



**MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO PIAUÍ
CENTRO DE CIÊNCIAS AGRÁRIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ZOOTECNIA TROPICAL**

JOSÉ DOS SANTOS DE MOURA

**ALGORITMO DE VISÃO COMPUTACIONAL PARA IDENTIFICAÇÃO DE
GALINHAS DA RAÇA CANELA-PRETA**

Teresina

2022

JOSÉ DOS SANTOS DE MOURA

**ALGORITMO DE VISÃO COMPUTACIONAL PARA IDENTIFICAÇÃO DE
GALINHAS DA RAÇA CANELA-PRETA**

Dissertação apresentada ao Programa de Pós-Graduação em Zootecnia Tropical da Universidade Federal do Piauí como requisito para obtenção do título de Mestre em Zootecnia Tropical.

Orientador: Dr. Natanael Pereira da Silva Santos
Co-orientador: Dr. Otílio Paulo da Silva Neto

Teresina

2022

FICHA CATALOGRÁFICA
Universidade Federal do Piauí
Biblioteca Comunitária Jornalista Carlos Castello Branco
Serviço de Processos Técnicos

M929a Moura, José dos Santos de.
Algoritmo de visão computacional para identificação de galinhas da raça Canela-preta. / José dos Santos de Moura. – 2022.
65 f.: il.

Dissertação (Mestrado) – Universidade Federal do Piauí, Pós-Graduação em Zootecnia Tropical, Teresina, 2022.
“Orientador: Prof. Dr. Natanael Pereira da Silva Santos.”

1. Galinhas. 2. Inteligência Artificial. 3. Rede neural convolucional. I. Moura, José dos Santos de. II. Título.

CDD 636.5

Bibliotecário: Géσιο dos Santos Barros – CRB-3/1469

ALGORITMO DE VISÃO COMPUTACIONAL PARA IDENTIFICAÇÃO DE
GALINHAS DA RAÇA CANELA-PRETA

JOSÉ DOS SANTOS DE MOURA

Dissertação aprovada em: 11/02/2022

Banca Examinadora:



Prof. Dr. Natanael Pereira da Silva Santos (Presidente) / DZO /UFPI



Prof. Dr. José Lindenberg Rocha Sarmiento (Interno) / DZO/CCA/UFPI



Prof. Dr. Romuere Rodrigues Veloso e Silva (Interno) / CSHNB/UFPI



Prof. Dr. Marcos Jacob de Oliveira Almeida (Externo) / Embrapa Meio-Norte



Prof. Dr. Otilio Paulo da Silva Neto (Externo) / IFPI

Dedico

Aos meus amados pais, irmãos, esposa e filhas.

AGRADECIMENTOS

Agradeço a Deus, pela minha vida, e por me permitir ultrapassar todos os obstáculos encontrados ao longo da realização desta pesquisa de dissertação.

Aos meus pais: José Reis de Moura e Gonçala Rosa de Moura.

Agradeço à minha esposa, Jacquelany Marreiros de Moura, pelo apoio e pelas palavras de incentivo durante toda a trajetória desta pesquisa.

Às minhas filhas, Ana Beatriz de Miranda Moura e Maria Marreiros de Moura, por todo o carinho.

Aos meus irmãos Jeovânio Pereira de Moura e Lindalva Rosa de Moura.

Ao meu orientador, Natanael Pereira da Silva Santos, e ao co-orientador, Otilio Paulo da Silva Neto, pela orientação, pela paciência e confiança, pela preocupação com meu bem-estar e pelos ensinamentos durante toda a pesquisa. A vocês o meu muito obrigado.

Aos meus professores Arnaud Azevedo Alves, Danielle Maria Machado Ribeiro Azevedo, Fábio Barroso Britto, José LindenbergRocha Sarmento, Leilane Rocha Barros Dourado e Natanael Pereira da Silva Santos pelas correções e ensinamentos que me permitiram apresentar um melhor desempenho durante a pesquisa.

Ao meu amigo e professor da UFPI- *Campus* Picos, Romuere Rodrigues Veloso e Silva pelo apoio durante a coleta de dados.

Ao meu co-orientando do curso tecnólogo em Análise de Sistema do IFPI- *Campus* Teresina Central, Ícaro Victor Félix Campelo, pela disponibilidade e apoio durante as análises dos resultados.

Aos meus amigos do "Projeto Canela-Preta", Marcos Jacob de Oliveira Almeida e Débora Araújo de Carvalho, por me incentivarem a fazer uma pós-graduação e colaborarem na construção deste projeto de pesquisa.

Ao meu amigo JeydsonJonys Barros Batista, que sempre esteve disponível para me auxiliar nas revisões de língua portuguesa, dos vários trabalhos feitos durante esses 18 meses, sempre prestativo e rápido nas correções.

Ao meu amigo e professor do IFPI - *Campus* Avançado José de Freitas, Luiz Carlos de Melo Júnior, que sempre esteve disponível para me auxiliar nas atividades de Estatística e Avicultura.

Aos colaboradores do IFPI -*Campus* Avançado José de Freitas, Antoniel de Sousa Santos e Luiz Carlos Soares da Silva, pelo apoio na construção dos ninhos e cuidados com as galinhas do experimento.

Aos meus amigos do criatório Débora Carvalho, o senhor Josimar Angélico de Carvalho e Euraíde Araújo Pessoa Carvalho, pela receptividade, pelo carinho e por disponibilizar o criatório para realização desta pesquisa. O meu muito obrigado.

Agradeço ainda à Universidade Federal do Piauí – UFPI, pela oportunidade de fazer parte do quadro de discentes desta instituição de excelência em ensino e, para todos nós, uma referência!

A todos os servidores e colaboradores do Instituto Federal do Piauí – *Campus* Avançado José de Freitas pelo apoio durante o desenvolvimento da pesquisa e a todos que participaram, direta ou indiretamente, do desenvolvimento desta pesquisa, enriquecendo o meu processo de aprendizado.

LISTA DE ILUSTRAÇÕES

REFERENCIAL TEÓRICO

Figura 1 – Reconhecimento e classificação de imagens por sistemas de visão computacional	21
Figura 2 – Etapas do processo de visão computacional	21
Figura 3 – Neurônio biológico (a) e modelo computacional neural (b)	24
Figura 4 – Fluxograma esquemático da arquitetura de uma rede neural convolucional	25
Figura 5 – Operação de convolução em uma camada convolucional	26
Figura 6 – Ilustração do processo de <i>max-pooling</i>	27
Figura 7 – Demonstração do funcionamento da rede YOLO com o uso de caixa delimitadora.....	28
Figura 8 – (a) Imagem pesquisa, (b) <i>Template</i> e (c) Imagem b extraindo característica da imagem a	29

CAPÍTULO I

Fig. 1. Different picture capture planes; (a) right side view; (b) front view; (c) left side view	44
Fig. 2. Example of images of Canela-Preta hens removed from the database	45
Fig. 3. Chicken identification process using convolutional neural network.....	45
Fig. 4. Chicken identification process using template matching.....	46
Fig. 5. (a) Image of Canela-Preta chicken detected and its bounding box; (b) Image of Canela-Preta chicken cropped from (a) delimited by the bounding box.	48
Fig. 6. Canela-Preta hen identified using template matching	49
Fig. 7. Training and validation accuracy values of the convolutional neural network.	52

LISTA DE TABELAS

Table 1 Convolutional neural network architecture for identification of Canela-Preta chickens	59
Table 2 Number of images of Canela-Preta chickens for each dataset.....	60
Table 3 Number of images detected using the YOLO algorithm	61
Table 4 Identification using template matching.....	62
Table 5 Comparison of methods used in similar studies	63

LISTA DE ABREVIATURAS E SIGLAS

ACC	Acurácia
ANN	<i>Artificial neural network</i> (Rede neural artificial)
BNB	Banco do Nordeste do Brasil
CCN	Correlação cruzada normalizada
CNN	<i>Convolutional neural network</i> (Rede neural convolucional)
COCO	<i>Common objects in context</i> (Objetos comuns em contexto)
DMA	Desvio médio absoluto
Embrapa	Empresa Brasileira de Pesquisa Agropecuária
Eq.	Equação
FN	Falso negativo
FP	Falso positivo
IOU	Interseção sobre a união
KNN	<i>K-Nearest Neighbor</i> (K-vizinho mais próximo)
ONGs	Organizações não governamentais
RAM	<i>Random access memory</i> (Memória de acesso aleatório)
ReLU	<i>Rectified linear unit</i> (unidade linear retificada)
RGB	<i>Red, green, and blue</i> (vermelho, verde e azul)
SEDUC	Secretaria de Estado da Educação
UESPI	Universidade Estadual do Piauí
UFPI	Universidade Federal do Piauí
UFVJM	Universidade Federal dos Vales do Jequitinhonha e Mucuri
VN	Verdadeiro negativo
VP	Verdadeiro positivo
YOLO	<i>You only look once</i> (olhe apenas uma vez)

LISTA DE SÍMBOLOS

%	Porcentagem
2D	Bidimensional
3D	Tridimensional
x	Multiplicação
Σ	Somatório
Kg	Quilograma
mm	Milímetro
GB	Gigabyte

RESUMO

MOURA, José dos Santos de. **Algoritmo de visão computacional para identificação de galinhas da raça Canela-preta**. 2022. 65p. Dissertação (Mestrado em Zootecnia Tropical) – Universidade Federal do Piauí, Teresina, 2022.

Com o aumento da produção comercial dos criatórios de animais puros da raça de galinhas Canela-Preta surge a necessidade de automatizar a identificação dos animais. Algoritmos de visão computacional têm se mostrado eficientes na automação de identificação de animais para zootecnia de precisão. Neste sentido, este trabalho tem como proposta desenvolver um algoritmo com base em visão computacional para detectar e identificar, por meio de imagens, galinhas da raça Canela-Preta. Para essa finalidade, foram capturadas 501 imagens de 167 fêmeas adultas. No entanto, 33 imagens de 11 indivíduos foram descartadas devido à baixa qualidade, de modo que apenas 468 imagens com resolução 1280 x 1920 pixels serviram como base de dados. Isto resultou em 156 indivíduos tomados como referência em três planos distintos (lateral direito, lateral esquerdo e frontal). Foram utilizados dois métodos para a identificação das galinhas. O primeiro consistiu na aplicação de uma rede neural convolucional (CNN), utilizando as 468 imagens da base separadas em treino, validação e teste, para gerar o modelo e, posteriormente, identificar o indivíduo. O segundo método utilizou 156 imagens frontais das galinhas para a detecção dos indivíduos pela rede YOLO (*you only look once*) e, em seguida, o *template matching*, que buscou as imagens detectadas para encontrar a melhor similaridade entre uma imagem de entrada (*template*) e outra de pesquisa (indivíduo). Como resultado, na etapa de detecção, obteve-se taxa de acerto de 86,54% e 14,46% de erro, correspondendo a 135 e 21 imagens, respectivamente. Para a etapa de identificação com uso da CNN, foi obtida acurácia de 40%. A técnica de *template matching* conseguiu identificar os indivíduos com acurácia de 86,54%, similaridade média de 99,58% e taxa de erro médio de 0,42%. Conclui-se que este trabalho atingiu sua proposta de desenvolver um algoritmo para identificar individualmente galinhas caipiras da raça Canela-Preta. Esse algoritmo poderá ser utilizado para a identificação de galinhas por meio de imagens, monitoramento,

controle genealógico, bem-estar e tomadas de decisões quanto ao manejo das galinhas.

Palavras-chave: galinhas; inteligência artificial; rede neural convolucional; *template matching*; Yolo.

ABSTRACT

MOURA, José dos Santos de. **Computer vision algorithm for identification of Canela-preta chickens**. 2022. 65p. Dissertation (Master of Tropical Animal Science) – Federal University of Piauí, Teresina, 2022.

The need for automated animal identification emerges with the increased commercial production of purebred Canela-Preta chickens. In this sense, computer vision algorithms have proven to be efficient in the automation of animal identification for precision livestock farming. In the current study, we proposed the development of an algorithm based on computer vision to detect and identify Canela-Preta chickens through images. For this purpose, 501 images of 167 adult female chickens were captured. Nevertheless, 33 low quality images of 11 individuals were discarded, so that the database was composed of only 468 images with 1280 × 1920 pixels. This resulted in 156 individuals used as reference in three different planes (right side view, left side view, and frontal plane). Two methods were used for chicken identification. The first method was the application of a convolutional neural network (CNN), using the 468 images of the database, which were distributed into training, validation, and testing to generate the model and subsequently identify the individual. The second method used 156 frontal images of the chickens for detection of the individuals applying the YOLO (you only look once) network, and then template matching, which searched the detected images to find the best similarity between an input image (template) and a search image (animal). A rate of 86.54% accuracy and an error rate of 14.46% were obtained in the detection step, which corresponded to 135 and 21 images, respectively. An accuracy of 40% was reached in the identification step using the CNN. The template matching allowed the identification of individuals with accuracy of 86.54%, average similarity of 99.58%, and average error rate of 0.42%. We concluded that this work has achieved its proposal of developing an algorithm for individual identification of Canela-Preta free-range chickens. Thus, this algorithm could be used for the image identification of chickens, monitoring, genealogical control, welfare, and decision-making regarding the management of chickens.

Keywords: chickens; artificial intelligence; convolutional neural network; template matching; Yolo.

SUMÁRIO

1 INTRODUÇÃO	17
2 REFERENCIAL TEÓRICO	18
2.1 Raça Canela-Preta	18
2.2 Visão computacional	20
2.3 Reconhecimento de padrões	22
2.4 Rede neural convolucional	24
2.5 YOLO (<i>you only look once</i>)	27
2.6 <i>Template matching</i>	29
2.7 Métricas de avaliação	30
2.7.1 Acurácia (ACC)	30
2.7.2 Desvio médio absoluto (DMA)	30
2.7.3 Correlação cruzada normalizada (CCN)	31
2.8 Trabalhos relacionados	31
3 REFERÊNCIAS	34
CAPÍTULO I	38
1 Introduction	41
2 Materials and methods	43
2.1. Ethical certification and experimental characterization	43
2.2. Image collection	44
2.3. Image-based methods for identification of Canela-Preta chickens	45
2.3.1. Identification algorithm using convolutional neural network.....	46
2.3.2. Identification algorithm using template matching.....	47
2.3.2.1. Detection using YOLO	47
2.3.2.2. Extraction of the region of interest.....	48
2.3.2.3. Identification of Canela-Preta chickens using template matching.....	48
2.4. Evaluation metrics	50
2.4.1. Accuracy.....	50
2.4.2. Mean absolute deviation.....	50
2.4.3. Normalized cross-correlation	51
2.5. Environment for algorithm development.....	51
3 Results	51
3.1. Convolutional neural network	51
3.2. Template matching	53

3.2.1. Detection	53
3.2.2. Identification	53
4 Discussion	53
5 Conclusions	55
References	56
CONSIDERAÇÕES FINAIS	64
APÊNDICES	65

1 INTRODUÇÃO

As galinhas domésticas (*Gallus gallus*) foram introduzidas no Brasil em meados do ano de 1500 pelos colonizadores portugueses. Essas galinhas se multiplicaram por meio de cruzamentos aleatórios no decorrer dos séculos, sob a pressão de seleção do ambiente e deram origem às raças nativas brasileiras, distribuídas em todas as regiões do país (CARVALHO et al., 2016).

Dentre as raças surgidas no Brasil e denominadas nativas, tem-se a raça Canela-Preta, que apesar de já ser criada tradicionalmente por pequenos produtores no Piauí, se tornaram objeto de interesse institucional a partir do ano de 2008.

Muito valorizada pelo mercado consumidor do Piauí, a produção de galinhas caipira da raça Canela-Preta vem sendo estimulada por órgãos públicos, privados e organizações não governamentais (ONGs). Deste modo, o número efetivo desses animais vem crescendo consideravelmente e seus produtos (carne e ovos) são bem aceitos no comércio local com valor comercial agregado (CARVALHO et al., 2021). Esse aumento fortalecerá a avicultura no Brasil, principalmente nos quesitos relacionados à biossegurança, sanidade e qualidade dos animais.

Diante do aumento da produção comercial dos criatórios de animais puros da raça Canela-Preta e da demanda por manejos que visem o bem-estar desses animais na produção, vê-se a necessidade de identificar essas aves por meio de técnicas não invasivas, sem a necessidade de retenção em gaiolas. Assim, surge a necessidade de automatizar a identificação dos animais para aperfeiçoar os avanços na cadeia produtiva das galinhas Canela-Preta.

A identificação precisa do animal por meio da análise de imagens pode abrir novos caminhos para programas de rastreabilidade animal, o que é de grande importância, em virtude da crescente demanda por segurança alimentar por consumidores finais em todo o mundo. Se forem precisas ao longo de todo o ciclo de vida da ave, essas informações com base em imagens permitiriam um maior nível de segurança de dados coletados e reduziriam a chance de fraude em toda a cadeia de abastecimento.

Shen et al. (2020) capturaram imagens no plano lateral de animais que foram utilizadas para a detecção de cada indivíduo na imagem. Posteriormente, as imagens detectadas foram transferidas para uma rede neural convolucional. Nesse

caso, foram coletadas sequências de imagens de 105 animais e o método proposto alcançou uma acurácia de 96,65% na classificação dos indivíduos.

Os sistemas de visão computacional estão crescendo em importância na pecuária, em função da sua capacidade de gerar informações em tempo real, não invasivas e precisas em nível de animal. No entanto, o desenvolvimento desses sistemas requer abordagens estatísticas e computacionais para o gerenciamento eficiente e mineração de dados apropriada.

O objetivo geral desta pesquisa foi desenvolver um algoritmo de visão computacional com base em inteligência artificial para identificar galinhas da raça Canela-Preta por meio de imagens.

Esta Dissertação está estruturada conforme normas do Manual de Normalização de Monografia, Dissertação e Tese da Universidade Federal do Piauí, e o Capítulo I segue as normas de publicação da revista *Journal of Food Engineering* (ISSN 0260-8774). O estudo foi segmentado a fim de melhorar a acomodação dos diferentes tópicos. Inicialmente, tem-se a revisão de literatura, que engloba os temas abordados no Capítulo I, o qual servirá de referencial teórico, bem como as respectivas referências bibliográficas utilizadas.

2 REFERENCIAL TEÓRICO

2.1 Raça Canela-Preta

Apesar de já ser criada tradicionalmente por pequenos produtores no Piauí há séculos, as primeiras galinhas da raça Canela-Preta foram objeto de interesse institucional somente no ano de 2008, quando em viagens pelo sertão do Estado, foram encontradas por Dr. Marcos Jacob de Oliveira Almeida, na cidade de Curral Novo – Piauí, em ações da SEDUC/Embrapa Meio-Norte. A partir daí, teve início um levantamento em diversos municípios e se constatou a presença dessa raça na maioria dos municípios piauienses. Nesse contexto, o município de Queimada Nova é considerado o berço da raça, pela antiguidade dos relatos da prática de criação e quantitativo de aves detectadas no início da prospecção, principalmente em comunidades tradicionais, tendo como referência a comunidade quilombola Tapuio e a comunidade indígena Cariri Serra Grande (SARMENTO et al., 2017).

As galinhas da raça Canela-Preta, em algumas regiões são conhecidas como “galinhas Jacu”, pois a coloração de algumas aves se assemelha àquela da ave silvestre Jacu (nome popular dado a ave silvestre Penélope). A reintrodução e difusão da produção sustentável das galinhas Canela-Preta são feitas, principalmente, por Escolas Famílias Agrícolas e Agrotécnicas, Institutos Federais, Governo do Estado do Piauí, além de fontes financiadoras de crédito como Banco do Nordeste do Brasil (BNB) e Agência de Fomento do Piauí que estimulam jovens produtores rurais e alunos dessas escolas.

Além das instituições que deram início ao resgate e reintrodução da raça Canela-Preta, os trabalhos de pesquisa da raça foram articulados em parceria entre várias instituições, dentre elas a Universidade Federal do Piauí (UFPI), Empresa Brasileira de Pesquisa Agropecuária (Embrapa), Universidade Estadual do Piauí (UESPI) e Universidade Federal dos Vales do Jequitinhonha e Mucuri (UFVJM), onde foram realizados estudos científicos com essa raça (CARVALHO et al., 2016, 2017, 2020).

Essas aves se caracterizam fenotipicamente por possuírem tarso e falanges de coloração preta, e corpo predominantemente preto com pigmentações nas penas do pescoço nas cores branca, dourada ou vermelha, assim como por possuírem carne de coloração mais escura, se comparada às demais galinhas crioulas (CARVALHO et al., 2016).

As galinhas da raça Canela-Preta são criadas predominantemente de forma extensiva, em que permanecem soltas e são alimentadas a campo (CARVALHO et al., 2017). Com isso, podemos inferir que os bons resultados reprodutivos de galinhas caipiras estão diretamente relacionados ao estado nutricional e sanitário do plantel (VIOLA; SOBREIRA, 2018).

As aves dessa raça têm potencial para serem selecionadas para produção de ovos ou para carne. As fêmeas iniciam o ciclo de produção de ovos a partir dos seis meses de idade. Nessa raça são observados ovos nas seguintes colorações: marrom, vermelha, azul e verde (nas variadas tonalidades dentro dessas cores). As aves adquirem peso médio para comercialização a partir de seis meses de idade, em regime semi-intensivo, e acima de oito meses, no extensivo (CARVALHO et al., 2016).

A produção de galinhas caipiras é uma fonte de proteína e renda para os pequenos produtores e é considerada parte inegável da rica culinária piauiense. A raça Canela-Preta está inscrita na “Arca do gosto” do movimento internacional Fundação *Slow food*, registrada como semente crioula animal do Brasil (ALMEIDA, 2020).

Resultados de pesquisas científicas publicadas com a raça comprovaram se tratar genuinamente de uma raça de galinha caipira brasileira. Estudos de DNA nuclear e mitocondrial atestam que sua composição genética tem ancestralidade de aves oriundas de países coincidentes com a história da colonização do Brasil (SARMENTO et al., 2017; CARVALHO et al., 2020).

A galinha caipira da raça Canela-Preta, a partir de 27 de outubro de 2021, foi declarada como Patrimônio Histórico, Cultural e Genético do estado do Piauí, conforme Lei estadual de nº 7. 615.

2.2 Visão computacional

Os sistemas com base em visão computacional processam imagens obtidas de câmeras eletrônicas e digitais 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 (NIXON; AGUADO, 2019). Além disso, segundo Szeliski (2010), a visão computacional tenta descrever o mundo que observamos em uma ou várias imagens, e reconstruir suas propriedades, tais como formatos, iluminação e distribuição de cores.

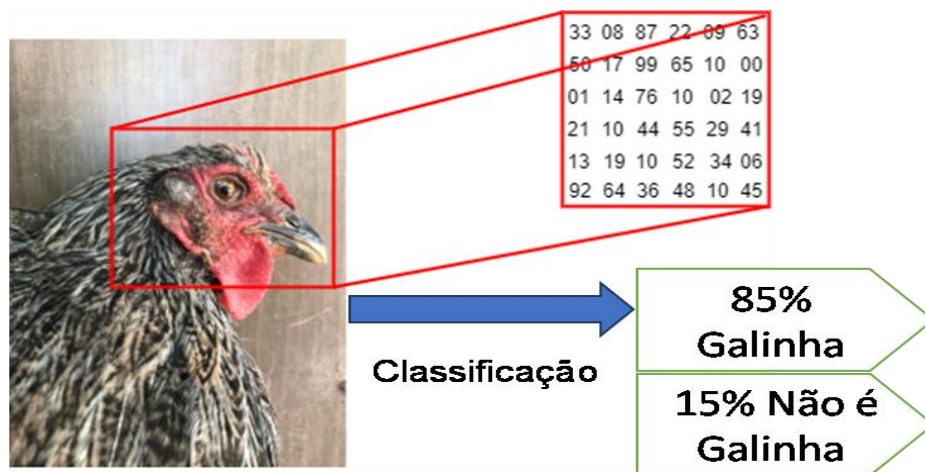
A visão computacional se esforça para desenvolver um método capaz de replicar uma das funções mais poderosas do sistema visual humano: o uso da luz, refletida até os olhos por diversos objetos seguindo os princípios físicos de óptica, para inferir características 3D do mundo real (KHAN et al., 2018). 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.

O mundo real é tridimensional (3D) no espaço. No entanto, as imagens obtidas do mundo real são geralmente bidimensionais (2D). Uma imagem 2D é uma função de intensidade de luz em duas dimensões e pode ser representada por um

vetor 2D $f(x,y)$, onde x e y são coordenadas espaciais e f é a amplitude de qualquer par de coordenadas (x, y) (ZHANG, 2017).

Uma imagem digital é considerada uma matriz onde suas linhas e colunas se referem à posição de algum ponto na imagem e o valor correspondente refere-se à intensidade desse ponto (ZHANG, 2017). Quando um computador reconhece uma imagem (toma uma imagem como entrada), ele identifica uma matriz de valores de pixel, conforme ilustrado na Figura 1.


Figura 1 – Reconhecimento e classificação de imagens por sistemas de visão computacional



Dependendo da resolução e do tamanho da imagem, o computador reconhece uma matriz de números com dimensões de largura e altura para uma imagem bidimensional. A ideia é entregar ao computador essa matriz com um conjunto de números para produzir dados que descrevem a probabilidade da imagem ser de determinada classe.

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 (MILANO; HONORATO, 2010).

Figura 2 – Etapas do processo de visão computacional



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 e câmeras de segurança normais ou térmicas (BORTH et al., 2014).

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, 2010).

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

A extração de características é usada para segmentação subsequente ou reconhecimento de objeto. O tipo de características que se deseja extrair, muitas vezes corresponde 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).

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

2.3 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. O padrão de um objeto consiste em dados

espaciais e cronológicos recebidos do objeto por um dispositivo de entrada e levados ao sistema de reconhecimento.

Os processos de tomada de decisão de um ser humano estão relacionados de alguma forma 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).

De acordo com Sá (2012), reconhecimento de padrões é a disciplina científica que lida com métodos de descrição e classificação de objetos. Conforme mencionado por Murty e Devi (2011), o 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 de um sistema de visão computacional, se necessita de uma base de dados acerca dos objetos a serem reconhecidos. Essa 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).

Um sistema para reconhecimento de padrões engloba três grandes etapas: representação e mensuração dos dados de entrada; extração das características; identificação e classificação do objeto em estudo (CASTRO; PRADO, 2002).

A classificação, frequentemente, é o último passo no processo geral e envolve organizar objetos em classes separadas. Nessa etapa, atribuímos um rótulo de classe apropriado para um padrão baseado em uma abstração que é gerada usando um conjunto de padrões de treinamento ou conhecimento do domínio (MURTY; DEVI, 2011).

As técnicas de reconhecimento de padrões podem ser divididas em: estruturais, em que os padrões são descritos de forma simbólica e a estrutura é a relação entre esses padrões; e técnicas que usam teoria de decisão, com padrões descritos por atributos quantitativos, de modo que é necessário determinar se o objeto possui esses atributos (MARENGONI; STRINGHINI, 2009).

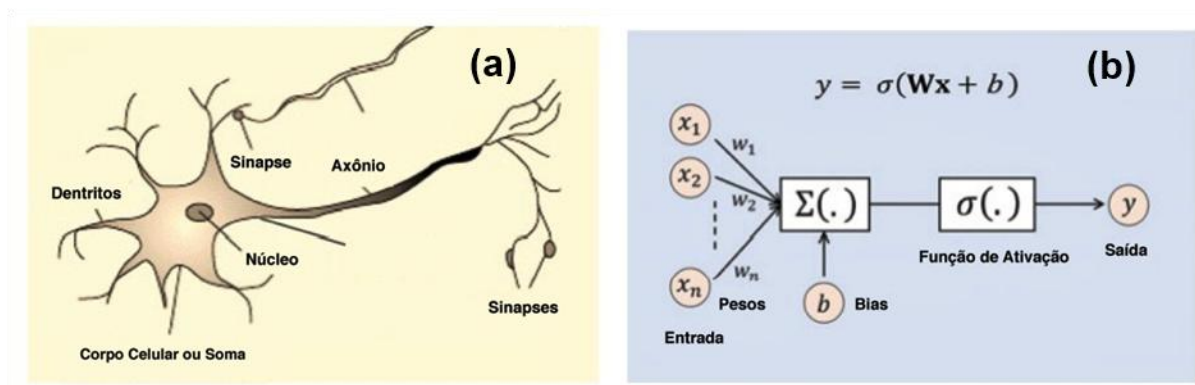
2.4 Rede neural convolucional

O cérebro é um computador paralelo não linear altamente complexo capaz de organizar componentes estruturais (neurônios), para realizar processamentos como reconhecimento de padrões, percepção e controle de movimento muito mais rápido que os computadores digitais mais eficientes. Já a rede neural é uma máquina projetada para modelar a maneira como o cérebro executa uma tarefa ou função específica. A rede é geralmente executada usando componentes eletrônicos ou simulada por programação em um computador digital (HAYKIN, 2007).

Inspiradas fortemente pela forma 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 (O'SHEA; NASH, 2015).

No modelo biológico, os neurônios recebem sinais e produzem uma resposta final que será transmitida a outras estruturas orgânicas. Na Figura 3(a), observa-se o modelo de um neurônio biológico. Os dendritos funcionam como meios de transmissão do sinal elétrico, trazendo informações de outros neurônios para o corpo celular. Este recebe a informação para então processá-la e enviá-la a outros neurônios por meio dos axônios. As conexões entre os dendritos e axônios terminais são chamadas de sinapses, nas quais há a comunicação efetiva dos sinais elétricos de célula a célula. Por fim, o axônio transmite os sinais de saída do corpo celular para outros neurônios (KHAN et al., 2018).

Figura 3 – Neurônio biológico (a) e modelo computacional neural (b)



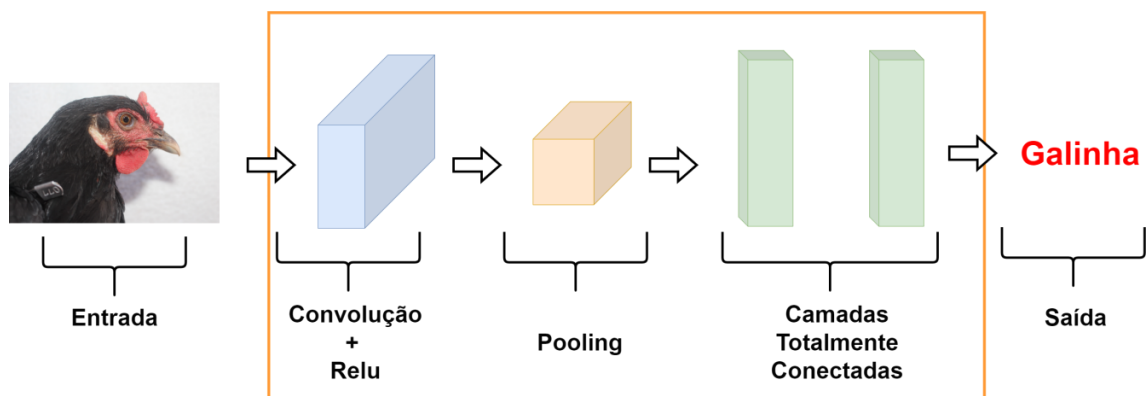
Fonte: Adaptado de KHAN et al. (2018).

O modelo computacional visa simular de forma análoga a estrutura biológica do cérebro, onde programa os componentes e o funcionamento de um neurônio biológico. Conforme a Figura 3(b), o modelo computacional de um neurônio consiste em um conjunto de conexões de entradas $x_1, x_2... x_n$, que alimentam a unidade com ativações vindas de outros neurônios. Essas entradas são ponderadas usando um conjunto de pesos denotados por $w_1, w_2... w_n$. 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 y . A saída final é então transmitida a outras unidades neurais conectadas (KHAN et al., 2018).

Soma-se a isso a necessidade de se estabelecer as redes neurais convolucionais (CNN). De acordo com O'Shea e Nash (2015), as CNNs são análogas às ANN tradicionais, de modo que sua composição corresponde a um sistema de neurônios que se auto-otimizam por meio do aprendizado e do aprimoramento dos saberes. As redes convolucionais 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 4. Com relação às camadas, estão divididas em: convolução, *pooling* e camadas totalmente conectadas (LECUN; BENGIO; HINTON, 2015; O'SHEA; NASH, 2015; GU et al., 2018; VOULODIMOS et al., 2018).

Figura 4 – Fluxograma esquemático da arquitetura de uma rede neural convolucional

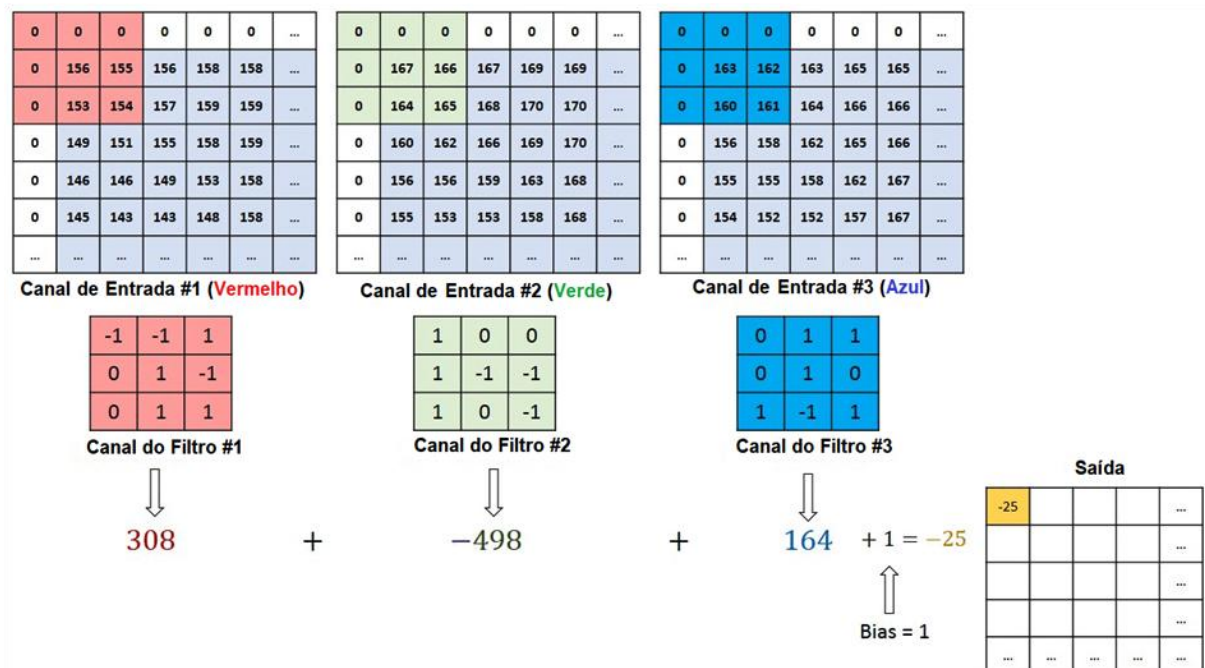


A camada convolucional é o componente principal de uma CNN, que inclui um conjunto de filtros (*kernels* convolucionais) que realizam a convolução com uma determinada entrada e geram um conjunto de mapa de características na saída (KHAN et al., 2018).

As unidades em uma camada convolucional são organizadas em mapa de características, onde cada unidade é conectada a uma parte da camada anterior por um conjunto de pesos (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).

A Figura 5 mostra um exemplo de convolução discreta do filtrado de imagens, em que a matriz de cor azul é a entrada $X_{m \times n}$ (mapa de características de entrada). Os filtros ou *kernels* K_{ij} de valores de dimensão 3×3 de cores vermelho, verde e azul são deslizados através da matriz de entrada.

Figura 5 – Operação de convolução em uma camada convolucional




Fonte: Adaptado de Alves (2018)

Cada posição da matriz de saída gerada $Y_{3 \times 3}$ de cor branca é preenchida pelo resultado da soma total de cada um dos elementos dos *kernels* k_{ij} , multiplicado por cada elemento do mapa de características de entrada X_{ij} , onde os *kernels* irão se deslizar por toda a entrada.

Pooling é um conceito importante da CNN, pois 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 Figura 6 ilustra a operação de *pooling*.

Figura 6 – Ilustração do processo de *max-pooling*



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 dimensionalidade 2×2 aplicados com um passo 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).

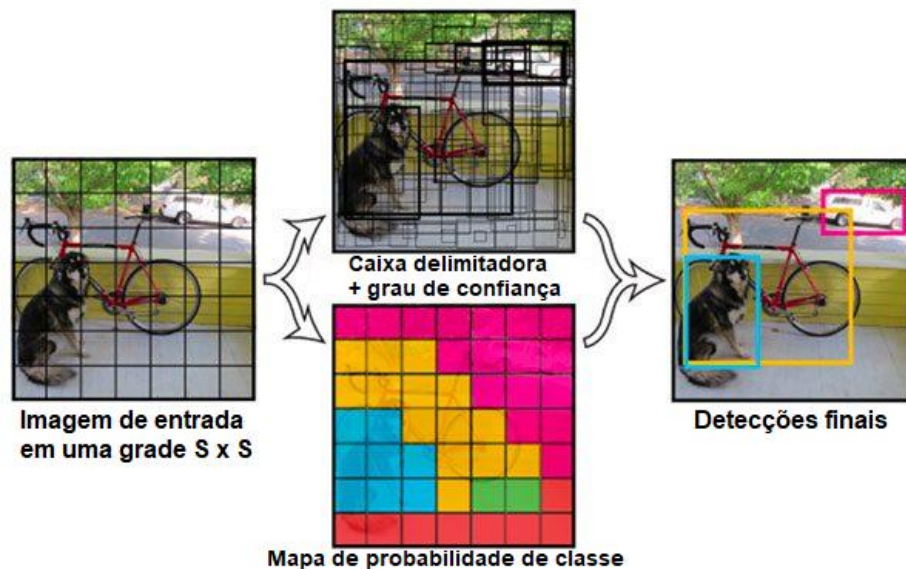
2.5 YOLO (*you only look once*)

De acordo com Redmon et al. (2016), o algoritmo YOLO trata da etapa de detecção de objetos como um problema de regressão. Esse 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 possui um eficiente desempenho 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. Isso garante vantagens em termos de velocidade (REYES et al., 2018). A Figura 7 mostra o procedimento da YOLO em uma imagem de entrada.

Figura 7 – Demonstração do funcionamento da rede YOLO com o uso de caixa delimitadora



Fonte: Adaptado de 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 da grade, essa célula é responsável por detectar o objeto. Cada célula da grade prevê B caixas delimitadoras, valores 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 valor de confiança é feita de acordo com o produto da probabilidade do objeto com a intersecção sobre a união ($Pr(\text{Objeto}) \times IOU^{realprevista}$). Se nenhum objeto existir nessa célula, as pontuações de confiança devem ser zero. Caso contrário, a pontuação de confiança será igual à IOU entre a caixa prevista e a verdade básica (REDMON et al., 2016).

2.6 Template matching

O casamento de modelos (*template matching*) é uma técnica de processamento de imagens para localizar uma imagem *template* em uma imagem de pesquisa (BRUNELLI, 2009).

A tarefa é comparar o *template* com cada região da imagem de pesquisa de mesma dimensão para encontrar a região que mais se assemelha com o *template* (HISHAM et al., 2015). A Figura 8 representa imagens de pesquisa e *template*.

Figura 8 – (a) Imagem pesquisa, (b) *Template* e (c) Imagem b extraíndo característica da imagem a



A Figura 8(b) corresponde à região delineada na Figura 8(a), seguindo o mesmo padrão de características. O processo de comparação acontece com (b) deslizando pixel a pixel em (a), chegando até a última posição, conforme mostrado

na Figura 8(c). Em cada posição é utilizada uma medida de similaridade para comparar as imagens. Após a varredura em todas as posições de (a), a posição que apresenta maior valor de similaridade é considerada a região onde está localizada a Figura 8(b) em (a) (NIXON; AGUADO, 2019).

2.7 Métricas de avaliação

As métricas apresentadas nesta seção são: acurácia (ACC), desvio médio absoluto (DMA) e correlação cruzada normalizada (CCN).

2.7.1 Acurácia (ACC)

A acurácia avalia os acertos de um modelo de classificação, em que o total de instâncias é previsto corretamente quando estas são testadas com dados ocultos por um classificador treinado (HOSSIN; SULAIMAN, 2015). Segundo Baratloo et al. (2015), acurácia é a proporção de predições corretas, assim como positivos e negativos verdadeiros. O cálculo da acurácia pode ser realizado pela Equação (1):

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (1)$$

em que: VP representa verdadeiros positivos; VN significa verdadeiros negativos; FP é falso positivo; e FN é falso negativo.

2.7.2 Desvio médio absoluto (DMA)

O DMA é a média das diferenças absolutas entre o valor estimado e o valor observado, em que todas as diferenças individuais têm peso igual, não considerando a direção do erro (SARMENTO et al., 2006). Assim, se tem a chance de zerar o erro ao somar erros positivos e negativos. O DMA pode ser calculado pela Equação (2):

$$DMA = \frac{1}{N} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

em que: N é a quantidade de observações; y_i é o valor observado; e \hat{y}_i é o valor estimado.

2.7.3 Correlação cruzada normalizada (CCN)

A CCN é uma medida de similaridade muito utilizada em processamento de imagens e é uma versão aperfeiçoada da correlação cruzada (GONZALEZ; WOODS, 2009). Essa medida apresenta um termo normalizador no denominador que lhe confere invariância a mudanças globais de brilho e resultados sempre dentro de um intervalo definido entre -1 e 1.

Nesse método, os valores da imagem padrão T são deslocados pela imagem I . Para cada posição do pixel em I , multiplica-se pelos valores dos pixels de T . O somatório dessa operação é armazenado em cada posição do deslocamento.

Gonzalez e Woods (2009) propuseram uma alteração no cálculo para tornar o resultado mais robusto, calculando a média local da imagem I e também do padrão T antes de se realizar a correlação, conforme a Equação (3) a seguir:

$$R(x, y) = \frac{\sum_{x', y'} (T(x', y') \cdot I(x + x', y + y'))}{\sqrt{\sum_{x', y'} T(x', y')^2 \cdot \sum_{x', y'} I(x + x', y + y')^2}} \quad (3)$$

em que: $R(x, y)$ é a matriz resultante; $T(x, y)$ é a representação da posição dos pixels na imagem padrão; $I(x, y)$ representa a posição dos pixels na imagem original; x' e y' são variáveis de deslocamento nas direções de x e y , respectivamente.

2.8 Trabalhos relacionados

No estudo de Mbelwa et al. (2021), foi proposta uma solução de aprendizagem profunda baseada em redes neurais convolucionais para prever se fezes de galinha pertenciam a uma das três classes analisadas. Para isso, foram utilizados modelos pré-treinados para solucionar o problema. Após ser feita uma comparação, o modelo desenvolvido a partir da *XceptionNet* teve um desempenho superior a outros modelos para todas as métricas utilizadas. Os resultados

experimentais mostraram ganho de aprendizagem por transferência (exatidão de validação de 94% utilizando o modelo pré-treinado sobre 93,67% da CNN desenvolvida a partir de treino completo no mesmo conjunto de dados).

Na pesquisa realizada por Kumar et al. (2018), foi proposta uma abordagem baseada em aprendizagem profunda para a identificação individual de bovinos com base nas características do padrão de imagem do focinho. Um banco de dados de focinhos foi criado para a realização do estudo e foi feita a extração do conjunto saliente de características de textura e representação da imagem da ponta do focinho de bovinos usando a técnica de aprendizado profundo baseado em rede neural convolucional. Neste caso, foi aplicada a técnica do auto-codificador de eliminação de ruídos empilhado para codificar a característica extraída das imagens de focinho. Nos testes realizados, a maior acurácia de identificação obtida foi 98,99%.

O trabalho de Saltoratto et al. (2013) apresenta uma ferramenta de monitoramento de avicultura a partir das imagens de *frames* de vídeos. Nesse trabalho 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 nos dias chuvosos com temperaturas baixas, as aves aqueciam-se na maior parte em 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. Nesse caso, foram empregadas técnicas de matriz de co-ocorrência, algoritmos genéticos e classificadores KNN (K-vizinhos mais próximos). 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 para o reconhecimento de porcos com custo baixo e escalável. Foram usados dois classificadores em cascata baseados em recursos Haar e uma rede neural convolucional rasa com imagens de alta qualidade 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 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. O algoritmo desenvolvido foi capaz de identificar as aves do restante da imagem por meio do processamento digital das imagens.

Na literatura não foram encontrados relatos de trabalhos relacionados à identificação de galinhas caipiras, conseqüentemente, não há relatos do uso de redes neurais convolucionais na identificação de galinhas caipiras da raça Canela-Preta.

3 REFERÊNCIAS

- ALBUQUERQUE, M. P. **Processamento de imagens: métodos e análises**. Rio de Janeiro: Centro Brasileiro de Pesquisas Físicas CBPF/MCT, 2000.
- ALMEIDA, M. J. O. **Galinha Canela-Preta**. Slow Food Brasil, 2020. Disponível em: https://slowfoodbrasil.org/arca_do_gosto/galinha-canela-preta/. Acesso em: 29 jun. 2021.
- ALVES, G. **Understanding ConvNets (CNN)**. Medium, 2018. Disponível em: <https://medium.com/neuronio/understanding-convnets-cnn-712f2afe4dd3>. Acesso em: 01 Fev. 2022.
- ANZAI, Y. **Pattern recognition and machine learning**. Elsevier, New York, 2012.
- BARATLOO, A. et al. Part 1: Simple definition and calculation of accuracy, sensitivity and specificity. **Emergency (Tehran, Iran)**, v. 3, n. 2, p. 48–9, 2015.
- BORTH, M. R. et al. A visão computacional no agronegócio: Aplicações e direcionamentos. In: 7º Encontro Científico de Administração, Economia e Contabilidade (ECAECO), 2014, Ponta Porã. **Anais [...]**. Ponta Porã: Unidade Universitária Ponta Porã, 2014. p. 1-12.
- BRUNELLI, R. **Template matching techniques in computer vision: theory and practice**. [S.l.]: John Wiley & Sons, 2009.
- CARVALHO, A. A. et al. **Crescimento corporal, particularidades e importância econômica das galinhas caipiras: uma revisão**. In: OELKE, C. A. (Org.). Suinocultura e Avicultura: do básico a zootecnia de precisão. Guarujá, SP: Científica Digital, v. 01, p. 167-179, 2021. Disponível em: <http://www.alice.cnptia.embrapa.br/alice/handle/doc/1131250>. Acesso em: 22 dez. 2021.
- CARVALHO, D. A. et al. Caracterização genética e estrutura populacional de galinhas crioulas Canela-Preta. **Pesquisa Agropecuária Brasileira**, v. 51, n. 11, p. 1899-1906, 2016.
- CARVALHO, D. A. et al. Padrão racial fenotípico de galinhas brasileiras da raça Canela-Preta. **Archivos de Zootecnia**, v. 66, n. 254, p. 195–202, 2017. <https://doi.org/10.21071/az.v66i254.2322>.
- CARVALHO, D. A. et al. Diversity and genetic relationship of free-range chickens from the northeast region of Brazil. **Animals**, v. 10, n. 10, p. 1–14, 2020. <https://doi.org/10.3390/ani10101857>.
- CASTRO, A. A. M. D.; PRADO, P. P. L. D. Algoritmos para reconhecimento de padrões. **Revista Ciências Exatas**, v. 8, n. 1, p. 129–145, 2002.

DU, J. Understanding of object detection based on CNN family and YOLO. **Journal of Physics: Conference Series**, v. 1004, p. 1–9, 2018. <https://doi.org/10.1088/1742-6596/1004/1/012029>.

EGMONT-PETERSEN, M.; RIDDER, D.; HANDELS, H. Image processing with neural networks – a review. **Pattern recognition**, v. 35, n. 10, p. 2279-2301, 2002. [https://doi.org/10.1016/S0031-3203\(01\)00178-9](https://doi.org/10.1016/S0031-3203(01)00178-9).

FUKUNAGA, K. **Introduction to statistical pattern recognition**. San Diego: Academic Press, 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**. 2018. 37f. Trabalho de Conclusão de Curso (Graduação) – Universidade Tecnológica Federal do Paraná, Pato Branco, 2018.

GU, J. et al. Recent advances in convolutional neural networks. **Pattern recognition**, v. 77, n. 1, p. 354-377, 2018. <https://doi.org/10.1016/j.patcog.2017.10.013>.

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. <https://doi.org/10.1109/SCORED.2015.7449303>.

HOSSIN, M.; SULAIMAN, M. A review on evaluation metrics for data classification evaluations. **International Journal of Data Mining & Knowledge Management Process**, v. 5, n. 2, p. 1–11, 2015. <https://doi.org/10.5121/ijdkp.2015.5201>.

KHAN, S. et al. A guide to convolutional neural networks for computer vision. **Synthesis Lectures on Computer Vision**, v. 8, n. 1, 2018, 207 p. <https://doi.org/10.2200/S00822ED1V01Y201712COV015>.

KUMAR, S. et al. Deep learning framework for recognition of cattle using muzzle point image pattern. **Measurement**, v. 116, p. 1–17, 2018. <https://doi.org/10.1016/j.measurement.2017.10.064>.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, p. 436–444, 2015. <https://doi.org/10.1038/nature14539>.

LOPES, F. A. A. **Visão computacional para estimativa de comportamento de aglomeração de galinhas poedeiras**. 2019. 73f. Dissertação (Mestrado em Agronegócio e Desenvolvimento) – Programa de Pós-graduação em Agronegócio e Desenvolvimento da Faculdade de Ciências e Engenharia da Universidade Estadual Paulista (UNESP), São Paulo, 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. <https://doi.org/10.22456/2175-2745.11477>.

MARSOT, M. et al. An adaptive pig face recognition approach using Convolutional Neural Networks. **Computers and Electronics in Agriculture**, v. 173, n. 1, p. 1–25, 2020. <https://doi.org/10.1016/j.compag.2020.105386>.

MBELWA, H.; MACHUVE, D.; MBELWA, J. Deep Convolutional Neural Network for chicken diseases detection. **International Journal of Advanced Computer Science and Applications**, v. 12, n. 2, p. 759–765, 2021. <https://doi.org/10.14569/IJACSA.2021.0120295>.

MILANO, D.; HONORATO, L. B. **Visão computacional**. São Paulo: UNICAMP, 2010.

MURTY, M. N.; DEVI, V. S. **Pattern recognition: an algorithmic approach**. London: Springer, [S.l.]: Universities Press, 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:1511.08458v2, 2015. <https://doi.org/10.48550/arXiv.1511.08458>.

REDMON, J. et al. You only look once: Unified, real-time object detection. In: Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016, Las Vegas. **Anais [...]**. Las Vegas: IEEE, 2016. p. 779–788. <https://doi.org/10.1109/CVPR.2016.91>.

REYES, E. et al. Near real-time object recognition for pepper based on deep neural networks running on a backpack. In: Proceedings of 22th RoboCup International Symposium, 2018, Montreal, Canada. **Anais [...]**. Montreal, 2016. 2018, p. 287–298. <https://doi.org/10.48550/arXiv.1811.08352>.

SÁ, J. P. M. **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. **Colloquium Exactarum**, v. 5, n. 2, p. 47–66, 2013. <https://doi.org/10.5747/ce.2013.v05.n2.e059>.

SARMENTO, J. L. R. et al. Estudo da curva de crescimento de ovinos Santa Inês. **Revista Brasileira de Zootecnia**, v.35, n.2, p.435–442, 2006. <https://doi.org/10.1590/S1516-35982006000200014>.

SARMENTO, J. L. R. et al. **Galinha caipira raça nativa Canela-Preta**. Folder. Teresina: UFPI, 2017. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1078370/galinha-caipira-da-raca-nativa-canela-preta>. Acesso em: 29 jun. 2021.

SHEN, W. et al. Individual identification of dairy cows based on convolutional neural networks. **Multimedia Tools and Applications**, v. 79, n. 21–22, p. 14711–14724, 2020. <https://doi.org/10.1007/s11042-019-7344-7>.

SZELISKI, R. **Computer vision: algorithms and applications**. The University of Washington, 2010.

VIOLA, T. H.; SOBREIRA, R. S. **Sistema alternativo de criação de galinhas caipiras**. 2. ed. Brasília, DF: Embrapa, 2018. v. 1. 56p.

VOULODIMOS, A. *et al.* Deep learning for computer vision: A brief review. **Computational Intelligence and Neuroscience**, v. 2018, n. 1, p. 1–13, 2018. <https://doi.org/10.1155/2018/7068349>.

ZHANG, Y. et al. **Image processing**. [S.l.]: Berlin, Boston: De Gruyter, 2017.

CAPÍTULO I

Computer vision algorithm for identification of free-range chickens

Highlights

- Computer vision can be useful for detection and identification of free-range chickens.
- The identification of Canela-Preta chickens using template matching was efficient.
- Template matching overcame a convolutional neural network in the identification of Canela-Preta hens.
- The image processing using template matching showed lower complexity than convolutional neural networks.

1 **Computer vision algorithm for identification of free-range chickens**

2
3 José dos Santos de Moura^{a,b*}, Natanael Pereira da Silva Santos^c, Ícaro Victor Félix
4 Campelo^a, Ana Caroline de Almeida Alves^a, Débora Araújo de Carvalho^d, Marcos
5 Jacob de Oliveira Almeida^e, José Lindenberg Rocha Sarmiento^c, Romuere Rodrigues
6 Veloso e Silva^f, Leilane Rocha Barros Dourado^c, Otílio Paulo da Silva Neto^g

7
8 ^a Graduate Program in Tropical Animal Science, Agrarian Sciences Center (CCA),
9 Federal University of Piauí (UFPI), Campus Universitário Ministro Petrônio Portella,
10 Teresina, PI 64049-550, Brazil

11 ^b Federal Institute of Education, Science and Technology of Piauí (IFPI), Rua da
12 Barragem do Bezerra, s/n, José de Freitas, PI 64110-000, Brazil

13 ^c Department of Animal Science, CCA, UFPI, Campus Universitário Ministro Petrônio
14 Portella, Teresina, PI 64049-550, Brazil

15 ^d Brazilian Micro and Small Business Support Service (SEBRAE), MA 006, km 39,
16 Bairro Canoeiro, Grajaú, MA 65940-000, Brazil

17 ^e Brazilian Agricultural Research Corporation (Embrapa) Meio-Norte, Sector of
18 Technology Transfer, Bairro Buenos Aires, Teresina, PI 64006-220, Brazil

19 ^f Information Systems, UFPI, Campus Senador Helvídio Nunes de Barros, Picos, PI
20 64607-670, Brazil

21 ^g IFPI, Rua Álvaro Mendes, 94, Teresina, PI 64000-040, Brazil

22
23 *Corresponding author: santos.moura@ifpi.edu.br

24

25

26 **ABSTRACT**

27 The increase in the number of Canela-Preta chicken farmers has the potential to
28 strengthen poultry farming and improve the quality of life of birds. Hence, there is a
29 need to identify chickens through modern and non-invasive techniques, such as the
30 use of images. This study aimed to develop a computer vision algorithm based on
31 artificial intelligence to identify Canela-Preta chickens using images. For this
32 purpose, 156 hens raised in an extensive system were used. Convolutional neural
33 networks and template matching were applied in different steps. An accuracy rate of
34 86.54% and similarity of 99.58% were obtained using YOLO (you only look once) for
35 detection and template matching for identification. It was concluded that the
36 individual identification of free-range Canela-Preta chickens using the proposed
37 methodology was accurate.

38 **Keywords:** artificial intelligence; Canela-Preta chicken; convolutional neural network;
39 template matching; YOLO.

40

41 **1. Introduction**

42

43 In the 1930s, poultry farming showed considerable progress in Brazil, so that
44 the native breeds were endangered. However, in 1980 the demand for native breed
45 products increased due to the valuation of natural products and the rusticity of native
46 birds, which are suitable to be raised in extensive systems (Carvalho et al., 2016).

47 Among the so-called native breeds that emerged in Brazil, we can mention the
48 Canela-Preta chickens, which are mostly present in the northeast region. Despite
49 being traditionally raised by smallholders in Piauí using low or no technological

50 investment, Canela-Preta chickens became an object of institutional interest only in
51 2008 (Carvalho et al., 2020).

52 The increase in the number of Canela-Preta free-range chicken breeders
53 strengthens poultry farming in Brazil, especially in terms of biosecurity, health, and
54 quality of the animals. Therefore, it is necessary to identify those chickens using
55 modern and non-invasive techniques, such as Artificial Intelligence and Pattern
56 Recognition based on convolutional neural networks (CNN) for image processing.
57 CNNs are particularly effective in extracting the appropriate features from a set of
58 training images without the need for manual extraction (McCool et al., 2017;
59 Rahmehoonfar and Sheppard, 2017).

60 The number of published reviewed articles demonstrates the interest and rapid
61 development of learning algorithms as the main image analysis framework in
62 computer vision systems for livestock species of economic interest, especially cattle
63 and swine (Oliveira et al., 2021).

64 Despite the high accuracy reported in the literature, the correct individual
65 identification of animals based only on RGB (red, green, blue) images can be
66 challenging. The amount of information loaded in a single image usually exceeds the
67 primary interest of the developer when creating computer vision systems. The
68 amount of information in the image can allow for future development as new ideas
69 are created and more sophisticated data analysis tools become available.

70 Several studies have already reported the identification of animals of different
71 species. For example, Hansen et al. (2018) used some techniques for pig face
72 recognition. In the aforementioned work, the authors used algorithms such as
73 Fisherfaces, a pre-trained facial CNN, and their own convolutional neural network,
74 which obtained the best accuracy in the identification of pigs. Shen et al. (2020)

75 proposed a method for identification of cows using side-view images. In this case, the
76 YOLO (you only look once) network, two convolutional neural networks and data
77 augmentation techniques were used to classify each individual. In turn, Salama et al.
78 (2019) performed the facial identification of sheep using their own CNN with data
79 augmentation.

80 Deep learning algorithms for computer vision systems, such as Mask R-CNN,
81 Faster R-CNN, YOLO, DeepLab, U-Net, among others have been used to detect and
82 identify individuals and/or objects through images (Oliveira et al., 2021).
83 Nevertheless, in the identification of free-range poultry this approach is still incipient.
84 Thus, the objective of the current study was to develop and evaluate computer vision
85 algorithms for individual identification of Canela-Preta chickens using CNN, YOLO,
86 and template matching.

87

88 **2. Materials and methods**

89

90 *2.1. Ethical certification and experimental characterization*

91

92 The experimental procedures carried out in this study were approved by the
93 Committee on Ethics in the Use of Animals (CEUA) of the Federal University of Piauí
94 (UFPI), Brazil (protocol number 692/2021).

95

96 For this experiment, we collected images of 167 healthy free-roaming Canela-
97 Preta hens raised on the Débora Carvalho Farm, located in the rural settlement
98 Resistência Camponesa, in the municipality of Demerval Lobão, PI, Brazil. The
99 experimental birds were divided into two groups of individuals with predominant ages
100 of 6 and 15 months and average weight of 1.591 kg. The birds were dewormed and
vaccinated against Newcastle disease, Gumboro disease, infectious bronchitis, fowl

101 pox, and avian infectious coryza. Each vaccine was administered according to the
102 protocol used on the farm.

103

104 *2.2. Image collection*

105

106 Each hen was restrained for 10 seconds to capture the images in three different
107 planes (Fig. 1). For this, a Canon digital camera, model T5i, 18-55 mm lens was
108 used.

109

110




111 **Fig. 1.** Different picture capture planes; (a) right side view; (b) front view; (c) left side
112 view.

113

114 A total of 501 images with the dimensions (height and width) 1280 × 1920 pixels
115 were collected. Subsequently, unusable images of 11 individuals were discarded,
116 that is, 33 pictures were deleted due to their low quality (Fig. 2). Therefore, the image
117 database used for the analyses contained 468 images of 156 chickens.

118

119



120 **Fig. 2.** Example of images of Canela-Preta hens removed from the database.

121

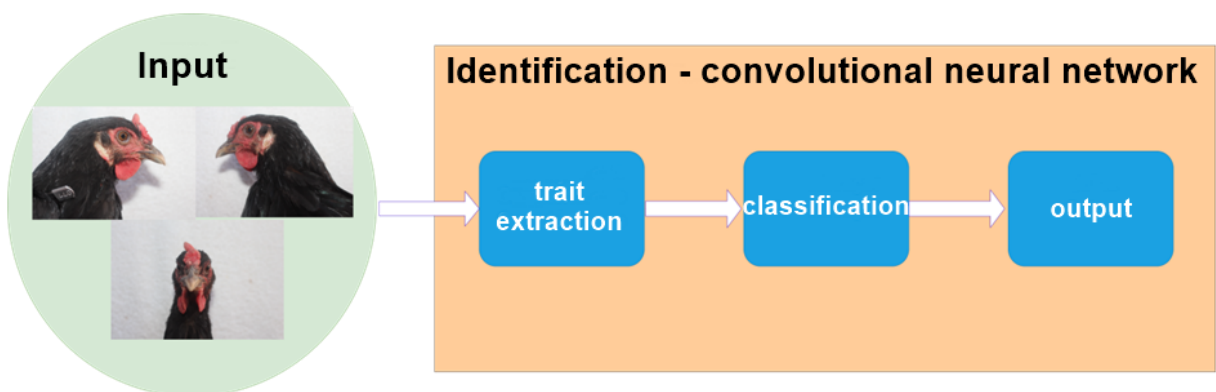
122 2.3. Image-based methods for identification of Canela-Preta chickens

123

124 In the first method used for the identification of Canela-Preta chickens, a
 125 convolutional neural network was used (Fig. 3).

126

127



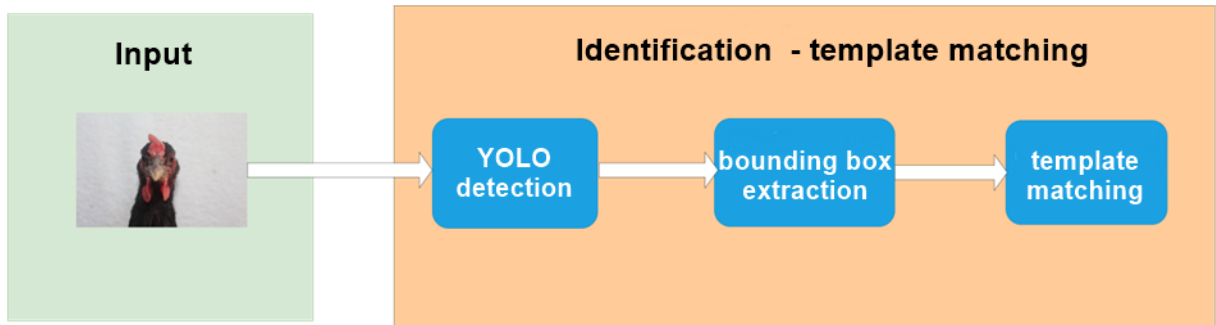
128 **Fig. 3.** Chicken identification process using convolutional neural network.

129

130 In the second method, the YOLO network was used for chicken detection and
 131 then the image bounding box was extracted. Finally, each hen was identified using
 132 template matching (Hashemi et al., 2016), as shown in Fig. 4.

133

134



135 **Fig. 4.** Chicken identification process using template matching.

136

137 2.3.1. Identification algorithm using convolutional neural network

138 For identification via CNN, 468 images of the right side, frontal and left side
 139 planes of 156 chickens were used. The database used for identification of Canela-
 140 Preta chickens using CNN was distributed in 64% for training, 16% for validation, and
 141 20% for testing.

142 The same label was assigned for each image of a certain chicken in order to
 143 allow the network to identify that the images belonged to the same individual.
 144 Therefore, random numbers ranging from 1 to 156 were randomly generated for each
 145 individual.

146 The labels were represented by integer numbers and then categorized, that is,
 147 they were transformed into the data format, labeling each image to insert them into
 148 the network. Details of the CNN architecture used here are shown in Table 1.

149 The network was composed of five convolutional layers with 3×3 and 2×2
150 kernels with rectified linear unit (ReLU) activations, five max pooling layers with 2×2
151 kernels and two fully connected layers with ReLU and softmax activations.

152 The input images were resized to 416×416 and the CNN was trained using the
153 Adam optimizer with a learning rate of 0.001, using eight batches and 100 epochs.
154 The categorical cross-entropy loss function was used in the last classification layer.
155 Hyperparameter tuning was performed by varying the number of epochs, input image
156 dimensions, and batch size.

157

158 *2.3.2. Identification algorithm using template matching*

159 Only the 156 images of the frontal plane were used for identification using
160 template matching. The following steps were performed in order to apply template
161 matching: i) extraction of the bounding box region of the chicken detected using
162 YOLO; ii) recognition of the individual extracted using template matching based on
163 normalized correlation coefficient.

164

165 *2.3.2.1. Detection using YOLO*

166 YOLO version 3 (Redmon et al., 2016) was used for chicken detection. It is
167 important to mention that YOLO v3 is an algorithm with high performance and speed
168 of detection of small objects.

169 The YOLO v3 pre-trained weights were initially stored on COCO dataset (Lin et
170 al., 2014) for chicken detection. Since the pre-trained model performs the detection of
171 chickens, it was not necessary to train the YOLO network. After detection, the images
172 were cropped and sent as templates for the next identification step using template
173 matching.


174

175 *2.3.2.2. Extraction of the region of interest*

176 The extraction was performed to crop the region of interest from the image,
177 starting from the detected bounding box. This process was performed to crop the
178 neck and head regions of the chickens delimited in the images (Fig. 5), and served
179 as input for chicken identification.

180

181



182 **Fig. 5.** (a) Image of Canela-Preta chicken detected and its bounding box; (b) Image
183 of Canela-Preta chicken cropped from (a) delimited by the bounding box.

184

185 *2.3.2.3. Identification of Canela-Preta chickens using template matching*

186 Of the 156 images of the frontal plane of chickens, 21 images were not detected
187 by the YOLO network. Thus, for identification via template matching, we used 135
188 frontal images obtained after the detection performed to train the algorithm. Images
189 of the detected chickens (templates) were used to identify each hen in the database
190 (search).

191 The algorithm was used to find in the database the image that corresponds to
192 the template image of the chicken. For this, the algorithm used normalized cross-
193 correlation to measure the degree of similarity between images in the database.

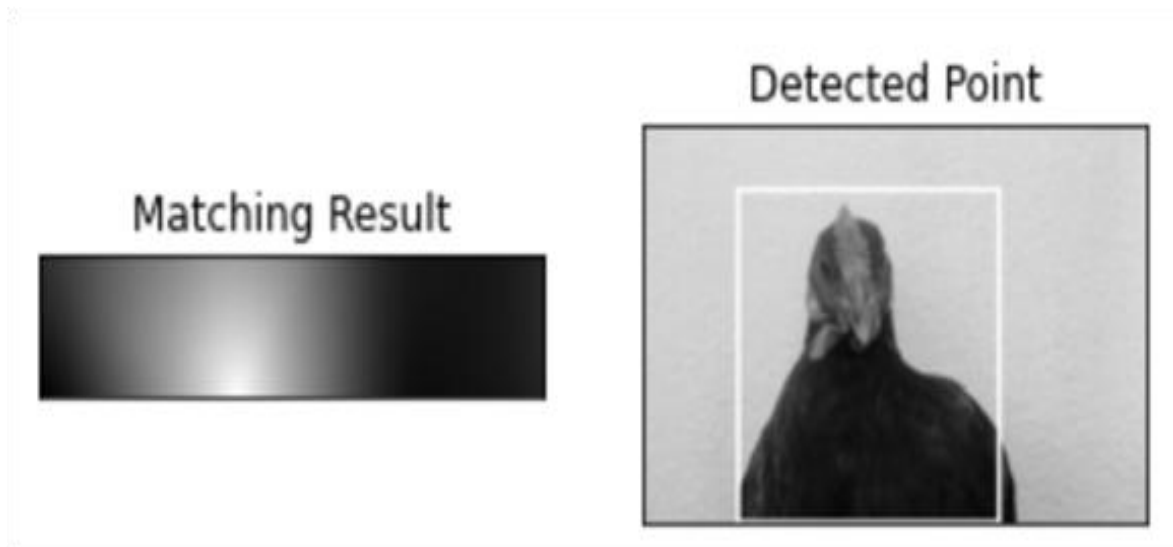
194 The algorithm performed a database scan comparing each template image
195 looking at each pixel in the search image and storing the computed result metric.
196 Subsequently, this metric was normalized to detect the most correlated points in the
197 image.

198 The minMaxLoc function was used to find the minimum and maximum values,
199 which indicate the best matches, thus drawing a bounding box in the image where
200 the points are at a larger scale. After a chicken image (template) was evaluated using
201 template matching, the resulting image corresponding to that chicken template was
202 compared to all the images in the database.

203 The image of a hen identified via template matching using normalized cross-
204 correlation is shown in Fig. 6.

205

206



207 **Fig. 6.** Canela-Preta hen identified using template matching.

208

209 *2.4. Evaluation metrics*

210

211 *2.4.1 Accuracy*

212 This metric was used to evaluate chickens correctly classified using the
 213 convolutional neural network. In this case, accuracy can be defined as the ratio
 214 between the number of chickens correctly classified and the total number of
 215 predictions made. We calculated accuracy using the equation below.

216

$$\text{Accuracy} = \frac{\text{TC} + \text{TN}}{\text{TC} + \text{TN} + \text{FC} + \text{FN}} \quad (1)$$

217

218 where: TC is the true classification of chicken; TN represents the true classification of
 219 non-chicken; FC is the false classification of chicken; FN is the false classification of
 220 non-chicken.

221

222 *2.4.2. Mean absolute deviation*

223 The mean absolute deviation (MAD) shown in Eq. (2) is the mean of absolute
 224 differences between the prediction and the real value of chickens. In this case, all
 225 individual differences have equal weight and the direction of error is not considered.

226

$$\text{MAD} = \frac{1}{N} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

227

228 where: N is the number of chickens; y_i is the real value of each hen; \hat{y}_i is the predicted
 229 value of each hen.

230

231 2.4.3. Normalized cross-correlation

232 This metric was used to evaluate the similarity between the templates of each
 233 hen and all search images in the database. The normalized cross-correlation was
 234 calculated using the equation below.

235

$$R(x, y) = \frac{\sum_{x', y'} (T(x', y') \cdot I(x + x', y + y'))}{\sqrt{\sum_{x', y'} T(x', y')^2 \cdot \sum_{x', y'} I(x + x', y + y')^2}} \quad (3)$$

236

237 where: $R(x,y)$ is the resulting matrix; $T(x,y)$ represents the position of pixels in the
 238 template; $I(x,y)$ is the position of pixels in the search image.

239

240 2.5. Environment for algorithm development

241

242 For the development of algorithms, we used a virtual cloud environment that
 243 provides graphics processing unit and 16GB of RAM. The chicken detection was
 244 performed using CNN and YOLO neural network, whereas the template matching
 245 was used for chicken identification. The Python programming language and the
 246 following Python libraries were used: TensorFlow (Goldsborough, 2016); Keras (Gulli
 247 and Pal, 2017); OpenCV (Culjak et al., 2012).

248

249 3. Results

250

251 3.1. Convolutional neural network


252

253 A database containing 468 images of chickens in three different planes was
254 used to apply CNN. The number of images for training, validation, and testing are
255 shown in Table 2.

256 The CNN model accuracy was 40% in the validation dataset (Fig. 7). During the
257 training, the accuracy values increased in each step. Meanwhile, the validation
258 accuracy value remained constant from epoch 30 onwards.

259

260



261 **Fig. 7.** Training and validation accuracy values of the convolutional neural network.

262

263 It was observed that the network was overfitted, probably due to the number of
264 images used in network training, since CNNs have a large number of parameters to
265 be trained and, therefore, several images are required for training. It is also important
266 to mention that when the training accuracy value is high, but the validation accuracy

267 is low, the network is probably only memorizing training data that are not relevant for
268 a more inclusive image classification.

269

270 *3.2. Template matching*

271

272 *3.2.1. Detection*

273 In this step, we analyzed the number of chickens detected or not by YOLO in
274 the images that showed the frontal plane of the chickens (Table 3). The YOLO
275 network showed accuracy of 86.54%.

276

277 *3.2.2. Identification*

278 The identification of Canela-Preta chickens using template matching was
279 efficient with average similarity of 99.58%, mean error of 0.42%, and accuracy of
280 86.54% (Table 4).

281 The accuracy and MAD were also used for analyzing the algorithm
282 performance, as shown in Table 4. The accuracy was used to evaluate the number of
283 images of chickens correctly identified using template matching. Meanwhile, the MAD
284 metric was used to evaluate the average similarity in the identification of the Canela-
285 Preta chickens in study. The values obtained were sufficient for identification of the
286 chickens in the images.

287

288 **4. Discussion**

289

290 The identification via CNN used all the search images available; however, no
291 satisfactory result was obtained in the classification of individuals. These results
292 showed low accuracy probably due to the low number of images obtained for training.

293 In a study to identify dairy cows through lateral view images using their own
294 database, Shen et al. (2020) used information of 105 different individuals and the
295 data augmentation approach, which generated a total of 82,633 images. In the study
296 mentioned above, they used the YOLO network to detect cows in the images and an
297 AlexNet convolutional neural network for image classification.

298 Hansen et al. (2018) proposed different methods for the facial identification of
299 pigs using their own database and data augmentation techniques, which allowed
300 them to obtain 1553 images of 10 individuals. In this case, the convolutional neural
301 network was the most efficient method, with accuracy of 96.7%.

302 In a study for facial identification of sheep, Salama et al. (2019) used images of
303 52 animals. For each sheep, 1000 images were generated after data augmentation,
304 resulting in a total of 52,000 images. In the aforementioned study, a convolutional
305 neural network was created for the sheep classification, which generated a model
306 that achieved 98.0% accuracy.

307 The main differences between the approaches applied in the studies mentioned
308 above (Table 5) and the method used in the current study were the data
309 augmentation techniques and animal species.

310 In the present study, template matching reached 99.58% of similarity and
311 overcame the convolutional neural network in the identification of Canela-Preta
312 chickens. This result was observed especially due to the lower complexity in image
313 processing performed using template matching.

314 It is important to mention that template matching compared two images
315 (template and search) to indicate a certain correspondence between them. On the
316 other hand, the convolutional neural network needs a sufficient amount of images
317 along with other parameters for classification of chickens.

318 It is also noteworthy that the data augmentation technique was not used in this
319 study for two reasons. Firstly, because the deformation of image structures could be
320 significantly affected by pre-processing, leading to the loss of relevant information
321 and compromising the learning of the convolutional neural network. The second
322 reason is that the large number of images to be trained would increase the
323 computational cost, thus leading to costly training and probably more hardware and
324 software requirements.

325 The method proposed here reached accuracy of 86.54% in the identification of
326 Canela-Preta chickens. No studies related to chicken identification using images
327 were found in the literature. Therefore, we compared our findings to those reported in
328 other animal species.

329 Differently of our work, in which we used only original images, the studies
330 reported in other species used image data augmentation techniques to expand the
331 size of the datasets. Therefore, we believe that the accuracy tends to increase when
332 data augmentation is used.

333

334 **5. Conclusions**

335

336 It was possible to identify Canela-Preta chickens using the proposed algorithm.
337 This will expand the understanding of bird identification from images, thus
338 contributing to the development of computational tools based on artificial intelligence.

339

340 Declaration of competing interest

341

342 The authors declare that they have no competing financial interests or personal
343 relationships that could influence the work reported in this paper.

344

345 Acknowledgements

346

347 This study was partially funded by the Coordenação de Aperfeiçoamento de
348 Pessoal de Nível Superior – Brasil (CAPES – Register number: 001).

349

350 References

351

352 Carvalho, D. A., Bonafé, C.M., Rodriguez-Rodriguez, M. D. P., Almeida, M. J. O.,
353 Sarmiento, J. L. R., Britto, F. B., Silva, M. A., 2016. Caracterização genética e
354 estrutura populacional de galinhas crioulas Canela-Preta. *Pesq. Agropec. Bras.*
355 51, 1899–1906. <https://doi.org/10.1590/S0100-204X2016001100012>.

356 Carvalho, D. A., Martínez, A. M., Carolino, I., Barros, M. C., Vallejo, M. E. C., Santos-
357 Silva, F., Almeida, M. J. O., Carolino, N., Bermejo, J. V. D., Sarmiento, J. L. R.,
358 2020. Diversity and genetic relationship of free-range chickens from the
359 northeast region of Brazil. *Animals* 10, 1857.
360 <https://doi.org/10.3390/ani10101857>.

361 Culjak, I., Abram, D., Pribanic, T., Dzapo, H., Cifrek, M., 2012. A brief introduction to
362 OpenCV, In: *Proceedings of the 35th International Convention*. MIPRO, pp.
363 1725–1730.

- 364 Goldsborough, P., 2016. A tour of TensorFlow. arXiv preprint. arXiv.1610.01178.
365 <https://doi.org/10.48550/arXiv.1610.01178>.
- 366 Gulli, A., Pal, S., 2017. Deep learning with Keras. Packt Publishing Ltd.
- 367 Hansen, M. F., Smith, M. L., Smith, L. N., Salter, M. G., Baxter, E. M., Farish, M.,
368 Grieve, B., 2018. Towards on-farm pig face recognition using convolutional
369 neural networks. *Comput. Ind.* 98, 145–152.
370 <https://doi.org/10.1016/j.compind.2018.02.016>.
- 371 Hashemi, N. S., Aghdam, R. B., Ghiasi, A. S. B., Fatemi, P. Template matching
372 advances and applications in image analysis. arXiv preprint arXiv:1610.07231,
373 2016. *Am. Sci. Res. J. Eng. Technol. Sci.*, 26, 91–108.
374 https://asrjetsjournal.org/index.php/American_Scientific_Journal/article/download/2378/955/.
- 375
- 376 Lin, T.-Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., Dollár, P.,
377 Zitnick, C. L., 2014. Microsoft COCO: Common objects in context. In: European
378 conference on computer vision. *ECCV*, pp. 740–755.
379 https://doi.org/10.1007/978-3-319-10602-1_48.
- 380 McCool, C., Perez, T., Upcroft, B., 2017. Mixtures of lightweight deep convolutional
381 neural networks: applied to agricultural robotics. *IEEE Robot. Autom. Lett.* 2,
382 1344–1351. <https://doi.org/10.1109/LRA.2017.2667039>.
- 383 Oliveira, D. A. B., Pereira, L. G. R., Bresolin, T., Ferreira, R. E. P., Dorea, J. R. R.,
384 2021. A review of deep learning algorithms for computer vision systems in
385 livestock. *Livest. Sci.* 253, 104700, <https://doi.org/10.1016/j.livsci.2021.104700>.
- 386 Rahnemoonfar, M., Sheppard, C., 2017. Deep count: fruit counting based on deep
387 simulated learning. *Sensors* 17, 905. <https://doi.org/10.3390/s17040905>.

- 388 Redmon, J., Divvala, S., Girshick, R., Farhadi, A., 2016. You only look once: unified,
389 real-time object detection. In: Proceedings of the IEEE Conference on
390 Computer Vision and Pattern Recognition. CVPR, pp. 779–788.
391 <https://doi.org/10.48550/arXiv.1506.02640>.
- 392 Salama, A., Hassanien, A. E., Fahmy, A., 2019. Sheep identification using a hybrid
393 deep learning and Bayesian optimization approach. IEEE Access 7, 31681–
394 31687. <https://doi.org/10.1109/ACCESS.2019.2902724>.
- 395 Shen, W., Hu, H., Dai, B., Wei, X., Sun, J., Jiang, L., Sun, Y., 2020. Individual
396 identification of dairy cows based on convolutional neural networks. Multimed.
397 Tools Appl. 79, 14711–14724. <https://doi.org/10.1007/s11042-019-7344-7>.
- 398
- 399
- 400
- 401
- 402
- 403
- 404
- 405
- 406
- 407
- 408
- 409
- 410
- 411

412 **Table 1** Convolutional neural network architecture for identification of Canela-Preta
 413 chickens.

Type of layer	Kernel size	Stride (steps)	Activation
Conv2D	3 × 3	1	ReLU
Max pooling	2 × 2	-	-
Conv2D	3 × 3	1	ReLU
Max pooling	2 × 2	-	-
Dropout	0.25	-	-
Conv2D	2 × 2	1	ReLU
Max pooling	2 × 2	-	-
Conv2D	2 × 2	1	ReLU
Max pooling	2 × 2	-	-
Conv2D	2 × 2	1	ReLU
Max pooling	2 × 2	-	-
Dropout	0.25	-	-
Flaten	-	-	-
Dense	64	-	ReLU
Dense	135	-	Softmax

414 Conv2D: 2D convolution layer; ReLU: rectified linear unit.

415

416

417

418

419 **Table 2** Number of images of Canela-Preta chickens for each dataset.

Dataset	%	Number of images
Training	64	299
Validation	16	75
Testing	20	94

420

421

422

423

424

425

426

427

428

429

430

431

432

433

434

435

436

437

438

439

440 **Table 3** Number of images detected using the YOLO algorithm.

Frontal plane	Detected		Not detected	
	Number	(%)	Number	(%)
156	135	86.54	21	14.46

441

442

443

444

445

446

447

448

449

450

451

452

453

454

455

456

457

458

459

460

461

462

463 **Table 4** Identification using template matching.

Images		Metric (%)		
Template	Search	Mean error	Similarity	Accuracy
135	156	0.42	99.58	86.54

464

465

466

467

468

469

470

471

472

473

474

475

476

477

478

479

480

481

482

483

484

485 **Table 5** Comparison of methods used in similar studies.

Paper	Original image	Size of image	Database	YOLO	CNN	Template matching	Accuracy
	databases	database for data augmentation					
Shen et al. (2020)	105	82,633	Own	X	X	-	96.65%
Hansen et al. (2018)	10	1,553	Own	-	X	-	96.70%
Salama et al. (2019)	52	52,000	Own	-	X	-	98.00%
Proposed method	156	-	Own	X	X	X	86.54%

486 YOLO: You only look once network; CNN: convolutional neural network.

CONSIDERAÇÕES FINAIS

Este trabalho se enquadra na categoria estrutural, em que as imagens representam o objeto de análise para a realização do reconhecimento de padrões de características (crista, barbela, plumagem na região do pescoço, tamanho do bico) das galinhas.

Um fator importante de se ressaltar é que o algoritmo desenvolvido nesta pesquisa proporciona inovação aos pequenos e médios produtores de galinhas da raça Canela-Preta no que tange ao monitoramento e a possível escrituração zootécnica dos animais, visto a grande importância da correta identificação dos animais para avaliações genéticas.

Este algoritmo de identificação de galinha da raça Canela-Preta pode ser considerado como a primeira etapa de uma ampla pesquisa e será introduzido numa ferramenta computacional para que pequenos e médios produtores possam monitorar em tempo real seu criatório e realizar tomadas de decisões quanto ao manejo, o controle zootécnico, bem-estar e predição de características para seleção de animais.

APÊNDICES

03/02/2022 16:19

https://suap.ifpi.edu.br/processo_eletronico/visualizar_capa_processo/29693/


Processo Eletrônico 23189.000044/2022-06



Data
03/02/2022
16:13:54

Setor de Origem
CAJFR - DG-JOFREIT-CAMPUS AVANÇADO JOSE DE FREITAS

Tipo
Inovação:
Registro de
Software

Assunto
Solicitação de registro de programa de computador: Algoritmo de visão computacional para identificação de galinhas da raça canela-preta

Interessados
Jose dos Santos de Moura

Situação
Em trâmite

Trâmites

- 03/02/2022 16:13
Aguardando recebimento por: CONIT-IFPI
- 03/02/2022 16:13
Enviado por: DG-JOFREIT-CAMPUS AVANÇADO JOSE DE FREITAS: Jose dos Santos de Moura