



MATEUS LOURENÇO DO CARMO

**MODELAGEM DIGITAL COMO FERRAMENTA DE APOIO À
EFICIÊNCIA ENERGÉTICA E ROTEIRIZAÇÃO PARA
VEÍCULOS ELÉTRICOS INTELIGENTES**

LAVRAS – MG

2025

MATEUS LOURENÇO DO CARMO

**MODELAGEM DIGITAL COMO FERRAMENTA DE APOIO À EFICIÊNCIA
ENERGÉTICA E ROTEIRIZAÇÃO PARA VEÍCULOS ELÉTRICOS INTELIGENTES**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós Graduação em Engenharia de Sistemas e Automação, área de concentração em Sistemas Inteligentes, para a obtenção do título de Mestre.

Prof. DSc. Danilo Alves de Lima
Orientador

Prof. DSc. Felipe Oliveira e Silva
Coorientador

LAVRAS – MG

2025

**Ficha Catalográfica elaborada pelo Sistema de Geração
de Ficha Catalográfica da Biblioteca Universitária da UFLA, com
dados informados pelo(a) próprio(a) autor(a).**

Carmo, Mateus Lourenço do.

Modelagem digital como ferramenta de apoio à eficiência energética e roteirização
para veículos elétricos inteligentes / Mateus Lourenço do Carmo. - 2026.
61 p.

Orientador: Danilo Alves de Lima

Coorientador: Felipe Oliveira e Silva

Dissertação (Mestrado Acadêmico) - Universidade Federal de Lavras, 2026.
Bibliografia.

1. veículos elétricos inteligentes. 2. planejamento de rotas. 3. eficiência energética.
4. gêmeo digital. 5. SUMO. I. Lima, Danilo Alves de. II. Oliveira e Silva, Felipe. III.
Universidade Federal de Lavras. IV. Título.

MATEUS LOURENÇO DO CARMO

**MODELAGEM DIGITAL COMO FERRAMENTA DE APOIO À EFICIÊNCIA
ENERGÉTICA E ROTEIRIZAÇÃO PARA VEÍCULOS ELÉTRICOS INTELIGENTES**

**DIGITAL MODELING AS A TOOL TO SUPPORT ENERGY EFFICIENCY AND
ROUTE PLANNING FOR SMART ELECTRIC VEHICLES**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós Graduação em Engenharia de Sistemas e Automação, área de concentração em Sistemas Inteligentes, para a obtenção do título de Mestre.

APROVADA em 23 de Março de 2026.

Prof. DSc. Danilo Alves de Lima	UFLA
Prof. DSc. Felipe Oliveira e Silva	UFLA
Prof. DSc. Arthur de Miranda Neto	UFLA
Prof. DSc. Leandro da Silva Camargo	IFSUL

Prof. DSc. Danilo Alves de Lima
Orientador

Prof. DSc. Felipe Oliveira e Silva
Coorientador

**LAVRAS – MG
2025**

Nenhuma conquista é construída sozinho. Deus ilumina o caminho, a família sustenta os passos e os amigos tornam a jornada possível.

AGRADECIMENTOS

Agradeço primeiramente a Deus por tudo o que me proporcionou até este momento da minha trajetória, pelas oportunidades, aprendizados e pela força necessária para superar os desafios ao longo deste caminho.

Aos meus pais, Antônio e Ângela, por todo o amor, apoio e incentivo ao longo da vida, sempre oferecendo suporte e acreditando em mim. Estendo também meus agradecimentos à família da minha irmã — Diego, Eloá e Laura — pelo carinho, pela torcida e por sempre demonstrarem apoio em todos os momentos.

À minha família, minha esposa Jaciara e meu filho Estevam, que representam o meu maior alicerce. Vocês são minha principal fonte de motivação e inspiração. Agradeço profundamente pela compreensão diante dos momentos e noites de ausência dedicados aos estudos, pelo apoio constante e por caminharem ao meu lado em cada etapa desta jornada.

À equipe da Carpintaria Lourenço — Douglas, Guilherme e Rogério — pela parceria, dedicação e apoio durante esse período. O comprometimento de vocês foi fundamental para contornar meus momentos de ausência e permitir que eu pudesse conciliar as responsabilidades profissionais com os compromissos acadêmicos. Este trabalho também carrega um pouco do esforço coletivo e da confiança construída em nossa trajetória profissional.

Aos amigos e familiares que, de diferentes maneiras, acompanharam essa jornada, agradeço pela amizade, pelas conversas, pelo incentivo e pelo apoio nos momentos de maior desafio.

À Universidade Federal de Lavras (UFLA) e ao Programa de Pós-Graduação em Engenharia de Sistemas e Automação (PPGESISA), pelo suporte institucional e pela oportunidade de crescimento acadêmico e profissional.

Ao meu orientador, professor Danilo, pela disponibilidade em todos os momentos, pelas orientações, ensinamentos e pelo direcionamento ao longo do desenvolvimento deste trabalho.

Ao professor Felipe, coorientador desta pesquisa, por compartilhar seus conhecimentos e pelas contribuições que enriqueceram este estudo.

Aos membros da banca examinadora, pela disponibilidade em participar deste momento e pelas valiosas contribuições que certamente colaboram para o aprimoramento deste trabalho.

O presente trabalho foi realizado com apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ).

RESUMO

A crescente demanda por soluções sustentáveis na mobilidade urbana tem impulsionado o desenvolvimento de Veículos Elétricos Inteligentes (IEVs) e estratégias voltadas à otimização de consumo energético. No entanto, fatores como autonomia limitada, escassez de pontos de recarga e variabilidade das condições de tráfego ainda representam obstáculos significativos à ampla adoção desses veículos. Nesse cenário, este trabalho investiga a aplicação de Gêmeos Digitais (DTs) como ferramenta de suporte à tomada de decisão em tempo de execução, voltada ao planejamento dinâmico de rotas e ao monitoramento energético de IEVs. Inicialmente, é conduzida uma análise bibliométrica a partir da base *Web of Science (WoS)*, com a finalidade de avaliar a relevância da temática no cenário global e conhecer melhor as possíveis aplicações conjuntas. Com isso, a pesquisa resultou em 4.209 documentos, dos quais 206 incluem o termo *digital twin* como palavra-chave. A construção do mapa de coocorrência revelou cinco agrupamentos temáticos principais, destacando os termos *electric vehicles*, *energy efficiency*, *autonomous vehicles* e *digital twin* como centrais no *corpus* analisado. Na etapa experimental, desenvolveu-se uma aplicação em simulação integrada ao *Simulation of Urban MObility (SUMO)*, acoplada à interface *Traffic Control Interface (TraCI)* e programada em linguagem *Python*, na qual a lógica do DT monitora continuamente variáveis operacionais como velocidade, aceleração e nível de carga da bateria. A cada passo da simulação, decisões como recálculo de rota e redirecionamento a pontos de recarga são tomadas dinamicamente com base nas condições da rede viária e na energia disponível. Os resultados obtidos demonstram a viabilidade do uso de DTs para mitigar a "ansiedade de autonomia", melhorar a eficiência energética em tempo real e favorecer uma maior aceitação dos Veículos Elétricos (EVs) na mobilidade urbana.

Palavras-chave: veículos elétricos inteligentes; planejamento de rotas; eficiência energética; gêmeo digital; SUMO.

ABSTRACT

The growing demand for sustainable solutions in urban mobility has driven the development of Intelligent Electric Vehicles (IEVs) and strategies aimed at optimizing energy consumption. However, factors such as limited range, scarcity of charging stations, and variability in traffic conditions still pose significant obstacles to the widespread adoption of these vehicles. In this context, this work investigates the application of Digital Twins (DTs) as a runtime decision-support tool for dynamic route planning and energy monitoring of intelligent electric vehicles (IEVs). Initially, a bibliometric analysis was conducted using the Web of Science database, with the aim of assessing the relevance of the topic in the global scenario and gaining a better understanding of potential joint applications. As a result, the research identified 4,209 documents, of which 206 include the term digital twin as a keyword. The construction of the co-occurrence map revealed five main thematic clusters, highlighting the terms electric vehicles, energy efficiency, autonomous vehicles, and digital twin as central to the analyzed corpus. In the experimental stage, a simulation-based application was developed and integrated with SUMO, coupled to the TraCI (Traffic Control Interface) interface and programmed in Python. In this setup, the digital twin logic continuously monitors operational variables such as speed, acceleration, and battery state-of-charge. At each simulation step, decisions such as route recalculation and redirection to charging points are made dynamically based on road network conditions and the available energy. The results obtained demonstrate the feasibility of using DTs to mitigate "range anxiety", improve real-time energy efficiency, and foster greater acceptance of electric vehicles in urban mobility.

Keywords: intelligent electric vehicles; route planning; energy efficiency; digital twin; SUMO.

INDICADORES DE IMPACTO

Do ponto de vista científico, este trabalho contribui para a sistematização do conhecimento ao empregar uma análise bibliométrica que permite identificar tendências emergentes, redes de pesquisa e lacunas ainda pouco exploradas na literatura sobre mobilidade elétrica inteligente, eficiência energética e DTs. Esse mapeamento fortalece a base teórica da dissertação e fornece subsídios relevantes para o direcionamento de pesquisas futuras, além de consolidar a integração conceitual entre diferentes áreas do conhecimento. Sob a ótica científico-tecnológica, a incorporação do modelo energético à lógica de DT amplia o uso dessa tecnologia como sistema ciberfísico aplicado à mobilidade elétrica, contribuindo para o desenvolvimento de arquiteturas voltadas ao monitoramento contínuo e à tomada de decisão em tempo real. No quesito ambiental, a proposta de seleção de rotas energeticamente eficientes favorece a redução do consumo de energia elétrica durante os deslocamentos, contribuindo de forma indireta para a diminuição das emissões associadas à geração de energia. Ressalta-se que os princípios adotados podem ser estendidos também a veículos movidos a combustíveis fósseis, reforçando seu potencial de contribuição para a mitigação dos impactos ambientais e para a redução dos gases de efeito estufa no setor de transportes. Em termos de planejamento urbano e políticas públicas, a aplicação do DT proposta neste trabalho apresenta-se como um instrumento estratégico de apoio à tomada de decisão no contexto da mobilidade elétrica. A arquitetura desenvolvida permite a simulação integrada de cenários urbanos, contemplando variáveis como tráfego, consumo energético veicular e disponibilidade de infraestrutura de recarga, o que fornece subsídios técnicos relevantes para o desenvolvimento e aprimoramento de Sistemas de Transporte Inteligentes (ITS). Além disso, o uso do DT como ferramenta de simulação possibilita que gestores públicos avaliem, de forma antecipada, os impactos operacionais, energéticos e logísticos de diferentes estratégias de mobilidade antes de sua implementação no ambiente real. Quanto aos impactos econômico, social e operacional, a otimização das rotas e o uso mais eficiente da infraestrutura de recarga podem resultar na redução de custos operacionais, especialmente em aplicações envolvendo frotas de EVs. O monitoramento contínuo do consumo energético, aliado à tomada de decisão dinâmica, contribui para a mitigação da ansiedade de autonomia, aumentando a confiança dos usuários na mobilidade elétrica. Adicionalmente, a abordagem proposta favorece maior confiabilidade operacional do veículo, reduzindo o risco de falhas energéticas durante o deslocamento e ampliando a robustez do sistema em ambientes urbanos complexos.

IMPACT INDICATORS

From a scientific perspective, this work contributes to the systematization of knowledge by employing a bibliometric analysis that enables the identification of emerging trends, research networks, and still underexplored gaps in the literature related to intelligent electric mobility, energy efficiency, and DTs. This mapping strengthens the theoretical foundation of the dissertation and provides relevant support for guiding future research, while also consolidating the conceptual integration between different areas of knowledge. From a scientific-technological standpoint, the incorporation of the energy model into the DT logic expands the use of this technology as a cyber-physical system applied to electric mobility, contributing to the development of architectures aimed at continuous monitoring and real-time decision-making. From an environmental perspective, the proposed energy-efficient route selection favors the reduction of electricity consumption during vehicle operation, indirectly contributing to the reduction of emissions associated with energy generation. It is noteworthy that the principles adopted can also be extended to vehicles powered by fossil fuels, reinforcing their potential contribution to mitigating environmental impacts and reducing greenhouse gas emissions in the transportation sector. In terms of urban planning and public policies, the DT application proposed in this work can serve as a strategic tool to support decision-making in the context of electric mobility. The developed architecture enables the integrated simulation of urban scenarios, incorporating variables such as traffic conditions, vehicle energy consumption, and the availability of charging infrastructure, thereby providing relevant technical support for the development and improvement of Intelligent Transportation Systems (ITS). Furthermore, the use of DTs as a simulation tool allows public managers to anticipate and evaluate the operational, energy, and logistical impacts of different mobility strategies before their implementation in real environments. Regarding economic, social, and operational impacts, route optimization and more efficient use of charging infrastructure can lead to reduced operational costs, particularly in applications involving electric vehicle fleets. Continuous monitoring of energy consumption, combined with dynamic decision-making, contributes to mitigating range anxiety and increasing user confidence in electric mobility. Additionally, the proposed approach enhances the operational reliability of vehicles by reducing the risk of energy-related failures during travel and improving system robustness in complex urban environments.

LISTA DE FIGURAS

Figura 2.1 – Exemplos de tipos de comunicações <i>Vehicle-to-Everything</i> (V2X).	21
Figura 2.2 – Componentes e características do ecossistema de DTs.	24
Figura 3.1 – Ilustração funcionamento algoritmo A*.	29
Figura 3.2 – Forças atuantes no veículo em uma rampa	30

LISTA DE TABELAS

Tabela 2.1 – Tipos de grupos de comunicação para com o veículo.	21
Tabela 7.1 – Síntese crítica das lacunas de pesquisa e contribuições da dissertação . . .	52

LISTA DE SIGLAS

ADS Sistema de Condução Automatizada.

AI Inteligência Artificial.

BMS Sistemas de Gerenciamento de Bateria.

CNN Rede Neural Convolucional.

DDT Tarefa de Condução Dinâmica.

DL Aprendizado Profundo.

DRL Aprendizagem por Reforço Profundo.

DT Gêmeo Digital.

EDP Previsão de Demanda de Energia.

ES Servidor de Borda.

EV Veículo Elétrico.

IEV Veículo Elétrico Inteligente.

ITS Sistemas de Transporte Inteligentes.

LSTM Memória de Longo Curto Prazo.

ML Aprendizado de Máquina.

ODD Domínio de Projeto Operacional.

RL Aprendizado por Reforço.

SAE Sociedade dos Engenheiros Automotivos.

SLAM Localização e Mapeamento Simultâneo.

SoC Estado de Carga.

SoH Estado de Saúde.

SUMO *Simulation of Urban MObility*.

TraCI *Traffic Control Interface*.

V2B *Vehicle-to-Building*.

V2G *Vehicle-to-Grid*.

V2H *Vehicle-to-Home.*

V2L *Vehicle-to-Load.*

V2V *Vehicle-to-Vehicle.*

V2X *Vehicle-to-Everything.*

WoS *Web of Science.*

SUMÁRIO

I	Introdução, Revisão de literatura, Conceitos gerais e Metodologia	13
1	INTRODUÇÃO	14
1.1	Objetivos	16
1.2	Estrutura do trabalho	16
1.3	Justificativa	17
2	REVISÃO DA LITERATURA	18
2.1	Veículos elétricos inteligentes	18
2.2	Deslocamento veicular	20
2.2.1	Roteirização	20
2.2.2	Planejamento de movimento	20
2.2.3	Planejamento de trajetória	21
2.3	Eficiência energética	22
2.4	Gêmeos digitais	24
2.5	Bibliometria	26
3	CONCEITOS GERAIS	28
3.1	Algoritmo A*	28
3.2	Formulação matemática para simulação de desempenho, consumo energético e autonomia em veículos elétricos	29
3.2.1	Força de Resistência ao Rolamento F_{rr}	30
3.2.2	Arrasto Aerodinâmico F_{ad}	30
3.2.3	Força de Subida de Rampa F_{hc}	31
3.2.4	Força de Aceleração F_{la}	31
3.2.5	Esforço de Tração Total F_{te}	31
4	METODOLOGIA	32
II	Trabalhos publicados	33
5	ARTIGO I: Gêmeos digitais e veículos elétricos inteligentes: estado da arte e possíveis aplicações	34
6	ARTIGO II: Desenvolvimento de um gêmeo digital para o monitoramento de autonomia de veículos elétricos conectados	43
7	DISCUSSÃO DOS RESULTADOS DOS ARTIGOS	50
III	Conclusão e trabalhos futuros	53
8	CONCLUSÃO	54
	REFERÊNCIAS	56

Parte I

Introdução, Revisão de literatura, Conceitos gerais e Metodologia

1 INTRODUÇÃO

Os grandes centros urbanos concentram a maior parte da população mundial e, apesar de oferecerem oportunidades de desenvolvimento e interação social, enfrentam desafios relacionados à organização urbana, impactos ambientais e saúde pública. Nesse contexto, fortalecer a capacidade de adaptação e o funcionamento de espaços urbanos mesmo diante de desafios ou variações é essencial, uma vez que as cidades são reconhecidas como a principal escala para a promoção de mudanças estruturais (Consonni *et al.*, 2024). Entre os principais desafios destaca-se a redução das emissões do setor de transportes, responsável por cerca de 27% das emissões globais de CO₂ oriundas da queima de combustíveis fósseis, segundo a Agência Internacional de Energia (INTERNATIONAL ENERGY AGENCY, 2020). O transporte rodoviário, predominante no meio urbano e dependente de gasolina e diesel, configura-se como um dos maiores contribuintes dessas emissões, evidenciando a necessidade de soluções sustentáveis para a mobilidade urbana.

O desenvolvimento de soluções tecnológicas voltadas à eficiência energética, à redução de impactos ambientais e à melhoria da mobilidade urbana tem impulsionado a evolução dos IEVs. Esses veículos integram motorização elétrica a sistemas avançados de condução automatizada, sensores embarcados e conectividade, permitindo decisões autônomas durante a operação. Essa convergência tecnológica favorece a substituição progressiva dos veículos com motores a combustão interna e contribui para a reconfiguração dos deslocamentos no ambiente urbano.

Nesse cenário, a automação veicular assume papel central. A Sociedade dos Engenheiros Automotivos (SAE) classifica a automação em seis níveis, variando da ausência de automação (nível 0) à condução totalmente autônoma (nível 5) (SAE, 2021). A autonomia veicular está diretamente associada à capacidade do veículo de operar sem intervenção humana, mesmo em ambientes dinâmicos e imprevisíveis, que envolvem variáveis como condições climáticas, presença de pedestres, ciclistas, animais e flutuações no tráfego e na infraestrutura viária (Krysiuk, 2021). No contexto dos EVs, essa autonomia é ainda mais desafiadora em função das limitações energéticas das baterias, o que demanda um gerenciamento preciso do consumo e reforça a relevância de estratégias de planejamento e roteirização baseadas em dados dinâmicos do ambiente.

O avanço dos EVs ainda enfrenta limitações estruturais e operacionais. A chamada "ansiedade de autonomia" – caracterizada pelo receio de esgotamento da carga durante o trajeto – constitui uma das principais barreiras à adoção em larga escala (Miri; Fotouhi; Ewin, 2021). Essa percepção resulta não apenas da capacidade limitada das baterias, mas também da escassez de estações de recarga, do tempo elevado de reabastecimento e da falta de padronização da infraestrutura. Nesse contexto, os Sistemas de Gerenciamento de Bateria (BMS) assumem papel fundamental ao possibilitar o monitoramento contínuo de parâmetros críticos, como tensão, corrente, temperatura, Estado de Carga (SoC) e Estado de Saúde (SoH) (Noreen; Fouladfar; Saeed, 2024).

Dessa forma, a eficiência energética torna-se um elemento central para a viabilidade da mobilidade elétrica. A combinação de modelos analíticos, estatísticos e computacionais para a estimativa do consumo energético amplia a previsibilidade operacional e subsidia a tomada de decisão em tempo real. Esses modelos podem integrar dados históricos do veículo, variáveis climáticas, padrões de condução e informações geográficas, proporcionando uma representação mais precisa do comportamento energético dos IEVs em diferentes cenários (Miri; Fotouhi; Ewin, 2021).

Além do gerenciamento energético interno, a operação de veículos inteligentes em ambientes urbanos complexos requer estratégias avançadas de roteirização, planejamento de mo-

vimento e definição de trajetórias. A roteirização pode priorizar a minimização da distância ou do consumo energético, considerando mapas globais e condições de tráfego (Chen *et al.*, 2023; Zhang *et al.*, 2022). O planejamento de movimento envolve decisões locais associadas à interação com obstáculos e regras de tráfego (Paliwal, 2023), enquanto o planejamento de trajetória incorpora a dimensão temporal, definindo instantes adequados para transitar por pontos específicos da via (Ren; Huang; Gabbar, 2022; Ayawli *et al.*, 2018).

Nesse cenário, os DTs emergem como ferramentas relevantes para a integração entre os domínios físico e virtual. Um DT consiste em uma representação digital fiel de um sistema físico, capaz de simular, monitorar e responder em tempo real com base em dados do ambiente (Zhang *et al.*, 2021). Quando integrados à Internet das Coisas (IoT — *Internet of Things*), os DT ampliam a capacidade de interação entre veículos, infraestrutura e ambiente, viabilizando decisões mais adaptativas e eficientes (Bhatti; Mohan; Raja Singh, 2021).

Neste trabalho, o conceito DT é adotado sob uma perspectiva conceitual e funcional, alinhada ao escopo da modelagem digital proposta. Embora a solução desenvolvida não se configure como um DT completo no sentido estrito de uma integração bidirecional e totalmente automatizada com um sistema físico real, ela incorpora os elementos fundamentais desse paradigma, tais como a representação digital do sistema, o monitoramento contínuo de variáveis operacionais, a comparação entre estados estimados e observados e o suporte à tomada de decisão adaptativa em tempo de execução. Dessa forma, argumenta-se que a modelagem digital aqui apresentada pode ser compreendida como uma instância operacional de DT em ambiente simulado, na medida em que reproduz e analisa o comportamento do sistema com capacidade de influenciar suas decisões, justificando o uso do termo DT ao longo do trabalho sem prejuízo ao rigor conceitual.

Aplicações práticas dessa tecnologia no setor de mobilidade têm demonstrado resultados positivos. Em cidades como Barcelona e Buenos Aires, os DTs são empregados na otimização de sistemas semaforicos e no planejamento do transporte coletivo, promovendo ganhos de eficiência operacional (Piromalis; Kantaros, 2022). No setor automotivo, essas soluções têm sido utilizadas no monitoramento em tempo real, na manutenção preditiva e no desenvolvimento de veículos autônomos com maior autonomia energética (Cohen; Pilati; Faccio, 2021).

Dada a natureza multidisciplinar e a rápida evolução dessas tecnologias, torna-se essencial compreender o panorama da produção científica relacionada aos IEVs e às soluções associadas. Nesse sentido, a análise bibliométrica configura-se como uma abordagem eficaz para mapear o avanço científico e tecnológico em torno dos DT, da eficiência energética e dos IEVs, permitindo identificar tendências, redes de colaboração e lacunas de pesquisa (Saputro *et al.*, 2023; Khan *et al.*, 2022). Estudos baseados na WoS e analisados com o VOSviewer evidenciam agrupamentos temáticos centrados em termos como *electric vehicles*, *energy efficiency*, *autonomous vehicles* e *digital twin*, destacando o potencial de integração entre esses domínios (You *et al.*, 2022; Ellili, 2023).

Com base nessas evidências e no levantamento realizado, o presente trabalho concentra-se na aplicação prática dessa integração conceitual, propondo a implementação de um DT acoplado a um ambiente de simulação no SUMO, via interface TraCI. O objetivo deste trabalho é empregar o DT como ferramenta para otimizar a eficiência energética e aumentar a confiabilidade da mobilidade elétrica, contribuindo para a mitigação da ansiedade de autonomia em cenários urbanos. A arquitetura desenvolvida permite o monitoramento contínuo de variáveis operacionais — como velocidade, aceleração e nível de carga da bateria — e a tomada de deci-

sões dinâmicas, como recálculo de rotas e direcionamento a estações de recarga, adaptando-se às condições do tráfego e da rede viária em tempo de execução¹.

1.1 Objetivos

Este trabalho tem como objetivo geral desenvolver e avaliar um sistema baseado em DT capaz de integrar o planejamento dinâmico de rotas e o monitoramento (em tempo de execução) do consumo energético de veículos inteligentes, utilizando o simulador SUMO acoplado à interface TraCI, de modo a otimizar a eficiência energética, aumentar a confiabilidade da mobilidade elétrica e contribuir para a mitigação da ansiedade de autonomia em cenários urbanos. Os objetivos específicos incluem:

- Conduzir uma análise bibliométrica com o propósito de identificar tendências e lacunas de pesquisa relacionadas à integração de IEVs, eficiência energética, planejamento de rotas e tecnologias de DT;
- Desenvolver e implementar algoritmos de planejamento de rotas no simulador SUMO, incorporando lógicas de recarga e redirecionamento dinâmico que considerem pesos e critérios de custo voltados à otimização energética, possibilitando a adaptação da rota diante de níveis críticos de carga da bateria e da disponibilidade de pontos de recarga;
- Integrar o modelo de consumo energético ao sistema de simulação para estimar e monitorar, em tempo de execução, o desempenho energético de um veículo real em ambiente simulado, empregando a lógica de DT como suporte à tomada de decisão;
- Aprimorar a interpretação topológica da via, garantindo maior fidelidade e realismo à representação do ambiente viário no simulador.

1.2 Estrutura do trabalho

Este trabalho está estruturado no formato de artigos científicos, organizados de maneira a proporcionar uma compreensão progressiva e integrada dos conceitos, métodos e resultados obtidos. O Capítulo 2 apresenta a revisão de literatura, abordando a fundamentação teórica relacionada a IEVs, estratégias de roteirização, eficiência energética, DT e bibliometria. Posteriormente o Capítulo 3 elenca os conceitos gerais para embasamento teórico. Em seguida, o Capítulo 4 descreve a metodologia adotada e introduz os resultados obtidos, apresentados sob a forma de artigos, cada qual compondo um capítulo específico.

O Artigo 1, correspondente ao Capítulo 5, apresenta uma análise bibliométrica voltada à identificação de tendências de pesquisa envolvendo DTs e IEVs, destacando padrões de publicação, redes de colaboração e áreas emergentes. O Artigo 2, no Capítulo 6, descreve a aplicação de um DT para roteirização e monitoramento do nível de energia de um veículo real em ambiente simulado. Nesta etapa, são detalhados os procedimentos metodológicos que permitem simular o comportamento do DT no contexto da tomada de decisão em tempo real, com foco na otimização da eficiência energética e no gerenciamento da autonomia do veículo.

Por fim, o Capítulo 8 apresenta as conclusões e contribuições do estudo.

¹ O tempo de execução corresponde ao tempo interno da simulação, enquanto o tempo real refere-se ao acompanhamento simultâneo de um evento conforme ele ocorre no mundo físico.

1.3 Justificativa

A adoção em larga escala de IEVs ainda é fortemente impactada por fatores como a autonomia limitada das baterias, a incerteza quanto ao consumo energético real e a chamada ansiedade de autonomia, especialmente em cenários urbanos complexos. Embora existam avanços na infraestrutura de recarga e nos sistemas embarcados, a ausência de ferramentas capazes de integrar, em tempo real, o estado do veículo, as condições do tráfego e a rede viária limita a confiabilidade das decisões de deslocamento. Nesse sentido, a aplicação de DTs justifica-se por oferecer um mecanismo capaz de monitorar continuamente variáveis operacionais, antecipar comportamentos energéticos e adaptar rotas de forma dinâmica. Tal abordagem contribui diretamente para o aumento da eficiência energética, da previsibilidade operacional e da confiança do usuário na mobilidade elétrica.

2 REVISÃO DA LITERATURA

Este capítulo apresenta o referencial teórico que oferece suporte a este trabalho e aborda conceitualmente os tópicos IEVs, roteirização, eficiência energética, DTs e bibliometria.

2.1 Veículos elétricos inteligentes

Considerando que diversos termos podem ser empregados para se referir aos veículos inteligentes, a SAE define o chamado Sistema de Condução Automatizada (ADS) como uma estrutura hierárquica na qual o veículo pode assumir, parcial ou totalmente, as funções relacionadas à condução dinâmica de forma autônoma (SAE, 2021). Sendo assim, o veículo é capaz de executar integral ou parcialmente a Tarefa de Condução Dinâmica (DDT). Essa capacidade de operar de maneira automatizada ocorre independentemente das condições específicas estabelecidas pelo Domínio de Projeto Operacional (ODD). Em termos práticos, o ADS permite ao veículo executar ações de direção com ou sem a necessidade de intervenção humana, levando em conta o ambiente em que se encontra. A partir dessa definição, a SAE estabelece uma taxonomia composta por seis níveis de automação, variando do nível 0, em que não há automação, até o nível 5, correspondente à automação completa.

A condução de veículos em rodovias públicas configura-se como uma tarefa intrinsecamente complexa, uma vez que exige constante interação com variáveis de natureza imprevisível, tais como as condições da infraestrutura viária, o volume e comportamento do tráfego, fatores climáticos, bem como a presença de outros veículos, pedestres, ciclistas e animais (Krysiuk, 2021). No contexto dos EVs, essa complexidade assume relevância adicional, pois afeta diretamente o consumo energético e, conseqüentemente, evidencia a necessidade de estratégias de previsão e planejamento para o processo de recarga, dado o caráter limitado da autonomia desses veículos. Essa limitação provoca o sentimento conhecido por “ansiedade de autonomia” que é caracterizado pela insegurança dos motoristas ficarem sem energia em seus veículos durante o trajeto, um dos principais motivos da não aceitação do público ao EV (Miri; Fotouhi; Ewin, 2021). Diante desse cenário, diversos estudos têm direcionado seus esforços para o desenvolvimento de BMS, os quais têm como objetivo monitorar continuamente as condições operacionais da bateria por meio de parâmetros críticos, tais como tensão (V), corrente elétrica (I), temperatura (T), SoC e SoH (Noreen; Fouladfar; Saeed, 2024).

Para fomentar a adoção de EVs, torna-se imprescindível investir tanto no aprimoramento de sistemas de geração de energia elétrica quanto na ampliação da infraestrutura de recarga. A utilização de fontes de energia renováveis, como a energia hidrelétrica, eólica e solar fotovoltaica, em contextos urbanos e rurais, representa uma alternativa promissora para a alimentação energética desses veículos. A viabilidade do uso dos EVs está diretamente atrelada à presença de pontos de recarga eficientes e acessíveis. Nesse sentido, é fundamental o planejamento e a implementação de soluções otimizadas de recarga, a fim de viabilizar o pleno aproveitamento do potencial tecnológico dos EVs (Onaolapo; Abe, 2024).

Nos sistemas de recarga, dois componentes se destacam como pilares tecnológicos essenciais: a fonte de energia e o próprio sistema de recarga. Esses sistemas podem ser classificados segundo duas dimensões principais: o tipo de fluxo de energia e a configuração física da instalação. Quanto ao fluxo, ele pode ser unidirecional, quando a energia flui apenas em direção ao veículo, ou bidirecional, quando há a possibilidade de devolução de energia do veículo para outros sistemas. Já quanto à instalação, essa pode ser embarcada (*on-board*), ou seja, integrada ao veículo, ou externa (*off-board*), instalada em local fixo (Onaolapo; Abe, 2024).

- Carregadores unidirecionais operam com fluxo energético unicamente da fonte para o veículo, convertendo a Corrente Alternada (CA) em Corrente Contínua (CC) dentro do próprio IEVs;
- Carregadores bidirecionais, por sua vez, permitem que o veículo reconverte a energia armazenada CC em CA, tornando-a utilizável em diferentes contextos, como:
 - *Vehicle-to-Home (V2H)*: fornecimento de energia elétrica do veículo para residências;
 - *Vehicle-to-Building (V2B)*: alimentação de edifícios a partir da bateria veicular;
 - *Vehicle-to-Grid (V2G)*: interação do veículo com a rede elétrica, contribuindo para o equilíbrio da carga;
 - *Vehicle-to-Load (V2L)*: fornecimento de energia para dispositivos ou equipamentos externos;
 - *Vehicle-to-Vehicle (V2V)*: transferência direta de energia entre veículos;
 - *V2X*: compartilhamento de energia com diversas aplicações e infraestruturas.

Adicionalmente, os carregadores classificados como *on-board* estão embutidos na arquitetura do veículo, possibilitando a recarga por meio de fontes externas comuns, enquanto os *off-board* são equipamentos estacionários, localizados em pontos estratégicos, onde os veículos se deslocam para realizar o reabastecimento energético.

Dessa forma, para acelerar a inserção dos EVs no mercado, torna-se necessário avançar em soluções que ampliem sua autonomia, seja por meio do aumento da capacidade das baterias, seja pela expansão da infraestrutura de recarga. No entanto, o alto custo associado à implementação dessas medidas representa um desafio considerável. Nesse contexto, a utilização de estimadores de consumo energético se revela uma estratégia essencial para elevar a confiança dos usuários em relação à viabilidade de seus deslocamentos. Diversas abordagens têm sido propostas na literatura com o objetivo de modelar o consumo de energia em EVs, as quais podem ser agrupadas em três categorias principais: modelos analíticos, estatísticos e computacionais (Miri; Fotouhi; Ewin, 2021).

- Modelos analíticos: Baseiam-se em fundamentos físicos para representar os principais componentes que influenciam o consumo de energia, como o rendimento do motor elétrico e a recuperação energética proporcionada pela frenagem regenerativa. Essa abordagem permite a estimativa da autonomia do veículo a partir do estado inicial da bateria e do modelo energético adotado.
- Modelos estatísticos: Utilizam dados históricos operacionais do próprio veículo, combinados com técnicas de aprendizado de máquina, para prever o consumo sob determinadas condições de condução. Apesar de apresentarem bons resultados, esses modelos são restritos às variáveis observadas durante o uso real do veículo.
- Modelos computacionais: Estendem as capacidades preditivas ao incorporar informações externas, como dados de localização geográfica GNSS (*Global Navigation Satellite System*), padrões de condução do usuário e variáveis ambientais (como condições climáticas), proporcionando uma análise mais abrangente do consumo energético.

Assim, a estimativa precisa do consumo de energia configura-se como um elemento-chave para viabilizar a adoção em larga escala dos EVs. Mesmo diante da expansão gradual da infraestrutura de suporte, que inclui estações de recarga e redução do tempo de abastecimento, os estimadores de consumo desempenham um papel estratégico ao fornecer maior previsibilidade, reforçando a confiança dos condutores na tomada de decisão durante o planejamento de suas rotas.

2.2 Deslocamento veicular

O deslocamento de veículos autônomos ou inteligentes é uma tarefa complexa que envolve múltiplos níveis de decisão e controle. Para fins de organização conceitual e técnica, essa tarefa pode ser dividida em três subtópicos principais: roteirização, planejamento de movimentos e planejamento de trajetória. Cada um desses níveis atua em uma escala distinta e com diferentes graus em relação ao ambiente e ao comportamento do veículo.

2.2.1 Roteirização

Na roteirização, conforme escopo de coleta de informações, as estratégias de orientação de rota podem ser segmentadas em estratégias de informação global e local (Chen *et al.*, 2023). As estratégias globais levam em consideração o quesito de otimização de distância. Segundo estudo realizado por Chen *et al.* (2023), a aplicação de estratégia global aprimora a eficiência do tráfego e reduz o consumo de energia. Por outro lado, a estratégia local segue o modelo baseado no custo de energia enquanto segue a trajetória global (Zhang *et al.*, 2022).

Nesse sentido, o setor de transporte tem direcionado investimentos para o desenvolvimento de ITS com o objetivo de melhorar a fluidez do tráfego e reduzir consumo de energia (Xiu *et al.*, 2023). Esses sistemas são caracterizados por terem a maioria das tarefas (navegação, tomada de decisões etc.) controladas pelos próprios veículos sem intervenção humana (Biswas; Wang, 2023). Esses sistemas combinam ciência e a tecnologia de ponta em diversas áreas como gestão de transporte, fabricação de veículos e controle de serviços (Hua *et al.*, 2022). Fortalecendo as conexões entre veículos, estradas e usuários, o ITS torna-se uma solução integrada que promove segurança, eficiência na rede e economia (He *et al.*, 2023).

2.2.2 Planejamento de movimento


O planejamento de movimento é uma etapa crucial para garantir o funcionamento confiável de veículos inteligentes. Assim, quando esses veículos precisam navegar em um ambiente, eles devem ser capazes de se deslocar em direção ao destino desejado sem colidir com obstáculos. Além disso, busca-se otimizar a rota para minimizar o consumo de combustível e, consequentemente, reduzir os custos operacionais (Paliwal, 2023).

Dado que os cenários de direção são complexos e a previsão precisa do comportamento dos veículos ao redor é difícil, os veículos inteligentes precisam se ajustar a uma grande variedade de situações dinâmicas no tráfego real. Logo, é importante a aplicação de algoritmos avançados de planejamento de movimento para auxiliarem o veículo a terem decisões razoáveis e responderem de forma ajustada em cenários de direção complexos e dinâmicos, sendo possível desse modo atingir um controle eficiente e confiável (Zhang *et al.*, 2022).

Para que seja possível o alcance da autonomia sobre o controle veicular, é necessário que o veículo possa ultrapassar a percepção, tomada de decisão e inteligência humana. Esse intuito pode ser alcançado com suporte de algoritmos de Inteligência Artificial (AI) e Aprendizado de Máquina (ML) evoluídos associados a comunicações V2X eficientes (Tong *et al.*, 2019).

A comunicação V2X parte do grupo de comunicação do veículo para o meio em que ele está inserido, conforme ilustra Figura 2.1. E cada tipo de grupo de comunicação está descrito na Tabela 2.1.

Figura 2.1 – Exemplos de tipos de comunicações V2X.



Fonte: Nanda *et al.* (2019)

Tabela 2.1 – Tipos de grupos de comunicação para com o veículo.

Comunicação	Do inglês	Tradução
V2H	<i>Vehicle-to-Human device</i>	Veículo-para-Dispositivo Humano
V2S	<i>Vehicle-to-Sensors</i>	Veículo-para-Sensores
V2I	<i>Vehicle-to-Infrastructure</i>	Veículo-para-Infraestrutura
V2R	<i>Vehicle-to-Roadside</i>	Veículo-para-Marginal da Estrada
V2V	<i>Vehicle-to-Vehicle</i>	Veículo-para-Veículo
V2X	<i>Vehicle-to-Everything</i>	Veículo-para-Tudo

Fonte: Adaptado de Nanda *et al.* (2019)

De acordo com Li *et al.* (2023), o planejamento de movimento de um veículo equipado com V2X possui relevante potencial para melhorar a segurança da condução autônoma e mitigar a incerteza do sensoriamento. Esse ponto consiste em 4 itens: 1- por meio de sensores a bordo, cada veículo obtém sua posição e velocidade; 2- compartilhamento das informações de posições e velocidades com todos os veículos por meio de um **Servidor de Borda (ES)**; 3- o ES unifica as informações e as compartilha com todos os veículos; 4- o veículo navega para atingir o objetivo evitando colisões com os outros.

2.2.3 Planejamento de trajetória

Quando em um ambiente típico, o planejamento de trajetória visa direcionar um veículo por caminhos sem colisões nos quais tanto os obstáculos estáticos quanto dinâmicos devem ser

evitados. Esse método pode ser projetado com ou sem base de modelos e incluir planejamento local ou global, além de otimização para determinados critérios. De modo geral, os modelos buscam encontrar o método mais rápido ou o caminho mais curto (Ren; Huang; Gabbar, 2022). Ou seja, o planejamento de trajetória está relacionado à velocidade e tempo em que o veículo deve passar pelos pontos.

Também são aplicados para o planejamento de trajetória métodos tradicionais que envolvem procedimentos que demandam muito tempo e recursos computacionais como **Localização e Mapeamento Simultâneo (SLAM)**, algoritmo de controle de distância, análise da curvatura da pista, histogramas de campo de vetores, entre outros (Ayawli *et al.*, 2018). Somado a isso, há a utilização de aplicações de **AI**, como redes neurais, lógica *fuzzy*, e algoritmos genéticos, as quais levam a uma alta precisão (Biswas; Wang, 2023). O **Aprendizado Profundo (DL)**, aplicado ao planejamento de trajetória, aplica três principais ferramentas: **Aprendizagem por Reforço Profundo (DRL)**, **Rede Neural Convolucional (CNN)** e **Memória de Longo Curto Prazo (LSTM)**. A **CNN** é frequentemente empregada em tarefas de classificação devido à sua habilidade de extrair características de imagens. De maneira mais específica, a **CNN** é aplicada para extrair características que serão utilizadas em uma sub tarefa de planejamento de trajetória. **LSTM** é um tipo de rede que processa dados de imagem e é comumente usada para dados de imagem sequenciais. Sendo uma das principais ferramentas de **DL**, o **DRL** pode alcançar resultados extraordinários sem a necessidade de depender de conjuntos de dados rotulados. Recentemente, o **DRL** tem sido amplamente requisitado em aplicações de planejamento de trajetória para variados tipos de veículos não tripulados nos mais variados ambientes. Em especial ele é aplicado em problemas de planejamento de trajetória em ambientes com obstáculos congestionados e terrenos acidentados (Ren; Huang; Gabbar, 2022).

Frente à evolução de tecnologias avançadas e sensores, os veículos autônomos podem elevar o desempenho e a capacidade do sistema de transporte contemporâneo. Devido à modelagem espacial mista de rede viária e à dinâmica temporal não linear, para veículos autônomos a previsão de tráfego é um campo desafiador e estimulante (Mishra *et al.*, 2023).

2.3 Eficiência energética

A estimativa precisa do consumo energético constitui um elemento central para o desenvolvimento de estratégias eficientes de roteamento e para a previsão confiável da autonomia em **EVs**. Essa tarefa, contudo, torna-se particularmente complexa em contextos urbanos, nos quais predominam variáveis dinâmicas e imprevisíveis — como congestionamentos, variações no fluxo de tráfego e a presença de sistemas de sinalização — que impactam diretamente o desempenho energético dos veículos (Thibault; Nunzio; Sciarretta, 2018).

O avanço tecnológico aplicado aos **IEVs** tem se destacado não apenas pela contribuição à redução de acidentes de trânsito e à melhoria da fluidez no tráfego, mas também por seu potencial em promover a conservação de energia e a diminuição das emissões de gases de efeito estufa (Min *et al.*, 2023). De acordo com Al-Wreikat, Serrano e Sodre (2021), a eficiência energética veicular está diretamente relacionada a diversos fatores, como as condições de condução, a eficiência dos sistemas embarcados e as estratégias adotadas para o gerenciamento de energia. Nesse sentido, diferentes estudos propuseram tecnologias voltadas à mudança no comportamento dos condutores como forma de aumentar a eficiência energética. Entre essas abordagens, destacam-se o uso de alertas audiovisuais (Hari *et al.*, 2012), sistemas de avaliação de desempenho baseados em avisos ao motorista (Magana; Munoz-Organero, 2015) e a recomendação de velocidades ideais para determinados trajetos (Li; Dridi; El-Moudni, 2014). No entanto, tais estratégias dependem da aceitação e da adesão voluntária dos condutores, o que

pode limitar sua efetividade na prática. Por outro lado, veículos com condução automatizada apresentam vantagem nesse aspecto, pois executam com precisão os comandos programados — como aceleração, frenagem e velocidade ideal — além de seguir a rota planejada de forma consistente, o que contribui diretamente para a otimização do consumo energético (Min *et al.*, 2023).

A eficiência energética em veículos autônomos também se relaciona à etapa de roteirização, sendo frequentemente analisada com o apoio de algoritmos de busca. Um exemplo representativo dessa abordagem é apresentado por Zhang *et al.* (2023), que utilizam o algoritmo A*, amplamente reconhecido por sua eficiência na identificação de caminhos ideais entre dois pontos em estruturas baseadas em grafos. Devido à sua habilidade em minimizar trajetos com base em funções de custo, o A* tem sido amplamente adotado em aplicações de roteirização energética, especialmente no contexto de veículos autônomos terrestres.

Para além da análise de características estáticas do ambiente, a antecipação de variáveis dinâmicas, como o comportamento do tráfego em tempo real, é igualmente fundamental para garantir uma condução eficiente. Antecipar os deslocamentos dos veículos ao redor durante o planejamento de rota possibilita a prevenção de variações abruptas de velocidade, melhorando tanto a segurança quanto o desempenho energético do trajeto (Pan *et al.*, 2022).

Nesse contexto, o uso do **Aprendizado por Reforço (RL)** tem se consolidado como uma estratégia eficaz. Essa técnica de aprendizado de máquina consiste na interação contínua de um agente com o ambiente, com o objetivo de maximizar uma função de recompensa por meio da adaptação progressiva do comportamento de condução. Como exemplo, Min *et al.* (2023) aplicaram o RL ao desenvolvimento de um sistema de condução eficiente, no qual são utilizados modelos baseados em redes LSTM para prever as trajetórias de veículos próximos em horizontes de tempo médio e longo. Essas previsões são integradas a um modelo de direção econômica que incorpora múltiplas restrições operacionais. Em seguida, o sistema é otimizado pelo aprendizado por reforço *Proximal Policy Optimization* (PPO) (Schulman *et al.*, 2017) para obter os parâmetros ótimos.

O estudo desenvolvido por Morlock *et al.* (2019) ilustra uma aplicação prática conhecida como **Previsão de Demanda de Energia (EDP)**, que combina dados do próprio veículo — como velocidade, aceleração e histórico de consumo energético — com informações preditivas extraídas de bancos de dados sobre tráfego e rotas planejadas. A antecipação dessas informações permite um controle mais preciso da velocidade, reduzindo a necessidade de frenagens e trocas de marcha desnecessárias, o que resulta em significativa economia de energia (Wang; Park; Han, 2022).

Nos últimos anos, avanços significativos em tecnologias de baterias e em sistemas de gerenciamento energético têm contribuído para mitigar uma das principais barreiras à adoção de EVs: a limitação de autonomia. Tecnologias como as baterias de fosfato de ferro-lítio (LFP) passaram a oferecer maior durabilidade, alcançando milhares de ciclos de carga e descarga, o que, na prática, pode representar uma vida útil superior a 1 milhão de quilômetros, dependendo das condições de uso. Paralelamente, melhorias na densidade energética e na capacidade de recarga rápida — com sistemas que permitem recargas substanciais em cerca de 30 minutos em estações de alta potência — têm ampliado a viabilidade operacional desses veículos. Além dos avanços em hardware, destaca-se a evolução dos sistemas de gerenciamento energético baseados em software, que têm permitido ganhos de autonomia por meio de atualizações remotas (*over-the-air*), sem alterações físicas no veículo. Estudos recentes apontam que essas melhorias combinadas — tanto em baterias quanto em software — têm reduzido progressivamente a “ansiedade de autonomia”, reforçando a importância de modelos precisos de estimativa de con-

sumo energético para apoiar a tomada de decisão dos condutores e maximizar o uso eficiente da energia disponível (International Energy Agency, 2024; Zhang *et al.*, 2023; Liu *et al.*, 2024).

2.4 Gêmeos digitais

O conceito de DT tem se destacado em diferentes áreas da engenharia e da tecnologia, sobretudo no contexto da Indústria 4.0, de sistemas ciberfísicos e de veículos inteligentes. Um DT consiste em uma representação virtual fiel de um objeto ou sistema físico, capaz de reproduzir, em tempo real, seu estado, comportamento e desempenho. Diferentemente de modelos digitais convencionais, o DT estabelece uma comunicação bidirecional com o sistema físico, na qual dados operacionais são continuamente enviados ao ambiente virtual para análise e simulação, enquanto os resultados obtidos retornam ao sistema real, possibilitando ajustes e intervenções baseadas em dados. Essa interação contínua entre os domínios físico e virtual é essencial para manter o sincronismo entre o DT e seu correspondente real, permitindo adaptações dinâmicas, otimização de desempenho e suporte à tomada de decisão em tempo real (Zhang *et al.*, 2021). A Figura 2.2 ilustra a estrutura de um ambiente de DT e seus principais componentes (Bhatti; Mohan; Raja Singh, 2021). Nela, é ilustrado o ecossistema de um DT como a integração contínua entre o espaço físico — representado por uma “máquina inteligente” instrumentada com sensores, monitoramento, computação de borda, realidade aumentada e mecanismos de atuação — e o espaço virtual, no qual o DT é construído a partir de modelos (por exemplo, *3D Computer-Aided Design* - CAD/3D - e modelagem do sistema), técnicas de AI, análises de dados e simulações preditivas. Essa integração é viabilizada por uma camada de interconexão baseada em nuvem, responsável por coletar e transmitir dados operacionais do sistema real ao ambiente digital, onde são processados para gerar diagnósticos, previsões e otimizações. Em seguida, os resultados retornam ao espaço físico como recomendações ou comandos, fechando um ciclo bidirecional de dados e resultados que permite ajustes dinâmicos, melhoria de desempenho e suporte à tomada de decisão em tempo real.

Figura 2.2 – Componentes e características do ecossistema de DTs.



Fonte: Bhatti, Mohan e Raja Singh (2021)

De acordo com a classificação proposta por Kritzinger *et al.* (2018), a distinção entre as diferentes representações virtuais de sistemas físicos fundamenta-se estritamente no nível de integração e automação do fluxo de dados entre as instâncias física e digital. As três categorias principais são definidas da seguinte forma:

1. **Modelo Digital (*Digital Model*):** Consiste na representação digital de um objeto físico (existente ou planejado) que não utiliza qualquer forma de troca automatizada de dados entre as instâncias. Nesse nível, o fluxo de informações é estritamente manual, o que implica que alterações no estado do objeto físico não possuem efeito direto no objeto digital e vice-versa.
2. **Sombra Digital (*Digital Shadow*):** Caracteriza-se pela existência de um fluxo de dados automatizado e unidirecional do objeto físico para o objeto digital. Nesta configuração, qualquer mudança no estado do sistema real é refletida automaticamente em sua representação virtual, mas o objeto digital não é capaz de induzir mudanças ou comandos de volta ao sistema físico.
3. **Gêmeo Digital (DT):** Representa o nível máximo de integração, no qual o fluxo de dados entre o objeto físico e o objeto digital é totalmente automatizado em ambas as direções. Nessa arquitetura, o objeto digital pode atuar como uma instância de controle sobre o sistema físico, de modo que uma alteração no estado do objeto virtual leva diretamente a uma mudança correspondente no objeto físico e vice-versa.

Essa distinção técnica é crucial para a pesquisa acadêmica, uma vez que as fontes indicam que, embora o termo DT seja amplamente difundido, a maioria das implementações descritas na literatura científica ainda se limita aos níveis de Modelo ou Sombra Digital.

A expansão da IoT tem reforçado o papel dos DTs, ao viabilizar a geração contínua de grandes volumes de dados em tempo real (Bhatti; Mohan; Raja Singh, 2021). Essa integração estabelece uma relação sinérgica, na qual os dados do ambiente físico alimentam o modelo digital, possibilitando uma compreensão dinâmica e preditiva do sistema.

Os DTs têm promovido transformações significativas tanto na indústria quanto no setor de mobilidade, ao viabilizarem uma gestão mais eficiente e decisões baseadas em dados. No contexto industrial, essa tecnologia tem sido aplicada com destaque na manutenção preditiva, permitindo o monitoramento constante de máquinas e equipamentos para antecipar falhas, reduzir custos e aumentar a produtividade (Piromalis; Kantaros, 2022). Além disso, contribui para a otimização de processos produtivos, como observado na indústria siderúrgica, onde sua aplicação tem resultado em maior eficiência operacional e redução de desperdícios (Cohen; Pilati; Faccio, 2021). Outra aplicação relevante está no mapeamento detalhado das etapas de produção, abrangendo desde ações de manutenção preventiva até o gerenciamento da capacidade produtiva, assegurando uma operação mais inteligente e integrada (Piromalis; Kantaros, 2022).

No campo da mobilidade, os DTs têm sido aplicados em diversas frentes para aprimorar a gestão de sistemas urbanos. Um exemplo notável é o caso de Barcelona, onde essa tecnologia é utilizada para coordenar semáforos inteligentes e monitorar o fluxo de veículos, contribuindo para a otimização da circulação viária e a redução de congestionamentos (Piromalis; Kantaros, 2022). Em Buenos Aires, os DTs auxiliam no planejamento do transporte coletivo, permitindo prever a demanda de passageiros e ajustar as rotas de ônibus de forma mais eficiente, elevando a qualidade do serviço prestado à população (Piromalis; Kantaros, 2022). No setor automotivo, a aplicação dos DTs tem impulsionado avanços tanto na autonomia energética dos EVs quanto no

desenvolvimento de tecnologias para veículos autônomos (Bhatti; Mohan; Raja Singh, 2021). Esses exemplos evidenciam o potencial transformador dos DTs, que têm promovido ganhos expressivos em eficiência, sustentabilidade e inovação em diferentes áreas (Piromalis; Kantaros, 2022).

Nesse contexto, o tema da roteirização ganha relevância por estar diretamente associado às estratégias de definição e otimização de rotas. Como reflexo disso, o setor de transportes tem direcionado esforços para o aprimoramento de ITS, que visam melhorar a fluidez do tráfego e reduzir o consumo energético por meio do uso de tecnologias avançadas (Xiu *et al.*, 2023).

A importância do monitoramento de dados em tempo real para EVs é evidenciada por Roy *et al.* (2022), que apresentam uma abordagem baseada na coleta de informações operacionais durante o uso de frotas de ônibus elétricos. O estudo demonstra que o acompanhamento contínuo de variáveis críticas, como velocidade, carga e consumo, é fundamental para modelar com maior precisão o comportamento energético desses veículos. A combinação de dados históricos com dados em tempo real torna a previsão de consumo mais confiável, contribuindo para aumentar a segurança e a confiança dos condutores em relação à autonomia energética dos EVs.

De forma geral, os benefícios do uso de DTs são amplamente reconhecidos. Sua integração com estratégias de eficiência energética possibilita o acompanhamento contínuo de parâmetros operacionais e a antecipação de comportamentos em diferentes cenários, promovendo a otimização do desempenho dos sistemas e subsidiando decisões mais assertivas. Essa abordagem contribui não apenas para a redução do consumo de energia, mas também para a melhoria da eficiência operacional em múltiplas aplicações.

2.5 Bibliometria

O termo “bibliometria” tem origem na combinação das palavras “biblio”, que remete a livros ou produção bibliográfica, e “metria”, relacionada à medição. Trata-se de uma abordagem quantitativa que utiliza técnicas estatísticas e matemáticas para monitorar, quantificar e analisar a produção científica. Em essência, a bibliometria oferece subsídios para compreender a dinâmica de desenvolvimento e a evolução do conhecimento científico em distintas áreas do saber (Saputro *et al.*, 2023).

Na última década, esse tipo de análise tem ganhado destaque entre pesquisadores de diversas áreas. O surgimento de novas ferramentas computacionais, o uso de abordagens interdisciplinares e o acesso ampliado a grandes repositórios de dados científicos têm contribuído significativamente para a popularização da bibliometria (Khan *et al.*, 2022). Essa metodologia permite a avaliação objetiva de informações bibliográficas, possibilitando a identificação de tendências, padrões e relações dentro de um campo específico de pesquisa. Entre os aspectos comumente analisados estão o desempenho de periódicos, temas emergentes, autoria, redes de cocitação e as principais referências utilizadas (Ellili, 2023).

O software *VOSviewer* é amplamente reconhecido como uma ferramenta eficaz para a análise de palavras-chave e citações em publicações científicas. Ele permite a construção de mapas visuais ricos e interativos, oferecendo diferentes formas de visualização e organização gráfica dos dados. Esses mapas são estruturados com base em diferentes tipos de relações bibliográficas, como o acoplamento bibliográfico (medido pela quantidade de referências compartilhadas entre dois artigos), a coocorrência (frequência com que dois termos aparecem juntos nos textos analisados) e a coautoria (número de publicações realizadas em colaboração entre dois autores). A interpretação desses mapas é feita por meio das conexões entre os elementos,

sendo que o tamanho dos rótulos representa sua relevância dentro da rede. Conexões mais fortes indicam vínculos mais significativos entre os itens mapeados (You *et al.*, 2022).

Dessa forma, a análise bibliométrica torna-se uma ferramenta estratégica para pesquisadores, ao permitir a identificação de tópicos emergentes, apontar lacunas no conhecimento científico, revelar áreas promissoras para futuras investigações, entre outras possibilidades (Saputro *et al.*, 2023).

3 CONCEITOS GERAIS

Este capítulo apresenta conceitos importantes aplicados neste trabalho para o desenvolvimento da solução proposta. Inicialmente, é apresentado o algoritmo A* e, em seguida, a conceituação das fórmulas utilizadas no Artigo 2.

3.1 Algoritmo A*

O algoritmo de busca A* é um método de busca amplamente empregado na determinação de caminhos ótimos entre dois nós em um grafo. Devido à sua eficiência computacional e à capacidade de otimizar trajetórias com base em funções de custo, o A* tem sido amplamente utilizado na identificação de caminhos mínimos. Essas características tornam o algoritmo particularmente adequado ao planejamento de trajetórias energeticamente eficientes para veículos terrestres inteligentes. Para isso, o algoritmo utiliza uma fila de prioridade, responsável por selecionar iterativamente o próximo trecho a ser expandido, além de estruturas auxiliares que armazenam os predecessores das arestas, permitindo a reconstrução do caminho final ao término da busca (Zhang *et al.*, 2023).

Formalmente, o A* define duas funções de custo principais: o custo real acumulado $g(n)$, que representa o esforço efetivamente despendido desde o nó inicial até o nó n , e o custo total estimado $f(n)$, obtido pela soma entre o custo acumulado e a heurística $h(n)$, conforme:


$$f(n) = g(n) + h(n). \quad (3.1)$$

Inicialmente, apenas o nó (ou aresta) de origem é inserido na fila de prioridade, com $g(n) = 0$ e $f(n) = h(n)$. A cada iteração, o algoritmo seleciona o elemento com menor valor de $f(n)$, expandindo a busca de forma eficiente em direção ao destino (Zhang *et al.*, 2023).

Na Figura 3.1 é possível observar que o nó "Início" é representado pelo quadrado verde à esquerda. A partir dele, o algoritmo analisa todos os nós vizinhos e calcula os respectivos valores de g , h e f . Esses valores são apresentados dentro de cada célula da malha. Os nós em cinza representam posições avaliadas durante o processo de busca, enquanto as bordas destacadas indicam os nós considerados candidatos na expansão da busca. Inicialmente, o algoritmo calcula os custos dos nós adjacentes ao ponto inicial. O valor de g aumenta conforme o deslocamento ocorre a partir da origem, enquanto h diminui à medida que os nós se aproximam do destino. A soma desses valores determina f , que indica a prioridade de exploração de cada nó. À medida que a busca avança, o algoritmo passa a explorar os nós com menor valor de f , expandindo gradualmente o caminho em direção ao destino. Por fim, o algoritmo alcança o nó *Fim*, indicado pelo quadrado verde à direita, reconstruindo o caminho ótimo a partir das conexões estabelecidas entre os nós predecessores. O trajeto destacado pelas setas representa o caminho final encontrado pelo algoritmo A*, demonstrando como a combinação entre custo acumulado e heurística permite conduzir a busca de maneira eficiente em direção ao objetivo (Choset *et al.*, 2005).

No contexto deste trabalho, a função heurística $h(n)$ é estendida para incorporar não apenas informações geométricas, como o comprimento das vias, mas também características topográficas, em especial a variação de elevação (Guzzella; Sciarretta, 2013). Essa adaptação possibilita uma estimativa mais realista do custo energético associado ao deslocamento veicular, preservando as propriedades de completude e eficiência do algoritmo A* e adequando-o ao objetivo de otimização energética. Dessa forma, a rota resultante não corresponde necessariamente ao menor caminho em termos de distância física, mas à trajetória que minimiza o consumo de energia.

Figura 3.1 – Ilustração funcionamento algoritmo A*.



Fonte: Adaptado de Choset *et al.* (2005)

Em síntese, o algoritmo A* implementado realiza uma busca guiada por custo energético, integrando distância e topografia. Essa abordagem permite a representação dos principais efeitos físicos que influenciam o consumo de energia durante o deslocamento de IEV.

3.2 Formulação matemática para simulação de desempenho, consumo energético e autonomia em veículos elétricos

Esta seção utiliza (Larminie; Lowry, 2012) como base conceitual para formulação matemática, para simulação de desempenho, consumo energético e autonomia em VEs.


O ponto inicial na modelagem do desempenho veicular consiste na formulação da equação que descreve o esforço de tração requerido. Esse esforço corresponde à força responsável por promover o deslocamento longitudinal do veículo e superar as forças resistivas, sendo transmitida ao pavimento por meio das rodas motrizes.

Considere-se um veículo de massa m , movendo-se com velocidade v , ao longo de uma via inclinada com ângulo ψ , conforme ilustrado na Figura 3.2. Nessa condição, o esforço de tração deve ser suficiente para atender aos seguintes requisitos:

- vencer a resistência ao rolamento;
- superar o arrasto aerodinâmico;
- compensar a componente do peso do veículo atuante no sentido oposto ao movimento em rampas;
- fornecer a força necessária para a aceleração do veículo, quando a velocidade não é constante.

Cada aspecto é conceituado separadamente a seguir.

Figura 3.2 – Forças atuantes no veículo em uma rampa .



Fonte: Larminie e Lowry (2012)

3.2.1 Força de Resistência ao Rolamento F_{rr}

A resistência ao rolamento decorre principalmente das perdas por histerese nos pneus, com contribuições adicionais do atrito nos mancais e no sistema de engrenagens. Essa força apresenta comportamento aproximadamente constante e é pouco influenciada pela velocidade do veículo, sendo proporcional ao seu peso.

A resistência ao rolamento pode ser expressa por:

$$F_{rr} = \mu_{rr} mg, \quad (3.2)$$

em que g é a aceleração da gravidade e μ_{rr} é o coeficiente de resistência ao rolamento, dependente principalmente do tipo e da pressão dos pneus. Valores típicos de μ_{rr} situam-se em torno de 0,015 para pneus radiais convencionais, podendo atingir aproximadamente 0,005 em pneus projetados especificamente para EVs. O valor desse coeficiente pode ser estimado experimentalmente por meio da medição da força necessária para rebocar o veículo a baixa velocidade e regime constante.

3.2.2 Arrasto Aerodinâmico F_{ad}

O arrasto aerodinâmico resulta da interação do veículo com o ar durante o deslocamento e depende de fatores como área frontal, formato da carroceria e presença de saliências externas. Essa força cresce com o quadrado da velocidade e pode ser expressa por:

$$F_{ad} = \frac{1}{2} \rho A_f C_d v^2, \quad (3.3)$$

em que ρ é a densidade do ar, A_f é a área frontal do veículo, C_d é o coeficiente de arrasto aerodinâmico.

O coeficiente C_d está diretamente relacionado ao projeto aerodinâmico do veículo, assumindo valores típicos em torno de 0,3 para automóveis de passeio, podendo atingir valores inferiores em EVs devido à maior flexibilidade construtiva e menor necessidade de sistemas de arrefecimento. Em contrapartida, veículos como motocicletas e ônibus apresentam valores sig-

nificativamente maiores. A densidade do ar varia com as condições ambientais, sendo comum adotar o valor aproximado de $1,25 \text{ kg} \cdot \text{m}^{-3}$ para aplicações gerais, resultando em F_{ad} expresso em Newtons ao utilizar unidades do Sistema Internacional (SI).

3.2.3 Força de Subida de Rampa F_{hc}

A força associada ao deslocamento do veículo em uma rampa corresponde à componente do peso atuante ao longo da inclinação da via. Essa parcela pode ser obtida diretamente pela decomposição da força gravitacional, sendo expressa por:

$$F_{hc} = mg \sin \psi, \quad (3.4)$$

em que ψ representa o ângulo de inclinação da rampa.

3.2.4 Força de Aceleração F_{la}

Quando a velocidade do veículo varia ao longo do tempo, é porque há a aplicação de uma força adicional para promover a aceleração, a , do veículo. Essa força está associada à aceleração linear do veículo e é descrita pela terceira lei de Newton, conforme:

$$F_{la} = ma, \quad (3.5)$$

3.2.5 Esforço de Tração Total F_{te}

O esforço de tração total é a soma de todas essas forças:

$$F_{te} = F_{rr} + F_{ad} + F_{hc} + F_{la} \quad (3.6)$$

A partir da determinação do esforço de tração total (F_{te}), conforme apresentado em (3.6), torna-se possível estimar a potência efetivamente requerida para o deslocamento do veículo. Essa potência representa a energia que deve ser fornecida pela bateria para superar as forças resistivas atuantes — resistência ao rolamento, arrasto aerodinâmico, inclinação da via e aceleração — considerando ainda as perdas associadas ao sistema de propulsão. Dessa forma, o cálculo do esforço de tração permite quantificar a potência de saída requerida do sistema (P_{out}), estabelecendo um elo direto entre as condições dinâmicas de operação e o consumo energético do veículo (Miri; Fotouhi; Ewin, 2021).

$$P_{out} = \frac{F_{te} \cdot v}{\eta} \quad (3.7)$$

Em que:

- η : eficiência do trem de força;

Observa-se que a potência requerida é proporcional tanto à resultante das forças resistivas quanto à velocidade de deslocamento, sendo inversamente proporcional à eficiência do sistema de tração. Assim, variações no relevo, no regime de aceleração ou nas condições aerodinâmicas impactam diretamente a demanda energética (Miri; Fotouhi; Ewin, 2021). Essa formulação consolida a base matemática necessária para a modelagem do consumo em EVs, permitindo integrar, de maneira consistente, os fenômenos físicos ao modelo computacional empregado no DT.

4 METODOLOGIA

O presente trabalho foi desenvolvido seguindo a metodologia de elaboração no formato de artigos científicos, de modo a permitir a consolidação de resultados parciais e finais em publicações técnico-científicas. Nesse contexto, foram produzidos dois artigos principais.

O **Artigo 1**, intitulado “Gêmeos digitais e veículos elétricos inteligentes: estado da arte e possíveis aplicações”, apresenta uma análise bibliométrica abrangente, contemplando os eixos temáticos de veículos inteligentes, eficiência energética, planejamento de rotas e DTs. Dessa forma, esse trabalho cumpre um papel fundamental na dissertação ao delimitar o problema de pesquisa, justificar sua relevância científica e tecnológica e demonstrar a necessidade de soluções que integrem modelagem energética, roteirização e monitoramento em tempo de execução. Esse trabalho foi submetido e apresentado no XVII Simpósio Brasileiro de Automação Inteligente (SBAI 2025), realizado em julho de 2025, constituindo-se como a base conceitual e teórica para o desenvolvimento do presente estudo.

O **Artigo 2**, intitulado “Desenvolvimento de um gêmeo digital para o monitoramento de autonomia de veículos elétricos conectados”, descreve o desenvolvimento e a aplicação de um sistema baseado no conceito de DT, projetado para integrar dados provenientes de um veículo real simulado a um ambiente de simulação no SUMO. Essa abordagem tem como propósito validar, em um cenário controlado, estratégias de monitoramento e tomada de decisão pelo DT. Neste contexto, o termo DT é adotado sob uma perspectiva conceitual e funcional, alinhada ao escopo da modelagem digital proposta, na qual o sistema desenvolvido, embora não opere em malha fechada com um ativo físico real, incorpora elementos centrais desse paradigma, como a representação digital do sistema, o monitoramento contínuo de variáveis operacionais e a capacidade de suportar decisões adaptativas em tempo de execução. Dessa forma, a modelagem digital implementada é tratada como uma instância operacional de DT em ambiente simulado, justificando o uso do conceito ao longo do trabalho sem prejuízo ao rigor metodológico.

Esse segundo trabalho resolve um problema mais específico dentro do escopo geral: como reduzir a divergência entre consumo estimado e real e garantir a confiabilidade da autonomia durante a operação do veículo. Para isso, incorpora elementos físicos (forças resistivas, topografia), algoritmos de roteirização (A^*) e regras de decisão baseadas em níveis críticos de bateria, consolidando uma abordagem preditivo-prescritiva. Este trabalho foi submetido e encontra-se aprovado para apresentação na 2nd *Brazilian Conference on Robotics* (CROS) a ser realizada em abril de 2026.

Diante do contexto apresentado, os dois artigos desenvolvidos visam, de forma complementar, sustentar as frentes de trabalho relacionadas às tendências de pesquisa identificadas, ao mesmo tempo em que contribuem com uma aplicação prática alinhada às mesmas.

Parte II

Trabalhos publicados

5 ARTIGO I: GÊMEOS DIGITAIS E VEÍCULOS ELÉTRICOS INTELIGENTES: ESTADO DA ARTE E POSSÍVEIS APLICAÇÕES

Trabalho foi submetido e apresentado no XVII Simpósio Brasileiro de Automação Inteligente (SBAI 2025) realizado em julho de 2025.

Gêmeos digitais e veículos elétricos inteligentes: estado da arte e possíveis aplicações

Mateus L. do Carmo * Danilo A. de Lima * Felipe O. Silva *

* Departamento de Automática, Universidade Federal de Lavras, MG,
Brasil. (e-mails: mateus.carmo@estudante.ufla.br,
danilo.delima@ufla.br, felipe.oliveira@ufla.br)

Abstract: The growing demand for reducing greenhouse gas emissions is driving the development of intelligent electric vehicles and strategies for optimizing energy consumption. However, challenges such as limited driving range, scarce charging infrastructure, and traffic uncertainties impact the acceptance of these vehicles. In this context, this study analyzes the application of Digital Twins (DTs) as a tool for optimized route planning and real-time monitoring of energy consumption in electric vehicles. Through a bibliometric analysis, recent trends and applications that interconnect DTs, energy efficiency, and trajectory planning are identified. The analysis of the Web of Science database resulted in 4,209 documents, of which 206 included the term “digital twin” as a keyword. The construction of the bibliometric map reveals five main clusters, with the terms “electric vehicles”, “energy efficiency”, “autonomous vehicles”, and “digital twin” as central topics. The data show that, although the term “digital twin” still has a lower frequency of co-occurrence, it has emerged as a growing trend with strong potential for practical application in the analyzed subjects.

Resumo: A crescente demanda por redução de emissões de gases de efeito estufa impulsiona o desenvolvimento de veículos elétricos inteligentes e estratégias de otimização de consumo energético. No entanto, desafios como autonomia limitada, escassez de infraestrutura de recarga e incertezas no tráfego impactam a aceitação desses veículos. Nesse contexto, este estudo analisa a aplicação de Gêmeos Digitais (DTs) como ferramenta aplicável no planejamento de rotas otimizadas e monitoramento do consumo de energia em veículos elétricos. Por meio de uma análise bibliométrica, identificam-se tendências e aplicações recentes que interligam DTs, eficiência energética e planejamento de trajetórias. A análise da base Web of Science resultou em 4.209 documentos, dos quais 206 apresentaram o termo “*digital twin*” como palavra-chave. A construção do mapa bibliométrico revela cinco agrupamentos principais, sendo os termos “*electric vehicles*”, “*energy efficiency*”, “*autonomous vehicles*” e “*digital twin*” os tópicos centrais. Os dados evidenciam que, embora o termo *digital twin* ainda apresente menor frequência de coocorrência, ele tem se mostrado uma tendência emergente com grande potencial de aplicação prática nos temas analisados.

Keywords: intelligent electric vehicles; energy efficiency; route planning; digital twins.

Palavras-chaves: veículos elétricos inteligentes, eficiência energética, planejamento de rotas, gêmeos digitais.

1. INTRODUÇÃO

A crescente demanda por redução de emissão de gases do efeito estufa tem impulsionado linhas de pesquisas voltadas para a energia verde, como fontes de energia sustentáveis e não esgotáveis. Diante disso, grandes montadoras de carros têm direcionado suas pesquisas e desenvolvimentos para os veículos verdes (elétricos, híbridos ou a gás natural) (Bhatti et al., 2021). Nesses veículos, principalmente nos elétricos, o uso eficiente da energia armazenada com previsibilidade é fundamental para a conclusão de um trajeto. Essa eficiência pode estar relacionada a diversos fatores, tais como regras ou condições do tráfego, limites físicos do veículo, condição da estrada, assim como o comportamento humano do condutor durante a direção. No que se refere ao fator humano, a tecnologia e

engenharia estudam há mais de uma década os veículos elétricos inteligentes. Esses veículos, dependendo do seu nível de automação (SAE, 2021), são capazes de tomar decisões independentes e executar ações inteligentes sem a necessidade de supervisão humana, alinhando-se, desse modo, ao padrão de condução (Wang et al., 2022a). Além disso, eles possuem grande similaridade em termos de sistemas eletrônicos e sensores, i.e., tanto os veículos elétricos quanto os elétricos inteligentes utilizam sistema de propulsão elétrico, o que, por sua vez, é o fator que possui relação direta à questão de autonomia energética (Abro et al., 2023).

A autonomia dos veículos elétricos é uma limitação que tem impactado negativamente sua aceitação entre os usuários. Esse ponto torna-se ainda mais crítico em países com dimensões continentais, como o Brasil, especialmente

devido a baixa disponibilidade de pontos de recarga, longos tempos de carregamento e inadequação da infraestrutura de apoio (Morlock et al., 2019). Ou seja, para a utilização desses veículos, faz-se necessária uma previsibilidade de distância a ser percorrida, informações da condição de tráfego, entre outros, para que seja possível estimar o local de recarga do veículo e assim chegar ao destino. Isso, sem considerar a disponibilidade do local de recarga no momento de sua utilização e consequente fila de espera. Como alternativa para solucionar essas questões, um planejamento de rotas otimizado pode ser aplicado a fim de estimar se o destino é alcançável, otimizar rotas com base no tempo e energia, gerenciar a frota de veículos elétricos e planejar a infraestrutura. Em (Thorgeirsson et al., 2021) esse conceito é aplicado na Previsão de Demanda de Energia (EDP, do inglês *Energy Demand Prediction*) que, além de fornecer a autonomia restante de condução, engloba esse planejamento de rota otimizado. Ainda assim, existem outras situações, como a condição real do trânsito, onde pode ocorrer a necessidade de geração de um novo trajeto e, desse modo, comprometer a autonomia restante do veículo. Isso colabora para a ocorrência do sentimento “ansiedade de autonomia”, que é tido como a insegurança do condutor em ficar sem energia suficiente para chegar ao destino, um dos principais motivos da não aceitação do público ao veículo elétrico (VE) (Miri et al., 2021).

Frente a esse contexto, surge como alternativa o gêmeo digital (DT, do inglês *Digital Twin*). Essa tecnologia ganhou mais notoriedade com o surgimento da indústria 4.0, onde se observam indústrias cada vez mais focadas em buscar tecnologias e tendências facilitadoras que representem melhoria contínua em termos de eficiência, segurança, produtividade, dentre outros (Bhatti et al., 2021). Nele, é feita uma representação digital de um objeto ou entidade no qual, por meio de uma comunicação bidirecional entre o meio físico e o digital, são realizados ajustes em tempo real e transmitidas informações a serem implementadas ao objeto para a tomada de decisões. Assim, sensores são utilizados para coletar informações relacionadas ao objeto e, posteriormente, enviadas ao DT para o processamento dos dados (Zhang et al., 2021). Isso permite uma série de novas aplicações no contexto dos veículos elétricos, como a apresentada em (Rajesh et al., 2024), onde o aumento da capacidade de armazenamento de energia das baterias foi estudado.

Diante da alta precisão individual proporcionada pelos Gêmeos Digitais (DTs), destaca-se como aspecto fundamental a capacidade de monitorar em tempo real tanto as condições específicas de cada veículo quanto os fatores externos, como o tráfego. Esse recurso pode ser considerado um ponto de partida para a implementação de sistemas de transporte e cidades inteligentes. Nesse contexto, Hui et al. (2021) propõem um esquema de planejamento de rotas baseado em DTs, voltado para a gestão eficiente do tráfego. Os resultados da simulação indicam que, ao considerar as necessidades individuais dos usuários, o modelo proposto proporciona maior utilidade e uma experiência de condução superior em comparação aos métodos convencionais, que geralmente se baseiam apenas em critérios como menor distância ou menor tempo de viagem.

Partindo da premissa que ainda são poucos os trabalhos que interligam veículos elétricos inteligentes e DTs, este

artigo tem como objetivo realizar uma revisão bibliométrica, verificando tendências de pesquisas que englobam veículos elétricos inteligentes, planejamento de rotas e eficiência energética, e suas aplicações com DT. Este trabalho contribui na apresentação de uma revisão da literatura atualizada dos tópicos abordados, fornece uma análise da revisão do estado da arte, trazendo os temas que foram desenvolvidos e ilustra quais as linhas de pesquisa estão aplicando a tecnologia de gêmeo digital e veículos elétricos inteligentes.

O restante deste estudo está organizado da seguinte forma: a Seção 2 realiza uma revisão de literatura sobre veículos elétricos inteligentes, eficiência energética, modelagem do consumo e energia, gêmeo digital e bibliometria. A Seção 3 descreve a metodologia utilizada, com seus resultados discutidos na Seção 4. As aplicações e as tendências para trabalhos futuros são demonstradas na Seção 5 e as considerações finais na Seção 6.

2. CONCEITOS GERAIS

2.1 Veículos Elétricos Inteligentes

Partindo do pressuposto de que existem vários termos utilizados para designar veículos inteligentes, a SAE (*Society of Automotive Engineers*) normatizou e definiu o conceito de sistema automatizado de condução (ADS, do inglês *Automated Driving System*) (SAE, 2021). Nele é fornecido uma taxonomia classificando o ADS em 6 níveis, onde o nível 0 representa nenhuma automação e o 5 total automação.

Dirigir um veículo em vias públicas é uma tarefa complexa devido à constante interação com elementos imprevisíveis, como condições da via, tráfego, condições climáticas, outros veículos, pedestres, ciclistas e animais (Krysiuk, 2021). Quando se trata de Veículo Elétrico (VE), essa complexidade interfere no consumo de energia do veículo e assim surge uma demanda pela previsão do recarregamento de energia devido à limitação de autonomia do mesmo. Desse modo, alguns estudos focam na criação e desenvolvimento de um sistema de gerenciamento de baterias (BMS, do inglês *Battery Management System*) que monitora as condições da bateria e parâmetros críticos como Tensão (V), Corrente (I), Temperatura (T), Estado de Carga (SOC) e Estado de Saúde (SOH) (Mumtaz Noreen et al., 2024).

Desse modo, para estimular a adoção de veículos elétricos, é essencial investir proporcionalmente no desenvolvimento de sistemas de geração elétrica e na expansão da infraestrutura de recarga. A presença de Fontes de Energia Renovável (FER), energia hidrelétrica, eólica e fotovoltaica (FV), tanto em áreas urbanas quanto rurais, oferece uma solução viável para o abastecimento desses veículos. O acesso aos VEs está diretamente relacionado à disponibilidade de pontos de recarga eficientes. Assim, é crucial planejar e implementar sistemas de recarga otimizados para garantir que o potencial dos VEs seja plenamente aproveitado (Onaolapo and Abe, 2024).

Nos sistemas de recarga, os dois elementos fundamentais da tecnologia dos VEs são a fonte de energia e o sistema de recarga. Esses sistemas podem ser classificados de forma abrangente conforme o fluxo de energia e a estrutura da

instalação. O fluxo de energia pode ocorrer de maneira unidirecional ou bidirecional, enquanto a instalação pode ser integrada ao próprio veículo (*on-board*) ou externa a ele (*off-board*) (Onalapo and Abe, 2024). Nesse sentido, carregadores unidirecionais são de fluxo único que enviam corrente alternada (CA) para o VE, onde é convertida em corrente contínua (CC). Carregadores bidirecionais, por sua vez, permitem que o VE converta a CC da bateria de volta em CA para diferentes aplicações, como:

- Vehicle-to-Home (V2H): fornecimento de energia do veículo para a residência;
- Vehicle-to-Building (V2B): fornecimento de energia do veículo para edifícios;
- Vehicle-to-Grid (V2G): integração do veículo à rede elétrica;
- Vehicle-to-Load (V2L): fornecimento de energia do veículo para cargas externas;
- Vehicle-to-Vehicle (V2V): transferência de energia entre veículos;
- Vehicle-to-Everything (V2X): fornecimento de energia para múltiplas aplicações.

Além disso, um carregador *on-board* é aquele integrado ao próprio VE, enquanto um *off-board* é instalado em um local fixo, necessitando deslocar-se para o reabastecimento.

Com isso, para acelerar a taxa de entrada dos VEs no mercado, deve-se evoluir no aumento de autonomia do veículo, elevando a capacidade da bateria e/ou o número de estações de recarga. Porém, devido ao elevado custo de implementação dessas alternativas, a aplicação de estimadores de consumo de energia torna-se crucial a fim de aumentar a confiança dos condutores. Diversos estimadores já foram propostos para modelar o consumo de energia em VE e são classificados em modelos analíticos, computacionais e estatísticos (Miri et al., 2021). Na abordagem analítica, os componentes do consumo energético são modelados, como a eficiência do motor e a recuperação de energia pela frenagem regenerativa, com base na física, permitindo estimar a autonomia do veículo considerando o estado inicial da bateria e o modelo energético. A abordagem estatística considera dados históricos e algoritmos de aprendizado de máquina para prever o consumo de energia em determinadas condições de condução, mas se limita aos dados operacionais do próprio veículo. Já os métodos computacionais incorporam informações externas, como a solução de localização do Sistema de Navegação Global via Satélite (GNSS), padrões de condução e condições climáticas, ampliando a análise além dos modelos analíticos tradicionais.

Portanto, a estimativa de consumo torna-se fundamental para avançar em larga escala a utilização desses veículos. Frente a isso, ainda que haja expansão da estrutura de suporte aos VEs (i.e. pontos de recarga, tempo de reabastecimento, etc.), os estimadores são ferramentas importantes que contribuem para a confiança e a tomada de decisão dos condutores em seus respectivos trajetos.

2.2 Eficiência Energética

O cálculo do consumo de energia é fundamental para as estratégias de roteirização (caracterizada por considerar a otimização de distância e custo de energia) e para a

eficiência na previsão de autonomia em veículos elétricos. No entanto, essa previsão é especialmente desafiadora em ambientes urbanos onde fatores incertos, como congestionamentos e sinalização, são mais comuns (Thibault et al., 2018).

O avanço da tecnologia dos veículos elétricos inteligentes não somente contribui para a diminuição de acidentes rodoviários e fluidez do tráfego, mas também apresenta uma considerável possibilidade de conservação de energia e redução de emissão de gases de efeito estufa (Min et al., 2023). Segundo Al-Wreikat et al. (2021), diversos fatores estão relacionados à eficiência energética dos veículos, como condições de condução, eficiência de seus mecanismos e estratégias de gerenciamento de energia. Diversos estudos se dedicaram ao aprimoramento da eficiência energética veicular ao alterar os hábitos e modos de condução dos condutores, tais como alertas audiovisuais (Hari et al., 2012), avaliação do desempenho de direção por meio de avisos (Magana and Munoz-Organero, 2015) e sugestão de velocidade ideal (Li et al., 2014). Contudo, na prática, alguns condutores têm a opção de não seguirem o comportamento indicado por esses métodos, mitigando a sua eficácia.

Relacionada também com a roteirização, a eficiência energética é estudada com o suporte de um algoritmo de busca. Um exemplo dessa relação é apresentado em (Zhang et al., 2023), onde é utilizado o algoritmo A* na determinação do caminho mais curto e de forma eficiente entre dois pontos em um gráfico. O A* e suas derivações são amplamente aplicados na roteirização energeticamente eficiente para veículos terrestres inteligentes devido à sua capacidade de otimizar trajetórias com base em funções de custo.

Os primeiros estudos sobre a estimativa do consumo de energia em veículos elétricos evidenciaram a complexidade do problema. Li et al. (2016) identificaram os principais fatores que influenciam esse consumo, destacando a topografia e o uso do sistema de climatização (HVAC) como variáveis determinantes. No entanto, a pesquisa considerou que dispositivos auxiliares, como faróis, estiveram sempre desligados, o que pode representar uma parcela significativa do consumo energético e indicar a necessidade de análises mais abrangentes.

Dessa forma, torna-se necessário um estudo mais aprofundado que leve em consideração múltiplos fatores (Roy et al., 2022), incluindo externos, como condições climáticas e de tráfego, internos, como temperatura e carga de passageiros, e parâmetros comportamentais do motorista, como acelerações bruscas e frenagens intensas.

2.3 Gêmeo Digital

O conceito de DT refere-se a uma representação digital de um objeto ou entidade física. O DT não apenas descreve o objeto, mas mantém também uma comunicação bidirecional com ele. Por um lado, o estado do objeto físico é transmitido ao DT, em um ambiente virtual, para simulações e ajustes em tempo real. De outro lado, a simulação digital e os resultados dos ajustes são reenviados ao objeto físico, onde podem ser implementados para orientar decisões. Essa interação de dados é fundamental para manter o sincronismo entre o DT e o objeto real (Zhang et al., 2021).

Desse modo, o objeto físico pode adaptar sua performance ou atividade em tempo real conforme o retorno gerado pelo DT.

O crescimento exponencial da Internet das Coisas (IoT, do inglês *Internet of Things*) trouxe ao DT ainda mais força, pois ela gera uma quantidade enorme de dados em tempo real, enquanto o DT analisa exclusivamente esses dados do mundo real de forma simultânea (Bhatti et al., 2021). Desse modo, a relação entre DT e IoT demonstra-se como uma estrutura mutuamente vantajosa, pois permite uma evolução prognóstica do ambiente em que estão inseridos.

Os gêmeos digitais vêm revolucionando tanto a indústria quanto a mobilidade, proporcionando otimização operacional e tomada de decisões mais precisas. Na indústria, essa tecnologia tem sido aplicada na manutenção preditiva, permitindo o monitoramento contínuo de máquinas e equipamentos para prevenir falhas antes que ocorram, reduzindo custos e melhorando a eficiência operacional (Piromalis and Kantaros, 2022). Também auxilia na otimização de processos, como na indústria siderúrgica, melhorando a eficiência produtiva e reduzindo desperdícios (Cohen et al., 2021). Outra aplicação relevante é no mapeamento e aprimoramento de todas as etapas de produção, desde a manutenção preventiva até o gerenciamento da capacidade produtiva, garantindo uma operação mais eficiente (Piromalis and Kantaros, 2022).

No contexto da mobilidade, essa tecnologia tem sido usada na gestão de tráfego urbano, como em Barcelona, onde semáforos inteligentes e análise de fluxo de veículos otimizam a circulação e reduzem congestionamentos. Em Buenos Aires, os gêmeos digitais são aplicados no planejamento do transporte público, ajudando a prever a demanda e otimizar rotas de ônibus para melhorar a experiência dos passageiros (Piromalis and Kantaros, 2022). Já na indústria automotiva, essa tecnologia está impulsionando a evolução da autonomia energética em veículos elétricos e o desenvolvimento de veículos autônomos (Bhatti et al., 2021). Essas aplicações demonstram o potencial transformador dos gêmeos digitais, promovendo maior eficiência, sustentabilidade e inovação nos mais diversos setores (Piromalis and Kantaros, 2022). Nesse sentido, o tema roteirização também ganha notoriedade por tratar das estratégias de orientação de rota. Com isso, o setor de transporte tem direcionado investimentos para o desenvolvimento de Sistemas de Transporte Inteligentes (STI) com o objetivo de melhorar a fluidez do tráfego e reduzir o consumo de energia (Xiu et al., 2023).

Em (Roy et al., 2022), é apresentada uma abordagem de coleta de dados durante viagens em uma frota de ônibus elétricos. Ele demonstra, assim, a relevância do monitoramento de atributos em tempo real para a modelagem de consumo de energia em VEs. Isso reforça que a disponibilidade histórica de dados é importante e que, somada ao monitoramento em tempo real, é possível atingir maior assertividade no monitoramento e projeção do consumo energético em veículos elétricos. Ou seja, a aplicação do DT contribui para a evolução da confiança do condutor em seu VE no quesito autonomia energética.

2.4 Bibliometria

O termo “bibliometria” deriva das palavras “biblio” (relacionada a livros ou bibliografia) e “métrica” (associada à medição). É uma abordagem quantitativa baseada em métodos estatísticos e matemáticos para rastrear, medir e realizar análise da produção científica. Ou seja, a bibliometria ajuda na compreensão da dinâmica e evolução do conhecimento científico em diferentes áreas de estudo (Saputro et al., 2023).

Nos últimos dez anos, as análises bibliométricas têm recebido uma atenção crescente entre os pesquisadores. A análise bibliométrica possibilita uma avaliação objetiva dos dados e detecta diversas tendências em um campo de pesquisa determinado, abrangendo o desempenho de periódicos, temas, autoria, cocitações e referencial (Ellili, 2023).

O programa *VOSviewer* é utilizado amplamente como uma ferramenta de análise de palavras-chave e citações em artigos científicos. Ele oferece funcionalidades eficientes, diferentes efeitos de visualização e ricos *layouts* por meio dos mapas criados. A base de exploração desses mapas é estruturada por meio das relações de citação: acoplamento bibliográfico (quantidade de referências compartilhadas entre dois artigos), coocorrência (a frequência com que dois termos são mencionados nos artigos) e coautoria (a quantidade de colaborações entre dois autores). Os mapas resultantes são analisados por meio de conexões em que sua importância está relacionada ao tamanho de seu rótulo. Uma conexão em destaque indica uma relação preponderante (You et al., 2022).

Logo, a análise bibliométrica pode auxiliar pesquisadores em diferentes aspectos, como, por exemplo, compreender tópicos emergentes em suas respectivas áreas, identificar áreas de oportunidades para pesquisas futuras, lacunas existentes em determinadas áreas, entre outros (Saputro et al., 2023).

Dados esses conceitos apresentados, este trabalho busca utilizar a bibliometria como forma de demonstrar as potenciais tendências de pesquisa utilizando gêmeos digitais, eficiência energética e veículos elétricos inteligentes.

3. METODOLOGIA

Esta pesquisa foi realizada utilizando uma abordagem descritiva em fevereiro de 2025. O objetivo principal foi analisar a relação entre documentos que tratam dos tópicos: veículos inteligentes, veículos elétricos, roteirização, eficiência energética e gêmeos digitais. Desse modo, busca-se levantar quais as tendências de pesquisa para novos pesquisadores que tenham interesse em caminhar nesse campo. Para isso, foram definidas as seguintes palavras-chave: *intelligent vehicles; trajectory planning, routing planning, motion planning, energy efficiency, digital twin*. Com as palavras-chave definidas, a extração bibliométrica foi realizada utilizando a base de dados *Web of Science* (WoS) da *Clarivate Analytics PLC* (Clarivate Analytics, 2024), abrangendo o período de 1945 a 2025 sendo extraída em formato .RIS e seguidamente analisada no software *VOSviewer* (versão 1.6.20.0).




Figura 1. Etapas para a pesquisa bibliométrica adotada.




Figura 2. Mapa bibliométrico gerado no VOSviewer baseado nas linhas de busca utilizadas.

A pesquisa na base WoS foi realizada utilizando o campo tópico. Foram utilizadas duas linhas de busca aplicando o operador “AND” entre elas e em cada linha foram descritos os termos relacionados às palavras-chave escolhidas do seguinte modo: (“trajectory_planning”OR“routing_planning”OR“motion_planning”OR“energy_efficiency”OR“digital_twin”) AND (“Autonomous_vehicles”OR“intelligent_vehicles”OR“connected_vehicles”OR“carlike_robot”OR“driverless_car”OR“intelligent_electric_vehicles”OR“electric_vehicles”OR“self-driving_car”).

Neste estudo, os termos associados a veículos foram incluídos na mesma linha de busca, considerando que veículos elétricos e veículos inteligentes (assim como seus sinônimos) compartilham similaridades em termos de sistemas eletrônicos e sensores embarcados, além de possuírem um sistema de propulsão elétrico (Abro et al., 2023). Dessa forma, com base no sistema de propulsão, torna-se essencial monitorar em tempo real o consumo de energia em ambos os tipos de veículos, bem como realizar um assertivo planejamento de rota e estimação do consumo ao longo de trajetos específicos. Após busca e extração dos dados, foi realizado o refinamento dos resultados, unificando termos repetidos ou similares, como *connected and automated vehicle* para *autonomous vehicles*. Os dados extraídos da base da WoS foram importados para o software VOSviewer utilizando os seguintes parâmetros: criação de mapas baseados em dados bibliográficos; coocorrências de palavras-chave; e número mínimo de 20 ocorrências. A Fig. 1 ilustra as etapas listadas anteriormente.

4. RESULTADOS DA BIBLIOMETRIA

A busca realizada na WoS, conforme Seção 3, resultou em 4209 documentos. A Fig. 2 representa o mapa bibliométrico gerado no VOSviewer. Por meio dele, é possível

observar a geração de 5 *clusters* diferenciados a princípio por cores: Vermelho (62 itens) em que se destacam *electric vehicles* e *energy efficiency*; verde (44 itens) destacando *autonomous vehicles* e *trajectory planning*; azul (26 itens) relacionado a *digital twin*, *artificial intelligence*; amarelo (14 itens) relacionado à *optimization*; roxo (9 itens) relacionado à *model*. Outro ponto que pode ser analisado é a dimensão dos círculos, que representam a frequência dos termos dentro do conjunto analisado e que, desse modo, *electric vehicles*, *energy efficiency*, *autonomous vehicles* e *digital twin*, são os tópicos centrais na literatura analisada. Por fim, nesse modelo de mapa, existe a espessura das conexões que representam a força da relação entre termos. Quanto maior a espessura da conexão, maior é a frequência de ocorrência de ambos os termos dentro dos artigos. Portanto, com esses dados, é possível notar que existe uma sólida linha de pesquisa que abrange os termos *electric vehicles/energy efficiency* e *autonomous vehicles/trajectory planning*. O tema *digital twin* apresenta conexão entre esses termos citados, mas com menor frequência quando observada a espessura da conexão entre eles. Ou seja, *digital twin* é um tema recente em estudo e que apresenta potenciais aplicações nos grupos estudados.

Em (Bhatti et al., 2021), por exemplo, é discutida a aplicação de DTs em veículos elétricos inteligentes onde destacam-se seu uso no monitoramento da saúde do veículo, gestão de baterias, carregamento inteligente e otimização de conversores de energia. Essas aplicações possibilitam manutenção preditiva, otimização do consumo energético e maior eficiência. Porém, alguns desafios são listados, como alta complexidade computacional, integração de dados em tempo real, custos elevados de implementação e riscos de segurança cibernética, os quais são destacados como barreiras para sua adoção em larga escala. O trabalho também aponta lacunas como a falta de padronização de modelos e protocolos e a escassez de estudos sobre implementação em frotas urbanas.

Outro exemplo está em (Ali et al., 2022) que traz o uso de DTs em Sistemas de Transporte Inteligente (ITS) com foco em veículos elétricos e autônomos. A pesquisa destaca aplicações como monitoramento em tempo real, otimização de recarga, previsão de tráfego urbano e sensores virtuais. Apesar do potencial de melhorar a eficiência e a segurança dos veículos, os principais desafios identificados incluem a complexidade computacional, a falta de padronização e interoperabilidade, a latência na conectividade em tempo real, o alto custo de implementação, além de preocupações com a privacidade de dados. Além disso, a baixa precisão dos modelos em condições reais e a falta de integração com a infraestrutura urbana representam lacunas que ainda precisam ser abordadas para garantir a ampla adoção dos DTs na mobilidade inteligente.

De acordo com a Fig. 3, as publicações têm início no ano de 1991. Nos anos seguintes, até o ano de 2010, observa-se uma baixa variação na quantidade de publicações. A partir de 2011 é que se inicia um crescimento no quantitativo de publicações.

Com o intuito de verificar quando iniciaram as publicações de trabalhos relacionados ao “*digital twin*”, foi extraída a base da WoS contendo os 4209 trabalhos, em formato excel, na qual realizou-se um filtro personalizado do tipo

texto na coluna “*Author Keywords*” com o termo específico “**twin**” (DT). Nesse filtro, houve um retorno de 206 publicações que contêm o termo *digital twin* expresso como palavra-chave do documento.

As Figs. 4 e 5 ilustram, respectivamente, a distribuição dessas publicações ao longo dos anos e a análise temporal do termo DT relacionado às outras palavras-chave escolhidas, onde é possível constatar uma evolução no quantitativo de publicações e o quão recente é o relacionamento de DT aos clusters *electric vehicles/energy efficiency* e *autonomous vehicles*. Assim, é possível confirmar que DT associado aos temas *electric vehicles/energy efficiency* e *autonomous vehicles/trajectory planning* é uma tendência de linha de pesquisa que oferece oportunidades de estudo e que pode alavancar a aceitação de veículos elétricos.

5. DISCUSSÕES E APLICAÇÕES

Os gêmeos digitais estão cada vez mais sendo aplicados em diferentes áreas como agricultura, saúde, processos industriais e em cidades inteligentes (Piromalis and Kantaros, 2022). Nesse contexto, existem plataformas que são aplicadas para simular e replicar as condições operacionais do veículo físico. Em (Wang et al., 2022b) é aplicado o *software* CARLA (do inglês *Car Learning to Act*) na interação de pedestres e veículos conectados; Xu et al. (2022) utilizam o *software* PTV Vissim para monitoramento de emissões em estradas, e desenvolvem e avaliam estratégias de direção ecológica dentro de uma área específica. Existem outros *softwares* que também podem ser utilizados como DT: MATLAB, CarSim PreScan, SUMO entre outros. Dentre eles, existem *softwares* que têm como principal aplicação, por exemplo, a dinâmica veicular em si, teste de sensores e análise estrutural.



Figura 3. Quantidade de publicações por ano conforme busca realizada na WoS Seção 3.




Figura 4. Quantitativo de publicações referente a *digital twin* por ano.




Figura 5. Análise temporal destacando o cluster *digital twin* e suas conexões com os clusters *electric vehicles/energy efficiency* e *autonomous vehicles* gerado no VOSviewer.

No setor automotivo, em veículos elétricos por exemplo, DTs proporcionam uma simulação virtual precisa do comportamento do sistema de propulsão e da gestão de baterias. Por meio da integração com sensores em tempo real, inteligência artificial e modelos preditivos, os gêmeos digitais permitem monitoramento contínuo do estado da bateria (SoC e SoH), auxiliando na previsão da autonomia do veículo e na otimização de estratégias de recarga. Contudo, existem desafios como alta dependência de dados em tempo real, latência no processamento (processamento em tempo real demanda alta capacidade computacional), fatores externos não modelados e complexidade na implementação que limitam a eficácia do modelo (Zhang et al., 2021). Além disso, o estudo aponta oportunidades como a falta de modelagem de variáveis adicionais, restrição a um único tipo de veículo e dificuldades na integração com sistemas de transporte inteligentes, ressaltando a necessidade de mais pesquisas para ampliar a aplicabilidade dos DTs na mobilidade elétrica.

Em (Zhuo et al., 2024), por sua vez, é proposto um método de aplicação de DTs que utiliza dados históricos de condução como entrada para a previsão de autonomia a fim de melhorar a precisão da previsão. Nele, os gêmeos digitais são aplicados utilizando floresta aleatória, que utiliza informações de consumo passadas, e algoritmo de janela deslizante quando há poucos sensores e dados disponíveis insuficientes. O estudo destaca desafios como variação nas condições externas, dependência de sensores e a falta de padronização na modelagem de DTs. Além disso, identifica brechas como a restrição a dados passados, a necessidade de validação em diferentes tipos de veículos e a demanda por treinamento contínuo dos modelos, evidenciando a relevância dos DTs na otimização da autonomia energética.

Outra aplicação relevante associada aos gêmeos digitais é o *map matching*, uma técnica computacional amplamente empregada em sistemas de navegação, que contribui para aprimorar a precisão posicional, além de oferecer suporte ao planejamento de rotas e outras funcionalidades essenciais. Embora existam avanços significativos tanto na utilização de gêmeos digitais para o gerenciamento e previsão da autonomia de veículos elétricos (Zhuo et al., 2024), quanto no desenvolvimento de algoritmos robustos de *map*

matching voltados à condução autônoma (Xia et al., 2023), percebe-se uma lacuna importante na integração dessas duas tecnologias dentro de um framework unificado. A combinação entre *map matching* e gêmeos digitais tem o potencial de viabilizar a criação de representações virtuais ainda mais precisas e dinâmicas, capazes de refletir, em tempo real, não apenas a posição do veículo, mas também aspectos específicos da via, críticos para a estimação do seu estado energético e planejamento de trajetórias frente às condições variáveis do tráfego.

No cenário brasileiro, as aplicações dos DTs acima descritas possuem potencial de implementação e certamente impulsionariam o mercado de veículos elétricos. No entanto, a autonomia limitada, a escassa disponibilidade de pontos de recarga e o tempo prolongado de carregamento limitam a expansão do quantitativo de veículos elétricos. A carga tributária de impostos e poucos incentivos fiscais aplicados nesses veículos também são fatores contributivos na resistência do público e impossibilitam o acesso a esse tipo de veículo por grande parte da população (Azevedo, 2018).

6. CONSIDERAÇÕES FINAIS

Este artigo apresentou um estudo sobre a relevância do gêmeo digital aplicado a temas como veículos elétricos/eficiência energética e veículos autônomos/planejamento de trajetória. Essa linha de pesquisa é ainda recente, conforme retratam as Figuras 4 e 5. Por isso, entende-se que há muito espaço para pesquisas da aplicabilidade de gêmeos digitais naquilo que envolve desde o veículo em si, até todo o sistema de transporte. Quanto ao veículo, um tópico relevante e relacionado ao custo de transporte é a eficiência energética, na qual o gêmeo digital tem atuação para beneficiar o consumo, seja em veículos elétricos, híbridos ou à combustão. Esse consumo energético, por sua vez, atende à demanda de redução de gases de efeito estufa e também à autonomia de energia no caso de veículos elétricos (ponto crucial no tópico ansiedade de autonomia). Para trabalhos futuros, tem-se como objetivo implementar a priorização de rotas que possuam pontos de recarga no trajeto, tanto no planejamento inicial quanto no recálculo de rota, ou ao atingir determinado nível crítico de energia/combustível do veículo durante o trajeto. Estudos iniciais já estão sendo feitos nesse sentido. Pretende-se também incluir técnicas de *map matching* para melhorar a estimação das condições da via e navegação do veículo.

AGRADECIMENTOS

Os autores agradecem ao Programa de Pós-Graduação em Engenharia de Sistemas e Automação (PPGESISA) da UFLA e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ) pelo apoio para este trabalho. Este trabalho foi financiado em parte pela Fundação de Desenvolvimento da Pesquisa (FUNDEP, Mover), proc. no. 27192.02.02/2021.01.00.

REFERÊNCIAS

Abro, G.E.M., Zulkifli, S.A.B.M., Kumar, K., El Ouanjli, N., Asirvadam, V.S., and Mossa, M.A. (2023). Comprehensive review of recent advancements in battery

- technology, propulsion, power interfaces, and vehicle network systems for intelligent autonomous and connected electric vehicles. *Energies*, 16(6).
- Al-Wreikat, Y., Serrano, C., and Sodr , J.R. (2021). Driving behaviour and trip condition effects on the energy consumption of an electric vehicle under real-world driving. *Applied Energy*, 297, 117096.
- Ali, W.A., Roccotelli, M., and Fanti, M.P. (2022). Digital twin in intelligent transportation systems: a review. In *2022 8th International Conference on Control, Decision and Information Technologies (CoDIT)*, volume 1, 576–581.
- Azevedo, M.H.d. (2018). Carros el tricos: viabilidade econ mica e ambiental de inser  o competitiva no mercado brasileiro.
- Bhatti, G., Mohan, H., and Raja Singh, R. (2021). Towards the future of smart electric vehicles: Digital twin technology. *Renewable and Sustainable Energy Reviews*, 141, 110801.
- Clarivate Analytics (2024). Web of science. URL <https://www.webofscience.com>. Acessado em: 12 fev. 2025.
- Cohen, Y., Pilati, F., and Faccio, M. (2021). Digitization of assembly line for complex products – the digital nursery of workpiece digital twins. *IFAC-PapersOnLine*, 54(1), 158–162. 17th IFAC Symposium on Information Control Problems in Manufacturing INCOM 2021.
- Ellili, N.O.D. (2023). Bibliometric analysis on corporate governance topics published in the journal of corporate governance: The international journal of business in society. *Corporate Governance: International Journal of Business in Society*, 23(1), 262–286.
- Hari, D., Brace, C.J., Vagg, C., Poxon, J., and Ash, L. (2012). Analysis of a driver behaviour improvement tool to reduce fuel consumption. In *2012 International Conference on Connected Vehicles and Expo (ICCVE)*, 208–213.
- Hui, Y., Wang, Q., Cheng, N., Chen, R., Xiao, X., and Luan, T.H. (2021). Time or reward: Digital-twin enabled personalized vehicle path planning. In *2021 IEEE Global Communications Conference (GLOBECOM)*, 1–6. IEEE.
- Krysiuk, C. (2021). Autonomous cars, development of modern transport technology. *Journal of Civil Engineering and Transport*, 3, 17–27.
- Li, J., Dridi, M., and El-Moudni, A. (2014). Multi-vehicles green light optimal speed advisory based on the augmented lagrangian genetic algorithm. In *17th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, 2434–2439.
- Li, W., Stanula, P., Egede, P., Kara, S., and Herrmann, C. (2016). Determining the main factors influencing the energy consumption of electric vehicles in the usage phase. *Procedia CIRP*, 48, 352–357. The 23rd CIRP Conference on Life Cycle Engineering.
- Magana, V.C. and Munoz-Organero, M. (2015). GAFU: Using a gamification tool to save fuel. *IEEE Intelligent Transportation Systems Magazine*, 7(2), 58–70.
- Min, H., Xiong, X., Yang, F., Sun, W., Yu, Y., and Wang, P. (2023). An energy-efficient driving method for connected and automated vehicles based on reinforcement learning. *Machines*, 11(2).
- Miri, I., Fotouhi, A., and Ewin, N. (2021). Electric vehicle energy consumption modelling and estimation—a case

- study. *International Journal of Energy Research*, 45(1), 501–520.
- Morlock, F., Rolle, B., Bauer, M., and Sawodny, O. (2019). Forecasts of electric vehicle energy consumption based on characteristic speed profiles and real-time traffic data. *IEEE Transactions on Vehicular Technology*, 69(2), 1404–1418.
- Mumtaz Noreen, M.T., Fouladfar, M.H., and Saeed, N. (2024). Evaluation of battery management systems for electric vehicles using traditional and modern estimation methods. *Network*, 4(4), 586–608.
- Onaolapo, A. and Abe, B. (2024). Innovative feature analysis of electric vehicle technology, charging infrastructure, power management, and control methods. *WSEAS Transactions on Power Systems*, 19, 350–359.
- Piromalis, D. and Kantaros, A. (2022). Digital twins in the automotive industry: The road toward physical-digital convergence. *Applied System Innovation*, 5(4).
- Rajesh, P., Soundarya, T., and Jithin, K. (2024). Driving sustainability - the role of digital twin in enhancing battery performance for electric vehicles. *Journal of Power Sources*, 604, 234464.
- Roy, M., Nambi, A., Sobti, A., Ganu, T., Kalyanaraman, S., Akella, S., Devi, J.S., and Sundaresan, S.A. (2022). Reliable energy consumption modeling for an electric vehicle fleet. In *Proceedings of the 5th ACM SIGCAS/SIGCHI Conference on Computing and Sustainable Societies*, COMPASS '22, 29–44. Association for Computing Machinery, New York, NY, USA.
- SAE (2021). Taxonomy and definitions for terms related to driving automation systems for on-road motor vehicles. *SAE International*.
- Saputro, D., Prasetyo, H., Wibowo, A., Khairina, F., Sidiq, K., and Wibowo, G. (2023). Bibliometric analysis of neural basis expansion analysis for interpretable time series (n-beats) for research trend mapping. *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, 17(2), 1103–1112.
- Thibault, L., De Nunzio, G., and Sciarretta, A. (2018). A unified approach for electric vehicles range maximization via eco-routing, eco-driving, and energy consumption prediction. *IEEE Transactions on Intelligent Vehicles*, 3(4), 463–475.
- Thorgeirsson, A.T., Scheubner, S., Fünfgeld, S., and Gautherin, F. (2021). Probabilistic prediction of energy demand and driving range for electric vehicles with federated learning. *IEEE Open Journal of Vehicular Technology*, 2, 160.
- Wang, X., Park, S., and Han, K. (2022a). Energy-efficient speed planner for connected and automated electric vehicles on sloped roads. *IEEE Access*, 10, 34654–34664.
- Wang, Z., Zheng, O., Li, L., Abdel-Aty, M.A., Cruz-Neira, C., and Islam, Z. (2022b). Towards next generation of pedestrian and connected vehicle in-the-loop research: A digital twin co-simulation framework. *IEEE Transactions on Intelligent Vehicles*, 8, 2674–2683.
- Xia, X., Bhatt, N.P., Khajepour, A., and Hashemi, E. (2023). Integrated inertial-lidar-based map matching localization for varying environments. *IEEE Transactions on Intelligent Vehicles*, 8(10), 4307–4318.
- Xiu, Y., Cao, K., Ren, X., Chen, B., and Chan, W.K.V. (2023). Self-similar growth and synergistic link prediction in technology-convergence networks: The case of intelligent transportation systems. *Fractal and Fractional*, 7(2).
- Xu, Z., Jiang, T., and Zheng, N. (2022). Developing and analyzing eco-driving strategies for on-road emission reduction in urban transport systems - a VR-enabled digital-twin approach. *Chemosphere*, 305, 135372.
- You, J., Chen, X., Chen, L., Chen, J., Chai, B., Kang, A., Lei, X., and Wang, S. (2022). A systematic bibliometric review of low impact development research articles. *Water*, 14(17), 2675.
- Zhang, H., Zhang, Y., Liu, C., and Zhang, Z. (2023). Energy efficient path planning for autonomous ground vehicles with ackermann steering. *Robotics and Autonomous Systems*, 162, 104366.
- Zhang, Z., Zou, Y., Zhou, T., Zhang, X., and Xu, Z. (2021). Energy consumption prediction of electric vehicles based on digital twin technology. *World Electric Vehicle Journal*, 12(4), 160.
- Zhuo, S., Li, H., Kaleem, M.B., Peng, H., and Wu, Y. (2024). Digital twin-based remaining driving range prediction for connected electric vehicles. *SAE International Journal of Electrified Vehicles*, 13(1), 23–36.

6 ARTIGO II: DESENVOLVIMENTO DE UM GÊMEO DIGITAL PARA O MONITORAMENTO DE AUTONOMIA DE VEÍCULOS ELÉTRICOS CONECTADOS

Trabalho submetido e aprovado para apresentação na 2nd *Brazilian Conference on Robotics* (CROS) a ser realizada em abril de 2026.

Development of a digital twin for monitoring the autonomy of intelligent and connected electric vehicles

1st Mateus Lourenço do Carmo

Departamento de Automática (DAT)

Universidade Federal de Lavras (UFLA)

Lavras, Brasil

mateus.carmo@estudante.ufla.br

2nd Danilo Alves de Lima

Departamento de Automática (DAT)

Universidade Federal de Lavras (UFLA)

Lavras, Brasil

danilo.delima@ufla.br

3rd Felipe Oliveira e Silva

Departamento de Automática (DAT)

Universidade Federal de Lavras (UFLA)

Lavras, Brasil

felipe.oliveira@ufla.br

Abstract—The accurate estimation of the energy consumption of an Electric Vehicle (EV) under variable conditions, such as topography, traffic, and road characteristics, is essential for predicting range, planning trips, and ensuring operational safety. However, the uncertainty associated with the real battery behavior remains one of the major concerns for EV users, motivating the development of tools capable of representing and anticipating this consumption more reliably. In this context, this work proposes a Digital Twin (DT) architecture dedicated to energy monitoring and decision-support for Intelligent and Connected EVs (ICEVs). The system integrates the SUMO (Simulation of Urban MObility) traffic simulator with an external energy model, employing the A* algorithm for initial route planning, in which the selected route corresponds to the one with the lowest estimated energy consumption. Elevation data obtained through the Google Elevation Application Programming Interface (API) are also incorporated into the route topology to compute road gradients and their impact on energy consumption. The validation considers data from a simulated EV, where the DT continuously compares the estimated consumption with the observed one during the simulation, identifying deviations greater than 15% and applying autonomous decision rules based on critical (20%) and safety (10%) battery levels. When necessary, the system performs dynamic route re-planning or redirects the vehicle to a charging point. The results demonstrate that the DT identifies consumption anomalies, adapts to operational variations, and guarantee a safe autonomy margin for the vehicle.

Index Terms—digital twin, intelligent and connected electric vehicles, energy efficiency, SUMO.

I. INTRODUCTION

The advancement of electric mobility has driven the development of strategies to increase the energy efficiency and operational reliability of Electric Vehicles (EVs). However, the gap between estimated and observed energy consumption remains a challenge, affecting range prediction and intensifying “range anxiety” [1]. This gap results from the influence of dynamic

factors, such as speed, acceleration, topography, and driving style, that are not always adequately represented in simulation models, limiting the ability to anticipate energy-related risks along the route.

In this context, Digital Twins (DTs) emerge as a promising alternative by virtually reproducing vehicle behavior [2], enabling continuous monitoring of energy state and comparison between estimated and observed values. This capability makes DTs particularly useful for Intelligent and Connected EVs (ICEVs), in which real-world data feed the virtual model to identify deviations and mitigate “range anxiety”. This is especially relevant in countries with large territorial extension [3]. With the advancement of the Internet of Things (IoT) and 5G, such models have been strengthened by larger volumes of data, expanding their predictive potential and applications across various sectors [4]. In mobility, notable contributions include traffic management, optimization of public transportation, and improvements in energy consumption of EVs and autonomous vehicles [4], [5]. Recent studies reinforce that the integrated data usage in DTs enhances the accuracy of consumption estimates, supporting more efficient routes and greater reliability in Intelligent Transportation Systems (ITS) [6], [7].

To be fully explored, the simulation environment of the DT must be capable of accurately representing the conditions that influence real energy consumption. In this work, the SUMO (Simulation of Urban MObility) simulator was chosen. It is widely used in traffic studies [8], but it has important limitations when applied to detailed energy modeling. Despite SUMO’s advantages in traffic analysis and multi-agent interaction, the simulator does not automatically compute traction forces, aerodynamic drag, rolling resistance, or torque, nor uses mass, real acceleration, or motor power to determine energy consumption. Furthermore, SUMO does not consider the influence of road geometry, such as slope, on vehicle performance. These limitations motivated the implementation, in this work, of a complementary physical model based on resistive forces, as well as the computation of power and energy consumption from vehicle parameters [1]. Additionally, terrain slope was incorporated through the Google Elevation

*This study was financed in part by the Brazilian National Council for Scientific and Technological Development (CNPq), under grant 312194/2022-6, in part by the Minas Gerais State Agency for Research and Development (FAPEMIG), under grant APQ-04659-22, and in part the Federal University of Lavras (UFLA), under grant 23090.000874/2026-48.

Application Programming Interface (API), increasing the fidelity of topographic representation and its impact on energy consumption.

Given this context, this article aims to develop and validate a predictive-prescriptive DT capable of monitoring battery level and energy consumption during simulation runtime, continuously comparing the estimated consumption with the observed one, and reacting to relevant deviations through decision rules based on critical and safety battery levels. The proposed approach not only seeks to reduce the uncertainty associated with the autonomy of ICEVs, but also establishes a solid foundation for future integration of the DT into the experimental vehicle under development at the authors' laboratory. The results demonstrate that the developed model shows sensitivity to dynamic route conditions, robustness in identifying anomalies, and potential to support intelligent energy management systems in real applications.

The remainder of this study is organized as follows: Section II presents a literature review on energy consumption estimation, energy efficiency, and energy consumption modeling. Section III details the methodology adopted, while Section IV discusses the experimental results. Finally, concluding remarks and future work are presented in Section V.

II. GENERAL CONCEPTS

Accurate estimation of energy consumption is essential for predicting the EVs range and mitigating "range anxiety", which leads drivers to perform early charging or use only 75–80% of the available battery [1], [6]. These estimation models are applied in eco-routing, real-time estimation, eco approach/departure strategies, and can achieve errors below 6% in cycles such as those of the U.S. Environmental Protection Agency (EPA) and the New European Driving Cycle (NEDC) [1].

Consumption variability remains a challenge, especially in fleet operations, in which routing decisions, battery sizing, and maintenance depend on reliable predictions [6], [10], [11]. Modeling approaches include analytical, statistical, and computational methods [6], incorporating external factors (weather, traffic, etc.), internal factors, and driver behavior. With the expansion of EV adoption, more accurate estimates become fundamental to strengthening user confidence and enabling large-scale deployment [12].

ICEVs have increased safety and efficiency benefits, while factors such as driving conditions, component performance, and management strategies directly affect energy consumption [13]. Behavioral interventions, such as audiovisual alerts [14], driving feedback [15], and speed recommendations [16], can enhance efficiency, although they depend on driver adherence.

In the same context of improving efficiency, route selection plays a fundamental role and is often supported by algorithms such as A*, which is widely used to optimize trajectories

It not only replicates and monitors the EV's energy state, but also anticipates autonomy insufficiency scenarios and executes corrective actions, such as route recalculation or redirection to charging [9].

in an energy-efficient manner, resulting in reductions in final energy consumption of up to 26.9% in simulations and 21.09% in real tests [17]. Anticipation of dynamic traffic is also relevant, and Reinforcement Learning (RL) techniques have been explored to improve energy-related decisions [18]. Early studies highlight the influence of factors such as topography and HVAC system usage [19], reinforcing the need for more comprehensive models that consider auxiliary variables and diverse operational conditions.

For more accurate energy assessments, it is necessary to adopt integrated strategies that consider vehicle reliability, range, battery efficiency, and the operation of the charging infrastructure. Modeling the energy efficiency and consumption of EVs involves various parameters, including resistive forces, demanded power, battery state of charge, and energy recovery through regenerative braking [6].

The resistive forces considered by Miri, Fotouhi and Ewin [1] — and widely adopted in the specialized literature — are illustrated in Fig. 1. The proposed energy model encompasses the main physical factors that influence vehicle motion and enables the estimation of the power required for displacement at each instant. The power output (P_{out}), resulting from overcoming the total resistive forces, is calculated by:

$$P_{out} = \frac{R_{total} \cdot v}{\eta_G}, \quad (1)$$

in which

- v : vehicle speed [m/s];
- η_G : powertrain efficiency;
- R_{total} : sum of the resistive forces:

$$R_{total} = R_R + R_A + R_\theta + R_I, \quad (2)$$

which can be defined as follows:

- **Rolling resistance force (R_R):**

$$R_R = C_{rr} \cdot m \cdot g. \quad (3)$$

It represents the sum of the resistive force caused by the contact of the tires (R_{RF} for the front and R_{RR} for the rear) with the ground. This force depends on the vehicle mass m , gravitational acceleration g , and the




Fig. 1. Diagram of the resistive forces acting on a vehicle [1].

rolling resistance coefficient $C_{rr} = 0.01 \cdot (1 + \frac{v}{100})$, which is a function of speed v .

- **Aerodynamic drag force (R_A):**

$$R_A = 0.5 \cdot \rho \cdot A_f \cdot C_d \cdot v^2. \quad (4)$$

This force corresponds to the opposition to vehicle motion due to air resistance. It depends on air density ρ , the vehicle's frontal area A_f , the aerodynamic drag coefficient C_d , and the square of v .

- **Grade resistance force (R_θ):**

$$R_\theta = m \cdot g \cdot \sin(\theta). \quad (5)$$

This force appears when the vehicle moves on sloped road. It is proportional to the m , the g , and the sine of the slope angle θ .

- **Inertial (acceleration) force (R_I):**

$$R_I = \delta \cdot m \cdot a. \quad (6)$$

It represents the force required to accelerate the vehicle and considers the mass m , the instantaneous acceleration a , and the rotational inertia factor δ , which accounts for the effects of rotating masses (such as wheels and axles).

In this way, the model integrates the contributions of each resistive component, enabling an accurate representation of the required power and, consequently, of the energy consumption under different operating conditions.

III. METHODOLOGY

This work uses the SUMO simulator [20], which is a modular and extensible microscopic simulator capable of representing the individual behavior of vehicles in complex road networks [8]. Integration occurs through the TraCI (Traffic Control Interface), which allows runtime access to information such as pose, speed, and acceleration. Since SUMO does not have a native energy consumption calculation, TraCI is used only for dynamic data collection, while the energy model—responsible for consumption estimation, monitoring, and decision making—is executed externally and in parallel with the simulator.

The system was developed in Python and adopts an event-driven architecture, so that decisions such as route recalculation and redirection to charging points are made dynamically, based on continuously updated data on the road network, battery charge status, and accumulated energy consumption. Thus, four main steps were considered, as presented in the following:

- 1) SUMO: involves configuring the simulation environment and defining the best route;
- 2) Vehicle and route: covers vehicle management;
- 3) Consumption estimation and simulation startup;

Runtime corresponds to the internal time of the simulation, while real time refers to the simultaneous monitoring of an event as it occurs in the physical world.

- 4) DT execution.

Each step is detailed in the following subsections, allowing for a clear and progressive understanding of how the adopted methodology works.

A. Simulation environment configuration and best route definition

To perform the simulation and analysis of the DT application, the digital map of the authors' university campus was used as the road scenario. This map was initially extracted from the opensource Java OpenStreetMap [21] platform and then converted to the .xml format, compatible with the SUMO simulator, using the *netedit* network editor (version 1.22.0).

Since the topography of the road network is not provided by OpenStreetMap, the altitude of the geographic coordinates was incorporated into the model through queries to the Google Elevation API, limited to 5,000 queries per month. Based on this information, the slope of each segment was estimated using the geometric relationship between the altitude variation and the projected horizontal distance.

Once the road environment was defined, fixed points of origin (A) and destination (B) were established, as shown in Fig. 2, which serve as the basis for simulating trips and evaluating viable routes. The best route was calculated using the A* algorithm [17]. It was selected based on an energy criteria, namely, a weight calculated for each possible route. This weight represents the estimated energy required to travel the route, consisting of the sum of the linear extension of each edge and the penalty resulting from the slope of the road. This slope was then integrated into the external energy model, applied in (5), and into the A* cost function, used in (7), thus allowing the consumption estimate to consider not only the linear length of the roads, but also the effects of the road slope on energy consumption. This cost is calculated by the expression that aggregates the length of the roads and the penalty factor proportional to the elevation, according to (7), reflecting the impact of topography on energy consumption. This penalty factor was assigned taking into account the physical basis also considered in [22].

$$W_{\text{route}} = \sum_{i=1}^n d_i + \sum_{i=1}^n (|\Delta h_i| \cdot \alpha), \quad (7)$$



Fig. 2. University campus road map generated in *netedit*.

where:

- W_{route} is the total energetic weight of the route;
- d_i is the length of the i -th edge;
- Δh_i is the elevation variation of the edge;
- $\alpha = 0.2$ is the penalization factor;
- n is the number of segments of the route.

After calculating the weight of all candidate routes, the system automatically identifies the one with the lowest value, corresponding to the most energy-efficient route. The A* cost function is used for preliminary estimation and route prioritization, while the direct physical energy calculation is performed within the DT monitoring module. In this way, the selection logic implemented ensures that the DT prioritizes routes that minimize total energy consumption, while simultaneously considering the distance traveled and the effects of road slope.

The heuristic parameters of the routing algorithm were defined based on the literature and empirically adjusted to ensure energetic consistency and computational stability. Tests indicated that moderate variations affect the system's sensitivity but do not compromise its decision-making robustness.

B. Vehicle management

To define the vehicle's physical parameters and formulate the energy consumption model, we used the data and models proposed in [1] as a basis. The vehicle data used refers to a real model, namely, the 2014 BMW i3 60Ah Range Extender (REx), whose specifications are taken directly from the aforementioned work. The data are:

- $m = 1,390\text{kg}$: vehicle mass;
- $\eta_G = 0.85$: powertrain efficiency;
- $g = 9.81\text{m/s}^2$: acceleration due to gravity;
- $\rho = 1.225\text{kg/m}^3$: air density;
- $A_f = 2.38\text{m}^2$: front area of the vehicle;
- $C_d = 0.3$: aerodynamic drag coefficient;
- $\delta = 1.15$: rotational inertia factor.

These parameters were used in the equations that make up the total resistive forces model and, consequently, in calculating the vehicle's power and energy consumption at each step of the simulation, as described in Section II. The decision to use real data from a commercial EV makes the simulation more realistic, allowing the developed computational model to be validated and integrated into the authors' laboratory for future real applications.

For energy management, two configurable parameters were defined: (a) the critical battery level, which triggers the assessment between continuing to the destination or redirecting the EV to a charging point; and (b) the safety level, which establishes the minimum energy required to complete the journey reliably. These mechanisms reflect the purpose of the DT, whose function is to virtually reproduce the actual

Considered as a constant average value to maintain consistency with the simulation abstraction level and reduce computational complexity. Future work may incorporate load-dependent motor and inverter efficiency maps to improve energetic fidelity.

behavior of the vehicle — including consumption, driving style, and operating conditions — to anticipate failures and avoid risky situations. As there is still no data from a physical vehicle, a second simulator was used with intentional errors inserted, allowing the DT's ability to identify anomalies and predict critical scenarios, such as the possibility of running out of fuel, to be tested, acting proactively in autonomy management.

C. Consumption estimation and simulation startup

The energy consumption model used was based on the equations presented in Section II and the physical parameters of a real vehicle, described in Section III-B. We used both for the preliminary estimation of energy consumption and for the instantaneous monitoring of consumption during the simulation. As mentioned before, the simulated vehicle that provides information to the DT was modeled based on vehicle data from the BMW i3, ensuring greater reliability in power consumption calculations and reproduced energy behavior.

The consumption estimation step uses average speed and acceleration values along the route with the lowest consumption, defined by the A* algorithm, allowing the DT to predict in advance whether the available energy is sufficient to reach the destination and, if necessary, to insert a recharging point. During execution, the system continuously monitors variables such as speed, acceleration, and slope, applying the same physical-mathematical model from the previous step to compare the predicted and current consumption. This integration between prediction and dynamic monitoring makes it possible to validate the feasibility of the route and adjust planning by recalculating routes or redirecting for recharging. The simulation is conducted by the `run_simulation()` function, which connects the system to TraCI, manages time progression, and updates data, such as position, speed, and consumption in real time. It also coordinates vehicle configuration modules, route planning, and energy calculations, allowing for the inclusion of multiple vehicles and elements, such as traffic lights, to represent different traffic conditions.

D. Digital Twin execution

The DT concept was applied through the integration of real-time monitoring and decision-making. The solution presented herein is characterized as a *Digital Twin Prototype* (DTP), since it is fully implemented in a simulation environment without direct connection to a real physical asset [23]. The system continuously tracks the vehicle, collecting speed, acceleration, and energy level data at each step of the simulation. This data feeds into the energy assessment mechanisms that support the DT decision-making process. Based on this information, DT performs a dynamic analysis, comparing the consumption observed in each segment during the simulation with the consumption previously estimated by the predictive model. In this process, DT acts on three main monitoring fronts:

- 1) checks whether actual consumption deviates by more than 15% from the predicted value for a given segment

of the route, a parameter used for early detection of divergence in energy performance;

- 2) monitors whether the battery level reaches the critical level of 20%, at which point the range is no longer sufficient to guarantee the safe completion of the journey;
- 3) ensures that the safety level of 10% is maintained, corresponding to the minimum desirable energy at the end of the journey.

The thresholds of 10%, 15%, and 20% were defined to represent different levels of severity in the divergence between predicted and observed energy consumption. The 10% value corresponds to expected variations arising from operational uncertainties, whereas 15% indicates relevant discrepancies that justify route reassessment. The 20% threshold was adopted as a more conservative condition to trigger prescriptive actions, such as rerouting or charging, thereby reducing the risk of insufficient autonomy. In general, lower thresholds increase the DT's sensitivity, while higher values reduce interventions but raise the risk of delayed detection.

When any of the defined conditions are violated — whether due to a significant deviation in consumption, reaching a critical level, or the impossibility of reaching the destination while maintaining safety levels — the DT interprets the situation as a significant deviation from the predicted scenario. In these circumstances, the system updates its estimates and automatically redirects the vehicle to the nearest charging point, ensuring that the operation remains within appropriate limits of reliability and efficiency. This logic expresses the role of the DT in monitoring, during the simulation, the vehicle's energy behavior and continuously verifying the feasibility of the route. As a result, the DT adjusts routes, prioritizes recharging when necessary, and ensures that the trip remains within safe and energy-efficient limits.

The simulation was run on a mid-range computer (multi-core CPU Intel I5 10th generation and 16 GB of RAM), resulting in an average time of approximately 21 seconds for each trip. This performance indicates that the model can be easily operated in a GNSS (Global Navigation Satellite System) rate of 1-4 Hz. Actually, during our executions, the DT receives and updates vehicle data — speed, acceleration, and battery level — at each step of *TraCI*, with a typical rate between 10 Hz and 20 Hz, which is compatible with embedded vehicle monitoring systems. This continuous data flow allows the DT to track the vehicle's energy behavior and make decisions with reduced latency, maintaining the temporal consistency required for operational applications.

IV. EXPERIMENTAL RESULTS

The validation of the DT was conducted through simulations that reproduce the energy behavior of the BMW i3 electric vehicle. Each simulation — referred to as a “trip” — represents the movement from the origin point (A) to the destination point (B), as illustrated in Fig. 2. The route has an approximate length of 982 meters, resulting in an average execution time of 21 seconds per trip. Since this distance is insufficient to generate significant variations in battery levels, a multiplicative

factor of 250 was applied to the energy consumption, enabling a more realistic assessment of the DT's behavior over multiple consecutive trips.

Through the terrain slope, it was possible to identify its influence on the energy consumption during a trip. Generally, the higher the penalization index, the greater the impact on the vehicle's energy consumption. This influence is illustrated in Fig. 3, which compares simulations with and without road slope.

To evaluate the DT's intervention capability, the vehicle was subjected to repeated trips, allowing the system to continuously monitor the accumulated energy consumption and compare the observed value with the estimated consumption. Whenever the real consumption exceeds the predicted value by more than 15%, the DT checks whether the vehicle is still able to reach its destination while maintaining the safety threshold of 10% battery. This behavior can be observed in Trip 5 of Fig. 4, in which the consumption exceeded the divergence limit, but the DT concluded that there was still sufficient energy to complete the route without requiring redirection to a charging point.

On the initial trips, the vehicle completes the route without reaching the critical battery level. In Trip 5 of Fig. 4, for example, the actual consumption exceeds the estimated consumption by approximately 20%; even so, the DT decides to maintain the original route, as the remaining energy still ensures the completion of the trip and the beginning of the subsequent one with adequate operational margins.




Fig. 3. Comparison between simulations with and without road inclination in a single trip.




Fig. 4. Comparison between estimated and real consumption, where the second one exceeds the predicted value by more than 15%.




Fig. 5. Accumulated battery level per trip.

The decision-making behavior becomes more evident in the later cycles, as shown in Fig. 5. At the end of the 17th trip, the battery level approached the critical limit, making it impossible to begin another trip without operational risk. In response, the DT determined that, on the 18th trip, the vehicle had to prioritize reaching the charging point, since the energy required to reach the destination exceeded that needed to arrive at the charging station. Thus, the system re-planned the route by including the recharge before proceeding to a new trip, ensuring the maintenance of minimum energy safety conditions.

These results demonstrate that the proposed DT was capable of detecting significant deviations in consumption, assessing the energy feasibility of each trip, and making autonomous decisions regarding replanning, ensuring that the vehicle remained within the defined safety limits for its operation and thus reducing range anxiety.

V. CONCLUSIONS AND FUTURE WORKS

This work presented the development of a DT for the energy monitoring of an ICEV. It demonstrated the feasibility of integrating the DT into an energy routing process, making it possible to monitor consumption in real time, identify deviations, and adjust decisions dynamically, contributing to greater energy efficiency and reduced range anxiety. Despite the positive results, the energy model had limitations because it did not consider factors such as temperature, battery degradation, and traffic effects.

These restrictions can be mitigated with a multi-objective A* and predictive improvement of the DT through machine learning techniques, allowing for more accurate estimates and early decisions. In addition, the use of SUMO as the base engine of the proposed DT facilitates the future incorporation of traffic elements and simulations that are more consistent with the urban scenario. Future work will focus on incorporating machine learning techniques into the energy model, allowing DT to refine its estimates based on actual vehicle performance and learn patterns of variation associated with driving style and time of day, expanding its predictive and adaptive potential.

REFERENCES

- [1] I. Miri, A. Fotouhi, and N. Ewin, "Electric vehicle energy consumption modelling and estimation—a case study," *International Journal of Energy Research*, vol. 45, no. 1, pp. 501–520, 2021.

- [2] Z. Zhang, Y. Zou, T. Zhou, X. Zhang, and Z. Xu, "Energy consumption prediction of electric vehicles based on digital twin technology," *World Electric Vehicle Journal*, vol. 12, no. 4, p. 160, 2021.
- [3] M. L. do Carmo, D. A. de Lima, and F. O. Silva, "Gêmeos digitais e veículos elétricos inteligentes: estado da arte e possíveis aplicações," in *Anais do XVII Simpósio Brasileiro de Automação Inteligente (SBAI 2025)*, São João del-Rei, MG, 2025, disponível nos anais do evento.
- [4] G. Bhatti, H. Mohan, and R. Raja Singh, "Towards the future of smart electric vehicles: Digital twin technology," *Renewable and Sustainable Energy Reviews*, vol. 141, p. 110801, 2021.
- [5] D. Piromalis and A. Kantaros, "Digital twins in the automotive industry: The road toward physical-digital convergence," *Applied System Innovation*, vol. 5, no. 4, 2022.
- [6] M. Roy, A. Nambi, A. Sobti, T. Ganu, S. Kalyanaraman, S. Akella, J. S. Devi, and S. A. Sundaresan, "Reliable energy consumption modeling for an electric vehicle fleet," in *Proceedings of the 5th ACM SIGCAS/SIGCHI Conference on Computing and Sustainable Societies*, ser. COMPASS '22. New York, NY, USA: Association for Computing Machinery, 2022, p. 29–44.
- [7] Y. Xiu, K. Cao, X. Ren, B. Chen, and W. K. V. Chan, "Self-similar growth and synergistic link prediction in technology-convergence networks: The case of intelligent transportation systems," *Fractal and Fractional*, vol. 7, no. 2, 2023.
- [8] DLR – German Aerospace Center, *SUMO - Simulation of Urban MObility: An open source traffic simulation*. Institute of Transportation Systems, 2023, accessed: Nov. 28, 2025. [Online]. Available: <https://sumo.dlr.de/docs/>
- [9] D. Jones, C. Snider, A. Nassehi, J. Yon, and B. Hicks, "Characterising the digital twin: A systematic literature review," *CIRP Journal of Manufacturing Science and Technology*, vol. 29, pp. 36–52, 2020.
- [10] J. Li, F. Wang, and Y. He, "Electric vehicle routing problem with battery swapping considering energy consumption and carbon emissions," *Sustainability*, vol. 12, no. 24, 2020.
- [11] L. d. C. Martins, R. D. Tordecilla, J. Castaneda, A. A. Juan, and J. Faulin, "Electric vehicle routing, arc routing, and team orienteering problems in sustainable transportation," *Energies*, vol. 14, no. 16, 2021.
- [12] M. T. Mumtaz Noreen, M. H. Fouladfar, and N. Saeed, "Evaluation of battery management systems for electric vehicles using traditional and modern estimation methods," *Network*, vol. 4, no. 4, pp. 586–608, 2024.
- [13] Y. Al-Wreikat, C. Serrano, and J. R. Sodr , "Driving behaviour and trip condition effects on the energy consumption of an electric vehicle under real-world driving," *Applied Energy*, vol. 297, p. 117096, 2021.
- [14] D. Hari, C. J. Brace, C. Vagg, J. Poxon, and L. Ash, "Analysis of a driver behaviour improvement tool to reduce fuel consumption," in *2012 International Conference on Connected Vehicles and Expo (ICCVE)*, 2012, pp. 208–213.
- [15] V. C. Magana and M. Munoz-Organero, "GAFU: Using a gamification tool to save fuel," *IEEE Intelligent Transportation Systems Magazine*, vol. 7, no. 2, pp. 58–70, 2015.
- [16] J. Li, M. Dridi, and A. El-Moudni, "Multi-vehicles green light optimal speed advisory based on the augmented lagrangian genetic algorithm," in *17th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, 2014, pp. 2434–2439.
- [17] H. Zhang, Y. Zhang, C. Liu, and Z. Zhang, "Energy efficient path planning for autonomous ground vehicles with ackermann steering," *Robotics and Autonomous Systems*, vol. 162, p. 104366, 2023.
- [18] C. Pan, A. Huang, J. Wang, L. Chen, J. Liang, W. Zhou, L. Wang, and J. Yang, "Energy-optimal adaptive cruise control strategy for electric vehicles based on model predictive control," *Energy*, vol. 241, p. 122793, 2022.
- [19] W. Li, P. Stanula, P. Egede, S. Kara, and C. Herrmann, "Determining the main factors influencing the energy consumption of electric vehicles in the usage phase," *Procedia CIRP*, vol. 48, pp. 352–357, 2016, the 23rd CIRP Conference on Life Cycle Engineering.
- [20] P. Alvarez Lopez, A. Banse, M. Behrisch, J. Erdmann, Y.-P. Fl tter d, R. Hilbrich, R. Nippold, and P. Wagner, "Simulation of urban mobility (sumo)," Nov. 2025.
- [21] I. Scholz, D. St cker, and colaboradores, "JOSM – java openstreetmap editor," <https://josm.openstreetmap.de/>.
- [22] L. Guzzella and A. Sciarretta, *Vehicle Propulsion Systems: Modeling and Optimization*, 2nd ed. Berlin, Heidelberg: Springer, 2013.
- [23] M. Grieves and J. Vickers, *Digital Twin: Mitigating Unpredictable, Undesirable Emergent Behavior in Complex Systems*. Springer, 2019.

7 DISCUSSÃO DOS RESULTADOS DOS ARTIGOS

Os dois artigos que compõem esta dissertação foram concebidos de forma complementar, estruturando uma linha de investigação que parte da compreensão do estado da arte até a proposição de uma solução aplicada. O Artigo I tem como principal contribuição a delimitação do problema de pesquisa e a identificação de lacunas científicas. Por meio de uma análise bibliométrica abrangente, o estudo evidencia que, embora existam avanços relevantes em áreas como eficiência energética, planejamento de rotas e veículos inteligentes, a integração desses elementos com DTs ainda é incipiente, especialmente no que se refere à tomada de decisão em tempo de execução. Esse ponto é central, pois demonstra que o problema abordado nesta dissertação não apenas é relevante, mas também carece de soluções consolidadas na literatura.

Por sua vez, o Artigo II atua diretamente sobre essa lacuna, ao propor e validar uma arquitetura de DT capaz de monitorar o consumo energético em tempo de execução e atuar de forma adaptativa. Diferentemente das abordagens tradicionais, o sistema desenvolvido não se limita à estimativa prévia, mas incorpora mecanismos de comparação contínua entre valores estimados e observados, permitindo intervenções dinâmicas, como o replanejamento de rotas e o redirecionamento para pontos de recarga. Dessa forma, argumenta-se que a principal contribuição desta dissertação não está apenas nos resultados individuais de cada artigo, mas na articulação entre eles, que estabelece uma progressão lógica clara: da identificação de uma lacuna científica (Artigo I) à proposição de uma solução estruturada e validada (Artigo II). Essa integração reforça o caráter científico do trabalho, ao demonstrar coerência entre problema, fundamentação e solução.

O problema central desta pesquisa é sintetizado como a necessidade de reduzir a incerteza na estimativa de consumo energético e aumentar a confiabilidade da autonomia em IEVs. A partir da análise do Artigo I, observa-se que a literatura reconhece amplamente a influência de fatores dinâmicos — como topografia, tráfego e comportamento do condutor — sobre o consumo energético. No entanto, a maioria das abordagens existentes trata esse problema de forma estática ou parcialmente dinâmica, o que limita sua capacidade de resposta frente a variações em tempo de execução. Nesse contexto, o Artigo II apresenta uma contribuição relevante ao demonstrar que a integração entre modelagem energética, monitoramento contínuo e lógica decisória baseada em limiares permite mitigar essa limitação. O sistema proposto compara continuamente o consumo estimado com o observado e, ao identificar desvios significativos, aciona estratégias adaptativas. Argumenta-se, portanto, que a principal resposta desta dissertação ao problema de pesquisa reside na introdução de uma capacidade adaptativa orientada por dados em tempo de execução, característica que não é plenamente explorada nas abordagens tradicionais, representando um avanço ao deslocar o problema de uma lógica puramente preditiva para uma lógica preditivo-prescritiva.

A análise conjunta dos artigos e da literatura permite posicionar a abordagem proposta em relação aos métodos existentes. Modelos tradicionais, sejam analíticos, estatísticos ou computacionais, apresentam boa capacidade de estimativa, porém são fortemente dependentes de condições pré-estabelecidas, o que implica perda de desempenho em cenários dinâmicos. Algoritmos de roteirização clássicos, focados em menor distância ou tempo, não consideram explicitamente o consumo energético, podendo levar a decisões subótimas. Mesmo abordagens mais avançadas, como aquelas baseadas no algoritmo A* com função de custo energético, embora representem um avanço significativo, ainda operam predominantemente de forma estática, sem incorporar mecanismos de adaptação contínua durante a execução do trajeto. Nesse cenário, argumenta-se que a abordagem proposta no Artigo II apresenta um diferencial claro ao integrar previsão, monitoramento e ação em um único *framework*, permitindo não apenas identificar

a melhor rota inicialmente, mas reavaliar continuamente sua viabilidade diante das condições reais de operação.

Apesar das contribuições apresentadas, uma análise crítica é necessária para delimitar o alcance dos resultados. A validação do sistema foi realizada em ambiente simulado, o que, embora permita controle experimental, não contempla todas as variabilidades do mundo real. Nesse sentido, argumenta-se que os resultados devem ser interpretados como indicativos de viabilidade, e não como validação definitiva em ambiente operacional. Além disso, o modelo energético adotado utiliza simplificações, como eficiência constante do trem de força e ausência de modelagem detalhada de sistemas auxiliares, o que pode impactar a precisão absoluta das estimativas. A ausência de modelagem do comportamento do condutor também representa uma limitação relevante. Ainda assim, argumenta-se que tais limitações não comprometem a principal contribuição do trabalho, uma vez que o foco está na estrutura decisória e na arquitetura do DT, e não na modelagem exaustiva de todos os fenômenos físicos.

A partir da integração dos artigos, a metodologia da pesquisa pode ser compreendida como um *pipeline* estruturado que inicia com a construção do ambiente de simulação, incluindo a definição da malha viária e a incorporação de dados topográficos. Em seguida, realiza-se o planejamento de rota por meio do algoritmo A*, considerando uma função de custo energético que inclui distância e inclinação. Durante a execução da simulação, dados dinâmicos são coletados e utilizados como entrada para um modelo energético externo. O DT realiza então o monitoramento contínuo do consumo e compara os valores observados com os estimados, aplicando regras decisórias que determinam a continuidade da rota, o replanejamento ou o redirecionamento para recarga. Argumenta-se que essa estrutura metodológica representa uma contribuição relevante, pois operacionaliza o conceito de DT em um fluxo contínuo de decisão, aproximando o modelo de aplicações reais.

As métricas adotadas, como consumo energético, divergência percentual entre valores estimados e observados, nível de carga da bateria e frequência de replanejamento, foram selecionadas de modo a capturar não apenas a eficiência do sistema, mas também sua capacidade de adaptação. O protocolo experimental, baseado na execução de múltiplas simulações com inserção de perturbações controladas, permite avaliar o comportamento do sistema frente a condições variáveis. Argumenta-se que essa escolha metodológica é adequada ao objetivo da pesquisa, pois privilegia a análise da robustez do sistema, indo além da avaliação em cenários ideais.

A análise integrada evidencia que o consumo energético é influenciado por múltiplos fatores, incluindo topografia, velocidade, aceleração, resistências físicas e condições de tráfego, além de fatores operacionais relacionados à estratégia de roteirização e às decisões do sistema. Dentre esses, destaca-se a topografia como um fator frequentemente negligenciado em abordagens simplificadas, mas que exerce impacto significativo no consumo energético. Argumenta-se, portanto, que a incorporação da inclinação da via tanto no modelo energético quanto na função de custo do algoritmo A* constitui uma contribuição importante desta dissertação.

A partir da integração entre a análise bibliométrica (Artigo I) e a validação experimental (Artigo II), observa-se que as lacunas identificadas na literatura não apenas persistem, mas se manifestam de forma concreta em cenários operacionais. A Tabela 7.1 apresenta uma síntese crítica dessas lacunas, relacionando-as diretamente às evidências empíricas observadas e às contribuições desta dissertação.

Tabela 7.1 – Síntese crítica das lacunas de pesquisa e contribuições da dissertação

Frente de Pesquisa	Lacunas identificadas na literatura (Artigo I)	Evidências empíricas (Artigo II)	Contribuição desta dissertação
Mobilidade elétrica inteligente	Predominância de abordagens que tratam planejamento de rotas e gestão energética de forma desacoplada (Artigo I)	Incapacidade de adaptação a variações dinâmicas de consumo ao longo da operação (Artigo II)	Integração entre roteirização energética e tomada de decisão adaptativa em tempo de execução
Eficiência energética em VEs	Dependência de modelos preditivos estáticos, com baixa adaptação a condições reais (Artigo I)	Divergência significativa entre consumo estimado e observado, comprometendo a confiabilidade da autonomia (Artigo II)	Monitoramento contínuo com avaliação de divergência e suporte decisório baseado em limiares operacionais
DTs na mobilidade	Aplicações concentradas em monitoramento, com baixa exploração de capacidades prescritivas (Artigo I)	Necessidade de atuação ativa do modelo digital para evitar falhas energéticas (Artigo II)	Desenvolvimento de um DT preditivo-prescritivo com capacidade de influenciar decisões em tempo de execução
Integração entre domínios	Fragmentação entre roteirização, modelagem energética e DT (Artigo I)	Dificuldade de coordenação entre estimativa, planejamento e resposta dinâmica (Artigo II)	Arquitetura integrada combinando simulação, modelo energético e lógica decisória em fluxo contínuo
Modelagem em tempo de execução	Baixa exploração de abordagens em tempo de execução (runtime), com foco em análises offline (Artigo I)	Limitações na adaptação a eventos imprevisíveis (tráfego, topografia, consumo) (Artigo II)	Introdução de modelo adaptativo com avaliação contínua da viabilidade energética da rota

Por fim, a análise conjunta do Artigo I e do Artigo II permite concluir que a principal contribuição dos artigos dentro desta dissertação está na evolução de modelos estáticos para uma abordagem dinâmica baseada em DT, capaz de integrar planejamento, monitoramento e tomada de decisão em tempo de execução. Argumenta-se que essa transição representa um avanço relevante no estado da arte, pois aumenta a confiabilidade da autonomia, reduz a incerteza associada ao consumo energético e contribui para a mitigação da ansiedade de autonomia. Além disso, a coerência entre os artigos e o corpo da dissertação reforça a consistência científica do trabalho, evidenciando que os resultados obtidos não são isolados, mas parte de uma construção metodológica e conceitual integrada.

Parte III

Conclusão e trabalhos futuros

8 CONCLUSÃO

Este trabalho teve como objetivo desenvolver e avaliar um sistema baseado em DTs para integrar o planejamento dinâmico de rotas e o monitoramento, em tempo de execução, do consumo energético de veículos inteligentes em ambientes urbanos. A abordagem, implementada no simulador SUMO acoplado à interface TraCI, buscou otimizar a eficiência energética, aumentar a confiabilidade da mobilidade elétrica e contribuir para a mitigação da ansiedade de autonomia. Para isso, o estudo combinou uma análise bibliométrica da literatura, o desenvolvimento de estratégias de roteirização com lógica adaptativa de recarga, a integração de modelos de consumo energético ao ambiente de simulação e o aprimoramento da representação topológica da via, resultando em uma arquitetura capaz de apoiar a tomada de decisão baseada em dados ao longo da operação veicular.

A solução proposta nesta dissertação pode ser posicionada, à luz da classificação de Kritzing *et al.* (2018), como um DT em estágio intermediário entre *Digital Shadow* e DT, com predominância de características de um Digital Twin preditivo-prescritivo em ambiente simulado. Isso se justifica pelo fato de que o modelo implementado realiza a coleta automatizada de dados do sistema físico simulado (via TraCI no SUMO), caracterizando um fluxo contínuo de dados do físico para o digital, típico de um Digital Shadow. No entanto, a solução vai além dessa definição ao incorporar lógica decisória baseada em limiares energéticos, permitindo que o modelo digital influencie o comportamento do sistema ao replanejar rotas ou redirecionar o veículo para recarga. Ainda que essa atuação ocorra dentro do ambiente de simulação — e não sobre um veículo físico real — ela representa um fluxo funcional do digital para o físico (simulado), aproximando a solução da definição de Digital Twin. Argumenta-se, portanto, que a principal limitação para classificá-lo como um Digital Twin completo reside na ausência de integração com um sistema físico real em malha fechada. Contudo, do ponto de vista arquitetural e funcional, o modelo desenvolvido já incorpora os elementos centrais de um DT, incluindo monitoramento em tempo de execução, comparação entre estados estimados e observados e tomada de decisão adaptativa, podendo ser interpretado como um Digital Twin operacional em ambiente virtual, com potencial direto de evolução para aplicação em sistemas reais.

A metodologia proposta e implementada demonstrou a viabilidade da aplicação de um DT no contexto de EVs, com ênfase no planejamento de rotas e no monitoramento energético em tempo real. A integração entre o simulador SUMO, a interface TraCI e a lógica programada em Python permitiu o desenvolvimento de um sistema capaz de realizar decisões dinâmicas baseadas nas condições operacionais do veículo e na infraestrutura viária disponível. O DT, nesse contexto, atua como um agente inteligente que monitora continuamente variáveis como nível de energia, posição, aceleração e consumo acumulado, sendo capaz de reagir de forma autônoma a eventos críticos, como a necessidade de recarga, realizando o replanejamento de rota e garantindo a continuidade da operação.

Além disso, este estudo reforça a relevância do DT como uma tecnologia emergente que, conforme evidenciado pela análise bibliométrica apresentada, possui ampla aplicabilidade tanto no nível do veículo individual quanto no gerenciamento sistêmico da mobilidade urbana. A eficiência energética, nesse contexto, revela-se um eixo central que conecta os avanços da eletrificação veicular à sustentabilidade ambiental e ao comportamento adaptativo dos sistemas inteligentes.

Apesar das limitações do SUMO em representar detalhadamente o consumo energético real — como a ausência nativa de parametrizações específicas para frenagem regenerativa ou perdas térmicas — os resultados obtidos destacam o potencial do DT para mitigar o fenômeno da “ansiedade de autonomia”, otimizar trajetos com base no consumo energético e apoiar a tomada de decisão em tempo de execução. Cabe complementar que o DT desenvolvido neste

trabalho não tem como propósito reproduzir integralmente todos os fenômenos físicos e eletroquímicos envolvidos na operação de EVs, tampouco substituir sistemas embarcados avançados de controle. Diferentemente de abordagens presentes na literatura que buscam alta fidelidade físico-química — incluindo modelagem detalhada de baterias, efeitos térmicos e degradação — o modelo proposto adota um nível de abstração orientado à tomada de decisão energética em nível sistêmico. Além disso, ao contrário de DTs plenamente implementados em ambientes industriais ou automotivos reais, a solução aqui apresentada não opera em malha fechada com um sistema físico real, estando restrita ao ambiente de simulação. No campo decisório, também não se propõe a resolver problemas de otimização global multiobjetivo ou incorporar, neste estágio, técnicas avançadas de aprendizado contínuo, como aprendizado por reforço. Argumenta-se, contudo, que essa delimitação não representa uma limitação conceitual, mas sim uma escolha metodológica coerente com o objetivo do trabalho, que é validar uma arquitetura funcional capaz de integrar monitoramento, previsão e ação adaptativa. Nesse sentido, a principal contribuição não está na complexidade do modelo físico, mas na capacidade de estruturar um DT operacional que atua sobre a incerteza energética em tempo de execução, posicionando-se como uma solução intermediária entre modelos puramente preditivos e sistemas totalmente autônomos de controle energético. Essa abordagem, portanto, estabelece uma base sólida e escalável para evoluções futuras rumo a aplicações reais mais completas.

Como perspectiva de trabalhos futuros, pretende-se realizar a incorporação de técnicas de ML com o objetivo de aprimorar a estimativa de consumo energético a partir do desempenho real do veículo na via. Essa abordagem permitirá que os modelos de consumo sejam continuamente ajustados com base em dados históricos e operacionais, considerando fatores como perfil de condução, topografia, condições de tráfego e comportamento dinâmico do veículo. A integração desses modelos ao DT tende a elevar o nível de fidelidade entre o ambiente simulado e a operação real, possibilitando estimativas mais precisas de autonomia e decisões energéticas mais robustas, reforçando o caráter adaptativo e preditivo do sistema proposto.

REFERÊNCIAS

- AL-WREIKAT, Y.; SERRANO, C.; SODRE, J. R. Driving behaviour and trip condition effects on the energy consumption of an electric vehicle under real-world driving. **Applied Energy**, v. 297, p. 117096, 2021. ISSN 0306-2619.
- AYAWLI, B. B. K. *et al.* An overview of nature-inspired, conventional, and hybrid methods of autonomous vehicle path planning. **Journal of Advanced Transportation**, 2018.
- BHATTI, G.; MOHAN, H.; Raja Singh, R. Towards the future of smart electric vehicles: Digital twin technology. **Renewable and Sustainable Energy Reviews**, v. 141, p. 110801, 2021. ISSN 1364-0321.
- BISWAS, A.; WANG, H.-C. Autonomous vehicles enabled by the integration of IOT, edge intelligence, 5G, and blockchain. **Sensors**, v. 23, n. 4, 2023. ISSN 1424-8220.
- CHEN, B. *et al.* The effects of autonomous vehicles on traffic efficiency and energy consumption. **Systems**, v. 11, n. 7, 2023. ISSN 2079-8954.
- CHOSSET, H. *et al.* **Principles of Robot Motion: Theory, Algorithms, and Implementations**. Cambridge, MA: MIT Press, 2005.
- COHEN, Y.; PILATI, F.; FACCIO, M. Digitization of assembly line for complex products – the digital nursery of workpiece digital twins. **IFAC-PapersOnLine**, v. 54, n. 1, p. 158–162, 2021. ISSN 2405-8963. 17th IFAC Symposium on Information Control Problems in Manufacturing INCOM 2021. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2405896321007229>>.
- CONSONNI, F. L. *et al.* **As cidades como protagonistas: políticas públicas de transição para a mobilidade elétrica**. São Paulo: Papagaio, 2024. 320 p. ISBN 978-65-89810-30-8.
- ELLILI, N. O. D. Bibliometric analysis on corporate governance topics published in the journal of corporate governance: The international journal of business in society. **Corporate Governance: International Journal of Business in Society**, v. 23, n. 1, p. 262–286, 2023. ISSN 1472-0701.
- GUZZELLA, L.; SCARRETTA, A. **Vehicle Propulsion Systems: Modeling and Optimization**. 2nd. ed. Berlin, Heidelberg: Springer, 2013.
- HARI, D. *et al.* Analysis of a driver behaviour improvement tool to reduce fuel consumption. In: **2012 International Conference on Connected Vehicles and Expo (ICCVE)**. [S.l.: s.n.], 2012. p. 208–213.
- HE, J. *et al.* Reinforcement learning for multi-item retrieval in the puzzle-based storage system. **European Journal of Operational Research**, v. 305, n. 2, p. 820–837, 2023. ISSN 0377-2217. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0377221722002661>>.
- HUA, S. *et al.* Optimality-guaranteed algorithms on the dynamic shared-taxi problem. **Transportation Research Part E: Logistics and Transportation Review**, v. 164, p. 102809, 2022. ISSN 1366-5545.
- INTERNATIONAL ENERGY AGENCY. **CO₂ Emissions from Fuel Combustion 2020**. Paris: IEA, 2020.

International Energy Agency. **Global EV Outlook 2024: Catching up with climate ambitions**. Paris, 2024. Acesso em: 02 abr. 2026. Disponível em: <<https://www.iea.org/reports/global-ev-outlook-2024>>.

KHAN, A. *et al.* A bibliometric review of finance bibliometric papers. **Finance Research Letters**, v. 47, p. 102520, 2022. ISSN 1544-6123.

KRITZINGER, W. *et al.* Digital twin in manufacturing: A categorical literature review and classification. **IFAC-PapersOnLine**, v. 51, n. 11, p. 1016–1022, 2018. ISSN 2405-8963. 16th IFAC Symposium on Information Control Problems in Manufacturing INCOM 2018. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2405896318316021>>.

KRYSIUK, C. Autonomous cars, development of modern transport technology. **Journal of Civil Engineering and Transport**, v. 3, p. 17–27, 2021.

LARMINIE, J.; LOWRY, J. **Electric vehicle technology explained**. [S.l.]: John Wiley & Sons, 2012.

LI, J.; DRIDI, M.; EL-MOUDNI, A. Multi-vehicles green light optimal speed advisory based on the augmented lagrangian genetic algorithm. In: **17th International IEEE Conference on Intelligent Transportation Systems (ITSC)**. [S.l.: s.n.], 2014. p. 2434–2439.

LI, Z. *et al.* Edge-assisted V2X motion planning and power control under channel uncertainty. **IEEE Transactions on Vehicular Technology**, IEEE, 2023.

LIU, X. *et al.* Recent advances in lithium-ion battery technologies and battery management systems for electric vehicles. **Renewable and Sustainable Energy Reviews**, v. 189, p. 113896, 2024.

MAGANA, V. C.; MUNOZ-ORGANERO, M. Gafu: Using a gamification tool to save fuel. **IEEE Intelligent Transportation Systems Magazine**, v. 7, n. 2, p. 58–70, 2015.

MIN, H. *et al.* An energy-efficient driving method for connected and automated vehicles based on reinforcement learning. **Machines**, v. 11, n. 2, 2023.

MIRI, I.; FOTOUHI, A.; EWIN, N. Electric vehicle energy consumption modelling and estimation—a case study. **International Journal of Energy Research**, Wiley Online Library, v. 45, n. 1, p. 501–520, 2021.

MISHRA, A. *et al.* Recent advancement in autonomous vehicle and driver assistance systems. In: **2023 IEEE International Students' Conference on Electrical, Electronics and Computer Science (SCEECS)**. [S.l.: s.n.], 2023. p. 1–5.

MORLOCK, F. *et al.* Forecasts of electric vehicle energy consumption based on characteristic speed profiles and real-time traffic data. **IEEE Transactions on Vehicular Technology**, IEEE, v. 69, n. 2, p. 1404–1418, 2019.

NANDA, A. *et al.* Internet of autonomous vehicles communications security: Overview, issues, and directions. **IEEE Wireless Communications**, v. 26, n. 4, p. 60–65, 2019.

NOREEN, M. T. M.; FOULADFAR, M. H.; SAEED, N. Evaluation of battery management systems for electric vehicles using traditional and modern estimation methods. **Network**, v. 4, n. 4, p. 586–608, 2024. ISSN 2673-8732.

ONAO LAPO, A.; ABE, B. Innovative feature analysis of electric vehicle technology, charging infrastructure, power management, and control methods. **WSEAS Transactions on Power Systems**, WSEAS, v. 19, p. 350–359, 2024.

PALI WAL, P. Improved artificial potential field method for motion-planning of autonomous vehicles. In: **2023 International Conference for Advancement in Technology (ICONAT)**. [S.l.: s.n.], 2023. p. 1–6.

PAN, C. *et al.* Energy-optimal adaptive cruise control strategy for electric vehicles based on model predictive control. **Energy**, v. 241, p. 122793, 2022. ISSN 0360-5442.

PIROMALIS, D.; KANTAROS, A. Digital twins in the automotive industry: The road toward physical-digital convergence. **Applied System Innovation**, v. 5, n. 4, 2022. ISSN 2571-5577.

REN, J.; HUANG, R.; GABBAR, H. The current trends of deep learning in autonomous vehicles: A review. **Journal of Engineering Research and Sciences**, v. 1, p. 56–68, 10 2022.

ROY, M. *et al.* Reliable energy consumption modeling for an electric vehicle fleet. In: **Proceedings of the 5th ACM SIGCAS/SIGCHI Conference on Computing and Sustainable Societies**. New York, NY, USA: Association for Computing Machinery, 2022. (COMPASS '22), p. 29–44. ISBN 9781450393478.

SAE. Taxonomy and definitions for terms related to driving automation systems for on-road motor vehicles. **SAE International**, 2021. Disponível em: <https://www.sae.org/standards/content/j3016_202104/>.

SAPUTRO, D. *et al.* Bibliometric analysis of neural basis expansion analysis for interpretable time series (n-beats) for research trend mapping. **BAREKENG: Jurnal Ilmu Matematika dan Terapan**, v. 17, n. 2, p. 1103–1112, Jun. 2023.

SCHULMAN, J. *et al.* **Proximal Policy Optimization Algorithms**. 2017. Disponível em: <<https://arxiv.org/abs/1707.06347>>.

THIBAUT, L.; NUNZIO, G. D.; SCARRETTA, A. A unified approach for electric vehicles range maximization via eco-routing, eco-driving, and energy consumption prediction. **IEEE Transactions on Intelligent Vehicles**, IEEE, v. 3, n. 4, p. 463–475, 2018.

TONG, W. *et al.* Artificial intelligence for vehicle-to-everything: A survey. **IEEE Access**, v. 7, p. 10823–10843, 2019.

WANG, X.; PARK, S.; HAN, K. Energy-efficient speed planner for connected and automated electric vehicles on sloped roads. **IEEE Access**, v. 10, p. 34654–34664, 2022.

XIU, Y. *et al.* Self-similar growth and synergistic link prediction in technology-convergence networks: The case of intelligent transportation systems. **Fractal and Fractional**, v. 7, n. 2, 2023.

YOU, J. *et al.* A systematic bibliometric review of low impact development research articles. **Water**, MDPI, v. 14, n. 17, p. 2675, 2022.

ZHANG, H. *et al.* Energy efficient path planning for autonomous ground vehicles with Ackermann steering. **Robotics and Autonomous Systems**, v. 162, p. 104366, 2023. ISSN 0921-8890.

ZHANG, Y. *et al.* Computational efficient motion planning method for automated vehicles considering dynamic obstacle avoidance and traffic interaction. **Sensors**, v. 22, n. 19, 2022. ISSN 1424-8220.

ZHANG, Z. *et al.* Energy consumption prediction of electric vehicles based on digital twin technology. **World Electric Vehicle Journal**, Multidisciplinary Digital Publishing Institute, v. 12, n. 4, p. 160, 2021.