

# Classificação Automática de Ovos por Translucência: Uma Contribuição para a Indústria 4.0

Patrik L. Peres, Márcio H. Costa, Álvaro Burin. Jr., Ton Kramer e Lucas Rodrigues

**Resumo**—Este trabalho apresenta uma proposta de classificador automático para imagens de translucência de ovos férteis e comerciais, baseado em métodos de aprendizado de máquina. A análise de translucência é utilizada para avaliação da qualidade de casca, podendo ser relacionada com aspectos nutricionais, sanitários e de manejo. Uma comparação entre diferentes estratégias de aprendizado de máquina, no maior banco de dados relatado na literatura até o momento, revela evidências de que o método de máquina de vetores suporte, alimentado pela rede ResNet512, resulta em desempenho compatível ao de especialistas humanos, permitindo a automatização do referido processo em sistemas comerciais.

**Palavras-Chave**— *Translucência, Aprendizado de Máquina*

**Abstract**— This paper presents an automated classifier for translucency images of fertile and commercial eggs, based on machine learning methods. Translucency analysis is utilized for the evaluation of shell quality, which can be correlated with nutritional, sanitary, and management aspects. A comparison among different machine learning strategies, on the largest database reported in the literature to date, reveals evidence that the support vector machine method, fed by the ResNet512 network, yields performance comparable to that of human specialists, enabling the automation of the aforementioned process in commercial systems.

**Keywords**— *Translucency, Machine Learning.*

## I. INTRODUÇÃO

O mercado global de proteína alimentar de frango, tanto em ovos quanto em carne, é um pilar da segurança alimentar mundial, com a produção anual superando 50 bilhões de aves [1]. Para atender à crescente demanda e garantir a sustentabilidade, a indústria avícola tem passado por uma transformação digital significativa. Tecnologias como internet das coisas (IoT), inteligência artificial (IA), robótica, sensoria-mento óptico e computação em nuvem estão convergindo para criar a chamada Indústria do “Ovo 4.0” [2].

As linhagens genéticas modernas de frangos de corte, caracterizadas pelo rápido crescimento, resultaram em um terço de seu ciclo de vida transcorrido dentro do ovo [3]. Com uma taxa média de eclodibilidade de 80,3% [3], a eficiência da produção avícola depende do monitoramento preciso da qualidade da casca. Diversos parâmetros são, portanto, quantificados e analisados, incluindo a dureza da casca, o tamanho do ovo, a presença de trincas e o potencial de fertilidade.

Na busca por métodos eficientes de avaliação, as técnicas não destrutivas, como análise por ultrassom, imagens térmicas, visão computacional, espectroscopia e imageamento hiper-espectral, destacam-se como as mais promissoras [1] [3].

---

Patrik L. Peres e Márcio H. Costa, Departamento de Engenharia Elétrica e Eletrônica, Universidade Federal de Santa Catarina, Florianópolis-SC, Brasil. Álvaro Burin Jr., Ton Kramer e Lucas Rodrigues, Zinpro Animal Nutrition Comercial Ltda, Piracicaba-SP, Brasil. E-mails: patrikloff@gmail.com; costa@eel.ufsc.br; {aburin, tkramer, lrodrigues}@zinpro.com.

A casca do ovo desempenha um papel crucial no desenvolvimento embrionário, atuando como barreira contra patógenos e perda de água, além de regular a respiração e fornecer cálcio [3]-[7]. A estrutura mineralizada da casca é composta por três camadas principais: mamilar, paliçada e cristalina vertical [6] [8]. Suas características são influenciadas por fatores intrínsecos e extrínsecos, como genética, idade, dieta e temperatura, impactando diretamente na taxa de eclodibilidade.

A análise da translucência da casca, um fenômeno explorado inicialmente em 1932 por Holst *et al.* [7], caracteriza-se pela presença de pequenas manchas claras visíveis a olho nu sob iluminação natural ou artificial [8]. Essa característica tem recebido crescente atenção devido à sua correlação com piores índices produtivos no incubatório [3]-[3], além de estar associada a um produto de qualidade inferior, reduzindo a atratividade para os consumidores [8]. A avaliação da translucidez é realizada de forma visual por especialistas, utilizando sistemas de pontuação que variam de três a seis níveis [6] [8]. Esse método, no entanto, é trabalhoso e sujeito a erros de classificação [2] [6] [8]. A avaliação acurada e de alto rendimento de ovos translúcidos ainda representa um desafio [8].

Este trabalho apresenta um sistema para segmentação e classificação de imagens de ovos utilizando o método de translucência e técnicas de aprendizagem de máquina. As principais contribuições deste trabalho são: (a) um método eficiente para segmentação de ovos em bandejas; (b) um método para classificação da translucência de ovos em três níveis (leve, moderado e severo); (c) uma análise de acurácia de classificação à luz do desempenho de especialistas humanos.

O trabalho foi organizado da seguinte forma: a Seção II apresenta uma revisão da literatura sobre métodos de estimação e classificação automática de parâmetros do ovo. A Seção III descreve o sistema comercial de aquisição de imagens utilizado e o procedimento convencional de análise. A proposta para segmentação e classificação automática das imagens e os procedimentos de avaliação são detalhados na Seção IV. A Seção V apresenta os resultados e discussão. As conclusões deste estudo são apresentadas na Seção VI.

## II. REVISÃO DA LITERATURA

Diversas estratégias têm sido aplicadas pela indústria avícola para a realização do controle de qualidade dos ovos. As formas mais comuns de análise compreendem a verificação do aspecto exterior da casca. Dessa análise resultam parâmetros indicadores de qualidade, como dimensões geométricas, índices de forma, espessura, trincas e grau de translucência [9].

A ovoscopia tem como objetivo a verificação da fertilidade do ovo, normalmente conduzida entre o quinto e décimo dia de incubação.

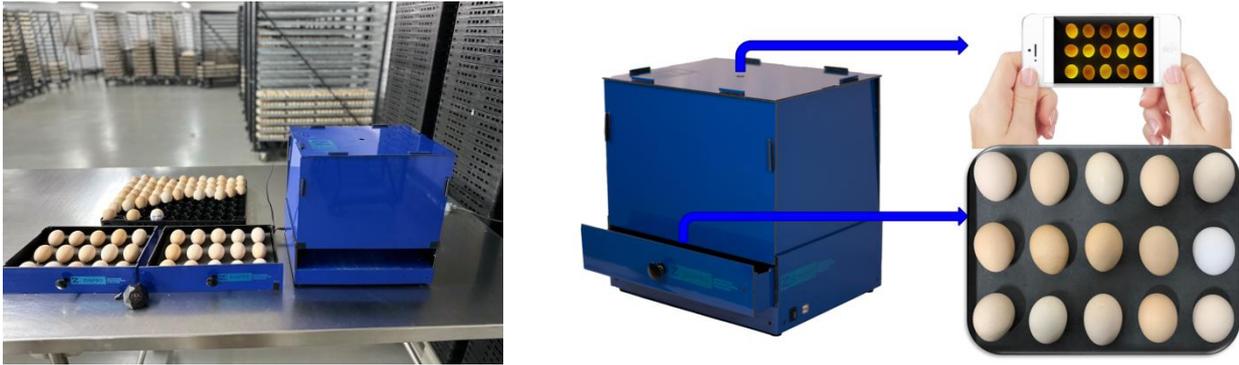


Fig. 1. Sistema de aquisição de imagens por translucência Zinpro® BlueBox™.

O procedimento é realizado através da exposição do ovo à luz brilhante, sendo seu interior inspecionado visualmente em busca de sinais de desenvolvimento embrionário. Em geral, apenas aproximadamente 5% de todo o conjunto de ovos incubados é investigado aleatoriamente por especialista humano [10].

Recentemente, técnicas de aprendizado de máquina têm sido utilizadas para a predição de fertilidade de ovos, em substituição ao método manual.

Em [11] foi proposta uma rede neural convolucional para classificação de fertilidade em ovos entre o sétimo e nono dia de incubação. Foi apresentada uma acurácia de 100% para um conjunto de 916 ovos (313 férteis e 603 inférteis). Em [12] procedimento similar foi utilizado, obtendo 99,96% de acurácia em um banco de 1540 imagens. Utilizando uma rede neural artificial, Fadchar e Cruz obtiveram 97% de acurácia na mesma tarefa utilizando 150 ovos [13]. Posteriormente, Çevic *et al.* investigaram o uso de técnicas de aprendizado profundo, apresentando 100% de acurácia no terceiro dia de incubação em um conjunto de 24 ovos, sendo 18 férteis [14]. Recentemente, Ahmed *et al.* utilizaram técnicas de aprendizado de máquina (extreme gradient boosting, categorical boosting, random forest e máquinas de vetores suporte) em conjunto com imagens hiperespectrais. Utilizando 771 ovos, o método categorical boosting obteve 95% de acurácia [10]. Em [15] foram utilizados classificadores convencionais baseados em máquinas de vetores suporte para distinguir ovos inférteis de ovos com embriões mortos, tendo sido obtido 100% de acurácia.

Em [16] foi investigada a possibilidade de classificação de qualidade de ovos em termos de quantidade de proteína. Classificadores binários para as categorias “excelente” e “muito bom” foram implementados utilizando árvores de decisão, análise de discriminantes lineares, regressão logística, naive Bayes, máquinas de vetores suporte, K vizinhos mais próximos, Random Forest e redes neurais artificiais em um total de 803 ovos (542 excelentes e 261 muito bons), atingindo acurácias entre 95 e 98%, dependendo do período de incubação.

Em [2] foi utilizado a técnica de máquinas de vetores suporte para a classificação do tamanho de ovos. O problema de três classes obteve acurácia de 98% em um conjunto de 425 ovos, sendo 128 pequenos, 209 médios e 88 grandes.

Apesar de vários avanços no sentido de obter estimadores de parâmetros indicadores de qualidade [9] e classificadores de fertilidade [10] [11] [13] [15], qualidade [16] e tamanho [2], os resultados apresentados na literatura foram obtidos a partir de pequenos conjuntos de dados. Adicionalmente, os autores desconhecem estudos sobre a automação do processo de classificação de eclodibilidade utilizando técnicas de aprendizado de máquina.

### III. SISTEMA DE AQUISIÇÃO

O sistema Zinpro® BlueBox™ de aquisição de imagens para análise de translucência de ovos (Fig. 1) consiste em um receptáculo para uma bandeja contendo um conjunto de quinze ovos distribuídos em uma matriz de três linhas por cinco colunas. Possui um conjunto de LEDs na parte inferior da gaveta de ovos e um compartimento na parte superior reservado para a alocação de um telefone celular, utilizado para captação das imagens. O telefone celular não faz parte do sistema e, portanto, a qualidade da câmera é definida pelo usuário.

Os ovos são selecionados por amostragem de cada lote, as imagens são digitalizadas e posteriormente analisadas por especialistas em relação a níveis de eclodibilidade em função da quantidade e qualidade das marcas de translucência (Fig. 2).

A metodologia de análise Zinpro® BlueBox™ é um procedimento padronizado e proprietário que utiliza três níveis [17]. O ovo tipo 1 apresenta nenhum ou poucos pontos de translucência, indicando maior potencial de eclodibilidade. O tipo 2 apresenta vários pequenos pontos de translucência, caracterizando ovos de médio potencial de eclodibilidade. O tipo 3 apresenta elevada quantidade de pontos de translucência, podendo apresentar grandes áreas. A existência de um número significativo de ovos do tipo 3 é um indicativo da necessidade de correção nutricional das matrizes ou poedeiras.

### IV. SISTEMA PROPOSTO

Esta seção apresenta o sistema proposto para classificação da translucência de ovos. São apresentados o banco de dados, a etapa de pré-processamento das imagens, englobando normalização, filtragem e segmentação, a descrição dos classificadores utilizados e a metodologia de avaliação.

#### A. Banco de Dados

O banco de imagens de propriedade da empresa Zinpro® foi constituído por um total de 2.211 imagens de bandejas contendo 15 ovos cada, totalizando 33.165 ovos. Um arquivo associado contém rótulos, atribuídos por profissional especialista humano, para cada ovo, sendo relativos a três classes de translucência (tipos 1, 2 e 3 - Fig. 2).

#### B. Segmentação

Devido à utilização de distintas câmeras de aparelhos celulares e diferentes condições de aquisições (iluminação e posicionamento) as imagens das bandejas não são padronizadas, podendo apresentar desvios significativos nas posições dos ovos, dificultando a individualização automática.

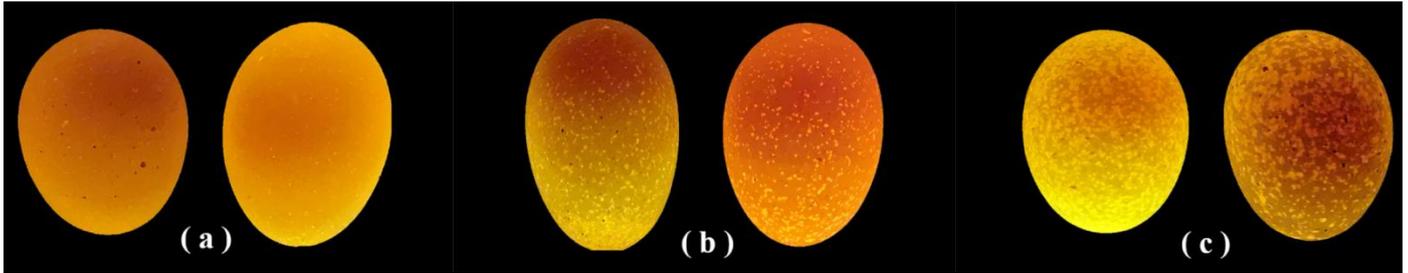


Fig. 2. Sistema de classificação de ovos por avaliador humano. (a) Tipo 1: nenhum ou poucos pontos de translucência; (b) Tipo 2: pequenos e vários pontos de translucência; e (c) Tipo 3: muitos e grandes pontos de translucência.

O procedimento de segmentação dos ovos das bandejas foi implementado por um processo automático de sete etapas, cada uma composta pelos seguintes passos: recorte, equalização de histograma, equalização adaptativa de histograma com contraste limitado e ajuste gamma [18], operações morfológicas de abertura (elementos de  $60 \times 60$  pixels) e fechamento (elementos de  $5 \times 5$ ,  $10 \times 10$ ,  $20 \times 20$ ,  $55 \times 55$  e  $60 \times 60$  pixels, dependendo da etapa), detecção de bordas utilizando o algoritmo de Canny ( $\sigma \in \{2, 2,5, 3, 4,5, 5\}$ ) [19] e estimação de máscara de segmentação (obtida pelo preenchimento da região de contorno definida pela técnica de Canny). Um procedimento de verificação é aplicado aos ovos segmentados de forma a detectar a existência de apenas uma área contígua, evitando a inclusão de partes de ovos adjacentes. Imagens que não são aprovadas pela etapa inicial são submetidas sequencialmente às demais etapas. As imagens que não são aprovadas ao final das sete etapas são rejeitadas. O procedimento de segmentação resultou em 97% de individualizações corretas. Como resultado, foram obtidos 32.395 ovos (de um total de 33.165) sendo 3.238 unidades do tipo 1 (9,99%), 18.838 unidades do tipo 2 (58,15%) e 10.319 do tipo 3 (31,85%).

### C. Normalização

A partir das imagens individualizadas foi realizada a transformação do formato RGB para tons de cinza, visto a independência das classes em relação à cor do ovo. Em sequência foi realizada normalização de brilho e contraste utilizando a técnica contrast limited adaptive histogram equalization [19]. Finalmente, realizou-se normalização da área do ovo utilizando interpolação bilinear e o redimensionamento de  $1286 \times 1508$  para  $224 \times 224$  pixels.

### D. Data Augmentation

O desbalanço entre as classes de dados foi compensado através da criação de imagens complementares obtidas através de rotações e inversões nos eixos vertical ou horizontal das imagens originais [20]. Foi realizada a criação de cinco novas imagens para cada ovo do tipo 1 e uma nova imagem para cada ovo tipo 3. Esse procedimento resultou em 19.438 imagens do tipo 1, 18.838 do tipo 2 e 20.638 do tipo 3, totalizando 58.914 imagens no banco de dados aumentado. Esse procedimento foi realizado separadamente nos grupos de treinamento, validação e teste de forma a evitar vazamento de informação.

### E. Extração de Características

A extração de parâmetros característicos foi realizada através de uma rede neural convolucional pré-treinada. Após testes preliminares com as redes MobileNetV2, ResNet101, ResNet152 e Xception foi selecionada a ResNet152 [21]. Essa rede extratora possui 152 camadas, sendo que a de entrada apresenta dimensão  $224 \times 224$ . A camada de saída foi retirada e

os 2.048 valores de saída da penúltima camada foram utilizados como parâmetros característicos. Os pesos usados foram obtidos a partir da Imagenet (rede pré-treinada com outras imagens).

### F. Classificadores

Os modelos de aprendizagem utilizados foram: máquinas de vetores suporte (SVM), Random Forest (RF), K vizinhos mais próximos (KNN), regressão linear (RL) e análise de discriminantes lineares (LDA). Os hiperparâmetros utilizados foram obtidos por busca exaustiva e os algoritmos implementados no ambiente MatLab.

Os 32.395 ovos individualizados foram separados da seguinte forma: 60% para o conjunto de treinamento, 10% para o conjunto de validação e 30% para o conjunto de teste.

### G. Avaliação

A avaliação de desempenho dos classificadores investigados foi realizada através das métricas: acurácia, acurácia balanceada, precisão, recall e F1.

Um conjunto de 600 ovos do conjunto de teste (sem data augmentation) adicionado a 20% de repetição dessas imagens foi selecionado aleatoriamente, mas de forma a manter a proporção original de tipos de ovos do banco de dados original, e organizado artificialmente na forma de 48 bandejas com 15 ovos cada. Essas bandejas foram submetidas à análise de cinco avaliadores profissionais da empresa Zinpro®, sem conhecimento do objetivo. Os resultados foram anotados de forma anonimizada. Esses resultados têm como objetivo a quantificação do desempenho humano médio na análise da translucência de ovos e a estimação da confiabilidade inter e intra-avaliador. A avaliação de desempenho dos avaliadores é parte integrante das atividades desses profissionais e realizada periodicamente pela empresa contratante.

A avaliação intra-avaliador (repetibilidade das respostas de um mesmo avaliador a uma mesma imagem em diferentes momentos) foi estimada pelo coeficiente de Pearson [22], enquanto que a confiabilidade inter avaliador (correlação linear entre as respostas dos diferentes participantes a um mesmo conjunto de imagens) foi estimada pelo coeficiente de correlação intraclasse (ICC) [22].

## V. RESULTADOS E DISCUSSÃO

A otimização dos hiperparâmetros dos classificadores foi realizada através do conjunto de validação utilizando a faixa de parâmetros apresentada na TABELA I.

Os resultados apresentados na TABELA II indicam melhor desempenho de classificação para o método de máquinas de vetores suporte. Dessa forma, os demais resultados apresentados referem-se ao SVM.

Os resultados da avaliação da concordância intra-avaliador são apresentados na TABELA III. Nota-se que a média de

concordância dos avaliadores é de 83% e o coeficiente de Pearson é 0,69. Esses resultados indicam consistência de classificação quando a mesma imagem é apresentada em dois momentos diferentes para um mesmo avaliador. O modelo de aprendizado de máquina, naturalmente, apresenta 100% de concordância e coeficiente de Pearson unitário. Por outro lado, a avaliação inter avaliador resultou em um ICC de 0,60, o que indica confiabilidade moderada para as classificações dos diferentes avaliadores [23].

TABELA I. OTIMIZAÇÃO DOS HIPERPARÂMETROS

| Modelo | Parâmetro         | Faixa                                      | Resultado           |
|--------|-------------------|--|---------------------|
| RL     | C                 | 0,01, 0,05, 0,1, 0,5, 1,5, 10              | 0,1                 |
| SVM    | C                 | 0,1, 1                                     | 0,1                 |
|        | kernel<br>gamma   | “linear”, ”rbf”, ”poly”<br>“scale”, ”auto” | “linear”<br>“scale” |
| RF     | max_depth         | 10, 20, 50, 100                            | 50                  |
|        | min_samples_split | 50, 100, 200, 300                          | 100                 |
|        | min_samples_leaf  | 50, 100, 200, 300                          | 50                  |
| KNN    | n_neighbors       | 10, 50, 100, 500                           | 50                  |
|        | Weights           | “uniform”, ”distance”                      | “distance”          |
|        | Metric            | “Euclidean”, ”Manhattan”                   | “Manhattan”         |
| LDA    | Solver            | “svd”, ”lsqr”, ”eigen”                     | Svd                 |

TABELA II. ACURÁCIA DOS MODELOS INVESTIGADOS

| Modelo | Acurácia     |               | Acurácia Balanceada |               |
|--------|--------------|---------------|---------------------|---------------|
|        | Média        | Desvio Padrão | Média               | Desvio Padrão |
| RL     | 84,6%        | 0,003         | 84,8%               | 0,003         |
| SVM    | <b>85,3%</b> | 0,005         | <b>85,5%</b>        | 0,005         |
| RF     | 80,8%        | 0,004         | 81,2%               | 0,007         |
| KNN    | 79,2%        | 0,005         | 79,8%               | 0,004         |
| LDA    | 83,4%        | 0,004         | 83,7%               | 0,004         |

A TABELA IV apresenta a comparação de desempenho entre os cinco avaliadores humanos, sua média e os resultados obtidos do modelo de aprendizagem SVM para o conjunto resumido de 600 ovos. O SVM apresenta resultados de acurácia, acurácia balanceada, precisão, recall e F1 compatíveis com os apresentados pela média de avaliação humana. A partir desses resultados, verifica-se que o método proposto é potencialmente viável para a automatização do processo de avaliação de translucência de ovos, provendo resultados dentro da faixa de confiabilidade humana. A Fig. 3 apresenta as matrizes de confusão relativas aos avaliadores 2 (menor acurácia balanceada) e 5 (maior acurácia balanceada) e modelo SVM, para a situação apresentada na TABELA IV.

TABELA III. TESTE DE CONCORDÂNCIA INTRA-AVALIADOR

| Avaliador | Concordância | Coefficiente de Pearson |
|-----------|--------------|-------------------------|
| 1         | 81,7%        | 0,66                    |
| 2         | 90,0%        | 0,66                    |
| 3         | 85,0%        | 0,76                    |
| 4         | 80,8%        | 0,67                    |
| 5         | 77,5%        | 0,69                    |
| Média     | 83,0%        | 0,69                    |

TABELA IV. AVALIAÇÃO DE DESEMPENHO

| Avaliador | Acurácia     | Acurácia Balanceada | Precisão   | Recall     | F1         |
|-----------|--------------|---------------------|------------|------------|------------|
| 1         | 75,7%        | 72,83%              | 76%        | 76%        | 76%        |
| 2         | 71,7%        | 57,88%              | 77%        | 72%        | 71%        |
| 3         | 72,4%        | 76,05%              | 77%        | 72%        | 74%        |
| 4         | 69,7%        | 74,18%              | 76%        | 70%        | 71%        |
| 5         | 75,4%        | <b>76,69%</b>       | 79%        | 75%        | 76%        |
| Média     | 73%          | 71,53%              | 77%        | 73%        | 73,6%      |
| Modelo    | <b>80,9%</b> | 71,47%              | <b>81%</b> | <b>81%</b> | <b>81%</b> |

Os resultados apresentados neste trabalho utilizaram um banco de dados proprietário com 32.395 ovos, configurando o maior banco de dados na literatura, no conhecimento destes autores.

O custo computacional do classificador SVM e da rede ResNet512 permitem a implementação do método proposto em plataformas comerciais, como a Zinpro® BlueBox™, possibilitando a automatização do processo de classificação com confiabilidade e repetibilidade dos resultados.

## VI. CONCLUSÕES

Este trabalho apresentou uma proposta de classificação automática de imagens de translucência de ovos para avaliação de eclodibilidade em plantas industriais. Os resultados indicam que o desempenho do método baseado em máquinas de vetores suporte, com parâmetros alimentados pela rede pré-treinada ResNet152 é próximo do obtido com avaliadores humanos profissionais. Essas conclusões foram obtidas utilizando o maior banco de imagens para essa aplicação já referenciado na literatura, no conhecimento dos autores. O sucesso na tarefa de segmentação e a limitada complexidade computacional permitem a implementação do algoritmo desenvolvido tanto em nuvem quanto em aparelhos celulares convencionais, permitindo a realização de análise automática confiável em sistemas comerciais como o Zinpro® BlueBox™.

## REFERÊNCIAS

- [1] A. O. Adegbenjo, L. Liu, M. O. Ngadi, “Non-destructive assessment of chicken egg fertility”, *Sensors*, v. 20, n. 19, pp. 1-23, 2020.
- [2] A Çelik, E Tekin, “Classification of hatchery eggs using a machine learning algorithm based on image processing methods: A comparative study”, *Brazilian Journal of Poultry Science*, v. 26, n. 2, pp. 1-12, 2024.

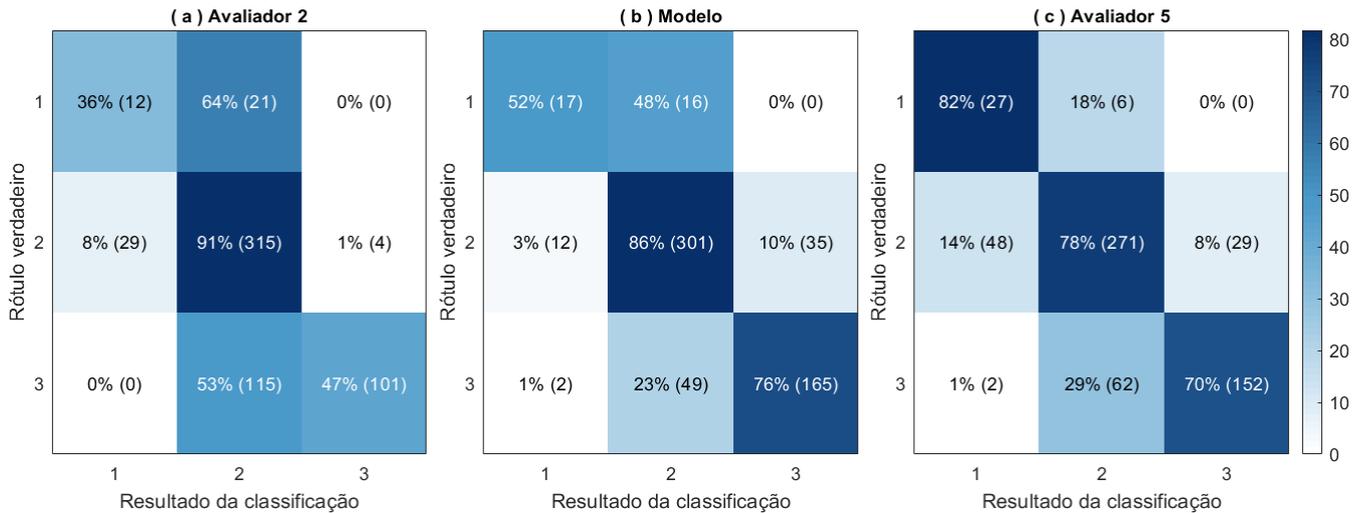


Fig. 3. Matriz de Confusão. (a) Avaliador 2 (menor acurácia balanceada); (b) Modelo de aprendizado SVM; e (c) Avaliador 5 (maior acurácia balanceada).

[3] F. L. Kroetz-Neto *et al.*, “Eggshell translucency: its relationship with specific gravity and eggshell color and its influence on broiler egg weight loss, hatchability, and embryonic mortalities”, *Poultry Science*, v. 103, n. 5, pp. 1-10, 2024.

[4] L. Orellana *et al.*, “Effect of translucency and eggshell color on broiler breeder egg hatchability and hatch chick weight”, *Poultry Science*, v. 102, n. 9, pp. 1-6, 2023.

[5] H. V. D. Brand *et al.*, “Effects of trace minerals source in the broiler breeder diet and eggshell translucency on embryonic development of the offspring”, *Poultry Science*, v. 102, n. 3, pp. 1-14, 2022.

[6] X. Cheng, Z. Ning, “Research progress on bird eggshell quality defects: a review”, *Poultry Science*, v. 102, n. 1, pp. 1-10, 2023.

[7] C. A. Morris *et al.*, “Impact of trace mineral supplementation and translucency score on eggshell quality, hatchability, fertility, and chick quality”, *Poultry Science*, v. 104, n. 1, pp. 1-10, 2025.

[8] L. Xuan, J. Zheng, “Translucent eggs of laying hens: A review”, *Poultry Science*, v. 103, n. 9, pp. 1-10, 2024.

[9] A. V. Vasileva *et al.*, “Assessing exterior egg quality indicators using machine vision”, *British Poultry Science*, v. 59, n. 6, pp. 636-645, 2018.

[10] M. W. Ahmed *et al.*, “Non-destructive detection of pre-incubated chicken egg fertility using hyperspectral imaging and machine learning”, *Smart Agricultural Technology*, v. 10, pp. 1-12, 2025.

[11] W. Koodtalang, T. Sangsuwan, A. Rerkratn, “Non-destructive fertility detection of multiple chicken eggs using image processing and convolutional neural network”, *International Conference on Mechatronics and Manufacturing (ICMM 2020)*, 2020, pp. 1-6.

[12] Z. Chen *et al.*, “Eggshell biometrics for individual egg identification based on convolutional neural networks”, *Poultry Science*, v. 102, n. 4, pp. 102540, 2023.

[13] N. A. Fadchar, J. C. Cruz, “Prediction model for chicken egg fertility using artificial neural network”, *International Conference on Industrial Engineering and Applications*, 2020, pp. 1-5.

[14] K. K. Çevik, H. E. Koçer, M. Boğa, “Deep learning based egg fertility detection”, *Veterinary Sciences*, v. 9, n. 10, pp. 1-13, 2022.

[15] Z. Zhu, K. Yang, Y. He, “Research on detection of fertility of group hatching eggs based on adaptive image segmentation”, *Applied Engineering in Agriculture*, v. 38, n. 2, pp. 283-291, 2022.

[16] E. Sehirli, K. Arslan, “An application for the classification of egg quality and Haugh unit based on characteristic egg features using machine learning models”, *Expert Systems with Applications*, v. 205, n. 1, pp. 1-6, 2022.

[17] BlueBox, Zinpro. Disponível em: <https://www.zinpro.com/pt/resource-center/blog/only-the-zinpro-bluebox-tells-the-full-story-of-eggshell-translucency>.

[18] R. Szeliski, *Computer Vision: Algorithms and Applications*. Springer, 2021, p. 1206.

[19] R. C. Gonzalez, R. E. Woods, *Digital Image Processing*. Pearson, 2018, pp. 1019.

[20] K. Maharana, S. Mondal, B. Nemedi, “A review: Data pre-processing and data augmentation techniques”, *Global Transitions Proceedings*, v. 3, pp. 91-99, 2022.

[21] M. K. Panda *et al.*, “Modified ResNet-152 network with hybrid pyramidal pooling for local change detection”, *IEEE Transactions on Artificial Intelligence*, v. 5, n. 4, pp. 1599-1612, 2024.

[22] P. C. Loizou, *Speech Enhancement: Theory and Practice*. CRC Press, 2013.

[23] J. P. Weir, “Quantifying test-retest reliability using the intraclass correlation coefficient and the SEM”, *Journal of Strength and Conditioning Research*, v. 19, n. 1, pp. 231-40, 2025.