming.

LISTA DE FIGURAS

Figura 1. Sensibilidades dos quatro cones nos comprimentos de onda.	19
Figura 2. Exemplo de uma arquitetura de uma rede <i>Deep</i>	23
Figura 3. Arquitetura do YOLO-v3.	25
Figura 4. Esquema da câmera de preferência.	29
Figura 5. Diagrama das etapas metodológicas da aplicação de Deep Learning.	31
Figura 6. Amostra de imagem de treinamento.	32
Figura 7. Anotação na imagem de treinamento.	33
Figura 8. Método implementado em Python das equações da atualização do tempo.	36
Figura 9. Método atualização da medição de estado implementado em Python.	36
Figura 10. Estágios do experimento de validação do sistema de rastreamento.	37
Figura 11. Coordenadas do quadro que delimita uma ave reconhecida pela rede YOLO.	38
Figura 12. Perda de aprendizado durante o treinamento.	39
Figura 13. Exemplo de imagem onde o modelo errou.	41
Figura 14. Tempo de permanência acumulado em horas em cada tratamento combinado de luz e temperatura.	42
Figura 15. Mediana do número de galinhas por tratamento de iluminação e período do dia. (A) no período da manhã. (B) no período da tarde.	43
Figura 16. Percentual de permanência por tratamento e período do dia.	44
Figura 17. Intervalos de confiança para média do número de galinhas observados em cada tratamento combinado de ambiente e iluminação.	45
Figura 18. Gráfico de Interação para o número de galinhas observado em cada tratamento combinado de temperatura e iluminação.	46
Figura 19. Imagem real capturada pelas câmeras de vídeo das salas posicionadas lado a lado.	47
Figura 20. Boxplot do número de galinhas por sala.	48
Figura 21. Acumulado das somas tempos distribuídos por dia do experimento.	49
Figura 22. Exemplo de <i>frame</i> unificado de três câmeras e trajeto percorrido pelas aves calculado pelo algoritmo de rastreamento baseado em filtro de Kalman.	51

Figura 23. Exemplos de *frames* sequenciais do vídeo processado. (A) *frame* com a identificação individual da ave. (B) *frame* seguinte com a trajetória da ave2. (C) *frame* com a conclusão do movimento da ave2.51

Figura 24. Troca de índice da ave. (A) índice 1 estático. (B) Troca do índice 2 por 1 devido ao desalinhamento das portas.52

LISTA DE TABELAS

Tabela 1. Esquema de distribuição dos tratamentos de iluminação monocromática nos compartimentos da câmara de preferência, repetido duas vezes.....	30
Tabela 2. Exemplo de estrutura de dados para análise.....	40
Tabela 3. Comparações de médias entre os fatores ambientes e cores para a variável número de galinhas	44

LISTA DE QUADROS

Quadro 1. Etograma de comportamentos naturais, indicadores de bem-estar.	17
Quadro 2. Comportamentos de estresse e sua definição.	18

SUMÁRIO

1	INTRODUÇÃO	14
2	OBJETIVO	15
2.1	OBJETIVO GERAL.....	15
2.2	OBJETIVOS ESPECÍFICOS.....	15
3	REVISÃO DE LITERATURA	16
3.1	AVICULTURA DE POSTURA	16
3.1.1	COMPORTAMENTO E BEM-ESTAR DAS AVES DE POSTURA.....	16
3.1.2	VISÃO E COMPORTAMENTO DAS GALINHAS EM EXPERIMENTOS	19
3.2	INTELIGÊNCIA ARTIFICIAL, APRENDIZADO DE MÁQUINA E DEEP LEARNING	21
3.2.1	DEEP LEARNING	22
3.3	APLICAÇÃO DO DEEP LEARNING NA AVICULTURA	25
3.4	RASTREAMENTO NA AVICULTURA	27
4	MATERIAIS E MÉTODOS	28
4.1	CARACTERIZAÇÃO DO EXPERIMENTO.....	28
4.2	DETECÇÃO DE AVES UTILIZANDO O YOLO.....	31
4.3	RASTREAMENTO DAS AVES.....	34
4.3.1	RASTREAMENTO UTILIZANDO O FILTRO DE KALMAN.....	34
4.3.2	VALIDAÇÃO EM VÍDEO EXPERIMENTAL	37
5	RESULTADOS E DISCUSSÃO.....	38
5.1	TREINAMENTO DO MODELO.....	38
5.2	PROCESSAMENTOS DOS VÍDEOS	40
5.3	PREFERÊNCIA POR TRATAMENTO DE LUZ.....	41
5.4	PREFERÊNCIA POR POSIÇÃO DA SALA	47
5.5	ANÁLISE DAS MOVIMENTAÇÕES DAS AVES (TRACKING)	49
6	CONSIDERAÇÕES FINAIS.....	53
7	REFERÊNCIAS.....	53

1 INTRODUÇÃO

O avanço das tecnologias de informação nos últimos anos tem provocado o desenvolvimento de modelos de *Deep Learning*, principalmente na área de visão computacional. Com a melhoria contínua da capacidade de computação e da popularização das unidades de processamento gráfico e ainda da tecnologia de processamento de *big data*, que permite o processamento de grandes volumes de dados, um número crescente de algoritmos de *Deep Learning* tem sido aplicado à agricultura (Kamilaris e Prenafeta-Boldú, 2018; Tulbure e Dulf, 2021).

Técnicas de visão de computacional tem sido utilizadas na agricultura para classificação de culturas (Yu et al., 2019; Zhuang e Zhang, 2019), segmentação de áreas de interesse (Gao et al., 2021), detecção de objetos e comportamentos (Partel et al., 2019, Casado-García et al. 2020), para contagem de itens e objetos (Quan et al., 2019; Carey et al., 2020; Wu et al., 2020), diagnóstico de doenças e pragas (Sun et al., 2018; Wang et al., 2020b).

Tulbure e Dulf (2021) relatam que as técnicas de detecção de objetos exigiam muito conhecimento nas áreas de extração de atributos e busca de características exclusivas dos modelos e algoritmos. No *Deep Learning* é permitido que sejam aplicados modelos computacionais de múltiplas camadas, que podem representar as entradas e saídas do problema a ser resolvido, provendo um modelo que aprenda com múltiplas camadas de abstração, sendo recomendado para problemas que não demonstraram ter soluções nas áreas de conhecimento de inteligência artificial e aprendizado de máquina tradicionais (Kamilaris e Prenafeta-Boldú, 2018).

As aplicações de *Deep Learning* e redes neurais Convolucionais são muito utilizadas em sensoriamento remoto para aplicações agrícolas (Gené-Mola et al., 2020; Ochoa e Guo, 2019, Xu et al., 2020). As aplicações são baseadas em modelos de estado da arte de *Deep Learning*, onde o YOLO, algoritmo para *Deep Learning*, está posicionado. Huang et al. (2020) e Kang e Chen (2020) empregaram um modelo de detecção de frutos da macieira em tempo real, utilizando o YOLO para classificar diferentes estágios de crescimento e maturação. Segundo Tian et al. (2019), na cultura da maçã a utilização de *Deep Learning* apresentou resultados de *F1 score* de 0,83 para diferentes estágios de maturação do fruto. Com esse resultado o YOLO pode ser utilizado para a detecção de objetos em contextos da agricultura.

Os experimentos para determinar um melhor ambiente para galinhas poedeiras expressarem seus comportamentos naturais e obterem maior rendimento produtivo, são realizados através de filmagens que normalmente são analisadas de forma manual. Ferramentas computacionais que permitam identificar e extrair informações comportamentais de aves em ambiente de produção tem sido objeto de vários estudos (Lin et al., 2018; Put et al., 2018; Wang et al., 2020a; Zaninelli et al., 2018).

A complexidade de identificar as aves de forma precisa e sistematizada em imagens com baixa iluminação e pouco contraste da ave com o restante do ambiente, impede que técnicas convencionais de análise de imagens sejam aplicadas.

Este trabalho propõe como problema de pesquisa desenvolver um sistema de monitoramento autônomo que reconheça galinhas e sua movimentação, em imagens com pouca iluminação e de baixa resolução e contraste da ave com o restante do ambiente, com o objetivo de extrair informação sobre comportamento de preferência de diferentes ambientes de criação. Complementar ao problema principal, este trabalho pretende demonstrar a viabilidade de rastrear individualmente as aves, utilizando o filtro de Kalman.

2 OBJETIVO

2.1 OBJETIVO GERAL

O objetivo deste trabalho foi desenvolver um modelo de rede neural convolucional utilizando *Deep Learning* e *Framework* YOLO para identificar e localizar galinhas em vídeos gravados em ambientes com baixa iluminação e pouco contraste e desenvolver um algoritmo para rastrear a movimentação das aves nessas condições.

2.2 OBJETIVOS ESPECÍFICOS

a) Aplicar uma arquitetura de rede convolucional capaz de realizar a detecção das aves em vídeos;

b) Analisar o comportamento de preferência das aves para três ambientes de iluminação monocromática (vermelho, verde e branco) interligados, e três condições de temperatura (calor = 35 °C, termoneutro = 24 °C e frio = 17 °C), contabilizando a presença dos animais em condição combinada de luz e temperatura;

c) Verificar a viabilidade tecnológica de medir e rastrear o deslocamento das aves utilizando filtro de Kalman a partir dos centros de massa detectados pela rede neural convolucional YOLO.

3 REVISÃO DE LITERATURA

3.1 AVICULTURA DE POSTURA

A domesticação do *Gallus gallus domesticus* (galinha) no início tinha apenas os propósitos de ornamentação e entretenimento, sendo que os primeiros relatos de criação de galinhas para fins comerciais são do final do século XIX no continente asiático (Lopes, 2011).

Segundo Arashiro (1989) e Fagnani (2014), as galinhas chegaram ao Brasil nos navios dos portugueses como recursos alimentares e fonte proteica para a nova colônia, as galinhas tinham finalidade de fornecer alimentos de forma sustentável. Na década de 1950 a região sudeste do Brasil foi a percursora no desenvolvimento da avicultura como uma atividade comercial. Vinte anos após o Desenvolvimento da atividade na região, os estados de Mato Grosso e Santa Catarina se destacaram na atividade devido ao seu diferencial competitivo de ofertar alimentação às aves a baixo custo (Turra, 2010; Dinten; Oliveira; Abrahão, 2006).

De acordo com o IBGE (2020) a produção de ovos foi de 965,41 milhões de dúzias no segundo trimestre de 2020, registrando uma elevação de 1,9% em comparação ao segundo trimestre de 2019 e apresentado os números similares à produção do 1º trimestre de 2020. Segundo Alcântara (2012) a maior parte dos ovos comercializados no Brasil é produzida com alta tecnologia e por linhagens de galinhas poedeiras comerciais de alto potencial genético. A grande maioria dos sistemas produtivos presentes no Brasil são constituídos de baterias de gaiolas.

3.1.1 COMPORTAMENTO E BEM-ESTAR DAS AVES DE POSTURA

A produção avícola brasileira enfrenta o desafio de equilibrar dois elementos em sua cadeia produtiva: crueldade e produtividade. Em muitos sistemas produtivos, as galinhas não expressam o seu comportamento natural (Costa et al., 2012). O espaço limitado das gaiolas restringe o movimento das aves e as impedem de

expressar comportamentos e atividade naturais, provocando o surgimento de osteoporose e sujeitando as aves a fraturas (Webster, 2004).

Segundo Wathes et al. (2008) o bem-estar das aves contribui para o aumento da sua produtividade. A qualidade do ovo depende fortemente das boas condições que as aves são criadas. Um indicador de uma ave saudável é quando ela expressa os seus comportamentos naturais, isto indica um bom nível de bem-estar (Sih et al., 2004).

Nos modernos sistemas de criação intensiva de galinhas poedeiras, onde elas são criadas livres de gaiolas, o enriquecimento ambiental tem sido uma prática adotada com frequência para favorecer a movimentação das aves no aviário. Nestes sistemas livres de gaiolas, a ave pode expressar os seus comportamentos naturais, as gaiolas enriquecidas ou mobiliadas são caracterizadas pela presença de poleiros, ninhos, camas e outros artefatos que permitem o comportamento natural e ainda melhoram o bem-estar das galinhas (Leyendecker et al., 2005; Sherwin et al., 2010; Lay et al., 2011; Stratmann et al., 2015; Weeks et al., 2016).

Vários comportamentos que as aves expressam sugerem o seu nível de bem-estar e podem ser fontes de informação importantes para o produtor e sistemas especialistas para suporte a decisão. No quadro 1 são apresentados alguns comportamentos esperados em um ambiente de conforto.

Quadro 1. Etograma de comportamentos naturais, indicadores de bem-estar.

Comportamentos	Definições
<i>Standing</i>	Incluindo ficar em pé, sentado, deitado, arranhando na caixa-ninho.
Andando	Movendo-se mais de três passos em uma direção e cabeça erguida
Bebendo	Galinha poedeira direcionando sua cabeça para bebedor, bicando e engolindo.
Bicar a gaiola	Bicando ou arranhando poleiro, ninho ou piso da gaiola
Arrumar penas	Galinha poedeira usando o bico para bicar, mordiscar, pentear, alisar as penas ou usar a garra para coçar as asas ou a cabeça
Comendo	Galinha poedeira direcionando a cabeça no comedouro e bicando, ingerindo ou comendo ração, uma ou várias vezes.

Comportamentos	Definições
Em pé	Galinha poedeira em pé, com as pernas estendidas, sem movimento do corpo, mas com os olhos abertos. A cabeça está ereta ou em postura relaxada
Empoleirar	Galinha poedeira com 2 pés em um poleiro, incluindo em pé, sentada e caminhando
Pular	Galinha poedeira pulando para cima ou para baixo do poleiro
Reconfortante	Incluindo sacudir o corpo, sacudir a cauda, levantar ou esticar as asas, esticar as pernas, esticar simultaneamente as asas e as pernas e banho de poeira
Sentado	Galinha poedeira sentada com o abdômen tocando o solo, asas fechadas, olhos abertos e sem qualquer atividade extra

Fonte: Adaptador de Webster e Hurnik (1990), Zhao et al. (2014), Casey-Trott e Widowski (2016).

Já no quadro 2 temos comportamentos esperados em um ambiente de estresse.

Quadro 2. Comportamentos de estresse e sua definição.

Comportamento	Definição
Bicada de agressão	O bico da galinha entra em contato com outra galinha.
Asa Elevada	Um espaço pode ser visto entre as asas e o corpo da galinha.
Canibalismo	As galinhas atacam outras para se alimentar

Fonte: Adaptado de Kim et al. (2021)

Os comportamentos de estresse podem ser desencadeados por um fator ambiental, como temperatura e/ou iluminação. Ainda pode ser provocado por muitas aves em um mesmo espaço (densidade de criação ou tamanho de grupo), diferentes idades ou aves doentes.

3.1.2 VISÃO E COMPORTAMENTO DAS GALINHAS EM EXPERIMENTOS

Segundo Lewis e Morris (2019) as galinhas apresentam quatro tipos de cones (vermelho, verde, azul e violeta) em seu sistema de visão. Isto representa que as galinhas enxergam as cores de forma diferentes que os humanos, que são tricromáticos (vermelho, verde e azul). A faixa do espectro de luz visível para os humanos está entre 495 à 750 nm, enquanto que as galinhas está entre 370nm e 700nm, ou seja, as aves possuem habilidade de enxergarem alguns comprimentos de onda ultravioleta. Além disso, humanos apresentam maior sensibilidade e acuidade visual na faixa de 545 à 575 nm, enquanto que as aves percebem a iluminação em intensidade diferente e são mais sensíveis aos comprimentos de ondas do azul e do vermelho (Figura 1).




Figura 1. Sensibilidades dos quatro cones nos comprimentos de onda.

Fonte: SEIFERT et al. (2020).

O comprimento de onda é processado de maneira diferente nas aves que nos humanos e podem estimular seu desempenho e comportamentos (Huber-Eicher et al., 2013; Baxter et al., 2014). Ainda os atributos da luz incluem fotoperíodo, intensidade e comprimento de onda e todos esses fatores têm influência na produção de ovos.

Muitos resultados de pesquisas afirmam que o tempo de exposição a luz é determinante para a maturidade sexual das galinhas e sua produtividade, ainda o tempo de exposição pode contribuir para que a ave expresse comportamentos de agressão (Lewis et al., 1997; Min et al., 2012; Janczak e Riber, 2015; Shi et al., 2019).

A galinha apresenta a estruturação da retina comum dos seres vertebrados, as três camadas nucleares são: a camada de células ganglionares, camada nuclear interna e camada nuclear externa. Os neurófilos são distribuídos em três camadas, fibras nervosas da retina, camada plexiforme interna e a plexiforme externa. O processamento do sinal da visão ocorre ao longo de duas vias principais. Na via vertical, as células bipolares conectam fotorreceptores às células ganglionares da retina cujos axônios formam o nervo óptico. As vias horizontais formadas por células horizontais no plexiforme externo e células amácrinas no plexiforme interno, modulam a via vertical, mediando processos como inibição lateral e seletividade direcional (Seifert et al., 2020).

Segundo Lewis e Morris (1999) a iluminação é um fator ambiental que é utilizado para controlar as funções fisiológicas das galinhas, pois este fator influencia no seu comportamento, produtividade e bem-estar. Ainda Parvin et al. (2014) relatam que a iluminação é um importante fator no sistema produtivo e pode ser modificado para melhorar o desempenho produtivo das galinhas.

O fator iluminação é um dos elementos que mais impactam na produção de ovos, pois alteram a fisiologia da ave, influenciando em seu bem-estar e comportamentos que afetam diretamente a produtividade das galinhas poedeiras (Mohammed et al., 2010; Jacome et al., 2014).

Baxter et al. (2014) dizem que o fornecimento adequado de luz é essencial para estimular o sistema de reprodução das aves por meio da excitação dos fotorreceptores hipotalâmicos. Para Elkomy et al. (2019) a intensidade e cor da luz são dois fatores importantes que afetam os comportamentos das aves. A alta intensidade de luz pode causar nas aves comportamentos não desejados, pois o excesso de luz aumenta as atividades e promove os comportamentos agressivos, como bicadas e canibalismo, e reduzem a produção de ovos (Newberry et al., 1988; Prayitno et al., 1997a; Lewis e Morris, 1999; Renema e Robinson, 2001; Shi et al., 2019).

As luzes brancas ou monocromáticas podem ser adotadas na criação de galinhas poedeiras (Hassan et al., 2014; Liu et al., 2017). Os diferentes comprimentos

de ondas que definem as cores da luz, causam alterações no comportamento e produtividade das poedeiras. As luzes em diferentes cores são estimulantes para a retina o que é relacionado com mudanças comportamentais que afetam as galinhas em seu desenvolvimento (Xie et Al., 2008).

Segundo Rozenboim et al. (2004) as luzes verde e azul estimularam o crescimento das aves e proporcionaram situações de bem-estar. Hassan et al. (2013) e Zhang et al. (2014) demonstraram que os comprimentos de onda verde e azul promovem crescimento das galinhas poedeiras e colaboram para um estado de calma e fomentam o melhor desempenho do sistema imunológico. Er et al. (2007) verificaram que as luzes verde e azul melhoram a qualidade do ovo.

As luzes vermelhas e laranja aumentam os níveis hormonais reprodutivos, o que favorece o desenvolvimento dos órgãos sexuais das aves, ainda que esses comprimentos de onda influenciam na idade de maturação sexual das galinhas poedeiras e melhoram o desempenho da reprodução (Pyrzak et al., 1987; Gongruttananun, 2011; Min et al., 2012; Hassan et al., 2013), eles promovem comportamentos não desejados como a bicada de agressão e o canibalismo (Rozenboim et al., 2004).

3.2 INTELIGÊNCIA ARTIFICIAL, APRENDIZADO DE MÁQUINA E *DEEP LEARNING*

Os termos inteligência artificial, aprendizado de máquina e *Deep Learning* muitas vezes são tratados de formas distintas. Segundo Ongsulee (2018), inteligência artificial pode ser definida pelo estudo de máquinas que executam ações inteligentes, similar a ações realizadas por humanos, onde um aprendizado do comportamento ou ação é aplicado para uma solução de um problema específico. Mohammadpour et al. (2019) relatam que a inteligência artificial se utiliza de técnicas e algoritmos para o processamento de dados e é utilizada em processamento de linguagem natural. Este processo utiliza dados complexos para que a inteligência artificial possa construir e realizar a ação e ainda englobar o aprendizado de máquina e o *Deep Learning* que serão abordados a seguir.

O aprendizado de máquina é um subconjunto da inteligência artificial, que trata de um contexto em que o computador pode aprender sem ser programado. O aprendizado de máquina evolui da inteligência artificial, utilizando-se especificamente

do reconhecimento de padrões e teoria da aprendizagem computacional (Ongsulee, 2018).

3.2.1 DEEP LEARNING

Segundo Kim et al. (2019b) o *Deep Learning* é um subconjunto da inteligência artificial que permite ao computador aprender com experiências anteriores. Ainda tem a capacidade de inferir em experiências anteriores os atributos que podem caracterizar aquele aprendizado. As redes neurais artificiais apresentam duas ou mais camadas, assim como as redes neurais biológicas, ou seja, as redes neurais artificiais apresentam a capacidade de reproduzir o comportamento de redes neurais biológicas (Ongsulee, 2018). As muitas camadas são utilizadas para extração, transformação e análise de características utilizando aprendizado supervisionado ou não supervisionado.

Os processos de *Deep Learning* anotam e classificam a entrada de dados semelhante ao processo biológico do cérebro, com a capacidade de consumir vários conjuntos de dados e aprender em diferentes níveis de complexidade, onde alguns algoritmos de aprendizado de máquina não apresentam sucesso em problemas complexos (Beysolow II, 2017). Segundo Najafabadi et al. (2015) essa técnica pode também funcionar de forma não supervisionada e ainda com dados não estruturados (imagens, por exemplo).

O nome “*Deep*” (profundo, em português) se dá devido ao número de camadas disponíveis. Diferente das redes neurais convencionais, os modelos de *Deep Learning* apresentam, geralmente três tipos de camadas: As camadas de entradas (onde se localizam os dados recebidos), as camadas ocultas (que são responsáveis pela extração de características) e a camada de saída (onde são expostos os resultados). A saída de uma camada é utilizada como a insumo para a próxima camada, conforme ilustrado na Figura 2.




Figura 2. Exemplo de uma arquitetura de uma rede *Deep*.

Fonte: Bahi e Batouche (2018).

Existe uma variedade de arquiteturas de *Deep Learning*. Cada arquitetura apresenta suas características e aplicações. Para propósito de contextualização deste trabalho, a seguir, seguem as definições de arquiteturas mais utilizadas.

O método mais utilizado no *Deep Learning* são as Redes Neurais Convolucionais (RNC). Elas foram inspiradas nos mecanismos de percepção visual dos seres vivos, esta arquitetura de rede é composta por várias camadas convolucionais que estão totalmente conectadas e geralmente requerem grandes conjuntos de dados de treinamento. A camada convolucional tem como objetivo identificar e analisar as características de entrada, isto permite que a camada destaque e identifique características simples como bordas linhas e sombras, assim como características mais complexas como objetos e formas (Han et al., 2018).

De acordo com Miotto et al. (2017), as redes neurais permitem a utilização de uma saída anterior como uma entrada da próxima camada. Elas são utilizadas principalmente em rastreamento de objetos e análise dados temporais e sequenciais. Beysolow II (2017) relata que essas redes possuem um conjunto de memória adicional

que permite o processamento de informações com lacunas de memória e que são capazes de aprender padrões.

Essas redes utilizam camadas Convolucionais para extrair características de uma imagem pelo processo de desconstrução da imagem (Mao, et. al, 2016). Uma rede de codificadores é responsável por criar a representação das arquiteturas e enquanto uma rede de decodificadores é responsável pela classificação e produção de recursos (Badrinarayanan e Cipolla, 2017).

As redes totalmente convolucionais utilizam camadas menos densas para realizar a extração de características de uma imagem, ou seja, em vez de utilizar as últimas camadas conectadas para essa extração. Isso é um benefício pois reduz o tempo de computação necessário para o treinamento e processamento da rede.

O YOLO (*The You Only Look Once*) é um método que unifica a classificação e localização de objetos em uma cena, utilizando diferentes camadas para abordar a detecção de objetos como um problema de regressão. O YOLO não exige que cada camada foque em uma área de interesse para regressão, o que torna a rede mais rápida na detecção. O YOLO tem uma alta acurácia e velocidade e, apresenta uma boa performance em detectar pequenos objetos em imagens de baixa resolução (Redmon et al., 2016, Redmon e Farhadi, 2017, Redmon e Farhadi, 2018).

YOLO-V3 é um algoritmo detecção de objetos aprimorado, baseado no YOLO9000 (Redmon e Farhadi, 2018). O YOLO-V3 utiliza de uma nova rede e apresenta 53 camadas convolucionais, denominado *darknet53*, conforme mostrado na Figura 3.




Figura 3. Arquitetura do YOLO-v3

Fonte. Adaptado de Redmon e Farhadi (2018).

3.3 APLICAÇÃO DO *DEEP LEARNING* NA AVICULTURA

Diversos sensores tem sido utilizados para coletar dados em ambientes de produção para posteriormente serem analisados utilizando *Deep Learning*. Lin et al. (2018) implementaram um sistema para detectar o estresse térmico em aves, monitorando a atividade, temperatura e umidade, utilizado um *hardware raspberry-pi*

com uma câmera acoplada para coletar fotos a 1 fps. O modelo foi treinado para identificar e localizar as aves na imagem e criaram um índice para evitar o fenômeno do estresse térmico combinando os dados das imagens com os dados de temperatura e umidade. Put et al. (2018) utilizaram os dados coletados com um sensor *Kinect*, para classificar o comportamento das aves em alimentadores. A partir de imagens coloridas e imagens de profundidade e, obtiveram uma acurácia de 96,4% na classificação. Em um experimento para analisar o comportamento de bicada em perus, foram coletados sons do comportamento e classificados manualmente em bicada e não-bicada, utilizando os vídeos para essa classificação manual (Nasirahmadi et al., 2020). A partir de uma base de dados de 9200 sons, sendo dividida em 80% para treinamento e 20% para validação, esse modelo apresentou 96% de acurácia para detectar bicadas.

Wang et al. (2020a) implementaram um detector de comportamento de aves, dividido em seis classes, onde uma precisão de aproximadamente 95% foi apresentada. Leroy et al. (2006) utilizaram técnicas de *Deep Learning* para prever comportamento do frango e ainda como prever o próximo comportamento baseado no comportamento anterior, essa técnica teve sucesso para identificar os comportamentos de coçar, andar e ficar parado.

Deep Learning também tem sido aplicado na classificação de comportamentos específicos de aves. Zaninelli et al. (2018) construíram um modelo para o reconhecimento de galinhas baseadas em formas, esse método foi utilizado para determinar o nível de ocupação dos ninhos e presenças de múltiplas galinhas no ninho. Fang et al. (2021) realizaram a estimativa de posição de galinha poedeiras, classificando as posições em pé, com acurácia de 75%, caminhando (52%), correndo (62%), comendo (93%), descansando (96%) e arrumando penas (92%). Li et al. (2021) desenvolveram um modelo para detectar o comportamento de alongamento, que pode ser utilizado como um sinal de bem-estar animal, com acurácia de 86%, possibilitando aos autores medir a quantidade de tempo que as aves passaram expressando esse comportamento.

Outras aplicações, além de análise comportamentais, foram desenvolvidas na avicultura. Um sistema de detecção de aves doentes foi desenvolvido por Zhuang e Zhang (2019) que apresentou uma acurácia de 99,7%. Já Wang et al. (2019) implementaram um sistema para determinar doenças intestinais em frangos com base em imagens de fezes, foram coletadas 10.000 imagens de fezes de frangos com

idades entre 25 e 35 dias e o sistema ofereceu suporte no diagnóstico de doenças intestinais de forma automática e não intrusiva, com acurácia de 93,3%.

As aplicações de *Deep Learning* estão presentes em outras etapas na criação das aves. Geng et al. (2019) propuseram um método automático para classificação da atividade embrionária em ovos, com objetivo de diferenciar com rapidez ovos com embriões vivos ou mortos. Foi utilizado *Deep Learning* em um conjunto de dados com batimentos cardíacos de 50 mil embriões, obtendo acurácia de 99,6% e desempenho para classificar 83 ovos por segundo. Já Ye et al. (2020) desenvolveram um modelo para reconhecer o nível de atordoamento em frangos de corte. O algoritmo foi aplicado a 27.828 imagens de frangos atordoados e teve a capacidade de diferenciar três condições de atordoamento com uma acurácia de 98,06%. Ainda Geffen et al. (2021) automatizaram o processo de contagem de galinhas poedeiras em gaiolas em um galinheiro de 87m de comprimento e um total de 11.000 galinhas poedeiras, com 37 gaiolas empilhadas em fileiras de seis andares, obtiveram uma acurácia de 89,6% em um banco de imagens de validação de 2.000 imagens.

3.4 RASTREAMENTO NA AVICULTURA

O rastreamento de animais vem sendo utilizado para análise de comportamento e bem-estar animal. Porém observá-los é uma tarefa árdua se realizada de modo manual. Pesquisas têm sido realizadas com as aves criadas em baias e salas experimentais, pois permitem melhor controle ambiental, facilitando a observação e registro dos animais em movimento (Lewis e Hurnik, 1990; Aydin et al., 2013; van der Sluis et al., 2019).

O filtro de Kalman foi utilizado por Roush et al. (1992) para analisar e realizar previsões de curto prazo no comportamento de galinhas poedeiras no consumo de ração. Seus resultados mostraram que mudanças de estado (estacionário ou movimentação), inclinação e respostas transitórias no comportamento das aves podem ser monitoradas diariamente. Segundo Grewal (2001) o filtro de Kalman é um método estatístico recursivo que possibilita a predição do próximo estado do objeto proposto, ele é utilizado em sistemas dinâmicos cujos seus parâmetros são dependentes de tempo.

A tecnologia de identificação por rádio frequência (RFID) foi usada em diversos estudos. Zhang et al. (2016) realizaram o rastreamento de frangos com a

tecnologia de RFID. As aves receberam etiquetas eletrônicas e o sistema calculou o tempo de movimentação das aves entre os dois leitores. Siegford et al. (2016) analisaram o comportamento e localização de galinhas poedeiras com a utilização da tecnologia RFID, testando várias frequências de transmissão e descrevendo suas vantagens e desvantagens. Sales et al. (2015) com auxílio da tecnologia RFID passivo de baixa frequência realizaram um experimento de preferência ambiental em galinhas poedeiras. Foram instalados leitores nas passagens entre as salas. O sistema foi capaz de quantificar o tempo que as galinhas permaneciam em cada sala.

Já Campbell et al. (2017) precisaram monitorar a densidade de galinhas poedeiras em um sistema produtivo com pastagem, em seu experimento com o auxílio da tecnologia RFID conseguiram identificar que as aves transitaram pelos três pastos, porém, o estudo não foi conclusivo quando à densidade máxima para galinhas ao ar-livre.

Baxter e O'Connell (2020) utilizaram tecnologia *Ultra-wideband* (UWB) e conseguiram um rastreamento de aves receberam com uma precisão de menor a 50 cm, quando comparado com a sua posição real. Considerou-se que a tecnologia UWB apresentou alta precisão no posicionamento das aves, porém apresentou limitação ao relatar as distâncias percorridas pelas aves.

O rastreamento de objetos em imagens é muito pesquisado, sendo construído por diferentes artefatos tecnológicos como processamento digital de imagens, inteligência artificial e aprendizado de máquina. O rastreamento de objetos é uma tecnologia mandatória para a análise visual de imagens (Bar-Shalom e Li, 1996, Spitzmiller e Adhami, 2010, Khan et. al, 2010, Lee e Chen, 2011).

4 MATERIAIS E MÉTODOS

4.1 CARACTERIZAÇÃO DO EXPERIMENTO

Foram utilizados vídeos de seis galinhas poedeiras da linhagem H&N Brown Nick, com 35 semanas de idade no início do experimento, alojadas em uma Câmara de Preferência Ambiental (CPA) da Faculdade de Engenharia Agrícola, FEAGRI/UNICAMP. A Câmara de Preferência possuía três compartimentos isolados entre si de 1,6 m x 1,4 m x 3,0 m (C x L x A), enriquecidos com cama de maravalha (5 cm de altura), poleiro (10 cm/ave e 30 cm de altura) e ninho, interligados entre si com

portas automáticas que permitiam trânsito e livre escolha às aves entre os três ambientes (Figura 4).




Figura 4. Esquema da câmara de preferência.

O comportamento de preferência das aves foi registrado por câmeras de vídeo da Intelbras® (sensor CCD 1/4", lente de 2,6 mm, São José, Santa Catarina, Brasil), com resolução VGA (640 x 480 pixels) e taxa de captura de 30 fps, equipadas com *Near Infrared*, instaladas no teto e no centro de cada um dos compartimentos da Câmara de Preferência, garantindo campo de visão de toda a área de cada compartimento.

Cada compartimento recebeu uma iluminação por LED monocromática diferente (branca, vermelha e verde) e a mesma iluminância de ~5 lx e fotoperíodo de 16:8 foram mantidos para todos os tratamentos. Para evitar que os compartimentos interferissem na análise da preferência das aves, cada compartimento recebeu a condição de iluminação por três dias seguidos, proporcionando dessa forma uma rotação nos tratamentos entre os compartimentos, e esse processo foi repetido uma vez de modo que cada compartimento recebeu duas vezes a mesma condição de luz.

A preferência das aves pelos ambientes iluminados foi testada para três condições de temperatura (35°C, 24°C e 17°C), simulando situações de calor, termoneutralidade e frio. A termoneutralidade é faixa de temperatura ambiental em que a ave não sofre estresse pelo calor ou pelo frio.

Após o período de adaptação e treinamento das aves para acesso aos compartimentos da Câmara de Preferência, as aves foram submetidas a três

tratamentos de iluminação, cada tratamento durante três dias (Ma, et al. 2016), conforme delineamento experimental apresentado na Tabela 1.

Foram monitorados os comportamentos de preferência das aves para três condições ambientais: Calor (35°C), Termoneutro (24°C) e Frio (17°C). O desenho experimental mostrado na Tabela 1 foi repetido para cada uma das condições ambientais duas vezes, totalizando 18 dias de experimento em cada condição ambiental. Os tratamentos de iluminação rotacionados em cada compartimento, realizando uma repetição de dois dias de modo a eliminar o efeito da posição nos dados (Kristensen et al., 2007).

Tabela 1. Esquema de distribuição dos tratamentos de iluminação monocromática nos compartimentos da câmara de preferência, repetido duas vezes.

Ambiente Térmico/Temperatura ambiente (°C)	Compartimentos		
	1	2	3
Calor (35°C)	Branco	Verde	Vermelho
	Vermelho	Branco	Verde
	Verde	Vermelho	Branco
Termoneutralidade (24°C)	Branco	Verde	Vermelho
	Vermelho	Branco	Verde
	Verde	Vermelho	Branco
Frio (17°C)	Branco	Verde	Vermelho
	Vermelho	Branco	Verde
	Verde	Vermelho	Branco

O ajuste da temperatura na Câmara de Preferência era sempre a mesma para todos os compartimentos, de modo que a preferência das aves pelo local era determinada apenas pela iluminação, naquela condição ambiental.

O delineamento experimental foi em blocos casualizados, no esquema fatorial 3×3 (3 ambientes, e 3 cores), com 3 blocos (salas) e 2 repetições, totalizando 54 aferições.

4.2 DETECÇÃO DE AVES UTILIZANDO O YOLO

Para o desenvolvimento de um modelo específico para a detecção de aves, foram executadas as etapas descritas na Figura 5.




Figura 5. Diagrama das etapas metodológicas da aplicação de *Deep Learning*.

Para a definição do tamanho da amostra, foi utilizado o cálculo descrito por Agranonik et al. (2011), na Equação 1.

$$\text{Cálculo de tamanho de amostra. } n = \frac{p(1-p)Z^2N}{\varepsilon^2(N-1) + Z^2 p(1-p)} \quad (1)$$

Onde:

n: tamanho da amostra;

p: proporção esperada;

Z: Valor da distribuição normal para determinado nível de confiança;

N: tamanho da população;

ε : tamanho do intervalo de confiança (margem de erro).

Na aplicação do cálculo, utilizou-se o número total de *frames* gravados $N = 34.992.000$, o grau de confiança em 99% para definir $Z = 1,96$ como valor da distribuição normal e margem de erro $\varepsilon = 4\%$. O resultado foi um tamanho de amostra $n = 1041$ imagens.

Para selecionar os *frames* de amostra, inicialmente foram extraídos aleatoriamente 3.000 *frames*. Na amostra de 3.000 *frames*, foram descartados aqueles que não apresentavam aves e novamente sorteado 1.041 imagens que possuíam ao menos uma galinha na cena. A Figura 6 mostra o exemplo de um *frame* selecionado.



Figura 6. Amostra de imagem de treinamento

O banco de dados de treinamento, denominado neste trabalho de *Dataset*, foi construído a partir da ferramenta *MakeSense*¹. Esta ferramenta foi desenvolvida pelo polonês, Piotr Skalski em 2019 e é mantida com a licença *Open-Source GPL-3.0*. Este *software* permitiu delimitar e marcar através de um retângulo cada uma das aves presentes nas 1.041 imagens. Todas as aves marcadas com essa ferramenta foram

¹ <https://www.makesense.ai/>

classificadas como “ave”. A Figura 7 mostra um *frame* com as aves marcadas pela ferramenta *MakeSense*®.



Figura 7. Anotação na imagem de treinamento.

A ferramenta *MakeSense*® cria um arquivo com as coordenadas do retângulo que marca cada ave em cada *frame*, que constitui, junto com os *frames*, o *dataset*. Este *dataset* foi utilizado no *Framework Darknet*, um *software open source* desenvolvido por Joseph Redmon e é utilizado para treinamento e validação de algoritmo de rede neural. Utilizou-se a arquitetura de rede YOLO v3, que utiliza linguagem de programação C e *CUDA*, plataforma de computação paralela que foi desenvolvida para aproveitar ao máximo as unidades de processamento gráfico (GPU).

Utilizou-se a arquitetura do YOLO v3, adaptada à existência de apenas uma categoria (“ave”), para o reconhecimento das aves nos vídeos gravados. Para a geração dos arquivos com pesos da rede, onde foi possível realizar o treinamento, em uma rede vazia, que aprendeu somente com as imagens marcadas de galinhas. A função de perda de aprendizagem pode refletir intuitivamente se o modelo de rede pode convergir para próximo a zero conforme o número de iterações aumenta.

O modelo foi treinado e utilizado para a identificação automática de galinhas nas 648 horas de vídeos que correspondem a 4 horas de filmagem diária em cada um

dos três compartimentos durante os 18 dias de experimento, para cada uma das três condições de temperatura.

4.3 RASTREAMENTO DAS AVES

4.3.1 RASTREAMENTO UTILIZANDO O FILTRO DE KALMAN

O filtro de Kalman é um método matemático e estatístico que visa prever ou estimar o estado em um sistema pelo tempo k usando a diferença e assumindo que o estado seguinte é uma soma dos estados anteriores $k - 1$. Nesse trabalho foi utilizada e implementada as equações (2 a 4) do filtro de Kalman, descritas por Kim e Bang (2018).

$$X_k = AX_{k-1} + Bu_{k-1} + W_{k-1} \quad (2)$$

$$Z_k = HX_k + V_k \quad (3)$$

$$p(w) \sim N(0, Q) \quad (4)$$

$$p(v) \sim N(0, R)$$

Onde:

- A é uma matriz $N \times N$ de passagem do estado anterior $k - 1$ para o estado atual k ;
- B é uma matriz $N \times l$ de controle aplicada a entrada Bu_{k-1} ;
- H é uma matriz $N \times N$ de transformação que é aplicada ao estado atual;
- W_{k-1} é um vetor que apresenta o ruído gerado no processo com a covariância Q e V_k é um vetor que apresenta o ruído medido na covariância R .

As equações do filtro de Kalman são as priori ($'X_k$) e posteriori (P_k): As equações priori são responsáveis pela projeção do estado atual e as estimativas do erro de covariância e as equações (5 a 9) de posteriori são responsáveis por melhorar a estimativa sendo assim incorporada na estimativa nova.

$$\hat{X}_k = AX_{k-1} + Bu_{k-1} \quad (5)$$

$$P_k = AP_{k-1}A^T + Q \quad (6)$$

Onde:

- X_{k-1} é o estado estimado anterior;
- P_k é a matriz de covariância do erro;
- P_{k-1} é a matriz de covariância do erro estimado e Q representa a covariância do ruído do processo.

$$K_k = P_k H^T (H P_k H^T + R)^{-1} \quad (7)$$

$$\hat{X}_k = X_k + K_k (z_k - HX_k) \quad (8)$$

$$P_k = (I - K_k H) P_{k-1} \quad (9)$$

Onde:

- K_k é o ganho de Kalman e R é a covariância do ruído de medição;
- $\hat{X}_k$ é a estimativa de estado previsto;
- $z_k - HX_k$ é a diferença entre a medição atual z_k com a medição estimada anterior HX_k ;
- P_k é a covariância do erro atualizado para ser utilizada no próximo incremento de tempo onde I é a matriz de identidade.

Para implementar o filtro de Kalman, utilizamos o estado inicial x_k e uma matriz de covariância de erro P_{k-1} . Foram utilizadas as equações 5 e 6 para a atualização do tempo no método predição, conforme Figura 8.

```
def predicao(atual):
    # Atualização do estado no tempo
    # Equação (4)
    atual.x = np.dot(atual.A, atual.x) + np.dot(atual.B, atual.u)

    # Cálculo do erro de covariância
    # Equação (5)
    atual.P = np.dot(np.dot(atual.A, atual.P), atual.A.T) + atual.Q
    return atual.x[0:2]
```

Figura 8. Método implementado em Python das equações da atualização do tempo.

As equações 7, 8 e 9 foram implementadas no método de correção da medição, esse método é responsável por atualizar as medidas da posição e corrigir divergências (Figura 9).

```
def atualizar(atual, z):
    # Cálculo do ganho de Kalman
    # Equação (6)
    D = np.dot(atual.H, np.dot(atual.P, atual.H.T)) + atual.R
    K = np.dot(np.dot(atual.P, atual.H.T), np.linalg.inv(D))

    # Atualização da estimativa do estado previsto
    # Equação (7)
    atual.x = np.round(atual.x + np.dot(K, (z - np.dot(atual.H, atual.x))))

    # Atualização da matriz de erro de covariância
    # Equação (8)
    I = np.eye(atual.H.shape[1])
    atual.P = (I - (K * atual.H)) * atual.P

    return atual.x[0:2]
```

Figura 9. Método atualização da medição de estado implementado em Python.




Figura 11. Coordenadas do quadro que delimita uma ave reconhecida pela rede YOLO.

$$\text{Centróide} = (x_c, y_c) \quad (10)$$

Onde:

$$x_c = \frac{(x_2 - x_1)}{2} \quad (11)$$

$$y_c = \frac{(y_2 - y_1)}{2} \quad (12)$$

O sistema realiza o rastreamento de múltiplas aves no frame através da inferência do ponto (centroide) por proximidade aos pontos anteriores e preditos. No estágio 4 são desenhadas nas imagens todas as marcações de número da ave e pontos preditos e anteriores calculados pelo filtro de Kalman no *frame* capturado no estágio 1 e salvo em um arquivo de vídeo.

5 RESULTADOS E DISCUSSÃO

5.1 TREINAMENTO DO MODELO

A utilização do *dataset* desenvolvido na etapa de metodologia foi utilizado para o treinamento de uma modelo para detecção de aves, utilizando *framework Darknet*. O modelo foi gerado após sete horas de processamento. A função de perda de aprendizagem específica do modelo é mostrada na Figura 12.




Figura 12. Perda de aprendizado durante o treinamento.

À medida que o número de épocas é incrementado, é observado que o modelo converge gradualmente e o valor da perda torna-se cada vez menor. Quando o modelo é iterado 10.000 vezes, o valor da perda é basicamente estável e caiu para próximo de 0 a rede basicamente converge, essa regressão é mais rápida e precisa, ainda prova a validade e eficácia do modelo. A precisão média da acurácia (mAP) foi de 99,9%, ou seja, em uma base de validação de 200 imagens que não fazem parte do grupo de 1.041 imagens de treinamento, o modelo após 3.500 épocas (iterações) obteve uma acurácia média de 99,9% que foi mantida até a época 10.000.

5.2 PROCESSAMENTOS DOS VÍDEOS

Os processamentos dos dados se deram em duas etapas. A primeira foi com o *Darknet* utilizando o arquivo de pesos da rede gerado com o YOLO v3 e um *script* em lote para a execução de maneira automatizada da identificação das aves nas 648 horas de vídeo. Os resultados da identificação das aves nos vídeos foram salvos em um arquivo de texto. Todos os 34.992.000 *frames* foram processados pela rede neural. Na segunda etapa do processamento dos dados, foi especificada uma estrutura de dados para organizar e viabilizar a análise dos dados (Tabela 2). As seis primeiras posições da estrutura de dados, representam dia do experimento, categoria do experimento, período de coleta de dados, número do *frame* processado, sala da coleta e quantidade de aves encontrada no *frame*, respectivamente. Após a quantidade de aves foi apresentada a probabilidade de o objeto identificado ser uma ave, segundo o modelo desenvolvido.

Tabela 2. Exemplo de estrutura de dados para análise.

Dia	Experimento	Período	Frame	Sala	Aves
7	Neutro	Tarde	1	1	1(100%)
7	Neutro	Tarde	2	1	1(100%)
7	Neutro	Tarde	3	1	1(100%)
7	Neutro	Tarde	100	1	4(100%, 100%, 100%,100%)

Os erros encontrados na identificação do modelo, podem ter ocorrido pela mobília dentro do galinheiro durante a interação da galinha com ela (Figura 13), na qual o modelo não identificou de forma satisfatória a ave.



Figura 13. Exemplo de imagem onde o modelo errou.

As aplicações de *Deep Learning* em visão computacional vêm se consolidando como a técnica de maior eficácia em ambientes visuais não controlados. O algoritmo YOLO v3 apresenta o potencial de atuar na detecção de objetos nesse contexto, se mostrado mais eficiente em relação as abordagens clássicas como *Support Vector Machine*, *Random Forest* e *Image template*, essa última utilizada em larga escala por soluções industriais.

5.3 PREFERÊNCIA POR TRATAMENTO DE LUZ

No experimento foi observado o tempo de permanência das 6 aves em um ambiente com iluminação e temperatura controlada. O tempo de permanência é calculado pela soma do total de galinhas identificadas em cada *frame*, dividido pela taxa de captura de 30 *frames* por segundo. O resultado é o tempo em segundos de permanência das galinhas no vídeo

Como não foi possível identificar as galinhas como indivíduos, o estudo está estruturado no tempo de permanência do grupo de aves em cada uns dos tratamentos e o período do dia, a Figura 14 indica a distribuição no acumulado dos tempos das aves nos tratamentos.




Figura 14. Tempo de permanência acumulado em horas em cada tratamento combinado de luz e temperatura.

Na análise de dados percebe-se que existe uma preferência da galinha pelo ambiente de luz branca, seguido pelo ambiente de luz vermelha. De acordo com Govardoskii e Zueva (1977) e Hart et al. (1999), a sensibilidade a luz das aves que possuem 4 cones em seu sistema de visão, apresenta uma sensibilidade que varia nos espectros de 350nm à 700 nm. A cor branca representa um alto estímulo na percepção do ambiente, pois estimula todo o campo de visão das aves (Prescott e Wathes, 2010; Prescott et al. 2003). Prayitno et al. (1997a) relataram resultado diferente do encontrado nesse trabalho, onde as galinhas preferiram luz verde ou azul ao invés de luz branca ou vermelha, seu experimento criou frangos de corte (machos e fêmeas) por um período de por 28 dias em uma fonte de iluminação com intensidade de ~30lux nas cores (azul, verde, vermelha e branca). Em contraponto, nos estudos de Lewis e Morris (2019) e Gunnarsson et al. (2008), as galinhas preferiram a luz branca.

A luz verde foi a que apresentou a menor preferência das aves e apresenta um resultado similar ao experimento de Rierson (2011) com frangos de corte, que verificaram que a preferência em se alimentarem dessas aves era sob iluminação branca seguida da vermelha e, com menos interesse, a cor verde.

Prayitno et al. (1997b) relata que não houve diferença de preferência entre as cores vermelha e branca, porém sobre a luz vermelha as aves apresentaram um comportamento mais agressivo em comparativo com aos outros espectros de luz branca, verde e azul. Percentualmente, as aves passaram 45% do tempo sob a luz branca, 37% do tempo sob a luz vermelha e 18% sob a luz verde na condição de termoneutralidade (Figura 14). Na condição de frio, a preferência pela luz branca aumentou para 57%, enquanto que a vermelha e a verde caíram para 31% e 12%, respectivamente. Percebe-se uma alteração na preferência pelos ambientes de luz na condição de calor, onde para os três tratamentos de luz branca, vermelha e verde, houve maior equilíbrio de ocupação com 39%, 29% e 33%, respectivamente.

Os resultados permitem afirmar que na condição de termoneutralidade e frio as aves manifestaram preferência pela iluminação branca, permanecendo menos tempo na iluminação verde. Contudo, na condição de calor houve distribuição mais equilibrada das aves nos compartimentos, que acabou refletindo no tempo de permanência das aves muito semelhante.

A Figura 15 mostra como as medianas de ocorrência de aves observadas em cada condição de temperatura e luz combinados. Verifica-se que na condição de frio há clara concentração de aves no ambiente de luz branca, enquanto no calor as aves estão perfeitamente distribuídas entre os tratamentos de luz.




Figura 15. Mediana do número de galinhas por tratamento de iluminação e período do dia. (A) no período da manhã. (B) no período da tarde.

A ausência de influência do período do dia na preferência das aves pelos tratamentos de luz é verificada na Figura 16.




Figura 16. Percentual de permanência por tratamento e período do dia.

A Análise de Variância ANOVA foi aplicada com nível de significância $p < 5\%$, com posterior comparações de médias pelo teste de Tukey (**Erro! Fonte de referência não encontrada.**).

Tabela 3. Comparações de médias entre os fatores ambientes e cores para a variável número de galinhas

	Branco	Verde	Vermelho
Calor	2,2 Ab	1,9 ABa	1,7 Ba
Frio	3,2 Aa	0,7 Cb	2,0 Ba
Temoneutralidade	2,6 Ab	1,0 Bb	2,2 Aa

Legenda: Maiúsculas (na linha) comparação entre as cores; minúsculas (na coluna) comparação entre os ambientes.

Observa-se na **Tabela 3** que a análise de comparação de médias mostra na situação de calor uma preferência das aves pela iluminação branca. Essa diferença não foi observada na análise de mediana mostrado na Figura 15. O número de aves observadas nas condições combinadas de iluminação e ambiente termoneutro e frio foram as mesmas da análise de mediana, sendo que houve uma preferência pela iluminação branca seguida da vermelha. A **Figura 17** mostra os intervalos de confiança da média do número de aves observado em cada condição ambiental combinada de temperatura e iluminação.




Figura 17. Intervalos de confiança para média do número de galinhas observados em cada tratamento combinado de ambiente e iluminação.

Conforme foi verificado na Figura 15 na análise da mediana, a média do número de galinhas também apresentou comportamento semelhante na condição ambiental de calor, onde não se verifica preferência evidente por qualquer tratamento de iluminação, corroborando com a hipótese de que as aves se distribuem entre as câmaras como uma estratégia social para aliviar o estresse calórico. A **Figura 18**, mostra o gráfico de interação do número de

galinhas observado em cada tratamento combinado de temperatura e iluminação.




Figura 18. Gráfico de Interação para o número de galinhas observado em cada tratamento combinado de temperatura e iluminação.

Conforme se observa no gráfico da **Figura 18**, enquanto a uma queda acentuada de permanência das aves nos ambientes de luz branca e vermelho, na iluminação verde há um aumento do número de aves. Também se observa que na iluminação branca o pico de concentração acontece na condição de frio, enquanto o pico de concentração de aves na iluminação vermelha acontece na condição de termoneutralidade. Esses resultados confirmam que o comportamento de preferência das aves depende da condição combinada de temperatura e iluminação.

5.4 PREFERÊNCIA POR POSIÇÃO DA SALA

O teste de preferência foi realizado em uma câmara que possuía três salas posicionadas lado a lado. Os tratamentos de luz foram rotacionados entre os compartimentos, para descartar qualquer interferência da sala (posição) nos resultados. A Figura 19 mostra a posição das salas vista pelas imagens do experimento.



Figura 19. Imagem real capturada pelas câmeras de vídeo das salas posicionadas lado a lado.

Quando se compara a presença de aves nas salas, considerando a sua posição na estrutura da câmara de preferência, a sala 2 é a de se verificou maior tempo de permanência com aves. A sala 2 é aquela que interliga as outras duas salas e, portanto, acaba servindo de passagem entre as salas 1 e 3. Na Figura 20 é mostrado o gráfico de *Boxplot* com a distribuição de ocorrências de aves para as três salas da câmara de preferência.




Figura 20. *Boxplot* do número de galinhas por sala.

Destaca-se também na Figura 20 que houve diferença entre a preferência das aves entre as salas 1 e 3. A sala 3 apresentou a menor mediana de aves, o que sugere entre as salas 1 e 3 há algo no ambiente que também afeta a preferência das aves. Contudo esse fator não foi controlado e o delineamento experimental de rotação dos tratamentos eliminou qualquer efeito desse fator nos resultados já apresentados e discutidos de preferência das aves nos diferentes tratamentos de luz e temperatura.

A Figura 21 mostra o acumulado de tempo de permanência das aves em cada sala. Era esperado que todas as salas tivessem curvas muito próximas, mas o fato da sala 2 ser passagem elevou o tempo de presença de aves nesse ambiente, independente do tratamento de luz ou temperatura. Além disso, fica claro também que existe diferença entre as salas 1 e 3 que afetou o comportamento de preferência das aves.




Figura 21. Acumulado das somas tempos distribuídos por dia do experimento.

5.5 ANÁLISE DAS MOVIMENTAÇÕES DAS AVES (*TRACKING*)

O rastreamento (*tracking*) tem sido usado para analisar o comportamento e o bem-estar dos animais, mas observá-los é uma tarefa árdua quando feita manualmente. Pesquisas têm sido realizadas com aves criadas em gaiolas e salas experimentais, pois esses ambientes permitem o maior controle de densidade, iluminação, temperatura, mobília, alimentação e condições da cama. Nesses ambientes são instaladas câmeras para capturar vídeos que serão utilizados como fonte de observação do comportamento e movimentação (Lewis e Hurnik, 1990; Aydin et al., 2013; van der Sluis et al., 2019).

Rastrear movimentos de animais geralmente requer análise de vídeo *offline*, e a análise manual de vídeo *offline* é uma tarefa que exige muito tempo e trabalho (Mollah et al., 2010). Fang et al. (2020) apresentaram o TBroiler. Este sistema detecta e prevê movimento em velocidades acima de 30 fps, com precisão de 73%, usando o modelo de rede Alexnet. Em um sistema de detecção de doenças, Zhuang e Zhang (2019) alcançaram um desempenho de 99,7% mAP e uma velocidade de execução de 40 fps usando uma GPU NVIDIA 1070 TI.

O algoritmo desenvolvido, obteve uma acurácia média de 99,9% e processamento em GPU acima de 90 fps. Esses atributos de performance permitem a aplicação do modelo para detecção e rastreamento em tempo real com equipamentos mais simples, que podem ser utilizados em estudos futuros ou mesmo

em condições comerciais. Os resultados são ainda mais relevantes quando comparamos a menor resolução das imagens originais utilizadas neste trabalho e o baixo contraste das aves com o fundo. Em todos os modelos encontrados na literatura atual, foram utilizadas imagens do tipo RGB e com alta resolução.

O rastreamento de aves por meio da visão computacional é uma tarefa complexa e, portanto, pouco explorada. Alguns estudos fizeram o rastreamento de aves aplicando outras tecnologias. Por exemplo, Feiyang et al. (2016) usaram tecnologias de identificação por radiofrequência (RFID) e, em seguida, aplicaram o algoritmo K-means para rastrear a movimentação das aves. O sistema de rastreamento baseado em uma sequência de centróides foi testado por Sergeant et al. (1998). Os *frames* foram capturados por câmeras instaladas sobre as aves e os centróides foram extraídos e processados para calcular o caminhar das aves. Um estudo de Fernández et al. (2018) teve como objetivo avaliar o estado de bem-estar de bandos de frangos de corte por meio do monitoramento em tempo real dos padrões de atividade e ocupação, utilizando técnicas tradicionais de visão computacional, sendo que o sistema implementado tem uma desvantagem, pois conforme o lote de frangos cresce, a imagem do frango com o piso perde o contraste, pois a maior lotação dos frangos por área dificulta a diferenciação entre a ave e fundo, causando erros nos cálculos.

O rastreamento implementado por imagens no presente trabalho utilizou o resultado da detecção de objetos com YOLO, resolvendo a maioria dos problemas encontrados em pesquisas anteriores com análise de imagens para identificar as aves para posterior rastreamento.

Os estágios descritos na metodologia, foram executados de forma sequencial. O processamento foi realizado em um vídeo de teste criado a partir da junção de três vídeos sincronizados das três câmeras (sala 1, sala 2 e sala 3) e nessa edição foram removidas as áreas de paredes, que não seriam úteis no processo de rastreamento das aves. A Figura 22 mostra um *frame* dos vídeos unificados com a presença das aves e seus trajetos já calculados pelo algoritmo de rastreamento baseado em filtro de Kalman, o trajeto percorrido pela ave4 (p.ex.) está representado pelos pontos da mesma cor, que indicam o seu trajeto percorrido até a porta da sala 1 para a sala 2.




Figura 22. Exemplo de *frame* unificado de três câmeras e trajeto percorrido pelas aves calculado pelo algoritmo de rastreamento baseado em filtro de Kalman.

A saída do processamento do algoritmo de rastreamento foi um vídeo com os desenhos dos trajetos das aves acumulados em todos os *frames*. O filtro de Kalman foi capaz de manter a identificação inicial das aves, a partir da qual foi possível mensurar as distâncias percorridas individualmente. Durante 30 minutos de duração desse vídeo unificado, todas as aves percorreram cumulativamente 5.420 centímetros (~54 m), sendo ave1 (1.370 cm), ave2 (340 cm), ave3 (1.881 cm), ave4 (832 cm), ave5 (613 cm) e ave6 (384 cm).

O movimento das aves foi identificado e traçado o seu caminho. Na Figura 23 é observado uma sequência de *frames* e os pontos vermelhos representam o caminho percorrido pela ave2.




Figura 23. Exemplos de *frames* sequenciais do vídeo processado. (A) *frame* com a identificação individual da ave. (B) *frame* seguinte com a trajetória da ave2. (C) *frame* com a conclusão do movimento da ave2.

Em alguns momentos em que existe um cruzamento entre as aves no *frame* e em alguns casos a identificação das aves são trocadas, o algoritmo não apresenta

uma limitação da distância dos pontos, isso ocorre devido ao alinhamento das portas nos *frames*. Na Figura 24A a ave marcada com índice 1 em verde, fica estática no vídeo aguardando que alguma coordenada de ave esteja próxima, no momento que a ave com índice 2 muda de sala ocorre mudança do índice 2 para 1, Figura 24B, pois eles são trocados na lista dos filtros de Kalman ativos, por causa dos desalinhamentos das portas. A mínima diferença de posição das câmeras impede que a junção dos vídeos seja perfeita, afetando os resultados de rastreamento.




Figura 24. Troca de índice da ave. (A) índice 1 estático. (B) Troca do índice 2 por 1 devido ao desalinhamento das portas.

Para o estudo do rastreamento das aves essas características dos vídeos experimentais deverão ser consideradas e uma alternativa metodológica deverá ser proposta para que se possa determinar se as aves se movimentam diferente em cada condição de iluminação e temperatura testados nesse trabalho. Nas condições dos vídeos analisados existe uma limitação no alinhamento dos vídeos para compor um novo vídeo unificado das três salas, com o enquadramento dos três ambientes e assim realizar uma análise do fluxo e movimento das aves entre os ambientes. Uma solução para essa limitação é um alinhamento das portas e gerar o novo vídeo unificado, mesmo que seja realizada uma deformação nas imagens, mas assim garantir a fluidez das aves entre as câmeras, assim aplicar a metodologia executada nesse trabalho.

6 CONSIDERAÇÕES FINAIS

A técnica de *Deep Learning* aplicada para a automação da análise de vídeo adotada no experimento, se mostrou eficaz, pois o modelo desenvolvido apresentou acurácia de 99,9%. O modelo e a metodologia podem ser replicados e utilizados para a análise de diferentes experimentos onde são necessários a identificação e contagem de galinhas.

A preferência das aves pela luz branca foi observada. Em contrapartida, verificou-se que a luz verde foi preterida pelas galinhas nesse experimento.

A temperatura influenciou no comportamento de preferência das aves e foi mais importante que o comprimento de onda da iluminação. Em condições de calor não foi verificada preferência por nenhum tipo de iluminação.

A utilização do filtro de Kalman para o rastreamento das aves foi eficiente e mostrou-se uma solução tecnológica viável. A união do *Deep Learning* para a detecção das aves com filtro de Kalman para rastreamento pode ser mais profundamente estudado para aplicações comerciais futuras.

7 REFERÊNCIAS

- AGRANONIK M.; HIRAKATA V. N. Cálculo de tamanho de amostras: proporções. **Revista HCPA**; v. 33, pp.382-8, 2011.
- ALCÂNTARA, J. B. **Qualidade físico-química de ovos comerciais: avaliação e manutenção da qualidade**. Goiânia: UFG, 2012. 32 f. Seminário (Doutorado) – Programa de Pós-Graduação em Ciência Animal, Universidade Federal de Goiás, 2012.
- ARASHIRO, O. **A história da avicultura do Brasil**. São Paulo: Ed. Gessulli, 1989.
- AYDIN, A.; PLUK, A.; LEROY, T.; BERCKMANS, D.; BAHR, C. Automatic identification of activity and spatial use of broiler chickens with different gait scores. **Transactions of the ASABE (American Society of Agricultural and Biological Engineers)**, v. 56, p. 1123-1132, 2013. DOI: <http://dx.doi.org/10.13031/trans.56.9987>
- BADRINARAYANAN, V.; KENDALL, A.; CIPOLLA, R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 39, pp. 2481-2495, 2017. DOI: <https://doi.org/10.1109/TPAMI.2016.2644615>
- BAHI, M.; BATOUCHE, M. Deep Learning for Ligand-Based Virtual Screening in Drug Discovery, **3rd International Conference on Pattern Analysis and Intelligent Systems (PAIS)**, 2018, pp. 1-5, 2018. DOI: <https://doi.org/10.1109/PAIS.2018.8598488>.

BAR-SHALOM, Y.; LI, X. R. Estimation and Tracking: Principles, Techniques, and Software. **IEEE Antennas and Propagation Magazine**, v. 38, p. 62-63, 1996. DOI: <https://doi.org/10.1109/MAP.1996.491294>

BAXTER M.; O'CONNELL, N. E. Testing ultra-wideband technology as a method of tracking fast-growing broilers under commercial conditions, **Applied Animal Behaviour Science**, v. 233, 2020. DOI: <https://doi.org/10.1016/j.applanim.2020.105150>.

BAXTER, M.; JOSEPH, N.; OSBORNE, V. R.; BÉDÉCARRATS, G. Y. Red light is necessary to activate the reproductive axis in chickens independently of the retina of the eye. **Poultry Science**, v. 93, p. 1289-1297, 2014. DOI: <https://doi.org/10.3382/ps.2013-03799>

BEYSOLOW II, T. Single and Multilayer Perceptron Models. In: Introduction to Deep Learning Using R. **Apress, Berkeley**, 2017. DOI: https://doi.org/10.1007/978-1-4842-2734-3_4

Biosystems Engineering, v. 194, p. 40-48, 2020. DOI: <https://doi.org/10.1016/j.biosystemseng.2020.03.015>

CAMPBELL, D.L.M.; HINCH, G.N.; DYALL, T.R. ; WARIN, L.; LITTLE, B.A.; LEE, C. Outdoor stocking density in free-range laying hens: radio-frequency identification of impacts on range use, **Animal**, v. 11, p. 121-130, 2017. DOI: <https://doi.org/10.1017/S1751731116001154>.

CAREY, J. C.; WEVERKA, J.; DIGAUDIO, R.; GARDALI, T.; PORZIG, E. L. Exploring variability in rangeland soil organic carbon stocks across California (USA) using a voluntary monitoring network, **Geoderma Regional**, v. 22, 2020. DOI: <https://doi.org/10.1016/j.geodrs.2020.e00304>

CASADO-GARCÍA, A.; DEL-CANTO, A.; SANZ-SAEZ, A.; PÉREZ-LÓPEZ, U.; BILBAO-KAREAGA, A.; FRITSCHI, F. B.; MIRANDA-APODACA, J.; MUÑOZ-RUEDA, A.; SILLERO-MARTÍNEZ, A.; YOLDI-ACHALANDABASO, A.; LACUESTA, M.; HERAS, J. LabelStoma: A tool for stomata detection based on the YOLO algorithm, **Computers and Electronics in Agriculture**, v. 178, 2020. DOI: <http://dx.doi.org/10.1016/j.compag.2020.105751>

CASEY-TROTT, T. M; WIDOWSKI, T. M. Behavioral differences of laying hens with fractured keel bones within furnished cages **Frontiers in Veterinary Science**, v. 3, p. 42, 2016. DOI: <http://dx.doi.org/10.3389/fvets.2016.00042>

COSTA, L. S., PEREIRA, D. F., BUENO, L. G. F., & PANDORFI, H. Some aspects of chicken behavior and welfare. **Brazilian Journal of Poultry Science**, v.14, n.3, p.159-164, 2012. DOI: <http://dx.doi.org/10.1590/S1516-635X2012000300001>.

DINTEN, C. A. M; OLIVEIRA, J. T. A; ABRAHÃO, R. F. Utilidade tecnológica na avicultura de corte: resultados de produção, composição da força de trabalho e tecnologia. **Informações Econômicas**, São Paulo, v. 36, n.6, jun. 2006.

ELKOMY, H. E.; TAHA, A. E.; BASHA, H. A.; ABO-SAMAH, M. I.; Sharaf, M. M. Growth and reproduction performance of Japanese quails (*Coturnix coturnix japonica*) under various environments of light colors. **Slovenian Veterinary Research**, v. 56, n. 22, p. 119-127, 2019. DOI: <http://dx.doi.org/10.26873/SVR-749-2019>

ER, D.; WANG, Z.; CAO, J.; CHEN, Y. Effect of monochromatic light on the egg quality of laying hens. **Journal of Applied Poultry Research**. v. 16, pp. 605-612, 2007. DOI: <https://doi.org/10.3382/japr.2006-00096>

FAGNANI, L. Trabalho e trabalhadores na avicultura: Experiências de Operários na Unidade de Produção de Pintainhos, Cooperativa Agroindustrial Lar (2006-2013). 2014. 247 f. Dissertação (Mestrado em História) – **Universidade Estadual do Oeste do Paraná, Marechal Cândido Rondon**.

FANG, C., HUANG, J., CUAN, K., ZHUANG, X., & ZHANG, T. Comparative study on poultry target tracking algorithms based on a deep regression network. **Biosystems Engineering**, 190, 176–183, 2020. DOI: <https://doi.org/10.1016/j.biosystemseng.2019.12.002>

FANG, C.; ZHANG, T.; ZHENG, H.; HUANG, J.; CUAN, K. Pose estimation and behavior classification of broiler chickens based on deep neural networks, **Computers and Electronics in Agriculture**, v.180, 2021. DOI: <https://doi.org/10.1016/j.compag.2020.105863>.

FEIYANG, Z.; YUEMING, H.; LIANCHENG, C.; LIHONG, G.; WENJIE, D. LU. W. Monitoring behavior of poultry based on RFID radio frequency network. **International Journal of Agricultural and Biological Engineering**, v. 9, p. 139-147, 2016. DOI: <https://doi.org/10.3965/j.ijabe.20160906.1568>

FERNÁNDEZ, A.P.; NORTON, T.; TULLO, E.; HERTEM, T.V.; YOUSSEF, A.; EXADAKTYLOS, V.; VANDREN, E.; GUARINO, M.; BERCKMANS, D. Real-time monitoring of broiler flock's welfare status using camera-based technology. **Biosystems Engineering**. v. 173, p. 103-114, 2018. DOI: <https://doi.org/10.1016/j.biosystemseng.2018.05.008>

GAO, J.; BURGHARDT, T.; ANDREW, W.; DOWSEY, A. W.; CAMPBELL, N. W. Towards self-supervision for video identification of individual Holstein-Friesian cattle: The cows, 2021 dataset, 2021. arXiv: <https://arxiv.org/abs/2105.01938>.

GEFFEN, O.; YITZHAKY, Y.; BARCHILON, N.; DRUYAN, S.; HALACHMI, I. A machine vision system to detect and count laying hens in battery cages. **Animal**, v. 14, p. 1-7, 2021. DOI <https://doi.org/10.1017/S1751731120001676>

GENÉ-MOLA, J.; SANZ-CORTIELLA, R.; ROSELL-POLO, J. R.; MORROS, J.; RUIZ-HIDALGO, J.; VILAPLANA, V.; GREGORIO, E. Fruit detection and 3D location using instance segmentation neural networks and structure-from-motion photogrammetry. **Computers and Electronics in Agriculture**. v. 169, 2020. DOI: <https://doi.org/10.1016/j.compag.2019.105165>

GENG, L.; WANG, H.; XIAO, Z.; ZHANG, F.; WU, J.; LIU, Y. Fully convolutional network with gated recurrent unit for hatching egg activity classification. in **IEEE Access**, vol. 7, pp. 92378-92387, 2019. DOI: <https://doi.org/10.1109/ACCESS.2019.2925508>.

GONGRUTTANANUN, N. Influence of red light on reproductive performance, eggshell ultrastructure, and eye morphology in Thai-native hens. **Poultry Science**, v. 90, pp. 2855-2863, 2011. DOI: <https://doi.org/10.3382/ps.2011-01652>

GOVARDOVSKII, V.I.; ZUEVA, L.V. Visual pigments of chicken and pigeon. **Vision research**. v.17, p.537-543, 1977. DOI: [https://doi.org/10.1016/0042-6989\(77\)90052-9](https://doi.org/10.1016/0042-6989(77)90052-9)

GREWAL, M.; ANDREWS, A. **Kalman filtering: theory and practice using MATLAB**. New York: John Wiley and Sons. Ed. 14, 2001. DOI: <https://doi.org/10.1002/9780470377819>.

GUNNARSSON, S.; HEIKKILÄ, M.; HULTGREN, J.; VALROS A. A note on light preference in layer pullets reared in incandescent or natural light. **Applied Animal Behaviour Science**, v. 112, p. 395-399, 2008. DOI: <https://doi.org/10.1016/j.applanim.2007.09.004>

HAN S.; PARK G.; LIM W.; KIM M.S.; NA J.; PARK I. Deep neural networks show an equivalent and often superior performance to dermatologists in onychomycosis diagnosis: Automatic construction of onychomycosis datasets by region-based convolutional deep neural network. **PLoS ONE**. v. 13, 2018. DOI: <https://doi.org/10.1371/journal.pone.0191493>

HART, N.S.; PARTRIDGE, .C; CUTHILL, I.C. Visual pigments, cone oil droplets, ocular media and predicted spectral sensitivity in the domestic turkey (*Meleagris gallopavo*), **Vision Research**, v. 39, p. 3321-3328, 1999. DOI: [https://doi.org/10.1016/S0042-6989\(99\)00071-1](https://doi.org/10.1016/S0042-6989(99)00071-1).

HASSAN, M. R.; SULTANA, S.; CHOE, H. S.; RYU, K. S. Effect of combinations of monochromatic LED light color on the performance and behavior of laying hens. **Journal of Poultry Science**, 51: 321-326, 2014. DOI: <http://dx.doi.org/10.2141/jpsa.0130105>

HASSAN, M. R.; SULTANA, S.; CHOE, H. S.; RYU, K. S. Effect of monochromatic and combined light colour on performance, blood parameters, ovarian morphology and reproductive hormones in laying hens. **Italian Journal of Animal Science**., v. 12, pp. 359-364, 2013. DOI: <https://doi.org/10.4081/ijas.2013.e56>

HUANG, S.; WU, S.; SUN, C.; MA, X.; JIANG, Y.; QI, L. Deep localization model for intra-row crop detection in paddy field. **Computers and Electronics in Agriculture**, v. 169, 2020. DOI: <https://doi.org/10.1016/j.compag.2019.105203>

HUBER-EICHER, B.; SUTER, A.; SPRING-STAHLI, P. Effects of colored light-emitting diode illumination on behavior and performance of laying hens. **Poultry Science**, v. 92, p. 869-873, 2013. DOI: <https://doi.org/10.3382/ps.2012-02679>

IBGE. Instituto Brasileiro de Geografia e Estatística. **Estatística da Produção Agropecuária**. Resultados Preliminares, jan-mar, 2020.

IEEE Access, v. 7, p. 92378-92387, 2019. DOI: <https://doi.org/10.1109/ACCESS.2019.2925508>

JACOME, I. M. T. D.; ROSSI, L. A.; BORILLE, R. Influence of artificial lighting on the performance and egg quality of commercial layers: a review. **Revista Brasileira de Ciência Avícola**, v. 16, p. 337-344, 2014. DOI: <http://dx.doi.org/10.1590/1516-635x160337-344>

JANCZAK, A. M.; RIBER, A. B. Review of rearing-related factors affecting the welfare of laying hens. **Poultry Science**, v. 94, p.1454-1469, 2015. DOI: <https://doi.org/10.3382/ps/pev123>

JONES, E. K. M.; WATHES, C. M.; WEBSTER, A. J. F. Avoidance of atmospheric ammonia by domestic fowl and the effect of early experience. **Applied Animal Behaviour Science**. v.90, p. 293 – 308, 2005. DOI: <https://doi.org/10.1016/j.applanim.2004.08.009>

- KAMILARIS, A.; PRENAFETA-BOLDÚ, F. X. Deep Learning in agriculture: A survey. **Computers and electronics in agriculture**, v. 147, p. 70-90, 2018. DOI: <https://doi.org/10.1016/j.compag.2018.02.016>
- KANG, H.; CHEN, C. Fast implementation of real-time fruit detection in apple orchards using Deep Learning . **Computers and Electronics in Agriculture**, v. 168, 2020. DOI: <https://doi.org/10.1016/j.compag.2019.105108>
- KHAN, N.; FEKRI, S.; GU, D. Improvement on state estimation for discrete-time LTI systems with measurement loss. **Measurement**, v.43, p. 1609-1622, 2010. DOI: <https://doi.org/10.1016/j.measurement.2010.09.011>.
- KIM, B., KIM, H., KIM, K., KIM, S., & KIM, J. (Learning not to learn: Training deep neural networks with biased data. **the IEEE Conference on Computer Vision and Pattern Recognition**, pp. 9012–9020, 2019b. DOI: <https://doi.org/10.1109/CVPR.2019.00922>
- KIM, D. H.; LEE, Y. K.; LEE, S. D.; KIM, S. H.; LEE, K. W. Physiological and behavioral responses of laying hens exposed to long-term high temperature, **Journal of Thermal Biology**, v. 99, 2021. DOI: <https://doi.org/10.1016/j.jtherbio.2021.103017>
- KIM, Y.; BANG, H. Introduction to Kalman Filter and Its Applications, Introduction and Implementations of the Kalman Filter, **IntechOpen**, 2018. DOI: <https://doi.org/10.5772/intechopen.80600>.
- KRISTENSEN, H. H.; BURGESS, L. R.; DEMMERS, T. G.; WATHES, C. M. The preferences of laying hens for different concentrations of atmospheric ammonia. **Applied Animal Behaviour Science**, v. 68, p. 307-318, 2000. DOI: [http://dx.doi.org/10.1016/S0168-1591\(00\)00110-6](http://dx.doi.org/10.1016/S0168-1591(00)00110-6)
- KRISTENSEN, H. H.; PRESCOTT, N. B.; PERRY, G. C.; LADEWIG, J.; ERSBØLL, A. K.; OVERVAD, K. C.; WATHES, C. M. The behaviour of broiler chickens in different light sources and illuminances. **Applied Animal Behaviour Science**, 103: 75-89, 2007. DOI: <https://doi.org/10.1016/j.applanim.2006.04.017>
- LAY, D. C.; FULTON, R. M.; HESTER, P. Y.; KARCHER, D. M.; KJAER, J. B.; MENCH, J. A.; MULLENS, B. A.; NEWBERRY, R. C.; NICOL, C. J.; O'SULLIVAN, N. P.; PORTER, R. E. Hen welfare in different housing systems **Poultry Science**, v. 90, p.278-294, 2011. DOI: <https://doi.org/10.3382/ps.2010-00962>
- LEE, M.; CHEN, T. Intelligent fuzzy weighted input estimation method for the forces generated by an operating rotating machine. **Measurement**, v. 44, p. 917-926, 2011. DOI: <https://doi.org/10.1016/j.measurement.2011.02.013>
- LEROY, T.; VRANKEN, E.; VAN BRECHT, A.; STRUELENS, E.; SONCK, B.; BERCKMANS, D. A computer vision method for on-line behavioral quantification of individually caged poultry. **Transactions of the ASABE**. V. 49, pp. 795-802, 2006. DOI: <https://doi.org/10.13031/2013.20462>
- LEWIS P., T MORRIS, T. Poultry and coloured light. **World's Poultry Science Journal**, v. 56, pp. 189-207, 2019. DOI: <https://doi.org/10.1079/WPS20000015>
- LEWIS, N. J.; HURNIK, J. F. Locomotion of broiler chickens in floor pens. **Poultry Science**, v. 69, p. 1087-1093, 1990. DOI: <https://doi.org/10.3382/ps.0691087>
- LEWIS, P. D.; MORRIS, T. R. Light intensity and performance of domestic pullets. **World's Poultry Science Journal**, v. 55, p. 241-250, 1999. DOI: <https://doi.org/10.1079/WPS19990018>

LEWIS, P.D.; PERRY, G.C.; MORRIS, T.R. Effect of size and timing of photoperiod increase on age at first egg and subsequent performance of two breeds of laying hen. **British Poultry Science**, v. 38, p. 142-150, 1997. DOI: <https://doi.org/10.1080/00071669708417959>

LEYENDECKER, M. ; HAMANN, H.; HARTUNG, J.; KAMPHUES, J.; NEUMANN, U.; SÜRIE, C.; DISTL, O. Keeping laying hens in furnished cages and an aviary housing system enhances their bone stability, **British Poultry Science**, v. 46, p. 536-544, 2005. DOI: <https://doi.org/10.1080/00071660500273094>

LI, G.; ZHAO, Y.; PORTER, Z.; PURSWELL, J. L. Automated measurement of broiler stretching behaviors under four stocking densities via faster region-based convolutional neural network, **Animal**, v. 15, 2021. DOI: <https://doi.org/10.1016/j.animal.2020.100059>.

LIN, C. Y.; HSIEH, K. W.; TSAI, Y. C.; KUO, Y. F. Monitoring chicken heat stress using deep convolutional neural networks. **ASABE Annual International Meeting, American Society of Agricultural and Biological Engineers**, p. 1-28, 2018. DOI: <https://doi.org/10.13031/aim.201800314>

LIU, K.; XIN, H.; SEKHON, J.; WANG, T. Effect of fluorescent vs. poultry-specific light-emitting diode lights on production performance and egg quality of W-36 laying hens. **Poultry Science**, v. 97, pp. 834-844, 2017. DOI: <https://doi.org/10.3382/ps/pex371>

LOPES, K. R. F. Avicultura: da pré-história à produção industrial. Lulu, 2011.

MA, H.; XIN, H.; ZHAO, Y.; LI, B.; SHEPHERD, T. A.; ALVAREZ, I. Assessment of lighting needs by W-36 laying hens via preference test. **Animal**, 10(4): 671-680, 2016. DOI: <https://doi.org/10.1017/s1751731115002384>

Make Sense, **Alpha**, 2021. URL: <https://www.makesense.ai/>

MAO, X. J.; SHEN, C.; YANG, Y. B. Image Restoration Using Convolutional Auto-encoders with Symmetric Skip Connections, pp. 1-17, 2016. ArXiv: <https://arxiv.org/abs/1606.08921>

MIN, J. K.; HOSSAN, M. S.; NAZMA, A.; JAE, C. N.; HAN, T. B.; HWAN, K. K.; DONG, W. K.; HYUN, S. C.; HEE, C. C.; OK, S. S. Effect of monochromatic light on sexual maturity, production performance and egg quality of laying hens. **Avian Biology Research**, 5(2): 69-74, 2012. DOI: <https://doi.org/10.3184/175815512X13350270679453>

MIOTTO, R.; WANG, F.; WANG, S.; JIANG, X.; DUDLEY, J. T. **Deep Learning for healthcare: review, opportunities and challenges. Briefings in Bioinformatics**, v. 19, pp. 1236-1246, 2017. DOI: <https://doi.org/10.1093/bib/bbx044>

MOHAMMADPOUR, A., KARAN, E., & ASADI, S. *Artificial intelligence techniques to support design and construction. 36th International Symposium on Automation and Robotics in Construction*, pp. 1282-1289, 2019. DOI: <https://doi.org/10.22260/ISARC2019/0172>

MOHAMMED, H. H.; GRASHORN, M. A.; BESSEI, W. The effects of lighting conditions on the behaviour of laying hens. **Archiv für Geflügelkunde**, V. 74, p. 197-202, 2010.

- MOLLAH, M.B.R; HASAN, M.A.; SALAM M.A.; ALI M.A. Digital image analysis to estimate the live weight of broiler. **Computers and Electronics in Agriculture**, v.72 (1): p. 48-52, 2010. <https://doi.org/10.1016/j.compag.2010.02.002>
- NAJAFABADI, M.M., VILLANUSTRE, F., KHOSHGOFTAAR, T.M. ET AL. Deep Learning applications and challenges in big data analytics. **Journal of Big Data**. 2015. DOI: <https://doi.org/10.1186/s40537-014-0007-7>
- NASIRAHMADI, A.; GONZALEZ, J.; STURM, B.; HENSEL, O.; KNIERIM, U. Pecking activity detection in group-housed turkeys using acoustic data and a Deep Learning technique, **Biosystems Engineering**, v. 194, p. 40-48, 2020. DOI: <https://doi.org/10.1016/j.biosystemseng.2020.03.015>.
- NEWBERRY, R. C.; HUNT, J. R.; Gardiner, E. E. Influence of light intensity on behavior and performance of broiler chickens. **Poultry Science**, v. 67, p. 1020-1025, 1988. DOI: <https://doi.org/10.3382/ps.0671020>
- OCHOA, K. S.; GUO, Z. A *framework* for the management of agricultural resources with automated aerial imagery detection. **Computers and Electronics in Agriculture**. v. 162, p. 53-69, 2019. DOI: <https://doi.org/10.1016/j.compag.2019.03.028>
- ONGSULEE, P.; CHOTCHAUNG, V.; BAMRUNGSI, E.; RODCHEEWIT, T. Big Data, Predictive Analytics and Machine Learning, **2018 16th International Conference on ICT and Knowledge Engineering (ICT&KE)**, pp. 1-6, 2018. DOI: <https://doi.org/10.1109/ICTKE.2018.8612393>
- PARTEL, V.; KAKARLA, S. C.; AMPATZIDIS, Y. Development and evaluation of a low-cost and smart technology for precision weed management utilizing artificial intelligence, **Computers and Electronics in Agriculture**, v. 157, 2019. DOI: <https://doi.org/10.1016/j.compag.2018.12.048>
- PARVIN, R.; MUSHTAQ, M. M. H; KIM, M. J.; CHOI, H. C. Light emitting diode (LED) as a source of monochromatic light: a novel lighting approach for behaviour, physiology and welfare of poultry. **World's Poultry Science Journal.**, v. 70, p. 543-556, 2014. DOI: <https://doi.org/10.1017/S0043933914000592>
- PRAYITNO D.S.; PHILLIPS C.J.; OMED H. The effects of color of lighting on the behavior and production of meat chickens. **Poultry Science**. v. 76, p. 452-7, 1997a. DOI: <https://doi.org/10.1093/ps/76.3.452>.
- PRAYITNO, D.; PHILLIPS, C. J.; STOKES, D. K. The effects of color and intensity of light on behavior and leg disorders in broiler chickens. **Poultry science**, v. 76, p. 1674-1681, 1997b. DOI: <https://doi.org/10.1093/ps/76.12.1674>
- PRESCOTT, N.; WATHES, C. Spectral sensitivity of the domestic fowl (*Gallus g. domesticus*), **British Poultry Science**, v. 40, p. 332-339, 2010. DOI: <https://doi.org/10.1080/00071669987412>.
- PRESCOTT, N.B.; WATHES, C.M.; JARVIS, J. 2003. Light, vision and the welfare of poultry. **Animal Welfare**. v.12, p. 269-288, 2003.
- PUT, H.; LIAN J.; FAN, M. Automatic recognition of flock behavior of chickens with convolutional neural network and kinect sensor. **International Journal Pattern Recognition Artificial Intelligence**, v. 32, p. 1850023, 2018. DOI: <https://doi.org/10.1142/S0218001418500234>

- PYRZAK, R.; SNAPIR, N.; GOODMAN, G.; PEREK, M. The effect of light wavelength on the production and quality of eggs of the domestic hen. **Theriogenology**, v. 28: p. 947-960, 1987. DOI: [https://doi.org/10.1016/0093-691X\(87\)90045-8](https://doi.org/10.1016/0093-691X(87)90045-8)
- QUAN, L.; FENG, H.; LV, Y.; WANG, Q.; ZHANG, C.; LIU, J.; YUAN, Z. Maize seedling detection under different growth stages and complex field environments based on an improved Faster R-CNN. **Biosystems Engineering**, v. 184, p. 1-23, 2019. DOI: <http://dx.doi.org/10.1016/j.biosystemseng.2019.05.002>
- REDMON, J.; DIVVALA, S.; GIRSHICK R.; FARHADI, A. You Only Look Once: Unified, Real-Time Object Detection, **2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**, pp. 779-788, 2016. DOI: <https://doi.org/10.1109/CVPR.2016.91>
- REDMON, J.; FARHADI, A. YOLO9000: Better, Faster, Stronger. **2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**, pp. 6517-6525, 2017. DOI: <https://doi.org/10.1109/CVPR.2017.690>
- REDMON, J.; FARHADI, A. YOLOv3: An Incremental Improvement. **Tech Report**. 2018. ArXiv: <https://arxiv.org/abs/1804.02767>
- RENEMA, R. A.; ROBINSON, F. E.; FEDDES, J. J. R.; FASENKO, G. M.; ZUIDHOFT, M. J. Effects of light intensity from photostimulation in four strains of commercial egg layers: 2. Egg production parameters. **Poultry Science**, v. 80, p. 1121-1131, 2001. DOI: <https://doi.org/10.1093/ps/80.8.1121>
- RIERSON, R.D. **Tese**. Broiler preference for light color and feed form, and the effect of light on growth and performance of broiler chicks, Kansas State University, Manhattan, KS, USA, 2011.
- ROUSH, W.B.; TOMIYAMA, K.; GARNAOUI, K.H.; D'ALFONSO, T.H.; CRAVENER, T.L. Kalman filter and an example of its use to detect changes in poultry production responses, **Computers and Electronics in Agriculture**, v. 6, p. 347-356, 1992. DOI: [https://doi.org/10.1016/0168-1699\(92\)90005-8](https://doi.org/10.1016/0168-1699(92)90005-8)
- ROZENBOIM, I; PIESTUN, Y.; MOBARKEY, N.; BARAK, M.; HOYZMAN, A.; HALEVY, O. Monochromatic light stimuli during embryogenesis enhance embryo development and posthatch growth. **Poultry Science**. v. 83 pp. 1413-1419, 2004. Doi: <https://doi.org/10.1093/ps/83.8.1413>
- SALES, G.T.; GREEN, A.R.; GATES, R.S.; BROWN-BRANDL, T.M.; EIGENBERG, R.A. Quantifying detection performance of a passive low-frequency RFID system in an environmental preference chamber for laying hens, **Computers and Electronics in Agriculture**, v. 114, p. 261-268, 2015. DOI: <https://doi.org/10.1016/j.compag.2015.03.008>
- SEIFERT, M. BADEN, T. OSORIO, R. The retinal basis of vision in chicken, **Seminars in Cell & Developmental Biology**, v. 106, p. 106-115, 2020. DOI: [10.1016/j.semcdb.2020.03.011](https://doi.org/10.1016/j.semcdb.2020.03.011)
- Sergeant, D.; Boyle, R.; Forbes, M. Computer visual tracking of poultry. **Computers and Electronics in Agriculture**, v. 21, p. 1-18, 1998. [https://doi.org/10.1016/S0168-1699\(98\)00025-8](https://doi.org/10.1016/S0168-1699(98)00025-8)
- SHERWIN, C. M.; RICHARDS, G. J.; NICOL, C.J.; Comparison of the welfare of layer hens in 4 housing systems in the UK. **British Poultry Science**, v. 51, p. 488-499, 2010. DOI: <https://doi.org/10.1080/00071668.2010.502518>

- SHI, H.; LI, B.; TONG, Q.; ZHENG, W.; ZENG, D.; FENG, G. Effects of LED light color and intensity on feather pecking and fear responses of layer breeders in natural mating colony cages. **Animals**, v. 9, p. 814, 2019. DOI: <https://doi.org/10.3390/ani9100814>
- SIEGFORD, J.M.; BEREZOWSKI, J.; BISWAS, S.K.; DAIGLE, C.L.; GEBHARDT-HENRICH, S.G. Assessing activity and location of individual laying hens in large groups using modern technology. **Animals**, v. 6, p. 10, 2016. DOI: <https://doi.org/10.3390/ani6020010>
- SIH, A; BELL, A. M.; JOHNSON, J. C.; ZIEMBA, R. C. Behavioral syndromes: an integrative overview. **Quarterly Review of Biology**, v. 79, p. 241-277, 2004. DOI: <http://dx.doi.org/10.1086/422893>
- SPITZMILLER, J. N.; ADHAMI, R. R. Tracking with Estimate-Conditioned Debiased 2-D Converted Measurements, **Intelligent Information Management**, v. 2, p. 286-294, 2010. DOI: <https://doi.org/10.4236/iim.2010.23033>.
- STRATMANN, A. FRÖHLICH, E.K.F., GEBHARDT-HENRICH, S.G., HARLANDER-MATAUSCHEK, A., WÜRBEL, H., TOSCANO, M. J. . Modification of aviary design reduces incidence of falls, collisions and keel bone damage in laying hens. **Applied Animal Behaviour Science**, n. 165, p. 112-123, 2015. DOI: <https://doi.org/10.1016/j.applanim.2015.01.012>
- SUN, Y.; LIU, X.; YUAN, M.; REN, L.; WANG, L.; CHEN, Z. Automatic in-trap pest detection using Deep Learning for pheromone-based *Dendroctonus valens* monitoring, **Biosystems Engineering**, v. 176, p. 140-150, 2018. DOI: <https://doi.org/10.1016/j.biosystemseng.2018.10.012>
- TIAN, Y.; YANG, G.; WANG, Z.; WANG, H.; LI, E.; LIANG, Z. Apple detection during different growth stages in orchards using the improved YOLO-V3 model. **Computers and Electronics in Agriculture**, v. 157, p. 417-426, 2019. DOI: <https://doi.org/10.1016/j.compag.2019.01.012>
- TULBURE, A.; DULF, E. A review on modern defect detection models using DCNNs – Deep convolutional neural networks, **Journal of Advanced Research**, 2021. DOI: <https://doi.org/10.1016/j.jare.2021.03.015>
- TURRA, F. Relatório anual 2010/2011 – **União brasileira de avicultura**. São Paulo, 2010.
- VAN DER SLUIS, M.; DE KLERK, B.; ELLEN, E. D.; DE HAAS, Y.; HIJINK, T.; RODENBURG, T. B. Validation of an ultra-wideband tracking system for recording individual levels of activity in broilers. **Animals**, v. 9, p. 580, 2019. DOI: <https://doi.org/10.3390/ani9080580>
- WANG, J.; SHEN, M.; LIU, L.; XU, Y.; OKINDA, C. Recognition and classification of broiler droppings based on deep convolutional neural network. **Journal of Sensors**, V. 2019, 2019. DOI: <https://doi.org/10.1155/2019/3823515>
- WANG, J.; WANG, N.; LI, L.; REN, Z. Real-time behavior detection and judgment of egg breeders based on YOLO v3. **Neural Computing and Applications**, v. 32, p. 5471-5481, 2020a. DOI: <https://doi.org/10.1007/s00521-019-04645-4>
- WANG, Q.; ZHANG, S.; DONG, S.; ZHANG, G.; YANG, J.; LI, R.; WANG, H. Pest24: A large-scale very small object data set of agricultural pests for multi-target detection.

Computers and Electronics in Agriculture, v. 175, 2020b. DOI: <https://doi.org/10.1016/j.compag.2020.105585>

WATHES, C.M.; KRISTENSEN, H.H.; AERTS, J.M.; BERCKMANS, D. Is precision livestock farming an engineer's daydream or nightmare, an animal's friend or foe, and a farmer's panacea or pitfall? **Computers and Electronics in Agriculture**, v. 64, p. 2-10, 2008. DOI: <https://doi.org/10.1016/j.compag.2008.05.005>

WEBSTER, A. B. Welfare implications of avian osteoporosis. **Poultry science**, v. 83, n. 2, p. 184-192, 2004. DOI: <https://doi.org/10.1093/ps/83.2.184>

WEBSTER, A.B.; J.F. HURNIK, J. F. An ethogram of White Leghorn-type hens in battery cages **Canadian Journal of Animal Science**, V. 70 p. 751-760, 1990. DOI: <https://doi.org/10.4141/cjas90-094>

WEEKS, C. A., LAMBTON, S. L., WILLIAMS, A. G. Implications for welfare, productivity and sustainability of the variation in reported levels of mortality for laying hen flocks kept in different housing systems: a meta-analysis of ten studies. **PLoS One**, v. 11, 2016. DOI: <https://doi.org/10.1371/journal.pone.0146394>

WU, W.; YANG, T.; LI, R.; CHEN, C.; LIU, T.; ZHOU, K.; SUN, C.; LI, C.; ZHU, X.; GUO, W. Detection and enumeration of wheat grains based on a Deep Learning method under various scenarios and scales, **Journal of Integrative Agriculture**, v. 19, n. 8, p. 1998-2008, 2020. DOI: [https://doi.org/10.1016/S2095-3119\(19\)62803-0](https://doi.org/10.1016/S2095-3119(19)62803-0)

XIE D, WANG ZX, DONG YL, CAO J, WANG JF, CHEN JL, et al. Effects of monochromatic light on immune response of broilers. **Poultry Science**, v. 87, pp. 1535-1539, 2008. DOI: <https://doi.org/10.3382/ps.2007-00317>

XU, B.; WANG, W.; FALZON, G.; KWAN, P.; GUO, L.; CHEN, G.; TAIT, A.; SCHNEIDER, D. Automated cattle counting using Mask R-CNN in quadcopter vision system. **Computers and Electronics in Agriculture**, v. 171, 2020. DOI: <https://doi.org/10.1016/j.compag.2020.105300>

YE, C.; YOUSAF, K.; QI, C.; LIU, C.; CHEN, K. Broiler stunned state detection based on an improved fast region based convolutional neural network algorithm. **Poultry Science**, v. 99, p. 637-646, 2020. DOI: <https://doi.org/10.3382/ps/pez564>

YU, Y.; ZHANG K.; YANG, L.; ZHANG, D. Fruit detection for strawberry harvesting robot in non-structural environment based on Mask-RCNN, **Computers and Electronics in Agriculture**, v. 163, 2019. DOI: <https://doi.org/10.1016/j.compag.2019.06.001>

ZANINELLI, M.; REDAELLI, V.; LUZI, F.; MITCHELL, M.; BONTEMPO, V.; CATTANEO, D.; DELL'ORTO, V.; SAVOINI, G. Development of a machine vision method for the monitoring of laying hens and detection of multiple nest occupations. **Sensors**, v. 18, pp. 132, 2018. DOI: <https://doi.org/10.3390/s18010132>

ZHANG, F. Y.; HU, Y. M.; CHEN, L. C.; GUO, L. H.; DUAN, W. J.; WANG, L. Monitoring behavior of poultry based on RFID radio frequency network. **International Journal of Agricultural and Biological Engineering**, v. 9, p. 139-147, 2016. DOI: <http://dx.doi.org/10.3965/j.ijabe.20160906.1568>

ZHANG, Z.; CAO, J.; WANG, Z.; DONG, Y.; CHEN, Y. Effect of a combination of green and blue monochromatic light on broiler immune response. **Journal of Photochemistry and Photobiology B: Biology**, v. 138, pp. 118-123, 2014. DOI: <https://doi.org/10.1016/j.jphotobiol.2014.05.014>

Zhao, Z. G.; Li, J. H.; Li, X.; Bao, J. Effects of housing systems on behavior, performance and welfare of fast-growing broilers. **Asian-Australasian Journal of Animal Sciences**, v. 27, p. 140-146, 2014. DOI: <https://dx.doi.org/10.5713%2Fajas.2013.13167>

ZHUANG, X.; ZHANG, T. Detection of sick broilers by digital image processing and Deep Learning, **Biosystems Engineering**, v. 179, 2019. DOI: <https://doi.org/10.1016/j.biosystemseng.2019.01.003>