



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"

UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"
FACULDADE DE ENGENHARIA – CAMPUS DE ILHA SOLTEIRA
CURSO DE ENGENHARIA CIVIL

ANÁLISE DE PREVISÃO DO QUOCIENTE DE IRREGULARIDADE (QI) EM
PAVIMENTO RODOVIÁRIO COM USO DE SMARTPHONE E INTELIGÊNCIA
ARTIFICIAL

RENAN BARONI ALTRAN

Orientador: Professor Dr. Jairo Salim Pinheiro de Lima

Trabalho de Conclusão de Curso
apresentado à Faculdade de
Engenharia do Campus de Ilha
Solteira – UNESP, como parte dos
requisitos para obtenção do grau de
Engenheiro Civil.

Ilha Solteira/SP
Maio de 2025

AGRADECIMENTOS

Está se encerrando uma das etapas mais importantes da minha vida, a graduação em Engenharia Civil, que me mostrou que essa profissão vai muito além de estruturas e construções — ela é, acima de tudo, uma escola de disciplina, planejamento, lógica e transformação. Ao longo desses anos, aprendi que ser engenheiro é buscar soluções com responsabilidade, criatividade e eficiência.

Sou imensamente grato aos meus pais, pelo apoio incondicional aos meus estudos e aos meus sonhos — inclusive os mais ousados — e por acreditarem em cada passo dessa trajetória. Sem o suporte e o amor de vocês, essa jornada não teria o mesmo significado.

Total gratidão também aos amigos que estiveram comigo nesse período, pelos momentos descontraídos e pelas conversas que me ajudaram a atravessar os desafios da graduação. Um agradecimento especial à República Dama Amada, que sempre será minha casa, aos seus moradores, meus irmãos, que sempre estiveram ao meu lado nessa caminhada e me deram um apoio fundamental. Também deixo meu agradecimento aos meus amigos Pedro Trevizoli, Ricardo Galindo e Lucas Garcia, que me ajudaram muito na pesquisa de campo.

À Unesp de Ilha Solteira e a todos os docentes que contribuíram com minha formação, muito obrigado. Em especial, ao Professor Jairo, por sua dedicação, seriedade e comprometimento, que tanto me inspiraram e pelo apoio neste trabalho. Sinto orgulho em dizer que estudei na Unesp.

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

- A469a Altran, Renan Baroni.
Análise de previsão do quociente de irregularidade (QI) em pavimento rodoviário com uso de smartphone e inteligência artificial / Renan Baroni Altran. -- Ilha Solteira: [s.n.], 2025
57 f. : il.
- Trabalho de conclusão de curso (Graduação em Engenharia Civil) - Universidade Estadual Paulista (UNESP), Faculdade de Engenharia, Ilha Solteira, 2025
- Orientador: Jairo Salim Pinheiro de Lima
Inclui bibliografia
1. Pavimentos. 2. Quociente De Irregularidade. 3. Smartphone. 4. Inteligência artifical.

ATA DE DEFESA DE TRABALHO DE CONCLUSÃO DE CURSO

CURSO: ENGENHARIA CIVIL

ÁREA DE CONCENTRAÇÃO: TRANSPORTES

REALIZADA EM: 17-06-2025

DISCENTE: Renan Baroni Altran

COMISSÃO EXAMINADORA

1. Prof. Dr. Jairo Salim Pinheiro de Lima – UNESP/FE Ilha Solteira (Orientador).
2. Prof. Dr. Cesar Gustavo da Rocha Lima – UNESP/FE Ilha Solteira (Examinadora).
3. Prof. Dr. Breno Padovezi Rocha – UNESP/FE Ilha Solteira (Examinador).

Título do trabalho: Análise de previsão do quociente de irregularidade (QI) em pavimento rodoviário com uso de smartphone e inteligência artificial.

Local: Unesp, Departamento de Engenharia Civil.

Horário de início: 14:00h.

Em sessão pública, após exposição em torno de 30 (trinta minutos), o discente foi arguido oralmente, e no final da exposição foi "**APROVADO**" pelos membros componentes da Comissão Examinadora. Nada mais havendo, foi lavrada a presente ATA, a qual é assinada pelos membros da Comissão Examinadora e pelo discente.

Ilha Solteira, 17 de junho de 2025.

Prof. Dr. Jairo Salim Pinheiro de Lima
UNESP/FE Ilha Solteira (Orientador)

Prof. Dr. Cesar Gustavo da Rocha Lima
UNESP/FE Ilha Solteira

Prof. Dr. Breno Padovezi Rocha
UNESP/FE Ilha Solteira

Ciente:

Discente: Renan Baroni Altran

Faculdade de Engenharia de Ilha Solteira

Cursos: Agronomia, Ciências Biológicas, Eng. Civil, Eng. Elétrica, Eng. Mecânica, Física, Matemática e Zootecnia.
Avenida Brasil Centro, 56 Caixa Postal 31 CEP 15385-000. Ilha Solteira São Paulo Brasil
pabx (18) 3743 1000 fax (18) 3742 2735 scom@adm.feis.unesp.br www.feis.unesp.br

RESUMO

Os principais objetivos dos pavimentos rodoviários são garantir trafegabilidade, conforto e segurança aos usuários. Com o passar do tempo e o uso contínuo, esses pavimentos são desgastados, exigindo intervenções que devem ser planejadas com base em avaliações técnicas. Nesse contexto, o Sistema de Gerência de Pavimentos (SGP) apresenta-se como uma ferramenta estratégica que permite o diagnóstico de condições de uma via, prever esse desgaste e deterioração, bem como orientar ações de manutenção com maior eficiência e menor custo. Entre os indicadores de irregularidades dos pavimentos utilizados no Brasil, destaca-se o Quociente de Irregularidade (QI), normalmente calculado pelo método de nível e mira normatizado pela DNER 173/86. Porém, esse método pode ser demorado e de alto custo, o que inspirou a busca por alternativas mais práticas. Este trabalho tem como proposta desenvolver um modelo preditivo de Inteligência Artificial baseado em regressão para estimar o QI com base em dados coletados por sensores de smartphones acoplados a veículos em movimento. Entre esses sensores, apresentam-se os acelerômetros, que permitem a captação e leitura das vibrações verticais geradas pelas irregularidades da pista, permitindo a correlação entre os sinais registrados e os valores reais de QI. Os resultados obtidos demonstraram boa acurácia preditiva, apesar de uma base de dados limitada, com coeficientes de determinação elevados e erros médios reduzidos, apontando para o potencial da abordagem como alternativa viável, acessível e de baixo custo para a avaliação funcional de pavimentos em contextos onde recursos técnicos e financeiros são limitados.

Palavras-chave: gerência de pavimentos; quociente de irregularidade; avaliação objetiva de pavimentos; inteligência artificial.

ABSTRACT

The main objectives of road pavements are to ensure trafficability, comfort, and safety for users. Over time and with continuous use, these pavements deteriorate, requiring interventions that must be planned based on technical evaluations. In this context, the Pavement Management System (PMS) emerges as a strategic tool that enables the diagnosis of road conditions, the prediction of wear and deterioration, and the guidance of maintenance actions with greater efficiency and lower cost. Among the pavement irregularity indicators used in Brazil, the Irregularity Quotient (IQ) stands out, which is typically calculated using the level and staff method standardized by DNER 173/86. However, this method can be time-consuming and costly, which has led to the search for more practical alternatives.

This work proposed the development of a regression-based Artificial Intelligence predictive model to estimate the IQ using data collected by smartphone sensors attached to moving vehicles. Among these sensors are accelerometers, which are capable of capturing and recording vertical vibrations caused by pavement irregularities, allowing for correlation between the recorded signals and the actual IQ values. The results obtained demonstrated good predictive accuracy, despite the limited dataset, with high coefficients of determination and low mean errors, indicating the potential of this approach as a viable, accessible, and low-cost alternative for functional pavement evaluation in contexts where technical and financial resources are limited.

Keywords: pavement management; irregularity quotient; objective pavement evaluation; artificial intelligence.

LISTA FIGURAS

Figura 1 - O Sistema Pavimento.....	6
Figura 2 - Estrutura de um Sistema de Gerência de Pavimentos	7
Figura 3 - Atividades básicas de um SGP.....	7
Figura 4 – Representação esquemática dos defeitos de superfície.	12
Figura 5 – Ficha de avaliação de serventia	14
Figura 6 – Variação da serventia ao longo do tempo ou tráfego.....	15
Figura 7 – Esquema de aplicação do método nível e mira	18
Figura 8 – Sistema de coordenadas de um smartphone	19
Figura 9 – Localização dos trechos 1 e 2 analisados.	24
Figura 10 – Localização do trecho 3 analisado.....	25
Figura 11 – Trecho 1, Rua Monção.....	25
Figura 12 – Trecho 2, Rua Batalha	26
Figura 13 – Trecho 3, Rua Corumbá	26
Figura 14 – Aplicação do método nível e mira no campo	28
Figura 15 – Local de fixação do Smartphone no veículo	30
Figura 16 – Interface do aplicativo “Medidor de Vibração”.....	31
Figura 17 – Pavimento não homogêneo presente no trecho 2	32
Figura 18 – Modelo de Regressão Linear Múltipla utilizado em linguagem Python.	33
Figura 19 – Modelo de Regressão Polinomial de Segundo Grau utilizado em linguagem Python.....	34
Figura 20 – Resultados do modelo de Regressão Linear Múltipla utilizado em linguagem Python.....	37
Figura 21 – Resultados do modelo de Regressão Polinomial utilizado em linguagem Python.....	40
Figura 22 - Gráfico de dispersão QI Previsto x QI Real do modelo de Regressão Linear	44
Figura 23 – Gráfico de dispersão QI Previsto x QI Real do modelo de Regressão Polinomial.....	44

LISTA TABELAS

Tabela 1 – Classificação do pavimento de acordo com seu QI.....	17
Tabela 2 – QI médio de cada trecho	35
Tabela 3 – Amplitude média e máxima de vibração para cada trecho	36
Tabela 4 – Previsão final do modelo de regressão polinomial com as variáveis normalizadas	39
Tabela 5 – Previsão final do modelo de regressão polinomial com as variáveis normalizadas	42
Tabela 6 – Comparativo dos resultados obtidos pelos dois modelos.....	43

ÍNDICE

1	INTRODUÇÃO	1
2	OBJETIVOS	4
2.1	Objetivos Gerais	4
2.2	Objetivos Específicos	4
3	REVISÃO BIBLIOGRÁFICA	5
3.1	Sistema de Gerência de Pavimentos	5
3.2	Desempenho do Pavimento	9
3.2.1	<i>Deterioração do Pavimento</i>	9
3.2.2	<i>Desempenho Funcional</i>	9
3.2.3	<i>Desempenho Estrutural</i>	10
3.3	Defeitos nos Pavimentos	10
3.4	Modelos de Previsão de Desempenho	12
3.5	Avaliação Funcional	13
3.5.1	<i>Tipos de avaliações funcionais</i>	13
3.5.2	<i>Avaliação Subjetiva</i>	13
3.5.3	<i>Avaliação Objetiva</i>	15
3.6	Irregularidade Longitudinal	15
3.7	Método do Nível e Mira	17
3.8	Dispositivos Móveis	18
3.8.1	<i>Sensores Presentes nos Smartphones Atuais</i>	18
3.8.2	<i>Uso dos Sensores dos Smartphones para Avaliação da Irregularidade</i>	19
3.9	Inteligência Artificial	20
3.9.1	<i>Modelos de Regressão</i>	20
3.9.2	<i>Regressão Linear Múltipla</i>	21
3.9.3	<i>Regressão Polinomial</i>	23
3.9.4	<i>Coeficiente de Determinação</i>	23
4	MATERIAIS E MÉTODOS	24
4.1	Materiais	24
4.2	Métodos	27
5	RESULTADOS E DISCUSSÃO	35
6	CONCLUSÃO	45
7	REFERÊNCIAS	46

1 INTRODUÇÃO

A avaliação funcional da condição de um pavimento rodoviário é um componente crítico para garantir estradas seguras e eficientes. Ela não apenas beneficia os usuários da estrada, como também tem implicações significativas em termos de segurança, economia e qualidade de vida das comunidades que dependem dessa infraestrutura.

Conceitua-se irregularidade longitudinal de um pavimento, ou simplesmente irregularidade, como o conjunto dos desvios da superfície viária em relação a um plano de referência, desvios estes que afetam a qualidade do rolamento, a dinâmica dos veículos e a ação dinâmica das cargas sobre a via (DNER, 2000).

Essas irregularidades podem ser causadas por diversos fatores, como desgaste natural, ação climática, tráfego intenso, inadequada construção ou manutenção e podem ser medidas subjetivamente ou objetivamente.

A capacidade de um trecho específico de pavimento de proporcionar, na opinião do usuário, rolamento suave e confortável em determinado momento, para quaisquer condições de tráfego é definida como serventia atual. O Valor de Serventia Atual (VSA) é uma medida subjetiva das condições de superfície do pavimento, feita por um grupo de avaliadores que percorrem o trecho sob análise, registrando as suas opiniões sobre a capacidade do pavimento atender às exigências do tráfego que sobre ele atua, no momento da avaliação, quanto à suavidade e ao conforto (DNIT, 2003).

Com o quociente entre a aceleração vertical total e o comprimento da seção é possível medir a irregularidade, em metros por quilometro, por meio do International Roughness Index (IRI). O IRI é o índice de irregularidade internacional utilizado em diversos países. No Brasil, embora algumas empresas também utilizem o IRI, o índice normatizado é o Quociente de Irregularidade (QI), descrito na DNER ES 173/86, e medido em contagens por quilometro.

O Quociente de Irregularidade é uma medida objetiva para a avaliação da condição de pavimentos, podendo variar de péssimo a excelente (DNIT, 2006), ele é um indicativo do estado de conservação funcional do pavimento e quanto menor for o seu valor, melhor é o estado do mesmo.

A medida de parâmetros relacionados à irregularidade pode ser realizada por diferentes tipos de equipamentos. Os sistemas medidores classificam-se em quatro grupos:

- a) sistemas de medidas diretas de perfil – Método de nível e mira;
- b) sistemas de medida indireta do perfil – Perfilômetro de superfície GMR, Perfilômetro AASHTO, Perfilômetro CHLOE, Merlin do TRRL;
- c) sistemas do tipo resposta – Rugosímetro BPR, Bump Integrator, Maysmeter, Integrador IPR/USP;
- d) sistemas de medida com sonda sem contato – Perfilômetro Laser, Perfilômetro Acústico da Universidade FELT (DNER, 2000).

Para este trabalho, será usado o sistema de medidas diretas de perfil – Método de nível e mira, normatizado pela norma técnica DNER ES 173/86 como referência para a “calibração” dos dados obtidos com aparelhos do tipo smartphones.

Para Islam *et al.* (2014), os smartphones atuais contam com diversos equipamentos de medição e sensores, entre eles acelerômetros e giroscópios. Esses smartphones, quando acoplados em veículos são capazes de captar as vibrações decorrentes das irregularidades longitudinais por meio do acelerômetro (Hanson et al., 2014). Para este trabalho foi utilizado o aplicativo “Medidor de Vibração” da EXA Tools para a leitura das amplitudes de vibração, que posteriormente seriam relacionadas, com o uso de Inteligência Artificial, aos valores de QI medidos para os trechos de pavimentos em questão.

Modelos de IA baseados em regressão, em especial os múltiplos e polinomiais, são amplamente utilizados para problemas em que se deseja prever uma saída numérica (neste caso, o Quociente de Irregularidade – QI) com base em múltiplos fatores de entrada (como amplitudes de vibração e velocidade). Geron (2019) admite que algoritmos de regressão linear e suas extensões são considerados modelos de aprendizado supervisionado que ajustam funções matemáticas para minimizar o erro entre os valores previstos e os reais. Tais modelos são de fácil implementação, altamente interpretáveis e, com o auxílio de técnicas de pré-processamento e engenharia de atributos, podem alcançar resultados comparáveis a métodos mais complexos, o que os torna ideais para aplicações com base de dados reduzida e bem estruturada, como é o caso deste estudo.

A escolha pela utilização de Inteligência Artificial baseada em regressão neste trabalho, justifica-se pela capacidade desse tipo de modelo aprender padrões matemáticos de dados observacionais, permitindo a previsão de variáveis contínuas com elevado nível de acurácia.

2 OBJETIVOS

2.1 Objetivos Gerais

Este trabalho tem como objetivo geral desenvolver algoritmo de Inteligência Artificial para estimar o quociente de irregularidade (QI) de vias pavimentadas, utilizando um aparelho de Smartphone.

2.2 Objetivos Específicos

- Revisão da Bibliografia.
- Cálculo de QI dos trechos definidos pelo método nível e mira.
- Coleta de dados de vibração com smartphone.
- Desenvolvimento de uma IA de Regressão que relacione dados de vibração coletados via smartphone com os resultados de QI.
- Análise dos resultados obtidos.

3 REVISÃO BIBLIOGRÁFICA

3.1 Sistema de Gerência de Pavimentos

De acordo com Bernucci *et al.* (2008), o objetivo principal da pavimentação é garantir a trafegabilidade em qualquer época do ano e condições climáticas, e proporcionar aos usuários conforto ao rolamento e segurança. Uma vez que o solo natural não é suficientemente resistente para suportar a repetição de cargas de roda sem sofrer deformações significativas, torna-se necessária a construção de uma estrutura, denominada pavimento, que é construída sobre o subleito. A estrutura do pavimento é dimensionada para suportar as cargas dos veículos, distribuindo as solicitações às suas diversas camadas e ao subleito, limitando as tensões e as deformações de forma a garantir um desempenho adequado da via, pelo período pretendido.

Porém, sabe-se que diferente de outras obras de construção civil, a vida útil de um pavimento é relativamente curta. Então, na metade da década de 1970, surgiu nos Estados Unidos o Sistema de Gerência de Pavimentos (SGP) e o seu desenvolvimento foi impulsionado pela necessidade de conservar a malha rodoviária existente (Albuquerque, 2007).

Albuquerque (2007), em sua tese de doutorado, retrata brevemente sobre o histórico de implementação do SGP nos EUA. A *American Association of State Highway and Transportation Officials* (AASHTO) publicou o seu primeiro guia sobre gerência de pavimentos em 1985, válido em todo território americano. Logo depois, o *Federal Highway Administration* (FHWA) estabeleceu que todos os estados norte americanos tinham que implantar um SGP para as suas malhas rodoviárias federais, como requisito para receber investimentos (NHI, 1988).

Os conceitos e necessidades de implantação de um SGP logo se espalharam pelo mundo, majoritariamente sendo impulsionado pelo programa *Highway Development and Management* (HDM), do Banco Mundial (Albuquerque, 2007). Países em desenvolvimento, desde 1980, estão aplicando a metodologia do HDM e a versão HDM-III foi utilizada por duas décadas analisando técnica e economicamente projetos de rodovias com o objetivo de preparar programas de investimentos em rodovias e análise de estratégias.


No Brasil, apesar da participação nas pesquisas para desenvolvimento das primeiras versões do HDM nos anos 1970, a implantação de um SGP no DNER (atualmente DNIT) se deu a partir de 1982, quando a Direção do Órgão, por iniciativa do Instituto de Pesquisas Rodoviárias (IPR), criou a Comissão Permanente de Gerência de Pavimentos – CPGP (Visconti, 2000 apud Albuquerque, 2007).

De acordo com Visconti (2000), foi a partir de 1985 que o DNER passou a utilizar a metodologia e os procedimentos para a utilização dos resultados para levantamentos em campo do modelo HDM-III, com o objetivo de selecionar economicamente as alternativas de manutenção para todos os trechos da rede federal pavimentada.

No início dos anos 2000, o Brasil passou a utilizar o novo modelo de análise técnica e econômica de rodovias do Banco Mundial, o HDM-4. Hoje, o Departamento Nacional de Infraestrutura de Transportes (DNIT) utiliza o HDM-4 como ferramenta obrigatória para a obtenção de financiamentos junto ao Banco Mundial, aplicando-o na análise econômica de redes rodoviárias.


As Figuras 1 e 2 mostram respectivamente, o conjunto de componentes que interagem mutuamente e formam o Sistema Pavimento e como um SGP é estruturado, de acordo com o Manual de Gerência de Pavimentos (DNIT, 2011).

Figura 1 - O Sistema Pavimento



Fonte: Manual de Gerência de Pavimentos (DNIT, 2011)


Figura 2 - Estrutura de um Sistema de Gerência de Pavimentos



Fonte: Manual de Gerência de Pavimentos (DNIT, 2011)

A Figura 3, apresenta a sequência lógica das atividades básicas que estruturam um SGP (Visconti, 2000).

Figura 3 - Atividades básicas de um SGP



Fonte: Visconti (2000)

Assim, um sistema de gerência de pavimentos compreende ampla gama de atividades, incluindo o planejamento, a programação de investimentos, o projeto, a construção, a manutenção e a avaliação e o controle periódicos de todas as fases do processo e da própria rede pavimentada (Visconti, 2000).

De acordo com a Figura 3, nota-se que as atividades específicas, a nível de rede, de um SGP estão normalmente ligadas à área de planejamento e são, segundo Visconti (2000), agrupadas em três grandes atividades:

- avaliação periódica dos pavimentos (ou coleta de dados);
- uso de metodologia para determinar as prioridades; e
- elaboração de programa plurianual de investimentos.

A avaliação periódica dos pavimentos é fundamental para o bom funcionamento de um sistema de gerência, pois é com base nela que se obtêm os dados e informações essenciais para orientar a tomada de decisão. Trata-se, sem dúvida, da etapa mais complexa e, ao mesmo tempo, a mais relevante do processo. Um modelo de priorização de investimentos, por mais sofisticado que seja, torna-se ineficaz se for alimentado com dados imprecisos ou inconsistentes.

Após a coleta das informações, aplica-se uma análise técnica baseada em critérios objetivos, que permite definir as prioridades de intervenção, indicando o momento mais adequado e a estratégia de manutenção a ser adotada.

Por fim, elabora-se um programa de investimentos de médio prazo — geralmente com horizonte entre três e cinco anos — no qual as recomendações técnicas são compatibilizadas com as diretrizes políticas e administrativas do órgão rodoviário. Esta última etapa tende a variar de acordo com as particularidades de cada organização rodoviária, o que dificulta a padronização de procedimentos entre diferentes instituições.

O subsistema de Projetos, segundo Albuquerque (2007), é responsável por analisar as propostas de restauração e construção de pavimentos, considerando as restrições orçamentárias estabelecidas no âmbito do planejamento. Dessa análise, busca-se identificar a alternativa mais eficiente em termos de aproveitamento dos recursos disponíveis. Para isso, é indispensável contar com dados técnicos detalhados, que envolvam o desempenho estrutural e funcional do pavimento, além de informações precisas sobre o tráfego previsto e os materiais utilizados na execução das obras.

Albuquerque (2007) ainda relata que o subsistema de Construção e Manutenção corresponde à fase de execução das intervenções previstas no planejamento e detalhadas nos projetos. Nessa etapa, é importante garantir o controle adequado dos custos envolvidos, bem como realizar a avaliação das características técnicas e do desempenho das soluções adotadas, a fim de assegurar a efetividade das ações e a durabilidade das obras realizadas.

3.2 Desempenho do Pavimento

3.2.1 Deterioração do Pavimento

Como apresentado no Manual de Restauração de Pavimentos Asfálticos (DNIT, 2006), os pavimentos são projetados para atender a determinadas exigências de desempenho ao longo de um período específico de vida útil. Durante esse tempo, é natural que ocorram mudanças em suas condições, partindo de um estado inicial ótimo até atingir um estado considerado ruim. Esse processo de perda gradual do desempenho funcional e estrutural da via é conhecido como deterioração do pavimento, e reflete os efeitos cumulativos do tráfego, do clima e do envelhecimento dos materiais ao longo dos anos.

3.2.2 Desempenho Funcional

O desempenho funcional refere-se à capacidade do pavimento satisfazer a sua função principal, que é a de fornecer uma superfície com serventia adequada em termos de qualidade de rolamento (DNIT, 2006).

No passado, definia-se por avaliações subjetivas à necessidade de restauração de um pavimento dada pela sua condição funcional, porém, os órgãos rodoviários têm à disposição equipamentos medidores de irregularidade longitudinal que efetuam medidas diretas do perfil em unidades como o IRI e o QI. Quando os pavimentos atingem valores limites de irregularidades ou de serventia, devem ser estudadas tratativas com a finalidade de restaurá-los.

3.2.3 Desempenho Estrutural

O desempenho estrutural refere-se à capacidade de um pavimento em manter a sua integridade estrutural, sem apresentar falhas significativas. Deve-se associar o desempenho estrutural com a preservação dos investimentos e considerar como o melhor momento para reabilitar o pavimento aquele que conduza a um menor custo do ciclo de vida (DNIT, 2006).

O Manual de Restauração de Pavimentos Asfálticos – DNIT (2006), relata que o conhecimento detalhado sobre os tipos, severidade e extensão dos defeitos no pavimento é fundamental para definir a necessidade de tratamentos específicos, além dos serviços convencionais de restauração. Dependendo do desempenho estrutural da via, pode ser indicada, por exemplo, a aplicação de camadas de alívio de tensão para reduzir a ocorrência de trincas por propagação no recapeamento. Em alguns casos, também se fazem necessários ensaios complementares para auxiliar na escolha da técnica de restauração mais adequada, que deve ser feita quando o pavimento atingir determinado nível de trincamento, deformação ou desagregação.

3.3 Defeitos nos Pavimentos


A norma DNIT 005/2003-TER – Defeitos nos pavimentos asfálticos – Terminologia define quais são os termos técnicos empregados em defeitos que ocorrem nos pavimentos flexíveis e semirrígidos e padroniza a linguagem adotada para a elaboração de normas e textos relativos a estes.

- **Fenda:** qualquer descontinuidade na superfície do pavimento, que conduza a aberturas de menor ou maior porte, apresentando-se sob diversas formas como fissuras ou trincas.
- **Afundamento:** deformação permanente caracterizada por depressão da superfície do pavimento, acompanhada, ou não, de solevamento, podendo apresentar-se sob a forma de afundamento plástico ou de consolidação.
- **Ondulação ou corrugação:** deformação caracterizada por ondulações ou corrugações transversais na superfície do pavimento.

- **Escorregamento:** deslocamento do revestimento em relação à camada subjacente do pavimento, com aparecimento de fendas em forma de meia-lua.
- **Exsudação:** excesso de ligante betuminoso na superfície do pavimento, causado pela migração do ligante através do revestimento.
- **Desgaste:** efeito do arrancamento progressivo do agregado do pavimento, caracterizado por aspereza superficial do revestimento e provocado por esforços tangenciais causados pelo tráfego.
- **Panela ou buraco:** cavidade que se forma no revestimento por diversas causas (inclusive por falta de aderência entre camadas superpostas, causando o deslocamento das camadas), podendo alcançar as camadas inferiores do pavimento, provocando a desagregação dessas camadas.
- **Remendo:** panela preenchida com uma ou mais camadas de pavimento na operação denominada de “tapa-buraco”, podendo ser profundo ou superficial.

A Figura 4 representa esquematicamente estes defeitos que ocorrem na superfície dos pavimentos flexíveis e semirrígidos.

Figura 4 – Representação esquemática dos defeitos de superfície.



Fonte: DNIT 005/2003-TER (DNIT, 2003).

3.4 Modelos de Previsão de Desempenho

Modelos de previsão de desempenho são ferramentas essenciais nos sistemas de gerência de pavimentos, pois permitem estimar como uma estrutura viária se comportará ao longo do tempo, considerando o tráfego, o clima, as condições iniciais da via e as ações de manutenção aplicadas. Com base nesses modelos, é possível planejar intervenções de forma preventiva, minimizando os custos totais de conservação e prolongando a vida útil do pavimento.

Esses modelos podem ser classificados em três categorias principais de acordo com Haas *et al.* (1994), citados por Rodrigues (2006).

- **Modelos empíricos:** são construídos de dados históricos e observações em campo, bastante utilizados por sua simplicidade e baixo custo de implementação; relacionam índices objetivos e subjetivos dos pavimentos com variáveis independentes.

- **Modelos mecanísticos:** baseiam-se em princípios físicos e nas propriedades dos materiais, considerando as solicitações aplicadas e as respostas da estrutura do pavimento.
- **Modelos empírico-mecanísticos:** combinam essas duas abordagens, equilibrando precisão com aplicabilidade prática.

Ferreira e Soares (2012) destacam que a escolha do modelo deve considerar a disponibilidade de dados, o tipo de pavimento e o nível de detalhamento exigido pelo estudo. Em países como o Brasil, onde a coleta sistemática de dados ainda enfrenta desafios, os modelos empíricos e híbridos são os mais utilizados em escala nacional.

Esses modelos são frequentemente incorporados a sistemas computacionais como o HDM-4, possibilitando simulações de vários cenários de intervenção e facilitando a priorização de investimentos em redes rodoviárias. A previsão de desempenho também é essencial para alimentar algoritmos de inteligência artificial que buscam automatizar a tomada de decisão na gestão da malha viária.

3.5 Avaliação Funcional

3.5.1 Tipos de avaliações funcionais

Como visto anteriormente (Bernucci et al., 2008) a avaliação funcional de um pavimento está ligada à condição de superfície do mesmo e a influência desta superfície no conforto ao rolamento. Esta avaliação é parte muito importante de um Sistema de Gerência de Pavimentos e permite definir o estado de degradação de um pavimento ou de um trecho de via.


De acordo com o DNIT (2006), existem as avaliações subjetivas, que avaliam as condições do pavimento por conceitos qualitativos (alfanuméricos) e as avaliações objetivas, que expressam a restauração do pavimento com medidas quantitativas da severidade dos defeitos superficiais.

3.5.2 Avaliação Subjetiva

O procedimento do DNIT 009/2003-PRO oficializou, no Brasil, a avaliação subjetiva por meio do VSA (Valor de Serventia Atual). Este VSA é atribuído por meio de uma escala numérica com variação de 0 a 5 e é dado subjetivamente pela média

das notas de avaliadores quanto ao conforto ao rolamento no trecho avaliado; esta escala apresenta 5 níveis de serventia, conforme expresso na Figura 5.

Figura 5 – Ficha de avaliação de serventia




Fonte: DNIT 009/2003-PRO (DNIT, 2003a).

O VSA é, em geral, elevado logo após a construção do pavimento, quando bem executado, pois exibe uma superfície suave e praticamente sem irregularidades. A condição de perfeição, sem qualquer irregularidade ($VSA = 5$), não é encontrada na prática. Como exemplo, nas pistas experimentais da AASHO, na década de 1960, foram obtidos valores de serventia inicial de 4,2 para pavimentos asfálticos e de 4,5 para pavimentos de concreto cimento Portland. Com o aprimoramento das técnicas construtivas, é possível obter, nos dois tipos de pavimentos, valores iniciais mais próximos da Nota 5. Portanto, o VSA, logo após o término da construção do pavimento, depende muito da qualidade executiva e das alternativas de pavimentação selecionadas (Bernucci et al., 2008).

Esse valor de serventia sempre diminuirá com o passar do tempo, muito por conta de intempéries e ação do tráfego, sobretudo. A Figura 6 mostra como a curva de serventia responde à utilização da via ao longo do tempo.

Figura 6 – Variação da serventia ao longo do tempo ou tráfego.



Fonte: Manual de Gerência de Pavimentos (DNIT, 2011)

3.5.3 Avaliação Objetiva

Para a avaliação objetiva de um determinado pavimento é utilizado o inventário dos defeitos (apresentado no item 3.3 deste documento), elaborado nas áreas de observação demarcadas no pavimento (com 6m x 3,5m, largura de faixa de tráfego), a cada 20 m. A avaliação objetiva consiste na medição direta dos parâmetros físicos que representam o desempenho funcional e estrutural da via.

Diferente das avaliações subjetivas, baseadas em inspeções visuais e julgamento técnico, a avaliação objetiva utiliza equipamentos e métodos normatizados para registrar características como irregularidade longitudinal, deflexão, textura superficial e atrito. Essas informações permitem quantificar o estado do pavimento de forma precisa e padronizada, subsidiando a tomada de decisão em sistemas de gerência. Ferreira e Soares (2012) admitem esse tipo de abordagem com fundamental para garantir confiabilidade aos diagnósticos e uniformidade aos critérios de intervenção.

3.6 Irregularidade Longitudinal

A irregularidade longitudinal é o somatório dos desvios da superfície de um pavimento, em relação a um plano de referência ideal do projeto geométrico, que afeta a dinâmica do veículo, o efeito dinâmico das cargas, a qualidade ao rolamento e a

drenagem superficial da via. Existe um índice internacional para a medida da irregularidade designado de IRI/*International Roughness Index* (índice de irregularidade internacional) – que é um índice estatístico, expresso em m/km, e quantifica os desvios da superfície do pavimento em relação à superfície de projeto (Bernucci et al., 2008).

A irregularidade longitudinal é avaliada ao longo de uma linha imaginária paralela ao eixo da via. Esta superfície de amostragem normalmente coincidente com as trilhas de roda deixadas pelos veículos. Em situações que exigem maior detalhamento, é possível realizar o levantamento do perfil em várias linhas paralelas, distribuídas transversalmente sobre a superfície da pista. A largura dessa linha de medição varia conforme o tipo de equipamento utilizado, podendo ser de alguns milímetros até poucos centímetros.

Existem diferentes métodos para realizar tal medição. Podem-se utilizar técnicas topográficas tradicionais, equipamentos de medição direta com ou sem contato, ou ainda métodos indiretos, como os equipamentos do tipo “resposta”. Estes últimos estimam a irregularidade com base nos desvios registrados pelo sistema de suspensão de um veículo em movimento, fornecendo uma representação do perfil longitudinal de acordo com o comportamento dinâmico durante o deslocamento.

Sayers e Karamihas (1998), citados pela Agência Nacional de Transportes Terrestres – ANTT (2017), classificam as técnicas e os equipamentos para medir irregularidades transversais.

- Avaliação direta: por meio de equipamentos de classe I (nível e mira; Dipstick, perfilômetro do TRL, etc.) e classe II (perfilógrafos, equipamentos com sensores a laser, APL francês, etc.);
- Avaliação indireta: equipamentos de classe III do tipo resposta (TRL Bump integrator, Maysmeter, Merlin, etc.).

Embora o IRI seja o índice internacional padrão para quantificar os desvios da superfície de um pavimento, no Brasil a escala padrão de irregularidade adotada, segundo a ANTT (2017), é o “Quociente de Irregularidade” (QI). O QI é expresso em contagens/km e calculado por nivelamento topográfico de um trecho, obtendo-se cotas com espaçamento de 0,5 m em cada trilha de roda.

De acordo com o DNIT (2006) os equipamentos mais utilizados para a medição do QI são os integradores do tipo resposta. No Brasil, para a calibrar e utilizar estes equipamentos existem métodos normalizados pelo DNER: Normas DNER-ES 173/86, DNER-PRO 164/94 e DNER-PRO 182/94.

- DNER-ES 173/86: Método de nível e mira para calibração de sistemas medidores de irregularidade tipo-resposta. A norma estabelece os procedimentos para o nivelamento detalhado de rodovias utilizando o método de nível e mira, com o objetivo de medir a irregularidade da superfície. Esses dados são utilizados principalmente na calibração de equipamentos do tipo “resposta”.
- DNER-PRO 164/94: Calibração e controle de sistemas medidores de irregularidade de superfície de pavimento (sistemas integradores IPR/USP e Maysmeter). Define o procedimento a ser usado na calibração e controle destes sistemas medidores de irregularidade de superfície de pavimento.
- DNER-PRO 182/94: Medição da irregularidade de superfície de pavimentos com sistemas integradores IPR/USP e Maysmeter. Define o procedimento a ser utilizado para determinação da irregularidade de superfície de rodovias com emprego destes, a nível de rede ou projeto.

A Tabela 1 demonstra como o DNIT classifica a condição dos pavimentos com base no Quociente de Irregularidade (QI).

Tabela 1 – Classificação do pavimento de acordo com seu QI.

Conceito	QI (contagens / Km)
Excelente	13 – 25
Bom	25 – 35
Regular	35 – 45
Ruim	45 – 60
Péssimo	Acima de 60

Fonte: Silva (2019), adaptada de DNIT (2006b)


3.7 Método do Nível e Mira

O método de nível e mira é uma técnica usada para o levantamento detalhado do perfil longitudinal de rodovias, utilizado especialmente na determinação do Quociente de Irregularidade (QI). Esse método baseia-se na obtenção de leituras altimétricas ao longo do pavimento, nas trilhas de roda externas e internas, com espaçamentos de 0,5m entre os pontos, por meio de um nível ótico e uma mira graduada, com nível de bolhas. Os dados coletados são posteriormente analisados

para identificar variações verticais que representam as irregularidades na superfície do pavimento.

A norma DNER-ES 173/86 define o procedimento referência para a calibração de equipamentos medidores de irregularidade do tipo "resposta", sendo considerado um método padrão por sua precisão na representação do perfil da via. A Figura 7 apresenta um desenho esquemático da aplicação do método nível e mira.

Figura 7 – Esquema de aplicação do método nível e mira



Fonte: Bisconsini (2016), adaptado de Sayers e Karamihas (1998)

3.8 Dispositivos Móveis

3.8.1 Sensores Presentes nos Smartphones Atuais

Os smartphones modernos contém uma série de sensores que permitem monitorar diversos aspectos do movimento. Dentre os sensores, destaca-se o acelerômetro como o principal recurso para a detecção de vibrações. Este sensor mede a variação da aceleração em três eixos (X, Y e Z), conforme esquematizado na Figura 8, e é amplamente utilizado em aplicações que envolvem detecção de movimento, posicionamento, rastreamento e avaliação de superfícies. Muitos

dispositivos também integram giroscópios, que medem a velocidade angular, e sensores de gravidade que contribuem para melhorar a precisão dos dados captados.

Figura 8 – Sistema de coordenadas de um smartphone



Fonte: Bisconsini (2016)

Nos smartphones que utilizam do sistema operacional *Android*, existem, em seu acervo, diversos aplicativos que permitem visualizar os dados apresentados por esses sensores listados acima. Neste trabalho, optou-se pelo o aplicativo “Medidor de Vibração” da “EXA Tools”, por permitir leitura simplificada dos dados e apresentar amplitudes de vibração média e máxima, variáveis importantes para o estudo em questão.

3.8.2 Uso dos Sensores dos Smartphones para Avaliação da Irregularidade

Bisconsini (2016) conta que essa tecnologia integrada nos aparelhos portáteis abriu portas para diversos tipos de estudos em diferentes campos de pesquisa. Por exemplo na área de transportes, como é o caso do aplicativo *Waze* que fornece informações em tempo real sobre as condições da via.

Estes aparelhos podem ser usados para a avaliação da irregularidade longitudinal, funcionando como sistemas de medição do tipo resposta. Apesar de não funcionar como um medidor convencional de classe, que acumula os deslocamentos entre a carroceria e o eixo traseiro do veículo em um único sentido, também não medem diretamente o perfil do pavimento como um perfilômetro, mas acelerações

verticais com um smartphone fixado internamente ao veículo. Esses sinais têm correlação com o IRI que, por sua vez, é altamente relacionado à avaliação funcional de pavimentos (Bisconsini, 2016).

3.9 Inteligência Artificial

3.9.1 Modelos de Regressão

A aplicação de modelos de regressão linear e polinomial mostra-se eficaz na previsão de variáveis contínuas em diversos contextos da engenharia civil. Esses modelos permitem estabelecer relações matemáticas entre variáveis independentes e uma variável dependente, facilitando a análise e a tomada de decisões baseadas em dados históricos, por exemplo. Na engenharia de pavimentos, essas técnicas podem ser utilizadas para prever indicadores como o Quociente de Irregularidade (QI), contribuindo para o planejamento de manutenção e melhoria das vias.

Por exemplo, um estudo de Caetano et al. (2018) propôs um modelo de regressão linear múltipla para estimar a geração de RCD (Resíduos de Construção e Demolição) em obras de alvenaria estrutural, demonstrando a aplicabilidade dessa técnica na previsão de variáveis relacionadas à construção civil. O modelo apresentou um coeficiente de determinação (R^2) de 0,802, indicando boa capacidade preditiva.

Em um estudo de Santana *et al.* (2018), foi utilizado um modelo de regressão polinomial para prever a caracterização das propriedades mecânicas de argamassas contendo agregados não convencionais, como EVA e fibras de piaçava. Os resultados mostraram que o modelo foi capaz de capturar as relações não-lineares entre as variáveis, proporcionando previsões mais precisas.

Python é uma linguagem de programação de alto nível e interpretada, voltada para programação de propósito geral. Criada por Guido van Rossum e lançada pela primeira vez em 1991, ela oferece estruturas que permitem uma programação clara tanto para projetos pequenos quanto para grandes escalas (BRAUNSCHWEIG, 2018).

Existem bibliotecas de algoritmos prontos para a produção que simplificam a criação e o treinamento de Inteligências Artificiais usando poucos códigos em Python, como o TensorFlow, o Keras e o Scikit-Learn. Geron (2019) lista as características de cada uma delas.

- Scikit-Learn: de fácil uso e implementa diversos algoritmos de Aprendizado de Máquina ao mesmo tempo e de modo eficiente, sendo, portanto, excelente ponto de partida para o aprendizado de máquina.
- TensorFlow: é uma biblioteca mais complexa para computação numérica distribuída. Ela permite treinar e executar redes neurais muito grandes de forma eficiente, distribuindo os cálculos por centenas de servidores com múltiplas GPUs, se necessário.
- Keras: é uma API de Deep Learning de alto nível que torna muito simples o treinamento e a execução de redes neurais. Ela pode ser executada sobre o TensorFlow, Theano ou Microsoft Cognitive Toolkit (anteriormente conhecido como CNTK).

Além das bibliotecas voltadas especificamente para o aprendizado de máquina, há também bibliotecas auxiliares que desempenham funções fundamentais no tratamento e visualização de dados em Python, como o Pandas e o Matplotlib, usadas neste estudo.

- Pandas é uma biblioteca para manipulação e análise de dados, escrita em Python. Essa é a biblioteca perfeita para iniciar análises exploratórias de dados, pois ela permite ler, manipular, agregar e plotar os dados em poucos passos (Ribeiro, 2020).
- O Matplotlib é uma biblioteca popular de visualização de dados em Python. Ele é frequentemente usado para criar visualizações estáticas, interativas e animadas. Ele permite gerar gráficos, histogramas, gráficos de barras, gráficos de dispersão, entre outros, com poucas linhas de código (DATAACAMP, 2024).

3.9.2 Regressão Linear Múltipla

O modelo de regressão linear é um dos mais simples que existem. A regressão linear utiliza uma equação direta de “forma fechada” que calcula diretamente os parâmetros do modelo que melhor se ajustam ao conjunto de treinamento. De forma mais geral, um modelo linear faz uma previsão simplesmente calculando uma soma ponderada das características de entrada, mais uma constante chamada de intercepto, como mostra a Equação 1 (Geron, 2019).

$$\hat{y} = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \cdots + \theta_n x_n \quad (1)$$

- $\hat{y}$ é o valor previsto;
- n é o número de variáveis;
- x_i é o valor da i -ésima variável;
- θ_j é o j -ésimo parâmetro do modelo (incluindo o valor de intercepto θ_0 e os pesos das variáveis $\theta_1, \theta_2, \dots, \theta_n$).

Mas para um modelo de regressão linear funcionar e apresentar a equação que mais aproxima os valores previstos do mínimo erro possível, precisamos de uma medida que avalia o quão bem (ou mal) o modelo se ajusta aos dados do treinamento, que por sua vez, consiste em ajustar os seus parâmetros para que ele se adeque da melhor forma possível ao conjunto treinado. Para Geron (2019), a medida de desempenho mais comum para um modelo de regressão é o Root Mean Square Error (RMSE). Então para treinar o modelo em questão é necessário encontrar o valor de θ que minimiza o RMSE. Porém, é mais simples, na prática, minimizar o Mean Square Error (MSE), que é o erro quadrático médio e conduz ao mesmo resultado. O MSE de uma hipótese de Regressão Linear h_θ em um conjunto de treinamento X é calculado usando a Equação 2.

$$MSE(X, h_\theta) = \frac{1}{m} \sum_{i=1}^m (\theta^T x^{(i)} - y^{(i)})^2 \quad (2)$$

- m é o número de instâncias no conjunto de dados no qual está sendo medido o MSE;
- $x^{(i)}$ é um vetor contendo todos os valores das características (excluindo o rótulo) da i -ésima instância no conjunto de dados;
- $y^{(i)}$ é o seu rótulo (ou seja, o valor de saída desejado para essa instância).
- X é uma matriz que contém todos os valores das características (excluindo os rótulos) de todas as instâncias no conjunto de dados. Há uma linha para cada instância, e a i -ésima linha é igual à transposta de $x^{(i)}$, indicada como $(x^{(i)})^T$.
- h é a função de previsão do sistema, também chamada de hipótese. Quando o sistema recebe o vetor de características de

uma instância $x^{(i)}$, ele retorna um valor previsto $\hat{y}^{(i)} = h(x^{(i)})$ para essa instância.

3.9.3 Regressão Polinomial

De acordo com Geron (2019), a regressão polinomial consegue trabalhar quando os dados são mais complexos do que uma linha reta, algo que a regressão linear não consegue. O modelo de regressão polinomial acrescenta potências de cada variável como nova variável e então treina um modelo linear com esse novo conjunto.

Quando há múltiplas variáveis, a regressão polinomial é capaz de encontrar relações entre elas. Isso é possível porque adiciona todas as combinações possíveis de variáveis até o grau especificado. Por exemplo, se houver duas variáveis a e b , o sistema com grau = 3 não adicionará apenas as variáveis a^2 , a^3 , b^2 e b^3 , mas também as combinações ab , a^2b e ab^2 (Geron, 2019).

3.9.4 Coeficiente de Determinação

O coeficiente de determinação (R^2) mede o quanto a variabilidade de uma variável é compartilhada com outra. Em outras palavras, pode indicar a qualidade de ajuste de um modelo de regressão. Por exemplo, podemos analisar a relação entre ansiedade em provas e o desempenho em provas. Este parâmetro varia de pessoa para pessoa devido a inúmeros fatores (diferenças de habilidade, níveis distintos de preparação, entre outros). Se somarmos toda essa variabilidade teremos uma estimativa da quantidade total de variabilidade nos desempenhos. Em seguida, podemos usar o R^2 para saber quanto dessa variabilidade é compartilhada com a ansiedade em provas (Field, 2017).

Supondo que essas duas variáveis apresentaram uma correlação de $-0,4410$, portanto o valor de R^2 será $(-0,4410)^2 = 0,194$. Esse valor nos informa quanta variabilidade no desempenho em provas é compartilhada com a ansiedade. Se convertermos esse valor em porcentagem (multiplicando por 100), podemos dizer que a ansiedade em provas compartilha 19,4% da variabilidade no desempenho (FIELD, 2017).

O R^2 varia entre 0 e 1 e o quanto mais próximo de 1 mais o modelo explica a variação dos dados com base nas variáveis de entrada.



Fonte: Google Earth. Adaptado pelo autor (acesso em abril de 2025)

Figura 11 – Trecho 1, Rua Monção



Fonte: Google Earth. Acesso em abril de 2025

Figura 12 – Trecho 2, Rua Batalha



Fonte: Google Earth. Acesso em abril de 2025

Figura 13 – Trecho 3, Rua Corumbá



Fonte: Google Earth. Acesso em abril de 2025

A fim de ler as cotas a serem levantadas para medir o QI em cada trecho, foi utilizada uma mira para nivelamento com comprimento de 4m, falante, com nível de bolhas. A mira é graduada em divisões de meio centímetro, possibilitando a leitura de cada cota com precisão milimétrica, por interpolação e um nível ótico com precisão de 1,5mm/km conforme estabelece a norma DNER-ES 173/86. Também foi empregada uma trena com 20 metros, graduada em centímetros. Esta trena foi estendida na superfície do pavimento alinhada com os rodeiros, para o posicionamento da mira a cada 0,5m. Os dados foram registrados em ficha de cadastro de anotação de cada leitura de cota e suas observações, esta ficha pode ser visualizada no Anexo A.

Para apoiar o Smartphone “iPhone XR” da marca “Apple”, com o qual registraram-se os resultados de vibrações para cada trecho analisado. Utilizou-se um suporte veicular multifuncional da marca “MBTech” para fixar o aparelho na parte posterior do banco dianteiro do veículo Citroën C3 GLX, 1.4 cilindradas, de ano 2012.

4.2 Métodos

O levantamento inicial da irregularidade dos pavimentos foi realizado seguindo o método de nível e mira, conforme definido em norma DNER-PRO 173/86, que visa calibrar sistemas medidores do tipo resposta e pode ser usado para avaliação periódica da irregularidade em trechos experimentais de pavimentos.

As leituras foram realizadas a cada intervalo regular de 0,5m, ao longo do eixo das trilhas de roda dos veículos. Em pavimentos urbanos, trilhas de rodas podem ser de difícil localização. Nos casos em estudo, e em conformidade com a norma, adotou-se a distância de 1,5m da guia para locar trilha externa. A equipe em campo consistia em uma pessoa para estender a trena e posicionar a mira a cada 0,5m e uma pessoa para posicionar o nível e ler em voz alta a cota de cada ponto para que uma terceira pudesse anotar conforme o Anexo A. A Figura 14 ilustra atividades para a cálculo do QI em campo.

Figura 14 – Aplicação do método nível e mira no campo



Fonte: Elaborado pelo autor

Após os trabalhos em campo aplicaram-se os cálculos normativos para determinar o Quociente de Irregularidade (QI), expresso em contagens por quilômetro. O QI é um índice consolidado no Brasil para avaliação funcional, sendo sensível às ondulações e discontinuidades da superfície que impactam diretamente no conforto dos usuários e na segurança do tráfego.

Cada trecho tinha aproximados 500m de extensão e os dados permitiram o cálculo direto do QI pela Equação 3.

$$QI = -8,54 + 6,17VA_{1,0} + 19,38VA_{2,5} \quad (3)$$

Onde,

- $VA_{1,0}$ é a aceleração vertical média quadrática para distância de base igual a 1,0m;
- $VA_{2,5}$ é a aceleração vertical média quadrática para distância de base igual a 2,5m.

A distância de base é determinada conforme a Equação 4.

$$VA_b = \left[\sum_{i=k+1}^{N-k} \frac{(SB_i)^2}{N-2k} \right]^{\frac{1}{2}} \quad (4)$$

Sendo:

$$SB_i = \frac{Y_{i+k} - 2Y_i + Y_{i-k}}{(kS)^2} \quad (5)$$

$$k = \frac{b}{S} \quad (6)$$


Onde:

- Y_i = cota em um ponto qualquer;
- b = comprimento da base;
- S = distância entre duas cotas consecutivas (0,5m);
- N = número de cotas levantadas.

É possível observar, pelas equações descritas acima, que as cotas levantadas para um ponto Y_i são correlacionadas e comparadas com as cotas 1,0m à frente e 1,0m anterior quando o comprimento da base é igual a 1,0m e com as cotas 2,5m à frente e 2,5m anterior quando esse comprimento é igual a 2,5m, definindo assim o plano altimétrico do trecho analisado.

A segunda etapa consistiu na coleta de dados de vibração utilizando sensores embarcados em um iPhone modelo XR, equipado com acelerômetro. O aparelho foi rigidamente fixado ao banco do veículo (Figura 15) de modo a evitar movimentos independentes da estrutura do automóvel, assegurando a qualidade dos registros.

Figura 15 – Local de fixação do Smartphone no veículo



Fonte: Elaborado pelo autor

As medições foram realizadas em dois regimes de velocidade constantes:


- 30 km/h, simulando condições de tráfego lento;
- 50 km/h, representando tráfego regular urbano.

Cada trecho foi percorrido cinco vezes em cada velocidade, intercalando o sentido do mesmo em cada passagem e o veículo foi ocupado somente pelo motorista e uma pessoa no banco traseiro para iniciar a leitura do aplicativo. Por exemplo, o levantamento no primeiro trecho ocorreu inicialmente no sentido Rua Monção – Rua Colinas e, depois, no sentido Rua Colinas – Rua Monção e assim sucessivamente, resultando em dez passagens em cada trecho. Durante o percurso foi registrado o sinal de aceleração nos três eixos (X, Y e Z) e com base nos sinais brutos, foram extraídas as seguintes métricas:

- amplitude média de vibração para cada passagem;
- amplitude máxima de vibração registrada em cada passagem.

O aplicativo utilizado para a coleta dos dados foi o “Medidor de Vibração” da EXA Tools, reconhecido por sua fácil interpretabilidade dos resultados e apresentação destas variáveis, relevantes para o estudo em questão. A Figura 16 mostra a interface do aplicativo.

Figura 16 – Interface do aplicativo “Medidor de Vibração”



Fonte: Elaborado pelo autor

Durante o registro de dados, buscaram-se manter condições homogêneas de condução, limitando acelerações ou frenagens bruscas, e o veículo trafegou com carga leve (apenas o motorista e um passageiro e porta-malas vazio) e calibragem de pneus regularizada, para evitar influência significativa na medição das vibrações.

Com os dados de irregularidade (QI) e de vibração (amplitudes médias e máximas) consolidados, foi desenvolvida abordagem de aprendizado de máquina supervisionado, empregando o ambiente de programação Python e as bibliotecas Scikit-Learn, Pandas e Matplotlib.

Inicialmente, os dados foram organizados em um DataFrame do Pandas que, segundo Ribeiro (2020), é semelhante a uma planilha do Excel, com linhas e colunas, associando a cada observação às variáveis independentes:

- amplitude média a 30 km/h;
- amplitude máxima a 30 km/h;
- amplitude média a 50 km/h;
- amplitude máxima a 50 km/h.

A variável dependente foi o QI medido in loco.

Foi realizada análise exploratória preliminar e, para maior assertividade dos resultados, foram desconsiderados os trechos de 20m (definido pelo comprimento da trena usada e consequente mudança de posição e cota do nível) com presença de lombadas, bueiros ou trechos não homogêneos do pavimento. Conforme definido em norma, tais ocorrências devem ser excluídas no resultado médio do QI, pois implicam em valores de irregularidades que destoam da média do pavimento analisado. A Figura 17 é um exemplo de trecho não homogêneo (excluído do cálculo de QI) presente entre a Rua Batalhas e a Rua Colinas.

Figura 17 – Pavimento não homogêneo presente no trecho 2



Fonte: Elaborado pelo autor

O modelo utilizado foi uma Regressão Linear Múltipla, onde foram executadas as seguintes etapas:

- divisão dos dados em variáveis de entrada (X) e variável alvo (y);
- treinamento do modelo de regressão utilizando o método dos mínimos quadrados ordinários;
- estimativa dos coeficientes de regressão e do termo independente.

Depois, foi ajustado um modelo polinomial de segundo grau, adicionando interações entre as variáveis e suas potências quadráticas, de modo adaptar eventuais relações não lineares e aumentar a capacidade preditiva.

Os modelos foram avaliados considerando os seguintes parâmetros:

- Coeficiente de determinação (R^2), indicando o percentual da variabilidade dos dados explicado pelo modelo;
- Erro Quadrático Médio (MSE), representando o erro médio entre os valores previstos e os reais.

As Figuras 18 e 19 apresentam o código em Python utilizado para os modelos de Regressão Linear Múltipla e Regressão Polinomial de Segundo Grau, respectivamente.

Figura 18 – Modelo de Regressão Linear Múltipla utilizado em linguagem Python.

```
In [1]: # IMPORTAÇÃO DAS BIBLIOTECAS
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.linear_model import LinearRegression
from sklearn.metrics import mean_squared_error, r2_score

# ORGANIZAÇÃO DOS DADOS COLETADOS
data = {
    "Velocidade": [30]*5 + [50]*5 + [30]*5 + [50]*5 + [30]*5 + [50]*5,
    "Amp_Media": [],
    "Amp_Maxima": [],
    "QI": [QI1]*10 + [QI2]*10 + [QI3]*10
}

df = pd.DataFrame(data)

# ANÁLISE DE CORRELAÇÃO
correlation_matrix = df.corr(numeric_only=True)

# REGRESSÃO LINEAR MÚLTIPLA
X = df[["Amp_Media", "Amp_Maxima"]]
y = df["QI"]

model = LinearRegression()
model.fit(X, y)
y_pred = model.predict(X)

# AVALIAÇÃO DO MODELO
mse = mean_squared_error(y, y_pred)
r2 = r2_score(y, y_pred)
print("Erro quadrático médio:", mse)
print("R²:", r2)

# EQUAÇÃO DO MODELO
print("Equação da Regressão:")
print(f"QI = {model.intercept_:.2f} + ({model.coef_[0]:.2f} * Amplitude Média) + ({model.coef_[1]:.2f} *
```

Fonte: Jupyter Notebook. Adaptado pelo autor

Figura 19 – Modelo de Regressão Polinomial de Segundo Grau utilizado em linguagem Python

```

In [14]: # IMPORTAÇÃO DAS BIBLIOTECAS
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.linear_model import LinearRegression
from sklearn.metrics import mean_squared_error, r2_score
from sklearn.preprocessing import StandardScaler, PolynomialFeatures

# ORGANIZAÇÃO DOS DADOS COLETADOS
data = {
    "Velocidade": [30]*5 + [50]*5 + [30]*5 + [50]*5 + [30]*5 + [50]*5,
    "Amp_Media": [],
    "Amp_Maxima": [],
    "QI": [QI1]*10 + [QI2]*10 + [QI3]*10
}

df = pd.DataFrame(data)

# ENGENHARIA DE ATRIBUTOS
df["Razao_Media_Maxima"] = df["Amp_Media"] / df["Amp_Maxima"]
df["Produto_Med_Max"] = df["Amp_Media"] * df["Amp_Maxima"]

# VARIÁVEIS INDEPENDENTES E VARIÁVEL DEPENDENTE
X = df[["Amp_Media", "Amp_Maxima", "Velocidade", "Razao_Media_Maxima", "Produto_Med_Max"]]
y = df["QI"]

# NORMALIZAÇÃO
scaler = StandardScaler()
X_scaled = scaler.fit_transform(X)

# REGRESSÃO POLINOMIAL DE 2º GRAU
poly = PolynomialFeatures(degree=2)
X_poly = poly.fit_transform(X_scaled)

# MODELO
model = LinearRegression()
model.fit(X_poly, y)
y_pred = model.predict(X_poly)

# AVALIAÇÃO DO MODELO
mse = mean_squared_error(y, y_pred)
r2 = r2_score(y, y_pred)

print("\n--- Avaliação do Modelo ---")
print(f"Erro Quadrático Médio (MSE): {mse:.2f}")
print(f"Coeficiente de Determinação (R²): {r2:.2f}")

# EQUAÇÃO DO MODELO
feature_names = poly.get_feature_names_out(X.columns)
intercept = model.intercept_
coefs = model.coef_

print("\n--- Equação do Modelo Polinomial ---\n")
equacao = f"QI = {intercept:.2f}"
for coef, name in zip(coefs[1:], feature_names[1:]):
    equacao += f" {coef:+.2f} * {name}"
print(equacao)

```

Fonte: Jupyter Notebook. Adaptado pelo autor

Adicionalmente, foram plotados gráficos de dispersão entre os valores previstos e reais e a equação resultante do modelo com os seus coeficientes estimados. Então, ao final do processo, foram geradas tabelas comparativas em Excel contendo o QI real medido pelo método de nível e mira, o QI previsto pelo modelo treinado, o erro absoluto de cada previsão e o erro absoluto médio para cada trecho de pavimento analisado.

5 RESULTADOS E DISCUSSÃO

Este trabalho tem como objetivo comparar o Quociente de Irregularidade medido com nível e mira (DNER-ES 173/86) para três trechos de pavimentos com os QIs dos mesmos segmentos, medidos com o auxílio de um algoritmo de Inteligência Artificial.

Os dados coletados dos planos altimétricos dos trechos permitiram o cálculo direto do QI por meio da equação 3 presente na norma do método, cujos resultados são apresentados na Tabela 2.

Tabela 2 – QI médio de cada trecho

Ida						Volta					
Trecho 1		Trecho 2		Trecho 3		Trecho 1		Trecho 2		Trecho 3	
Subtrecho	QI	Subtrecho	QI	Subtrecho	QI	Subtrecho	QI	Subtrecho	QI	Subtrecho	QI
1	250,9	1	48,8	1	116,3	1	210,5	1	125,5	1	114,0
2	231,2	2	23,0	2	96,1	2	168,6	2	40,7	2	125,5
3	143,9	3	37,3	3	105,6	3	187,3	3	48,1	3	98,2
4	150,2	4	64,6	4	152,7	4	104,4	4	40,3	4	135,3
5	117,2	5	39,1	5	111,6	5	116,9	5	48,3	5	122,5
6	139,6	6	24,2	6	62,6	6	156,6	6	44,1	6	154,8
7	173,5	7	20,5	7	114,3	7	76,3	7	47,3	7	130,9
8	44,9	8	49,5	8	133,8	8	72,0	8	30,5	8	154,5
9	108,6	9	36,4	9	108,6	9	88,7	9	19,0	9	196,0
10	102,7	10	31,0	10	82,6	10	133,2	10	27,9	10	169,1
11	156,4	11	31,1	11	66,9	11	120,2	11	52,7	11	110,2
12	90,5	12	47,3	12	142,3	12	123,2	12	149,1	12	105,3
13	190,9	13	39,1	13	186,8	13	166,2	13	53,3	13	127,6
14	89,0	14	59,3	14	115,6	14	141,6	14	26,2	14	120,4
15	123,2	15	43,1	15	90,6	15	105,9	15	22,8	15	123,7
16	113,6	16	30,6	16	106,6	16	103,9	16	38,3	16	137,6
17	67,2	17	123,3	17	171,0	17	123,5	17	35,7	17	145,0
18	115,8	18	90,2	18	170,6	18	173,8	18	31,4	18	130,2
19	138,0	19	-	19	173,9	19	138,6	19	30,7	19	113,4
20	79,8	20	-	20	132,3	20	108,9	20	21,7	20	90,4
21	127,5	21	-	21	74,5	21	124,5	21	89,7	21	-
22	122,2	22	-	22	106,7	22	86,0	22	50,9	22	-
23	35,9	23	-	23	68,8	23	-	23	18,3	23	-
24	-	24	-	24	114,3	24	-	24	168,2	24	-
QI Médio ida						QI Médio volta					
126,6		46,6		116,9		128,7		52,5		130,2	
QI do trecho											
Trecho 1				Trecho 2				Trecho 3			
127,7				49,6				123,6			

Fonte: Elaborado pelo autor

Cada subtrecho da Tabela 2 é referente à mudança de posição do nível usado em campo, compreendendo (em maioria) comprimento de 20m, salva exceções quando havia algum obstáculo.

Lembrando que ao longo do processo de coleta dos dados houve lombadas, bueiros e (mostrado na Figura 17) trechos não-homogêneo de pavimentos capazes de interferir nos resultados do QI. Estes subtrechos foram descartados para maior representatividade do estado real do pavimento.

De acordo com a classificação do DNIT (2006) que define a condição dos pavimentos pelo cálculo de seu QI em contagens/km (Tabela 1), os trechos de pavimentos estudados são classificados respectivamente como péssimo, ruim e péssimo.

Foi definido como parâmetro de comparação a variação das acelerações verticais captadas por um aparelho enquanto o veículo trafega em diferentes velocidades por esses trechos.

A coleta das vibrações foi realizada utilizando um smartphone com aplicativo que permite visualizar a leitura do acelerômetro fixado na parte posterior do banco dianteiro. As medições foram feitas com o veículo a 30 km/h e a 50 km/h, percorrendo cada trecho cinco vezes em cada velocidade, alternando os sentidos das viagens. Os dados brutos foram tratados para obter a média e o pico (amplitude máxima) das vibrações, como resume a Tabela 3.

Tabela 3 – Amplitude média e máxima de vibração para cada trecho

Velocidade (km/h)	Trecho 1		Trecho 2		Trecho 3	
	Amplitude média (m/s ²)	Amplitude máxima (m/s ²)	Amplitude média (m/s ²)	Amplitude máxima (m/s ²)	Amplitude média (m/s ²)	Amplitude máxima (m/s ²)
30	1,2	5,2	0,7	3,9	1,5	5,1
30	1,3	4,0	0,7	3,2	1,5	4,7
30	1,3	4,8	0,6	3,6	1,4	4,0
30	1,2	4,3	0,7	3,2	1,5	6,1
30	1,3	5,1	0,7	3,7	1,5	5,8
50	1,4	4,7	0,8	4,2	1,7	6,8
50	1,5	7,5	0,9	4,0	1,6	5,2
50	1,5	4,9	0,9	5,2	1,7	5,6
50	1,5	4,6	0,7	5,0	1,7	5,7
50	1,5	5,8	0,8	4,8	1,7	6,1

Fonte: Elaborado pelo autor

Esses dados foram organizados com o uso da biblioteca Pandas, ferramenta amigável para manipular dados em Python, permitindo armazenar os dados em *DataFrames* (estruturas semelhantes a planilhas).

Então foi criado um algoritmo de regressão linear múltipla que pudesse correlacionar as variáveis independentes com a variável dependente (QI medido) e avaliar a precisão do modelo de acordo com o MSE e o R^2 . A Figura 20 apresenta o algoritmo com o *DataFrame* organizado e as suas avaliações.

Figura 20 – Resultados do modelo de Regressão Linear Múltipla utilizado em linguagem Python.

```
In [1]: # IMPORTAÇÃO DAS BIBLIOTECAS
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.linear_model import LinearRegression
from sklearn.metrics import mean_squared_error, r2_score

# ORGANIZAÇÃO DOS DADOS COLETADOS
data = {
    "Velocidade": [30]*5 + [50]*5 + [30]*5 + [50]*5 + [30]*5 + [50]*5,
    "Amp_Media": [
        1.2, 1.3, 1.3, 1.2, 1.3,
        1.4, 1.5, 1.5, 1.5, 1.5,
        0.7, 0.7, 0.6, 0.7, 0.7,
        0.8, 0.9, 0.9, 0.7, 0.8,
        1.5, 1.5, 1.4, 1.5, 1.5,
        1.7, 1.6, 1.7, 1.7, 1.7
    ],
    "Amp_Maxima": [
        5.2, 4.0, 4.8, 4.3, 5.1,
        4.7, 7.5, 4.9, 4.6, 5.8,
        3.9, 3.2, 3.6, 3.2, 3.7,
        4.2, 4.0, 5.2, 5.0, 4.8,
        5.1, 4.7, 4.0, 6.1, 5.8,
        6.8, 5.2, 5.6, 5.7, 6.1
    ],
    "QI": [127.7]*10 + [49.6]*10 + [123.6]*10
}

df = pd.DataFrame(data)

# ANÁLISE DE CORRELAÇÃO
correlation_matrix = df.corr(numeric_only=True)

# REGRESSÃO LINEAR MÚLTIPLA
X = df[["Amp_Media", "Amp_Maxima"]]
y = df["QI"]

model = LinearRegression()
model.fit(X, y)
y_pred = model.predict(X)

# AVALIAÇÃO DO MODELO
mse = mean_squared_error(y, y_pred)
r2 = r2_score(y, y_pred)
print("Erro quadrático médio:", mse)
print("R²:", r2)

# EQUAÇÃO DO MODELO
print("Equação da Regressão:")
print(f"QI = {model.intercept_:.2f} + ({model.coef_[0]:.2f} * Amplitude Média) + ({model.coef_[1]:.2f} *")

Erro quadrático médio: 191.37990749888394
R²: 0.8514184986836264
Equação da Regressão:
QI = 4.06 + (99.76 * Amplitude Média) + (-5.48 * Amplitude Máxima)
```

Fonte: Jupyter Notebook. Adaptado pelo autor

Pode-se notar que o algoritmo gerou uma equação de regressão linear múltipla (Equação 7) com base no treinamento da IA com os dados de QI e amplitudes de vibração apresentados nas Tabelas 2 e 3.

$$QI = 4,06 + (99,76 * A_{med}) + (-5,48 * A_{máx}) \quad (7)$$

Ou seja: para cada unidade de aumento na amplitude média, o QI aumenta aproximadamente 99,76 contagens/km e para cada aumento na amplitude máxima, o QI diminui aproximadamente 5,48 contagens/km. O valor de intercepto 4,06 (Equação 7) é um valor base estimado para quando ambas as amplitudes são 0 (valor puramente matemático).

Isso implica que, a amplitude média reflete a consistência das vibrações ao longo do trecho, uma sequência regular de irregularidades, já a amplitude máxima reflete picos isolados (buracos grandes ou desníveis pontuais) que não necessariamente refletem o estado geral da via. Esse comportamento indica que, nos trechos analisados, eventos isolados de vibração intensa (picos) não foram suficientes para elevar significativamente o QI total, pois o método de cálculo do QI é acumulativo ao longo do trecho e responde melhor à presença contínua e repetitiva de irregularidades.

O MSE resultante do modelo foi de 191,38 e o R^2 de 0,85. Ou seja, o erro quadrático médio entre os valores reais e previstos é alto, mas 85% da variação do QI nos trechos analisados são explicados pelo conjunto de vibrações captadas pelo smartphone.

Aplicando as variáveis de amplitudes de vibração na Equação 7, obtemos os valores de QI previstos pelo modelo, conforme Tabela 4.

Tabela 4 – Previsão final do modelo de regressão polinomial com as variáveis normalizadas

QI Medido (Contagens/km)	Velocidade (km/h)	Amplitude média (m/s ²)	Amplitude máxima (m/s ²)	QI Previsto (Contagens/km)
Trecho 1				
127,7	30	1,2	5,2	95,3
127,7	30	1,3	4,0	111,8
127,7	30	1,3	4,8	107,4
127,7	30	1,2	4,3	100,2
127,7	30	1,3	5,1	105,8
127,7	50	1,4	4,7	118,0
127,7	50	1,5	7,5	112,6
127,7	50	1,5	4,9	126,8
127,7	50	1,5	4,6	128,5
127,7	50	1,5	5,8	121,9
Trecho 2				
49,6	30	0,7	3,9	52,5
49,6	30	0,7	3,2	56,4
49,6	30	0,6	3,6	44,2
49,6	30	0,7	3,2	56,4
49,6	30	0,7	3,7	53,6
49,6	50	0,8	4,2	60,9
49,6	50	0,9	4,0	71,9
49,6	50	0,9	5,2	65,3
49,6	50	0,7	5,0	46,5
49,6	50	0,8	4,8	57,6
Trecho 3				
123,6	30	1,5	5,1	125,8
123,6	30	1,5	4,7	127,9
123,6	30	1,4	4,0	121,8
123,6	30	1,5	6,1	120,3
123,6	30	1,5	5,8	121,9
123,6	50	1,7	6,8	136,4
123,6	50	1,6	5,2	135,2
123,6	50	1,7	5,6	143,0
123,6	50	1,7	5,7	142,4
123,6	50	1,7	6,1	140,2

Fonte: Elaborado pelo autor

Apesar do limitado conjunto de trechos e as suas variáveis respectivas, além da reduzida variação entre dois deles, os resultados foram promissores, apresentando boa relação entre as variáveis e o resultado previsto. Mesmo assim, foi possível melhorar a capacidade preditiva da regressão linear aplicada. Inicialmente, realizou-se uma etapa de engenharia de atributos, acrescentando novas variáveis derivadas dos dados brutos: razão entre a amplitude média e máxima e o produto entre elas. Além disso, a velocidade do veículo foi incluída como variável independente, e os dados foram normalizados para garantir melhor comportamento numérico do modelo. Por fim, aplicou-se uma regressão polinomial de segundo grau, conforme mostra a Figura 21.

Figura 21 – Resultados do modelo de Regressão Polinomial utilizado em linguagem Python

```

In [4]: # IMPORTAÇÃO DAS BIBLIOTECAS
import pandas as pd
import matplotlib.pyplot as plt
from sklearn.linear_model import LinearRegression
from sklearn.metrics import mean_squared_error, r2_score
from sklearn.preprocessing import StandardScaler, PolynomialFeatures

# ORGANIZAÇÃO DOS DADOS COLETADOS
data = {
    "Velocidade": [30]*5 + [50]*5 + [30]*5 + [50]*5 + [30]*5 + [50]*5,
    "Amp_Media": [
        1.2, 1.3, 1.3, 1.2, 1.3,
        1.4, 1.5, 1.5, 1.5, 1.5,
        0.7, 0.7, 0.6, 0.7, 0.7,
        0.8, 0.9, 0.9, 0.7, 0.8,
        1.5, 1.5, 1.4, 1.5, 1.5,
        1.7, 1.6, 1.7, 1.7, 1.7
    ],
    "Amp_Maxima": [
        5.2, 4.0, 4.8, 4.3, 5.1,
        4.7, 7.5, 4.9, 4.6, 5.8,
        3.9, 3.2, 3.6, 3.2, 3.7,
        4.2, 4.0, 5.2, 5.0, 4.8,
        5.1, 4.7, 4.0, 6.1, 5.8,
        6.8, 5.2, 5.6, 5.7, 6.1
    ],
    "QI": [127.7]*10 + [49.6]*10 + [123.6]*10
}

df = pd.DataFrame(data)

# ENGENHARIA DE ATRIBUTOS
df["Razao_Media_Maxima"] = df["Amp_Media"] / df["Amp_Maxima"]
df["Produto_Med_Max"] = df["Amp_Media"] * df["Amp_Maxima"]

# VARIÁVEIS INDEPENDENTES E VARIÁVEL DEPENDENTE
X = df[["Amp_Media", "Amp_Maxima", "Velocidade", "Razao_Media_Maxima", "Produto_Med_Max"]]
y = df["QI"]

# NORMALIZAÇÃO
scaler = StandardScaler()
X_scaled = scaler.fit_transform(X)

# REGRESSÃO POLINOMIAL DE 2º GRAU
poly = PolynomialFeatures(degree=2)
X_poly = poly.fit_transform(X_scaled)

# MODELO
model = LinearRegression()
model.fit(X_poly, y)
y_pred = model.predict(X_poly)

# AVALIAÇÃO DO MODELO
mse = mean_squared_error(y, y_pred)
r2 = r2_score(y, y_pred)

print("\n--- Avaliação do Modelo ---")
print(f"Erro Quadrático Médio (MSE): {mse:.2f}")
print(f"Coefficiente de Determinação (R²): {r2:.2f}")

# EQUAÇÃO DO MODELO
feature_names = poly.get_feature_names_out(X.columns)
intercept = model.intercept_
coefs = model.coef_

print("\n--- Equação do Modelo Polinomial ---\n")
equacao = f"QI = {intercept:.2f}"
for coef, name in zip(coefs[1:], feature_names[1:]):
    equacao += f" {coef:.2f} * {name}"
print(equacao)

--- Avaliação do Modelo ---
Erro Quadrático Médio (MSE): 37.66
Coefficiente de Determinação (R²): 0.97

--- Equação do Modelo Polinomial ---
QI = 115.52 -7.27 * Amp_Media +4.57 * Amp_Maxima -7.71 * Velocidade -5.28 * Razao_Media_Maxima +28.18 * Produto_Med_Max -180.50 * Amp_Media^2 +233.42 * Amp_Media Amp_Maxima +98.77 * Amp_Media Velocidade +466.05 * Amp_Media Razao_Media_Maxima -25.00 * Amp_Media Produto_Med_Max +26.32 * Amp_Maxima^2 -59.35 * Amp_Maxima Velocidade -42.59 * Amp_Maxima Razao_Media_Maxima -267.47 * Amp_Maxima Produto_Med_Max +0.00 * Velocidade^2 -63.37 * Velocidade Razao_Media_Maxima -0.14 * Velocidade Produto_Med_Max -129.98 * Razao_Media_Maxima^2 -314.60 * Razao_Media_Maxima Produto_Med_Max +169.41 * Produto_Med_Max^2

```

Fonte: Jupyter Notebook. Adaptado pelo autor

Nota-se melhora significativa na previsibilidade pelo modelo polinomial de segundo grau, que obteve coeficiente de determinação (R^2) de 0,97 e erro quadrático médio de 37,66, indicando excelente performance para os dados disponíveis. A equação final (Equação 8) modela a influência combinada e não linear das amplitudes e da velocidade no Quociente de Irregularidade (QI).

$$\begin{aligned}
 QI = & 115,52 - (49,86 * A_{méd}) + (4,57 * A_{máx}) - (7,71 * V) \\
 & - \left(5,28 * \frac{A_{méd}}{A_{máx}} \right) + (261,6 * A_{méd} * A_{máx}) - (495,1 * A_{méd}^2) \\
 & + (98,77 * A_{méd} * V) + \left(466,05 * \frac{A_{méd}^2}{A_{máx}} \right) \\
 & - (25 * A_{méd}^2 * A_{máx}) + (26,32 * A_{máx}^2) \\
 & - (59,35 * A_{máx} * V) - (267,47 * A_{méd} * A_{máx}^2) \\
 & - \left(63,37 * V * \frac{A_{méd}}{A_{máx}} \right) - (0,14 * V * A_{méd} * A_{máx}) \\
 & - \left\{ 129,98 * \left(\frac{A_{méd}}{A_{máx}} \right)^2 \right\} + \{ 169,41 * (A_{méd} * A_{máx})^2 \}
 \end{aligned} \tag{8}$$

Com a normalização dos dados antes do treinamento da Inteligência Artificial, não é possível substituir os dados originais na equação e obter o resultado final entregue pelo modelo, pois ela consiste em reescalar as variáveis para que tenham média zero e desvio padrão igual a um. Geron (2019) sugere primeiro subtrair a média dos dados (fazendo com que os valores padronizados tenham média zero) e, em seguida, dividir pelo desvio padrão. O resultado é uma distribuição com variância igual a 1, tornando o modelo menos sensível a valores que se desviam significativamente da maioria dos outros dados em um conjunto, em outras palavras, o processo de normalização diminui os “ruídos” desses dados.

A Equação 9 usa a variável “amplitude média” como exemplo para o cálculo de normalização, feito em todas as variáveis treinadas no modelo.

$$A_{méd_i_norm} = \frac{A_{méd_i} - \left(\frac{\sum_{i=1}^n A_{méd}}{n} \right)}{\sigma_{A_{méd}}} \tag{9}$$

Os dados utilizados para normalizar as variáveis e realizar os cálculos foram:

- média das amplitudes médias: 1,233 m/s²;
- desvio-padrão das amplitudes médias: 0,374m/s²;
- média das amplitudes máximas: 4,893 m/s²;
- desvio-padrão das amplitudes máximas: 1,013m/s²;
- média das velocidades: 40km/h;
- desvio-padrão das velocidades: 10km/h;
- média da razão entre as amplitudes médias e máximas: 0,251;
- desvio-padrão da razão entre as amplitudes médias e máximas: 0,057;
- produto das amplitudes médias e máximas: 6,293;
- desvio-padrão do produto das amplitudes médias e máximas: 2,819.

Aplicando os dados normalizados na Equação 8, obtiveram-se os resultados previstos pelo modelo, disponíveis na Tabela 5.

Tabela 5 – Previsão final do modelo de regressão polinomial com as variáveis normalizadas

QI Medido (contagens/km)	Amplitude média (normalizado) (m/s ²)	Amplitude máxima (normalizado) (m/s ²)	Velocidade (normalizado) (km/h)	Razão das amplitudes (normalizado)	Produto das amplitudes (normalizado)	QI Previsto (contagens/km)
Trecho 1						
127,7	-0,089126551	0,302731165	-0,983187494	-0,351022969	-0,018919237	128,1
127,7	0,178253128	-0,881869033	-0,983187494	1,302148421	-0,387844388	121,2
127,7	0,178253128	-0,092135568	-0,983187494	0,351856023	-0,018919237	125,1
127,7	-0,089126551	-0,585718983	-0,983187494	0,496354867	-0,402033817	117,9
127,7	0,178253128	0,204014482	-0,983187494	0,072358259	0,119427694	126,1
127,7	0,445632807	-0,190852251	0,983187494	0,826224569	0,101690908	119,5
127,7	0,713012487	2,573214877	0,983187494	-0,890834035	1,758306729	127,7
127,7	0,713012487	0,006581115	0,983187494	0,970963315	0,374837414	127,7
127,7	0,713012487	-0,289568934	0,983187494	1,321217834	0,215206339	126,2
127,7	0,713012487	0,895031264	0,983187494	0,137599117	0,853730639	121,9
Trecho 2						
49,6	-1,426024947	-0,980585716	-0,983187494	-1,250708079	-1,264041621	58,8
49,6	-1,426024947	-1,671602498	-0,983187494	-0,561886667	-1,437862125	49,6
49,6	-1,693404626	-1,276735765	-0,983187494	-1,475629357	-1,466240983	44,2
49,6	-1,426024947	-1,671602498	-0,983187494	-0,561886667	-1,437862125	49,6
49,6	-1,426024947	-1,178019082	-0,983187494	-1,080497383	-1,313704622	56,3
49,6	-1,158645267	-0,684435666	0,983187494	-1,057918413	-1,040558116	49,2
49,6	-0,891265588	-0,881869033	0,983187494	-0,452237544	-0,955421543	55,7
49,6	-0,891265588	0,302731165	0,983187494	-1,363168718	-0,572306963	69,5
49,6	-1,426024947	0,105297799	0,983187494	-1,943465614	-0,990895115	38,1
49,6	-1,158645267	-0,092135568	0,983187494	-1,475629357	-0,870284970	52,3
Trecho 3						
123,6	0,713012487	0,204014482	-0,983187494	0,760352755	0,481258131	122,4
123,6	0,713012487	-0,190852251	-0,983187494	1,199498178	0,268416697	131,5
123,6	0,445632807	-0,881869033	-0,983187494	1,740744912	-0,245950099	128,7
123,6	0,713012487	1,191181313	-0,983187494	-0,085542117	1,013361713	127,5
123,6	0,713012487	0,895031264	-0,983187494	0,137599117	0,853730639	121,0
123,6	1,247771845	1,882198095	0,983187494	-0,013641053	1,868274803	126,4
123,6	0,980392166	0,302731165	0,983187494	0,998504696	0,718931064	130,3
123,6	1,247771845	0,697597897	0,983187494	0,926208571	1,14461393	125,8
123,6	1,247771845	0,79631458	0,983187494	0,832773229	1,204919003	124,4
123,6	1,247771845	1,191181313	0,983187494	0,489666396	1,446139294	121,2

Fonte: Elaborado pelo autor


Com os resultados de QI previstos em ambos os modelos estudados foi elaborada a Tabela 6, comparando a assertividade de ambos com base no erro absoluto de cada previsão e no erro médio de cada trecho. Deste modo foram gerados os gráficos das Figuras 22 e 23 de dispersão, para melhor visualizar os resultados apresentados.

Tabela 6 – Comparativo dos resultados obtidos pelos dois modelos

QI Medido (Contagens/km)	Regressão Linear Múltipla		Regressão Polinomial de Segundo Grau	
	QI Previsto (Contagens/km)	Erro Absoluto	QI Previsto (Contagens/km)	Erro Absoluto
Trecho 1				
127,7	95,3	32,4	128,1	0,4
127,7	111,8	15,9	121,2	6,5
127,7	107,4	20,3	125,1	2,6
127,7	100,2	27,5	117,9	9,8
127,7	105,8	21,9	126,1	1,6
127,7	118,0	9,7	119,5	8,2
127,7	112,6	15,1	127,7	0,0
127,7	126,8	0,9	127,7	0,0
127,7	128,5	0,8	126,2	1,5
127,7	121,9	5,8	121,9	5,8
Trecho 2				
49,6	52,5	2,9	58,8	9,2
49,6	56,4	6,8	49,6	0,0
49,6	44,2	5,4	44,2	5,4
49,6	56,4	6,8	49,6	0,0
49,6	53,6	4,0	56,3	6,7
49,6	60,9	11,3	49,2	0,4
49,6	71,9	22,3	55,7	6,1
49,6	65,3	15,7	69,5	19,9
49,6	46,5	3,1	38,1	11,5
49,6	57,6	8,0	52,3	2,7
Trecho 3				
123,6	125,8	2,2	122,4	1,2
123,6	127,9	4,3	131,5	7,9
123,6	121,8	1,8	128,7	5,1
123,6	120,3	3,3	127,5	3,9
123,6	121,9	1,7	121,0	2,6
123,6	136,4	12,8	126,4	2,8
123,6	135,2	11,6	130,3	6,7
123,6	143,0	19,4	125,8	2,2
123,6	142,4	18,8	124,4	0,8
123,6	140,2	16,6	121,2	2,4
Erro Médio (Regressão Linear Múltipla)		Erro Médio (Regressão Polinomial de Segundo Grau)		
10,970		4,463		


Fonte: Elaborado pelo autor

Figura 22 - Gráfico de dispersão QI Previsto x QI Real do modelo de Regressão Linear



Fonte: Elaborado pelo autor

Figura 23 – Gráfico de dispersão QI Previsto x QI Real do modelo de Regressão Polinomial



Fonte: Elaborado pelo autor

6 CONCLUSÃO

Este trabalho permitiu concluir que é possível determinar o valor do QI de pavimentos rodoviários por meio de medições realizadas com o uso de sensores de smartphones e aplicação de modelos de Inteligência Artificial.

A formulação matemática para calcular QI empregou dois modelos de regressão. A análise dos resultados indicou que o segundo modelo – a regressão polinomial de segundo grau – apresentou desempenho superior em relação a regressão linear múltipla, tanto no que diz respeito à precisão quanto à aderência aos dados reais. Enquanto o modelo linear obteve um erro quadrático médio em torno de 191,38 contagens/km e R^2 de 0,85, o modelo polinomial reduziu esse erro para 37,66 contagens/km e atingiu R^2 de 0,97, indicando melhora significativa.

Os resultados obtidos neste estudo reforçam a capacidade da Inteligência Artificial, em especial os modelos de regressão, como ferramenta técnica aplicável à Engenharia Civil. A IA demonstrou potencial para lidar com variáveis, gerar previsões confiáveis e auxiliar na tomada de decisões relacionadas à avaliação e manutenção de infraestruturas viárias.

Ainda assim, este estudo apresenta limitações. A base de dados foi restrita e, mesmo com resultados coerentes, seria necessário ampliar a amostragem para validar o modelo em outras condições, como variação do modelo do veículo, smartphone e diferentes aplicativos, fatores que podem interferir nas medições e devem ser considerados em trabalhos futuros. Também vale mencionar que, por se tratar de um modelo treinado com dados normalizados, a equação resultante depende dessa transformação — o que pode dificultar a sua aplicação direta sem o devido processamento dos dados.

Apesar dessas limitações, ao permitir estimativas precisas com menor custo e maior agilidade, a aplicação de algoritmos preditivos em problemas de engenharia representa não apenas uma tendência, mas uma evolução metodológica que pode transformar a forma como gestores e engenheiros lida com dados e planejamento, como na área de transportes, onde essa possibilidade pode ser especialmente útil em situações com orçamento reduzido.

7 REFERÊNCIAS

AASHTO. **Pavement management guide**. American Association of State Highway and Transportation Officials. Washington, DCC/USA, 2001.

AGÊNCIA NACIONAL DE TRANSPORTES TERRESTRES – ANTT. **Recurso de desenvolvimento tecnológico RDT: Irregularidade longitudinal de pavimentos: Correlação entre QI e IRI e comparação de equipamentos**. Nova Lima/MG, 2017. 358p.

ALBUQUERQUE, F. S. **Sistema de gerência de pavimento para departamentos de estradas do Nordeste Brasileiro**. 2007. 303 f. Tese (Doutorado) - Curso de Engenharia Civil, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2007.

BERNUCCI, L. B. et al. **Pavimentação asfáltica: formação básica para engenheiros**. Rio de Janeiro: PETROBRAS: ABEDA, 2008. 504 p.

BISCONSINI, D. R. **Avaliação da Irregularidade Longitudinal dos Pavimentos com Dados Coletados por Smartphones**. 2016. Dissertação (Mestrado) – Escola de Engenharia de São Carlos da Universidade de São Paulo, 2016.

BRASIL. DEPARTAMENTO NACIONAL DE INFRAESTRUTURA E TRANSPORTES – DNIT. Diretoria Executiva. Instituto de Pesquisas Rodoviárias. **Manual de gerência de pavimentos**. Rio de Janeiro, 2011. 189p. (IPR Publ. 745).

BRASIL. DEPARTAMENTO NACIONAL DE INFRAESTRUTURA E TRANSPORTES – DNIT. **Manual de restauração de pavimentos asfálticos**. Rio de Janeiro, 2006. 310p. (IPR Publ. 720).

BUSBEE, K. L.; BRAUNSCHWEIG, D. Programming Fundamentals. Rebus Community, 2018. Disponível em: <<https://press.rebus.community/programmingfundamentals/>> Acesso em: 8 jun. 2025.

CAETANO, M. O.; FAGUNDES, A. B.; GOMES, L. P. **Modelo de regressão linear para estimativa de geração de RCD em obras de alvenaria estrutural**. Ambiente Construído, Porto Alegre, v. 18, n. 2, p. 309-324, abr./jun. 2018. ISSN 1678-8621 Associação Nacional de Tecnologia do Ambiente Construído.

DATA CAMP. **Introdução à plotagem com Matplotlib em Python**. 2024. Disponível em: <<https://www.datacamp.com/pt/tutorial/matplotlib-tutorial-python>>. Acesso em: 13 mai. 2025.

DEPARTAMENTO NACIONAL DE ESTRADAS DE RODAGEM. DNER-PRO 164/94: **Calibração e controle de sistemas medidores de irregularidade de superfície de pavimento (Sistemas Integradores IPR/USP e Maysmeter)**. IPR, 1994. 18p.

DEPARTAMENTO NACIONAL DE ESTRADAS DE RODAGEM. DNER-ES 173/86: **Método de Nível e Mira para Calibração de Sistemas Medidores de Irregularidade Tipo Resposta**. IPR, 1986. 13p.

DEPARTAMENTO NACIONAL DE ESTRADAS DE RODAGEM. DNER-PRO 182/94: **Medição da irregularidade da superfície de pavimento com sistemas integradores IPR/USP e maysmeter**. IPR, 1994. 9p.

DEPARTAMENTO NACIONAL DE INFRAESTRUTURA E TRANSPORTES. DNIT 005/2003 – TER: **Defeitos nos pavimentos flexíveis e semi-rígidos: Terminologia**. Rio de Janeiro: IPR, 2003. 12p.

DEPARTAMENTO NACIONAL DE INFRAESTRUTURA E TRANSPORTES. DNIT – 009/2003 - PRO: **Avaliação subjetiva da superfície de pavimentos flexíveis e semi-rígidos - Procedimento**, Rio de Janeiro: IPR, 2003. 6p.

FERREIRA, S. R.; SOARES, J. B. **Técnicas de Avaliação de Pavimentos Rodoviários**. 2. ed. Brasília: UnB, 2012.

Field, A. **Discovering statistics using IBM SPSS Statistics**. 5. ed. SAGE Publications Ltd, 2017. 1104p.

GERON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems**. 2. ed. O'Reilly Media, 2019.

HANSON, T., CAMERON, C., & HILDEBRAND, E. **Evaluation of low-cost consumer-level mobile phone technology for measuring international roughness index (IRI) values**. Canadian Journal of Civil Engineering, 2014. 41(9), 819–827p.

ISLAM, S., BUTTLAR, W. G., ALDUNATE, R. G., & VAVRIK, W. R. **Use of cellphone application to measure pavement roughness**. T&DI Congress 2014: Planes, Trains, and Automobiles, 2014. 553-563p. (American Society of Civil Engineers).

KARAMIHAS, S.M. SAYERS, M.W. **The Little Book of Profiling. Basis information about measuring an interpreting road profiles**. The Regent of the University of Michigan. 1998.

RIBEIRO, L. **Introdução à biblioteca Pandas**. 2020. Disponível em: <<https://medium.com/tech-grupozap/introdu%C3%A7%C3%A3o-a-biblioteca-pandas-89fa8ed4fa38>>. Acesso em: 13 mai. 2025.

RODRIGUES, R. M. **Modelos para previsão de desempenho de pavimentos com base em dados de concessionárias de rodovias**. In: 5° CONGRESSO BRASILEIRO DE RODOVIAS E CONCESSÕES – CBR&C, Campinas, 2007.

SANTANA, M. R. O.; DOMINGUEZ, D. S.; IGLESIAS, S. M. PESSÔA, J. R. C.; DIAS, L. A. **Modelos de regressão aplicados na caracterização de argamassas leves contendo agregados não convencionais de EVA e fibras de piaçava**. Universidade Estadual de Santa Cruz - UESC, Campus Soane Nazaré de Andrade, Ilhéus, BA, Brasil. Revista Matéria, v. 23 n. 3, 2018.

SILVA, J. A. R. A. **Análise dos parâmetros de irregularidade longitudinal de ciclofaixas com uso do equipamento Merlin na cidade de João Pessoa – PB**. Trabalho de Conclusão de Curso. João Pessoa, PB. UFPB, 2019.

VISCONTI, T. S. **O sistema gerencial de pavimentos do DNER**. Rio de Janeiro: Departamento Nacional de Estradas de Rodagem, Instituto de Pesquisas Rodoviárias, Divisão de Apoio Tecnológico, 2000.

ANEXO A – Folha utilizada em campo para anotação das cotas

IDENTIFICAÇÃO DA SEÇÃO	
RUA:	Magalhães
PERÍMETRO:	
SENTIDO:	

CÁLCULO DO COEFICIENTE DE IRREGULARIDADE						
CONVÊNIO CTG/UNESP						
Trecho:						
Dist.	LM (m)		LM (m)		LM (m)	
(m)	RI	RE	RI	RE	RI	RE
Acum =						
0,0	3,747		3,971			
0,5	3,712		3,931			
1,0	3,702		3,895			
1,5	3,670		3,740			
2,0	3,610		3,815			
2,5	3,576		3,766			
3,0	3,521		3,695			
3,5	3,497		3,645			
4,0	3,442		3,592			
4,5	3,392		3,555			
5,0	3,340		3,496			
5,5	3,289		3,468			
6,0	3,235		3,392			
6,5	3,170		3,359			
7,0	3,115		3,297			
7,5	3,062		3,252			
8,0	3,017		3,200			
8,5	2,958		3,159			
9,0	2,895		3,009			
9,5	2,838		3,061			
10,0	2,793		2,992			
10,5	2,705		2,870			
11,0	2,643		2,788			
11,5	2,609		2,748			
12,0	2,562		2,755			
12,5	2,495		2,720			
13,0	2,467		2,672			
13,5	2,393		2,612			
14,0	2,344		2,570			
14,5	2,303		2,516			