



Instituto Federal de Educação, Ciência e Tecnologia do Piauí

Campus Teresina Central

Curso de Análise e Desenvolvimento de Sistemas

Ícaro Victor Félix Campelo

**Classificação de galinhas para o manejo em avicultura utilizando
redes neurais convolucionais**

Teresina

2021

Ícaro Victor Félix Campelo

**Classificação de galinhas para o manejo em avicultura utilizando
redes neurais convolucionais**

Trabalho de Conclusão de Curso (monografia) apresentado como exigência parcial para obtenção do diploma do Curso de Análise e Desenvolvimento de Sistemas do Instituto Federal de Educação, Ciência e Tecnologia do Piauí. Campus Teresina Central

Orientador: Prof. Dr. Otílio Paulo da Silva Neto

Coorientador: Prof. José dos Santos de Moura

Teresina

2021

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD

Campelo, Ícaro Victor Félix

C193c Classificação de galinhas para o manejo em avicultura utilizando redes neurais convolucionais / Ícaro Victor Félix Campelo. - 2022.
36 f.: il. color.

Trabalho de Conclusão de Curso (Tecnologia em Análise e Desenvolvimento de Sistemas) - Instituto Federal do Piauí, Campus Teresina Central, 2022.

Orientador : Prof. Dr. Otílio Paulo da Silva Neto.

Coorientador : Prof. Esp. José dos Santos de Moura.

1. Avicultura. 2. Inteligência Artificial. 3. Rede neural convolucional. 4. Aprendizado de máquina. I.Título.

CDD - 004.21

Elaborado por Sindya Santos Melo CRB 3/1085

Ícaro Victor Félix Campelo

Trabalho de Conclusão de Curso (monografia) apresentado como exigência parcial para obtenção do diploma do Curso de Análise e Desenvolvimento de Sistemas do Instituto Federal de Educação, Ciência e Tecnologia do Piauí. Campus Teresina Central.

Aprovado em:

BANCA EXAMINADORA:

Prof. Dr. Otílio Paulo da Silva Neto (Orientador)
Instituto Federal do Piauí (IFPI)

Prof. Me. Rogério da Silva Batista
Instituto Federal do Piauí (IFPI)

Prof. Esp. José dos Santos de Moura
Instituto Federal do Piauí (IFPI)

Teresina

2021

Agradecimentos

Eu gostaria de agradecer à toda minha família e aos professores que me guiaram durante esta jornada, sem vocês este trabalho não seria possível. Também gostaria de mandar agradecimentos especiais aqueles que colaboraram diretamente para o meu crescimento enquanto aluno e enquanto ser humano: à minha mãe Odete e à minha avó Erminedes, que sempre acreditaram em mim; ao meu irmão Wilson, que constantemente me ajudou dispondo de seu tempo e experiência para me apoiar; ao meu primo Kevin, por quem tenho imensa admiração, que muito contribuiu com observações vitais; aos professores Otilio Paulo da Silva Neto e José dos Santos Moura, gigantes sobre os quais apoio meu trabalho.

Muito obrigado a todos!

Tudo o que temos de decidir é o que fazer com o tempo que nos é dado.

J.R.R. Tolkien

RESUMO

O setor da pecuária, tendo a avicultura um dos seus principais expoentes, vem sendo um dos principais agentes motores da economia global por gerar renda, empregos e movimentar a agroindústria. O desenvolvimento da avicultura no Brasil se deu por conta de novos sistemas de produção relacionados à biossegurança, sanidade, qualidade dos animais e da carne. Por outro lado, o setor encara dificuldades referentes ao manejo, ao monitoramento e ao bem estar dos animais, juntamente a problemas relacionados à falta de mão de obra qualificada. Sistemas de inteligência artificial surgem cada vez mais no setor agrícola e se tornam uma solução para esse tipo de problemática, visto que simulam o cérebro humano, conseguindo ter um entendimento próprio e assim, capacitando-se para substituir a mão de obra tradicional. As redes neurais convolucionais(CNN) são um subtipo de aprendizado de máquina que utiliza grandes quantidades de dados, buscando detectar padrões em imagens e aprender diferentes níveis de abstração. Este trabalho tem como objetivo desenvolver um método capaz de detectar galinhas em imagens, por meio da inteligência artificial, para auxiliar profissionais no manejo da avicultura. Para o desenvolvimento deste trabalho, foram utilizadas 468 imagens fotográficas com o mesmo padrão de dimensão adquiridas em campo. As fotos passaram por um processo de rotulação e após isso foram separadas em 80% para treino, essas subdivididas em 80% treino e 20% para validação, e 20% para teste. As fotografias rotuladas com suas respectivas originais foram passadas para uma rede YOLO que realizou o treinamento, gerando um modelo ao final. O modelo apresentou uma taxa de 50% de acurácia na classificação. Conclui-se que este trabalho apresentou resultados promissores na classificação com as imagens adquiridas. Para o objetivo futuro, pretende-se aumentar a quantidade de imagens para cada base e realizar mudanças em alguns parâmetros da rede neural.

Palavras-chave: Avicultura, Inteligência Artificial, Rede Neural Convolucional, Aprendizado de Máquina.

ABSTRACT

The livestock sector, with poultry farming as one of its main exponents, has been one of the main driving forces in the global economy for generating income, jobs and moving the agribusiness. The development of poultry farming in Brazil was due to new production systems related to biosecurity, health, quality of animals and meat. On the other hand, the sector faces difficulties related to the handling, monitoring and welfare of animals, together with problems related to the lack of qualified labor. Artificial intelligence systems appear more and more in the agricultural sector and become a solution to this type of problem, as they simulate the human brain, managing to have their own understanding and thus, enabling themselves to replace the traditional workforce. Convolutional neural networks (CNN) are a subtype of machine learning that uses large amounts of data, seeking to detect patterns in images and learn different levels of abstraction. This work aims to develop a method capable of detecting chickens in images, through artificial intelligence, to help professionals in poultry management. For the development of this work, 468 photographic images with the same dimension pattern acquired in the field were used. The photos went through a labeling process and after that they were separated into 80% for training, these subdivided into 80% training and 20% for validation, and 20% for testing. The photographs labeled with their respective originals were passed to a YOLO network that carried out the training, generating a model at the end. The model presented a 50% accuracy rate in classification. It is concluded that this work presented promising results in the classification with the acquired images. For the future objective, it is intended to increase the amount of images for each base and make changes in some parameters of the neural network.

Keywords: Poultry Farming, Artificial Intelligence, Convolutional Neural Networks, Deep Learning.

LISTA DE FIGURAS

Figura 1 – Etapas do processo de visão computacional Fonte: Autor	19
Figura 2 – Neuronio biologico(esquerda) e modelo computacional(direta).	22
Figura 3 – Arquitetura de uma rede neural convolucional. Fonte: (O'SHEA; NASH, 2015)	23
Figura 4 – Demonstração do funcionamento da rede Yolo com o uso de bounding box. Fonte: (REDMON et al., 2016)	25
Figura 5 – Imagens capturadas Fonte: Autor	29
Figura 6 – Imagens Descartadas Fonte: Autor	29
Figura 7 – Processo para a classificação das galinhas com a apresentação de uma rede neural convolucional Fonte: Autor	31

LISTA DE TABELAS

Tabela 1 – Hiperparâmetros e seus respectivos valores	30
Tabela 2 – Separação das imagens em bases de treino, validação e teste	33
Tabela 3 – Resultado da aplicação da rede neural convolucional	33

LISTA DE SIGLAS

ACC	Acurácia
ANN	Rede Neural Artificial
CNN	Rede Neural Convolucional
IA	Inteligência Artificial
LEAKY RELU	Leaky Rectified Linear Unit
RELU	Rectified Linear Unit
YOLO	You Only Look Once

SUMÁRIO

LISTA DE FIGURAS	9
LISTA DE TABELAS	10
SUMÁRIO	12
1 INTRODUÇÃO	14
1.1 Objetivos	15
1.1.1 Objetivo Geral	15
1.1.2 Objetivos Específicos	15
2 TRABALHOS RELACIONADOS	16
3 FUNDAMENTAÇÃO TEORICA	18
3.1 Avicultura	18
3.2 Visão Computacional	18
3.3 Reconhecimento de Padrões	20
3.4 Redes Neurais Artificiais	21
3.5 Rede Neural Convolucional	22
3.6 Rede convolucional Yolo	24
3.7 Métricas de Avaliação	26
3.7.1 Acurácia	26
3.7.2 Entropia Cruzada Binária	27
4 METODOLOGIA	28
4.1 Ambiente de Desenvolvimento	28
4.2 Aquisição de Imagens	28
4.3 Classificação	29
4.3.1 Treinamento	29
4.3.2 Aplicação da Rede Neural	30
4.3.3 Detecção	31

4.3.4	Avaliação do Modelo	32
5	RESULTADOS	33
5.1	Base de Imagens	33
5.2	Classificação	33
6	CONCLUSÃO E TRABALHOS FUTUROS	35
6.1	Trabalhos Futuros	35
	REFERÊNCIAS	36

1 Introdução

Para Coelho e Borges (1999), é fato (HISHAM et al., 2015) que (ZHANG et al., 2017) a pecuária é um dos principais agentes motores da economia global, sendo responsável por gerar renda, empregos e movimentar a agroindústria. (BRUNELLI, 2009) Esse complexo sistema tem como um de seus principais expoentes a Avicultura, em especial a criação de Galinhas. Ademais, conforme Zen et al. (2014), novos sistemas de produção contribuíram para o desenvolvimento da avicultura no Brasil, principalmente nos quesitos relacionados à biossegurança, sanidade, qualidade dos animais e da carne de frango. (GONZALEZ; WOODS, 2009) Com isso, tem-se a necessidade de classificar e identificar essas Aves por meio de técnicas modernas de Inteligência Artificial e Reconhecimento de Padrões utilizando Redes Neurais Convolucionais para o processamento de imagens e vídeos. (KUMAR et al., 2018)

Em um primeiro momento, (SHORTEN; KHOSHGOFTAAR, 2019) é válido evidenciar a importância das inteligências artificiais para a compreensão acerca da problemática. De acordo com Chiovatto (2019), o termo inteligência artificial começou a ser utilizado em meados da segunda metade dos anos cinquenta em Dartmouth, a partir da ideia de construir computadores com as mesmas características do cérebro humano. Somando-se a isso, tem-se que Jackson (2019) estabeleceu que tal conceito passou a ser amplamente popularizado no campo computacional à medida que o avanço tecnológico alcançava os alicerces teóricos iniciais. Isso culminou na criação de sistemas sofisticados capazes de ter um aprendizado próprio e gradual, enquanto simultaneamente alavancou a forma de se compreender o universo digital no que se refere ao processamento de dados. Além disso, cabe ressaltar o elo existente entre as IAs e aprendizado de máquina (Machine Learning), em especial a relação com aprendizado profundo (Deep Learning). (HASHEMI et al., 2016)

Segundo Dargan et al. (2019), Deep Learning corresponde a um subcampo do aprendizado de máquinas que utiliza um conjunto de algoritmos buscando detectar padrões e aprender diferentes níveis de abstração e processamento não linear. Muitos dos métodos de Deep Learning usam arquiteturas de Rede Neural, e devido a isso são frequentemente relacionados a redes neurais profundas. O termo ‘Deep’ geralmente se refere ao número de camadas ocultas na rede neural; Redes Neurais tradicionais somente possuem de 2 a 3 camadas ocultas, enquanto redes profundas podem ter mais de 150 camadas. Modelos de

Deep Learning são treinados usando um grande conjunto de dados rotulados bem como fazem uso da arquitetura de redes neurais, aprendendo diretamente por meio de recursos dos dados, sem a necessidade de extração manual. Para LeCun, Bengio e Hinton (2015), um tipo específico de rede feedforward profunda muito mais fácil de treinar e de forma geral muito melhor que redes com conectividade total entre camadas adjacentes é a rede neural convolucional(CNN). CNN convolve recursos aprendidos com dados de entrada e usa camadas convolucionais 2D, tornando essa arquitetura adequada para processar dados 2D, como imagens. Seguindo essa linha de raciocínio, pode-se vincular esses conceitos com a Avicultura e seus desafios.

Diante disso, nota-se que os avanços na área de IA são fulcrais para facilitar os métodos de controle das Aves. Pôde-se, então fazer uso de um sistema específico de classificação por meio do qual seria possível identificar Galinhas através de uma Análise de suas estruturas anátomo-fisiológicas(formato da cabeça, troncos e padrão de penas). Desse modo, o sistema supracitado será devidamente desenvolvido no decorrer deste trabalho.

1.1 Objetivos

1.1.1 Objetivo Geral

Desenvolver um sistema capaz de detectar galinhas em imagens e vídeos, por meio da inteligência artificial, para auxiliar profissionais em manejo da Avicultura.

1.1.2 Objetivos Específicos

Para atingir o objetivo principal, foram definidos os seguintes objetivos específicos:

- Realizar o levantamento bibliográfico acerca da Avicultura;
- Estudar os conceitos da avicultura moderna;
- Definir uma base de imagens de galinhas;
- Implementar algoritmo de detecção de galinhas;
- Propor métricas de avaliação da rede neural convolucional;

2 Trabalhos Relacionados

O trabalho de Saltoratto et al. (2013), apresenta uma ferramenta de monitoramento de avicultura a partir das imagens de frames de vídeos. Foram aplicadas técnicas para redução do brilho (intensidade) da imagem, assim como morfologia matemática e algoritmo de inundação como alguns dos procedimentos aplicados às imagens. A conclusão foi que os dias chuvosos com temperaturas baixas, as aves aqueciam-se na maior parte que eram filmadas.

Na pesquisa de Grando (2018), propõe-se a utilização da visão computacional para classificação de bovinos por meio de características do focinho. Foram empregadas técnicas de matriz de co-ocorrência, algoritmos genéticos e classificador knn. Os resultados do estudo demonstraram que a taxa de acerto do método escolhido foi de 96,75%, mostrando que o classificador se mostrou eficiente para executar o trabalho proposto.

No estudo de Marsot et al. (2020), foi proposto um framework que engloba algoritmos de aprendizado de máquinas para oferecer uma solução reconhecimento de porcos com o custo baixo e escalável. Foram usados dois classificadores em cascata baseados em recursos Haar e uma rede neural convolucional rasa com imagens de altas qualidades para detectar rostos e olhos de porcos. O reconhecimento facial foi realizado através do emprego de uma rede neural convolucional profunda. Mapas de ativação de classe gerados por grad-CAM e mapas de saliência foram utilizados para compreender visualmente como os parâmetros discriminantes foram aprendidos pela rede neural. Foi aplicada uma abordagem proposta em 10 porcos selecionados aleatoriamente filmados em condição de fazenda, o método proposto demonstrou o desempenho superior em relação ao método de última geração com uma precisão de 83% sobre 320 imagens de teste.

O objetivo do trabalho de Lopes (2019) foi desenvolver um algoritmo computacional para processamento e análise de imagens de poedeiras criadas sobre cama de maravalha capaz de identificar o grau de aglomeração das aves em diferentes condições de conforto térmico. Para os objetivos específicos foi proposto um índice de aglomeração baseado em medidas obtidas na análise das imagens e confirmar as diferenças deste índice de aglomeração em diferentes condições de temperatura do ambiente de criação. O algoritmo foi desenvolvido em ambiente MatLab® e foi dividido em duas etapas: processamento e

análise da imagem. Os vídeos foram processados frame a frame pelo algoritmo e medidas de área, perímetro e distâncias entre os centros de massa dos aglomerados de aves foram obtidas na análise das imagens. A partir dessas medidas foi proposto um índice de aglomeração que foi usado para calcular o nível de aglomeração de cada frame de dois vídeos obtidos em condições térmicas distintas: 21°C e 32°C. Os resultados obtidos de índice de aglomeração nas duas condições de temperatura foram submetidos ao teste T-student que confirmou diferença nas duas situações, validando dessa forma o índice de aglomeração proposto. Foi feita a repetição do experimento em condições de ambiente térmico diferentes e constatou-se que o algoritmo desenvolvido não respondeu adequadamente à troca da cama e às variações de iluminação que se apresentaram. O algoritmo desenvolvido foi capaz de identificar as aves do restante da imagem por meio do processamento digital das imagens.

3 Fundamentação Teórica

3.1 Avicultura

Segundo Mottet e Tempio (2017), carne e os ovos de frango estão entre os alimentos de origem animal mais consumidos pela população, presentes em uma grande variedade de culturas, tradições e religiões, fazendo-as elementos chave para a segurança alimentar e nutricional em um nível global. Ademais, de acordo com Watanabe(2018), o crescimento do elevado nível de produtividade e qualidade da Avicultura no Brasil se deve ao avanço tecnológico e científico, em união com os sistemas de integração.

Ainda segundo Watanabe (2016), a automatização dos processos de produção será mais exigida, criando novas tendências conforme o possível aumento da preocupação com a redução dos custos. Esta situação relaciona-se com os conceitos expostos por Paganela et al. (2019). De acordo com Paganela et al. (2019), os elos entre as várias ligações da cadeia de produção criam relações complexas. A indústria agrícola altamente interligada pode planejar atividades e reduzir os custos de produção e a agilidade no acompanhamento das evoluções tecnológicas.

Outrossim, sabe-se que utilizando tecnologia avançada que visa o monitoramento automático em tempo real do bem-estar animal, saúde, impacto ambiental e parâmetros de produção, os agricultores inteligentes visam reduzir o trabalho e o uso de recursos, ao mesmo tempo em que melhoram o bem-estar animal (AVICULTURA INDUSTRIAL, 2018)

Diante do exposto convém à Emprapa (s.d.) o uso do monitoramento em tempo real das Aves em aviários biosseguros e auto sustentáveis. No setor da Avicultura, este processo é visto como uma forte tendência no setor. Dessa forma o uso de conhecimentos provenientes da análise de sistemas pode trazer diversas melhorias e avanços no processo produtivo e, conseqüentemente, uma ampliação dos lucros.

3.2 Visão Computacional

Primeiramente, vale destacar o livro “Feature Extraction and Image Processing for Computer Vision”, dos autores Mark Nixon e Alberto Aguado. De acordo com Nixon e

Aguado (2019), os sistemas com base em visão computacional processam imagens obtidas de câmeras eletrônicas de forma semelhante ao organismo humano, no qual o cérebro atua como um processador e os olhos atuam como um sistema óptico do hardware de vigilância. Além disso, segundo Szeliski (2010), a visão computacional tenta descrever o mundo que observamos em uma ou várias imagens, e reconstruir suas propriedades tal como, formatos, iluminação e distribuição de cores.

Aliado a isso, tem-se nos estudos de Khan et al. (2018) que a visão computacional esforça-se para desenvolver um método capaz de replicar uma das funções mais poderosas do sistema visual humano: O uso da luz, refletida até olhos por diversos objetos seguindo os princípios físicos de óptica, para inferir características 3D do mundo real. Soma-se então que nos estudos de Szeliski (2010), evidenciou-se que pesquisadores vêm desenvolvendo técnicas matemáticas, simultaneamente, para a reaquisição da aparência e o formato tridimensional de objetos em imagens.

Segundo Milano e Honorato (2014), basicamente todos os sistemas de visão computacional envolvem reconhecimento e identificação de objetos em imagens e transformações destes objetos em dados que serão processados e utilizados por um sistema especializado. Desse modo, convém evidenciar as etapas características do processo de visão computacional (Figura 1).




Figura 1 – Etapas do processo de visão computacional

Fonte: Autor

A etapa de aquisição de imagens é o primeiro passo no sistema de visão computacional e caracteriza-se pela captura, armazenamento e transmissão de uma imagem. Essa etapa pode ser realizada com instrumentos de diversos tipos como, por exemplo, câmeras digitais, celulares, smartphones, tablets, infravermelho, câmeras de segurança normais ou térmicas (BORTH et al., 2014).

Pré-processamento significa qualquer operação na qual a entrada consiste em dados do sensor e da qual a saída é uma imagem completa (PETERSEN et al, 2002). Pré Processamento é o processo realizado antes de obter informações de uma imagem, de forma a aplicar métodos específicos que facilitem a identificação de um objeto, como por

exemplo destaque de contornos, bordas, destaque de figuras geométricas, etc (MILANO; HONORATO, 2014).

A extração de recurso é usada para segmentação subsequente ou reconhecimento de objeto. O tipo de características que se deseja extrair muitas vezes correspondem a características geométricas ou perceptuais específicas em uma imagem (bordas, cantos e junções) ou dependentes da aplicação, por exemplo, características faciais. (EGMONT-PETERSEN; RIDDER; HANDELS, 2002).

Segmentar consiste na realidade em dividir a imagem em diferentes regiões, que serão posteriormente analisadas por algoritmos especializados em busca de informações ditas de "alto-nível" (ALBUQUERQUE; ALBUQUERQUE, 2000). A segmentação é a partição de uma imagem em partes que são coerentes de acordo com algum critério. Quando considerada como uma tarefa de classificação, o objetivo da segmentação é atribuir rótulos a pixels ou voxels individuais (EGMONT-PETERSEN; RIDDER; HANDELS, 2002).

O reconhecimento de objetos consiste em localizar as posições e, possivelmente, orientações e escalas de instâncias de objetos em uma imagem. O objetivo também pode ser atribuir um rótulo de classe a um objeto detectado (EGMONT-PETERSEN; RIDDER; HANDELS, 2002). Está relacionada a encontrar padrões ou regularidades em imagens, porém antes que o reconhecimento ocorra, o padrão deve ser detectado (BORTH et al., 2014).

3.3 Reconhecimento de Padrões

Segundo Anzai (2012), o uso do termo "reconhecimento" na computação significa que um computador reconhece que os padrões de objetos são aqueles que foram processados anteriormente. E em relação ao padrão de um objeto são dados espaciais e cronológicos recebidos do objeto por um dispositivo de entrada e levado ao sistema de reconhecimento.

É sentido que os processos de tomada de decisão de um ser humano estão de alguma forma relacionados ao reconhecimento de padrões; por exemplo, o próximo movimento em um jogo de xadrez é baseado sobre o padrão presente no quadro. O objetivo do reconhecimento de padrões é esclarecer esses mecanismos complicados de processos de tomada de decisão e automatizar essas funções usando computadores (FUKUNAGA, 2013).

Segundo Sa (2012), reconhecimento de padrões é a disciplina científica que lida

com métodos de descrição e classificação de objetos. De acordo com Murty e Devi (2011), reconhecimento de padrões pode ser definido como a classificação de dados baseados em um conhecimento já obtido ou em informações estatísticas extraídas de padrões e/ou suas representações.

Para fazer a identificação um sistema de visão necessita uma base de dados acerca dos objetos a serem reconhecidos, esta base de conhecimento pode ser implementada diretamente no código, através, por exemplo, de uma rede regrada, ou esta pode ser aprendida a partir de um conjunto de amostras dos componentes a serem reconhecidos utilizando técnicas de aprendizado de máquina.(MARENGONI; STRINGHINI, 2009)

Outrossim, um sistema para reconhecimento de padrões engloba três grandes etapas: representação dos dados de entrada e sua mensuração, extração das características e finalmente identificação e classificação do objeto em estudo (CASTRO; PRADO, 2002). Segundo Murty e Devi (2011), a etapa de classificação, frequentemente, é o último passo no processo geral, e envolve organizar objetos em classes separadas. De acordo com Murty e Devi (2011), no processo de classificação, atribuímos um rótulo de classe apropriado para um padrão baseado em uma abstração que é gerado usando um conjunto de padrões de treinamento ou conhecimento do domínio.

Segundo Marengoni e Stringhini (2009), as técnicas de reconhecimento de padrões podem ser divididas em duas categorias: estruturais, em que os padrões são descritos de forma simbólica, e a estrutura é a relação entre esses padrões; o outro grupo é baseado no uso de técnicas que usam teoria de decisão e os padrões neste grupo são descritos por atributos quantitativos, portanto, é necessário determinar se o objeto possui esses atributos.

3.4 Redes Neurais Artificiais

Segundo Haykin (2007), o cérebro é um computador paralelo não linear altamente complexo que tem a capacidade de organizar componentes estruturais, chamados neurônios, para realizar determinados processamentos (reconhecimento de padrões, percepção e controle de movimento) muito mais rápido que os computadores digitais mais eficientes de hoje.

Ademais, conforme O'Shea e Nash (2015), inspiradas fortemente pelo jeito que o

sistema nervoso biológico opera, as redes neurais artificiais(ANN) são sistemas de processamento computacionais formados de nós interconectados(neurônios), que trabalham de forma cruzada e de forma dividida para aprender juntos com a entrada, a fim de otimizar sua saída final. De acordo com Haykin (2007), rede neural é uma máquina projetada para modelar a maneira como o cérebro executa uma tarefa ou função específica; a rede é geralmente implementada usando componentes eletrônicos ou simulada por programação em um computador digital. A Figura 2 apresenta um neurônio biológico(esquerda) e um modelo computacional(direita).




Figura 2 – Neurônio biológico(esquerda) e modelo computacional(direita).

Fonte: (KHAN et al., 2018)

Conforme a Figura 2, o modelo computacional de um neurônio consiste em um conjunto de conexões de entrada que alimentam a unidade com ativações vindas de outros neurônios. Essas entradas são ponderadas usando um conjunto de pesos denotados por $\{w\}$. A unidade de processamento soma todas as entradas e aplica uma função de limite não linear (também conhecida como função de ativação) para calcular a saída. A saída final é então transmitida a outras unidades neurais conectadas (KHAN et al., 2018).

3.5 Rede Neural Convolucional

Soma-se a isso, a necessidade de se estabelecer as redes neurais convolucionais(CNN). Para O'Shea, Nash(2015), às CNNs são análogas às ANN tradicionais, sua composição corresponde a um sistema de neurônios que se auto-otimizam por meio do aprendizado e do aprimoramento dos saberes. As ConvNets são projetadas para processar dados que vêm na forma de várias matrizes, por exemplo, uma imagem colorida composta de três

matrizes de duas dimensões contendo intensidades de pixel nos três canais de cores (LECUN; BENGIO; HINTON, 2015).

A arquitetura de uma CNN é composta por uma série de camadas que irão processar as imagens de entrada, como mostrado na Figura 3. Com relação às camadas, estão divididas em: convolução, pooling e camadas totalmente conectadas (GU et al., 2018; LECUN; BENGIO; HINTON, 2015; O'SHEA; NASH, 2015; VOULODIMOS et al., 2018).




Figura 3 – Arquitetura de uma rede neural convolucional.

Fonte: (O'SHEA; NASH, 2015)

A camada convolucional é o componente principal de uma CNN. Inclui um conjunto de filtros (também chamados de kernels convolucionais) que realizam a convolução com uma certa entrada e geram um conjunto de feature maps na saída (KHAN et al., 2018).

As unidades em uma camada convolucional são organizadas em feature maps, onde cada unidade é conectada a uma parte da camada anterior por meio de um conjunto de pesos denominado de filtros. O resultado da soma dos pesos é então passado para uma Relu, que é uma unidade linear retificadora que produz zero em metade de seu domínio. (LECUN; BENGIO; HINTON, 2015).

Pooling é um conceito importante da CNN. Ele diminui a carga computacional, reduzindo o número de conexões entre as camadas convolucionais (GU et al., 2018). A camada de pooling não afeta a dimensão da profundidade do volume. A operação realizada por esta camada também é chamada de subamostragem ou redução da amostragem, pois a redução do tamanho leva a uma perda simultânea de informações (VOULODIMOS et al., 2018). A camada de pooling opera sobre cada mapa de ativação na entrada e calcula

sua dimensionalidade usando a função “MAX”. Na maioria das CNNs, eles vêm como max-pooling com núcleos de uma dimensionalidade de 2X2 aplicados com um stride de 2 ao longo das dimensões espaciais da entrada. Isso reduz o mapa de ativação para 25% do tamanho original - enquanto mantém o volume de profundidade em seu tamanho padrão (O’SHEA; NASH, 2015)

Seguindo várias camadas convolucionais e de pooling, o raciocínio de alto nível na rede neural é realizado por meio de camadas totalmente conectadas. Os neurônios em uma camada totalmente conectada têm conexões completas com todas as ativações na camada anterior, como seu nome indica. Sua ativação pode, portanto, ser calculada com uma multiplicação de matriz seguida por um desvio de polarização (VOULODIMOS et al., 2018)

3.6 Rede convolucional Yolo

De acordo com (REDMON et al., 2016), o algoritmo yolo trata a etapa de detecção de objetos como um problema de regressão. Ainda segundo (REDMON et al., 2016), o algoritmo trabalha em uma arquitetura de rede neural convolucional para a predição de múltiplas caixas delimitadoras(bounding boxes) juntamente com a probabilidade de conter objeto nas mesmas, e que possui uma eficiente performance na detecção de imagens treinadas.

Diferente de outros sistemas, onde propostas ou regiões de interesse são geradas explicitamente como janelas candidatas a objetos, nas quais uma inferência de classe é executada, YOLO processa cada imagem apenas uma vez para efetuar várias detecções em vez de processar as propostas individualmente. E isso garante vantagens em termos de velocidade (REYES et al., 2018). A Figura 4 mostra o procedimento da YOLO em uma imagem de entrada.




Figura 4 – Demonstração do funcionamento da rede Yolo com o uso de bounding box.
 Fonte: (REDMON et al., 2016)

O algoritmo divide a imagem de entrada em uma grade $S \times S$. Caso um objeto esteja dentro de uma célula do grid, essa célula do grid é responsável por detectar esse objeto. Cada célula do grid prevê B caixas delimitadoras, scores de confiança para essas caixas e probabilidade de C classes. Essas previsões são codificadas como um tensor de $S \times S \times (B \times 5 + C)$ (DU, 2018). A definição do score de confiança é feita de acordo com o cálculo: $Pr(Object) * IOU_{prevista}^{real}$. Se nenhum objeto existir nessa célula, as pontuações de confiança devem ser zero. Caso contrário, a pontuação de confiança será igual à interseção sobre a união (IOU) entre a caixa prevista e a verdade básica (REDMON et al., 2016).

O Yolo na sua primeira versão contou com 24 camadas convolucionais seguidas de 2 camadas totalmente conectadas. Em vez dos módulos iniciais usados pela rede GoogLeNet, simplesmente é utilizado camadas de redução 1×1 seguidas por camadas convolucionais 3×3 (REDMON et al., 2016)

Em 2017, foi lançada a versão 2 do YOLO com melhorias de desempenho, passando a utilizar um modelo totalmente convolucional. Segundo (REDMON; FARHADI, 2017), considerando imagens com 416×416 pixels, o YOLOv2 atingiu 67 FPS, 22 FPS a mais em relação a primeira versão do algoritmo, sendo 13,4% superior em termos de acurácia. Junto com versão 2, foi publicado um modelo pré-treinado chamado de YOLO9000, contendo 9

mil categorias de diferentes objetos, prontas para prever e detectar classes que não tenham dados rotulados.

YOLOv2 também usa uma nova rede com o pensamento “rede em rede”, prevê com pooling médio global e comprime os recursos colocando o núcleo convolucional entre os 3 núcleos convolucionais. Sua rede neural tem menos camadas convolucionais (19 em vez de 24 da YOLOv1) e menos filtros, mais 5 camadas máximas de pooling (DU, 2018).

A versão mais recente, Yolov3, lançada em 2018, apresenta melhorias de desempenho. A recente versão apresenta um novo método para extração de características. Para (REDMON; FARHADI, 2018), a nova rede neural convolucional é uma proposta híbrida entre a rede utilizada no YOLOv2, e a Darknet-19. Segundo (REDMON; FARHADI, 2018), YOLOv3 realiza a predição de áreas retangulares em três escalas diferentes, facilitando a aumentando a capacidade na detecção de objetos menores.

3.7 Métricas de Avaliação

As métricas de avaliação são calculadas com o intuito avaliar o desempenho da CNN em relação a etapa de treinamento e predição do algoritmo utilizado. As métricas apresentadas nesse seção é: acurácia(accuracy) e a função de perda(loss function).

3.7.1 Acurácia

A acurácia(ACC) ou taxa de erro avalia a capacidade de generalização dos classificadores. A acurácia avalia a correção completa de um classificador, em que o total de instancias são previstas corretamente quando testadas com dados ocultos por um classificador treinado (HOSSIN; SULAIMAN, 2015). Segundo Zhu et al. (2010), acurácia é a proporção de predições corretas, assim como positivos e negativos verdadeiros. A acurácia é realizada pela equação 3.1.

$$ACC = \frac{VP + VN}{VP + VN + FP + FN}, \quad (3.1)$$

sendo, VP verdadeiros positivos, TN Verdadeiros negativos , FP falso positivo e FN falso negativo.

3.7.2 Entropia Cruzada Binária

Durante o treinamento, a função de perda é uma importante métrica de avaliação, e é função que se deseja minimizar neste processo. Esta deve ser avaliada tanto sobre o conjunto de treinamento quanto sobre o conjunto de validação.

A entropia cruzada é uma métrica empregada para obter a distância entre as distribuições de probabilidade, e tem como objetivo medir a qualificação de um conjunto de probabilidades da classe estimada que corresponde as classes verdadeiras,

$$H(p, q) = - \sum_x p(x) \log q(x) \quad (3.2)$$

Onde $p(x)$ está a probabilidade desejada e $q(x)$ a probabilidade real.

4 Metodologia

4.1 Ambiente de Desenvolvimento

O algoritmo utilizado neste trabalho para a detecção de galinhas a partir de imagens coletadas em campo foi o YOLO (You Only Look Once) criado por Joseph Redmon (REDMON et al., 2016). Neste caso, em particular, foi utilizado o Yolov3 juntamente com a biblioteca tensorflow.

Foi utilizada uma implementação que segue algumas técnicas e boas práticas de desenvolvimento limpo(clean) para o Yolov3, desenvolvido por terceiros, criado com base no repositório original juntamente com outros repositórios não oficiais. Uma das vantagens é que essa implementação traz melhorias no desempenho da detecção.

Algumas bibliotecas necessárias para o treinamento e detecção das imagens foram instaladas através do ambiente Anaconda. Dentre essas estão: opencv, tensorflow, keras, python3, numpy, etc.

As etapas de detecção de galinha, tratadas nesse trabalho foram executados em um notebook MacBook Pro (13-inch, 2020, Two Thunderbolt 3 ports). Processador 1,4 GHz Intel Core i5 Quad-Core. Memória 8 GB 2133 MHz LPDDR3.

4.2 Aquisição de Imagens

Primeiramente, é válido destacar que a aquisição de imagens de Galinhas em campo é um problema que exige uma carga considerável de trabalho. Para a realização desse processo é necessário capturar um número considerável de imagens para que a classificação seja feita de maneira satisfatória e, paralelamente, deve-se fazer o manejo correto das aves. Tais tarefas, dificultaram o processo de aquisição de imagens, visto que, a destreza manual e cuidado com o animal são arduamente conciliadas.

Para cada galinha foram capturadas 3 imagens e, conforme visualizado na Figura 5, em 3 planos distintos: Plano lateral direito (à esquerda), plano lateral esquerdo (à direita) e plano frontal (ao centro).



Figura 5 – Imagens capturadas
Fonte: Autor

As galinhas capturadas apresentavam características próprias como a plumagem da região do pescoço, tamanho da crista, formato do bico, etc. Foram coletadas 501 imagens ao todo, cada uma com o mesmo padrão de dimensão (altura e largura) de 1280x1920. Dessas imagens coletadas, foram descartadas 33 em virtude da má qualidade das imagens, conforme ilustra a Figura 6. Complementa-se que foram descartadas as 3 imagens, frontal, lateral esquerdo e lateral direito referente ao indivíduo. Portanto, a base de imagens utilizada para esta pesquisa foi de 468 imagens.




Figura 6 – Imagens Descartadas
Fonte: Autor

Nenhuma espécie de tratamento nas imagens foi aplicada, seja de redução de ruídos, filtros ou quaisquer outras espécies de melhoria digital das gravuras.

4.3 Classificação

4.3.1 Treinamento

Para o treinamento, foi necessário a rotulação manual do elemento de interesse presente nas imagens. As rotulações foram salvas no formato PASCAL VOC e separadas aleatoriamente com 80% para treinamento e 20% para validação. Ao final do processo

foram geradas algumas pastas com os seguintes conteúdos: Arquivos xml para cada imagem (incluindo o nome do arquivo de imagem, coordenadas da área retangular construída que contém o objeto, bem como sua categoria); Dois arquivos txt(um com os dados de treino e outro com dados de validação); Imagens do objeto a ser reconhecido (galinha) em formato jpeg; Um arquivo no formato .pbt.txt contendo o identificador (número) e a categoria (classe) do objeto.

Além disso, foram gerados dois arquivos binários de treino e validação em formato .tfrecord, formatos compatíveis com o tensorflow, que contém dados para o aprendizado da rede neural.

Com as imagens definidas, foram passados para o arquivo de treino alguns parâmetros necessários ao treinamento: O arquivo de rótulos (.names) com o nome das classes a serem treinadas (neste caso foi criado somente a classe 'galinha'); Os arquivos tfrecords (train.tfrecord e val.tfrecord); O arquivo de pesos (weights); Taxa de aprendizagem (learning rate) de 0,001; 50 Épocas; Batch de tamanho 8; Entrada das imagens com 416x416 de dimensão; A versão completa da implementação do Yolov3 do repositório utilizado. A Tabela 1 mostra alguns hiperparâmetros da rede neural com seus respectivos valores.

Tabela 1 – Hiperparâmetros e seus respectivos valores

Hiperparâmetro	Valor
Otimizador	Adam
Taxa de aprendizado	0.001
Função de Ativação	Leaky Relu
Épocas	100
Batch	8
Função de Perda	Cross-Entropy

A escolha desses hiperparâmetros foi realizada variando-se os números de épocas e o tamanho do batch. A escolha dos parâmetros se deu com a finalidade de criar modelos com a maior acurácia possível, com base na arquitetura utilizada.

4.3.2 Aplicação da Rede Neural

O processo de aplicação da rede neural convolucional inicia-se a partir das imagens de entrada(original e marcada), de dimensões 416x416 e com os três canais de cores RGB, na primeira camada convolucional. Nesta camada é realizado o processo de convolução com 512 neurônios e, em seguida, é aplicada a função de ativação Leaky ReLU, uma versão

melhorada da função ReLU, útil para trazer não linearidade ao modelo. Na sequência, é realizada a redução das dimensões das representações, através da camada max-polling, que extrai o valor máximo de vizinhança. O processo se repete de forma análoga nas próximas camadas convolucionais, porém a segunda camada com 256 e a terceira com 128 neurônios. A saída das camadas convolucionais e pooling (subamostragem) representa características da imagem de entrada, e estas são passadas para as camadas totalmente conectadas para a classificação da imagem, como ilustra a Figura 7.




Figura 7 – Processo para a classificação das galinhas com a apresentação de uma rede neural convolucional
Fonte: Autor

A arquitetura apresenta kernels (filtros) de tamanho 1 e 3. A convolução com o kernel 1x1 atua como um filtro que seleciona os melhores recursos em um conjunto de canais e os agrupa como um novo conjunto. A função de ativação usada nas camadas de convolução foi a LeakyRelu. A função Leaky ReLU não zera os valores negativos, ao invés disso aplica a eles um fator de divisão, tornando-os muito pequenos (próximos de zero). O Otimizador Adam foi utilizado batch normalization e a função de perda utilizada foi a entropia cruzada binária(binary cross-entropy), no qual o valor retornado será uma probabilidade entre 0 e 1.

Não foi utilizado nenhuma técnica de transfêrencia de aprendizado(transfer learning) e a rede foi treinada utilizando dados próprios.

4.3.3 Detecção

Nesta pesquisa, utilizou-se na etapa de classificação uma camada completamente conectada para gerar a saída da rede, como ilustra a Figura 7. Essa camada recebe todo o aprendizado das características, geradas pelas convoluções, na etapa anterior. Essa etapa

é crucial para determinar se o modelo conseguiu aprender a classe de saída esperada (galinha).

O processo de detecção foi realizado configurando o arquivo de detecção do repositório utilizado de acordo com os parâmetros passados. Dentre os parâmetros estava o modelo gerado na etapa de classificação.

Entretanto, considerando a pouca quantidade de imagens no treino, a etapa de detecção apresentou algumas falhas e a rede não obteve sucesso em detectar o objeto em algumas imagens.

4.3.4 Avaliação do Modelo

Uma métrica é uma função para julgar o desempenho do modelo de Deep Learning. Neste foram utilizadas duas métricas para a avaliação: acurácia (ACC) e a entropia cruzada, ambas descritas na Seção 3.7.

A acurácia foi utilizada para identificar o número de previsões corretas do modelo. Dentre todas as classificações, quantas o modelo classificou corretamente. A entropia cruzada foi utilizada para medir as probabilidades da classe estimada (Galinha) que corresponde as classes verdadeiras.

5 Resultados

Nesta seção são apresentados os resultados obtidos pela arquitetura da CNN, na classificação de galinha, de acordo com a análise das imagens.

5.1 Base de Imagens

Inicialmente, a base contou com 501 imagens e após uma avaliação, foram descartadas 33 imagens, devido a baixa qualidade, resultando em 468 imagens.

As 468 imagens foram usadas para a realização deste trabalho e assim, foram formadas bases de treino, validação e teste para a realização do treinamento e detecção, com valores mostrados na Tabela 2.

Tabela 2 – Separação das imagens em bases de treino, validação e teste

Bases	%	Separação 1	%	Separação 2
Treino	80	374	80	299
Validação	0		20	75
Teste	20	94	0	94

5.2 Classificação

O processo de treinamento demandou cerca de 2 horas e, ao final dessa etapa, o modelo gerado pela rede neural apresentou acurácia de 50%, com 100 épocas de treinamento, na classificação das imagens do conjunto de validação.

Ao iniciar o treinamento da rede neural, a perda(loss) tem seu valor inicial elevado, e a medida que os passos(epocas) do treinamento avançava, esse valor reduziu significativamente, finalizando o processo de treinamento do modelo. Para o aprendizado da rede, o valor da loss deve diminuir, de modo que fique o mais proximo de zero.

A Tabela 3 apresenta o valor de acuracia obtido, de acordo com o último modelo gerado.

Tabela 3 – Resultado da aplicação da rede neural convolucional

Treino/Valiação	Épocas	Base (Treino/Validação)	Acúracia
80/20	100	299/75	0,50

Após as avaliações, não possível obter um valor acima de 0.5, pelo fato da baixa quantidade de imagens pertencentes nas bases de treino e validação para o treinamento da rede.

6 Conclusão e Trabalhos Futuros

Nessa pesquisa foi apresentada uma abordagem para detecção de galinhas por meio de imagens, através da aplicação de técnicas modernas de visão computacional e rede neural convolucional.

O objetivo do trabalho possibilitou verificar a capacidade da CNN em classificar a galinha, obtendo uma acurácia de 0.50, com as iterações realizadas. O trabalho apresentou resultados satisfatórios na classificação de 468 imagens.

Observamos que a métrica utilizada na literatura foi suficiente para uma análise confiável do resultado final. Para o objetivo futuro deseja-se aumentar o número de imagens e configurar alguns parâmetros da CNN para melhorar a acurácia do modelo.

6.1 Trabalhos Futuros

Os seguintes passos serão realizados em atividades futuras:

1. Aumentar a base de imagens para se obter um treinamento satisfatório e consequentemente fazer a detecção de galinhas em imagens e vídeos.
2. Realizar o treinamento com outras arquiteturas de Rede Neural convolucional.
3. Incluir outras métricas de avaliação para avaliar o desempenho da rede neural no treinamento e na validação.
4. Ajustar alguns parâmetros da metodologia com o objetivo de melhorar a acurácia do modelo.
5. Estudar algumas técnicas de processamento de imagens para obter uma detecção favorável.

Referências

- ALBUQUERQUE, M. P. de; ALBUQUERQUE, M. P. de. Processamento de imagens: métodos e análises. *Centro Brasileiro de Pesquisas Físicas MCT*, 2000.
- ANZAI, Y. *Pattern recognition and machine learning*. [S.l.]: Elsevier, 2012.
- AVICULTURA INDUSTRIAL. *Inovações inteligentes de aves oferecem novos insights*. 2018. Disponível em:<<https://www.aviculturaindustrial.com.br/imprensa/inovacoes-inteligentes-de-aves-oferecem-novos-insights/20180727-090947-h492>>. Acesso em: 08 de jun. de 2021.
- BORTH, M. R. et al. A visão computacional no agronegócio: Aplicações e direcionamentos. *7º Encontro Científico de Administração, Economia e Contabilidade (ECAECO)*, 2014.
- BRUNELLI, R. *Template matching techniques in computer vision: theory and practice*. [S.l.]: John Wiley & Sons, 2009.
- CASTRO, A. A. M. D.; PRADO, P. P. L. D. Algoritmos para reconhecimento de padrões. *Revista Ciências Exatas*, v. 8, n. 2002, 2002.
- CHIOVATTO, M. Watson, uso de inteligência artificial (ai) e processos educativos em museus. *Revista Docência e Ciberultura*, v. 3, n. 2, p. 217–230, 2019.
- COELHO, C. N.; BORGES, M. O complexo agro-industrial (cai) da avicultura. *Revista de política agrícola*, v. 8, n. 3, p. 1–36, 1999.
- DARGAN, S. et al. A survey of deep learning and its applications: A new paradigm to machine learning. *Archives of Computational Methods in Engineering*, Springer, p. 1–22, 2019.
- DU, J. Understanding of object detection based on cnn family and yolo. In: IOP PUBLISHING. *Journal of Physics: Conference Series*. [S.l.], 2018. v. 1004, n. 1, p. 012029.
- EGMONT-PETERSEN, M.; RIDDER, D. de; HANDELS, H. Image processing with neural networks—a review. *Pattern recognition*, Elsevier, v. 35, n. 10, p. 2279–2301, 2002.
- EMPRAPIA. *Tendências em avicultura*. s.d. Disponível em:<<https://www.embrapa.br/suinos-e-aves/cias/tendencias/aves>>. Acesso em: 08 de jun. de 2021.
- FUKUNAGA, K. *Introduction to statistical pattern recognition*. [S.l.]: Elsevier, 2013.
- GONZALEZ, R. C.; WOODS, R. C. *Processamento digital de imagens*. [S.l.]: Pearson Educación, 2009.
- GRANDO, M. L. *Classificação de bovinos por meio da característica do focinho utilizando visão computacional*. Dissertação (B.S. thesis) — Universidade Tecnológica Federal do Paraná, 2018.

- GU, J. et al. Recent advances in convolutional neural networks. *Pattern Recognition*, Elsevier, v. 77, p. 354–377, 2018.
- HASHEMI, N. S. et al. Template matching advances and applications in image analysis. *arXiv preprint arXiv:1610.07231*, 2016.
- HAYKIN, S. *Redes neurais: princípios e prática*. [S.l.]: Bookman Editora, 2007.
- HISHAM, M. et al. Template matching using sum of squared difference and normalized cross correlation. In: IEEE. *2015 IEEE Student Conference on Research and Development (SCORed)*. [S.l.], 2015. p. 100–104.
- HOSSIN, M.; SULAIMAN, M. A review on evaluation metrics for data classification evaluations. *International Journal of Data Mining & Knowledge Management Process*, Academy & Industry Research Collaboration Center (AIRCC), v. 5, n. 2, p. 1, 2015.
- JACKSON, P. C. *Introduction to artificial intelligence*. [S.l.]: Courier Dover Publications, 2019.
- KHAN, S. et al. A guide to convolutional neural networks for computer vision. *Synthesis Lectures on Computer Vision*, Morgan & Claypool Publishers, v. 8, n. 1, p. 1–207, 2018.
- KUMAR, S. et al. Deep learning framework for recognition of cattle using muzzle point image pattern. *Measurement*, Elsevier, v. 116, p. 1–17, 2018.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *nature*, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015.
- LOPES, F. A. A. Visão computacional para estimativa de comportamento de aglomeração de galinhas poedeiras. Universidade Estadual Paulista (UNESP), 2019.
- MARENGONI, M.; STRINGHINI, S. Tutorial: Introdução à visão computacional usando opencv. *Revista de Informática Teórica e Aplicada*, v. 16, n. 1, p. 125–160, 2009.
- MARSOT, M. et al. An adaptive pig face recognition approach using convolutional neural networks. *Computers and Electronics in Agriculture*, Elsevier, v. 173, p. 105386, 2020.
- MILANO, D. de; HONORATO, L. B. *Visao computacional*. 2014.
- MOTTET, A.; TEMPIO, G. Global poultry production: current state and future outlook and challenges. *World's Poultry Science Journal*, Taylor & Francis, v. 73, n. 2, p. 245–256, 2017.
- MURTY, M. N.; DEVI, V. S. *Pattern recognition: An algorithmic approach*. [S.l.]: Springer Science & Business Media, 2011.
- NIXON, M.; AGUADO, A. *Feature extraction and image processing for computer vision*. [S.l.]: Academic press, 2019.
- O'SHEA, K.; NASH, R. An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*, 2015.
- PAGANELA, V. M. et al. A inovação na cadeia produtiva avícola brasileira. Florianópolis, SC, 2019.

- REDMON, J. et al. You only look once: Unified, real-time object detection. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2016. p. 779–788.
- REDMON, J.; FARHADI, A. Yolo9000: better, faster, stronger. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2017. p. 7263–7271.
- REDMON, J.; FARHADI, A. Yolo3: An incremental improvement. *arXiv preprint arXiv:1804.02767*, 2018.
- REYES, E. et al. Near real-time object recognition for pepper based on deep neural networks running on a backpack. In: SPRINGER. *Robot World Cup*. [S.l.], 2018. p. 287–298.
- SA, J. M. D. *Pattern recognition: concepts, methods and applications*. [S.l.]: Springer Science & Business Media, 2012.
- SALTORATTO, A. Y. K. et al. Monitoramento de avicultura a partir de técnicas de visão computacional. In: *Colloquium Exactarum. ISSN: 2178-8332*. [S.l.: s.n.], 2013. v. 5, n. 2, p. 47–66.
- SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for deep learning. *Journal of Big Data*, Springer, v. 6, n. 1, p. 1–48, 2019.
- SZELISKI, R. *Computer vision: algorithms and applications*. [S.l.]: Springer Science & Business Media, 2010.
- VOULODIMOS, A. et al. Deep learning for computer vision: A brief review. *Computational intelligence and neuroscience*, Hindawi, v. 2018, 2018.
- WATANABE, G. E. O desenvolvimento da avicultura no brasil e as tendências para os próximos anos. 2016.
- ZEN, S. D. et al. Evolução da avicultura no brasil. *Informativo CEPEA, Análise trimestral, custos de produção da avicultura. Ano*, v. 1, 2014.
- ZHANG, Y. et al. *Image processing*. [S.l.]: Walter de Gruyter GmbH & Co KG, 2017.
- ZHU, W. et al. Sensitivity, specificity, accuracy, associated confidence interval and roc analysis with practical sas implementations. *NESUG proceedings: health care and life sciences, Baltimore, Maryland*, v. 19, p. 67, 2010.