

Reflexões sobre aplicações de Inteligência Artificial: modelos físicos e modelos baseados em dados como paradigmas de pesquisa na infraestrutura viária

Reflections on Artificial Intelligence applications: physical models and data-driven models as research paradigms in road infrastructure

Jorge Barbosa Soares¹

¹Universidade Federal do Ceará, Fortaleza, Ceará, Brasil

Contato: jsoares@det.ufc.br,  (JBS)

Recebido:

28 de agosto de 2024

Revisado:

5 de outubro de 2024

Aceito para publicação:

5 de outubro de 2024

Publicado:

19 de dezembro de 2024

Editor de Área:

Francisco Thiago Sacramento Aragão,
Universidade Federal do Rio de
Janeiro, Brasil

Palavras-chave:

Inteligência Artificial.
Aprendizado de máquina.
Ciência de dados.
Pavimentos.

Keywords:

Artificial Intelligence.
Machine learning.
Data science.
Pavements.

DOI: 10.58922/transportes.v32i3.3045



RESUMO

O presente artigo traz uma reflexão sobre aplicações de Inteligência Artificial (IA) na pesquisa em pavimentação. O uso crescente das mesmas representa uma virada epistemológica na área, construída sobretudo em cima de modelos físicos. Na busca por soluções, modelos baseados em dados podem produzir resultados satisfatórios sem explicar os processos físicos subjacentes que levaram a esses resultados. São exemplificadas aplicações como levantamento automatizado de defeitos e cidades inteligentes, e reconhecem-se alguns dos riscos, como questões éticas e viés de dados. Alerta-se como as inovações devem não apenas melhorar o desempenho imediato, mas contribuir para um entendimento mais completo e sustentável da infraestrutura viária. A IA possui um potencial transformador, bem como é um atrator de alunos(as) e jovens pesquisadores(as), algo essencial para o avanço de qualquer área de conhecimento. Espera-se que o tipo de reflexão feita aqui encoraje discussões e colaborações necessárias para navegar os desafios postos e maximizar os benefícios das tecnologias emergentes.

ABSTRACT

This paper reflects on applications of Artificial Intelligence in pavement research, whose increasing use represents an epistemological turn in the area, mostly built on top of physical models. In the search for solutions, data-driven models can produce satisfactory results without explaining the underlying physical processes that led to these results. Applications such as automated distress surveying and smart cities are exemplified, and some of the associated risks are recognized, such as ethical issues and data bias. It highlights how innovations should not only improve immediate performance, but contribute to a more complete and sustainable understanding of road infrastructure. AI tools have a transformative potential, as well as the ability to attract students and young researchers, which is essential for the advancement of any area of knowledge. It is hoped that the type of reflection and thinking provided herein will encourage discussions and collaborations necessary to navigating the challenges posed and maximizing the benefits of emerging technologies.

1. INTRODUÇÃO

A motivação para este artigo se originou na *Keynote Lecture*, “*Physics-Inspired vs. Data-Driven: Paradigms in Pavement Infrastructure Research*”, proferida em junho de 2024 na Conferência da Sociedade Internacional de Pavimentos Asfálticos (ISAP), em Montreal, envolvendo o tema Inteligência Artificial (IA). Assim como, no passado, em Soares (2020), sobre um período de transição

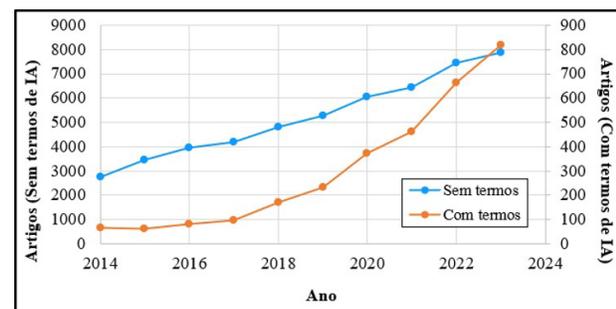
na pavimentação nacional quanto a métodos de dimensionamento, desta vez uma reflexão sobre as aplicações de IA na área de infraestrutura foi considerada oportuna.

O crescimento do uso de ferramentas de IA deve representar uma virada epistemológica também na infraestrutura viária. A reflexão é tempestiva quando se acompanham os trabalhos técnico-científicos em diferentes nichos e que envolvem o uso de IA. Em um levantamento bibliométrico na base Scopus, utilizando os termos apresentados na Figura 1, encontra-se uma ordem de grandeza a mais de artigos quando comparado a uma busca destas mesmas palavras, todavia acrescida das palavras “*artificial intelligence or machine learning or neural network or data science*” (milhar vs. centena). Os gradientes são distintos quando se observam os últimos 4 anos. Em 2023, artigos de infraestrutura viária contendo termos associados à IA representam cerca de 10% do total de artigos sobre o tema que não incluem esses termos. Na conferência ISAP 2024, artigos em IA representaram 5,5% do total de 181. O percentual deve ser distinto em um futuro breve e cabe refletirmos sobre como aproveitar da melhor forma as novas ferramentas, com a devida cautela, o que inclui não apenas questões técnicas das ferramentas em si, mas a devida confiabilidade nos dados que as alimentam.

Termos da pesquisa bibliométrica:

(*pavement OR asphalt OR "roads and streets"*)
 AND (*structure OR design*) OR (*test OR*
"decision making") OR (*traffic OR maintenance*
 OR *management OR rut* OR crack**) OR
 (*emulsion OR binder OR concrete*) OR (*base*
 OR *subbase OR subgrade OR soil OR granular*)

(a)



(b)

Figura 1. Publicação anual de artigos sobre pavimentação e IA: (a) Termos da pesquisa bibliográfica; (b) Artigos com e sem termos de IA nos últimos 10 anos.

Um ponto de partida para a reflexão consta no título deste artigo, que traz modelos físicos e modelos baseados em dados (*data-driven*) como paradigmas da pesquisa em pavimentos. Tradicionalmente a engenharia civil faz uso da física clássica e resolve os problemas por meio de uma abordagem que envolve cinemática (deformações), cinética (tensões), leis de conservação (massa, momento, energia, além da produção de entropia) e equações constitutivas. Como exemplo, o problema de valor de contorno de sistemas de camadas não é trivial, com soluções analíticas fechadas restritas a 3 camadas e uma série de hipóteses simplificadoras sobre o comportamento dos materiais. O usual é a utilização de métodos numéricos para soluções de tensões e deformações, sendo a complexidade dos materiais tratada frequentemente de forma desagregada da análise. Um olhar mais aprofundado para os materiais, em menores escalas, acaba usado para fins de seleção e desenvolvimento de produtos, bem como para a compreensão dos mecanismos do comportamento e das falhas do sistema.

Saindo-se da escala da física clássica para escalas muito pequenas, aumenta-se a complexidade. Raramente nas pesquisas da engenharia civil se chega à nanoescala e menos ainda à escala atômica, ainda que haja esforços em pesquisas em dinâmica molecular na nossa área. Cabe uma analogia entre a escala física e a escala de dados: quando se sai da escala de dados convencionalmente usada na engenharia por meio de ferramentas estatísticas, de dezenas a milhares de dados, para trilhões

ou mais de dados, ganha-se também em complexidade (Figura 2). Outras ferramentas passam a ser mais indicadas, correndo-se, porém, o risco de se perder a compreensão dos processos que geram os dados. Essa dicotomia é crítica para a pesquisa, não apenas em pavimentos.



Figura 2. Analogia entre escala de tamanho e escala de dados (produzida em colaboração por R. N. Costa Filho para Soares, 2024).

A analogia ajuda em uma das reflexões; à direita da Figura 2 (escalas pequenas e grande quantidade de dados), tende-se a concentrar no desempenho e não no processo. De forma resumida, a mecânica quântica, uma teoria bem-sucedida da física moderna, é frequentemente citada como um exemplo de uma ferramenta de alto desempenho, nem sempre plenamente compreendida. De forma análoga, modelos baseados em dados podem revelar padrões e previsões com uma precisão inédita. Todavia, a boa performance das previsões pode vir à custa da compreensão de mecanismos subjacentes. Na busca por soluções, a quantidade de dados e a baixa interpretabilidade dos modelos podem obscurecer processos fundamentais que governam o comportamento dos materiais em sistemas de camadas. Kissinger et al. (2024) destacaram uma mudança significativa no foco da compreensão humana para a performance algorítmica, ressaltando que a IA pode produzir resultados impressionantes sem necessariamente explicar os processos subjacentes que levaram a esses resultados. Esse fenômeno, no contexto da IA, é relevante para a pesquisa em pavimentos, onde a aplicação de modelos baseados em dados tem o potencial de complementar ou transformar a abordagem tradicional baseada, por exemplo, na física clássica (Prince, 2023; Cranmer, 2024).

2. CONTEXTO DA IA NA PAVIMENTAÇÃO

A abordagem tradicional da física na pavimentação, apesar de sua robustez, enfrenta limitações devido à necessidade de simplificações e à dificuldade em lidar com a complexidade dos materiais em escalas menores. O avanço da IA permite integrar uma série de abordagens para coletar, criar e/ou analisar vastos conjuntos de dados. Uma pesquisa bibliométrica revela temas emergentes no uso da IA para a pavimentação, sendo mais comuns os que envolvem: redes neurais artificiais (*artificial neural network*, ANN), redes neurais convolucionais (*convolutional neural network*, CNN), máquinas de vetores de suporte (*support vectors machine*, SVM) e algoritmos baseados em aprendizado profundo (*deep learning*).

Um conjunto de trabalhos foca no reconhecimento de *pixels* com o uso de IA para análise de imagens e vídeos da superfície do pavimento para detecção e reconstrução de trincas (Zhang et al., 2017; Tong et al., 2017) e para o mapeamento e reconhecimento de vias (Xu et al., 2018). Outras abordagens usam algoritmos de IA para estudar propriedades mecânicas e químicas e desenvolver

novos materiais. Embora essenciais, ensaios são demorados e caros. Com IA, é possível analisar grandes volumes de dados sobre as propriedades dos materiais e seus desempenhos em diferentes condições de modo a prever o módulo de resiliência (MR) de diferentes camadas, estabilizadas ou não, confinadas ou não (Ghorbani et al., 2020; Kaloop et al., 2019; Saha et al., 2018), além de prever o módulo complexo (Eidgahee et al., 2022). Outras pesquisas buscam prever o IRI (*international roughness index*) (Abdelaziz et al., 2020), ou a deformação permanente (DP) em materiais granulares (Alnedawi et al., 2019) e em misturas asfálticas (Majidifard et al., 2021). Há ainda algoritmos de aprendizagem de máquina que já foram usados para verificar a resistência à compressão de agregados reciclados de concreto, ilustrando estudos sobre o reaproveitamento de materiais (Naderpour et al., 2018).

No Brasil, o uso de IA na infraestrutura viária ganhou destaque com a aplicação de algoritmos de aprendizado de máquina para otimizar processos de construção e manutenção de estradas. Brega (1997) foi um dos primeiros a usar ANNs para avaliar o Índice de Irregularidade Global. Coutinho Neto (2000) investigou um procedimento de retroanálise usando ANNs para simular os resultados dos ensaios de viga Benkelman e do *Falling Weight Deflectometer (FWD)*. Há pesquisas que usaram análise estatística (regressão), ANNs e uma combinação das duas abordagens para modelar a viscosidade de ligantes asfalto-borracha (Specht et al., 2007; Specht e Khatchatourian, 2014). Nunes e Mota (2019) desenvolveram uma estrutura de sensoriamento participativo para classificar a qualidade da superfície de vias através de diferentes algoritmos de aprendizado de máquina. Souza et al. (2022a) usaram modelos baseados em ANNs para prever a classificação AASHTO (*American Association of State Highway and Transportation Officials*) e o CBR (*California Bearing Ratio*) de solos do estado do Ceará. Ribeiro e Oliveira (2023) usaram ANNs para prever o coeficiente de atrito em pistas de pouso e decolagem brasileiras. Mota et al. (2023) construíram e analisaram um banco de dados de misturas asfálticas para avaliar o Módulo Dinâmico (MD). Há trabalhos nacionais com aplicações diversas de ferramentas da IA à infraestrutura, dando suporte no projeto e na gerência de pavimentos.

O Ministério da Ciência e Tecnologia (2024) acabou de apresentar o plano brasileiro de IA, cujos eixos são: construção de supercomputadores e infraestrutura sustentável; formação de profissionais; uso de IA para melhorar a eficiência dos serviços públicos; apoio ao desenvolvimento de soluções de IA na indústria, criação de *datacenters* verdes e incentivo a *startups* de IA. É previsto um investimento significativo, o que possibilitará o aumento da quantidade e do escopo das pesquisas em diversas áreas. Este panorama ilustra que os grupos de infraestrutura brasileiros estão bem posicionados para este momento desafiador e para ousar em inovações. A colaboração entre universidades, empresas privadas e órgãos governamentais será um fator crucial para o sucesso dessas iniciativas, garantindo que as estradas brasileiras se mantenham seguras, sustentáveis, eficientes e duradouras.

3. APLICAÇÕES EM ANDAMENTO

A seguir são descritas aplicações de ferramentas de IA na pavimentação, desenvolvidas pelo grupo de pesquisa do autor e apresentadas na já referida conferência da ISAP. Estão divididas em 7 blocos: (i) Rigidez de subcamadas e (ii) de misturas asfálticas; (iii) Deformação permanente (DP) de misturas; (iv) Interface agregado-ligante; (v) Levantamento automatizado de defeitos; (vi) Cidades inteligentes e IA generativa. Na ocasião da ISAP, o autor foi instigado a trazer sua perspectiva da IA na parte ambiental da infraestrutura e uma breve reflexão sobre este tema foi incluída (vii).

3.1. Rigidez de subcamadas

Os principais parâmetros de subcamadas modelados na engenharia rodoviária são a DP e o MR. O MR foi o foco de estudo do trabalho de Souza et al. (2022b), ilustrado na Figura 3, que demonstra a maior capacidade de previsão da ANN quando comparada com uma abordagem estatística tradicional de regressão. As variáveis mais frequentemente usadas para prever tais medidas são propriedades básicas dos materiais, como massa específica seca máxima, umidade ótima, granulometria, limites de consistência e CBR. As ANNs têm demonstrado alta precisão, frequentemente com acurácia superior a 90% em suas métricas de desempenho. Os modelos são considerados satisfatórios, pois se aproximam dos valores dos ensaios de laboratório e podem ser usados no dimensionamento mecânico-empírico. O uso de ANNs na previsão de rigidez de materiais granulares se apresenta como uma abordagem alternativa, poderosa e acurada. Com o avanço contínuo da IA e com a crescente disponibilidade de dados, essas técnicas desempenharão um papel cada vez mais importante na otimização do tempo e dos recursos econômicos na execução dos projetos e da gestão da infraestrutura rodoviária.

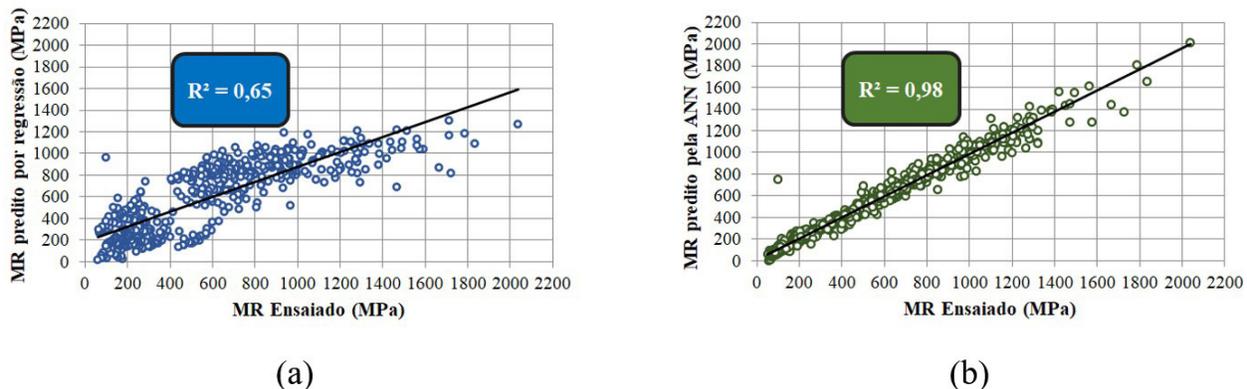


Figura 3. Gráficos de dispersão comparativo entre modelos (a) de regressão estatística e (b) ANN.

3.2. Rigidez de misturas asfálticas

A rigidez de misturas asfálticas, representada pelo módulo dinâmico ($|E^*|$), é frequentemente prevista por modelos semiempíricos, que, apesar de sua utilidade, tendem a simplificar as relações complexas e não-lineares dos materiais asfálticos. A fim de melhor representar essas relações em um modelo de previsão, Melo et al. (2024) propuseram uma metodologia baseada em Processos Gaussianos (*Gaussian Process*, GP) para estimar a curva mestra de misturas asfálticas sob condições de escassez de dados, usando um banco de dados de 49 amostras. Embora métricas globais como o coeficiente de determinação (R^2) sejam amplamente usadas para avaliar modelos, podem mascarar discrepâncias locais. Outras métricas globais, como o erro quadrático médio (MSE) ou o erro absoluto médio (MAE), também podem ocultar variações locais ao resumir o desempenho do modelo em um único valor. Ao usar o *Random Forest Regression* e o *Gradient Boosting Regression*, dois métodos baseados em árvores de decisão, os modelos em Melo et al. (2024) apresentaram boas métricas gerais, mas exibiram variabilidade significativa nas curvas preditas. Isso evidencia a importância de complementar métricas globais com análises locais detalhadas, como a plotagem das curvas preditas e a comparação de erros ao longo de diferentes pontos da curva. O uso de Processos

Gaussianos permite incorporar a variabilidade dos dados na estimativa do $|E^*|$, resultando em uma *Master Curve Confidence Band* (MCCB) com intervalos de confiança para as previsões. Essa abordagem aprimora a precisão preditiva e fornece uma ferramenta para o projeto de misturas, levando em consideração a incerteza inerente ao comportamento dos materiais.

Modelar o ensaio de rigidez é apenas o início no desenvolvimento de misturas. Ensaios de deformação permanente e de fadiga também já foram modelados com sucesso e, junto com um modelo de elementos finitos em 3D, permitem a dosagem virtual em um projeto de otimização. Modelos baseados em *machine learning* são ideais para buscas rápidas de valores iniciais, enquanto o Método dos Elementos Finitos, embora mais lento, oferece a precisão necessária para refinar e validar esses resultados. Um gerador de corpos de prova virtuais em 3D está sendo desenvolvido para visualizar o empacotamento dos componentes após a dosagem inicial, otimizando custos ao direcionar os melhores candidatos para testes laboratoriais.

3.3. Deformação permanente de misturas asfálticas

A resistência à DP de misturas asfálticas pode ser verificada por meio do ensaio uniaxial de carga repetida, que fornece o *Flow Number* (FN). Para economizar tempo e recursos, uma alternativa à execução desse ensaio é a utilização de modelos de aprendizado de máquina. Mariano (2023) construiu um banco de dados com características do ligante (tipo, penetração, ponto de amolecimento, viscosidade), dos agregados (TMN, % passante nas peneiras) e da volumetria (V_v) de 251 misturas a fim de prever a resistência à DP a partir dessas variáveis. Através da correlação entre o FN e a intensidade do tráfego (FN < 300, tráfego leve/médio; $300 \leq \text{FN} < 1000$, tráfego pesado; FN ≥ 1000 , tráfego extremamente pesado), as misturas foram classificadas pelo nível de tráfego equivalente usando modelos baseados em ANN e *eXtreme Gradient Boosting* (algoritmo baseado em árvores de decisão). Essa transformação foi realizada por associar o FN com uma variável essencial no dimensionamento, além de melhorar os resultados obtidos, obtendo-se uma acurácia de até 80%.

Estão sendo testados modelos de aprendizado probabilístico, que se baseiam no teorema de Bayes, usado para definir os parâmetros e as saídas de modelos como distribuições de probabilidade. As predições possuem média e desvio padrão, sendo possível estabelecer uma faixa de valores preditos possíveis. Foram avaliados modelos de regressão polinomial bayesiana (RPB) e GP, usando regressão para prever o FN e classificação para prever o nível de tráfego equivalente. Serão realizados testes com a incorporação da física do fenômeno ao modelo. Isso pode ser feito de diferentes maneiras, dentre elas a adição de equações diferenciais ordinárias que representam o fenômeno. Os resultados até o momento mostram o potencial da aplicação desses modelos como uma ferramenta auxiliar ao projeto de misturas asfálticas, reduzindo ou mesmo eliminando ensaios, nesse último caso para fins de anteprojeto.

3.4. Interface agregado-ligante

A relação adesiva entre agregado e ligante, fundamental para conferir um bom desempenho à mistura, tem sido estudada com o intuito de compreender adequadamente o fenômeno. Estudos sugerem que a adesividade agregado-ligante é explicada principalmente pela química na interface dos materiais (Lucas et al., 2019). Há pesquisas que fazem uso do processamento digital de imagem (PDI) para aferir o parâmetro. Com o poder da tradução de características visuais em dados, acredita-se poder inferir a química na superfície dos agregados através de imagens digitais. Caso a química de agregados possa ser traduzida por parâmetros visuais de imagens digitais, se

terá um meio para conectar informações de área de agregado coberta (ou não) por ligante, após o contato com a água, com a respectiva química da superfície do agregado. A Figura 4 exemplifica a hipótese com uma imagem de petrografia (superfície de um agregado) apresentando conexões com regiões de uma partícula com áreas cobertas e não cobertas por ligante asfáltico.

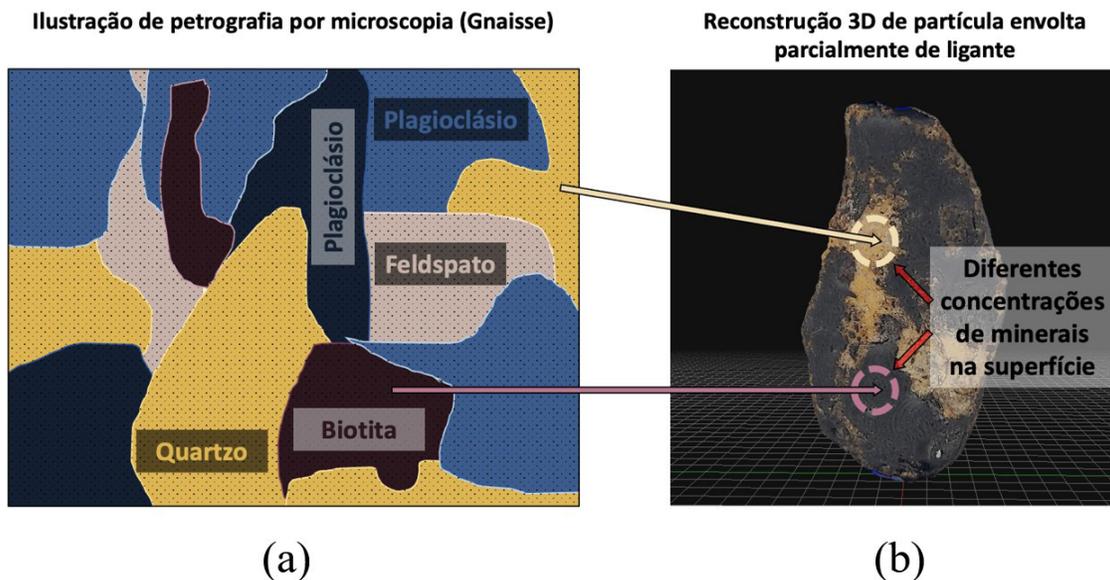


Figura 4. Cores sugerindo informações mineralógicas na superfície dos agregados.

Apesar da diversidade de minerais na superfície de rochas e de estes compósitos químicos apresentarem semelhanças visuais, é esperado que a cor forneça informações importantes relativas à composição química, sobretudo associada a origem mineralógica. As relações entre química, cor e adesividade podem não ser simples de observar, mas com a possibilidade de um banco de dados robusto e o uso da IA para detectar padrões complexos, potencializa-se a compreensão da interação adesiva na interface agregado-ligante. Compreendendo melhor o comportamento nesta interface, é possível um avanço na escolha mais consciente do tipo e do teor de aditivo melhorador de adesividade em caso de má afinidade entre os materiais. Uma vez estabelecida uma conexão entre cor e química do agregado, torna-se plausível, no momento de pré-seleção, inferir o potencial de adesividade do agregado a tipos específicos de ligante antes mesmo de se realizar um ensaio.

3.5. Levantamento automatizado de defeitos

Gonçalves et al. (2024) desenvolveram uma abordagem para monitoramento contínuo das condições de pavimento rodoviário utilizando IA e tecnologia de smartphones. Criaram o Sistema de Medição de Irregularidades e Defeitos Rodoviários (MIDR), que consiste em: um aplicativo para smartphone que capta dados de imagem, GPS e tomada de tempo; e uma CNN para detecção de defeitos, conforme Figura 5. Testes de campo indicaram métricas de desempenho promissoras para detecção de trincas, remendos e panelas. Serafim et al. (2023) propuseram um método de avaliação de defeitos e sinais verticais usando imagens produzidas por motoristas. Utilizando vídeos do YouTube produzidos por motoristas brasileiros, treinaram e validaram um modelo de CNN, obtendo uma precisão geral de 74,9%, com boa detecção para panelas, remendos e sinais de trânsito. Mesmo com dados obtidos casualmente ou com uso de IoT (*Internet of Things*), é

possível desenvolver uma rede de aprendizado eficiente. A IoT se refere a uma rede de dispositivos e objetos interconectados, equipados com sensores, software e outras tecnologias que permitem coletar, trocar e agir sobre dados por meio de protocolos de comunicação padrão. Sua vantagem está em gerar grandes volumes de dados - *big data* - essenciais para descobrir padrões relevantes.

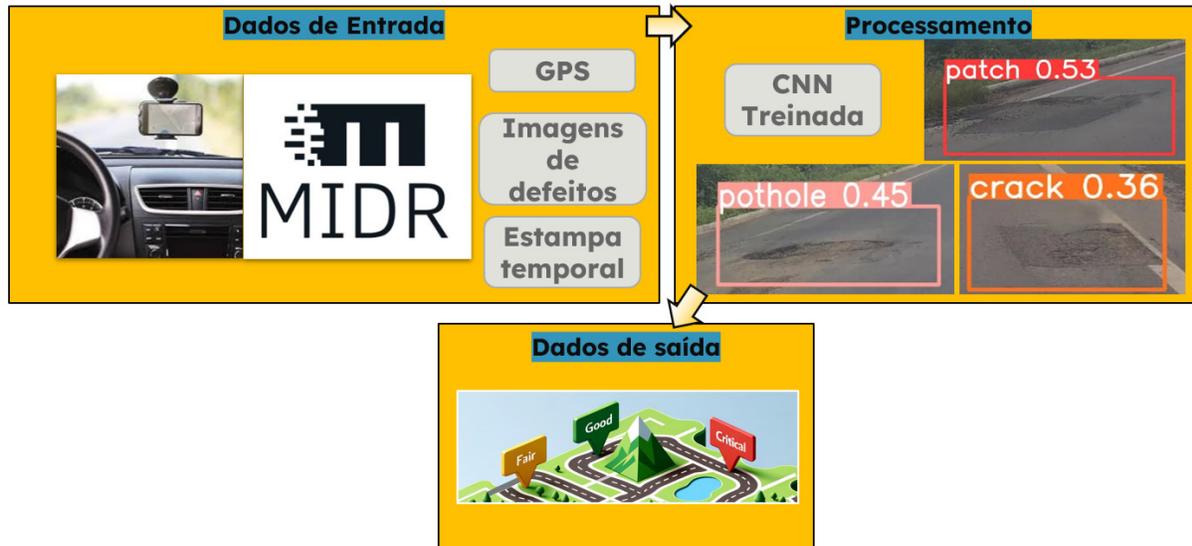


Figura 5. Identificação automática de defeitos [adaptado de: Gonçalves et al., 2024].

As pesquisas tendem a desenvolver ferramentas e métodos de baixo custo para verificar a condição da superfície de pavimentos usando dispositivos como smartphones e câmeras esportivas para captação e processamento de imagens com CNNs. A expectativa é da utilização de sensores múltiplos conectados a redes de IoT para monitoramento contínuo das rodovias. Com isso, dados podem ser capturados não somente por drones ou smartphones, mas por fotossensores, câmeras de contagem de tráfego, satélites, dentre outros. Com base nesse grande volume de dados, deverão surgir CNNs capazes de processar imagens captadas por diferentes dispositivos, automatizando a contagem de defeitos nas imagens e reduzindo a necessidade de realização de levantamentos em campo. Essas abordagens já estão documentadas como parte das iniciativas de Cidades Inteligentes, oferecendo exemplos de boas práticas na pavimentação.

3.6. Cidades Inteligentes e Inteligência Artificial Generativa

O conceito de Cidades Inteligentes ganhou popularidade com a integração de tecnologia e análise de dados para a gestão de recursos e serviços urbanos. A Cidade Inteligente incorpora diferentes áreas em aspectos distintos da gestão urbana e da inovação como energia, edifícios, água e saúde inteligentes, entre outras. Os avanços nessas áreas são valiosos para o estudo mais amplo da inovação na infraestrutura, em específico quais tecnologias são fundamentais para alcançar os objetivos inteligentes: IoT, análise de grandes volumes de dados (*big data*), gêmeos digitais e IA Generativa. Uma vez que a plataforma IoT está em operação e gerando *big data* em tempo real, é possível criar gêmeos digitais, que são réplicas virtuais de sistemas físicos. O modelo digital é continuamente atualizado para refletir as mudanças no sistema físico, permitindo o monitoramento em tempo real, a análise preditiva de impactos para otimização de desempenho e manutenção. Gêmeos digitais podem ser desenvolvidos utilizando a infraestrutura IoT, por exemplo, para

monitorar vias urbanas em tempo real e correlacionar com variáveis ambientais como poluição e ilhas de calor (Figura 6).

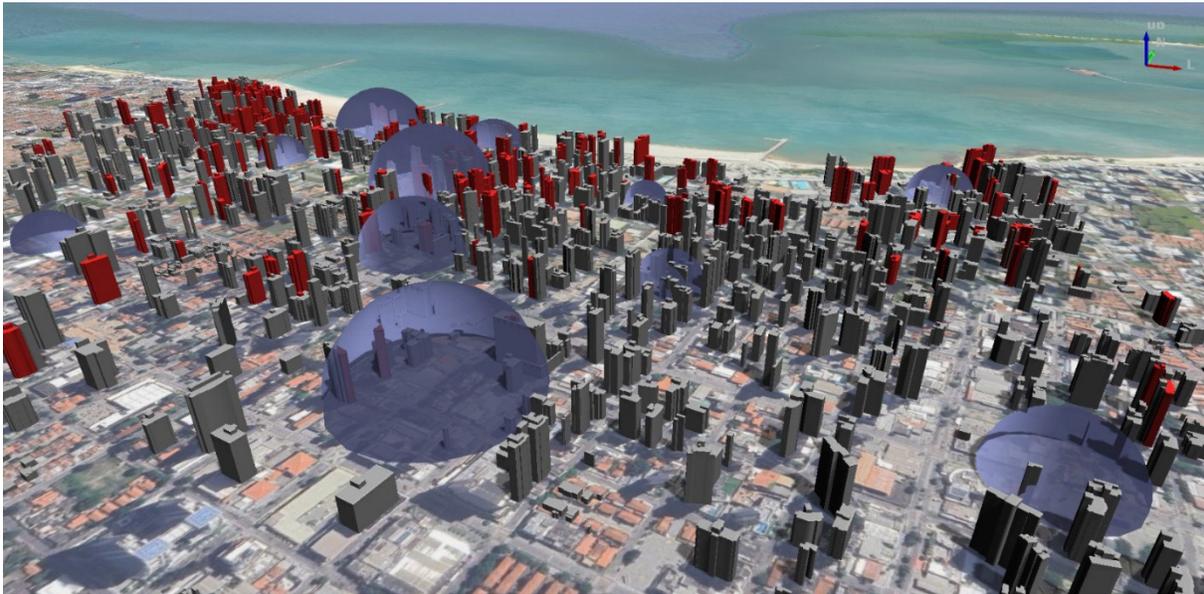


Figura 6. Gêmeo digital de Fortaleza mostra a densidade de edifícios (vermelhos) e níveis de poluição em grandes vias obtidos com rede de sensores de qualidade do ar.

O desafio é como interpretar e usar esses dados de forma eficaz. Além da IA tradicional, os avanços em IA Generativa têm democratizado o uso dessas tecnologias, permitindo que usuários comuns se beneficiem de suas capacidades em áreas como criação de conteúdo e análise de dados (Furtado et al., 2024a). Uma das vantagens da IA Generativa é a interação mais simples e acessível entre os usuários e os algoritmos de IA por meio de prompts, que são instruções ou perguntas em texto usadas para orientar a IA a gerar respostas ou realizar tarefas. Isso facilita a criação de produtos e serviços, tornando-os acessíveis. Gestores da área de pavimentos podem usar frases simples para extrair *insights* de dados geoespaciais de defeitos, criar mapas personalizados e automatizar análises de dados, sem a necessidade de conhecimentos especializados em geoprocessamento ou programação (Furtado et al., 2024b).

3.7. IA e as mudanças climáticas

As mudanças climáticas são um dos maiores desafios do mundo moderno. As alterações dos padrões do clima e a incerteza sobre as condições futuras requerem soluções robustas para os projetos de pavimentos e que incorporem a resiliência climática. As estratégias adotadas podem ser divididas em: mitigação (redução de gases do efeito estufa, em várias fases do ciclo de vida de um pavimento) e adaptação (redução do risco e garantia da funcionalidade dos projetos de pavimentos frente às mudanças climáticas).

As aplicações de IA para o planejamento adaptativo dos pavimentos despontam em um contexto de alta complexidade e de incerteza climática futura, com múltiplas possibilidades de respostas para a tomada de decisão. Piryonesi e El-Diraby (2021) utilizaram estratégias de *machine learning* como ferramenta para suporte na previsão de condições de pavimentos asfálticos frente às mudanças climáticas com níveis de precisão acima de 90%.

A IA além de auxiliar na análise e interpretação de dados complexos para apoiar decisões estratégicas, pode ser aplicada na construção de diferentes cenários climáticos futuros, na escolha e previsão de propriedades dos materiais utilizados na pavimentação e modelos de previsão de desempenho. No Ceará, destaca-se o desenvolvimento de modelos de previsão de propriedades geotécnicas para pavimentos que utilizam IA, principalmente as ANN (Souza et al., 2022a), além do estudo dos impactos das mudanças climáticas no desempenho de pavimentos (Araújo et al., 2023). Diversos são os cenários e modelos projetados em um país continental como o Brasil, e.g., as alterações climáticas esperadas em precipitação, temperatura e eventos extremos no país não serão homogêneas. Enquanto a Região Sul estará mais sujeita a chuvas extremas, o Nordeste estará mais suscetível a maiores períodos de seca. Assim, as soluções adaptativas identificadas para cada região precisarão ser distintas. A IA é uma possibilidade concreta de aplicação e uma ferramenta essencial para garantir a resiliência e a sustentabilidade da infraestrutura viária diante das adversidades climáticas futuras.

4. O FUTURO DA IA NA INFRAESTRUTURA VIÁRIA NACIONAL E SEUS RISCOS

É bem evidente que a engenharia continuará a expandir o uso de ferramentas de IA, muitas das quais não são novidades, sendo algumas existentes há décadas. Seu uso crescente deve-se a dois fatores principais: (i) aumento do poder computacional, com a capacidade de processamento e armazenamento de dados tendo crescido exponencialmente; (ii) aprimoramento na obtenção de dados, com novos métodos de captura de dados, sensores avançados e processamento de baixo custo.

As ferramentas de IA acelerarão algumas previsões de propriedades, não necessariamente fundamentais, para apoio a tomada de decisão, inclusive em laboratório. Não se trata de abdicar da caracterização fundamental relativa a fenômenos relevantes, mas sim de apoiar decisões quando os fenômenos não são bem descritos pelos modelos mais sofisticados e ainda pouco práticos. Um esforço em compreensão fundamental dos fenômenos físicos, mas apostando em algumas previsões baseadas em dados, pode gerar avanço de conhecimento científico. Isso vem sendo feito em outras áreas, com ferramentas comprimindo informação de grande volume de dados, ou seja, a IA como compilador de experiências de diferentes fontes para prever resultados futuros. As ferramentas vêm evoluindo e podem testar com rapidez diferentes modelos simbólicos (equações), que eventualmente têm o potencial de traduzir parte da física dos fenômenos, facilitando no futuro a descoberta de modelos teóricos mais adequados (Cranmer, 2024).

Diante do exposto, as ferramentas continuarão a ajudar projetos científicos e inovadores. Trazem ainda um efeito colateral positivo: atraem bons estudantes e pesquisadores, criam interdisciplinaridades, impactando significativamente a engenharia civil e, em particular, a engenharia rodoviária. Estas áreas têm enfrentado queda acentuada na procura e na retenção de alunos. A introdução de tecnologias avançadas pode reverter essa tendência, preparando os alunos(as) para atuarem em áreas de conhecimento diversas.

Recentemente, em função das Novas Diretrizes Nacionais Curriculares (DCNs), muitos cursos de engenharia vêm reformulando seus currículos, sendo uma boa oportunidade de explicitamente criar integrações entre diversas áreas da Engenharia Civil e delas com áreas básicas, incluindo a Computação. Experiências do tipo estão atualmente em curso, sem necessariamente se incorrer em aumento de carga horária, por meio de Projetos Integradores ou de outras atividades formativas que estimulem interdisciplinaridade. Desafios de inovação podem utilizar essas tecnologias, cada vez mais disponíveis e de fácil uso, e promover aplicações contextualizadas de conhecimentos

da engenharia civil. Nesse sentido, a disciplina de Programação pode ser conectada a diversos desses projetos, incentivando a criação de algoritmos aplicados a problemas reais. Além disso, a curricularização da Extensão também pode direcionar projetos para o uso de IA em muitas disciplinas que se beneficiariam em termos de eficiência das tarefas, fortalecendo a relação entre teoria e prática. Essas estratégias modernizam o currículo, preparando engenheiros(as) para os desafios contemporâneos.

No entanto, é importante reconhecer alguns dos riscos associados ao uso da IA:

- **Questões Éticas:** a produção de textos e a geração de dados com a facilidade atual levantam preocupações éticas significativas;
- **Alucinações, Conteúdo Falso ou Irrelevante:** a IA Generativa pode gerar informações aparentemente plausíveis, todavia completamente fabricadas ou irrelevantes. As chamadas “alucinações” podem comprometer a confiança nas aplicações de IA, especialmente em contextos onde a precisão é crítica;
- **Consumo de Energia (Sustentabilidade):** a infraestrutura computacional necessária para suportar a IA consome bastante energia, sendo essencial desenvolver soluções mais eficientes e sustentáveis;
- **Modelos Opacos (Dificuldade de Compreensão):** muitos algoritmos de IA são considerados “caixas-pretas”. A falta de transparência e a concentração de conhecimento em poucas entidades podem limitar a compreensão e a capacidade de intervenção de outros *stakeholders*. É essencial investir na educação e formação para que engenheiros(as) e gestores(as) possam usar essas ferramentas de maneira eficaz e informada;
- **Viés e Desbalanço de Dados:** algoritmos treinados em conjuntos de dados enviesados podem perpetuar ou até exacerbar erros. É fundamental escrutinar os dados e que os modelos sejam constantemente avaliados e ajustados para minimizar esses vieses;
- **Responsabilidade pelos Erros:** um desafio é determinar responsabilidades quando a IA comete um erro. Se um modelo de IA gera conteúdo incorreto ou prejudicial, a responsabilidade deve recair sobre o desenvolvedor, o usuário ou a entidade que implantou a IA? Tal falta de clareza pode levar a lacunas na regulamentação e proteção legal.

5. CONSIDERAÇÕES FINAIS

À medida que nos aproximamos dos limites da nossa capacidade cognitiva, buscamos nas máquinas – computadores – o potencial aprimoramento do pensamento, transcendendo nossas limitações. Os computadores acrescentaram um domínio digital separado do domínio físico em que sempre vivemos. A revolução intelectual trazida pela IA nos desafia a uma nova abordagem para o conhecimento, que equilibre a capacidade de performance com a necessidade de compreensão. Para a infraestrutura viária, isso significa integrar reflexões e descobertas produzidas por modelos baseados em dados (*data-driven*) com a compreensão tradicional baseada na física (*mechanics*), criando uma abordagem que aproveite o melhor dos dois mundos. A IA oferece ferramentas poderosas para melhorar a performance, mas deve ser complementada por uma compreensão dos processos físicos subjacentes. Assim, facilitaremos que as inovações em pavimentação não apenas melhorem o desempenho imediato, mas contribuam para um entendimento mais completo e sustentável da infraestrutura. Este tipo de abordagem é essencial inclusive quando da sensibilização para o

financiamento de projetos no nosso domínio de conhecimento. Afinal, a IA possui um potencial transformador e de entregas práticas, além de ser um atrator de jovens pesquisadores; todavia, a conscientização e a mitigação dos riscos associados são cruciais para garantir que seu impacto seja positivo e sustentável. A colaboração entre cientistas, engenheiros(as) e formuladores de políticas, incluindo-se o compartilhamento de dados, será vital para navegar esses desafios e maximizar os benefícios das tecnologias emergentes.

AGRADECIMENTOS

Ao CNPq pela bolsa PQ e ao grupo de pesquisa do LMP/UFC (INCT-Infra). Ao DNIT, ao TCE-CE e à Funcap pelo apoio à pesquisa e inovação, com o encorajamento para explorar o potencial da IA. Um agradecimento aos ex-alunos(as) pelos exemplos para o manuscrito e gentil ajuda desde a minha *Keynote Lecture* na Conferência da ISAP 2024: Antonio Ribeiro Junior, Carla Beatriz Araújo, Carlos David Melo, Haikel Busgaib, Jorge Lucas Júnior, Lara Furtado, Lucas Babadopulos, Lucas Mariano, Otávio Gomes, e um reconhecimento especial ao Pedro Rocha pela organização dos exemplos e figuras. Ao Nicolás Soares, um cientista de dados com quem estou sempre a aprender, agradeço pela atenciosa revisão do texto e por apontar ajustes relevantes em aspectos técnicos.

REFERÊNCIAS

- Abdelaziz, N.; R.T.A. El-Hakim; S.M. El-Badawy et al. (2020) International Roughness Index prediction model for flexible pavements. *The International Journal of Pavement Engineering*, v. 21, n. 1, p. 88-99. DOI: 10.1080/10298436.2018.1441414.
- Alnedawi, A.; R. Al-Ameri e K.P. Nepal (2019) Neural network-based model for prediction of permanent deformation of unbound granular materials. *Journal of Rock Mechanics and Geotechnical Engineering*, v. 11, n. 6, p. 1231-1242. DOI: 10.1016/j.jrmge.2019.03.005.
- Araújo, C. B. C.; F.A. Souza Filho; J.B. Soares et al. (2023) The effects of climate change on the performance of asphaltic pavement structures. *International Journal of Advances in Engineering and Technology*, v. 16, n. 3, p. 66.
- Brega, J.R.F. (1997) *Utilização de Redes Neurais Artificiais em um Sistema de Gerência de Pavimentos*. Tese (doutorado). Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos.
- Coutinho Neto, B. (2000) *Redes Neurais Artificiais Como Procedimento para Retroanálise de Pavimentos Flexíveis*. Dissertação (mestrado). Escola de Engenharia de São Carlos, Universidade de São Paulo. São Carlos.
- Cranmer, M. (2024) *The Next Great Scientific Theory is Hiding Inside a Neural Network*. New York: Simons Foundation.
- Eidgahee, D.R.; H. Jahangir; N. Solatifar et al. (2022) Data-driven estimation models of asphalt mixtures dynamic modulus using ANN, GP and combinatorial GMDH approaches. *Neural Computing & Applications*, v. 34, n. 20, p. 17289-17314. DOI: 10.1007/s00521-022-07382-3.
- Furtado, L.S.; J.B. Soares e V. Furtado (2024a) A task-oriented framework for generative AI in design. *Journal of Creativity*, v. 34, n. 2, p. 100086. DOI: 10.1016/j.yjoc.2024.100086.
- Furtado, L.S.; H. Busgaib; L. Babadopulos et al. (2024b) Prompts para análise de dados espaciais sobre defeitos de pavimentos com o ChatGPT-4. In *XXII Congreso Ibero Latinoamericano del Asfalto*. Madrid: ASEFMA.
- Gonçalves, H.B.B.; K.B. Paz; L.F.A.L. Babadopulos et al. (2024) Continuous visual survey of road pavement using convolutional neural networks and smartphone technology: a data-driven approach. In *Proceedings of the International Conference on Maintenance and Rehabilitation of Pavements*. Cham: Springer, p. 203-213. Vol. 523. DOI: 10.1007/978-3-031-63584-7_21.
- Ghorbani, B.; A. Arulrajah; G. Narsilio; S. Horpibulsuk; M.W. Bo (2020) Development of genetic-based models for predicting the resilient modulus of cohesive pavement subgrade soils. *Soils and Foundations*, v. 60, n. 2, p. 398-412. DOI: 10.1016/j.sandf.2020.02.010.
- Kaloo, M.R.; D. Kumar; P. Samui et al. (2019) Particle Swarm Optimization Algorithm-Extreme Learning Machine (PSO-ELM) model for predicting resilient modulus of stabilized aggregate bases. *Applied Sciences*, v. 9, n. 16, p. 3221. DOI: 10.3390/app9163221.
- Kissinger, H. A., E. Schmidt e D. Huttenlocher (2024) ChatGPT Heralds an intellectual revolution. *WSJ*.
- Lucas Jr., J.L.O.; L.F.A.L. Babadopulos e J.B. Soares. (2019) Aggregate-binder adhesiveness assessment and investigation of the influence of morphological and physico-chemical properties of mineral aggregates. *Road Materials and Pavement Design*, v. 20, n. sup1, p. S79-S94. DOI: 10.1080/14680629.2019.1588773.
- Majidifard, H.; B. Jahangiri; P. Rath et al. (2021) Developing a prediction model for rutting depth of asphalt mixtures using gene expression programming. *Construction & Building Materials*, v. 267, p. 120543. DOI: 10.1016/j.conbuildmat.2020.120543.
- Mariano, A.L.G. (2023) *Uso de Aprendizado de Máquina Interpretável para Avaliação da Deformação Permanente em Misturas Asfálticas*. Dissertação (mestrado). Programa de Pós-graduação em Engenharia de Transportes, Universidade Federal do Ceará. Fortaleza.
- Melo, C. D. R., Soares, J. B., Parente Jr., E., & Silva, J. C. T. (2024) Gaussian process-based estimation of asphalt mixture master stiffness curve under data scarcity. No prelo.
- Ministério da Ciência e Tecnologia (2024) *IA para o Bem de Todos: Proposta de Plano Brasileiro de Inteligência Artificial 2024-2028*. Brasília.

- Mota, B.C.; B.P. Ignez; G.V. Silva et al. (2023) Construção e análise de banco de dados de misturas asfálticas com ferramentas de inteligência artificial. In *Anais do 37º Congresso de Pesquisa e Ensino em Transportes*. Santos, SP.
- Naderpour, H.; A.H. Rafiean e P. Fakharian (2018) Compressive strength prediction of environmentally friendly concrete using artificial neural networks. *Journal of Building Engineering*, v. 16, p. 213-219. DOI: 10.1016/j.job.2018.01.007.
- Nunes, D.E. e V.F.S. Mota (2019) A participatory sensing framework to classify road surface quality. *Journal of Internet Services and Applications*, v. 10, n. 1, p. 13. DOI: 10.1186/s13174-019-0111-1.
- Piryonesi, S.M. e T. El-Diraby (2021) Climate change impact on infrastructure: a machine learning solution for predicting pavement condition index. *Construction & Building Materials*, v. 306, p. 124905. DOI: 10.1016/j.conbuildmat.2021.124905.
- Prince, S.J.D. (2023) *Understanding Deep Learning*. Cambridge: The MIT Press.
- Ribeiro, T.R. e F.H.L. Oliveira (2023) Desenvolvimento de modelos de previsão de coeficiente de atrito em pistas de pouso e decolagem brasileiras com Redes Neurais Artificiais. *Revista Transportes*, v. 31, n. 2, e2792. DOI: 10.58922/transportes.v31i2.2792.
- Saha, S.; F. Gu; X. Luo et al. (2018) Use of an artificial neural network approach for the prediction of resilient modulus for unbound granular material. *Soil and Foundation*, v. 2672, n. 52, p. 23-33.
- Serafim, M.O.; C.A. Sousa; L.C. Almeida et al. (2023) Automated detection of defects and vertical signs on roadways using images produced by drivers. *Journal of Testing and Evaluation*, v. 51, n. 4, p. 1897. DOI: 10.1520/JTE20220298.
- Soares, J.B. (2020) Reflexões sobre um programa de pesquisa científica para a infraestrutura viária do Brasil. *Revista Transportes*, v. 28, n. 5, p. 154-168. DOI: 10.14295/transportes.v28i5.2174.
- Soares, J. B. (2024) Physics-Inspired vs. Data-Driven: Paradigms in Pavement Infrastructure Research (Keynote Lecture). In *14th ISAP Conference, International Society for Asphalt Pavements*. Montreal, Canadá: ÉTS.
- Souza, W.M.; A.J.A. Ribeiro e C.A.U. Silva (2022a) Use of ANN and visual-manual classification for prediction of soil properties for paving purposes. *The International Journal of Pavement Engineering*, v. 23, n. 8, p. 1482-1490. DOI: 10.1080/10298436.2020.1807546.
- Souza, W.M.; A.J.A. Ribeiro e S.H.A. Barroso (2022b) Estimating the resilient modulus of subgrade materials using visual inspection. *Transportes*, v. 30, n. 3, p. 2738. DOI: 10.14295/transportes.v30i3.2738.
- Specht, L.P. e O. Khatchatourian (2014) Application of artificial intelligence to modelling asphalt-rubber viscosity. *The International Journal of Pavement Engineering*, v. 15, n. 9, p. 1-11. DOI: 10.1080/10298436.2014.893316.
- Specht, L.P.; O. Khatchatourian; L.A.T. Brito et al. (2007) Modeling of asphalt-rubber rotational viscosity by statistical analysis and neural networks. *Materials Research*, v. 10, n. 1, p. 69-74.
- Tong, Z.; J. Gao e H. Zhang (2017) Recognition, location, measurement, and 3D reconstruction of concealed cracks using convolutional neural networks. *Construction & Building Materials*, v. 146, p. 775-787. DOI: 10.1016/j.conbuildmat.2017.04.097.
- Xu, Y.; Z. Xie; Y. Feng et al. (2018) Road extraction from high-resolution remote sensing imagery using deep learning. *Remote Sensing*, v. 10, n. 9, p. 1461. DOI: 10.3390/rs10091461.
- Zhang, A.; K.C.P. Wang; B. Li et al. (2017) Automated pixel-level pavement crack detection on 3D asphalt surfaces using a deep-learning network. *Computer-Aided Civil and Infrastructure Engineering*, v. 32, n. 10, p. 805-819. DOI: 10.1111/mice.12297.