OVOSCOPIA DIGITAL E VISÃO COMPUTACIONAL NA INSPEÇÃO DE OVOS: DESEMPENHO, RENDIMENTO E CUSTO-BENEFÍCIO

Maria Eduarda Quírico Valente, Marivan da Conceição Monteiro, Surama Azevedo Freitas, Magda Aparecida Nogueira Andrade

Universidade Federal do Espírito Santo, Alto Universitário, s/nº, Guararema – 29500-000 – Alegre-ES, Brasil, mariaeduardavalente02@gmail.com, marivandaconceicaomonteiro3@gmail.com, smzanini@yahoo.com.br, magda.nogueira@ufes.br

Resumo

A ovoscopia digital associada à visão computacional permite avaliar ovos sem romper a casca e reduzir a dependência da inspeção exclusivamente visual. Este trabalho analisou o desempenho tecnológico, o rendimento operacional e os fatores relacionados ao custo-benefício dessa tecnologia por meio de revisão narrativa de literatura e pesquisa documental. Os estudos analisados mostram aplicações na mensuração de características morfométricas, detecção de trincas, quantificação da translucidez, classificação da qualidade, estimativa de componentes internos e monitoramento da produção. Os métodos permitiram extrair informações das imagens, classificar ovos, estimar características e reconhecer ovos em condições de campo. Entretanto, os resultados variaram conforme a iluminação, as características da casca, a qualidade das imagens e a representatividade das bases de treinamento. O rendimento operacional depende do fluxo de trabalho e da integração com outras etapas, enquanto a relação custo-benefício deve considerar os custos de implantação e operação em comparação com benefícios potenciais, como redução de perdas, maior rapidez, rastreabilidade e menor subjetividade.
Palavras-chave: Qualidade de ovos. Inspeção não destrutiva. Aprendizado de máquina. Automação. Avicultura de postura.
Área do Conhecimento: Ciências Agrárias – Zootecnia.

Introdução

A qualidade dos ovos destinados ao consumo depende de características externas e internas que precisam ser verificadas durante a classificação e o armazenamento. Integridade da casca, dimensões, porosidade, câmara de ar, posição da gema e aspecto do albúmen estão entre os parâmetros associados à qualidade do produto. Parte dessas avaliações é realizada visualmente e, em algumas situações, por procedimentos que exigem a quebra do ovo. A ovoscopia constitui uma alternativa não destrutiva: o ovo é colocado diante de uma fonte luminosa e a translucidez da casca permite observar estruturas internas e alterações sem romper o produto (Araújo; Albino, 2011). A técnica é simples, mas a interpretação depende do operador e tende a ser menos padronizada quando aplicada manualmente em grandes lotes.

Na ovoscopia digital, a imagem capturada pela câmera deixa de servir apenas para observação visual e passa a fornecer dados que podem ser processados para medir características do ovo, comparar padrões e identificar alterações automaticamente. Estudos recentes mostram aplicações para morfometria, porosidade e detecção de trincas (Castro Júnior et al., 2025a), quantificação automática da translucidez (Castro Júnior et al., 2025b), avaliação não destrutiva da qualidade a partir da forma do ovo (Oliveira-Boreli et al., 2023), classificação e identificação de defeitos (Yang et al., 2023) e monitoramento automatizado em ambiente de produção (Wu et al., 2025). Também há trabalhos que combinam imagens com outras fontes de informação para estimar características internas, como massa dos componentes e massa da gema (Ferraz Júnior, 2024; Liu et al., 2024). Assim, a imagem deixa de funcionar apenas como apoio visual e passa a integrar sistemas de mensuração e decisão.

A relevância da inspeção não se limita à aparência externa. Defeitos de casca podem alterar características do ovo durante o armazenamento, incluindo perda de água, permeabilidade da casca e atributos do albúmen e da gema (Wengerska et al., 2023). A translucidez, por sua vez, pode reduzir a aceitação comercial devido ao seu aspecto visual (Xuan; Zheng, 2024). Ao mesmo tempo, o desempenho obtido em condições experimentais não é suficiente para definir a conveniência da adoção em escala comercial. Cor da casca, iluminação, posicionamento, velocidade do processo e composição da base de imagens podem modificar o comportamento dos modelos. A decisão pela adoção também

deve considerar aspectos econômicos e operacionais, como necessidade de mão de obra, manutenção, vida útil e consumo de energia dos equipamentos, possibilidade de integração com outros sistemas e valor das perdas que podem ser evitadas com a melhoria da inspeção.

Diante dessas diferenças entre desempenho experimental e uso prático, este trabalho teve como objetivo analisar o desempenho tecnológico da ovoscopia digital associada à visão computacional, discutir o rendimento operacional de diferentes configurações de inspeção e examinar os principais fatores que condicionam sua relação custo-benefício na avicultura de postura.

Metodologia

O estudo consistiu em revisão narrativa de literatura associada à pesquisa documental. Foram priorizados artigos dos últimos cinco anos sobre ovoscopia, qualidade de ovos, inspeção não destrutiva, visão computacional, processamento de imagens, aprendizado de máquina e automação. As buscas combinaram os termos *egg quality, candling, computer vision, machine learning, eggshell translucency, crack detection* e *non-destructive assessment*. Incluíram-se trabalhos diretamente relacionados aos atributos ou sistemas analisados; obras anteriores foram mantidas apenas como base técnica ou econômica.

Na análise tecnológica, registraram-se aplicação, variável avaliada, configuração, amostra, indicadores e limitações. O R^2 representou a variação da resposta explicada pelo modelo, sem corresponder à porcentagem de acerto, e a correlação indicou a intensidade e a direção da associação linear (Chicco; Warrens; Jurman, 2021; Schober; Mascha; Vetter, 2021). Acurácia, precisão, *recall* e F1 corresponderam, respectivamente, à proporção total de acertos, de classificações positivas corretas, de casos positivos identificados e ao equilíbrio entre precisão e *recall* (Spies; Ng, 2025). A mAP resumiu o desempenho na detecção entre classes e limites de sobreposição (Yang et al., 2023; Wu et al., 2025). MAPE e RMSE expressaram o erro em porcentagem e na unidade da variável; valores menores indicaram melhor desempenho, e o RMSE atribuiu maior peso aos desvios elevados (Chicco; Warrens; Jurman, 2021).

O rendimento operacional foi analisado pela velocidade de processamento, taxa de reconhecimento e execução integrada das tarefas (Wu et al., 2025). Também foram consideradas limitações de iluminação, cor e translucidez da casca, segmentação e representatividade das bases. A capacidade nominal correspondeu aos ovos informados por ciclo ou hora; o rendimento, à quantidade efetivamente processada, considerando manuseio, inspeção, classificação, descarte, paradas e integração. Valores por ciclo não foram convertidos em ovos por hora sem informação sobre sua duração.

A avaliação de custo-benefício foi qualitativa, pois os dados não permitiram calcular *payback* ou retorno sobre o investimento. A comparação considerou fatores de custo e benefício e a escala de uso, distinguindo inspeção pontual, equipamentos multiposição e linhas automatizadas.

Resultados

Os trabalhos analisados mostram que a visão computacional pode atuar em diferentes etapas da avaliação dos ovos, desde a extração de medidas da casca até a classificação de defeitos e o monitoramento em condições de produção. A Tabela 1 reúne estudos recentes com resultados quantitativos diretamente relacionados à inspeção não destrutiva e à automação.

Tabela 1 - Síntese de estudos recentes sobre inspeção não destrutiva e visão computacional aplicada a ovos.

Fonte	Aplicação	Resultado principal
Castro Júnior et al. (2025a)	Morfometria, porosidade e trincas	$R^2 > 0,85$; porosidade: $R^2 = 0,97$ (brancos) e 0,87 (marrons); trincas: precisão > 91%
Castro Júnior et al. (2025b)	Quantificação e classificação da translucidez	SVM com acurácia > 90% para níveis de translucidez
Oliveira-Boreli et al. (2023)	Qualidade a partir do índice de forma	6.378 ovos; Random Forest com acurácia de 97,9%
Ferraz Júnior (2024)	Estimativa de componentes internos	MAPE < 4%; $R^2 = 0,97$ para massa total/conteúdo interno e 0,75 para clara
Liu et al. (2024)	Estimativa da massa da gema	$R^2 = 0,82$; RMSE = 1,05 g no conjunto de teste
Yang et al. (2023)	Classificação, defeitos e estimativa de peso	Acurácia de 94,8%; $R^2 = 0,96$ para estimativa de peso

Fonte	Aplicação	Resultado principal
Wu et al. (2025)	Monitoramento em ambiente de produção	Precisão 94,0%; recall 92,8%; 91,7 FPS; reconhecimento em campo 98,9%

Fonte: elaborado pelos autores a partir das referências analisadas.

Como os trabalhos diferem em amostra, atributo avaliado, equipamento e métrica de desempenho, os valores devem ser interpretados dentro de cada desenho experimental e não como uma classificação direta entre métodos.

Castro Júnior et al. (2025a) avaliaram 326 ovos comerciais, 162 de casca marrom e 164 de casca branca, em um sistema automatizado de visão computacional. Os coeficientes de determinação foram superiores a 0,85 para as variáveis morfométricas. Na análise de porosidade, o ajuste foi maior nos ovos brancos (R^2 = 0,97) do que nos marrons (R^2 = 0,87). Na identificação de trincas, a precisão foi de 96,15% para ovos marrons e 91,17% para ovos brancos, enquanto o recall foi de 89,28% e 88,57%, respectivamente. A diferença observada entre as colorações sugere que a resposta do sistema não depende apenas do algoritmo: contraste, tonalidade, iluminação e segmentação interferem na informação extraída da imagem.

A translucidez da casca, tradicionalmente avaliada de forma visual, também pode ser medida por processamento digital de imagens, permitindo sua transformação em uma variável quantitativa. Castro Júnior et al. (2025b) compararam a classificação visual dos ovos com medidas obtidas a partir das imagens e aplicaram modelos de aprendizado de máquina supervisionado para separar os ovos em diferentes níveis de translucidez. Entre os modelos testados, destacou-se o SVM (*Support Vector Machine*, ou Máquina de Vetores de Suporte), método computacional utilizado para classificar observações em grupos a partir de padrões identificados nos dados. Esse modelo apresentou acurácia superior a 90% na classificação dos níveis de translucidez. Apesar do bom desempenho, os autores observaram apenas associações moderadas entre a translucidez e algumas características da casca obtidas por métodos invasivos, como espessura e peso. Isso indica que a translucidez não deve ser utilizada isoladamente como indicador da qualidade da casca, mas em conjunto com outras variáveis. Essa interpretação também está de acordo com Xuan e Zheng (2024), que descrevem a translucidez como uma característica de interesse comercial e biológico, mas destacam que ela pode estar relacionada a diferentes fatores e ser avaliada por distintos métodos.

A estimativa de características internas amplia o alcance da inspeção não destrutiva. Ferraz Júnior (2024) utilizou câmera de alta resolução, iluminação RGBW, Raspberry Pi e redes neurais convolucionais, obtendo MAPE inferior a 4% e R^2 de 0,97 para massa total e conteúdo interno, enquanto a massa de clara apresentou R^2 de 0,75. Em ovos de pato, Liu et al. (2024) integraram espectroscopia VIS-NIR, imagens RGB e peso do ovo para estimar a massa da gema. O modelo apresentou R^2 de 0,82 e RMSE de 1,05 g no conjunto de teste; após a retirada das variáveis de cor e espessura da casca, o desempenho permaneceu próximo, com R^2 de 0,79 e RMSE de 1,11 g.

Outras abordagens recentes mostram que informações relativamente simples da imagem também podem contribuir para a classificação. Oliveira-Boreli et al. (2023) analisaram imagens de 6.378 ovos e relacionaram o índice de forma com características de qualidade interna e da casca; entre os modelos testados, o Random Forest alcançou acurácia de 97,9%. Yang et al. (2023) combinaram RTMDet e Random Forest para classificação de categorias, identificação de defeitos e estimativa de peso, obtendo acurácia máxima de 94,8% na classificação e R^2 de 0,96 para a regressão do peso. Em condição mais próxima do uso comercial, Wu et al. (2025) avaliaram um sistema de monitoramento com YOLOv8s modificado: o modelo apresentou precisão de 94,0%, recall de 92,8% e processamento de 91,7 quadros por segundo, enquanto o teste de campo em 60 gaiolas atingiu 98,9% de reconhecimento de ovos.

A utilidade da detecção de defeitos fica mais clara quando se consideram seus efeitos posteriores. Wengerska et al. (2023), ao acompanharem 1.800 ovos por 35 dias, observaram que defeitos da casca, inclusive trincas externas, influenciaram a gravidade específica, a perda de água, a permeabilidade da casca, a altura e o pH do albúmen e as características da gema. Esses achados ajudam a explicar por que a inspeção automatizada não deve ser vista apenas como recurso de classificação estética: identificar alterações com consistência pode ter implicações sobre a conservação, o descarte e o destino do produto.

O levantamento mostrou que a forma de expressar a capacidade varia conforme o nível de automação. Nos equipamentos manuais de múltiplas posições, foram identificadas capacidades nominais de 30 ou 120 ovos por ciclo, permitindo a inspeção simultânea de vários ovos. Nos sistemas

automáticos integrados à alimentação, classificação ou embalagem, a capacidade foi de aproximadamente 10.000 ovos por hora, enquanto nas linhas industriais variou de 30.600 a 180.000 ovos por hora. A operação dessas linhas exige fluxo contínuo, sincronização, manutenção adequada e volume suficiente para utilizar a capacidade instalada. Os valores correspondem às capacidades nominais informadas no material consultado, não ao rendimento efetivamente observado.

Capacidades expressas em ovos por ciclo e em ovos por hora não permitem comparação direta. O rendimento horário de um equipamento com 120 posições depende dos tempos de carregamento, inspeção, retirada dos ovos e organização do lote seguinte. Sistemas automáticos também podem operar abaixo da capacidade nominal quando outras etapas se tornam gargalos. Portanto, a capacidade nominal representa um limite de projeto ou referência comercial, e não uma garantia de produção efetiva.

Discussão

A digitalização da ovoscopia traz uma mudança que vai além da substituição da inspeção visual por uma câmera. A principal vantagem é transformar imagens em registros mensuráveis e recuperáveis. Quando a informação é associada a lote, classe ou decisão de descarte, torna-se possível acompanhar padrões, documentar não conformidades e alimentar sistemas de rastreabilidade. Wengerska et al. (2023) mostram que defeitos de casca influenciam características do ovo durante o armazenamento; Xuan e Zheng (2024), por sua vez, descrevem o impacto da translucidez sobre a aparência e a aceitação comercial. A utilidade prática, entretanto, depende de o dado ser obtido com estabilidade e em velocidade compatível com o processo.

Os resultados de Castro Júnior et al. (2025a, 2025b), Ferraz Júnior (2024), Oliveira-Boreli et al. (2023) e Liu et al. (2024) mostram que tecnologias ópticas podem estimar atributos bastante diferentes, mas também deixam claro que a qualidade do dado de entrada é determinante. Iluminação, fundo da imagem, posição do ovo, cor e espessura da casca e qualidade da segmentação influenciam a informação extraída. Em uma unidade comercial, essas fontes de variação podem ocorrer simultaneamente. Por isso, resultados obtidos em uma base específica não dispensam validação com lotes de origens diferentes e sob condições reais de operação.

Outro cuidado necessário é a comparação entre métricas. Um R^2 de 0,97 não significa, por si só, que um sistema possui 97% de acerto, assim como uma correlação elevada não informa diretamente o erro médio das estimativas. Acurácia é apropriada para tarefas de classificação; MAPE e RMSE descrevem erro de predição em escalas diferentes; R^2 expressa quanto da variação de uma variável é explicada pelo modelo. Misturar esses indicadores pode produzir uma impressão de superioridade que os resultados não sustentam. A escolha de um método deve considerar o atributo de interesse, a consequência de um erro de classificação e a tolerância operacional do processo.

Yang et al. (2024), ao revisarem aplicações de visão computacional na avicultura, destacam que a adoção prática depende de algoritmos, hardware, capacidade de processamento, condições ambientais e disponibilidade de dados adequadamente anotados. O estudo de Wu et al. (2025) acrescenta um ponto importante a essa discussão ao demonstrar desempenho elevado em teste de campo, e não apenas em imagens obtidas em bancada. Ainda assim, uma granja ou unidade classificadora apresenta variações de velocidade, poeira, vibração, reflexos, iluminação e diferenças entre lotes. A tecnologia precisa, portanto, ser analisada como um sistema completo, no qual aquisição da imagem, processamento, decisão e integração mecânica funcionem de forma coordenada.

O rendimento operacional é outro ponto em que a simples leitura da especificação pode levar a interpretações equivocadas. Em ovoscópios manuais ou multiposição, a velocidade depende do operador e do tempo necessário para posicionar e retirar os ovos. Em linhas automatizadas, o limite pode estar no acumulador, na lavagem, na classificação por peso, na embalagem ou na retirada de produtos não conformes. Uma linha de maior capacidade somente gera benefício quando existe volume suficiente para mantê-la em utilização e quando as etapas anteriores e posteriores não reduzem o fluxo. Assim, a comparação entre equipamentos deve considerar taxa de utilização e gargalos, e não somente o número nominal de ovos por hora.

A análise econômica segue a mesma lógica. Santos et al. (2017) verificaram, em um estudo de caso com dois aviários integrados, que a unidade automatizada apresentou produção e lucros maiores que a unidade manual. Esse estudo não avaliou ovoscopia digital isoladamente; portanto, seus resultados não podem ser transferidos diretamente para essa tecnologia. A contribuição está em mostrar que investimento e benefício precisam ser examinados em conjunto. No caso da ovoscopia, uma análise

consistente deveria incluir aquisição, instalação, manutenção, energia, depreciação, mão de obra, treinamento, tempo, contrapondo esses custos à redução de perdas, à menor dependência de inspeção subjetiva, ao aumento de velocidade, à possibilidade de rastreabilidade e ao valor dos erros evitados.

A escala modifica o peso relativo desses fatores. Em pequenas unidades, um ovoscópio simples pode atender ao objetivo de melhorar a observação sem exigir automação complexa. Nessa situação, a adoção se relaciona principalmente à qualidade e à padronização da inspeção, sem que os dados reunidos permitam estimar substituição de mão de obra ou retorno financeiro. Em escala intermediária, equipamentos com várias posições podem ampliar a quantidade de ovos avaliados em cada ciclo, mas a vantagem depende do tempo real de operação e do número de pessoas envolvidas. Em grandes unidades, a análise deve considerar a integração com classificação, aquisição automática de imagens, registro de dados e rastreabilidade. Nesse caso, o custo do módulo de ovoscopia deve ser analisado dentro da linha, pois o benefício pode resultar da combinação de várias funções.

Os estudos recentes também deixam lacunas relevantes. Ainda são necessários ensaios que comparem desempenho em diferentes cores de casca, velocidades de processamento e condições de iluminação, além de bases de imagens mais amplas e representativas. A relação entre translucidez e outras medidas de qualidade também merece investigação, pois os resultados disponíveis indicam utilidade do atributo sem sustentar sua substituição direta por medidas invasivas (Castro Júnior et al., 2025b). Para a análise econômica, continuam escassos estudos que apresentem, simultaneamente, custo de implantação, horas de uso, manutenção, consumo energético, mão de obra e perdas antes e depois da adoção. Sem esses dados, é possível discutir os fatores que tornam a tecnologia mais ou menos atraente, mas não estabelecer um *payback* aplicável a diferentes realidades produtivas.

Conclusão

A ovoscopia digital associada à visão computacional amplia as possibilidades da inspeção não destrutiva ao permitir mensuração, registro e classificação de características que, na avaliação convencional, dependem fortemente do operador ou exigem procedimentos destrutivos. A literatura recente documenta aplicações para morfometria, porosidade, trincas, translucidez, estimativa de componentes internos, classificação de qualidade, peso e detecção de defeitos. Há também evidência de funcionamento em ambiente de produção, embora o desempenho continue condicionado pela iluminação, pelas características da casca, pela qualidade das imagens, pela representatividade das bases de treinamento e pela integração do sistema.

O rendimento e a relação custo-benefício não podem ser definidos apenas pela capacidade nominal do equipamento ou pela acurácia de um algoritmo. Uma avaliação econômica consistente deve considerar os custos de aquisição, instalação, manutenção, consumo de energia, depreciação, mão de obra, treinamento, tempo de parada e integração com as demais etapas do processo. Esses custos devem ser comparados aos benefícios potenciais, como redução de perdas, menor dependência da inspeção subjetiva, ganhos de velocidade, possibilidade de rastreabilidade e valor dos erros evitados. A importância de cada fator varia conforme a escala, o fluxo e o grau de automação da unidade produtiva. Nas operações de maior volume, também deve ser considerada a integração da ovoscopia com a classificação dos ovos e o registro de dados. Estudos em condições comerciais, com avaliação econômica completa e acompanhamento das perdas antes e depois da implantação, ainda são necessários para quantificar esses benefícios com maior segurança.

Referências

ARAÚJO, W. A. G.; ALBINO, L. F. T. **Incubação comercial**. 1. ed. Viçosa, MG: Transworld Research Network, 2011. 171 p.

CASTRO JÚNIOR, S. L. de *et al.* Automated system for extraction of eggshell morphometric characteristics in chicken eggs. **Smart Agricultural Technology**, Amsterdam, v. 12, art. 101470, 2025a. DOI: 10.1016/j.atech.2025.101470. Disponível em: https://doi.org/10.1016/j.atech.2025.101470. Acesso em: 28 ago. 2026.

CASTRO JÚNIOR, S. L. de *et al.* Translucency of chicken eggs: proposal of an automated system for analysis and classification. **Poultry Science**, Cambridge, v. 104, n. 10, art. 105612, 2025b. DOI: 10.1016/j.psj.2025.105612. Disponível em: https://doi.org/10.1016/j.psj.2025.105612. Acesso em: 28 ago. 2026.

CHICCO, D.; WARRENS, M. J.; JURMAN, G. The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. **PeerJ Computer Science**, London, v. 7, e623, 2021. DOI: 10.7717/peerj-cs.623. Disponível em: https://doi.org/10.7717/peerj-cs.623. Acesso em: 28 ago. 2026.

FERRAZ JÚNIOR, A. **Desenvolvimento de um método automatizado para estimar a massa dos componentes dos ovos de galinha por meio de visão computacional e inteligência artificial**. 2024. 124 f. Dissertação (Mestrado em Ciências) – Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, 2024. DOI: 10.11606/D.74.2024.tde-24042025-100716. Disponível em: https://teses.usp.br/teses/disponiveis/74/74134/tde-24042025-100716/pt-br.html. Acesso em: 28 ago. 2026.

LIU, Y. F.; XIAO, D. Q.; NI, X.; LI, W. G. Estimating yolk weight of duck eggs using VIS-NIR spectroscopy and RGB images and whole egg weights. **Poultry Science**, Cambridge, v. 103, n. 7, art. 103829, 2024. DOI: 10.1016/j.psj.2024.103829. Disponível em: https://doi.org/10.1016/j.psj.2024.103829. Acesso em: 28 ago. 2026.

OLIVEIRA-BORELI, F. P. de *et al.* Non-destructive assessment of hens' eggs quality using image analysis and machine learning. **Smart Agricultural Technology**, Amsterdam, v. 4, art. 100161, 2023. DOI: 10.1016/j.atech.2022.100161. Disponível em: https://doi.org/10.1016/j.atech.2022.100161. Acesso em: 28 ago. 2026.

SANTOS, T. O. dos *et al.* Reflexos da tecnologia de automação nos resultados econômicos de aviários integrados a uma empresa do ramo avícola. In: CONGRESSO BRASILEIRO DE CUSTOS, 24., 2017, Florianópolis. **Anais [...]**. Florianópolis: Associação Brasileira de Custos, 2017. 15 p. Disponível em: https://anaiscbc.emnuvens.com.br/anais/article/view/4306. Acesso em: 28 ago. 2026.

SCHOBER, P.; MASCHA, E. J.; VETTER, T. R. Statistics from A (Agreement) to Z (z Score): a guide to interpreting common measures of association, agreement, diagnostic accuracy, effect size, heterogeneity, and reliability in medical research. **Anesthesia & Analgesia**, Philadelphia, v. 133, n. 6, p. 1633-1641, 2021. DOI: 10.1213/ANE.0000000000005773. Disponível em: https://doi.org/10.1213/ANE.0000000000005773. Acesso em: 28 ago. 2026.

SPIES, N. C.; NG, D. P. Performance metrics for machine learning solutions in laboratory medicine. **Laboratory Medicine**, Oxford, v. 56, n. 6, p. 597-607, 2025. DOI: 10.1093/labmed/lmaf013. Disponível em: https://doi.org/10.1093/labmed/lmaf013. Acesso em: 28 ago. 2026.

WENGERSKA, K.; BATKOWSKA, J.; DRABIK, K. The eggshell defect as a factor affecting the egg quality after storage. **Poultry Science**, Cambridge, v. 102, n. 7, art. 102749, 2023. DOI: 10.1016/j.psj.2023.102749. Disponível em: https://doi.org/10.1016/j.psj.2023.102749. Acesso em: 28 ago. 2026.

WU, Z.; ZHANG, H.; FANG, C. Research on machine vision online monitoring system for egg production and quality in cage environment. **Poultry Science**, Cambridge, v. 104, n. 1, art. 104552, 2025. DOI: 10.1016/j.psj.2024.104552. Disponível em: https://doi.org/10.1016/j.psj.2024.104552. Acesso em: 28 ago. 2026.

XUAN, L.; ZHENG, J. Translucent eggs of laying hens: a review. **Poultry Science**, Cambridge, v. 103, n. 9, art. 103983, 2024. DOI: 10.1016/j.psj.2024.103983. Disponível em: https://doi.org/10.1016/j.psj.2024.103983. Acesso em: 28 ago. 2026.

YANG, X.; BIST, R. B.; SUBEDI, S.; CHAI, L. A computer vision-based automatic system for egg grading and defect detection. **Animals**, Basel, v. 13, n. 14, art. 2354, 2023. DOI: 10.3390/ani13142354. Disponível em: https://doi.org/10.3390/ani13142354. Acesso em: 28 ago. 2026.

YANG, X. *et al.* Computer vision-based cybernetics systems for promoting modern poultry farming: a critical review. **Computers and Electronics in Agriculture**, Amsterdam, v. 225, art. 109339, 2024. DOI: 10.1016/j.compag.2024.109339. Disponível em: https://doi.org/10.1016/j.compag.2024.109339. Acesso em: 28 ago. 2026.