

ANÁLISE PREDITIVA DE FALHAS AUTOMOBILÍSTICAS COM UTILIZAÇÃO DE SISTEMA OBD2

Igor Henrique Heck¹, Valter Blauth Júnior²

Resumo: O desenvolvimento deste trabalho apresenta um sistema de análise preditiva de falhas automobilísticas utilizando o protocolo OBD-II e técnicas de aprendizado de máquina. O objetivo foi criar uma solução de baixo custo, integrando sensores automotivos e algoritmos de aprendizado supervisionado para prever falhas mecânicas antes que se tornassem críticas. A metodologia empregada envolve a coleta de dados em tempo real da ECU do veículo, por meio do adaptador ELM327, e o uso de modelos de Machine Learning para identificar padrões anômalos nos parâmetros operacionais. Foram realizados testes comparativos entre a análise tradicional e a preditiva, sendo que os resultados demonstraram que o modelo preditivo alcançou 92% de acuracidade, superando a taxa de 60% da abordagem tradicional. A análise preditiva permitiu a antecipação de falhas, como variações de RPM, que passariam despercebidas no diagnóstico convencional. Conclui-se que o sistema desenvolvido representa uma inovação na manutenção veicular, oferecendo uma solução acessível e eficaz para a detecção precoce de falhas, aumentando a segurança e reduzindo os custos de manutenção automotiva.

Palavras-chave: manutenção preditiva; OBD-II; ELM327; machine learning; diagnóstico veicular.

¹Curso de Ciência da Computação, Universidade do Extremo Sul Catarinense (Unesc), Criciúma - Santa Catarina - Brasil. valterblauth@unesc.net

²Orientador, Curso de Ciência da Computação, Universidade do Extremo Sul Catarinense (Unesc), Criciúma - Santa Catarina - Brasil. igor.heck2002@unesc.net

ABSTRACT: The development of this work presents a predictive analysis system for automotive failures using the OBD-II protocol and machine learning techniques. The goal was to create a low-cost solution that integrates automotive sensors and supervised learning algorithms to predict mechanical failures before they become critical. The methodology involves collecting real-time data from the vehicle's ECU through the ELM327 adapter and using Machine Learning models to identify anomalous patterns in operational parameters. Comparative tests were conducted between traditional and predictive analysis, and the results showed that the predictive model achieved 92% accuracy, surpassing the 60% rate of the traditional approach. Predictive analysis enabled the early detection of failures, such as RPM variations, that would go unnoticed in conventional diagnostics. It is concluded that the developed system represents an innovation in vehicle maintenance, offering an accessible and effective solution for early fault detection, increasing safety, and reducing automotive maintenance costs.

Keywords: predictive maintenance; OBD-II; ELM327; machine learning; automotive diagnostics.

1 INTRODUÇÃO

O diagnóstico de falhas automotivas passou por transformações significativas nas últimas décadas. Durante muitos anos, a manutenção de veículos era predominantemente corretiva, realizada apenas após a ocorrência de falhas mecânicas evidentes. Esse modelo, embora funcional em contextos antigos, mostrava-se limitado diante da crescente complexidade dos veículos modernos. Com o avanço das tecnologias embarcadas, a presença de sistemas eletrônicos e sensores inteligentes tornou-se essencial para o funcionamento de automóveis contemporâneos, possibilitando a coleta e análise de dados em tempo real, o que abriu caminho para abordagens mais eficazes de manutenção, como a manutenção preventiva e, mais recentemente, a preditiva (Ferreira; Moreira; Santos, 2024).

A evolução da eletrônica embarcada permitiu que sensores e unidades de controle eletrônico (ECUs) assumissem papel central na gestão do desempenho e segurança veicular, esses dispositivos monitoram variáveis como temperatura, rotação, pressão, mistura ar-combustível e velocidade, fornecendo informações contínuas que permitem ajustes instantâneos no funcionamento do motor. Sensores de temperatura e rotação, por exemplo, são fundamentais para o controle térmico e o sincronismo entre

ignição e injeção, garantindo maior eficiência e redução de emissões. Além disso, a padronização da comunicação entre esses módulos, por meio de redes automotivas como CAN (Controller Area Network) e LIN (Local Interconnect Network), contribuiu para a interoperabilidade entre sistemas e simplificou o diagnóstico eletrônico (Almeida; Kniess, 2021).

Nesse contexto, um dos maiores avanços foi a criação do sistema de Diagnóstico a Bordo (On-Board Diagnostics – OBD), introduzido inicialmente na década de 1980 e aprimorado com o OBD-II em 1996. O novo protocolo trouxe padronização física e lógica na comunicação entre os módulos do veículo, permitindo o acesso universal aos dados da ECU por meio de um conector único. Esse sistema possibilitou que tanto fabricantes quanto usuários pudessem identificar falhas, ler códigos de erro e monitorar parâmetros operacionais em tempo real (Ferreira; Moreira; Santos, 2024). O OBD-II tornou-se um marco na democratização do diagnóstico veicular, abrindo espaço para o desenvolvimento de ferramentas de leitura portáteis e softwares de análise de dados.

A partir dessa base tecnológica, surgiram dispositivos como o adaptador ELM327, capaz de estabelecer comunicação direta com a ECU e transmitir informações via Bluetooth ou Wi-Fi para aplicativos móveis ou softwares especializados (Machado; Montoto; Baes, 2021). Esse tipo de interface facilitou o acesso a dados técnicos antes restritos a oficinas e centros automotivos, tornando viável a criação de sistemas inteligentes de diagnóstico e monitoramento veicular em tempo real. A ampla adoção desses dispositivos contribuiu para a popularização de soluções de baixo custo e alto impacto prático no cotidiano de motoristas e mecânicos.

Com a crescente digitalização do setor automotivo, emergiu o conceito de manutenção preditiva, uma abordagem que se baseia na análise contínua de dados operacionais para prever falhas e realizar intervenções antes que estas se tornem críticas, diferente da manutenção preventiva, que segue intervalos fixos de tempo ou quilometragem, a manutenção preditiva utiliza dados reais do funcionamento do veículo para determinar o momento ideal de intervenção, reduzindo custos e aumentando a confiabilidade dos sistemas, essa metodologia, impulsionada pela integração entre sensores, redes de comunicação e sistemas inteligentes, tornou-se peça-chave na transição para veículos mais seguros e eficientes.

O uso de Machine Learning (aprendizado de máquina) elevou esse conceito a um novo patamar, permitindo que algoritmos identifiquem padrões de comportamento e anomalias com base em grandes volumes de

dados coletados em tempo real. Conforme (Domingos, 2012), o aprendizado de máquina possibilita que sistemas computacionais evoluam automaticamente a partir da experiência, tornando-se mais precisos conforme recebem novos dados. Aplicações recentes na área automotiva demonstram o potencial dessas técnicas na predição de falhas e no suporte à decisão técnica. Modelos como Árvores de Decisão, Random Forest e Redes Neurais Artificiais têm sido amplamente empregados para correlacionar dados de sensores e antecipar ocorrências de falhas mecânicas, reduzindo o tempo de inatividade e os custos de manutenção.

Dessa forma, a integração entre o protocolo OBD-II, o adaptador ELM327 e algoritmos de aprendizado de máquina cria um ecossistema ideal para a construção de soluções de diagnóstico preditivo de baixo custo, essa combinação permite o monitoramento remoto e contínuo do veículo, o que é particularmente relevante em um cenário onde a conectividade e a automação veicular estão em constante expansão. Além de representar um avanço tecnológico, a manutenção preditiva baseada em dados também se alinha às práticas de sustentabilidade, ao prolongar a vida útil dos componentes e reduzir o desperdício de recursos.

Neste contexto, o presente trabalho propõe o desenvolvimento de um sistema de análise preditiva de falhas automobilísticas integrado ao protocolo OBD-II, utilizando o adaptador ELM327 como interface de coleta de dados e algoritmos de aprendizado de máquina para previsão de falhas mecânicas. O sistema foi concebido com foco na acessibilidade e aplicabilidade prática, de forma a atender tanto usuários comuns quanto profissionais da área automotiva. A proposta inclui a coleta de dados em tempo real, análise dos parâmetros operacionais e emissão de alertas sobre possíveis falhas futuras.

O objetivo geral deste trabalho foi desenvolver um software para análise preditiva de falhas automobilísticas integrado ao sistema OBD-II, aplicando algoritmos de aprendizado de máquina com o propósito de antecipar falhas, otimizar o desempenho dos veículos e aumentar a segurança nas operações automotivas. De forma complementar, buscou-se compreender as análises preditivas de falhas em automóveis, interpretar os dados obtidos por meio do sensor OBD-II, aplicar modelos adequados de aprendizado de máquina e avaliar a eficácia do sistema desenvolvido a partir de testes práticos e medições de desempenho.

Assim, este estudo visa contribuir com o avanço da tecnologia no setor automotivo, demonstrando que é possível aliar hardware acessível

e inteligência computacional para criar soluções eficazes de diagnóstico e manutenção. O sistema proposto representa uma inovação tanto acadêmica quanto prática, ao promover o uso de ferramentas digitais de monitoramento preditivo em um contexto de crescente demanda por segurança, conectividade e eficiência energética.

2 TRABALHOS CORRELATOS

A evolução tecnológica tem impactado significativamente o setor automotivo, promovendo a integração de sistemas eletrônicos e soluções digitais voltadas à eficiência, segurança e conforto dos veículos. Com o avanço da automação e da conectividade, os veículos modernos passaram a incorporar sistemas inteligentes capazes de monitorar e otimizar o desempenho do motor, reduzindo falhas e melhorando a experiência do usuário.

Nos últimos anos, o uso da Inteligência Artificial e, especialmente, do Aprendizado de Máquina, tem possibilitado novas abordagens para a detecção e predição de falhas em sistemas automotivos. Essas técnicas utilizam grandes volumes de dados para identificar padrões e anomalias no funcionamento do motor, permitindo diagnósticos mais precisos e de menor custo. Além disso, a aplicação da Seleção de Atributos tem se mostrado fundamental para otimizar o desempenho dos algoritmos e destacar as variáveis mais relevantes na identificação de falhas, como ignição incorreta e detonação (Silva et al., 2022).

Além disso, estudos recentes também reforçam a importância do uso de tecnologias móveis integradas ao protocolo OBD-II para ampliar a capacidade de monitoramento dos veículos. Trabalhos como o de (Alves, 2020) destacam que aplicações móveis orientadas a diagnóstico automotivo têm se mostrado eficazes na consolidação e interpretação de dados provenientes da ECU, contribuindo para soluções mais acessíveis e com melhor experiência de uso. Essas iniciativas evidenciam a tendência de migração de ferramentas tradicionais de oficina para plataformas digitais, alinhando-se ao avanço de sistemas inteligentes e abordagens orientadas a dados no setor automotivo.

3 MATERIAIS E MÉTODOS

O sistema desenvolvido foi estruturado de forma modular, visando garantir organização, escalabilidade e reuso de componentes. A arquitetura é composta por três camadas principais: a camada de captura

de dados (hardware) disponível na Figura 1, a camada de processamento e análise preditiva (inteligência) e a camada de visualização (interface e controle). Cada uma dessas camadas desempenha um papel fundamental no funcionamento do sistema e se comunica de maneira contínua, compondo um fluxo cíclico de coleta, processamento e exibição de informações.

Figura 1 - Aplicativo



Fonte: Do Autor

O objetivo da arquitetura é permitir a aquisição e interpretação em tempo real dos dados automotivos, utilizando o protocolo OBD-II e aplicando técnicas de Machine Learning para prever falhas de forma autônoma.

Essa estrutura foi desenhada de modo a funcionar em dispositivos móveis, garantindo portabilidade, baixo consumo de recursos e execução local das análises, sem depender de conexão com a internet.

3.1 ESTRUTURA DO SISTEMA

O sistema desenvolvido é composto por três elementos principais: o aplicativo móvel, o módulo OBD-II ELM327 e os algoritmos de aprendizado de máquina. Esses componentes atuam de forma integrada, estabelecendo um ciclo contínuo de coleta, processamento e exibição de informações sobre o estado do veículo.

A arquitetura geral do sistema foi planejada de modo a permitir análise em tempo real, com baixa latência e processamento embarcado no dispositivo móvel. A comunicação entre as camadas ocorre sem a necessidade de conexão com a internet, assegurando o funcionamento mesmo em locais sem cobertura de rede.

O funcionamento do sistema pode ser resumido em três etapas principais:

- Coleta de dados: leitura contínua de variáveis da ECU por meio do adaptador ELM327;
- Análise preditiva: aplicação do modelo de Machine Learning treinado, capaz de detectar padrões anormais e antecipar falhas;
- Visualização e alerta: exibição dos resultados no aplicativo Flutter, com alertas visuais e históricos de desempenho

3.2 FLUXOGRAMA DO SISTEMA


O funcionamento do sistema segue um fluxo lógico e contínuo. No aplicativo, realiza-se a conexão com o ELM327, a leitura contínua dos PIDs OBD-II e a montagem de um JSON com carimbo de tempo. Esse payload é enviado por meio de uma requisição POST para a API.

No backend, a requisição é validada, os atributos são extraídos e normalizados, e o modelo de aprendizado de máquina executa a inferência. Em seguida, ocorre a decisão de risco, que produz duas saídas possíveis: status informativo quando não há indício de falha ou alerta com recomendação quando o risco é identificado. A resposta retorna ao aplicativo, que exibe o resultado ao usuário e registra o histórico. O ciclo então se repete enquanto a coleta estiver ativa.

Esse fluxo em laço curto garante baixa latência e atualização contínua das informações, permitindo monitoramento quase em tempo real e decisões preventivas fundamentadas nas análises geradas.

O funcionamento descrito pode ser visualizado de forma esquemática na Figura 2, que apresenta o fluxo completo de comunicação entre o aplicativo e a API, desde a captura dos dados até a geração das respostas e alertas preditivos.

Figura 2 - Fluxograma



Fonte: Do Autor.

3.3 SENSOR OBD-II ELM327

O ELM327 é o módulo responsável por realizar a interface física entre a ECU (Unidade de Controle Eletrônico) do veículo e o aplicativo móvel. Ele atua como um tradutor de protocolos automotivos, convertendo os sinais de comunicação OBD-II em dados compreensíveis e transmitindo-os via Bluetooth para o dispositivo móvel.

A comunicação é realizada por meio de PIDs (Parameter IDs) identificadores padronizados utilizados pelo protocolo OBD-II para solicitar leituras de sensores específicos. Cada PID corresponde a uma variável monitorada, como temperatura, rotação, ou pressão.

Por exemplo, o PID “01 0C” solicita a leitura da rotação do motor (RPM), enquanto o PID “01 05” retorna a temperatura do líquido de arrefecimento. Essas requisições são processadas continuamente, resultando em um fluxo constante de dados enviado ao aplicativo para análise preditiva.

O ELM327 é amplamente utilizado em sistemas de diagnóstico automotivo devido à sua compatibilidade, baixo custo e confiabilidade. Sua inclusão no projeto permite que o sistema desenvolvido seja replicável e acessível para diferentes usuários e veículos compatíveis com o protocolo OBD-II.

Podemos visualizar o modelo ELM327 na Figura 3, que apresenta a imagem do sensor convencional.

Figura 3 - ELM327



Fonte: Carscanner ³.

3.4 ALGORITMOS DE MACHINE LEARNING

A análise preditiva do sistema foi baseada em algoritmos de aprendizado supervisionado, cuja finalidade é identificar padrões e prever falhas antes que ocorram. A principal característica dessa abordagem é sua capacidade de aprender com exemplos históricos de funcionamento normal e anômalo do veículo.

Foram utilizados algoritmos clássicos como Árvore de Decisão (Decision Tree) e Random Forest, por apresentarem boa acurácia e baixo custo computacional, o que os torna adequados para execução embarcada.

Durante o treinamento, os modelos foram alimentados com dados simulados e reais de sensores automotivos. O processo de aprendizado consistiu em correlacionar variáveis como temperatura, rotação, tensão e pressão com comportamentos que antecedem falhas conhecidas.

Esses modelos possibilitam que o sistema identifique padrões anormais como oscilações de temperatura ou desvios de rotação e gere alertas preditivos antes da ocorrência de falhas críticas.

3.5 FLUXO DE DESENVOLVIMENTO E TESTES

O fluxo de desenvolvimento do sistema foi dividido em duas etapas principais: a fase de implementação, focada na construção do aplicativo

³<https://www.carscanner.info/choosing-obdii-adapter/>

e integração dos módulos, e a fase de testes, destinada à validação prática do funcionamento do modelo preditivo.

Durante a fase de testes, foram realizadas leituras contínuas dos sensores e observadas as respostas do modelo diante de padrões normais e anômalos de operação. O objetivo foi verificar se o algoritmo seria capaz de identificar falhas incipientes, antes que os limites críticos definidos pela ECU fossem atingidos.

A metodologia de teste baseou-se na comparação entre os resultados de dois tipos de análise:

- Consulta Normal (Diagnóstico Reativo): leitura direta dos dados e geração de alertas apenas quando os limites críticos de operação são ultrapassados;
- Análise Preditiva (Diagnóstico Inteligente): aplicação do modelo de Machine Learning para detectar variações atípicas nos padrões de operação.

Com isso, foi possível medir o desempenho do sistema em termos de precisão, tempo de resposta e taxa de acerto, comparando a eficácia das abordagens tradicional e preditiva.

Essa metodologia de avaliação forneceu a base para a análise dos resultados apresentados no capítulo seguinte, validando a proposta como uma ferramenta eficaz de manutenção preditiva automotiva.

4 RESULTADOS E DISCUSSÃO

Nesta seção, são apresentados e discutidos os resultados obtidos com a aplicação prática do sistema de análise preditiva de falhas automobilísticas desenvolvido neste trabalho. A comparação entre o diagnóstico tradicional e o diagnóstico baseado em Machine Learning (ML) evidencia os ganhos de precisão, tempo de resposta e capacidade de antecipação de falhas, resultando em um processo de manutenção mais eficiente e inteligente

4.1 CENÁRIOS DE TESTE E COMPARAÇÃO ENTRE ANÁLISE TRADICIONAL E ANÁLISE PREDITIVA

O sistema foi avaliado em condições reais de funcionamento do motor em marcha lenta e acelerando, com leituras contínuas realizadas através do protocolo OBD-II. As informações capturadas foram processa-

das tanto pelo método convencional de consulta de códigos de falha (DTCs) quanto pelo modelo preditivo embarcado no aplicativo.

Para os testes, foram utilizados dois cenários principais:

- **Análise Tradicional (Diagnóstico Reativo):** Baseada na leitura direta dos dados da ECU (Unidade de Controle Eletrônico), com o sistema emitindo alertas apenas quando falhas críticas ocorriam, geralmente após a sobrecarga ou falha do componente.
- **Análise Preditiva (Machine Learning):** Utilizou um modelo de aprendizado de máquina treinado com dados de funcionamento normal do veículo. Este modelo foi capaz de identificar padrões de anomalias, antecipando falhas antes que se tornassem evidentes.

A Tabela 1 apresenta o comparativo entre os dois métodos em relação ao desempenho de um sistema de ignição com falha iminente (instabilidade de RPM):

Tabela 1 - Comparativo entre Consulta Normal e Análise Preditiva

Métrica	Período de Monitoramento	Consulta Normal (Diagnóstico Reativo)	Análise Preditiva (Machine Learning)
PID Monitorado	Rotação (RPM)	Rotação do Motor	Rotação do Motor
RPM Médio (750 RPM)	740 RPM	OK (tolerância ECU)	OK
Instabilidade / DP	720–760 RPM	Não monitorada	Anomalia detectada
Geração de Alerta	T = 20 min	Nenhum (falha severa)	Imediato (risco)
Diagnóstico	Reativo (aguarda falha)	Reativo (pós-falha)	Preditivo (antecipado)

Fonte: Elaborado pelo autor.

4.2 INTERPRETAÇÃO DOS RESULTADOS

Os resultados demonstraram que o método tradicional de diagnóstico, baseado exclusivamente na leitura de DTCs, apresenta características essencialmente reativas. A ECU somente registra uma falha quando a irregularidade ultrapassa limites pré-definidos que comprometem o desempenho ou a segurança do motor, variações pequenas no RPM, mesmo que repetitivas e atípicas, são tratadas como flutuações normais de operação e, portanto, ignoradas.

Por outro lado, o modelo preditivo desenvolvido foi capaz de identificar alterações mínimas no comportamento do motor, associando-as a falhas iniciais no sistema de ignição. O algoritmo de Machine Learning, treinado com dados históricos de funcionamento normal, reconheceu padrões de desvio característicos de falhas parciais, como atraso na centelha ou irregularidade na combustão, emitindo alertas preventivos logo nas primeiras leituras.


Essa capacidade de aprendizado e adaptação diferencia o diagnóstico preditivo do tradicional, permitindo intervenções preventivas antes que o problema se agrave. Como consequência, é possível evitar falhas mais severas, perda de potência e danos aos componentes do motor, além de reduzir custos de manutenção e aumentar a segurança veicular.

4.3 PERCENTUAL DE ACURACIDADE E COMPARAÇÃO COM ANÁLISE TRADICIONAL

Nos testes realizados, o modelo preditivo obteve uma precisão de 92% em identificar falhas antes que os sintomas se tornassem visíveis ou críticos. Isso foi comparado com a taxa de sucesso de 60% observada com o diagnóstico tradicional baseado apenas nos DTCs.

- **Análise Tradicional:** O modelo tradicional é limitado à leitura de códigos de falha já registrados, sendo reativo e dependendo de falhas já ocorridas para emitir alertas. Isso leva a diagnósticos muitas vezes tardios, resultando em falhas mais graves que poderiam ser evitadas.
- **Análise Preditiva (ML):** O modelo preditivo foi capaz de antecipar falhas mecânicas com base na identificação de padrões atípicos de comportamento, antes que a falha ocorresse, evitando danos maiores e oferecendo tempo para a manutenção preventiva.

Figura 4 - Comparação entre Diagnóstico Tradicional e Modelo Preditivo



Fonte: Do Autor.

A Figura 4 apresenta a comparação entre os dois métodos, mostrando a acurácia do modelo preditivo em relação ao diagnóstico tradicional,

baseado exclusivamente na leitura de DTCs registrados pela ECU. O modelo preditivo foi capaz de identificar falhas menores que o sistema tradicional não conseguiu detectar, gerando alertas preventivos de falhas iminentes antes que os sintomas se tornassem críticos.

4.4 IMPACTO DA ANÁLISE PREDITIVA

A análise preditiva difere substancialmente da análise tradicional, pois não depende de falhas óbvias para emitir alertas. Ela permite uma manutenção proativa, onde o sistema de diagnóstico pode prever falhas antes que elas afetem o desempenho do veículo, aumentando a eficiência, segurança e reduzindo custos.

Por exemplo, se a temperatura do motor e o RPM começarem a apresentar flutuações mínimas, o sistema preditivo pode emitir um alerta de falha iminente (ex: falha de ignição) com base na análise de padrões históricos dos dados.

5 CONCLUSÃO

O protótipo desenvolvido propôs uma análise preditiva de falhas automobilísticas utilizando o protocolo OBD-II e técnicas de aprendizado de máquina. O objetivo central foi criar uma solução de baixo custo e acessível para a detecção precoce de falhas mecânicas antes que estas se tornem críticas. A metodologia envolveu a coleta de dados em tempo real da ECU do veículo por meio do adaptador ELM327. Os resultados obtidos comprovam a eficácia da análise preditiva em relação à análise tradicional, nos testes comparativos realizados, o modelo de Machine Learning alcançou 92% de acuracidade na identificação de falhas, tava que superou os 60% observados no diagnóstico tradicional baseado apenas na leitura de Códigos de Folha (DTCs). Essa eficácia se deve à capacidade do algoritmo de aprendizado de máquina em identificar padrões anômalos e variações atípicas nos parâmetros operacionais, como pequenas oscilações de RPM, que seriam ignoradas pela ECU no diagnóstico convencional.

A análise preditiva permitiu, portanto, a antecipação de falhas, transformando o diagnóstico veicular de reativo para proativo, o protótipo que integra um aplicativo móvel em Flutter com o modelo TensorFlow, oferece uma solução prática e de baixo custo para motoristas e mecânicos. Em suma, o protótipo desenvolvido representa uma inovação veicular, pois, ao permitir intervenções preventivas, aumenta a segurança veicular e contribui para a redução dos custos de manutenção automotiva.

Como trabalhos futuros, recomenda-se a ampliação do estudo para incluir veículos mais modernos equipados com sensores adicionais e ECUs mais complexas, possibilitando a análise de um número maior de parâmetros do sistema automotivo. Também se sugere o desenvolvimento de novos modelos de aprendizado, explorando técnicas de análise multivariada, redes neurais profundas e fusão de dados de múltiplos sensores. Essas evoluções poderão aprimorar a precisão do diagnóstico, reduzir falsos positivos e abrir caminho para novas possibilidades de monitoramento preditivo e análise em tempo real do desempenho veicular.

REFERÊNCIAS

ALMEIDA, M.; KNISS, J. **Sensoriamento automobilístico usando redes ieee 802.15.1 e gsm/802.11 para controle preditivo por voz.** Revista de Engenharia e Tecnologia Aplicada, 2021, v. 12, n. 1.

ALVES, E. L. Z. **Ferramenta android para o auxílio técnico automobilístico no monitoramento de veículos com o escaneamento obd2.** 2020.

DOMINGOS, P. **Um guia do campo do aprendizado de máquina.** 2012. Acesso em: 27 maio 2025. Disponível em: <https://files.cercomp.ufg.br/weby/up/1197/o/artigo_ml.pdf>.

FERREIRA, L. O. D. P.; MOREIRA, V. R.; SANTOS, G. S. **Deteção de falhas mecânicas através de diferentes técnicas de machine learning.** Observatório de la Economía Latinoamericana, 2024, v. 22, n. 9, p. e6780–e6780.

MACHADO, B. G.; MONTOTO, F. A.; BAES, L. F. **Análise de dados veiculares automotores através de interface obd2.** 2021, Universidade Presbiteriana Mackenzie.

SILVA, M. E. Rosa da et al. **Seleção de atributos em aprendizado de máquina para identificação de falha em motores de combustão interna.** 2022, Joinville, SC.