XXI ENTAC – Encontro Nacional de Tecnologia do Ambiente Construído
14 a 16 de outubro de 2026 | Goiânia-Brasil
DOI: https://doi.org/10.46421/entac.v21i1.8469

Tecnologias digitais e IA na identificação de manifestações patológicas: revisão sistemática e estudo em fachadas de restauro

Digital technologies and AI in the identification of pathological manifestations: systematic review and study using façade of heritage buildings

Paulo Rafael Lira Sobrinho
Escola Politécnica de Pernambuco | Recife | Brasil | prls@poli.br
Lia Rafael dos Santos
Escola Politécnica de Pernambuco | Recife | Brasil | santos.lia64@gmail.com
Alberto Casado Lordsleem Júnior
Escola Politécnica de Pernambuco | Recife | Brasil | acasado@poli.br
Emilia Rahnemay Kohlman Rabbani
Escola Politécnica de Pernambuco | Recife | Brasil | emilia.rabbani@upe.br
Yêda Vieira Póvoas
Escola Politécnica de Pernambuco | Recife | Brasil | yvp@poli.br

Resumo

Este estudo investiga o uso de tecnologias digitais e inteligência artificial (IA) no diagnóstico de manifestações patológicas em revestimentos externos, combinando uma Revisão Sistemática da Literatura (RSL) e um estudo de caso com fachadas de imóveis de restauro. A RSL, conduzida segundo o protocolo PRISMA, identificou 32 artigos das bases Scopus e ScienceDirect, revelando amplo emprego de termografia infravermelha, veículos aéreos não tripulados (UAVs) e métodos de *deep learning* na detecção de fissuras, umidade, eflorescência e descolamentos. Os resultados indicam que essas tecnologias ampliam a precisão, a segurança e a eficiência das inspeções, reduzindo a subjetividade e riscos associados aos métodos visuais tradicionais. O estudo de caso avaliou a capacidade interpretativa de plataformas de IA (Chatgpt e Gemini), constatando limitações na identificação de patologias apenas por imagens. Conclui-se que a integração entre tecnologias digitais e IA transforma o processo de diagnóstico, embora a inspeção presencial permaneça essencial em edificações históricas.

Palavras-chave: Termografia. Aprendizado profundo. Veículos aéreos não tripulados. Diagnóstico. Mapa de danos.

Abstract

This study investigates the use of digital technologies and artificial intelligence (AI) in diagnosing pathological manifestations in external coatings, combining a Systematic Literature Review (SLR) and a case study involving the façades of heritage buildings. The SLR, conducted according to the PRISMA protocol, identified 32 articles from the Scopus and ScienceDirect databases, revealing extensive use of infrared thermography, unmanned aerial vehicles (UAVs), and deep learning methods for detecting cracks, moisture, efflorescence, and detachments. The results indicate that these technologies enhance the accuracy, safety, and efficiency of inspections, reducing subjectivity and the risks associated with traditional visual methods. The case study assessed the interpretive capability of AI platforms (Chatgpt and Gemini), identifying limitations in detecting pathologies solely from images. It is concluded that the integration of digital

technologies and AI is transforming the diagnostic process, although on-site inspection remains essential in historical buildings.

Keywords: Thermography. Deep learning. Unmanned aerial vehicles. Diagnosis. Damage map.

INTRODUÇÃO

Globalmente, a construção civil contribui significativamente para o Produto Interno Bruto (PIB) de diversas economias e é frequentemente apontada como um setor lento na adaptação de práticas e ferramentas modernas, permanecendo dependente de métodos tradicionais e sistemas de gestão desatualizados [1, 2].

Apesar da construção civil desempenhar historicamente um papel central no desenvolvimento econômico e social, o setor continuamente enfrenta vários desafios relacionados a qualidade, produtividade, gestão de dados e a resistência à adoção de novas tecnologias. Essa conjuntura se agrava quando se observam os impactos diretos dessas limitações no desempenho dos sistemas construtivos, especialmente no que diz respeito à ocorrência de manifestações patológicas.

Segundo Rodrigues *et al.* (2023) [3] as patologias em edificações podem ocorrer em diferentes tipos de construções, causando danos à sua estrutura, funcionalidade ou estética.

A presença de manifestações patológicas como rachaduras, eflorescência, manchas de umidade e descolamento de revestimentos representam um risco significativo para a segurança pública, como evidenciado por incidentes de queda de detritos em áreas urbanas [4].

Historicamente, as inspeções visuais convencionais dependem essencialmente da experiência e do conhecimento de inspetores, muitas vezes requerendo técnicas de riscos e trabalhos em altura, como o uso de andaimes ou acesso por cordas [5]. Lin, Chiang e Putranto (2024) [6] destacam que métodos tradicionais, como o teste de percussão, são precisos, mas dependem de mão de obra, são caros e demorados, especialmente para grandes áreas, além desse tipo de inspeção ser propensa a erros humanos.

Em estudos em edifícios históricos, o diagnóstico de patologias em revestimentos de argamassa tem empregado a combinação do levantamento visual e percussão, permitindo o mapeamento de danos como descolamentos e áreas com umidade [7].

Em resposta as análises utilizando os métodos tradicionais, a indústria da Engenharia, Arquitetura e Construção tem adotado rapidamente tecnologias digitais e inteligência artificial (IA) para desenvolver procedimentos de inspeção mais objetivos, precisos e automatizados [8].

Desta forma, as técnicas de ensaios não destrutivos ganharam destaques, como exemplo a termografia bastante utilizada para identificar anomalias que afetam os revestimentos. He *et al.* (2025) [9] destaca que a eficiência da inspeção de fachadas foi drasticamente aprimorada pela incorporação de veículos aéreos não tripulados

(VANTs) e, segundo Ruiz *et al.* (2022) [10], estes equipamentos equipados com sensores, permitem inspeções rápidas, seguras em edifícios de média e grande altura.

A presente RSL visa, portanto, consolidar o conhecimento existente sobre a aplicação dessas tecnologias digitais e de inteligência artificial no diagnóstico, detecção e classificação de manifestações patológicas em revestimentos externos em argamassa, destacando as lacunas de pesquisa considerando os grandes desafios da indústria da construção.

Após o estudo e conhecimento das fontes selecionadas na revisão sistemática da literatura, o estudo de caso buscará analisar a capacidade de interpretação de duas ferramentas de inteligência artificial ao analisar fotos de fachadas de imóveis de restauro com mapa de danos já elaborados.

METODOLOGIA

ESTRATÉGIA DA PESQUISA

A pesquisa seguiu as orientações do método de RSL PRISMA, os artigos selecionados para esse estudo foram pesquisados no Portal de Periódicos da Coordenação de Aperfeiçoamento Pessoal de Nível Superior CAPES/MEC.

Este estudo baseou-se na metodologia empregada por Page *et al.* (2021) [11].

CRITÉRIOS DE SELEÇÃO

Na definição dos termos de busca foi utilizado a estratégia PICo, conforme apresentado no Quadro 1.

Quadro 1: Critérios PICo

Critérios PICo	
População (P)	Revestimentos
Interesse (I)	Manifestações patológicas
Contexto (Co)	Tecnologias digitais, inteligência artificial, inspeção, diagnóstico, manutenção

Fonte: Autores.

Foram considerados elegíveis:

- Artigos completos;
- Publicados entre 2020 e 2025;
- Escritos em português ou inglês;
- Revisado por pares.

Para a pesquisa foram escolhidas as bases de dados Scopus e Science Direct, por conterem uma excelente avaliação técnica e a disponibilidade de artigos. Os termos utilizados são: *((TITLE-ABS-KEY("coating*" OR "mortar*" OR "facade*" OR "cladding*")) AND (TITLE-ABS-KEY("pathological manifestation*" OR "building pathology" OR "defect*" OR "damage*" OR "deterioration")) AND (TITLE-ABS-KEY("artificial intelligence" OR "AI" OR "machine learning" OR "deep learning" OR*

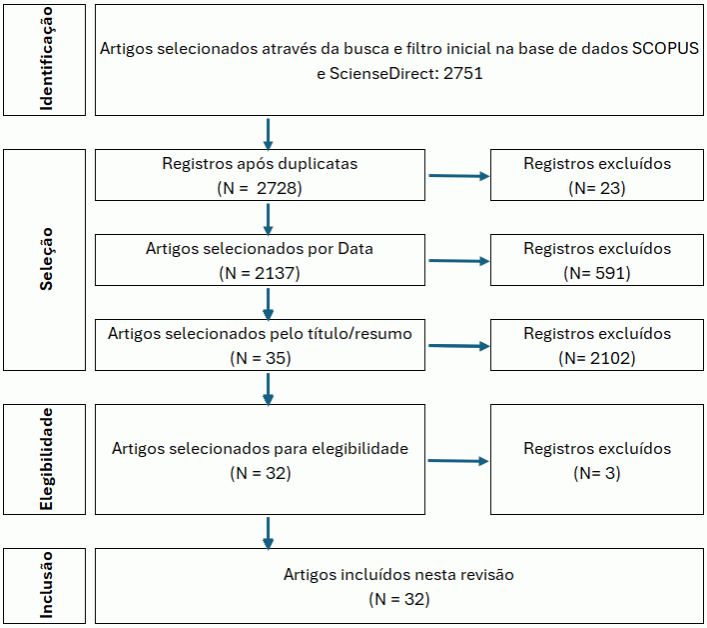
"computer vision" OR "digital technology" OR "image processing" OR "BIM" OR "UAV" OR "drone*" OR "sensor*" OR "photogrammetry" OR "thermography"))).*

ANÁLISE DE DADOS

Após estabelecido a estrutura da pesquisa RSL, realizou-se as exportações dos dados em formato BIPTEX, para tratamento no software Parsifal.

Através do diagrama de fluxo PRISMA, Figura 1, é possível identificar o roteiro.

Figura 1: Fluxograma da pesquisa realizada



Fonte: Autores.

ESTUDO DE CASO

O estudo de caso objetivou identificar a capacidade interpretativa de duas ferramentas de inteligência artificial ao analisar manifestações patológicas utilizando fotos de fachadas de imóveis de restauro na cidade do Recife, PE.

Para a realização das análises foi definido o prompt padrão, Figura 2, para utilização na realização das simulações no Chatgpt e Google Gemini.

Figura 2: Prompt padrão

```
Você é um engenheiro civil ou arquiteto especialista em patologia dos
revestimentos.

1.Identifique as manifestações patológicas dos revestimentos, atribuindo
cores.
2. Quais as prováveis causas, qual a severidade e o risco de evolução.
3. Quais as recomendações ténicas.
4. Quais as prováveis causas ou mecanismos de origem.
5. Grau de severidade conforme padrão G.U.T.
6. Confiança da análise (baixa, média, alta).
Ao final resuma a análise destacando a patologia identificada e grau de risco.
Apresente a análise através de uma tabela com cada tópico sendo uma linha e
cada coluna à uma manifestação patológica identificada.
Não invente elementos inexistentesna imagem, descreva apaenas o que for
visualmente identificável.
Utilize como referências: Norma – 1/88 Alterazioni Macroscoche dei Materiali
Lapidei – Lessico.
Negri, A.; Russo, J.- degrado dei materiali lapedi: Proposta di simbologia
grafica. In.: Carbonara, Giovanni: trattato di restauro architettonic, Secondo
Aggiornamento. Grandi temi de Restauro, Utet: Torino, 2008.
```

Fonte: Autores.

As análises apresentadas pelas ferramentas de IA em seguida foram confrontadas com os mapas de danos convencionais, elaborados por profissional especialista em interpretações de manifestações patológicas em fachadas.

RESULTADOS

Os artigos selecionados focam na inspeção e diagnóstico de defeitos em fachadas de edifícios, tratando predominantemente de tecnologias não destrutivas e o uso da inteligência artificial.

TECNOLOGIAS DIGITAIS APLICADAS ÀS MANIFESTAÇÕES PATOLÓGICAS EM REVESTIMENTOS

A inspeção de edifícios vem enfrentando desafios devido à subjetividade e aos riscos associados aos métodos visuais tradicionais, já que essas inspeções convencionais dependem essencialmente da experiência e do conhecimento empírico do profissional [5, 12, 13]. Desta forma, a indústria de engenharia tem adotado tecnologias digitais e inteligência artificial [8].

Ruiz *et al.* (2022) [10] e Kang, Kim e Kim (2025) [14] complementam destacando a inspeção e o monitoramento de edifícios e infraestruturas de forma mais rápida, segura e precisa superando as limitações de tempo, custo e falta de objetividade associadas às inspeções visuais convencionais.

A partir dos artigos selecionados, foi elaborada o Quadro 2 com as tecnologias digitais aplicadas e manifestações patológicas analisadas.

Quadro 2: Artigos, tecnologia digital e manifestação analisada

Nº	Referência	Tecnologia digital aplicada	Manifestação patológica analisada

[15]	Zheng *et al.*, 2025	Termografia Infravermelha (IR) (ativa/passiva), Aprendizado de Máquina, Segmentação de Imagem.	Deficiência em isolamento térmico e falhas de vedação em juntas/caixilhos.
[12]	*Moradi; Gorji Kandi; Yahyaei, 2022*	Sistema de Visão por Máquina, Processamento de Imagem.	Bolhas em revestimentos.
[16]	*Franzoni; Bassi, 2022*	Plug Cerâmico Sensorizado (monitoramento remoto de umidade), Método Gravimétrico.	Umidade em paredes históricas de alvenaria.
[17]	Ishikawa *et al.*, 2024	Termografia Ativa.	Não especificado.
[13]	*Shin; Lee, 2024*	Redes Neurais Convolucionais (CNNs), Selective Layer Attention Network (SAN), Grad-CAM.	Rachaduras, descascamento, exposição de armadura em fachadas.
[18]	*Wang et al., 2024a*	Fusão de Imagens Infravermelho-Visível (IVIF) baseada em GAN, *Deep Learning* (Segmentação de Instância).	Rachaduras, descascamento, danos por umidade, descolamento de reboco
[19]	*Ferreira et al., 2024*	Veículo Aéreo Não Tripulado (UAV), Termografia Infravermelha.	Padrões de manchas, vazios e pontos úmidos (não visíveis a olho nu).
[20]	*Xu et al., 2023*	Segmentação de imagem, Análise de Parâmetros Geométricos.	Rachaduras em fachadas de edifícios.
[4]	*Liang et al., 2024*	UAVs, Filtragem Automatizada de Dados (detecção de pontos-chave SIFT), Algoritmo *Greedy*.	Defeitos em fachadas (rachaduras, descascamento).
[21]	Dinardo *et al.*, 2020	Termografia Pulsada Longa (LPT), Algoritmo de Processamento de Imagem (para detecção e quantificação).	Defeitos subsuperficiais
[22]	*Lee; Lee; Kim, 2022*	Redes Neurais Convolucionais Profundas (DCNNs), UAVs, BoxAug (Método de Aumento de Dados baseado em *bounding-box*).	Delaminação, rachadura, descascamento, vazamento em fachadas residenciais.
[23]	Jiang; Han; Bai, 2021	UAV, *Deep Learning* (CNNs, FCNs, U-Net), Nuvem de Pontos Fotogramétrica, Imagens de Múltiplos Recursos (RGB, Elevação/DEM, Normal).	Detecção de objetos e defeitos em componentes de construção e infraestrutura (segmentação pixel a pixel).
[24]	*Zhang; Pan; Zhang, 2022*	*Deep Learning* (DAN-PSPNet-Lsym), Segmentação Semântica, Função de Perda Simétrica (Lsym), Módulos de Atenção.	Elementos de fachada (janela, parede, porta, varanda, telhado, etc.).
[7]	*Bersch et al., 2021*	Termografia, Inspeção Visual/Percussão, Análise Laboratorial (XRF, XRD, TGA).	Manifestações patológicas em revestimento de argamassa (descolamentos, umidade, microfissuras, biodeterioração).

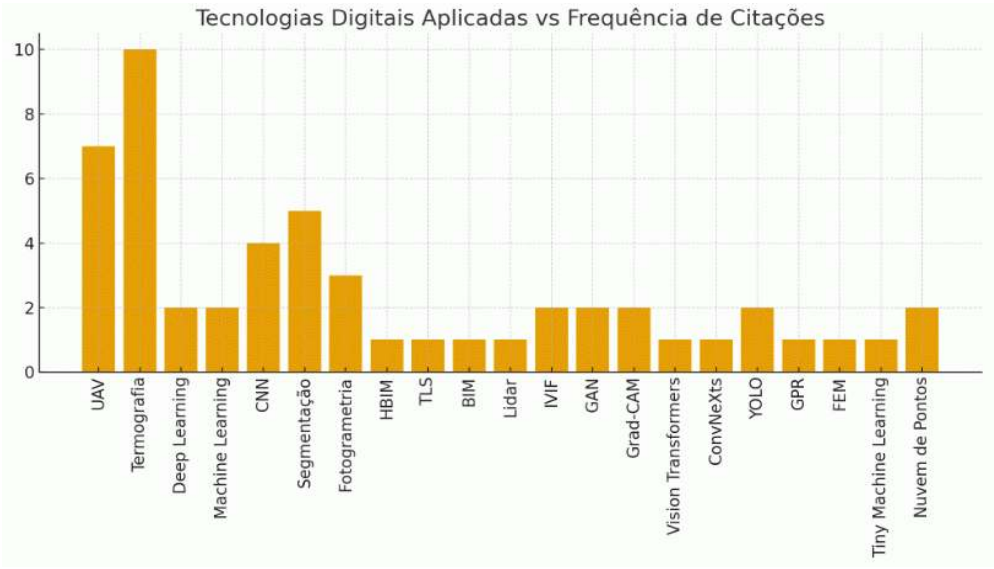
[3]	*Rodrigues et al., 2023*	*Laser Scanning* Terrestre (TLS), Fotogrametria (UAVs), HBIM (*Historical BIM*), GIS, Matriz GUT.	Múltiplas patologias em fachada (eflorescência, manchas de umidade/infiltração, rachaduras, desintegração de revestimentos, etc.).
[8]	*Interlando et al., 2024*	Redes Neurais Profundas (*Vision Transformers*, ConvNeXts), Aprendizado em Conjunto (*Ensemble Learning*), Grad-CAM.	Descascamento, rachaduras, manchas, vegetação.
[5]	*Guo; Wang; Li, 2021*	*Deep Learning* (Mask R-CNN), Regras para anotação, treinamento e retificação.	Defeitos de fachada (bolhas, rachaduras, delaminação, crescimento biológico, descascamento, desprendimento).
[25]	*Cui et al., 2022*	*Few-shot Learning*, Classificador Extensível, Aprendizado Contrastivo (com HNM).	Defeitos de fachada, incluindo classes raras (eflorescência, desprendimento com armadura exposta) e classes comuns.
[26]	*Wang et al.,* 2024b	UAVs, Termografia Infravermelha (IRT), Registro de Imagem Multimodal, IVIF (GAN), Segmentação de Instância.	Danos por umidade/vazamento, eflorescência, rachaduras/arranhões, vazios/falhas de material.
[14]	*Kang; Kim; Kim, 2025*	CNN, *Scan to BIM*, Laser Scanner (Lidar), Arquivos COBie, *Dynamo scripts*.	Rachaduras, desprendimento, vazamento e eflorescência, exposição de armadura.
[27]	*D'Orazio; Quagliarini; Gianangeli, 2023*	Redes Neurais (NN), Inteligência Artificial (AI), Cálculo de Chuva Impulsionada pelo Vento (WDR).	Crescimento de microalgas (biodeterioração) em fachadas.
[28]	*Chen et al., 2025*	IRT *on-site*, Testes de Percussão com Martelo.	Descolamento de azulejos.
[29]	*Yu et al., 2024*	UAV, Nuvem de Pontos (derivada de imagens), Análise de Múltiplos Recursos (profundidade, escala de cinza, PCA local).	Danos induzidos por terremoto em fachadas (desprendimento/spalling e rachaduras).
[6]	*Lin; Chiang; Putranto, 2024*	Robô Escalador Bio-inspirado (GLEWBOT), *Tiny Machine Learning* (para *edge computing*), CNN para Reconhecimento Acústico.	Defeitos em azulejos de parede exterior
[30]	*Diz-Mellado et al., 2021*	Ensaios Não Destrutivos (END: DIP, IRT, LL, AVT, GPR), Método de Elementos Finitos (FEM).	Deterioração estrutural e construtiva, fissuras, recalque
[31]	*Guedes et al., 2025*	UAV, Sensores (RGB, Térmico, Multiespectral), Fotogrametria.	Rachaduras, manchas de umidade, descolamento de revestimento, presença de musgo.

[32]	Mandinec; Sasic Kalagasidis; Johansson, 2025	UAV, Visão Computacional (CV, YOLOv4), *Machine Learning* (ML), Modelo de Vizinhança 3D (PAIR framework).	Deterioração de fachada (geral), desprendimento .
[33]	Hashimoto; Shiotani, 2023	Imagem Sônica-IR.	Interfaces de rachaduras em materiais cimentícios.
[34]	*De Souza Silva; Bauer, 2024*	Termografia Infravermelha (IR), Análise Delta-T.	Rachaduras (lineares e ramificadas) em revestimentos de argamassa.
[35]	*Barbosa; Rosse; Laurindo, 2021*	Termografia Infravermelha, Matriz de Priorização GUT.	Danos por umidade em fachadas.
[10]	Ruiz *et al.*, 2022	UAV, Fotogrametria Digital (AGISOFT PhotoScan), Modelos 3D, Ortomosaicos.	Manifestações patológicas (rachaduras, eflorescência, descolamento, mofo).
[9]	He *et al.*, 2025	UAV, Termografia IR, Aprendizado Cross-modal Fracamente Alinhado (WCL), MFDN (*Multimodal Feature Description Network*), PCGL (*Prompt-aided Cross-modal Graph Learning*).	Defeitos subsuperficiais

Fonte: Autores.

A partir da Figura 3 é possível identificar que a termografia e os VANTs ou UAV destacam-se como as tecnologias mais aplicadas

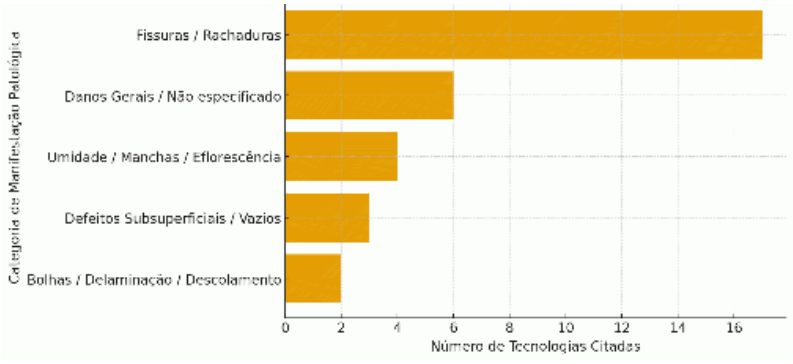
Figura 3: Frequência de citações das tecnologias digitais nos artigos



Fonte: Autores.

A análise quantitativa apresentada na Figura 4 revelou ainda que as tecnologias digitais são predominantemente aplicadas na detecção de fissuras e rachaduras.

Figura 4: Manifestações patológicas mais diagnosticadas



Fonte: Autores.

POTENCIAL DAS TECNOLOGIAS DIGITAIS E DA INTELIGÊNCIA ARTIFICIAL PARA A DETECÇÃO DE MANIFESTAÇÕES PATOLÓGICAS EM REVESTIMENTOS

Diversas fontes destacam a aplicação de VANTs e visão computacional para a detecção e classificação automática de manifestações patológicas utilizando modelos de *deep learning*.

Segundo os autores Zhang, Pan e Zhang (2022) [24], a principal vantagem do *deep learning* na detecção de elementos de fachadas está na sua capacidade de aprender representações das imagens sem depender de conhecimento manual, evidenciando ganhos de desempenho em acurácia e precisão em relação aos métodos tradicionais.

Desta forma, a partir do Quadro 3 é possível identificar que a transformação na forma de identificação de patologias através da automação, objetividade, precisão e integração de inúmeros dados complexos representam diversas vantagens quando implementadas.

Quadro 3: Transformação e vantagens

Transformação	**Descrição**	**Vantagem**
Automação e Objetividade	A IA, através da técnica *Deep Learning*, permite a avaliação de forma objetiva, automática e com baixo custo.	Substituem a análise tradicional sujeita a erro humano, fornecendo resultados de inspeção mais precisos e confiáveis.
Detecção e Classificação Avançada (*Deep Learning*)	Modelos como Faster R-CNN, VGG16, ResNet50 e meta-learning são empregados.	Classificação automática de defeitos como fissuras, descolamento e exposição de armadura.
	Técnicas como U-Net e Instance Segmentation identificam defeitos em nível de pixel.	Crucial para quantificar a localização e a morfologia dos danos.

	Estruturas de *Deep Learning* mais avançadas integram conhecimento de engenharia para forçar a detecção de elementos de fachada (como janelas e portas).	Superando limitações de modelos baseados apenas em dados visuais.
Integração de Dados	Fusão de imagens visíveis e infravermelhas	Essencial especialmente para patologias que se estendem pela profundidade do material (umidade e descolamento).
Quantificação de Danos	Em rachaduras, os sistemas de visão computacional podem quantificar precisamente a geometria do dano.	São parâmetros críticos em normas de engenharia para avaliar a severidade.
Priorização (Previsão de Danos)	Redes neurais podem ser aplicadas para prever processos de deterioração.	A exemplo do crescimento de microalgas, integrando dados experimentais e ambientais (como chuva, porosidade e rugosidade do material).
Gestão da informação	Integração BIM:O uso de laser scanners e fotogrametria com VANTs alimenta a metodologia Scan to BIM.	Permite o gerenciamento integrado dos dados de inspeção (localização, tipo, causa e custos de reparo) em um modelo 3D visual, superando a ineficiência dos relatórios baseados em papel.

Fonte: Autores.

RESULTADOS DO ESTUDO DE CASO

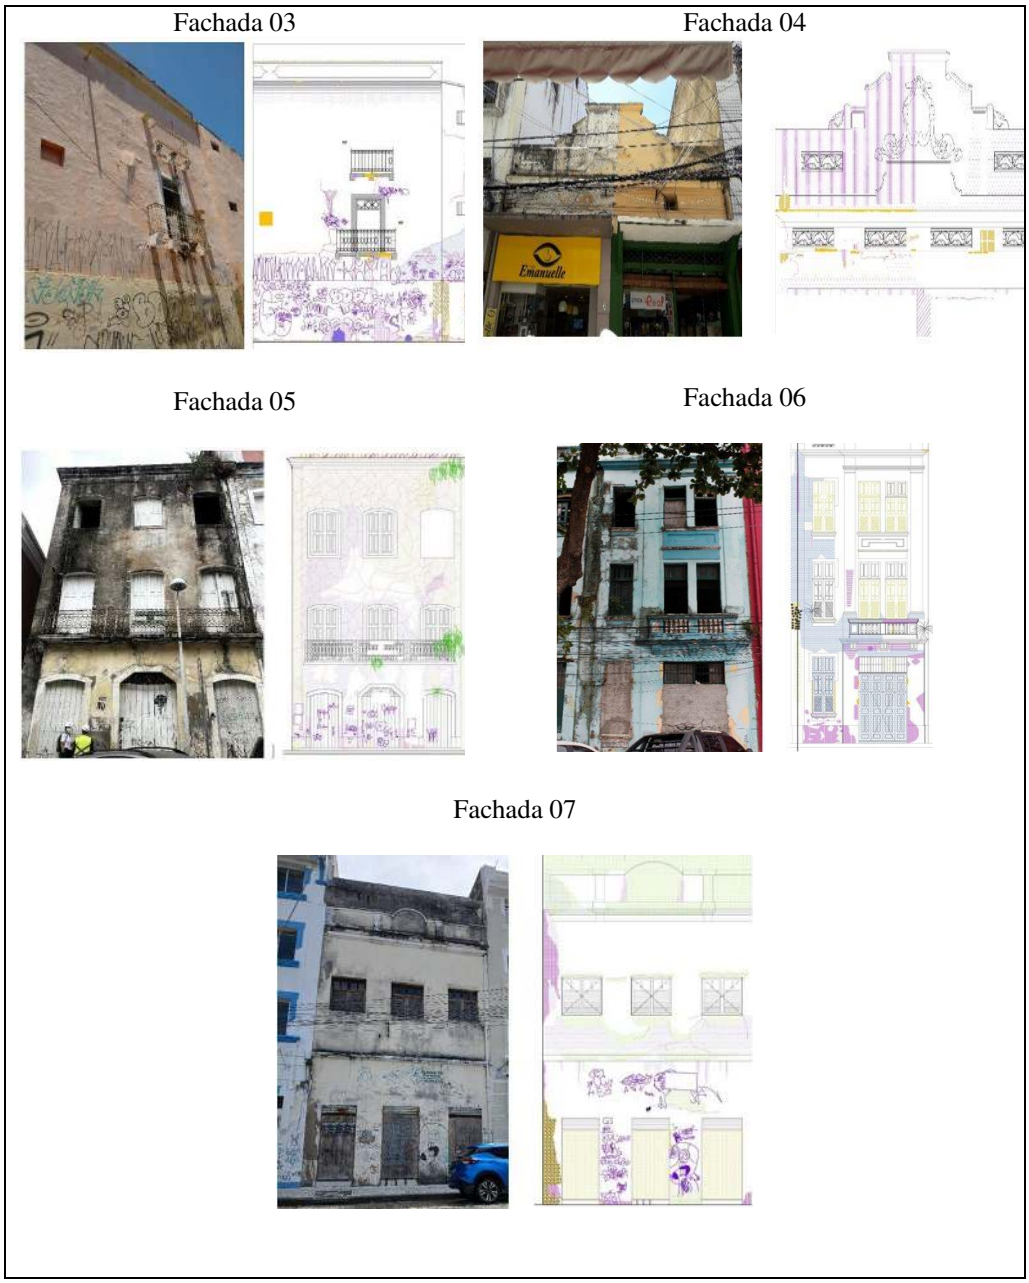
O estudo foi realizado utilizando como base sete fotos de fachadas de imóveis restaurados na cidade do Recife (PE). Buscando-se avaliar a confiabilidade das interpretações das ferramentas de inteligência artificial Chatgpt e Gemini com relação aos mapas de danos convencionais.

A Figura 5 apresenta as fotos das fachadas selecionadas para o estudo e seus respectivos mapas de danos.

Figura 5: Imagens selecionadas



DOI: https://doi.org/10.46421/entac.v21i1.8469



Fonte: Autores.

Para apresentação do estudo de caso, foi selecionado a fachada 02 para discussão dos resultados.

Os resultados das análises feitas nas duas plataformas de I.A., Gemini e Chatgpt, se basearam em seis questões objetivas e, como referência, a utilização da norma italiana 1/88 [36] e lessico de Negri e Russo (2008) [37], já que foram os mesmos critérios utilizados para a realização dos mapas de danos convencionais.

ANÁLISE DA FACHADA 02

Através da Figura 6 é possível constatar as diferenças nas representações.

Figura 6: Fachada 02 com mapa de danos convencional (à esquerda) e como apresentado pelo Chatgpt (imagem à direita)



Fonte: Autores.

A Figura 7 apresenta a tabela de identificação de manifestações patológicas geradas com a análise da plataforma Chatgpt.

Figura 7: Identificação de manifestações patológicas geradas com a análise da plataforma Chatgpt

	Patológica 1	Patológica 2	Patológica 3	Patológica 4
Tópico	**Umidade ascendente e manchas de sujidade (🔵)**	**Descolamento e destacamento do revestimento (🟡)**	**Perda de material e exposição do substrato (🟥)**	**Fissuras e microfissuras (🟠)**
Identificação Visual (Cores Atribuídas)	(🔵 Azul) Áreas escuras e úmidas na parte inferior da fachada, com manchas e eflorescências próximas ao solo.	(🟡 Amarelo) Descolamentos e bolhas do revestimento nas faixas intermediárias e próximas aos vãos	(🟥 Vermelho) Trechos com perda total do revestimento, expondo o substrato de alvenaria e argamassa antiga.	(🟠 Laranja) Fissuras finas verticais e irregulares próximas às bordas e transições de materiais.
Descrição da manifestação	Manchas escuras e desagregação superficial por ação contínua da umidade ascendente e respingos de chuva.	Destacamentos parciais e perda de aderência do revestimento de argamassa ou pintura.	Áreas onde o revestimento já se desprendeu totalmente, deixando o substrato aparente	Aberturas lineares sutis indicando movimentação do substrato ou retração da argamassa.
Prováveis Causas/Mecanismos de Origem	Umidade ascendente capilar proveniente do solo; ausência de barreira de impermeabilização na base das paredes.	Perda de aderência devido a ciclos de umedecimento e secagem, envelhecimento dos materiais e má aderência inicial.	Avanço do destacamento, lavagem superficial e ausência de manutenção; degradação por umidade e impacto mecânico.	Movimentação higrotérmica, retração da argamassa, esforços diferenciais próximos a aberturas e juntas.
Grau de Severidade (Padrão G.U.T.)	**Gravidade: 4** – degradação do desempenho e estética. **Urgência: 4** – pode evoluir com chuvas. **Tendência: 5** – tende a se ampliar.	**Gravidade: 5** – risco de destacamento e perda de proteção. **Urgência: 4** – deve ser corrigido para evitar infiltrações. **Tendência: 4** –	**Gravidade: 5** – exposição direta do substrato à ação da água e sais. **Urgência: 5** – requer intervenção imediata.	**Gravidade: 3** – dano localizado. **Urgência: 3** – requer selagem e monitoramento. **Tendência: 3** –
Severidade (clas. geral)	**Alta**	**Alta**	**Muito Alta**	**Moderada**
Risco de evolução	Alto — manutenção da umidade causa perda de aderência e eflorescência.	Alto — destacamentos podem se expandir e atingir áreas adjacentes.	Crítico — degradação acelerada e infiltração direta no substrato.	Médio — possível ampliação se não tratada.
Recomendações Técnicas	-Instalar barreira física ou química contra umidade ascendente. - Limpeza com jato de baixa pressão. - Aplicação de revestimento hidrofugante respirável. - Rejuntamento inferior com argamassa de baixa retração.	- Remover o revestimento solto e refazer com argamassa compatível (traço tradicional à base de cal e areia). - Aplicar fundo preparador e pintura mineral.	- Reconstituição das camadas de argamassa e acabamento, compatíveis com o substrato original. - Verificar condições estruturais e de aderência.	- Selagem das fissuras com argamassa fina ou selante acrílico compatível. - Monitorar evolução.
Confiança da Análise	Alta	Alta	Alta	Média

Fonte: Autores.

Com relação ao uso da plataforma Gemini, apresentado no Figura 8, destaca-se uma falha com a interpretação da existência de uma fissura vertical em um item que se tratava de uma fiação elétrica.

Figura 8: Identificação de manifestações patológicas geradas com a análise da plataforma Gemini.

	Manifestação Patológica 1	Manifestação patológica 2	Manifestação patológica 3
Tópico	Descolamento e Queda de Revestimento (Buraco na Parede)	Fissura/Fratura Vertical	Manchas/Alteração Cromática (Pichação/Graffiti)
Identificação Visual (Cores Atribuídas)	**Cor do Substrato Exposto (Marrom/Bege Escuro):** Ausência total da argamassa e exposição do tijolo/estrutura interna, principalmente no térreo e ao redor do vão.	**Linha Escura Vertical:** Se estende do topo à base da edificação, passando pelo vão superior e inferior, visível na cor do revestimento (salmão/rosa pálido).	**Cores Variadas e Escuras (Preto, Azul, Laranja, Amarelo):** Tinta em spray e pincel sobre a argamassa.
Termo Técnico NorMaL 1/88	**Mancanza / Lacuna** (Ausência de material/Revestimento perdido)	**Fratturazione / Fessurazione** (Fratura/Fissura)	**Macchia** (Mancha) devido a **Atti di Vandalismo** (Atos de Vandalismo)
Prováveis Causas/Mecanismos de Origem	**Intrínsecas/Mecânicas:** Falha de aderência da argamassa ao substrato, combinada com infiltração de água, presença de sais solúveis (eflorescência) e, possivelmente, ação mecânica (impacto ou vandalismo).	**Estruturais/Térmicas:** Movimentação estrutural (assentamento diferencial, recalque) ou grandes variações térmicas que causam dilatação e retração excessivas.	**Causas Externas (Vandalismo):** Aplicação intencional de tintas sobre o revestimento da fachada.
Grau de Severidade (Padrão G.U.T.)	**Severidade (S): 4 (Colapso Parcial/Degradação Extrema):** O material (revestimento) se perdeu e expôs o substrato, permitindo a infiltração direta.	**Severidade (S): 3 (Extensa/Profunda):** A fissura é contínua e percorre toda a altura do pano de parede, indicando ser profunda e potencialmente estrutural.	**Severidade (S): 3 (Extensa/Profunda):** Cobre a maior parte da área inferior e central do revestimento.
Risco de Evolução (E)	**Risco (E): 3 (Alto):** A exposição do substrato leva à rápida degradação por intempéries, com potencial para queda de mais material e comprometimento do substrato (alvenaria).	**Risco (E): 3 (Alto):** Fissuras profundas podem ser indicativas de falha estrutural e, certamente, são canais diretos de infiltração de água para o interior da edificação.	**Risco (E): 1 (Baixo):** Não degrada o material rapidamente, mas o esforço de limpeza pode danificar a argamassa remanescente.
Urgência (U)	**Urgência (U): 3 (Intervenção Imediata):** Necessidade de recomposição da barreira de proteção imediatamente.	**Urgência (U): 3 (Intervenção Imediata):** Exige monitoramento e tratamento urgente (infiltração e risco estrutural).	**Urgência (U): 1 (Programável):** Pode ser tratada após as patologias que comprometem a integridade do material.
Recomendações Técnicas	**Recomposição e Tratamento:** Remoção da argamassa remanescente solta, limpeza do substrato, tratamento de sais (se houver) e aplicação de nova argamassa de revestimento compatível	**Monitoramento e Injeção:** Vedar a fissura (superfície), monitorar a sua evolução. Se for estrutural, realizar tratamento (injeção de resinas) após estabilização da causa-raiz.	**Limpeza e Proteção:** Remoção da tinta com produtos compatíveis e aplicação de pintura final ou protetor anti-grafite.
Confiança da Análise	**Alta:** A ausência de material é inquestionável.	**Média:** A presença é clara, mas a causa (estrutural ou superficial) só se confirma com inspeção *in loco* (calibradores e testes).	**Alta:** Evidente, cobrindo visualmente a área.

Fonte: Autores.

Com base nas análises realizadas, no que se refere às manifestações em manchas, umidade, biológicas e pichações, o Gemini e o Chatgpt fizeram recomendações semelhantes. Em relação aos danos físicos como fissuras, trincas e desplacamentos, nas recomendações são sugeridas medidas que podem ser recomendáveis e não recomendáveis, preconizando o conceito da reversibilidade com o objetivo que a técnica de correção utilizada não agrave ou resultem em novos danos.

As plataformas apresentaram ainda a escala G.U.T. com precisão, sendo observado que o Chatgpt apresentou avaliações consideradas mais graves.

CONCLUSÃO

A combinação das abordagens digitais resulta em soluções mais confiáveis, objetiva e segura para o diagnóstico e monitoramento contínuo das fachadas, sendo uma alternativa eficiente em termos de custo e tempo em comparação com a inspeção tradicional.

Através das fontes pesquisadas é possível concluir que as tecnologias digitais são utilizadas com foco na fase do levantamento de dados e a inteligência artificial atua no processamento e automatização do diagnóstico.

Com relação as análises das manifestações patológicas das fachadas de imóveis de restauro, conclui-se que o uso das plataformas ainda não apresenta confiabilidade suficiente para identificação através de fotos, sendo recomendável a continuidade da elaboração dos mapas de danos *in loco* e de forma convencional. Foi possível constatar a dificuldade na percepção de tridimensionalidade nas imagens fornecidas e a interpretação do contraste de luz e sombra como sendo manifestações patológicas.

Como proposta de perspectivas para novos estudos, pode-se destacar a necessidade do desenvolvimento de uma inteligência artificial ensinada e específica para a elaboração de mapas de danos e interpretações de manifestações patológicas através de imagens, além da necessidade da formação dos engenheiros e arquitetos frente à crescente desta demanda.

Declaração

Durante a preparação deste artigo, o primeiro e segundo autores utilizaram as ferramentas Chatgpt e Gemini como objeto de método de estudo para avaliar a capacidade interpretativa ao analisar manifestações patológicas utilizando fotos de fachadas de imóveis de restauro. Após a utilização das ferramentas, os autores revisaram e editaram o conteúdo conforme necessário e assumem total responsabilidade pelo conteúdo do artigo publicado.

REFERÊNCIAS

[1] Ribeiro, D. A. C. Tecnologias advindas da Indústria 4.0 aplicada na construção civil: efeitos e desafios da implantação no Brasil. 2019. Trabalho de Conclusão de Curso (Graduação em Engenharia Civil) – **Universidade Federal de Ouro Preto**, Ouro Preto, 2019.

[2] Instituto brasileiro de geografia e estatística. Produto Interno Bruto – PIB 2023: resultados preliminares. Rio de Janeiro: **IBGE**, 2024.

[3] Rodrigues, B. N. *et al.* Digital survey applied to the assessment of pathological manifestations in the architectural heritage of Monte Alegre in Piracicaba/SP. **Journal of Building Pathology and Rehabilitation**, [*S. l.*], v. 8, n. 1, p. 60, jun. 2023, https://doi.org/10.1007/s41024-023-00306-1.

[4] Liang, H. *et al.* Automated filtering of façade defect images using a similarity method for enhanced inspection documentation. **Building Research & Information**, [*S. l.*], v. 52, n. 1–2, p. 194–206, 17 fev. 2024, https://doi.org/10.1080/09613218.2023.2282567.

[5] Guo, J.; Wang, Q.; Li, Y. Evaluation-oriented façade defects detection using rule-based deep learning method. **Automation in Construction**, [*S. l.*], v. 131, p. 103910, nov. 2021, https://doi.org/10.1016/j.autcon.2021.103910.

[6] Lin, T.-H.; Chiang, P.-C.; Putranto, A. Multispecies hybrid bioinspired climbing robot for wall tile inspection. **Automation in Construction**, [*S. l.*], v. 164, p. 105446, ago. 2024, https://doi.org/10.1016/j.autcon.2024.105446.

[7] Bersch, J. D. *et al.* Diagnosis of Pathological Manifestations and Characterization of the Mortar Coating from the Facades of Historical Buildings in Porto Alegre — Brazil: A Case Study of Château and Observatório Astronômico. **International Journal of Architectural Heritage**, [*S. l.*], v. 15, n. 8, p. 1145–1169, 3 ago. 2021, https://doi.org/10.1080/15583058.2020.1771475.

[8] Interlando, M. *et al.* Ensembles of Deep Neural Networks for the Automatic Detection of Building Facade Defects From Images. **IEEE Access**, [*S. l.*], v. 12, p. 164953–164965, 2024, https://doi.org/10.1109/ACCESS.2024.3494550.

[9] He, S. *et al.* Weakly-aligned cross-modal learning framework for subsurface defect segmentation on building façades using UAVs. **Automation in Construction**, [*S. l.*], v. 170, p. 105946, fev. 2025, https://doi.org/10.1016/j.autcon.2024.105946.

[10] Ruiz, R. D. B. *et al.* Unmanned aerial vehicles (UAV) as a tool for visual inspection of building facades in AEC+FM industry. **Construction Innovation**, [*S. l.*], v. 22, n. 4, p. 1155–1170, 28 nov. 2022, https://doi.org/10.1108/CI-07-2021-0129.

[11] Page, Matthew J. *et al.* The PRISMA 2020 statement: an updated guideline for reporting systematic reviews**. bmjl,** v. 372, 2021, https://doi.org/10.1136/bmj.n71.

[12] Moradi, N.; Gorji Kandi, S.; Yahyaei, H. A new approach for detecting and grading blistering defect of coatings using a machine vision system. **Measurement**, [*S. l.*], v. 203, p. 111954, nov. 2022, https://doi.org/10.1016/j.measurement.2022.111954.

[13] Shin, H.; Lee, S. An Efficient Explainable Convolutional Network with Visualization of Feature Maps for Enhanced Understanding of Building Facade Defects. **Journal of Computing in Civil Engineering**, [*S. l.*], v. 38, n. 5, p. 04024024, set. 2024, https://doi.org/10.1061/JCCEE5.CPENG-5857.

[14] Kang, S.; Kim, S.; Kim, S. Improvement of the defect inspection process of deteriorated buildings with scan to BIM and image-based automatic defect classification. **Journal of Building Engineering**, [*S. l.*], v. 99, p. 111601, abr. 2025, https://doi.org/10.1016/j.jobe.2024.111601.

[15] Zheng, S. *et al.* A method for quantitatively evaluating the impact of defects on wall U-value using infrared thermal imaging. **Building Simulation**, [*S. l.*], v. 18, n. 2, p. 281–293, fev. 2025, https://doi.org/10.1007/s12273-024-1213-7.

[16] Franzoni, E.; Bassi, M. A new sensorized ceramic plug for the remote monitoring of moisture in historic masonry walls: First results from laboratory and onsite testing. **Structural Control and Health Monitoring**, [*S. l.*], v. 29, n. 12, dez. 2022, https://doi.org/10.1002/stc.3126.

[17] Ishikawa, M. *et al.* Active Thermography Inspection of Surface-whitened Mortars – Measurement of Surface Spectral Absorptivity for Investigation of Efficient Heating Light Wavelengths. **Journal of Nondestructive Evaluation**, [*S. l.*], v. 43, n. 1, p. 7, mar. 2024, https://doi.org/10.1007/s10921-023-01026-9.

[18] Wang, P.; Xiao, J.; *et al.* An automatic building façade deterioration detection system using infrared-visible image fusion and deep learning. **Journal of Building Engineering**, [*S. l.*], v. 95, p. 110122, out. 2024, https://doi.org/10.1016/j.jobe.2024.110122.

[19] Ferreira, J. A. D. S. *et al.* Assessment of Staining Patterns in Facades Using an Unmanned Aerial Vehicle (UAV) and Infrared Thermography. **Drones**, [*S. l.*], v. 8, n. 10, p. 542, 1 out. 2024, https://doi.org/10.3390/drones8100542.

[20] Xu, S. *et al.* Assessment of geometric parameters of segmented crack on concrete building facade using deep learning. **Structures**, [*S. l.*], v. 57, p. 105188, nov. 2023, https://doi.org/10.1016/j.istruc.2023.105188.

[21] Dinardo, G. *et al.* Automatic defect detection and characterization by thermographic images based on damage classifiers evaluation. **Metrology and Measurement Systems**, [*S. l.*], , p. 219–242, 9 mar. 2020, https://doi.org/10.24425/mms.2020.132771.

[22] Lee, K.; Lee, S.; Kim, H. Y. Bounding-box object augmentation with random transformations for automated defect detection in residential building façades. **Automation in Construction**, [*S. l.*], v. 135, p. 104138, mar. 2022, https://doi.org/10.1016/j.autcon.2022.104138.

[23] Jiang, Y.; Han, S.; Bai, Y. Building and Infrastructure Defect Detection and Visualization Using Drone and Deep Learning Technologies. **Journal of Performance of Constructed Facilities**, [*S. l.*], v. 35, n. 6, p. 04021092, dez. 2021, https://doi.org/10.1061/(ASCE)CF.1943-5509.0001652.

[24] Zhang, G.; Pan, Y.; Zhang, L. Deep learning for detecting building façade elements from images considering prior knowledge. **Automation in Construction**, [*S. l.*], v. 133, p. 104016, jan. 2022, https://doi.org/10.1016/j.autcon.2021.104016.

[25] Cui, Z. *et al.* Few-shot classification of façade defects based on extensible classifier and contrastive learning. **Automation in Construction**, [*S. l.*], v. 141, p. 104381, set. 2022, https://doi.org/10.1016/j.autcon.2022.104381.

[26] Wang, P.; Wang, J.; *et al.* Fusion-Based Damage Segmentation for Multimodal Building Façade Images from an End-to-End Perspective. **Buildings**, [*S. l.*], v. 15, n. 1, p. 63, 27 dez. 2024, https://doi.org/10.3390/buildings15010063.

[27] D'Orazio, M.; Quagliarini, E.; Gianangeli, A. Influence of the rain on algae growth on building facades. A predictive model based on neural networks. **Building and Environment**, [*S. l.*], v. 246, p. 110990, dez. 2023, https://doi.org/10.1016/j.buildenv.2023.110990.

[28] Chen, J. *et al.* Infrared thermography of façade delamination: Quantifying environmental variability and heat transfer mechanisms. **Construction and Building Materials**, [*S. l.*], v. 494, p. 143177, out. 2025, https://doi.org/10.1016/j.conbuildmat.2025.143177.

[29] Yu, R. *et al.* Multi-feature driven rapid inspection of earthquake-induced damage on building facades using UAV-derived point cloud. **Measurement**, [*S. l.*], v. 232, p. 114679, jun. 2024, https://doi.org/10.1016/j.measurement.2024.114679.

[30] Diz-Mellado, E. *et al.* Non-destructive testing and Finite Element Method integrated procedure for heritage diagnosis: The Seville Cathedral case study. **Journal of Building Engineering**, [*S. l.*], v. 37, p. 102134, maio 2021, https://doi.org/10.1016/j.jobe.2020.102134.

[31] Guedes, J. V. F. *et al.* Performance of Sensors Embedded in UAVs for the Analysis and Identification of Pathologies in Building Façades. **Buildings**, [*S. l.*], v. 15, n. 6, p. 875, 12 mar. 2025, https://doi.org/10.3390/buildings15060875.

[32] Mandinec, J.; Sasic Kalagasidis, A.; Johansson, P. Predicting façade deterioration using machine learning approach with drone imagery and microclimate data. **Automation in Construction**, [*S. l.*], v. 178, p. 106443, out. 2025, https://doi.org/10.1016/j.autcon.2025.106443.

[33] Hashimoto, K.; Shiotani, T. Sonic-IR imaging technique for detection of crack interfaces in cementitious materials. **Construction and Building Materials**, [*S. l.*], v. 386, p. 131549, jul. 2023, https://doi.org/10.1016/j.conbuildmat.2023.131549.

[34] De Souza Silva, M.; Bauer, E. Thermographic evaluation of cracks of different formats in rendered facades. **Journal of Building Engineering**, [*S. l.*], v. 98, p. 111342, dez. 2024, https://doi.org/10.1016/j.jobe.2024.111342.

[35] Barbosa, M. T. G.; Rosse, V. J.; Laurindo, N. G. Thermography evaluation strategy proposal due moisture damage on building facades. **Journal of Building Engineering**, [*S. l.*], v. 43, p. 102555, nov. 2021, https://doi.org/10.1016/j.jobe.2021.102555.

[36] Instituto centrale per il restauro. Norma – 1/88 Alterazioni Macroscoche dei Materiali Lapidei**:** Lessico. Roma: **CNR-ICR**, 1990.

[37] Negri, A.; Russo, J.- Degrado dei materiali lapedi: Proposta di simbologia grafica. In.: Carbonara, Giovanni: trattato di restauro architettonic, Secondo Aggiornamento. **Grandi temi de Restauro**, Utet: Torino, 2008.