

Detecção de Anomalias em Pavimentos Rodoviários com Inteligência Artificial: Uma Visão Geral

Pedro Martins Bittencourt¹, Sávio Salvarino Teles de Oliveira¹,
Lucas Araújo Pereira¹, Anderson da Silva Soares¹

¹ Instituto de Informática – Universidade Federal de Goiás (UFG)
74.690-900 – Goiânia – Goiás – Brasil

bittencourtpedro@discente.ufg.br
{savioteles, apereiral, andersonsoares}@ufg.br

Abstract. *The deterioration of paved road infrastructure represents a significant challenge for transportation safety, economic efficiency, and the management of maintenance resources. In this context, the use of computer vision and artificial intelligence (AI) techniques, especially deep learning, has emerged as a promising alternative to automate the detection and classification of pavement anomalies such as potholes, cracks, and patches. This paper presents an overview to identify and categorize the state-of-the-art AI-based methodologies applied to highway damage detection. The study provides a detailed analysis of the most commonly used datasets, types of anomalies addressed, algorithmic approaches employed, and performance evaluation strategies.*

Resumo. *A deterioração da infraestrutura rodoviária pavimentada representa um desafio significativo para a segurança no transporte, a eficiência econômica e a gestão de recursos destinados à manutenção. Nesse cenário, o uso de técnicas de visão computacional e inteligência artificial (IA), especialmente o aprendizado profundo (deep learning), tem se destacado como uma alternativa promissora para automatizar a detecção de anomalias em pavimentos. Este artigo apresenta uma visão geral com o objetivo de identificar e categorizar o estado da arte em metodologias baseadas em IA aplicadas à detecção de danos em rodovias.*

1. Introdução

A infraestrutura rodoviária é um pilar fundamental para o desenvolvimento socioeconômico, viabilizando o transporte de pessoas e bens [Zhu et al. 2022]. Contudo, a constante exposição a cargas de tráfego e a fatores ambientais leva a uma deterioração progressiva dos pavimentos asfálticos [Chen and Fu 2025, Mahmud et al. 2024]. Anomalias como trincas e buracos são as manifestações mais comuns desse processo de degradação [Chun et al. 2021, Deng et al. 2022, Zhu et al. 2022] e representam uma ameaça direta à segurança dos motoristas, além de elevarem os custos de manutenção veicular e logística [Zhu et al. 2022, Park and Nguyen 2025].

Tradicionalmente, a inspeção de pavimentos é realizada por meio de avaliações visuais manuais [Chun et al. 2021, Buza et al. 2017]. Este método, embora direto, é intensivo em mão de obra, lento, subjetivo e potencialmente perigoso para os inspetores [Dong et al. 2022, Chen and Fu 2025, Buza et al. 2017]. A subjetividade das avaliações

humanas pode levar a inconsistências na classificação dos danos, afetando a priorização e a eficácia das ações de manutenção [Park and Nguyen 2025, Dong et al. 2022].

Para superar essas limitações, a comunidade científica e a indústria têm se voltado para soluções automatizadas baseadas em visão computacional e aprendizado profundo (deep learning) [Dong et al. 2022, Mahmud et al. 2024]. Essas tecnologias oferecem o potencial para inspeções mais rápidas, objetivas, seguras e econômicas [Deng et al. 2022, Wang et al. 2025]. Abordagens baseadas em Redes Neurais Convolucionais (CNNs) tornaram-se o padrão para tarefas de classificação de imagens, detecção de objetos e segmentação de anomalias em pavimentos [Chun et al. 2021, Zhu et al. 2022, Dong et al. 2022]. Modelos como YOLO (You Only Look Once) [Redmon et al. 2016], Faster R-CNN [Ren et al. 2015] e SSD (Single Shot MultiBox Detector) [Liu et al. 2016] são frequentemente empregados para localizar defeitos, enquanto arquiteturas como U-Net [Ronneberger et al. 2015] e SegNet [Badrinarayanan et al. 2017] permitem a delimitação precisa em nível de pixel, essencial para uma avaliação quantitativa dos danos [Zhu et al. 2022, Deng et al. 2022, Wang et al. 2025].

A aquisição de dados visuais também evoluiu, com o uso crescente de câmeras acopladas a veículos, smartphones e, mais notavelmente, Veículos Aéreos Não Tripulados (VANTs ou drones), que oferecem alta manobrabilidade e custo-benefício para a coleta de imagens de alta resolução [Zhu et al. 2022, Mahmud et al. 2024].

Este artigo apresenta uma visão geral que investiga o estado da arte das metodologias de detecção de anomalias em pavimentos utilizando inteligência artificial. O objetivo é analisar e sintetizar os métodos de aquisição de dados, as arquiteturas de deep learning empregadas, as métricas de avaliação e os desafios persistentes, fornecendo um panorama consolidado das tendências e lacunas na pesquisa atual.

2. Método da Pesquisa

Este estudo foi conduzido sob a forma de um Mapeamento Sistemático da Literatura, com o objetivo de organizar e analisar a produção científica recente sobre o uso de inteligência artificial na detecção de anomalias em pavimentos.

2.1. Questões de Pesquisa

As questões de pesquisa foram formuladas com o objetivo de orientar este mapeamento, buscando compreender, em primeiro lugar, quais são os principais métodos de aquisição de dados visuais (imagens) empregados na detecção de anomalias em pavimentos. Além disso, pretende-se identificar quais modelos e arquiteturas de deep learning têm sido mais utilizados para a detecção e/ou segmentação de trincas e buracos. Outro aspecto de interesse é levantar as métricas de desempenho comumente adotadas para avaliar a eficácia dos modelos propostos. Por fim, também se busca explorar os principais desafios, limitações e direções futuras apontados na literatura.

2.2. Palavras-chave e Bases de Busca

A definição da string de busca considerou termos relacionados a defeitos em pavimentos e técnicas de visão computacional baseadas em aprendizado profundo. Foram incluídas combinações como “pavement damage”, “road defect”, “pothole detection” e “crack detection” associadas a descritores como “deep learning”, “CNN”, “transformer” e “computer vision”. A busca foi conduzida em bases digitais de referência na área de ciência

da computação e engenharia como ACM Digital Library, IEEE Xplore, ScienceDirect e Scopus.

2.3. Critérios de Inclusão e Exclusão

Para garantir relevância e consistência, foram estabelecidos critérios de inclusão que privilegiaram artigos publicados a partir de 2017, com foco em métodos de aquisição baseados em câmeras e que tratassem explicitamente da detecção de trincas ou buracos. Foram selecionados apenas estudos completos em conferências ou periódicos. Excluíram-se trabalhos publicados antes de 2017, pesquisas que utilizassem sensores primários distintos de câmeras, estudos que não abordassem trincas ou buracos como foco central.

2.4. Execução da Revisão

A busca inicial com a string definida retornou um grande volume de artigos. Após a aplicação dos critérios de inclusão e exclusão com base na leitura de títulos e resumos, um conjunto menor foi selecionado para análise completa. Deste conjunto, os artigos base para este mapeamento foram identificados como altamente relevantes e representativos das diferentes abordagens e desafios na área, sendo a base para as análises apresentadas nas seções seguintes.

3. Métodos Identificados

Esta seção consolida os resultados da análise dos artigos selecionados, respondendo às questões de pesquisa propostas.

3.1. Aquisição e Processamento de Dados

A aquisição de dados é a etapa inicial e fundamental. A literatura evidencia uma transição de veículos de inspeção especializados e caros [Dong et al. 2022] para métodos mais acessíveis e flexíveis. A abordagem mais presente é o uso de câmeras montadas em veículos [Chen and Fu 2025, Dong et al. 2022] ou sistemas portáteis. Neste último caso, [Park and Nguyen 2025] desenvolveram uma técnica com duas câmeras e uma luz laser em um dispositivo portátil, projetado para medir não apenas a área, mas também a profundidade dos buracos em tempo real. Este método se destaca pelo baixo custo e alta flexibilidade [Park and Nguyen 2025].

Outra abordagem encontrada foi o uso de Veículos Aéreos Não Tripulados (VANTs), destacada por sua eficiência de custo, segurança e capacidade de cobrir grandes áreas rapidamente [Zhu et al. 2022, Mahmud et al. 2024]. Estudos como os de [Zhu et al. 2022] e [Mahmud et al. 2024] utilizam VANTs equipados com câmeras de alta resolução. Parâmetros de voo, como a altitude, são cruciais para a qualidade da imagem. Altitudes menores, como 10 metros, fornecem imagens mais nítidas das trincas [Mahmud et al. 2024], enquanto altitudes maiores, como 30 metros, são necessárias para cobrir a largura de múltiplas faixas e evitar obstáculos [Zhu et al. 2022].

Independentemente do método de captura, as imagens de alta resolução geralmente precisam ser pré-processadas. Uma prática observada foi a de dividir as imagens originais em blocos menores (ex: 512x512 pixels) para otimizar o uso de recursos computacionais [Zhu et al. 2022, Wang et al. 2025, Dong et al. 2022]. Além disso, técnicas de aumento de dados (data augmentation) são aplicadas para aumentar a diversidade do

conjunto de dados [Mahmud et al. 2024]. A anotação das imagens, seja por caixas delimitadoras ou máscaras de segmentação, é uma etapa crítica e trabalhosa, especialmente para a segmentação em nível de pixel [Zhu et al. 2022, Wang et al. 2025].

3.2. Conjuntos de Dados

Alguns conjuntos de dados públicos apoiam a pesquisa em detecção de danos em pavimentos, variando desde bases focadas em um único tipo de anomalia até coleções que abrangem múltiplas deficiências. Entre os mais abrangentes estão os Road Damage Datasets (RDD 2018–2022) [Maeda et al. 2018, Maeda et al. 2021, Arya et al. 2021, Arya et al. 2024], que contêm imagens de ruas de diversos países com anotações de trincas e buracos, os GAPs [Eisenbach et al. 2017, Stricker et al. 2019, Stricker et al. 2021], com imagens de rodovias da Alemanha anotadas com trincas, buracos, remendos e outras classes. Para o estudo específico de fissuras, existem conjuntos de dados menores e mais especializados, como Crack500 [Zhang et al. 2016, Yang et al. 2019], CFD [Shi et al. 2016] e CrackTree260 [Zou et al. 2012], que contêm um número menor de imagens focadas em padrões finos de rachaduras. Adicionalmente, bases como SH-REC2022 [Moscoso Thompson et al. 2022] oferecem dados mais ricos, capturando diversos tipos de defeitos e incluindo informações de profundidade.

3.3. Modelos e Arquiteturas de Deep Learning

Os artigos analisados empregam uma variedade de modelos de deep learning. A literatura faz uma distinção clara entre a detecção de objetos, que localiza anomalias dentro de uma caixa delimitadora [Zhu et al. 2022], e a segmentação, que identifica os pixels exatos que pertencem à anomalia [Deng et al. 2022, Wang et al. 2025]. A abordagem de segmentação é particularmente crucial para análises quantitativas, como o cálculo preciso de área e volume das irregularidades [Park and Nguyen 2025, Dong et al. 2022].

A Tabela 1 apresenta uma síntese dos principais estudos sobre detecção de anomalias em pavimentos, destacando tipos de defeitos, fontes de dados e arquiteturas utilizadas.

Tabela 1. Síntese dos estudos sobre detecção de anomalias em pavimentos.

Estudo	Tipo de Anomalia	Fonte de Dados	Arquitetura / Método
[Akagic et al. 2017]	Buracos	Imagens RGB	Segmentação no espaço de cores
[Buza et al. 2017]	Danos de alta severidade	Pavimentos asfaltados	Clustering / superpixels (não supervisionado)
[Chun et al. 2021]	Trincas e buracos	MMS (Mobile Mapping System)	CNN + GIS
[Dong et al. 2022]	Trincas, buracos, remendos	Veículo com câmeras móveis	Classificação → segmentação → avaliação de severidade

Tabela 1 – Continuação

Estudo (título original)	Tipo de Anomalia	Fonte de Dados	Arquitetura / Método
[Mahmud et al. 2024]	Trincas	UAV/drones (10 m)	YOLOv4 (vs YOLOv3, Faster R-CNN, SSD)
[Deng et al. 2022]	Trincas	Imagens locais	YOLOv5 + ramo de segmentação
[Widodo et al. 2024]	Buracos (detecção + medidas)	RGB + sensor de profundidade Intel RealSense	YOLOv8 + estimativa geométrica
[Wang et al. 2025]	Trincas	Imagens de rodovias urbanas	ShuttleNetS3 + convoluções deformáveis
[Chen and Fu 2025]	Trincas (vídeo)	Vídeos rodoviários (1280×720)	Segmentação de instâncias + atenção ECA

Dentro das arquiteturas de detecção, a família de modelos YOLO é proeminente devido ao seu excelente equilíbrio entre velocidade e precisão [Deng et al. 2022]. Os estudos comparam e utilizam diferentes versões da arquitetura: [Zhu et al. 2022] constataram que o YOLOv3 teve um desempenho superior para seu conjunto de dados, com um mAP de 56,6%, enquanto [Mahmud et al. 2024] verificaram que o YOLOv4 superou o YOLOv3 em seus experimentos. Versões mais recentes como YOLOv5 e YOLOv8 também são mencionadas como base para o desenvolvimento de modelos de segmentação de instância [Deng et al. 2022, Park and Nguyen 2025].

Para obter detalhes em nível de pixel, modelos de segmentação mais específicos são essenciais. [Dong et al. 2022] propõem um sistema que primeiro classifica a imagem e, em seguida, a envia para um modelo de segmentação refinado com módulos de atenção (GAM). De forma similar, [Wang et al. 2025] apresentam o ShuttleNetS3, uma rede avançada que utiliza convoluções deformáveis (DCNv4) para detectar com extrema precisão múltiplas anomalias simultaneamente.

Em contraste com a maioria das abordagens supervisionadas, alguns estudos exploram métodos não supervisionados. [Buza et al. 2017] e [Akagic et al. 2017] propõem técnicas que utilizam processamento de imagem e clustering para extrair a superfície do asfalto e identificar buracos sem a necessidade de um conjunto de dados de treinamento pré-annotado, o que reduz a dependência da custosa etapa de anotação manual.

3.4. Métricas de Desempenho

A avaliação dos modelos é realizada com um conjunto padronizado de métricas. As mais comuns para tarefas de detecção são a Precisão (Precision), Revocação (Recall) e o F1-Score [Mahmud et al. 2024, Chen and Fu 2025]. Para medir o desempenho geral,

a Precisão Média (AP) e a Precisão Média Média (mAP) são utilizadas como padrão [Mahmud et al. 2024, Deng et al. 2022]. Nos estudos, [Deng et al. 2022] alcançaram um mAP de 87,13%, e [Chen and Fu 2025] obtiveram um AP de 71,7%. Em tarefas de segmentação, a métrica principal é a Interseção sobre União (IoU) [Wang et al. 2025], enquanto a capacidade de processamento em tempo real, essencial para aplicações em movimento, é medida em Quadros por Segundo (FPS) [Deng et al. 2022, Chen and Fu 2025].

Por fim, índices compostos de severidade como Pavement Conditions Index (PCI), Índice de Gravidade Global (IGG) e Crack Ratio têm sido usadas para traduzir métricas técnicas em indicadores compreensíveis por engenheiros e gestores públicos, ligando IA à tomada de decisão prática.

A Tabela 2 resume as métricas mais empregadas e os trabalhos que as adotaram.

Tabela 2. Síntese das métricas utilizadas em estudos de detecção e avaliação de pavimentos.

Métrica	Trabalhos que utilizaram	Tipo de aplicação
mAP (mean Average Precision)	[Mahmud et al. 2024], [Deng et al. 2022] e [Widodo et al. 2024]	Detecção de buracos e trincas
IoU (Intersection over Union)	[Wang et al. 2025], [Chen and Fu 2025], [Chun et al. 2021] e [Dong et al. 2022]	Segmentação / instância
Precisão / Recall / F1-score	[Dong et al. 2022], [Mahmud et al. 2024], [Deng et al. 2022], [Legramanti et al. 2023] e [Freitas and Nobre Júnior 2020]	Detecção e segmentação
R² (Correlação)	[Widodo et al. 2024]	Estimativa geométrica
Índices de Severidade (IGG, PCI, Crack Ratio)	[Dong et al. 2022], [Chun et al. 2021] e [Nunes-Ramos et al. 2024]	Avaliação de condição do pavimento

3.5. Cenário no Brasil

O Brasil possui uma malha rodoviária superior a 1,7 milhão de quilômetros, sendo o modal rodoviário responsável por mais de 60% do transporte de cargas [Freitas and Nobre Júnior 2020]. Contudo, a infraestrutura apresenta deficiências significativas, o que compromete a segurança, a eficiência logística e a economia nacional [Freitas and Nobre Júnior 2020].

A avaliação de pavimentos é regida por normas do DNIT, como as DNIT 006/2003-PRO e 007/2003-PRO, baseadas em inspeção visual manual [Nunes-Ramos et al. 2024]. Apesar de amplamente utilizadas, essas metodologias são onerosas, subjetivas e arriscadas [Mello 2024].

Pesquisas recentes têm apontado para a adoção de técnicas automatizadas com visão computacional e aprendizado profundo. Na UFSM, [Nunes-Ramos et al. 2024] verificaram que inspeções com VANTs podem atingir até 82% da precisão dos métodos tradicionais, oferecendo uma alternativa mais segura, embora com limitações na detecção de trincas finas. Na UTFPR, [Legramanti et al. 2023] obtiveram acurácia de 93,1% na classificação manual e 32,7% na automática de patologias em imagens de drones, demonstrando o potencial das RPAs para coleta de dados. Já na UFC, [Freitas and Nobre Júnior 2020] aplicaram redes neurais convolucionais para detectar buracos e remendos com acurácias de 97% e 92%, respectivamente, evidenciando o potencial do Deep Learning para inspeção automatizada.

Em síntese, o país avança na integração entre pesquisa e prática na manutenção rodoviária automatizada, com destaque para o uso de IA, VANTs e sistemas embarcados. Persistem, contudo, desafios como a padronização de bases de dados, a validação sob diferentes condições ambientais e a atualização das normas do DNIT para contemplar tecnologias emergentes.

3.6. Discussão e Tendências

Nos últimos cinco anos, observa-se uma clara dominância de métodos baseados em CNNs e na família de arquiteturas YOLO. Ao mesmo tempo, Transformers e modelos híbridos emergem como tendências promissoras, com uma ênfase crescente na implementação em tempo real, utilizando dispositivos móveis e drones, e no aproveitamento de dados multimodais. Apesar desses avanços, os principais desafios da área persistem, incluindo a escassez de grandes bases de dados padronizadas que permitam uma comparação justa entre modelos, a dificuldade de garantir a generalização dos algoritmos para ambientes distintos e a necessidade de evoluir dos sistemas de detecção para soluções que integrem a classificação de gravidade e a recomendação de reparos.

3.7. Desafios e Limitações

Apesar dos avanços, vários desafios persistem. Uma queixa recorrente na literatura é a falta de conjuntos de dados públicos, grandes e padronizados, o que dificulta a comparação direta e justa entre diferentes modelos [Buza et al. 2017, Akagic et al. 2017]. Além disso, o desempenho dos modelos é fortemente afetado por condições ambientais, como variações de iluminação, sombras e a presença de água, que pode ocultar ou alterar a aparência das anomalias [Chun et al. 2021, Zhu et al. 2022].

A complexidade do cenário também impõe dificuldades, pois falsos positivos podem ser gerados por elementos que se assemelham a defeitos, como manchas de óleo ou marcas de pneu [Dong et al. 2022], e a detecção simultânea de múltiplos tipos de defeitos permanece uma tarefa complexa [Zhu et al. 2022]. Finalmente, a transição de uma avaliação 2D para uma análise 3D, que inclua profundidade e volume para quantificar os danos, é um passo crucial, mas ainda é uma área em desenvolvimento, com a técnica de duas câmeras de [Park and Nguyen 2025] sendo um passo notável nessa direção.

4. Conclusões

Este mapeamento confirma que o uso de inteligência artificial está revolucionando a inspeção automatizada de pavimentos. A análise revela uma progressão de métodos de detecção baseados em caixas delimitadoras para técnicas de segmentação em nível de pixel, que fornecem informações mais ricas para a avaliação quantitativa. A família YOLO se destaca pela aplicabilidade em tempo real, enquanto arquiteturas mais sofisticadas buscam maximizar a precisão. A aquisição de dados por câmeras veiculares e VANTs de baixo custo representa uma democratização da tecnologia.

No entanto, desafios significativos permanecem, principalmente relacionados à robustez dos modelos em condições ambientais adversas e à carência de benchmarks públicos. As direções futuras da pesquisa devem se concentrar no desenvolvimento de datasets públicos, na criação de modelos híbridos mais robustos, na exploração de técnicas de aprendizagem com menos supervisão para mitigar o gargalo da anotação de dados, e no foco na quantificação 3D para fornecer dados acionáveis às equipes de manutenção. A superação desses desafios permitirá a criação de sistemas de gerenciamento de infraestrutura rodoviária mais proativos, eficientes e seguros.

Referências

- Akagic, A., Buza, E., and Omanovic, S. (2017). Pothole detection: An efficient vision based method using RGB color space image segmentation. In *2017 40th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, pages 1104–1109. IEEE.
- Arya, D., Maeda, H., Ghosh, S. K., Toshniwal, D., and Sekimoto, Y. (2021). Rdd2020: An annotated image dataset for automatic road damage detection using deep learning. *Data in brief*, 36:107133.
- Arya, D., Maeda, H., Ghosh, S. K., Toshniwal, D., and Sekimoto, Y. (2024). Rdd2022: A multi-national image dataset for automatic road damage detection. *Geoscience Data Journal*, 11(4):846–862.
- Badrinarayanan, V., Kendall, A., and Cipolla, R. (2017). Segnet: A deep convolutional encoder-decoder architecture for image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12):2481–2495.
- Buza, E., Akagic, A., Omanovic, S., and Hasic, H. (2017). Unsupervised method for detection of high severity distresses on asphalt pavements. In *2017 IEEE 14th International Scientific Conference on Informatics*, pages 45–50. IEEE.
- Chen, Q. and Fu, S. (2025). Continuous pavement crack detection using eca-enhanced instance segmentation of video images. *Construction and Building Materials*, 465:140247.
- Chun, P.-j., Yamane, T., and Tsuzuki, Y. (2021). Automatic detection of cracks in asphalt pavement using deep learning to overcome weaknesses in images and GIS visualization. In *Applied Sciences*, volume 11, page 892. MDPI.
- Deng, L., Zhao, X., Chu, H., and Xiang, C. (2022). Automatic inspection of cracks on pavement surfaces based on improved segmentation model. In *International Conference on Smart Transportation and City Engineering (STCE 2022)*, volume 12460 of *Proc. of SPIE*, page 124602U.

- Dong, H., Song, K., Wang, Y., Yan, Y., and Jiang, P. (2022). Automatic inspection and evaluation system for pavement distress. *IEEE Transactions on Intelligent Transportation Systems*, 23(8):12377–12387.
- Eisenbach, M., Stricker, R., Seichter, D., Amende, K., Debes, K., Sesselmann, M., Ebersbach, D., Stoeckert, U., and Gross, H.-M. (2017). How to get pavement distress detection ready for deep learning? a systematic approach. In *International Joint Conference on Neural Networks (IJCNN)*, pages 2039–2047.
- Freitas, G. T. d. M. and Nobre Júnior, E. F. (2020). Identificação de patologias em pavimentos rodoviários utilizando inteligência artificial. In *Anais do 34º Congresso de Pesquisa e Ensino em Transportes*, pages 831–834, 100% Digital. Associação Nacional de Pesquisa e Ensino em Transportes. Realizado de 16 a 21 de novembro de 2020.
- Legramanti, G., Duarte, R. D., Gomes Junior, E. V., Dallagnol, S. L., Bisconsini, D. R., Felipetto, H. S., and Moraes, L. (2023). Clasificación supervisada de patologías en la superficie de los pavimentos de asfalto desde una aeronave pilotada remotamente (rpa). *Revista ALCONPAT*, 13(3):271–285. Epub 31-Mayo-2024.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., and Berg, A. C. (2016). Ssd: Single shot multibox detector. In Leibe, B., Matas, J., Sebe, N., and Welling, M., editors, *Computer Vision – ECCV 2016*, pages 21–37, Cham. Springer International Publishing.
- Maeda, H., Kashiya, T., Sekimoto, Y., Seto, T., and Omata, H. (2021). Generative adversarial network for road damage detection. *Computer-Aided Civil and Infrastructure Engineering*, 36(1):47–60.
- Maeda, H., Sekimoto, Y., Seto, T., Kashiya, T., and Omata, H. (2018). Road damage detection and classification using deep neural networks with smartphone images. *Computer-Aided Civil and Infrastructure Engineering*, 33(12):1127–1141.
- Mahmud, M. N., Osman, M. K., Ismail, A. P., Ahmad, F., Ahmad, K. A., Ibrahim, A., and Rabiani, A. H. (2024). Crack detection on asphalt road in malaysia using uav images and yolov4. In *2024 IEEE 14th International Conference on Control System, Computing and Engineering (ICCSCE)*, pages 64–69.
- Mello, F. B. (2024). Análise da aplicação da inteligência artificial, associada a dispositivos de coleta de imagens, como ferramentas para a detecção de patologias em vias públicas. Master’s thesis, Programa de Pós-Graduação em Cidades Inteligentes e Sustentáveis. Administração.
- Moscato Thompson, E., Ranieri, A., Biasotti, S., Chicchon, M., Sipiran, I., Pham, M.-K., Nguyen-Ho, T.-L., Nguyen, H.-D., and Tran, M.-T. (2022). Shrec 2022: Pothole and crack detection in the road pavement using images and rgb-d data. *Computers & Graphics*, 107:161–171.
- Nunes-Ramos, V., Viera Trevisan, E., Pivoto Specht, L., da Silva Pereira, D., and Dotto Bueno, L. (2024). Distress manifestation in asphalt pavements: Comparison between local and unmanned aerial vehicle (uav) measurements. *Anuário do Instituto de Geociências*, 47.

- Park, S.-S. and Nguyen, N.-N. (2025). Two-camera vision technique for measuring pothole area and depth. *Measurement*, 247:116809.
- Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. (2016). You only look once: Unified, real-time object detection. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 779–788.
- Ren, S., He, K., Girshick, R., and Sun, J. (2015). Faster r-cnn: towards real-time object detection with region proposal networks. In *Proceedings of the 29th International Conference on Neural Information Processing Systems - Volume 1*, NIPS'15, page 91–99, Cambridge, MA, USA. MIT Press.
- Ronneberger, O., Fischer, P., and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In Navab, N., Hornegger, J., Wells, W. M., and Frangi, A. F., editors, *Medical Image Computing and Computer-Assisted Intervention – MIC-CAI 2015*, pages 234–241, Cham. Springer International Publishing.
- Shi, Y., Cui, L., Qi, Z., Meng, F., and Chen, Z. (2016). Automatic road crack detection using random structured forests. *IEEE Transactions on Intelligent Transportation Systems*, 17(12):3434–3445.
- Stricker, R., Aganian, D., Sesselmann, M., Seichter, D., Engelhardt, M., Spielhofer, R., Hahn, M., Hautz, A., Debes, K., and Gross, H.-M. (2021). Road surface segmentation - pixel-perfect distress and object detection for road assessment. In *International Conference on Automation Science and Engineering (CASE)*, pages 1–8.
- Stricker, R., Eisenbach, M., Sesselmann, M., Debes, K., and Gross, H.-M. (2019). Improving visual road condition assessment by extensive experiments on the extended gaps dataset. In *International Joint Conference on Neural Networks (IJCNN)*, pages 1–8.
- Wang, D., Zhang, A. A., Peng, Y., Wei, Y., Cheng, H., and Shang, J. (2025). Adaptive learning network for detecting pavement distresses in complex environments. *Engineering Applications of Artificial Intelligence*, 152:110784.
- Widodo, H., Taufiqurrohman, H., Muis, A., Wijayanto, Y. N., Prihantoro, G., Dwiyanti, H., Cahya, Z., Widaryanto, A., and Nugroho, T. H. (2024). Experimental evaluation of pothole detection and its dimension estimation using yolov8 and depth camera for road surface analysis. In *2024 International Conference on Radar, Antenna, Microwave, Electronics, and Telecommunications (ICRAMET)*, pages 339–344.
- Yang, F., Zhang, L., Yu, S., Prokhorov, D., Mei, X., and Ling, H. (2019). Feature pyramid and hierarchical boosting network for pavement crack detection. *IEEE Transactions on Intelligent Transportation Systems*.
- Zhang, L., Yang, F., Zhang, Y. D., and Zhu, Y. J. (2016). Road crack detection using deep convolutional neural network. In *Image Processing (ICIP), 2016 IEEE International Conference on*, pages 3708–3712. IEEE.
- Zhu, J., Zhong, J., Ma, T., Huang, X., Zhang, W., and Zhou, Y. (2022). Pavement distress detection using convolutional neural networks with images captured via UAV. *Automation in Construction*, 133:103991.
- Zou, Q., Cao, Y., Li, Q., Mao, Q., and Wang, S. (2012). Cracktree: Automatic crack detection from pavement images. *Pattern Recognition Letters*, 33(3):227–238.