

VEÍCULOS AÉREOS NÃO TRIPULADOS, PROCESSAMENTO DE IMAGENS E INTELIGÊNCIA ARTIFICIAL NA INSPEÇÃO DE ESTRUTURAS PORTUÁRIAS: REVISÃO DE APLICAÇÕES, LIMITAÇÕES E OPORTUNIDADES

Rafaela de Jesus Gomes¹, José Renato de Oliveira Lima¹

¹Universidade Federal do Maranhão, São Luís - MA, Brasil,
rafaela.jesus@discente.ufma.br.

Resumo: As inspeções em estruturas portuárias enfrentam desafios relacionados ao acesso, à segurança e à identificação de anomalias. Esta compilação do contexto tecnológico do tema analisa a aplicação de veículos aéreos não tripulados (VANTs), processamento digital de imagens e Inteligência Artificial nas inspeções estruturais. Os estudos evidenciam ganhos em eficiência, precisão, segurança e suporte à manutenção preditiva e ao gerenciamento de ativos portuários.

Palavras-chave: Veículos aéreos não tripulados; Estruturas portuárias; Processamento de imagens; Inteligência Artificial; Inspeção estrutural.

1. INTRODUÇÃO

As estruturas portuárias desempenham papel fundamental na logística, no comércio internacional e no desenvolvimento econômico, sendo essenciais para a movimentação de cargas e a integração dos diferentes modais de transporte. A continuidade das operações depende da integridade de ativos como cais, píeres, silos, armazéns, guindastes e demais estruturas de apoio, que requerem monitoramento sistemático ao longo de sua vida útil (Allende-Prieto et al., 2025; Belmoukari; Audy; Forget, 2023).

Por estarem inseridas em ambientes costeiros e marítimos, essas estruturas permanecem expostas à umidade, à salinidade, aos íons cloreto e às variações térmicas, condições que aceleram processos de degradação, especialmente a corrosão, comprometendo a durabilidade, a segurança e o desempenho operacional das instalações (Tsaïmou et al., 2024; Alharbi et al., 2026).

Nesse contexto, as inspeções periódicas são indispensáveis para identificar precocemente manifestações patológicas e subsidiar o planejamento da manutenção. Entretanto, os métodos convencionais ainda apresentam limitações relacionadas ao tempo de execução, aos custos operacionais, às dificuldades de acesso e à exposição dos profissionais a ambientes potencialmente perigosos, sobretudo em estruturas de grande porte ou localizadas sobre a água (Duque; Seo; Wacker, 2018; Aljuaid et al., 2024; Lima et al., 2026).

Nos últimos anos, a aplicação de veículos aéreos não tripulados (VANTs), associada ao processamento digital de imagens e à Inteligência Artificial, tem ampliado as possibilidades de inspeção e


monitoramento estrutural. A integração dessas tecnologias permite obter imagens de alta resolução, automatizar a identificação de anomalias e gerar informações que apoiam estratégias de manutenção preventiva e preditiva, contribuindo para inspeções mais seguras, rápidas e precisas (Jofré-Briceño et al., 2021; Ali et al., 2023; Oyedjeji; Khan; Erkoyuncu, 2024; Alharbi et al., 2026).

Dessa forma, este trabalho tem como objetivo realizar uma revisão bibliográfica sobre a aplicação de veículos aéreos não tripulados (VANTs), do processamento digital de imagens e da Inteligência Artificial na inspeção de estruturas portuárias, com ênfase em silos, armazéns, esteiras transportadoras e demais ativos operacionais. Além de reunir os principais avanços descritos na literatura, busca-se discutir as potencialidades, as limitações e as perspectivas dessas tecnologias para o monitoramento da infraestrutura portuária e o apoio à manutenção baseada na condição dos ativos.

2. MATERIAL E MÉTODOS

Este trabalho caracteriza-se como uma revisão bibliográfica de natureza qualitativa e caráter exploratório, desenvolvida com o objetivo de analisar a aplicação de veículos aéreos não tripulados (VANTs), do processamento digital de imagens e da Inteligência Artificial na inspeção de estruturas portuárias. A abordagem qualitativa foi adotada por permitir a análise crítica e a integração do conhecimento científico disponível sobre o tema.

O levantamento bibliográfico foi realizado por meio de consultas a bases de dados, plataformas e mecanismos de busca científicos, incluindo Scopus,



Web of Science, ScienceDirect, Google Scholar e MDPI. As buscas foram conduzidas utilizando descritores em português e inglês, como port infrastructure, drone inspection, unmanned aerial vehicles (UAVs), computer vision, image processing, artificial intelligence, deep learning, corrosion detection e smart ports.

Foram considerados artigos científicos revisados por pares, artigos de revisão e documentos técnicos relacionados à inspeção de estruturas portuárias, ao emprego de VANTs, ao processamento digital de imagens e à Inteligência Artificial. Foram excluídas publicações sem relação direta com o tema ou que não apresentassem fundamentação técnico-científica compatível com os objetivos desta pesquisa.

Os estudos selecionados foram analisados de forma comparativa e organizados em seis eixos temáticos: (i) infraestrutura portuária e desafios das inspeções; (ii) aplicação de VANTs na inspeção de estruturas portuárias; (iii) processamento digital de imagens; (iv) Inteligência Artificial aplicada às inspeções; (v) benefícios para a manutenção e operação portuária; e (vi) limitações e perspectivas futuras. Essa organização orientou a discussão dos resultados, permitindo comparar as diferentes tecnologias empregadas, suas aplicações, vantagens, limitações e perspectivas para o monitoramento da infraestrutura portuária.

3. RESULTADOS E DISCUSSÃO

A revisão da literatura evidenciou que a aplicação de veículos aéreos não tripulados (VANTs), processamento digital de imagens e Inteligência Artificial tem se concentrado principalmente na inspeção de ativos como cais, píeres, silos, armazéns, guindastes e pátios de contêineres. Entre os estudos analisados, apenas parte foi desenvolvida especificamente em ambientes portuários, enquanto diversos trabalhos adaptam metodologias originalmente propostas para outras infraestruturas, como pontes, tubulações, edificações e instalações industriais, indicando o potencial de transferência dessas tecnologias para o contexto portuário.

Quanto às plataformas de inspeção, predominam drones equipados com câmeras RGB, complementados, em alguns casos, por sensores térmicos, LiDAR, sistemas hiperespectrais e técnicas de fotogrametria para geração de modelos tridimensionais. As principais aplicações concentram-se na identificação de corrosão, fissuras, deformações e outros defeitos superficiais, utilizando desde técnicas clássicas de processamento digital de imagens até algoritmos de aprendizado de máquina e aprendizado profundo.

Em relação aos métodos computacionais, observa-se que o processamento digital de imagens é empregado principalmente para aquisição, pré-processamento, segmentação e extração de características, enquanto

os modelos de Inteligência Artificial são utilizados para classificação, detecção, localização e segmentação automática das anomalias. Entre as arquiteturas mais recorrentes destacam-se redes neurais convolucionais (CNNs), modelos da família YOLO, EfficientNet, técnicas de Transfer Learning e algoritmos específicos para reconhecimento de padrões.

De forma geral, os trabalhos relatam ganhos na rapidez das inspeções, redução da exposição dos profissionais a ambientes de risco e maior disponibilidade de informações para o planejamento da manutenção. Entretanto, permanecem desafios relacionados às condições de iluminação, sombras, reflexos, variabilidade das superfícies inspecionadas, limitações das bases de dados utilizadas no treinamento dos modelos e à necessidade de validação das soluções em operações portuárias reais. A partir dessa síntese, os resultados são discutidos nas seções seguintes, organizadas conforme os principais eixos temáticos identificados na revisão bibliográfica.

3.1 Infraestrutura portuária e desafios das inspeções

Os estudos revisados mostram que a infraestrutura portuária reúne ativos como cais, píeres, silos, armazéns, esteiras transportadoras e guindastes, cuja integridade é indispensável para a continuidade das operações logísticas. A exposição contínua à umidade, à salinidade, aos íons cloreto e às variações térmicas favorece mecanismos de degradação, como corrosão, fissuras, delaminações e perda de material, comprometendo a durabilidade, a segurança e o desempenho operacional dessas instalações (Allende-Prieto et al., 2025; Tsaimou et al., 2024).

Outro aspecto recorrente na literatura refere-se às dificuldades associadas às inspeções convencionais. A grande extensão das áreas portuárias, a diversidade dos ativos e as limitações de acesso tornam essas atividades mais demoradas e onerosas, exigindo frequentemente andaimes, plataformas elevatórias, embarcações ou técnicas de acesso por cordas, além de aumentar a exposição das equipes a condições potencialmente perigosas (Tsaimou et al., 2024; Aljuaid et al., 2024).

Os trabalhos também convergem ao destacar que a identificação precoce das manifestações patológicas é determinante para o planejamento da manutenção, pois permite reduzir custos de intervenção, minimizar interrupções operacionais e prolongar a vida útil dos ativos. Nesse contexto, a evolução dos smart ports tem impulsionado a incorporação de soluções digitais voltadas ao monitoramento estrutural e ao gerenciamento da infraestrutura, favorecendo decisões baseadas em dados (Belmoukari; Audy; Forget, 2023).

Diante desse cenário, os VANTs, aliados ao processamento digital de imagens e à Inteligência Artificial, surgem como uma alternativa capaz de superar parte das limitações dos métodos tradicionais. A combinação dessas tecnologias amplia a rapidez e a segurança das inspeções, além de fornecer informações mais precisas para o acompanhamento das condições estruturais e o planejamento das intervenções de manutenção.

3.2 Aplicação de drones na inspeção de estruturas portuárias

A adoção de veículos aéreos não tripulados (VANTs) têm transformado as inspeções em estruturas portuárias, sobretudo em locais de difícil acesso ou que oferecem maior risco às equipes de campo. Em comparação com os métodos convencionais, o uso de drones reduz a necessidade de andaimes, plataformas elevatórias, embarcações e técnicas de acesso por cordas, aumentando a segurança das atividades e reduzindo o tempo necessário para sua execução (Duque; Seo; Wacker, 2018; Jofré-Briceño et al., 2021).

Os trabalhos revisados demonstram que essa tecnologia pode ser aplicada na avaliação de cais, píeres, silos, armazéns, guindastes, coberturas e esteiras transportadoras. A elevada mobilidade das aeronaves possibilita ampliar a cobertura das inspeções, registrar imagens sob diferentes ângulos e acompanhar a evolução das condições estruturais ao longo do tempo (Jofré-Briceño et al., 2021; Tsaïmou et al., 2024).

As principais aplicações dos VANTs nas inspeções de estruturas portuárias são sintetizadas na Figura 1, que reúne os diferentes ativos inspecionados e as principais finalidades descritas na literatura.




Figura 1. Principais aplicações de drones na inspeção de estruturas portuárias.

Fonte: Elaborado pelos autores, com base em Jofré-Briceño et al. (2021), Duque, Seo e Wacker (2018), Alharbi et al. (2026) e Lima et al. (2026).

Além do registro visual, os VANTs permitem gerar ortofotos, modelos tridimensionais e registros digitais que podem ser integrados a plataformas de gerenciamento de ativos, contribuindo para o planejamento das inspeções e das intervenções de manutenção (Jofré-Briceño et al., 2021; Tsaïmou et al., 2024).

Outro ponto destacado na literatura refere-se ao planejamento das missões de voo. Parâmetros como trajetória, altitude, sobreposição das imagens e condições meteorológicas influenciam diretamente a confiabilidade dos levantamentos, especialmente em ambientes portuários, caracterizados pela presença de obstáculos e intenso fluxo operacional (Jofré-Briceño et al., 2021; Zhang et al., 2024). Nesse contexto, a integração de câmeras de alta resolução, receptores GNSS/GPS, sensores LiDAR e sistemas SLAM tem ampliado a precisão da navegação e a qualidade dos dados coletados (Zhang et al., 2024).

Em conjunto, as pesquisas indicam que o emprego de VANTs reduz o tempo de execução das inspeções, diminui custos operacionais e minimiza a exposição dos profissionais a ambientes potencialmente perigosos, favorecendo inspeções mais frequentes e o acompanhamento contínuo das condições dos ativos (Alharbi et al., 2026; Duque; Seo; Wacker, 2018; Edeh et al., 2021; Lima et al., 2026). Entretanto, a obtenção das imagens representa apenas a primeira etapa do processo, sendo necessária sua interpretação por meio de técnicas de processamento digital para identificar e caracterizar automaticamente as manifestações patológicas.

3.3 Processamento de imagens na identificação de anomalias

A expansão do uso de veículos aéreos não tripulados (VANTs) nas inspeções estruturais aumentou significativamente a disponibilidade de imagens de alta resolução. Contudo, o elevado volume de dados produzidos torna a avaliação exclusivamente manual pouco eficiente, tornando o processamento digital de imagens indispensável para automatizar a detecção de anomalias (Ali et al., 2023).

De acordo com a literatura, esse processamento envolve etapas como pré-processamento, segmentação e extração de características, que permitem reconhecer alterações superficiais, como corrosão, fissuras e deformações. A aplicação dessas técnicas transforma informações visuais em dados quantitativos capazes de apoiar a avaliação da integridade estrutural, reduzir a subjetividade das inspeções e aumentar a confiabilidade dos resultados (Ali et al., 2023; Alharbi et al., 2026).

Nas subseções seguintes são apresentados os fundamentos do processamento digital de imagens, as principais técnicas empregadas na análise de estruturas e sua aplicação na identificação automatizada de anomalias em ambientes portuários.

3.3.1 Fundamentos do processamento de imagens aplicado às inspeções estruturais

O processamento digital de imagens constitui um dos principais recursos empregados nas inspeções estruturais, pois permite transformar registros obtidos em campo em informações capazes de apoiar a avaliação da integridade dos ativos. Segundo Ali et al. (2023), esse processo compreende uma sequência de procedimentos destinados a melhorar a qualidade das imagens e evidenciar características relevantes para a identificação de anomalias.

O fluxo de processamento inicia-se com a aquisição das imagens, cuja qualidade está diretamente relacionada aos sensores utilizados durante a inspeção. Câmeras RGB são amplamente empregadas na detecção de defeitos superficiais devido à elevada resolução espacial, enquanto sensores térmicos permitem identificar anomalias associadas a variações de temperatura. Sensores hiperespectrais possibilitam diferenciar materiais e produtos de corrosão por meio de suas assinaturas espectrais, e sistemas LiDAR fornecem informações tridimensionais da geometria das estruturas, auxiliando na identificação de deformações e alterações geométricas (Alharbi et al., 2026).

As etapas do processamento digital de imagens discutidas nesta subseção estão resumidas na Figura 2, que apresenta o fluxo desde a aquisição das imagens até a preparação dos dados para as etapas de análise.



Figura 2. Fluxograma do processamento digital de imagens aplicado à inspeção de estruturas portuárias.

Fonte: Elaborado pelos autores, com base em Ali et al. (2023).

Na sequência, realiza-se o pré-processamento, cuja finalidade é minimizar interferências que possam comprometer as etapas posteriores da análise. Entre as técnicas mais empregadas destacam-se a filtragem, utilizada para reduzir ruídos, a equalização de histograma, que melhora o contraste, e as operações morfológicas, responsáveis por realçar regiões de interesse e corrigir pequenas imperfeições presentes nas imagens (Ali et al., 2023).

Esses procedimentos aumentam a qualidade dos dados e tornam mais confiáveis as etapas de segmentação e extração de características. Dessa forma, o pré-processamento constitui a base para a identificação automatizada de anomalias, contribuindo para inspeções mais precisas e consistentes em estruturas portuárias (Ali et al., 2023).


3.3.2 Técnicas de processamento e extração de características

Concluído o pré-processamento, inicia-se a segmentação, etapa responsável por isolar automaticamente as regiões de interesse do restante da imagem. Esse procedimento direciona a análise para áreas com indícios de manifestações patológicas, reduzindo interferências do fundo e aumentando a precisão das etapas seguintes (Ali et al., 2023).

Entre as técnicas de segmentação descritas na literatura destacam-se a limiarização (thresholding), a detecção de bordas, o crescimento de regiões e o agrupamento de pixels (clustering). A seleção do método depende das características da superfície, das condições de aquisição das imagens e do tipo de defeito investigado. Em estruturas portuárias, fatores como reflexos, sombras e geometrias complexas podem influenciar diretamente o desempenho desses algoritmos, exigindo estratégias compatíveis com cada situação (Ali et al., 2023).

Após a delimitação das regiões de interesse, realiza-se a extração de características, cujo objetivo é representar matematicamente os padrões presentes na superfície inspecionada. Entre os descritores mais empregados estão o Histogram of Oriented Gradients (HOG), utilizado para caracterizar bordas e formas; os filtros de Gabor, aplicados à análise de textura; o Laplacian of Gaussian (LoG), empregado na detecção de contornos; e a Transformada Wavelet, capaz de identificar padrões em diferentes escalas da imagem (Ali et al., 2023).

Além dos atributos relacionados à textura e à forma, a informação cromática também desempenha papel importante na caracterização das superfícies. Os espaços de cores HSV (Hue, Saturation e Value) e HSI (Hue, Saturation e Intensity) apresentam maior robustez que o modelo RGB diante de variações de iluminação, favorecendo a diferenciação entre



superfícies preservadas e regiões afetadas por processos corrosivos (Ali et al., 2023).

A integração dessas técnicas permite caracterizar as superfícies de maneira mais completa, produzindo atributos que servirão de entrada para os métodos de reconhecimento e classificação automática.

3.3.3 Processamento de imagens aplicado à detecção automática de corrosão

A detecção automática de corrosão representa uma das aplicações mais relevantes do processamento digital de imagens na inspeção de estruturas metálicas. Em vez de depender exclusivamente da interpretação visual do inspetor, essas técnicas utilizam características extraídas das imagens para identificar regiões deterioradas de forma objetiva e reproduzível (Ali et al., 2023; Khayatazad et al., 2020).

Entre as abordagens mais utilizadas destaca-se a análise conjunta de textura e cor, uma vez que o avanço da corrosão modifica simultaneamente a rugosidade e a aparência superficial dos materiais. Khayatazad et al. (2020) verificaram que a combinação desses atributos apresenta desempenho superior ao uso isolado de cada característica.

Na análise textural, a Gray Level Co-occurrence Matrix (GLCM) é amplamente empregada para representar a distribuição espacial dos níveis de cinza da imagem. A partir dessa matriz são calculados parâmetros capazes de diferenciar superfícies homogêneas de regiões que apresentam irregularidades características do processo corrosivo (Khayatazad et al., 2020).

As características cromáticas complementam essa avaliação. Embora as imagens sejam normalmente capturadas no espaço RGB, sua conversão para HSV reduz a influência das condições de iluminação e melhora a identificação das tonalidades associadas aos produtos de corrosão. Como consequência, a integração entre textura e cor aumenta a precisão da delimitação das áreas degradadas e reduz classificações incorretas provocadas por superfícies rugosas ou objetos com coloração semelhante à ferrugem (Khayatazad et al., 2020).

O impacto das condições de aquisição sobre o desempenho do algoritmo é apresentado na Figura 3, que compara os resultados obtidos em diferentes cenários de iluminação e qualidade das imagens.




Figura 3. Desempenho do algoritmo de detecção automática de corrosão em diferentes condições de aquisição das imagens.

Fonte: Elaborado pelos autores, com base em Khayatazad et al. (2020).

Os resultados obtidos por Khayatazad et al. (2020) indicam que essa abordagem melhora a confiabilidade da identificação automática da corrosão. Ainda assim, fatores como iluminação irregular, sombras, reflexos e baixa qualidade das imagens continuam limitando o desempenho dos algoritmos, evidenciando a importância das etapas de pré-processamento apresentadas anteriormente.


Os atributos extraídos nessa etapa constituem a base para os modelos de Inteligência Artificial, que utilizam essas informações para reconhecer padrões, classificar anomalias e automatizar o processo de inspeção.

3.3.4 Reconstrução tridimensional aplicada às inspeções portuárias

Além da identificação de anomalias em imagens bidimensionais, o processamento digital possibilita a reconstrução tridimensional dos ativos inspecionados, ampliando a capacidade de análise das condições estruturais. Essa abordagem fornece uma representação mais fiel da geometria das estruturas e facilita o acompanhamento de alterações ao longo do tempo (Mohsan et al., 2021).

A reconstrução é obtida a partir de imagens sobrepostas capturadas por veículos aéreos não tripulados (VANTs) e processadas por técnicas de fotogrametria. Entre os métodos mais utilizados destacam-se o Structure from Motion (SfM), responsável por estimar a posição das câmeras e gerar uma nuvem inicial de pontos, e o Multi-View Stereo (MVS), empregado para densificar essa representação e produzir modelos com maior nível de detalhamento (Mohsan et al., 2021).

Essa abordagem permite identificar deformações geométricas, deslocamentos, fissuras e outras alterações estruturais, além de criar registros digitais que facilitam a comparação entre diferentes campanhas de inspeção. Como consequência, reduz-se a necessidade de medições presenciais e amplia-se a disponibilidade de dados para o monitoramento dos ativos.



Outra contribuição apontada na literatura é a integração dessas reconstruções com plataformas Building Information Modeling (BIM) e Digital Twin, reunindo informações geométricas, operacionais e históricas em um ambiente digital. Essa integração favorece o acompanhamento contínuo da condição dos ativos, auxilia o planejamento das inspeções e oferece suporte ao gerenciamento da manutenção durante todo o ciclo de vida da infraestrutura (Mohsan et al., 2021).

Dessa maneira, a reconstrução tridimensional complementa as técnicas de processamento digital de imagens ao fornecer uma representação espacial detalhada das estruturas inspecionadas. Os dados produzidos também podem ser utilizados por algoritmos de Inteligência Artificial para automatizar a identificação de padrões e apoiar a tomada de decisão.

3.4 Inteligência Artificial aplicada às inspeções estruturais

A Inteligência Artificial (IA) amplia as possibilidades do processamento digital de imagens ao interpretar automaticamente as características extraídas durante as etapas anteriores e transformá-las em informações úteis para a inspeção estrutural. Diferentemente das técnicas clássicas, que dependem de regras previamente definidas, os algoritmos de IA aprendem padrões diretamente dos dados, permitindo detectar, localizar e classificar anomalias com maior rapidez e consistência (Ali et al., 2023; Alharbi et al., 2026).

Nas inspeções de estruturas portuárias, essas técnicas vêm sendo empregadas para reconhecer corrosão, fissuras, deformações e outros defeitos em imagens obtidas por VANTs, contribuindo para reduzir a subjetividade das avaliações e apoiar estratégias de manutenção baseadas na condição dos ativos. O avanço dos modelos computacionais também tornou possível processar grandes volumes de imagens em intervalos reduzidos, favorecendo o monitoramento contínuo da infraestrutura (Alharbi et al., 2026).

3.4.1 Machine Learning e Deep Learning nas inspeções estruturais

Os trabalhos revisados mostram que as aplicações de Inteligência Artificial concentram-se principalmente em duas abordagens: Machine Learning (ML) e Deep Learning (DL). Embora ambas tenham como objetivo reconhecer padrões presentes nas imagens, diferenciam-se pela forma como as características são obtidas e processadas.

Nos métodos de Machine Learning, a classificação depende de atributos previamente extraídos durante o processamento digital de imagens, como textura, cor e forma. Esses descritores servem de entrada para algoritmos capazes de distinguir regiões preservadas de áreas degradadas, tornando o desempenho

diretamente relacionado à qualidade das características selecionadas (Ali et al., 2023).

No Deep Learning, por outro lado, essa etapa passa a ser realizada automaticamente pelas próprias redes neurais, que aprendem representações hierárquicas diretamente a partir das imagens. Essa característica torna os modelos mais adequados para cenários complexos, nos quais a corrosão apresenta diferentes padrões de tamanho, formato e intensidade (Shirsath et al., 2022; Alharbi et al., 2026).

Outro aspecto recorrente na literatura refere-se à influência da base de treinamento sobre o desempenho dos modelos. Conjuntos de dados diversificados, contendo imagens obtidas sob diferentes condições de iluminação, ângulos de captura e níveis de degradação, favorecem maior capacidade de generalização e reduzem falhas durante a aplicação em ambientes reais (Alharbi et al., 2026).

3.4.2 Redes neurais convolucionais e Transfer Learning

Entre as arquiteturas de Deep Learning, as Redes Neurais Convolucionais (CNNs) representam a solução mais empregada para análise automática de imagens em inspeções estruturais. Sua principal vantagem consiste na extração automática de características, eliminando a necessidade de definir manualmente descritores como textura ou bordas (Shirsath et al., 2022; Ali et al., 2023).

Durante o treinamento, sucessivas camadas convolucionais identificam padrões visuais de diferentes níveis de complexidade, enquanto operações de pooling reduzem a dimensionalidade dos dados e tornam o modelo menos sensível a pequenas variações na posição dos objetos. Ao final desse processo, as características aprendidas são utilizadas para classificar imagens ou regiões específicas da estrutura (Shirsath et al., 2022).

Grande parte das aplicações recentes também utiliza Transfer Learning, estratégia que adapta redes previamente treinadas em grandes bancos de imagens para tarefas específicas de inspeção. Essa abordagem reduz o tempo de treinamento e melhora o desempenho quando há disponibilidade limitada de imagens de corrosão, situação comum em aplicações industriais (Shirsath et al., 2022).

Arquiteturas como VGG16 e ResNet50 destacam-se nesse contexto por apresentarem elevada capacidade de generalização, permitindo desenvolver modelos mais robustos mesmo com conjuntos de dados relativamente reduzidos.

3.4.3 Modelos de Inteligência Artificial para detecção e classificação de anomalias

Os estudos mais recentes concentram-se no desenvolvimento de modelos capazes de executar

simultaneamente a detecção, localização, segmentação e classificação das anomalias estruturais. Essa evolução amplia a quantidade de informações disponíveis para o planejamento das intervenções e reduz a necessidade de interpretação manual dos resultados (Aich et al., 2026; Oyedeji; Khan; Erkoyuncu, 2024).

Entre os algoritmos de detecção, a família YOLO destaca-se pelo equilíbrio entre velocidade e precisão. Shen et al. (2024) aplicaram o YOLOv5 associado à visão monocular tridimensional para identificar automaticamente funis de descarga em terminais portuários, alcançando precisão média de 96,06%, erro de posicionamento de aproximadamente 35 cm e processamento em tempo real de 102 quadros por segundo.

O desempenho desse estudo evidencia o potencial da arquitetura para aplicações operacionais em ambientes portuários, onde a rapidez na análise é um requisito importante. Os principais resultados obtidos por Shen et al. (2024) estão apresentados no Quadro 1.

Quadro 1. Desempenho do modelo YOLOv5 aplicado à infraestrutura portuária.

Indicador	Resultado
Modelo	YOLOv5
Aplicação	Identificação de funis de descarga
Precisão média	96,06%
Erro médio de posicionamento	35 cm
Velocidade	102 FPS

Fonte: Adaptado de Shen et al. (2024).

Enquanto modelos como o YOLOv5 priorizam velocidade e localização dos objetos, arquiteturas voltadas à segmentação produzem informações mais detalhadas sobre a extensão dos danos. Nesse contexto, Aich et al. (2026) combinaram o YOLOv8-seg para segmentação das áreas corroídas com a EfficientNet-B0 para classificação da severidade da corrosão, permitindo identificar simultaneamente a posição e o nível de degradação das estruturas.

Uma abordagem ainda mais abrangente foi proposta por Oyedeji, Khan e Erkoyuncu (2024), que integraram diferentes modelos de Deep Learning em um fluxo capaz de realizar detecção, localização,

classificação do estágio da corrosão e delimitação automática das regiões degradadas. Em comparação aos modelos destinados a uma única tarefa, essa estratégia fornece informações mais completas para subsidiar decisões de manutenção.

De forma conjunta, esses trabalhos evidenciam uma tendência de evolução das aplicações de Inteligência Artificial, que passam da simples identificação de defeitos para sistemas capazes de caracterizar automaticamente a localização, a extensão e a severidade das anomalias, aproximando as inspeções estruturais de modelos cada vez mais autônomos e orientados à manutenção preditiva.

3.4.4 Desafios e perspectivas da Inteligência Artificial nas inspeções estruturais

Embora a Inteligência Artificial tenha ampliado a capacidade de automatizar a análise de imagens e reconhecer anomalias estruturais, sua aplicação em ambientes portuários ainda enfrenta limitações técnicas que restringem sua adoção em larga escala. Os trabalhos consultados mostram que o desempenho dos modelos está diretamente relacionado à qualidade das imagens utilizadas no treinamento, à diversidade dos cenários representados e à disponibilidade de bases de dados suficientemente abrangentes (Alharbi et al., 2026; Bastian et al., 2019).

Entre os principais desafios está a capacidade de generalização dos algoritmos. Modelos desenvolvidos com conjuntos de dados restritos tendem a apresentar redução de desempenho quando aplicados a diferentes tipos de estruturas, materiais ou condições operacionais. No contexto portuário, a presença de sombras, reflexos, elevada umidade, salinidade e diferentes estágios de degradação superficial aumenta a complexidade da identificação automática das anomalias (Bastian et al., 2019; Alharbi et al., 2026).

Outro ponto discutido refere-se à interpretabilidade dos modelos de aprendizado profundo. Apesar dos elevados índices de acurácia obtidos por arquiteturas recentes, muitas decisões ainda são produzidas por mecanismos pouco transparentes, dificultando a compreensão dos critérios empregados na classificação das anomalias. Por essa razão, as soluções baseadas em IA são apresentadas como ferramentas de apoio à inspeção, complementando a análise realizada pelos profissionais responsáveis pela avaliação estrutural (Alharbi et al., 2026).

As publicações também apontam uma tendência de integração entre Inteligência Artificial, VANTs, sensores inteligentes, Internet das Coisas (IoT), modelos tridimensionais, BIM e Digital Twin. Essa convergência tecnológica possibilita que as informações coletadas em campo sejam processadas de forma integrada, favorecendo o monitoramento contínuo dos ativos e o planejamento de intervenções

baseado na condição real das estruturas (Alharbi et al., 2026; Mohsan et al., 2021).

Em conjunto, os resultados evidenciam que a evolução da Inteligência Artificial tende a consolidar sistemas de inspeção cada vez mais automatizados e integrados à gestão da infraestrutura portuária. Entretanto, sua aplicação operacional ainda depende da construção de bases de dados mais representativas, da validação dos modelos em diferentes cenários e do desenvolvimento de algoritmos capazes de manter desempenho consistente diante das condições adversas características do ambiente marítimo.

3.5 Benefícios para a manutenção e operação portuária

A adoção integrada de veículos aéreos não tripulados (VANTs), processamento digital de imagens e Inteligência Artificial tem provocado mudanças na forma de monitorar a infraestrutura portuária. Mais do que substituir procedimentos convencionais, essas tecnologias ampliam a frequência das inspeções, aumentam a disponibilidade de informações sobre os ativos e fornecem suporte técnico para decisões de manutenção baseadas na condição real das estruturas. Como consequência, seus benefícios estendem-se além da etapa de inspeção, refletindo na eficiência operacional, na segurança das equipes e na gestão da infraestrutura (Tsaimou et al., 2024; Alharbi et al., 2026).

3.5.1 Eficiência operacional e redução de custos

Entre os principais benefícios identificados está a otimização das atividades de inspeção. Em comparação com métodos convencionais, os VANTs reduzem o tempo necessário para aquisição dos dados ao minimizar a utilização de andaimes, plataformas elevatórias, embarcações e paralisações operacionais (Tsaimou et al., 2024).

Ao comparar diferentes técnicas de inspeção, Tsaimou et al. (2024) verificaram que os drones oferecem maior flexibilidade para avaliação de defeitos superficiais, permitindo ampliar a cobertura das estruturas em menor intervalo de tempo. Essa característica favorece campanhas de inspeção mais frequentes, especialmente em ambientes sujeitos à rápida evolução de processos corrosivos.

Resultados experimentais apresentados por Edeh et al. (2021) reforçam essa tendência ao demonstrarem redução do tempo de inspeção de aproximadamente 3,5 horas para 0,66 hora na avaliação de quatro silos, além da diminuição da equipe necessária de quatro para dois profissionais. Esses resultados evidenciam que o principal ganho não se restringe à redução de custos, mas também ao aumento da produtividade e da capacidade de monitoramento da infraestrutura.

Assim, os trabalhos analisados indicam que a eficiência operacional decorre da combinação entre

rapidez na coleta de dados, maior cobertura das inspeções e melhor aproveitamento dos recursos humanos e materiais (Tsaimou et al., 2024; Edeh et al., 2021).

3.5.2 Segurança operacional e redução dos riscos ocupacionais

Outro benefício recorrente está relacionado à redução da exposição dos inspetores a ambientes potencialmente perigosos. Em estruturas portuárias, diversas atividades exigem acesso a regiões elevadas, áreas confinadas e locais sujeitos à movimentação contínua de equipamentos, aumentando os riscos durante as inspeções.

Nesse contexto, Alharbi et al. (2026) destacam que a utilização de VANTs permite executar grande parte das avaliações de forma remota, reduzindo a necessidade de acesso direto às estruturas e, consequentemente, a exposição dos profissionais.


Essa percepção também foi observada por Lima et al. (2026), que identificaram, por meio de entrevistas com especialistas do setor portuário, a segurança operacional como um dos principais fatores que justificam a adoção dessa tecnologia. Segundo os autores, esse benefício é particularmente relevante na inspeção de silos, guindastes, estruturas metálicas elevadas e áreas com intenso fluxo de equipamentos. Dessa forma, a utilização de drones contribui não apenas para diminuir riscos ocupacionais, mas também para viabilizar inspeções mais frequentes sem aumentar a exposição das equipes, fortalecendo a confiabilidade das operações (Alharbi et al., 2026; Lima et al., 2026).

Os benefícios da utilização de drones em relação à redução da exposição dos profissionais aos riscos ocupacionais são ilustrados na Figura 4, comparando as inspeções convencionais e aquelas realizadas com VANTs.



Figura 4. Comparação entre inspeções convencionais e inspeções realizadas por drones quanto à exposição dos profissionais aos riscos ocupacionais.

Fonte: Elaborado pelos autores, com base em Lima et al. (2026) e Alharbi et al. (2026).



3.5.3 Manutenção preditiva e gestão inteligente de ativos

Os benefícios dessas tecnologias tornam-se ainda mais expressivos quando os dados coletados durante as inspeções são incorporados aos sistemas de gerenciamento da infraestrutura. A integração entre VANTs, sensores e Inteligência Artificial amplia a capacidade de monitoramento contínuo dos ativos, permitindo que as intervenções sejam planejadas com base nas condições observadas durante a operação (Alharbi et al., 2026).

Park (2026) destaca que a análise contínua dos dados favorece a identificação antecipada de alterações estruturais, permitindo priorizar intervenções antes que ocorram falhas de maior gravidade. Essa abordagem contribui para uma utilização mais eficiente dos recursos destinados à manutenção e reduz a necessidade de intervenções corretivas emergenciais.

Nesse cenário, observa-se uma transição gradual da manutenção predominantemente corretiva para estratégias preditivas, nas quais o histórico das inspeções, os dados monitorados e os modelos computacionais são utilizados de forma integrada para apoiar a gestão dos ativos ao longo de todo o seu ciclo de vida (Alharbi et al., 2026; Park, 2026).

3.5.4 Contribuições da Inteligência Artificial para a gestão operacional

Além da identificação automática de defeitos, discutida na Seção 3.4, a Inteligência Artificial também contribui para o gerenciamento das operações portuárias. As informações obtidas durante as inspeções podem ser utilizadas para planejar missões de voo, estabelecer prioridades de manutenção e apoiar decisões relacionadas ao gerenciamento da infraestrutura (Ahmad et al., 2025; Park, 2026).

Ahmad et al. (2025) destacam que algoritmos baseados em aprendizado por reforço permitem otimizar trajetórias de voo, adaptar automaticamente as missões às condições operacionais e reduzir deslocamentos desnecessários durante a aquisição dos dados. Embora essas aplicações não interfiram diretamente na detecção das anomalias, elas aumentam a eficiência das inspeções.

Complementarmente, Park (2026) ressalta que a integração entre IA e plataformas digitais possibilita analisar grandes volumes de informações provenientes das inspeções, fornecendo subsídios para o planejamento das intervenções e para a priorização dos ativos que demandam manutenção.

Assim, a principal contribuição da Inteligência Artificial para a operação portuária está na transformação dos dados coletados em informações estratégicas capazes de apoiar decisões mais rápidas, consistentes e fundamentadas.

3.6 Limitações e perspectivas futuras

Apesar dos avanços observados, a implementação de VANTs, processamento digital de imagens e Inteligência Artificial em ambientes portuários ainda enfrenta limitações que restringem sua aplicação em larga escala. Entre os principais desafios destacam-se a influência das condições ambientais sobre a qualidade das imagens, a autonomia limitada das aeronaves, a disponibilidade de bases de dados representativas para treinamento dos modelos e a integração entre sensores, plataformas digitais e sistemas de gerenciamento (Ali et al., 2023; Alharbi et al., 2026).

Outro aspecto frequentemente apontado refere-se à robustez dos algoritmos quando empregados em condições reais de operação. Variações de iluminação, sombras, reflexos, interferências atmosféricas e geometrias complexas podem reduzir a qualidade das imagens e comprometer o desempenho dos métodos de processamento e classificação automática. Esses fatores demonstram que a eficiência dos modelos depende tanto das técnicas empregadas quanto da qualidade dos dados obtidos durante as inspeções (Ali et al., 2023; Bastian et al., 2019).

As perspectivas de desenvolvimento concentram-se na ampliação da autonomia dos sistemas de inspeção. Ahmad et al. (2025) destacam que técnicas baseadas em Deep Reinforcement Learning (DRL) possibilitam adaptar automaticamente as rotas dos VANTs, evitar obstáculos e otimizar a cobertura das áreas inspecionadas. Os autores também ressaltam que a escolha da plataforma aérea, considerando autonomia de voo, capacidade de carga e sensores embarcados, influencia diretamente o desempenho das missões.

Outra tendência consiste na integração entre Inteligência Artificial, Internet das Coisas (IoT), sensores LiDAR, modelos de Digital Twin e plataformas de gerenciamento de ativos. Essa convergência tecnológica tende a tornar o monitoramento estrutural mais contínuo, permitindo que aquisição, processamento e interpretação dos dados ocorram de forma integrada. Como consequência, espera-se ampliar a confiabilidade das inspeções, fortalecer a manutenção preditiva e aperfeiçoar a gestão da infraestrutura portuária (Alharbi et al., 2026; Ahmad et al., 2025).

4. CONCLUSÃO

Este estudo evidenciou que a aplicação de veículos aéreos não tripulados (VANTs), associada ao processamento digital de imagens e à Inteligência Artificial, representa uma alternativa eficiente para a inspeção de estruturas portuárias. Os estudos analisados demonstram que essas tecnologias proporcionam maior rapidez na aquisição de dados, elevada precisão na identificação de anomalias,

redução da exposição dos profissionais a ambientes de risco e suporte às estratégias de manutenção preventiva e preditiva.

Além de ampliar a confiabilidade das inspeções, a integração entre drones, visão computacional e algoritmos de Inteligência Artificial favorece o monitoramento contínuo da infraestrutura, contribuindo para a otimização da gestão dos ativos e da operação portuária. Nesse contexto, essas tecnologias apresentam potencial para substituir ou complementar métodos convencionais de inspeção, especialmente em estruturas de grande porte e de difícil acesso.

Por fim, conclui-se que a incorporação dessas ferramentas representa um importante avanço para a modernização das inspeções estruturais, tornando-as mais seguras, ágeis e eficientes. Espera-se que este manuscrito contribua para a disseminação do conhecimento sobre o tema e sirva como referência para futuras pesquisas e aplicações voltadas ao monitoramento inteligente da infraestrutura portuária.

5.REFERÊNCIAS

AHMAD, S. et al. **Flight into the Future: A Holistic Review of AI Trends, Vision, and Challenges in UAV Networks.** Artificial Intelligence Review, 2025. DOI: 10.1007/s10462-025-11449-7.

AICH, S. et al. **A two-stage deep learning framework for automated corrosion segmentation and severity classification using YOLOv8-seg and EfficientNet-B0.** Automation, v. 7, n. 2, p. 65, 2026. DOI: 10.3390/automation7020065.

ALHARBI, A.; ALQUDSI, Y.; ALHARBI, A. A.; MOHIUDDIN, M. B. **Unmanned Aerial Systems for Corrosion Detection: Multi-Sensor Technologies, Challenges, and Opportunities for Next-Generation Inspection.** Quality and Reliability Engineering International, 2026. DOI: <https://doi.org/10.1002/qre.70251>.

ALI, A. A. I. M. et al. **Computer Vision and Image Processing Approaches for Corrosion Detection.** Journal of Marine Science and Engineering, Basel, v. 11, n. 10, p. 1954, 2023. DOI: 10.3390/jmse11101954.

ALLENDE-PRieto, C. et al. **Monitoring bulk storage in port infrastructure through the fusion of UAV orthophotos, SAR imagery and machine learning.** Heliyon, v. 11, e43024, 2025. DOI: 10.1016/j.heliyon.2025.e43024.

ALJUAID, A. et al. **Drone Applications in Airport Operations and Management: A Comprehensive**

Review. Drones, v. 8, n. 233, 2024. DOI: 10.3390/drones8060233.

BASTIAN, B. T. et al. **Deep learning-based corrosion detection and localization in pipeline images using convolutional neural networks.** NDT & E International, v. 107, p. 102134, 2019. DOI: <https://doi.org/10.1016/j.ndteint.2019.102134>.

BELMOUKARI, B.; AUDY, J.-F.; FORGET, P. **Smart port: a systematic literature review.** European Transport Research Review, v. 15, art. 4, 2023. DOI: 10.1186/s12544-023-00581-6.

DUQUE, L.; SEO, J.; WACKER, J. **Synthesis of unmanned aerial vehicle applications for infrastructures.** Journal of Performance of Constructed Facilities, v. 32, n. 4, 2018. DOI: 10.1061/(ASCE)CF.1943-5509.0001185.

EDEH, J. C. et al. **Development and Deployment of Quadcopter in Silos' Inspection and Surveillance.** Arid Zone Journal of Engineering, Technology and Environment, v. 17, n. 4, p. 429-438, 2021.


JOFRÉ-BRICEÑO, C.; GONZÁLEZ, V.; ALARCÓN, L. F. et al. **Implementation of Facility Management for Port Infrastructure through the Use of UAVs, Photogrammetry and BIM.** Sensors, v. 21, n. 19, p. 6686, 2021. DOI: <https://doi.org/10.3390/s21196686>.

KHAYATAZAD, M. et al. **Automated corrosion detection by combining roughness and color analysis of digital images.** Developments in the Built Environment, v. 3, p. 100022, 2020. DOI: <https://doi.org/10.1016/j.dibe.2020.100022>.

LIMA, G. et al. **Unmanned aerial vehicles in smart ports: benefits, challenges and future perspectives.** Journal of Shipping and Trade, v. 11, n. 19, 2026. DOI: <https://doi.org/10.1186/s41072-026-00240-8>.

MOHSAN, S. A. H.; OTHMAN, N. Q. H.; LI, Y.; ALSHARIF, M. H.; KHAN, M. A.; SOLAIMAN, B. **Robotics and AI in infrastructure inspection: A comprehensive review of unmanned aerial vehicles, unmanned ground vehicles, photogrammetry, computer vision and building information modeling.** Sensors, v. 21, n. 23, p. 1-45, 2021. DOI: 10.3390/s21237808.

OYEDEJI, O. A.; KHAN, S.; ERKOYUNCU, J. A. **Multi-phase deep learning framework for corrosion detection, stage classification, anomaly localization and damage region identification.** Applied Soft Computing, v. 164, p. 112008, 2024. DOI: <https://doi.org/10.1016/j.asoc.2024.112008>.



PARK, I.-H. **Generative Artificial Intelligence for Unmanned Aerial Vehicle Systems: A Comprehensive Survey.** Drones, v. 10, n. 4, p. 292, 2026. DOI: 10.3390/drones10040292.

SHEN, Z.; WANG, J.; ZHANG, Y.; ZHENG, L.; MI, C.; SHEN, Y. **Identification and Positioning Method of Bulk Cargo Terminal Unloading Hopper Based on Monocular Vision Three-Dimensional Measurement.** Journal of Marine Science and Engineering, v. 12, n. 8, p. 1282, 2024. DOI: 10.3390/jmse12081282.

SHIRSATH, K.; PARJANE, V. A.; MEHERKHAMB, A.; RATNAPARKHI, S.; KANADE, S. **Deep Learning for Automated Corrosion Detection Using Supervised Machine Learning & CNN Algorithm.** International Research Journal of Modernization in Engineering Technology and Science, v. 4, n. 1, jan. 2022.

TSAIMOU, C. N. et al. **Introducing Unmanned Aerial Vehicles to Multi-Criteria Performance Assessment of Inspection Techniques for Port Concrete Infrastructure.** Maritime Technology and Research, v. 6, n. 4, 2024. DOI: 10.55142/mtr.269216.

ZHANG, Y. et al. **Path Planning Method for Drone Inspection in Port Container Yard.** Journal of Marine Science and Engineering, v. 12, n. 5, 2024. DOI: 10.3390/jmse12050739.