v7.n11.2026

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA DETECÇÃO E SOLUÇÃO DE PROBLEMAS AUTOMOTIVOS

USE OF ARTIFICIAL INTELLIGENCE FOR DETECTION AND SOLUTION OF AUTOMOTIVE PROBLEMS

USO DE INTELIGENCIA ARTIFICIAL PARA LA DETECCIÓN Y SOLUCIÓN DE PROBLEMAS AUTOMOTRICES

Murilo Paiva Garbelini[1], Felipe Diniz Dallilo[2]

e7119494
https://doi.org/10.47820/recima21.v7i11.9494

PUBLICADO: 11/2026

RESUMO

A indústria automotiva tem passado por um processo acelerado de digitalização, no qual os veículos modernos são estruturados por complexas redes de comunicação e módulos eletrônicos. Essa evolução tornou o diagnóstico automotivo mais desafiador, evidenciando as limitações dos métodos tradicionais de inspeção. Este trabalho tem como objetivo analisar a aplicação da Inteligência Artificial (IA) como ferramenta de apoio na detecção e solução de falhas automotivas. A pesquisa foi conduzida por meio de uma revisão de literatura fundamentada em conceitos de *Machine Learning* e *Deep Learning*, aliada a um estudo de caso comparativo. A simulação submeteu dois modelos de IA Generativa (ChatGPT, versão GPT-4o, e Gemini, versão 1.5 Pro) a cinco cenários reais de diagnóstico ocorridos em oficinas mecânicas, contrastando as respostas computacionais (com *prompts* básicos e enriquecidos) com os laudos técnicos humanos por meio de uma rubrica de classificação técnica estruturada (1 a 5). Os resultados demonstraram que ambas as IAs elevam sua precisão quando alimentadas pela percepção sensorial (*feeling*) do mecânico, observando-se, na amostra avaliada, desempenho ligeiramente superior do modelo Gemini (média 4,92) na resolução de falhas lógicas e sistêmicas, como panes na rede Controller Area Network (CAN) e no Body Control Module (BCM). Conclui-se, considerando as limitações amostrais do estudo, que a Inteligência Artificial atua de forma promissora como um copiloto técnico, organizando planos de testes e otimizando o tempo de manutenção, desde que operada de forma complementar à expertise do profissional automotivo.

PALAVRAS-CHAVE: *Inteligência Artificial. Diagnóstico Automotivo. Machine Learning. Redes Automotivas.*

ABSTRACT

The automotive industry has undergone an accelerated digitization process, in which modern vehicles are structured by complex communication networks and electronic modules. This evolution has made automotive diagnostics more challenging, highlighting the limitations of traditional inspection methods. This study aims to analyze the application of Artificial Intelligence (AI) as a support tool in the detection and resolution of automotive faults. The research was conducted through a literature review based on Machine Learning and Deep Learning concepts, combined with a comparative case study.

[1] Graduando em Sistemas de Informação pela Universidade de Araraquara (UNIARA), atuando na área de Inteligência Artificial e Sistemas de Informação.
[2] Doutor em Engenharia de Software pela Universidade de São Paulo (USP) e docente pesquisador na Universidade de Araraquara (UNIARA) na área de Sistemas de Informação e Engenharia de Software.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

The simulation subjected two Generative AI models (ChatGPT, version GPT-4o, and Gemini, version 1.5 Pro) to five real diagnostic scenarios from mechanical workshops, contrasting the computational responses (using basic and enriched prompts) with human technical reports through a structured technical classification rubric (1 to 5). The results demonstrated that both AIs increase their accuracy when fed by the mechanic's sensory perception (feeling), with the Gemini model showing slightly higher performance in the analyzed sample (average 4.92) in resolving logical and systemic faults, such as CAN Bus and BCM module failures. Given the sample limitations, it is concluded that Artificial Intelligence acts promisingly as a technical copilot, organizing test plans and optimizing maintenance time, provided it is operated in a complementary manner to the automotive professional's expertise.

KEYWORDS: *Artificial Intelligence. Automotive Diagnostics. Machine Learning. Automotive Networks.*

RESUMEN
La industria automotriz ha pasado por un proceso acelerado de digitalización, en el cual los vehículos modernos están estructurados por complejas redes de comunicación y módulos electrónicos. Esta evolución ha hecho que el diagnóstico automotriz sea más desafiante, evidenciando las limitaciones de los métodos tradicionales de inspección. Este trabajo tiene como objetivo analizar la aplicación de la Inteligencia Artificial (IA) como herramienta de apoyo en la detección y solución de fallas automotrices. La investigación se llevó a cabo mediante una revisión de literatura fundamentada en conceptos de Machine Learning y Deep Learning, combinada con un estudio de caso comparativo. La simulación sometió dos modelos de IA Generativa (ChatGPT, versión GPT-4o, y Gemini, versión 1.5 Pro) a cinco escenarios reales de diagnóstico ocurridos en talleres mecánicos, contrastando las respuestas computacionales (con prompts básicos y enriquecidos) con los informes técnicos humanos mediante una rúbrica de clasificación técnica estructurada (1 a 5). Los resultados demostraron que ambas IAs elevan su precisión cuando son alimentadas por la percepción sensorial (feeling) del mecánico, observándose, en la muestra analizada, un desempeño ligeramente superior del modelo Gemini (promedio 4,92) en la resolución de fallas lógicas y sistémicas, como fallos en la Red CAN y en el módulo BCM. Se concluye, considerando las limitaciones muestrales, que la Inteligencia Artificial actúa de manera prometedora como un copiloto técnico, organizando planes de pruebas y optimizando el tiempo de mantenimiento, siempre que se opere de forma complementaria a la experiencia del profesional automotriz.

PALABRAS CLAVE: *Inteligencia Artificial. Diagnóstico Automotriz. Machine Learning. Redes Automotrices.*

INTRODUÇÃO

A indústria automotiva passou por intensas transformações nas últimas décadas, impulsionadas pelo avanço da tecnologia, da eletrônica embarcada e dos sistemas computacionais aplicados aos veículos. Os automóveis modernos deixaram de ser formados apenas por componentes mecânicos e passaram a incorporar sensores, módulos eletrônicos, unidades de controle, redes de comunicação interna e sistemas embarcados responsáveis por monitorar e controlar diferentes funções do veículo. Sistemas como injeção eletrônica, freios com Anti-lock Braking System (ABS), controle de estabilidade, direção assistida, monitoramento de

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

temperatura, pressão, rotação e desempenho do motor demonstram como a tecnologia passou a ocupar papel fundamental no funcionamento dos automóveis atuais.

Com essa evolução, o processo de diagnóstico automotivo também se tornou mais complexo. Problemas que antes podiam ser identificados principalmente por inspeção visual, por testes práticos ou pela experiência do profissional atualmente dependem, muitas vezes, da leitura de códigos de falha, interpretação de dados de sensores e análise da comunicação entre diferentes módulos eletrônicos. Nesse cenário, o diagnóstico tradicional continua sendo importante, porém pode apresentar limitações quando utilizado de forma isolada, principalmente em falhas intermitentes, problemas multifatoriais ou situações em que o código de erro indica apenas um sintoma, e não necessariamente a causa principal da falha.

Diante desse contexto, a Inteligência Artificial (IA) apresenta-se como uma alternativa promissora para apoiar o diagnóstico e a manutenção automotiva. Por meio da análise de grandes volumes de dados, sistemas baseados em IA podem identificar padrões de funcionamento, reconhecer anomalias, auxiliar na classificação de falhas e contribuir para a previsão de problemas antes que eles se agravem. Entre as técnicas associadas à Inteligência Artificial, destacam-se o *Machine Learning* e o *Deep Learning*. O *Machine Learning* permite que modelos computacionais aprendam com dados históricos e identifiquem relações entre sintomas, parâmetros de funcionamento e falhas já registradas. Já o *Deep Learning*, baseado em redes neurais profundas, amplia essa capacidade ao lidar com dados mais complexos, como sinais de vibração, sons, imagens, séries temporais e informações coletadas em tempo real.

Apesar de benefícios como o aumento da precisão na identificação de falhas e a redução do tempo necessário para o diagnóstico, a aplicação da IA no setor automotivo também apresenta desafios. O desempenho dos modelos inteligentes depende da qualidade das informações coletadas e da correta estruturação dos dados de entrada; por isso, a Inteligência Artificial deve ser compreendida como um recurso de apoio ao diagnóstico, e não como substituta completa do conhecimento técnico humano.

Diante disso, o problema de pesquisa a ser investigado é: de que maneira modelos de Inteligência Artificial Generativa (ChatGPT e Gemini) comportam-se no suporte ao diagnóstico de falhas automotivas reais e qual o impacto da inclusão da percepção sensorial do mecânico humano na assertividade dessas ferramentas?

A justificativa e a relevância da pesquisa manifestam-se, no plano acadêmico, pela avaliação experimental comparativa de grandes modelos de linguagem aplicados à engenharia e eletrônica veicular; e, no plano prático, pela proposição de uma metodologia estruturada de

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

engenharia de *prompts* capaz de otimizar o tempo de pátio e evitar trocas indevidas de componentes nas oficinas de reparação.

O objetivo geral deste trabalho é analisar como a Inteligência Artificial pode contribuir para o diagnóstico automotivo em termos de precisão, rapidez e eficiência na identificação de falhas em veículos modernos. Para alcançar esse propósito, os objetivos específicos são: a) realizar uma revisão bibliográfica sobre Inteligência Artificial, *Machine Learning*, *Deep Learning* e redes automotivas; b) estruturar uma metodologia de engenharia de *prompts* dividindo as entradas entre o relato leigo do cliente (*Prompt* Básico) e a percepção sensorial técnica (*Prompt* Enriquecido); e c) comparar, por meio de uma rubrica de classificação técnica estruturada (1 a 5), o desempenho do diagnóstico humano isolado frente aos modelos ChatGPT (GPT-4o) e Gemini (1.5 Pro) em cinco cenários reais de oficina.

1. REFERENCIAL TEÓRICO

Esta seção apresenta os principais conceitos teóricos relacionados à Inteligência Artificial e sua aplicação no diagnóstico automotivo, abordando fundamentos de IA, *Machine Learning*, *Deep Learning*, diagnóstico tradicional e sistemas embarcados.

1.1. Inteligência Artificial

A Inteligência Artificial (IA) é um campo da ciência da computação voltado ao desenvolvimento de sistemas capazes de executar tarefas que, tradicionalmente, exigiriam capacidades associadas à inteligência humana, como raciocínio, aprendizagem, percepção e tomada de decisão. Russell e Norvig (2020) definem a IA como o estudo de agentes que percebem o ambiente e tomam ações de forma orientada a objetivos, compreensão que ajuda a sustentar sua aplicação em contextos complexos de análise e decisão. No setor automotivo, essa perspectiva torna-se relevante porque os veículos modernos operam com grande volume de dados provenientes de sensores, módulos eletrônicos e sistemas embarcados.

Com o avanço tecnológico, a IA passou a ser aplicada em diferentes setores produtivos, incluindo a indústria automotiva. Nesse contexto, sua utilização está associada à análise de dados, à automação de processos, ao apoio à manutenção e à identificação de falhas. A presença crescente de componentes eletroeletrônicos e redes automotivas ampliou a dependência dos veículos em relação ao processamento de informações, o que reforça a necessidade de soluções inteligentes para interpretação de dados e apoio à tomada de decisão técnica (CARVALHO, 2008; SILVA, 2015; MACHADO; MACHADO; FILGUEIRAS, 2018).

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Além disso, a indústria automotiva vem sendo impactada por um processo mais amplo de transformação digital. Lopez-Vega e Moodysson (2023) identificam múltiplos tópicos tecnológicos associados a essa transformação, mostrando que o setor vem passando por mudanças estruturais baseadas em tecnologias digitais. Nesse cenário, a IA passa a ocupar posição estratégica, especialmente em atividades relacionadas ao monitoramento, análise e uso de dados automotivos.

1.2. Machine Learning

Machine Learning, ou aprendizado de máquina, é uma subárea da Inteligência Artificial voltada ao desenvolvimento de sistemas capazes de aprender a partir de dados. Segundo Mitchell (1997), um sistema aprende quando melhora seu desempenho em determinada tarefa com base na experiência adquirida. Essa abordagem permite a construção de modelos computacionais capazes de identificar padrões em grandes volumes de dados e aplicar esse conhecimento a novas situações.

No contexto automotivo, essa abordagem é particularmente relevante, pois os veículos modernos produzem continuamente informações por meio de sensores e unidades de controle eletrônico (Electronic Control Units – ECUs). Isso permite que modelos inteligentes sejam treinados para interpretar sinais de funcionamento, reconhecer padrões de anomalia e associar determinados comportamentos a condições de falha. Gong et al. (2022) destacam que diferentes algoritmos de aprendizado de máquina podem ser empregados em sistemas automotivos para previsão e alerta de falhas em subsistemas como transmissão, motor e pneus.

Entre as principais abordagens de *Machine Learning*, destacam-se o aprendizado supervisionado, o aprendizado não supervisionado e o aprendizado por reforço. No âmbito deste trabalho, o aprendizado supervisionado apresenta maior relevância, pois permite o treinamento de modelos com base em registros históricos de falhas previamente identificadas, favorecendo a construção de sistemas capazes de auxiliar no diagnóstico automotivo (GONG et al., 2022).

1.3. Deep Learning

O *Deep Learning*, ou aprendizado profundo, é uma evolução do *Machine Learning* baseada em redes neurais artificiais compostas por múltiplas camadas de processamento. Goodfellow, Bengio e Courville (2016) destacam que esse tipo de técnica permite modelar relações complexas e aprender representações hierárquicas dos dados, o que amplia significativamente a capacidade analítica dos sistemas inteligentes.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Uma de suas principais vantagens está na possibilidade de extrair características relevantes diretamente dos dados brutos, reduzindo a dependência de seleção manual de variáveis. No diagnóstico automotivo, o *Deep Learning* apresenta grande potencial por possibilitar a análise de informações provenientes de sensores, vibrações, sons, imagens e dados operacionais em tempo real, lidando melhor com dados não lineares e altamente variáveis (GONG et al., 2022). Dessa forma, o *Deep Learning* fortalece a transição de uma abordagem corretiva para uma abordagem preditiva e inteligente.

1.4. Diagnóstico Automotivo Tradicional

O Diagnóstico Automotivo Tradicional baseia-se, em grande medida, na experiência do profissional, na inspeção visual e na utilização de equipamentos como *scanners* automotivos. Esses recursos auxiliam na identificação de problemas ao permitir a leitura de códigos de falha e o acompanhamento de determinados parâmetros do veículo.

Entretanto, esse modelo apresenta limitações diante da crescente complexidade dos veículos atuais. Em muitos casos, os códigos de erro indicam apenas sintomas do problema, e não necessariamente sua causa-raiz. Além disso, falhas intermitentes, multifatoriais ou relacionadas à integração entre diferentes sistemas podem tornar o diagnóstico mais demorado e sujeito a interpretações equivocadas. Silva (2015), ao discutir redes automotivas em ambiente virtual, evidencia a complexidade crescente da comunicação entre sistemas embarcados nos veículos, o que ajuda a explicar por que métodos tradicionais tendem a ser insuficientes quando usados isoladamente.

1.5. Aplicação da IA no Diagnóstico Automotivo

A aplicação da Inteligência Artificial no diagnóstico automotivo tem crescido devido à sua capacidade de processar grandes volumes de dados e identificar padrões com maior eficiência. Sistemas baseados em IA podem analisar informações provenientes de sensores, históricos de manutenção, parâmetros de funcionamento e eventos operacionais do veículo, permitindo identificar anomalias e sugerir possíveis causas de falhas (GONG et al., 2022).

Outra aplicação relevante da IA no setor automotivo aparece no suporte técnico e no acesso à informação especializada. Medeiros et al. (2023) analisam *chatbots* baseados em modelos de linguagem aplicados a manuais automotivos em PDF e concluem que esse tipo de solução oferece *insights* sobre efetividade e aplicabilidade de ferramentas de IA no setor, especialmente na interface com manuais e resolução de consultas técnicas.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

1.6. Sensores e Sistemas Embarcados

Os veículos modernos são equipados com diversos sensores e sistemas embarcados responsáveis por monitorar variáveis como temperatura, pressão, rotação, velocidade, emissões e desempenho do motor. Esses dados são processados por unidades de controle eletrônico, formando a base para o funcionamento inteligente do veículo (SILVA, 2015; MACHADO; MACHADO; FILGUEIRAS, 2018). Nesse cenário, sensores e sistemas embarcados tornam-se fundamentais para a aplicação de técnicas de Inteligência Artificial, pois fornecem a base informacional necessária para treinamento, monitoramento e análise em tempo real.

2. METODOLOGIA

A pesquisa caracteriza-se como aplicada, exploratória e descritiva, com abordagem qualitativa e quantitativa (GIL, 2002). Para avaliar a viabilidade e a eficácia da Inteligência Artificial como ferramenta de apoio ao diagnóstico, realizou-se uma análise experimental comparativa baseada em cinco estudos de caso reais coletados a partir do histórico de diagnósticos de oficinas mecânicas, mantendo o anonimato dos estabelecimentos e dos proprietários dos veículos.

2.1. Metodologia de Comparação e Escala de Avaliação

Os cinco cenários reais foram extraídos de Ordens de Serviço (OS) cedidas mediante autorização formal de oficinas mecânicas independentes do interior do Estado de São Paulo, mantendo-se o anonimato de clientes, veículos e estabelecimentos. O método consiste em isolar as variáveis de entrada de cada problema e submetê-las a dois modelos de Inteligência Artificial Generativa: o ChatGPT, na versão GPT-4o (OPENAI, 2026), e o Gemini, na versão 1.5 Pro (GOOGLE, 2026). Os testes foram executados em julho de 2026 via interface web oficial, em sessões anônimas independentes sem histórico prévio (zero-shot) e com três repetições por cenário para assegurar a estabilidade da resposta modal, a qual foi contrastada com o laudo técnico definitivo do mecânico humano.

A avaliação técnica foi realizada de forma independente por dois especialistas em reparação automotiva, utilizando uma rubrica de classificação técnica própria estruturada de 1 a 5 pontos (números inteiros), composta pela média ponderada de três critérios objetivos: Critério 1 (C1) – Identificação da Causa-Raiz (peso 50% ou 0,5); Critério 2 (C2) – Viabilidade e Sequenciamento do Plano de Testes (peso 30% ou 0,3); e Critério 3 (C3) – Especificidade Técnica e Ausência de Redundâncias (peso 20% ou 0,2). A nota final de cada cenário resulta da fórmula (C1 x 0,5) +

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

(C2 x 0,3) + (C3 x 0,2), o que origina matematicamente pontuações decimais (como 2,5, 3,5, 4,2, 4,5 e 4,8) a partir das seguintes faixas inteiras atribuídas a cada critério:

1 – Conhecimento Muito Insuficiente: Sugestões genéricas, descontextualizadas ou com erro conceitual técnico.

2 – Conhecimento Insuficiente: Diagnóstico plausível, mas focado em componentes periféricos com baixa correlação ao problema principal.

3 – Conhecimento Regular (Equivalente à Triagem Básica): Identificação correta do subsistema afetado, mas com plano de testes genérico.

4 – Conhecimento Satisfatório: Diagnóstico preciso da causa-raiz e plano de testes válido, porém com etapas intermediárias adicionais.

5 – Conhecimento Excelente: Capacidade analítica sistêmica que aponta diretamente a causa-raiz e o teste exato sem redundâncias.

2.2. Engenharia de *Prompts* para o Diagnóstico

Para que o comparativo possua validade analítica, adotou-se um protocolo padronizado no fornecimento das informações à IA, simulando a exata ordem de serviço recebida por um técnico automotivo. A estruturação do prompt (comando de entrada) foi desenhada para restringir respostas genéricas e forçar a Inteligência Artificial a atuar com o raciocínio lógico de um especialista em diagnóstico avançado.

O prompt padrão adotado para todos os testes segue a seguinte estrutura lógica:

Atribuição de Papel (Role-playing): Definição do nível de expertise exigido do modelo.

Contextualização do Objeto: Especificações técnicas do veículo.

Entrada de Variáveis (Sintomas): Descrição física e comportamental da falha.

Restrição e Saída: Limitação do número de causas prováveis e exigência de um plano de testes ordenado.

Modelo do Prompt Padronizado aplicado na pesquisa:

"Atue como um mecânico automotivo sênior especialista em diagnóstico avançado e redes de comunicação veicular. Serão fornecidos a seguir o contexto de um veículo e os sintomas apresentados. Com base estritamente nessas informações, liste as três causas-raiz mais prováveis para o problema, em ordem de probabilidade metodológica. Para cada causa, sugira o primeiro teste físico ou eletrônico que deve ser realizado na oficina.

Veículo: [MODELO/ANO]

Sintoma relatado: [DESCRIÇÃO DO PROBLEMA]

Contexto adicional: [INFORMAÇÃO EXTRA, SE HOUVER]"

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

2.3. Definição dos Cenários de Teste

Os cinco cenários reais selecionados abrangem diferentes níveis de complexidade dos sistemas embarcados automotivos:

- Cenário 1 – Sistema de Injeção (Bico Injetor)
  - Veículo: Volkswagen Gol 1.6 MSI Flex (2018).
  - Sintoma: Motor apresentando falhas de ignição (engasgos), perda de potência e aumento no consumo de combustível.
  - Diagnóstico real da oficina: Defeito físico/elétrico no bico injetor.
- Cenário 2 – Sistema ABS (Chicote Elétrico)
  - Veículo: Toyota Corolla 2.0 XEi Flex (2019).
  - Sintoma: Luz de avaria do ABS acesa no painel de instrumentos e perda de leitura de velocidade em uma das rodas, gerando código de falha no scanner.
  - Diagnóstico real da oficina: Rompimento ou falha de isolamento no chicote elétrico do sensor do ABS.
- Cenário 3 – Módulo de Carroceria (BCM)
  - Veículo: Jeep Renegade 1.8 Flex (2020).
  - Sintoma: Acionamento involuntário e autônomo dos vidros elétricos do veículo, sem comando prévio do motorista.
  - Diagnóstico real da oficina: Falha interna ou infiltração no módulo de conforto/carroceria (BCM).
- Cenário 4 – Rede CAN (Instabilidade Geral)
  - Veículo: Chevrolet Cruze 1.4 Turbo (2021).
  - Sintoma: Múltiplas luzes de advertência acendendo simultaneamente no painel de instrumentos, acompanhadas de queda dos ponteiros indicadores.
  - Diagnóstico real da oficina: Instabilidade e interferência na comunicação da Rede CAN (Controller Area Network).
- Cenário 5 – Rede CAN (Isolamento por Infiltração)
  - Veículo: Volkswagen Amarok 3.0 V6 Diesel (2021).
  - Sintoma: Perda total de comunicação entre os módulos eletrônicos de controle, impedindo o funcionamento do veículo.
  - Contexto adicional: A falha ocorreu logo após a lavagem do cofre do motor.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

- Diagnóstico real da oficina: Infiltração de umidade nos conectores provocando curto-circuito e derrubando a comunicação da Rede CAN.

2.4. Matriz de Entradas: Relato do Cliente vs. Percepção Sensorial (Feeling) do Mecânico

Para avaliar a sensibilidade do modelo de IA a variáveis contextuais, os testes foram divididos em duas etapas de entrada (inputs):

Prompt Básico: Contém estritamente o relato preliminar repassado pelo proprietário do veículo na recepção da oficina.

Prompt Enriquecido*:* Agrega a análise perceptiva e sensorial (feeling) realizada pelo mecânico experiente na inspeção primária física (ruídos específicos, cheiro de gases não queimados, calor localizado e padrões anormais de vibração).

A relação entre o que foi inicialmente relatado e as percepções físicas captadas pelo profissional em cada cenário encontra-se detalhada a seguir:

 Cenário 1 – Sistema de Injeção (Bico Injetor):

- Relato do Cliente: "O carro perde força em retomadas e está gastando mais combustível."
- Percepção Sensorial do Mecânico: Odor característico de combustível não queimado pelo escapamento e estalo metálico em frequência irregular na flauta de injeção ao acelerar.

 Cenário 2 – Sistema ABS (Chicote Elétrico):

- Relato do Cliente: "A luz do freio ABS acendeu repentinamente no painel."
- Percepção Sensorial do Mecânico: Ausência de travamento na roda, porém folga aparente e marcas de abrasão na guia plástica do chicote elétrico junto à caixa de roda.

 Cenário 3 – Módulo de Carroceria (BCM):

- Relato do Cliente: "Os vidros elétricos baixam sozinhos com o carro parado."
- Percepção Sensorial do Mecânico: Ruído intermitente característico de relé interno armando sem comando no compartimento sob o painel, associado a vestígios sutis de umidade na forração interna.

 Cenário 4 – Rede CAN (Instabilidade Geral):

- Relato do Cliente: "O painel acendeu múltiplas luzes de alerta simultaneamente e os ponteiros pararam de funcionar."
- Percepção Sensorial do Mecânico: O motor permanece em funcionamento perfeitamente estável e sem falhas mecânicas, evidenciando que o defeito é estritamente na linha de tráfego de dados e não no conjunto de ignição/carga.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

 Cenário 5 – Rede CAN (Isolamento por Infiltração):

- *Relato do Cliente:* "Lavei o motor e o veículo simplesmente não dá mais partida."
- *Percepção Sensorial do Mecânico:* Presença de água acumulada sob as travas plásticas dos conectores principais e cheiro de circuito superaquecido próximo à central.

3. RESULTADOS E DISCUSSÃO

Para mensurar o nível de profundidade e precisão técnica demonstrado pelos modelos em relação ao diagnóstico mecânico humano, aplicou-se a escala de 1 a 5 definida na metodologia deste estudo. O experimento avaliou duas das principais Inteligências Artificiais Generativas disponíveis no mercado: o ChatGPT (OpenAI) e o Gemini (Google).

Ambos os modelos foram submetidos aos mesmos cinco cenários sob duas condições de entrada: o *prompt básico* (contendo estritamente o relato preliminar e leigo do cliente) e o *prompt enriquecido* (agregando a percepção sensorial e o *feeling* empírico do mecânico, como ruídos, odores e inspeção visual prévia).

O Quadro 1 consolida os resultados quantitativos do diagnóstico humano em comparação com os modelos ChatGPT (GPT-4o) e Gemini (1.5 Pro), enquanto o Quadro 2 apresenta a síntese das respostas modais geradas em cada condição.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Quadro 1. Desempenho comparativo dos diagnósticos segundo a rubrica técnica (Escala 1 a 5)

Cenário Avaliado	Mecânico (C1/C2/C3 = Nota)	ChatGPT Básico (C1/C2/C3 = Nota)	ChatGPT Enriquecido (C1/C2/C3 = Nota)	Gemini Básico (C1/C2/C3 = Nota)	Gemini Enriquecido (C1/C2/C3 = Nota)
Cenário 1 – Injeção (Bico Injetor)	5/4/4 = **4,5**	2/2/2 = **2,0**	5/4/4 = **4,5**	3/2/2 = **2,5**	5/5/4 = **4,8**
Cenário 2 – Sistema ABS (Chicote)	5/4/4 = **4,5**	3/3/3 = **3,0**	5/4/4 = **4,5**	3/3/3 = **3,0**	5/5/4 = **4,8**
Cenário 3 – Módulo BCM	4/4/4 = **4,0**	4/3/3 = **3,5**	5/5/4 = **4,8**	4/4/4 = **4,0**	5/5/5 = **5,0**
Cenário 4 – Rede CAN (Painel)	4/4/4 = **4,0**	3/3/3 = **3,0**	5/5/4 = **4,8**	3/3/3 = **3,0**	5/5/5 = **5,0**
Cenário 5 – Rede CAN (Infiltração)	4/4/5 = **4,2**	4/4/4 = **4,0**	5/5/5 = **5,0**	5/4/4 = **4,5**	5/5/5 = **5,0**
Média Aritmética Global	**4,24**	**3,10**	**4,72**	**3,40**	**4,92**

Nota: Pesos: C1 (Causa-Raiz) = 0,5; C2 (Plano de Testes) = 0,3; C3 (Especificidade) = 0,2.

Fonte: Autoria própria (2026).

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

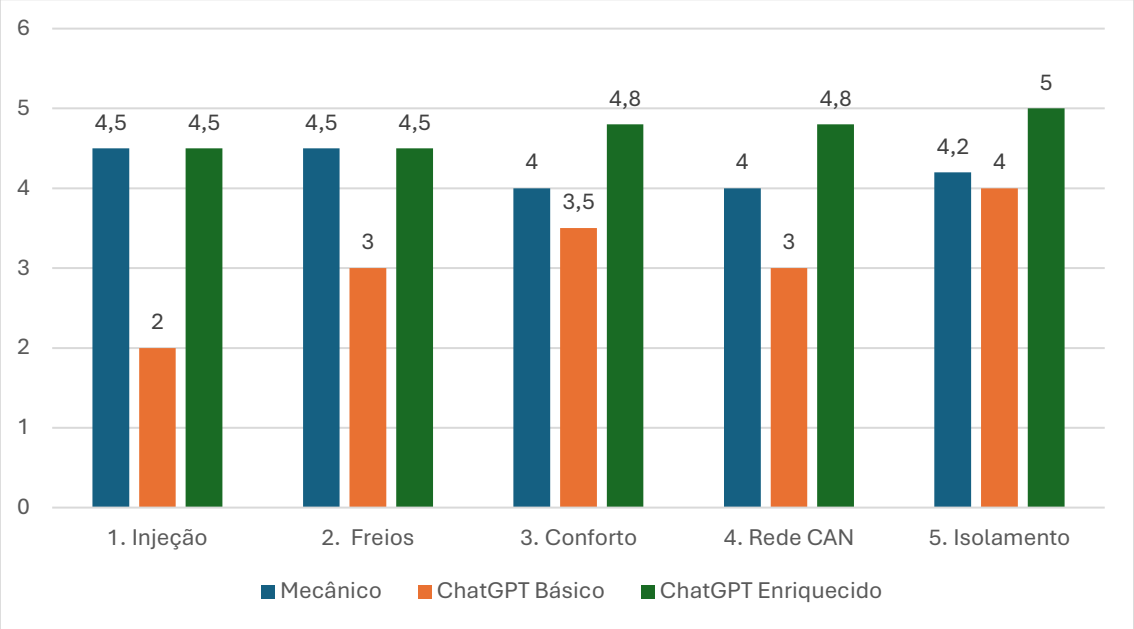
Quadro 2. Síntese das respostas modais (1ª causa-raiz e 1º teste) geradas pelos modelos de IA

Cenário	Saída com Prompt Básico	Saída com Prompt Enriquecido
Cenário 1 (Bico Injetor)	**ChatGPT:** Velas/cabos; inspeção de centelha. **Gemini:** Bobina ou sonda; leitura via *scanner*.	**ChatGPT:** Bico injetor travado; teste de vazão em bancada. **Gemini:** Bico injetor gotejando; medição ôhmica e teste em proveta.
Cenário 2 (Chicote ABS)	**ChatGPT:** Sensor sujo/avariado; leitura de código no *scanner*. **Gemini:** Sensor de roda ou anel fônico; leitura via *scanner*.	**ChatGPT:** Rompimento no chicote ABS; teste de continuidade com multímetro. **Gemini:** Abrasão no chicote do sensor; teste de continuidade movimentando a suspensão.
Cenário 3 (Módulo BCM)	**ChatGPT:** Interruptor da porta em curto; desmontagem. **Gemini:** Módulo de conforto/BCM ou botão; leitura via *scanner*.	**ChatGPT:** Infiltração no módulo BCM; inspeção de oxidação nos pinos/relés. **Gemini:** Curto por umidade na placa do BCM; inspeção dos conectores e medição de fuga.
Cenário 4 (Rede CAN)	**ChatGPT:** Bateria fraca ou alternador; teste de carga. **Gemini:** Queda de tensão na bateria/aterramento; teste com multímetro.	**ChatGPT:** Falha na rede CAN do painel; leitura de códigos de rede (série U). **Gemini:** Falha de terminação na rede CAN; medição de resistência (60 ohms) e osciloscópio.
Cenário 5 (Infiltração CAN)	**ChatGPT:** Umidade na ignição/sensores; secagem. **Gemini:** Curto por água na ECU ou conectores; inspeção visual.	**ChatGPT:** Curto por água nos conectores da ECU/CAN; secagem e teste OBD-II. **Gemini:** Isolamento do barramento CAN nos conectores da ECU; limpeza dielétrica e medição CAN High/Low.

Fonte: Autoria própria (2026).

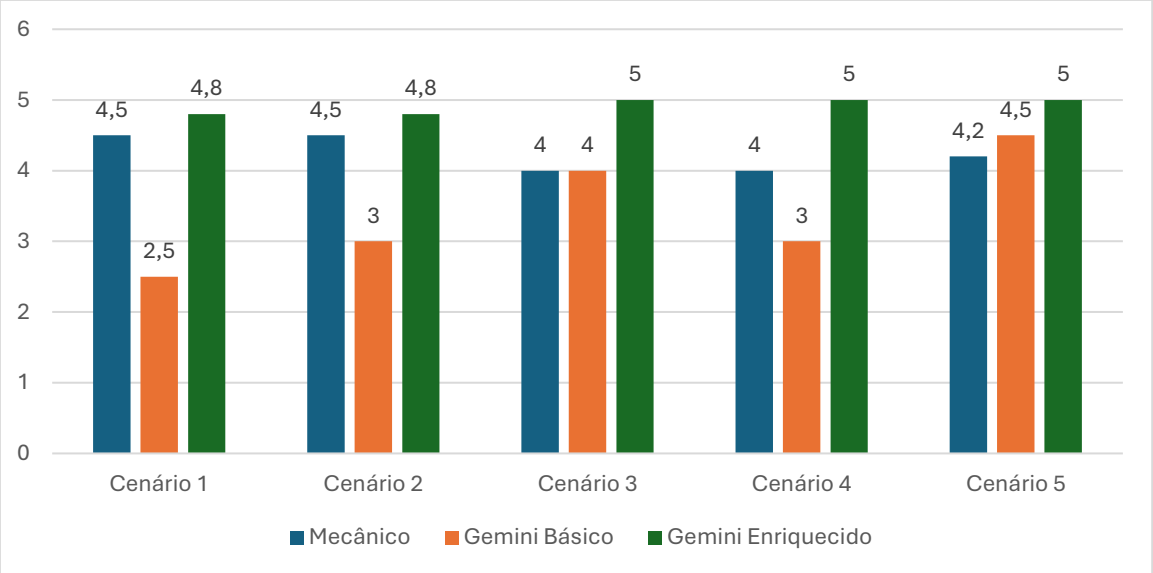
Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Gráfico 1. Desempenho comparativo por cenário: Mecânico vs. ChatGPT (Escala 1 a 5)



Fonte: Autoria própria (2026).

Gráfico 2. Desempenho comparativo por cenário: Mecânico vs. Gemini (Escala 1 a 5)



Fonte: Autoria própria (2026).

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Os Gráficos 1 e 2, em conjunto com os Quadros 1 e 2, ilustram a evolução da precisão diagnóstica do ChatGPT e do Gemini em função da qualidade das variáveis de entrada. Observa-se que, ao receberem apenas o relato leigo do cliente (*Prompt* Básico), ambos os modelos atingem pontuações médias inferiores às do mecânico humano nos cenários puramente mecânicos e periféricos (Cenários 1 e 2), demonstrando forte dependência de hipóteses estatísticas genéricas em vez de correlações físicas diretas.

Ao avaliar os cenários por meio do *prompt* básico, o modelo Gemini (média 3,40) demonstrou ligeira superioridade em relação ao ChatGPT (média 3,10). O ChatGPT adotou uma postura mais conservadora e ancorada em estatísticas globais, sugerindo, por exemplo, testar a bateria ou as velas de ignição antes dos bicos injetores ou da rede de comunicação. Em contrapartida, o Gemini conseguiu estabelecer correlações iniciais mais precisas entre os sintomas relatados e possíveis falhas sistêmicas nos módulos eletrônicos, obtendo pontuações superiores logo na primeira interação nos Cenários 1, 3 e 5.

Com a introdução do *prompt* enriquecido — que integra a percepção sensorial e empírica do mecânico, como ruídos, odores e inspeção visual —, ambas as Inteligências Artificiais apresentaram evolução consistente na pontuação técnica, alcançando médias de 4,72 (ChatGPT) e 4,92 (Gemini) frente à média de 4,24 do diagnóstico humano isolado. Essa diferença nos Cenários 3, 4 e 5 decorre dos critérios C2 e C3 da rubrica: enquanto o reparador humano realizou verificações empíricas intermediárias antes de isolar a falha de rede, o Gemini atingiu a nota máxima de "Conhecimento Excelente" (5,0) ao recomendar diretamente, a partir das evidências sensoriais fornecidas pelo próprio técnico, a medição ôhmica da Rede CAN e o uso de osciloscópio (Quadro 2). O ChatGPT também demonstrou elevada consistência (notas entre 4,5 e 5,0), ficando discretamente abaixo na média amostral por manter testes secundários preliminares nos Cenários 1 a 4.

Em suma, na amostra exploratória avaliada ($n = 5$), o modelo Gemini apresentou média global ligeiramente superior (4,92 contra 4,72 do ChatGPT no *prompt* enriquecido), sobretudo pelo direcionamento imediato de testes de rede nos Cenários 3, 4 e 5. Ressalta-se, contudo, que devido ao número reduzido de cenários e à natureza qualitativa das entradas, tais resultados indicam uma tendência de comportamento nos casos estudados e não permitem generalizações absolutas, sugerindo que a eficácia de ambas as IAs depende diretamente da qualidade da triagem física prévia realizada pelo mecânico humano.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

4. CONSIDERAÇÕES FINAIS

Este trabalho teve como objetivo analisar a viabilidade e a eficácia da aplicação da Inteligência Artificial no diagnóstico e na solução de problemas automotivos. Diante da crescente complexidade eletrônica e estrutural dos veículos modernos, conclui-se que o diagnóstico tradicional, isoladamente, tornou-se insuficiente para lidar com falhas sistêmicas em redes de comunicação e módulos embarcados.

Os resultados obtidos por meio do estudo de caso comparativo demonstraram que a Inteligência Artificial possui alto potencial como ferramenta de suporte técnico. Nos cenários envolvendo distúrbios complexos em sistemas eletrônicos, como falhas no módulo de carroceria (BCM) e curtos-circuitos na Rede CAN, os modelos demonstraram elevada aderência técnica na amostra estudada quando alimentados com variáveis de contexto e percepção sensorial humana. Já em falhas de injeção e sensores de roda com entradas puramente básicas, os modelos priorizaram etapas pautadas em incidência estatística global, o que reforça a indispensabilidade da validação física humana.

Dessa forma, evidencia-se que a Inteligência Artificial, neste estágio tecnológico, não substitui o conhecimento empírico e a percepção sensorial do mecânico automotivo, mas atua como um poderoso sistema de apoio à tomada de decisão. A correta estruturação dos comandos (engenharia de *prompts*) e a inserção de dados precisos permitem que a IA organize o raciocínio diagnóstico, evite interpretações equivocadas de códigos de falha e otimize o tempo de pátio nas oficinas mecânicas. Destaca-se, como limitação desta pesquisa, o caráter exploratório restrito a cinco estudos de caso e à inserção manual dos *prompts*, não cabendo extrapolação estatística generalizada sem testes em amostras ampliadas.

Para trabalhos futuros, sugere-se a aplicação de modelos de *Deep Learning* treinados especificamente com bancos de dados de telemetria automotiva local, bem como o desenvolvimento de interfaces diretas entre *scanners* OBD-II e sistemas de IA Generativa, minimizando a dependência da entrada manual de dados pelo reparador.

REFERÊNCIAS

CARVALHO, E. G. Inovação tecnológica na indústria automobilística: características e evolução recente. **Economia e Sociedade**, Campinas, v. 17, n. 3, p. 467-491, dez. 2008. DOI: https://doi.org/10.1590/S0104-06182008000300006. Disponível em: https://www.scielo.br/j/ecos/a/dZZpqddXTF5dKJzwkf5qxKp/?format=pdf&lang=pt. Acesso em: 10 abr. 2026.

GIL, A. C. **Como elaborar projetos de pesquisa**. 4. ed. São Paulo: Atlas, 2002.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

GONG, C.-S. A. et al. How to implement automotive fault diagnosis using artificial intelligence scheme. **Micromachines**, Basel, v. 13, n. 9, art. 1380, 2022. DOI: https://doi.org/10.3390/mi13091380. Disponível em: https://www.mdpi.com/2072-666X/13/9/1380. Acesso em: 10 abr. 2026.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. Cambridge: MIT Press, 2016.

GOOGLE. **Gemini (versão Gemini 1.5 Pro)**: modelo de linguagem de grande escala. Mountain View: Google, 2026. Disponível em: https://gemini.google.com/. Acesso em: 14 jul. 2026.

LOPEZ-VEGA, H.; MOODYSSON, J. Digital transformation of the automotive industry: network evolution and the rise of platform ecosystems. **Technology Analysis & Strategic Management**, London, v. 35, n. 11, p. 1400-1413, 2023. DOI: https://doi.org/10.1080/09537325.2022.2151873. Disponível em: https://www.tandfonline.com/doi/full/10.1080/09537325.2022.2151873. Acesso em: 10 abr. 2026.

MACHADO, H.; MACHADO, T. H. P.; FILGUEIRAS, A. C. **A tecnologia da informação aplicada em veículos automóveis no Brasil**. Anápolis: Universidade Estadual de Goiás, 2018. Disponível em: https://repositorio.ueg.br/jspui/bitstream/riueg/5388/2/AC%20024%200010-2018.pdf. Acesso em: 13 abr. 2026.

MEDEIROS, T. A. et al. Analysis of language-model-powered chatbots for query resolution in PDF-based automotive manuals. **Vehicles**, Basel, v. 5, n. 4, p. 1384-1399, 2023. DOI: https://doi.org/10.3390/vehicles5040076. Disponível em: https://www.mdpi.com/2624-8921/5/4/76. Acesso em: 13 abr. 2026.

MITCHELL, T. M. **Machine Learning**. New York: McGraw-Hill, 1997.

OPENAI. **ChatGPT (versão GPT-4o)**: modelo de linguagem de grande escala. San Francisco: OpenAI, 2026. Disponível em: https://chat.openai.com/. Acesso em: 14 jul. 2026.

RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 4. ed. Hoboken: Pearson, 2020.

SILVA, R. R. da. **Modelagem e análise de redes automotivas em ambiente virtual**. 2015. 71 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Automotiva) – Universidade de Brasília, Brasília, 2015. Disponível em: https://bdm.unb.br/bitstream/10483/11385/1/2015_RafaelRodriguesdaSilva.pdf. Acesso em: 13 abr. 2026.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.