


ANÁLISE INTELIGENTE PARA APOIO À INSPEÇÃO VETERINÁRIA EM FRIGORÍFICOS BASEADA EM VISÃO COMPUTACIONAL

INTELLIGENT ANALYSIS TO SUPPORT VETERINARY INSPECTION IN MEAT PROCESSING PLANTS BASED ON COMPUTER VISION

ANÁLISIS INTELIGENTE PARA APOYAR LA INSPECCIÓN VETERINARIA EN PLANTAS PROCESADORAS DE CARNE BASADO EN VISIÓN ARTIFICIAL

Gabriel Smaniotto Araujo
Universidade do Estado de Mato Grosso - UNEMAT
e-mail: gabriel.smaniotto@unemat.br

Dra. Janecler Foppa
 <https://orcid.org/0000-0002-8906-4195>
Universidade do Estado de Mato Grosso - UNEMAT
e-mail: janecler.foppa.snp@gmail.com

Submissão em: 25/11/2025

Aceito em: 19/01/2026

RESUMO

O avanço das tecnologias de inteligência artificial e visão computacional tem revolucionado os processos de inspeção veterinária em frigoríficos, proporcionando maior precisão, eficiência e segurança alimentar. Este estudo teve como objetivo analisar a aplicação integrada de redes neurais convolucionais (CNNs), redes neurais recorrentes (RNNs) e *Vision Transformers* (ViTs) em sistemas inteligentes voltados à detecção de anomalias e controle de qualidade. A metodologia utilizada foi revisão integrativa, publicações entre 2021 e 2025, em bases científicas. Os resultados apontam que a combinação dessas arquiteturas potencializa a análise visual e preditiva, permitindo decisões automatizadas mais confiáveis e em tempo real. Conclui-se que a integração das redes neurais representa evolução significativa para modernização da inspeção alimentar, promovendo abordagem proativa, autônoma e baseada em dados. **Palavras-chave:** Controle de Qualidade, Inspeção Alimentar, Inteligência Artificial

ABSTRACT

The advancement of artificial intelligence and computer vision technologies has revolutionized veterinary inspection processes in meat processing plants, providing greater precision, efficiency, and food safety. This study aimed to analyze the integrated application of convolutional neural networks (CNNs), recurrent neural networks (RNNs), and Vision Transformers (ViTs) in intelligent systems focused on anomaly detection and quality control. The methodology used was an integrative review of publications between 2021 and 2025 in scientific databases. The results indicate that the combination of these architectures enhances visual and predictive analysis, allowing for more reliable and real-time automated decisions. It is concluded that the integration of neural networks represents a significant evolution for the

modernization of food inspection, promoting a proactive, autonomous, and data-driven approach.

Keywords: Quality Control, Food Inspection, Artificial Intelligence

RESUMEN

El avance de la inteligencia artificial y las tecnologías de visión artificial ha revolucionado los procesos de inspección veterinaria en las plantas procesadoras de carne, proporcionando mayor precisión, eficiencia y seguridad alimentaria. Este estudio tuvo como objetivo analizar la aplicación integrada de redes neuronales convolucionales (CNN), redes neuronales recurrentes (RNN) y *Vision Transformers* (ViT) en sistemas inteligentes enfocados en la detección de anomalías y el control de calidad. La metodología empleada fue una revisión integradora de publicaciones entre 2021 y 2025 en bases de datos científicas. Los resultados indican que la combinación de estas arquitecturas mejora el análisis visual y predictivo, permitiendo decisiones automatizadas más fiables y en tiempo real. Se concluye que la integración de redes neuronales representa una evolución significativa para la modernización de la inspección de alimentos, promoviendo un enfoque proactivo, autónomo y basado en datos.

Palabras clave: Control de Calidad, Inspección de Alimentos, Inteligencia Artificial

1 INTRODUÇÃO

O avanço da Inteligência Artificial (IA) e das técnicas de visão computacional tem impulsionado uma transformação profunda nos sistemas de controle de qualidade e inspeção de alimentos, especialmente no setor de produtos de origem animal.

A crescente demanda por processos mais rápidos, seguros e padronizados tem levado indústrias e centros de pesquisa a investir em soluções automatizadas capazes de substituir métodos tradicionais de inspeção visual, historicamente dependentes da experiência humana e sujeitos a falhas subjetivas (Ding *et al.*, 2025). Nesse contexto, a adoção de redes neurais profundas, como as Redes Neurais Convolucionais (CNNs) e as Redes Neurais Recorrentes (RNNs), surge como alternativa tecnológica de alto impacto, aliando precisão computacional, eficiência operacional e rastreabilidade contínua.

As CNNs destacam-se por sua capacidade de analisar imagens em múltiplas escalas, identificando padrões sutis de textura, cor e forma, o que as torna ideais para tarefas de detecção de contaminações, lesões e defeitos estruturais em carcaças (Black *et al.*, 2025; Ferri *et al.*, 2024). Em paralelo, as RNNs, especialmente em suas variações LSTM (Long Short-Term Memory) e GRU (Gated Recurrent Unit), têm se destacado pela habilidade de aprender relações temporais complexas, permitindo prever a ocorrência de contaminações, flutuações na qualidade e variações nos parâmetros ambientais que afetam a segurança alimentar (Du *et al.*, 2021; Geng *et al.*, 2023).

Mais recentemente, os *Vision Transformers* (ViTs) emergiram como uma nova geração de modelos voltados à atenção contextual e à análise global das imagens, superando as limitações das CNNs em determinadas tarefas (Saha; Basak; Demir, 2025; Wang *et al.*, 2025).

A integração entre essas três arquiteturas, CNNs, RNNs e ViTs, configura um ecossistema inteligente de aprendizado profundo, no qual a análise espacial, temporal

e contextual se complementam, resultando em sistemas de inspeção mais precisos, autônomos e explicáveis (Ding *et al.*, 2025; Jeong *et al.*, 2025). Além de detectar e prever irregularidades, esses modelos híbridos são capazes de gerar diagnósticos auditáveis, reforçando a confiabilidade das decisões automatizadas e contribuindo para a conformidade com normas sanitárias internacionais.

Assim, este estudo tem como objetivo analisar de forma integrada o papel das redes neurais convolucionais, recorrentes e dos *Vision Transformers* no desenvolvimento de sistemas inteligentes de inspeção veterinária em frigoríficos, com base em uma revisão integrativa da literatura publicada entre 2021 e 2025. A questão norteadora definida foi: Como as arquiteturas de redes neurais avançadas têm sido aplicadas em sistemas inteligentes de inspeção alimentar entre 2021 e 2025? Essa pergunta orientou todas as fases da coleta e análise dos dados científicos.

A proposta busca evidenciar os principais avanços tecnológicos, as limitações observadas e as tendências futuras que moldam a transformação digital do setor de inspeção alimentar, consolidando a IA como eixo estruturante da segurança alimentar moderna e da automação industrial inteligente.

2 FUNDAMENTOS DA INTELIGÊNCIA ARTIFICIAL NA SEGURANÇA ALIMENTAR

A IA tem se consolidado como um dos pilares tecnológicos mais relevantes para o aprimoramento da segurança alimentar, permitindo que processos de inspeção, controle de qualidade e rastreabilidade sejam realizados com precisão e rapidez inéditas. A aplicação de algoritmos inteligentes possibilita o monitoramento contínuo e automatizado da cadeia produtiva, desde o abate até o consumo, reduzindo falhas humanas e fortalecendo o controle sanitário (Ding *et al.*, 2025).

A incorporação de modelos de aprendizado profundo (Deep Learning) no setor alimentício tem permitido identificar contaminações, fraudes e desvios de qualidade com alta acurácia. Conforme Alvarez-García *et al.* (2024), a IA aplicada à mensuração da qualidade da carne em diferentes estágios da cadeia produtiva demonstra o potencial de padronizar avaliações sensoriais e físico-químicas, tradicionalmente dependentes de inspeções manuais.

A convergência entre IA e inspeção veterinária emerge como um marco no controle sanitário, especialmente em frigoríficos e abatedouros, onde a precisão e a velocidade das decisões são determinantes. Além de automatizar tarefas de inspeção, a IA tem a capacidade de aprender padrões complexos e generalizar soluções em diferentes contextos alimentares. Alzahrani (2023) destaca que os avanços em redes neurais profundas aplicadas à visão computacional demonstram que modelos previamente desenvolvidos para diagnósticos médicos, como na análise de lesões cutâneas, podem ser transferidos e adaptados para a detecção de anomalias em alimentos.

Estudos recentes, como o de Gao e Agarwal (2025), ressaltam que o desenvolvimento de sistemas de teste baseados em visão computacional requer modelagem precisa, validação contínua e otimização de parâmetros para lidar com dados de imagem em grande escala.

Ding *et al.* (2025) destacam que, quando combinadas, as redes convolucionais e recorrentes alcançam níveis superiores de desempenho, integrando análise visual e processamento temporal de dados para avaliar em tempo real o estado dos alimentos.

2.1 Arquitetura e funcionamento das redes neurais convolucionais (CNNs)

As CNNs representam um dos avanços mais significativos no campo da inteligência artificial aplicada à visão computacional. Inspiradas na estrutura do córtex visual humano, essas redes têm a capacidade de reconhecer padrões complexos em imagens, tornando-se ferramentas essenciais para a análise automatizada de qualidade e segurança alimentar. Segundo Ding *et al.* (2025), a CNN é composta por múltiplas camadas interconectadas que extraem, transformam e classificam informações visuais de forma hierárquica, permitindo que o sistema aprenda a distinguir entre elementos sutis, como defeitos de textura, variações de cor ou contaminações microscópicas.

O papel das CNNs na segurança alimentar tem sido amplamente explorado em estudos aplicados à detecção de contaminantes e defeitos em produtos de origem animal. Black *et al.* (2024) demonstraram, por meio de um sistema multiespectral, que a utilização de redes convolucionais permite identificar contaminações fecais invisíveis em carcaças de aves, garantindo maior precisão nas decisões de condenação durante o processo de abate. A integração de CNNs com sensores de fluorescência e câmeras hiperespectrais potencializa o reconhecimento de anomalias, uma vez que cada tipo de contaminação possui uma assinatura espectral específica.

Alvarez-García *et al.* (2024) destacam o uso dessas redes na avaliação da cor, marmoreio e textura da carne bovina, parâmetros cruciais para a classificação e valorização do produto. A CNN, nesse contexto, atua como um avaliador automatizado, substituindo julgamentos subjetivos por métricas quantitativas obtidas de forma padronizada.

A eficiência das CNNs também se deve ao processo de treinamento supervisionado, no qual grandes volumes de imagens rotuladas são utilizados para ajustar os pesos das conexões neuronais. Gao e Agarwal (2025) enfatizam que o desempenho dessas redes depende da qualidade dos dados e da calibragem dos hiperparâmetros, como tamanho do filtro, taxa de aprendizado e número de camadas.

2.2 Aplicações das redes neurais recorrentes (RNNS) e modelos derivados (LSTM e GRU)

As RNNs distinguem-se das arquiteturas convolucionais por sua capacidade de processar dados sequenciais, sendo fundamentais em tarefas que envolvem dependências temporais e previsão de eventos. Diferentemente das CNNs, que analisam estruturas espaciais fixas, as RNNs mantêm uma “memória” dos estados anteriores, permitindo interpretar o contexto e as variações ao longo do tempo. Conforme Ding *et al.* (2025), essa característica torna o modelo particularmente adequado para monitorar padrões dinâmicos na cadeia produtiva alimentar, como flutuações de temperatura, umidade e tempo de exposição de carcaças, parâmetros que influenciam diretamente a segurança dos alimentos.

O grande diferencial das RNNs está na recorrência entre suas camadas, o que lhes permite retroalimentar informações previamente processadas para gerar previsões mais precisas. Contudo, com o desaparecimento ou explosão de gradientes durante o treinamento prejudicam o aprendizado de longas dependências. Para superar essas limitações, surgiram os modelos derivados, *Long Short-Term Memory* (LSTM) e *Gated Recurrent Units* (GRU), que introduzem mecanismos de portas de controle para regular o fluxo de informações. Geng *et al.* (2023) demonstraram que uma rede

LSTM otimizada foi capaz de antecipar riscos de contaminação alimentar ao correlacionar variáveis ambientais e microbiológicas, alcançando maior acurácia em comparação com modelos lineares tradicionais.

As LSTM destacam-se por sua capacidade de capturar padrões complexos e retardados no tempo, o que é essencial em sistemas preditivos de segurança alimentar. Du *et al.* (2021) desenvolveram um modelo baseado em *multigraph structural LSTM* para prever surtos de doenças transmitidas por alimentos, utilizando dados históricos de vigilância epidemiológica e características ambientais.

A integração das RNNs com modelos de visão computacional amplia consideravelmente as possibilidades de análise em tempo real. Ding *et al.* (2025) enfatizam que, quando acopladas às CNNs, as redes recorrentes agregam contexto temporal à análise visual, permitindo que sistemas de inspeção reconheçam não apenas o estado atual, mas também a evolução de uma anomalia.

As GRU, por sua vez, apresentam estrutura mais simples e leve que as LSTM, mantendo desempenho semelhante com menor custo computacional. Gao e Agarwal (2025) observam que, em aplicações industriais de visão computacional, as GRU são especialmente vantajosas quando o tempo de resposta é crítico e os volumes de dados são elevados.

O uso combinado de RNNs com dados multiespectrais e variáveis ambientais tem impulsionado avanços significativos na previsão de riscos microbiológicos. Estudos como o de Black *et al.* (2025) indicam que modelos recorrentes podem aprender padrões de contaminação associados à presença de Salmonella e outras bactérias, correlacionando informações de imagem com séries temporais de temperatura e umidade.

2.3 Integração de CNNs, RNNs e *Vision Transformers* em sistemas inteligentes de inspeção

A convergência entre CNNs, RNNs e ViTs tem redefinido o paradigma da visão computacional aplicada à inspeção automatizada de alimentos. Essa integração busca unir a força analítica das CNNs na extração espacial de características, a capacidade temporal das RNNs em capturar padrões dinâmicos e a eficiência contextual dos ViTs em interpretar relações globais dentro das imagens.

Os sistemas híbridos CNN-RNN, amplamente utilizados na inspeção de produtos de origem animal, são capazes de correlacionar informações visuais com dados sequenciais oriundos de sensores industriais. Alvarez-García *et al.* (2024) destacam que, em frigoríficos e linhas de abate automatizadas, essas redes permitem não apenas a identificação de defeitos visuais, mas também a previsão de anomalias estruturais que se desenvolvem ao longo do processo produtivo. A CNN atua como o primeiro filtro de percepção, captando características espaciais relevantes, enquanto a RNN (em especial as variações LSTM e GRU) processa as sequências temporais, produzindo uma análise contínua e contextualizada da qualidade do produto.

A introdução dos *Vision Transformers* marca um avanço significativo nessa integração. Inspirados no mecanismo de atenção utilizado em modelos de linguagem natural, os ViTs são capazes de analisar uma imagem como uma sequência de “tokens”, atribuindo pesos distintos às regiões mais informativas. Lim *et al.* (2025) demonstram que, em aplicações como a classificação de carcaças bovinas, o uso de Transformers leves, como o EfficientViT, resulta em um aumento expressivo da

acurácia com menor consumo de energia computacional. Essa arquitetura supera limitações das CNNs tradicionais, especialmente em situações em que o contexto global é mais relevante do que os detalhes locais, como na avaliação simultânea de textura, cor e proporção anatômica.

O ponto mais promissor da integração entre CNNs, RNNs e ViTs reside na construção de sistemas de inspeção totalmente inteligentes e adaptativos. Geng *et al.* (2023) explicam que o uso combinado de CNNs para extração espacial e de LSTMs para análise temporal permite antecipar riscos microbiológicos antes mesmo de se manifestarem visualmente.

Ferri *et al.* (2024) verificaram que, ao aplicar CNNs e ViTs em conjunto para a detecção de lesões cutâneas em suínos, os modelos híbridos alcançaram maior consistência em avaliações automatizadas de bem-estar animal.

A integração entre CNNs, RNNs e ViTs também favorece o desenvolvimento de sistemas de inspeção contínua, nos quais imagens capturadas em sequência são processadas e analisadas em fluxo. Gao e Agarwal (2025) ressaltam que a combinação dessas arquiteturas, acopladas a modelos de teste automatizado, proporciona maior estabilidade operacional e reduz a necessidade de calibração humana.

3 METODOLOGIA

A presente pesquisa caracteriza-se como uma revisão integrativa da literatura, cuja finalidade foi reunir, analisar e sintetizar o conhecimento científico existente sobre a aplicação de redes neurais convolucionais (CNNs), redes neurais recorrentes (RNNs) e *Vision Transformers* em sistemas inteligentes de inspeção voltados à segurança alimentar e à análise automatizada em frigoríficos. A escolha pela revisão integrativa justifica-se pela amplitude metodológica que permite incluir estudos experimentais, revisões sistemáticas oferecendo visão abrangente e crítica sobre o estado atual da tecnologia na área de inspeção veterinária assistida por visão computacional.

As buscas foram realizadas entre agosto e outubro de 2025 nas principais bases de dados acadêmicas, *Scopus*, *Web of Science*, *PubMed*, *ScienceDirect*, *SpringerLink* e *IEEE Xplore*, além de repositórios institucionais, como *ProQuest Dissertations & Theses*, Universidade de *Liverpool Repository*, *University of Twente Repository* e *Auburn University ETD*. Foram utilizados descritores em português e inglês, combinados com operadores booleanos: (*deep learning OR neural networks*) AND (*computer vision OR vision transformers*) AND (*food safety OR meat inspection*). O recorte temporal compreendeu o período de 2021 a 2025, com o intuito de incluir apenas estudos recentes que refletissem os avanços tecnológicos contemporâneos em visão computacional aplicada à segurança alimentar.

Como critérios de inclusão, foram selecionados conteúdos que abordassem explicitamente o uso de CNNs, RNNs, LSTM, GRU ou *Vision Transformers* em aplicações relacionadas à inspeção, classificação, rastreamento ou controle de qualidade de produtos alimentícios. Foram excluídos trabalhos anteriores a 2021, revisões narrativas sem base empírica, estudos exclusivamente teóricos sobre redes neurais e publicações sem acesso completo ao texto. No total, 22 estudos atenderam aos critérios de inclusão.

A extração e análise dos dados foram conduzidas de forma manual e sistematizada. Inicialmente, cada estudo foi examinado quanto ao tipo de arquitetura

neural utilizada, ao objetivo principal da aplicação, ao contexto experimental (frigorífico, laboratório ou processamento industrial), às métricas de desempenho relatadas e às principais contribuições tecnológicas. As informações foram organizadas em um quadro-síntese comparativo, que possibilitou identificar padrões de recorrência, lacunas metodológicas e tendências emergentes.

No processo de análise, priorizou-se a leitura crítica e interpretativa, buscando não apenas descrever os resultados, mas compreender as relações entre os métodos empregados e os avanços obtidos. A metodologia empregada por Ding et al. (2025) e Geng et al. (2023) serviu como referência para avaliação de estudos experimentais de redes híbridas (CNN-RNNLSTM), Saha, Basak e Demir (2025) orientaram a análise dos modelos baseados em *Vision Transformers*. Esse cruzamento teórico e empírico garantiu maior rigor interpretativo e permitiu estabelecer um panorama técnico detalhado sobre a evolução das arquiteturas de inteligência artificial voltadas à inspeção alimentar.

Por fim, a síntese integrativa dos resultados foi organizada de modo a evidenciar os principais eixos temáticos emergentes da literatura: (a) evolução das CNNs na extração de padrões visuais complexos; (b) aplicações temporais de RNNs e derivados na previsão de contaminações; (c) adoção de *Vision Transformers* para atenção contextual e eficiência energética; e (d) integração de arquiteturas híbridas para inspeção preditiva em tempo real. Dessa forma, esta revisão integrativa busca não apenas mapear o estado da arte, mas também fornecer subsídios teóricos e metodológicos para o desenvolvimento de novos sistemas inteligentes de inspeção, contribuindo para o avanço da segurança alimentar e para a inovação tecnológica no setor agroindustrial.

4 RESULTADOS E DISCUSSÃO

A seguir, apresentam-se os resultados obtidos a partir da revisão integrativa conduzida entre 2021 e 2025, com o objetivo de mapear as principais pesquisas sobre o uso de CNNs, RNNs) e ViTs em sistemas inteligentes de inspeção alimentar e veterinária. Foram incluídos estudos experimentais, revisões e teses que abordam a automação da análise de qualidade, a detecção de contaminações e o monitoramento de carcaças em frigoríficos. Os trabalhos foram organizados no Quadro 1, a seguir.

Quadro 1 – Síntese dos estudos incluídos

Autor/Ano	Objetivo	Método	Resultado	Correlação com o estudo atual
Almjally; Almukadi (2025)	Desenvolver um sistema de reconhecimento de sinais baseado em visão computacional profunda.	CNNs e modelos híbridos com atenção visual.	Obteve acurácia acima de 98% em reconhecimento gestual, demonstrando robustez de CNNs combinadas com atenção visual.	Evidencia a aplicabilidade das CNNs em tarefas complexas de reconhecimento visual, reforçando seu potencial em inspeções alimentares automatizadas.
Alvarez-García et al. (2024)	Implementar IA para medir qualidade da carne em	Modelos de deep learning e visão multispectral.	Sistema automatizado de medição de marmoreio e	Demonstra a viabilidade de CNNs e sensores ópticos no controle de qualidade

	diferentes estágios da cadeia produtiva bovina.		textura com precisão superior à avaliação humana.	de produtos cárneos em frigoríficos.
Alzahrani (2023)	Aplicar IA e visão computacional na análise de lesões cutâneas.	CNNs e transfer learning em imagens médicas.	Modelo com sensibilidade de 95% na detecção de anomalias em pele.	Fornecer paralelo direto com a detecção de lesões e contaminações em carcaças animais.
Black (2024)	Detectar contaminações fecais e condenações em carcaças de aves por imagem multiespectral.	Aprendizado profundo e espectroscopia.	Sistema detectou contaminações invisíveis ao olho humano.	Fundamenta o uso de CNNs e sensores multiespectrais na inspeção veterinária automatizada.
Black <i>et al.</i> (2025)	Mitigar riscos de <i>Salmonella</i> por detecção automatizada de contaminações.	CNNs e machine learning em fluorescência multiespectral.	Redução de 35% em falsos negativos de detecção.	Corroborar o uso de IA para inspeções higiênicas-sanitárias em linhas de abate.
Ding <i>et al.</i> (2025)	Analisar a aplicação de CNNs e RNNs em segurança alimentar.	Revisão e experimentação com modelos híbridos CNNRNN.	Destacou alto desempenho na detecção e previsão de riscos alimentares.	Fornecer base teórica central para integração entre redes convolucionais e recorrentes.
Du <i>et al.</i> (2021)	Prever riscos de doenças alimentares por redes LSTM multiestruturais.	LSTM com múltiplos grafos estruturais.	Sistema preditivo com precisão de 93% em surtos simulados.	Sustenta o uso de redes recorrentes para antecipação de riscos em inspeções alimentares.
Ferri <i>et al.</i> (2024)	Detectar lesões dorsais e laterais em carcaças suínas.	CNNs aplicadas a imagens RGB e infravermelhas.	Detecção automatizada com precisão de 96%.	Reforça a eficiência das CNNs em análises visuais na inspeção de bem-estar animal.
Gao; Agarwal (2025)	Modelar testes automatizados em sistemas de visão computacional.	IA aplicada ao controle e validação de sistemas visuais.	Estruturas de teste automatizadas melhoraram a estabilidade operacional.	Aplica-se ao controle de qualidade dos modelos de inspeção inteligente.
Geng <i>et al.</i> (2023)	Desenvolver rede LSTM otimizada para análise de risco alimentar.	Modelo híbrido IAPSO-LSTM.	Obteve alta acurácia em previsão de contaminações alimentares.	Corroborar o potencial preditivo de RNNs e LSTM na segurança alimentar.
Gonçalves <i>et al.</i> (2021)	Segmentar imagens de carcaças com CNNs.	CNNs aplicadas à segmentação de imagens agrícolas.	Segmentação precisa das regiões de interesse.	Demonstra a aplicabilidade das CNNs na automação de inspeções industriais.

Gorji <i>et al.</i> (2022)	Identificar automaticamente contaminações fecais em carnes.	Deep learning e fluorescência óptica.	Acurácia de 97% na identificação de contaminações invisíveis.	Apoia o uso de visão computacional para detecção microbiológica.
Hassan <i>et al.</i> (2023)	Detecção de contaminações com interação segura entre máquina e ambiente.	CNNs com arquitetura de segurança contextual.	Melhor desempenho em ambientes dinâmicos de inspeção.	Contribui para sistemas inteligentes mais autônomos e seguros em frigoríficos.
Jamil, Ata; Lee (2023)	Revisar o uso de <i>Transformers</i> em visão computacional.	Estudo de arquitetura e desempenho dos ViTs.	Evidenciou eficiência e interpretabilidade superiores às CNNs em certas tarefas.	Fundamenta o uso dos <i>Vision Transformers</i> em inspeções com múltiplos parâmetros visuais.
Jeong <i>et al.</i> (2025)	Revisar aplicações de IA no processamento de carnes.	Revisão abrangente de IA em abate e qualidade carnea.	Relatou ganhos de eficiência e rastreabilidade.	Consolida a relevância da IA como ferramenta de transformação no setor frigorífico.
Lim <i>et al.</i> (2025)	Aplicar <i>Vision Transformers</i> leves na classificação de carcaças bovinas.	EfficientViT e aprendizado supervisionado.	Acurácia superior a 98% na classificação de grau de carne.	Sustenta a integração dos ViTs com CNNs para inspeções automatizadas.
Lund <i>et al.</i> (2025a)	Avaliar desempenho de sistemas de visão para contaminação em suínos.	Modelagem de classes latentes e CNNs.	Acurácia de 94% em detecção de resíduos.	Confirma a confiabilidade de IA para inspeção veterinária automatizada.
Lund <i>et al.</i> (2025b)	Comparar modelos visuais para detecção de pleurisia em suínos.	CNNs e análise comparativa de arquiteturas.	CNN ResNet obteve melhor desempenho entre modelos.	Indica a importância da seleção arquitetônica para otimizar inspeções.
Saha, Basak; Demir (2025)	Avaliar <i>Vision Transformers</i> em dispositivos embarcados.	Revisão e análise experimental de ViTs.	Desempenho otimizado em ambientes de borda.	Mostra a viabilidade de inspeção inteligente em tempo real.
Sun <i>et al.</i> (2025)	Modelar percepção visual humana por aprendizado de máquina.	Machine learning em neurovisão.	Modelos reproduziram padrões humanos de detecção visual.	Fornecer base teórica sobre percepção automatizada aplicada à visão computacional.
Waelen (2023)	Analisar o potencial e os riscos da visão computacional.	Revisão teórica e casos práticos.	Identificou limitações éticas e interpretativas dos sistemas de visão.	Adverte sobre a importância da ética e validação nos sistemas de inspeção automatizada.

Wang <i>et al.</i> (2025)	Comparar desempenho de ViTs para classificação de imagens.	Estudo comparativo entre ViTs e CNNs.	ViTs superaram CNNs em datasets complexos.	Reforça a tendência de substituição ou hibridização entre ViTs e CNNs.
---------------------------	--	---------------------------------------	--	--

Fonte: Elaborado pelo autor, 2025.

Eixo 1 – Desempenho e aplicabilidade das CNNs

Os estudos de Ding *et al.* (2025), Alvarez-García *et al.* (2024) e Ferri *et al.* (2024) apontam as redes neurais convolucionais como o alicerce dos sistemas de visão computacional aplicados à segurança alimentar. O desempenho superior das CNNs deve-se à sua capacidade de extrair padrões visuais complexos e invariantes, permitindo identificar texturas, cores e anomalias em produtos de origem animal com precisão acima de 95%. Em ambientes industriais, essa robustez operacional é essencial para garantir o controle sanitário e a rastreabilidade. No entanto, estudos como o de Hassan *et al.* (2023) destacam que o desempenho das CNNs depende fortemente da qualidade dos dados e da calibração dos sensores ópticos, indicando a necessidade de integração com outras arquiteturas para maximizar resultados.

Eixo 2 – Papel preditivo das RNNs e seus derivados (LSTM e GRU)

A contribuição das redes neurais recorrentes está na capacidade de modelar relações temporais, algo indispensável em sistemas que monitoram continuamente o ciclo produtivo alimentar. Geng *et al.* (2023) e Du *et al.* (2021) evidenciam que modelos LSTM e GRU conseguem prever com antecedência a ocorrência de contaminações e desvios microbiológicos, antecipando riscos e reduzindo perdas. Esses modelos funcionam como “memórias inteligentes”, capazes de associar dados históricos de temperatura, umidade e tempo de armazenamento a padrões de deterioração. A análise desses estudos demonstra que as RNNs, embora mais complexas computacionalmente, ampliam o papel da IA de ferramenta de detecção para agente preditivo e preventivo no contexto da segurança alimentar.

Eixo 3 – Ascensão dos Vision Transformers na atenção contextual

A literatura recente, especialmente os trabalhos de Lim *et al.* (2025), Saha, Basak e Demir (2025) e Wang *et al.* (2025), demonstra que os ViTs representam uma transição paradigmática na visão computacional. Diferentemente das CNNs, que processam imagens de forma localizada, os ViTs utilizam mecanismos de atenção que permitem compreender a imagem como um todo, identificando relações globais entre suas partes. Isso se mostra particularmente relevante em inspeções complexas, nas quais as variações de cor, textura e forma precisam ser avaliadas de forma integrada. Em estudos comparativos, os ViTs apresentaram melhor desempenho em tarefas de classificação global de carcaças e inspeção simultânea de múltiplos parâmetros, superando CNNs em precisão e capacidade interpretativa.

Eixo 4 – Integração híbrida e potencial de inovação na inspeção automatizada

A convergência entre CNNs, RNNs e ViTs marca uma nova geração de sistemas inteligentes de inspeção, capazes de integrar análise espacial, temporal e contextual. Ding *et al.* (2025) e Jeong *et al.* (2025) destacam que os modelos híbridos obtêm resultados significativamente mais precisos ao combinar as forças de cada arquitetura, a CNN na extração de características visuais, a RNN na compreensão temporal e o *Transformer* na priorização de informações relevantes. Essa integração resulta em sistemas autônomos que não apenas detectam contaminações, mas também explicam suas decisões, reforçando a transparência e a confiabilidade dos processos de inspeção veterinária.

4.1 Desempenho e aplicabilidade das redes neurais convolucionais (CNNs)

A literatura revisada demonstra que as CNNs são amplamente empregadas na detecção visual de anomalias, contaminações e padrões de qualidade em produtos cárneos, consolidando-se como a base estrutural da visão computacional aplicada à segurança alimentar. Essa predominância decorre de sua capacidade de aprender representações espaciais complexas e generalizáveis, permitindo um alto nível de precisão em ambientes industriais automatizados.

Ding *et al.* (2025) destacam que as CNNs, quando associadas a outras arquiteturas, como RNNs e *Vision Transformers*, alcançam níveis de desempenho superiores em tarefas de inspeção automatizada. Alvarez-García *et al.* (2024) reforçam essa evidência ao demonstrarem que modelos convolucionais, combinados a sensores multiespectrais, conseguem medir o marmoreio e a textura da carne com precisão superior à avaliação humana.

Em consonância, Ferri *et al.* (2024) aplicaram CNNs para identificar lesões cutâneas em suínos, atingindo índices de acurácia de 96%, o que demonstra a robustez e aplicabilidade dessa arquitetura na inspeção de bem-estar animal. Já Black *et al.* (2025) comprovaram que o uso de CNNs acopladas a sistemas de fluorescência multiespectral reduziu significativamente os falsos negativos na detecção de contaminações por *Salmonella*, validando seu uso em ambientes críticos de controle sanitário.

A seguir, apresenta-se o Quadro 2, que sintetiza as principais diferenças funcionais e operacionais entre redes neurais convolucionais (CNNs) e redes neurais recorrentes (RNNs), evidenciando como cada uma contribui, de forma complementar, para o avanço dos sistemas inteligentes de inspeção e segurança alimentar.

Quadro 2 – Comparativo entre CNNs e RNNs

Aspecto	Redes Neurais Convolucionais (CNNs)	Redes Neurais Recorrentes (RNNs / LSTM / GRU)
Tipo de dado	Imagens e informações espaciais (2D/3D).	Séries temporais e dados sequenciais.
Função principal	Extração de padrões visuais e classificação de imagens.	Modelagem temporal e previsão de eventos em sequência.
Vantagens	Alta precisão espacial, eficiência em reconhecimento visual e baixo custo de processamento.	Capacidade de aprender dependências temporais e prever comportamentos futuros.
Limitações	Dificuldade em capturar relações temporais e variações contextuais.	Maior complexidade computacional e risco de sobreajuste.

Principais aplicações	Deteção de contaminações, lesões, marmoreio e defeitos em carcaças (BLACK et al., 2025; FERRI et al., 2024).	Previsão de surtos, rastreamento de risco e análise de padrões temporais (Du et al., 2021; Geng et al., 2023).
Desempenho médio	Acurácia entre 94% e 98% em inspeções visuais (DING et al., 2025).	Precisão entre 90% e 96% em análises preditivas (DU et al., 2021).
Correlação com o estudo atual	Base técnica da análise visual e da automação de inspeções veterinárias.	Complemento preditivo e analítico para a deteção antecipada de anomalias.

Fonte: Elaborado pelo autor, 2025.

De modo geral, os estudos convergem ao demonstrar que as CNNs constituem o núcleo das operações de visão computacional em frigoríficos e sistemas de inspeção automatizados, enquanto as RNNs, especialmente em suas versões LSTM e GRU, atuam como camadas preditivas, conferindo memória, contexto temporal e capacidade de antecipação. Assim, o desempenho e a aplicabilidade das CNNs, embora amplamente comprovados, alcançam seu potencial máximo quando integrados a arquiteturas recorrentes e mecanismos de atenção contextual, configurando uma abordagem híbrida mais eficaz para a segurança alimentar contemporânea.

5 CONCLUSÃO

A análise desenvolvida ao longo deste estudo evidencia que a aplicação de redes neurais profundas representa um marco na modernização dos sistemas de inspeção veterinária e controle de qualidade em frigoríficos. As CNNs mostraram-se fundamentais na identificação visual de anomalias, contaminações e padrões de qualidade, demonstrando grande eficiência em ambientes de produção em larga escala. Paralelamente, as RNNs, em especial suas variações LSTM e GRU, ampliam o alcance analítico ao possibilitar a modelagem de comportamentos temporais, oferecendo previsões sobre riscos e variações de qualidade ao longo das cadeias produtivas.

A integração entre CNNs, RNNs e ViTs emerge como uma estratégia promissora para a criação de sistemas inteligentes mais robustos e autônomos, capazes de combinar análise espacial, temporal e contextual em tempo real. Essa convergência tecnológica permite que a inspeção de alimentos deixe de ser apenas um processo de deteção reativa, passando a constituir um sistema proativo de prevenção e rastreabilidade, alinhado às exigências contemporâneas de segurança alimentar e sustentabilidade industrial.

Os resultados também revelam que, embora a implementação dessas tecnologias ainda enfrente desafios relacionados à calibração de sensores, à padronização de bases de dados e ao custo computacional, os ganhos em precisão, eficiência e confiabilidade superam significativamente as limitações dos métodos tradicionais. Dessa forma, conclui-se que a utilização combinada das arquiteturas neurais estudadas constitui uma base sólida para o desenvolvimento de sistemas inteligentes de inspeção veterinária, capazes de transformar a gestão da segurança alimentar e consolidar um novo paradigma de automação industrial orientada por dados e aprendizado profundo.

REFERÊNCIAS

ALMJALLY, A.; ALMUKADI, W. S. Deep computer vision with artificial intelligence based sign language recognition to assist hearing and speech-impaired individuals. **Scientific Reports**, v. 15, p. 32268, 2025. Disponível em: <https://doi.org/10.1038/s41598-025-09106-8>. Acesso em: 17 out. 2025.

ALVAREZ-GARCÍA, J.; LI, J.; WANG, Y.; et al. Implementing AI to measure meat quality at multiple stages of the beef value chain. **International Journal of Food Science & Technology**, v. 59, n. 7, p. 4393-4402, 2024. Disponível em: <https://doi.org/10.1111/ijfs.17205>. Acesso em: 17 out. 2025.

ALZHRANI, S. A. **Artificial intelligence for skin lesion analysis based on computer vision and deep learning**. 2023. Tese (Doutorado), University of Liverpool. Disponível em: https://livrepository.liverpool.ac.uk/3168503/1/201338546_Feb2023.pdf. Acesso em: 17 out. 2025.

BLACK, M. T. **Application of Multispectral Imaging for Identification of Poultry Carcass Condemnations and Fecal Contamination**. 2024. Thesis (Doctoral Program in Engineering), Auburn University, Auburn, AL. Disponível em: <https://etd.auburn.edu/bitstream/handle/10415/9291/Full%20Thesis.pdf>. Acesso em: 17 out. 2025.

BLACK, M. T.; XUE, F.; WANG, J.; et al. Detection of visible and invisible fecal contamination on chicken carcasses using multispectral fluorescence imaging and machine learning to mitigate Salmonella risks. **Journal of Food Protection**, v. 88, n.10, p.100613, 2025. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/40912660/>. Acesso em: 17 out. 2025.

DING, H.; HOU, H.; WANG, L.; CUI, X.; YU, W.; WILSON, D. I. Application of Convolutional Neural Networks and Recurrent Neural Networks in Food Safety. **Foods**, v. 14, n. 2, art. 247. 2025. Disponível em: <https://www.mdpi.com/2304-8158/14/2/247>. Acesso em: 17 out. 2025.

DU, Y.; WANG, H.; CUI, W.; ZHU, H.; GUO, Y.; DHAREJO, F. A.; ZHOU, Y. Foodborne disease risk prediction using multigraph structural long short-term memory networks: algorithm design and validation study. **JMIR Medical Informatics**, v. 9, n. 8, e29433, 2021. Disponível em: <https://medinform.jmir.org/2021/8/e29433/>. Acesso em: 17 out. 2025.

FERRI, F.; FERRARI, E.; MONTI, M.; et al. Automated detection and imaging of dorsal and lateral skin lesions for welfare assessment in pig carcasses at slaughter. **Computers and Electronics in Agriculture**, 2024. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0168169924004496>. Acesso em: 17 out. 2025.

GAO, J.; AGARWAL, R. AI Test Modeling for Computer Vision System—A Case Study. **Computers**, v. 14, n. 9, art. 396, 2025. Disponível em: <https://www.mdpi.com/2073-431X/14/9/396>. Acesso em: 17 out. 2025.

GENG, Z.; WANG, X.; JIANG, Y.; HAN, Y.; MA, B.; CHU, C. Novel IAPSO-LSTM neural network for risk analysis and early warning of food safety. **Expert Systems with Applications**, v. 230, art. 120747, 2023. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0957417423012496>. Acesso em: 17 out. 2025.

GONÇALVES, D. N.; WEBER, V. A. M.; PISTORI, J. G. B.; et al. Carcass image segmentation using CNN-based methods. **Information Processing in Agriculture**, v. 8, n. 4, p. 603-612, 2021. Disponível em: <https://dx.doi.org/10.1016/j.inpa.2020.11.004>. Acesso em: 17 out. 2025.

GORJI, H. T.; SHAHABI, S. M.; SHARMA, A.; et al. Combining deep learning and fluorescence imaging to automatically identify fecal contamination on meat carcasses. **Scientific Reports**, v. 12, p. 2392, 2022. Disponível em: <https://www.nature.com/articles/s41598022-06379-1>. Acesso em: 17 out. 2025.

HASSAN, S. A.; KHALIL, M. A.; AULETTA, F.; FILOSA, M.; CAMBONI, D.; MENCIASSI, A.; ODDO, C. M. Contamination Detection Using a Deep Convolutional Neural Network with Safe Machine—Environment Interaction. **Electronics**, v. 12, n. 20, p. 4260, 2023. Disponível em: <https://www.mdpi.com/2079-9292/12/20/4260>. Acesso em: 17 out. 2025.

JAMIL, S.; ATA, R. U.; LEE, Y.-D. A Comprehensive Survey of Transformers for Computer Vision. **Drones**, v. 7, n. 5, 287, 2023. Disponível em: <https://www.mdpi.com/2504-446X/7/5/287>. Acesso em: 17 out. 2025.

JEONG, K.; et al. Artificial Intelligence in Meat Processing: A comprehensive review of datadriven applications and future directions. **Meat and Muscle Biology**, v. 9, n.1, p. 20157, 2025. Disponível em: <https://www.iastatedigitalpress.com/mmb/article/id/20157/>. Acesso em: 17 out. 2025.

LIM, H.; LEE, S.; KIM, J.; et al. Beef carcass grading with EfficientViT: a lightweight vision transformer approach. **Applied Sciences**, v.15, n.11, p.6302. 2025. Disponível em: <https://www.mdpi.com/2076-3417/15/11/6302>. Acesso em: 17 out. 2025.

LUND, D. H.; DAMM, B. I.; KJELDSSEN, A. M.; et al. Using latent class modelling to evaluate the performance of a computer vision system for pig carcass contamination. **Preventive Veterinary Medicine**, v.246, p.106670. 2025. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/40359587/>. Acesso em: 17 out. 2025.

LUND, D. H.; DAMM, B. I.; KJELDSSEN, A. M.; et al. Comparing computer vision models for detecting chronic pleurisy in pigs. **Preventive Veterinary Medicine**,

v.246, p. 106701, 2025. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/41056660/>. Acesso em: 17 out. 2025.

SAHA, S.; BASAK, S.; DEMIR, B. Vision transformers on the edge: a comprehensive survey. **Neurocomputing**, v. 643, p. 130417, 2025. Disponível em: <https://doi.org/10.1016/j.neucom.2025.130417>. Acesso em: 17 out. 2025.

SUN, Z.; et al. Machine learning modelling of human visual motion perception. **Nature Machine Intelligence**, v. 7, p.1037-1052, 2025. Disponível em: <https://doi.org/10.1038/s42256-025-01068-w>. Acesso em: 17 out. 2025.

WAELEN, R. **The power of computer vision – Promise, potential and peril. 2023.** Thesis (Doctor of Philosophy), University of Twente. Disponível em: <https://research.utwente.nl/en/publications/the-power-of-computer-vision-a-critical-analysis/>. Acesso em: 17 out. 2025.

WANG, Y.; DENG, Y.; ZHENG, Y.; CHATTOPADHYAY, P.; WANG, L. Vision Transformers for Image Classification: A Comparative Survey. **Technologies**, v. 13, n. 1, p. 32, 2025. Disponível em: <https://doi.org/10.3390/technologies13010032>. Acesso em: 17 out. 2025.