



UNIVERSIDADE ESTADUAL PAULISTA
“JÚLIO DE MESQUITA FILHO”

Faculdade de Engenharia
Câmpus de Ilha Solteira

ANDRES LUIS SABILLON ANTUNEZ

**PLANEJAMENTO ÓTIMO DE INFRAESTRUTURA DE CARREGAMENTO DE
VEÍCULOS ELÉTRICOS INCLUINDO ANÁLISE ESPACIAL E CONSIDERANDO
MÚLTIPLOS PROPRIETÁRIOS**

Ilha Solteira
2025

ANDRES LUIS SABILLON ANTUNEZ

**PLANEJAMENTO ÓTIMO DE INFRAESTRUTURA DE CARREGAMENTO DE
VEÍCULOS ELÉTRICOS INCLUINDO ANÁLISE ESPACIAL E CONSIDERANDO
MÚLTIPLOS PROPRIETÁRIOS**

Dissertação apresentada à Faculdade de Engenharia
da Universidade Estadual Paulista – UNESP, Câmpus
de Ilha Solteira, como parte dos requisitos para a
obtenção do título de Mestre em Engenharia Elétrica.

Área de Conhecimento: Automação.

Orientador:

Prof. Dr. John Fredy Franco Baquero

Coorientador:

Dr. Mario Andrés Mejía Alzate

Ilha Solteira

2025

FICHA CATALOGRÁFICA

Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

S116p Sabillon Antunez, Andres Luis.
Planejamento ótimo de infraestrutura de carregamento de veículos elétricos incluindo análise espacial e considerando múltiplos proprietários / Andres Luis Sabillon Antunez. -- Ilha Solteira: [s.n.], 2025
78 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2025

Orientador: John Fredy Franco Baquero
Co-orientador: Mario Andres Mejia Alzate
Inclui bibliografia

1. Análise geoespacial. 2. Cadeias de Markov. 3. Eficiência energética. 4. Mobilidade elétrica. 5. Planejamento de estações de carregamento de veículos elétricos. 6. Otimização matemática multiobjetivo.


Amanda Sertori dos Santos

Bibliotecária - CRB/8-9061
Seção Técnica de Referência, Atendimento ao
Usuário e Documentação
Diretoria Técnica de Biblioteca e Documentação

IMPACTO POTENCIAL DESTA PESQUISA

A pesquisa proposta possui um impacto potencial significativo no avanço do planejamento urbano e da mobilidade sustentável, ao integrar métodos de modelagem matemática, análise espacial e lógica fuzzy para otimizar a localização e o dimensionamento de estações de carregamento de veículos elétricos (ECVEs). Ao considerar múltiplos proprietários de infraestrutura e utilizar dados reais de mobilidade, o modelo torna-se mais representativo da complexidade do ambiente urbano brasileiro, oferecendo uma ferramenta robusta para gestores públicos e investidores privados. Isso pode contribuir diretamente para a expansão eficiente da infraestrutura de recarga, promovendo a adoção de veículos elétricos e a redução de emissões nos centros urbanos..

POTENTIAL IMPACT OF THIS RESEARCH

The proposed research has significant potential impact on advancing urban planning and sustainable mobility by integrating mathematical modeling, spatial analysis, and fuzzy logic to optimize the location and sizing of electric vehicle charging stations (EVCSs). By accounting for multiple infrastructure owners and using real mobility data, the model becomes more representative of the complexity of the Brazilian urban environment, offering a robust tool for public managers and private investors. This can directly contribute to the efficient expansion of charging infrastructure, promoting the adoption of electric vehicles and reducing emissions in urban centers.



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Ilha Solteira

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: PLANEJAMENTO ÓTIMO DE INFRAESTRUTURA DE CARREGAMENTO DE VEÍCULOS ELÉTRICOS INCLUINDO ANÁLISE ESPACIAL E CONSIDERANDO MÚLTIPLOS PROPRIETÁRIOS

AUTOR: ANDRES LUIS SABILLON ANTUNEZ

ORIENTADOR: JOHN FREDY FRANCO BAQUERO

COORDENADOR: MARIO ANDRES MEJIA ALZATE

Aprovado como parte das exigências para obtenção do Título de Mestre em Engenharia Elétrica, área:
Automação pela Comissão Examinadora:

 Documento assinado digitalmente
JOHN FREDY FRANCO BAQUERO
Data: 04/03/2025 16:32:34-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. JOHN FREDY FRANCO BAQUERO (Participação Presencial)
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP

 Documento assinado digitalmente
JOEL DAVID MELO TRUJILLO
Data: 07/03/2025 07:28:28-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. JOEL DAVID MELO TRUJILLO (Participação Virtual)
Centro de Engenharia, Modelagem e Ciências Sociais / Universidade Federal do ABC - UFABC

 Documento assinado digitalmente
TAYENNE DIAS DE LIMA
Data: 05/03/2025 07:41:06-0300
Verifique em <https://validar.itl.gov.br>

Dra. TAYENNE DIAS DE LIMA (Participação Virtual)
Departamento de Engenharia Eletrotécnica / Instituto Superior de Engenharia do Porto - ISEP

Ilha Solteira, 28 de fevereiro de 2025

AGRADECIMENTOS

Gostaria de expressar minha profunda gratidão ao meu orientador, Prof. Dr. John Fredy Franco Baquero, pela orientação constante, pelos ensinamentos valiosos e pela confiança depositada ao longo de toda esta jornada. Sua dedicação, paciência e rigor acadêmico foram fundamentais para o desenvolvimento deste trabalho.

Agradeço também ao meu coorientador, Dr. Mario Andres Mejia Alzate, por suas contribuições técnicas imprescindíveis, pelas sugestões precisas e pelo apoio contínuo nas etapas mais desafiadoras da pesquisa. O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

À Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), pelo apoio financeiro, concedido por meio do Processo nº 409062/2023-5.

Dedico este trabajo

A mi familia, base de todo lo que soy.

En especial, a mi querido hermano Santiago, cuya ausencia física jamás apagará su eterna presencia en mi vida. Su recuerdo sigue siendo una fuente de fuerza e inspiración. A su esposa Claudia y a su hija Adriana, que continúan con valentía y amor su legado.

A mi hermano Carlos y a su esposa Julia, quienes me han acompañado de forma incondicional a lo largo de este camino de la maestría. Su apoyo, cercanía y aliento constante fueron fundamentales en los momentos más exigentes de esta etapa.

A mis padres Santiago y Mabel, por su dedicación incansable, por sus enseñanzas y por haber creído en mí incluso en los momentos más difíciles.

Y, con todo mi corazón, a mi esposa Katherine. Esta conquista es tan tuya como mía. Gracias por tu paciencia infinita, por tu fe en mí incluso cuando yo dudaba, por tu amor que sostiene, empuja y alienta. Tu presencia fue mi mayor fortaleza.

Sin ustedes, este camino no habría sido posible.

RESUMO

Para alcançar as metas de adoção de veículos elétricos (VEs), é fundamental desenvolver uma infraestrutura de carregamento robusta, que garanta soluções de recarga eficientes e acessíveis aos usuários. Este trabalho apresenta um método inovador, baseado em otimização matemática, para o planejamento ótimo de estações de carregamento de veículos elétricos (ECVEs), integrando análise espacial e considerando múltiplos proprietários dessa infraestrutura. O método proposto consta de três etapas. Na primeira etapa, a demanda energética dos VEs é estimada usando dados reais de mobilidade, levando em conta variações temporais e espaciais no uso dos VEs. Na segunda etapa, a identificação de locais potenciais para a instalação das ECVEs é realizada por meio de estudos geoespaciais e socioeconômicos, usando lógica fuzzy, para a classificação e priorização dos melhores candidatos. A terceira etapa permite determinar a localização e a capacidade ótima das ECVEs por meio de um modelo de programação linear inteira mista (MILP), que busca minimizar dois objetivos principais: a distância total percorrida pelos usuários até as ECVEs e os custos de investimento na construção dessa infraestrutura. Essa abordagem garante uma distribuição equitativa das ECVEs, equilibrando acessibilidade para os usuários e viabilidade econômica para os proprietários envolvidos. A eficácia do método proposto é validada por meio de simulações computacionais, demonstrando sua capacidade de lidar com os desafios complexos do planejamento da infraestrutura de carregamento de VEs. Os resultados evidenciam o potencial do método proposto em integrar diversos aspectos técnicos, econômicos e espaciais, contribuindo para soluções de mobilidade urbana sustentável. Além disso, a abordagem proposta se destaca por sua escalabilidade e adaptabilidade, permitindo sua aplicação a diferentes contextos e respondendo às crescentes demandas pelo desenvolvimento da infraestrutura de carregamento de VEs em escala global.

Palavras-chave: análise geoespacial; cadeias de Markov; eficiência energética; mobilidade elétrica; planejamento de estações de carregamento de veículos elétricos; otimização matemática multiobjetivo.

ABSTRACT

To achieve electric vehicle (EV) adoption goals, it is crucial to develop a robust charging infrastructure that ensures efficient and accessible recharging solutions for users. This study presents an innovative method, based on mathematical optimization, for the optimal planning of electric vehicle charging stations (EVCS), integrating spatial analysis and considering multiple infrastructure owners. The proposed method consists of three stages. In the first stage, the energy demand of EVs is estimated using real mobility data, accounting for temporal and spatial variations in EV usage. In the second stage, the identification of potential locations for EVCS installation is conducted through geospatial and socioeconomic studies, employing fuzzy logic for the classification and prioritization of the best candidates. The third stage determines the optimal location and capacity of EVCSs through a mixed-integer linear programming (MILP) model, aimed at minimizing two main objectives: the total distance traveled by users to reach the EVCSs and the investment costs in constructing this infrastructure. This approach ensures an equitable distribution of EVCSs, balancing user accessibility and economic feasibility for the involved owners. The effectiveness of the proposed method is validated through computational simulations, demonstrating its ability to address the complex challenges of EV charging infrastructure planning. The results highlight the potential of the proposed method to integrate various technical, economic, and spatial aspects, contributing to sustainable urban mobility solutions. Furthermore, the proposed approach stands out for its scalability and adaptability, enabling its application to different contexts and responding to the growing demands for the development of EV charging infrastructure on a global scale.

Keywords: geospatial analysis; Markov chains; energy efficiency; electric mobility; EV charging station planning; multi-objective mathematical optimization.

LISTA DE FIGURAS

Figura 1 – Trabalhos publicados por ano com abordagens semelhantes às apresentadas neste documento.	13
Figura 2 – Exemplo de três funções difusas de carácter triangular.	22
Figura 3 – Candidatos dentro da área 1 em relação ao centroide populacional	23
Figura 4 – Mapa de rotas de tráfego com maior tráfego na área 1	26
Figura 5 – Mapa da localização dos candidatos presentes na área 1 em relação ao centroide econômico.....	28
Figura 6 – Representação da cadeia de Markov.	37
Figura 7 – Probabilidade de carga associada à distância em relação a s_i, j	39
Figura 8 – Gráfica de distribuição de θ_i	40
Figura 9 – Curva comparativa horária de demanda energética de sistemas diferentes.	42
Figura 10 – Fluxograma do método de identificação de locais candidatos de ECVEs.	45
Figura 11 – Fluxograma do processo desenvolvido.	51
Figura 12 – Mapa da cidade de Presidente Prudente dividido por áreas.	52
Figura 13 – Classificação atribuída por áreas.....	53
Figura 14 – Mapa dos centroides populacionais de cada subárea de Presidente Prudente.	54
Figura 15 – Mapa dos centroides econômicos de cada subárea de Presidente Prudente.	54
Figura 16 – Mapa de rotas mais importantes de Presidente Prudente.	55
Figura 17 – Mapa da cidade do Presidente prudente.....	56
Figura 18 – Perfis de demanda de carregamento dos VEs.	58
Figura 19 – Resultados dos candidatos na avaliação do logica fuzzy.....	59
Figura 20 – Fronteira de Pareto para alocação de ECVEs	60
Figura 21 – Mapa de calor dos critérios avaliados.	61
Figura 22 – Resultados do modelo de otimização.....	62

LISTA DE TABELAS

Tabela 1 – Candidatos presentes	55
Tabela 2 – Potenciais novos agentes	57
Tabela 3 – Tamanho dos potenciais agentes presentes.....	57

LISTA DE SÍMBOLOS

α	Parâmetro de combinação convexa que atribui a importância aos objetivos de investimento e distância.
α_r	Grau de pertencimento das variáveis econômicas associadas às funções fuzzy para o critério econômico
$\beta_{z,j}^{den}$	Possibilidade de que um veículo elétrico (VE) da área z seja carregado na área j em relação à densidade de VEs naquela área.
$\beta_{z,j}^{dis}$	Possibilidade de que um VE que pertence à área z seja carregado na área j em relação à distância a percorrer.
$\beta_{p,z}$	Demanda absorvida pela estação de carregamento (ECVE) p da área z .
γ_p	Quantidade de carregadores instalados na ECVE p .
$\bar{\gamma}$	Máximo de carregadores que podem ser instalados numa ECVE
δ_r	Grau de pertencimento para a função de dependência.
δ_t	Tempo de espera para um VE ser carregado numa ECVE.
δ_{max}	Tempo máximo de espera permitido para um VE ser carregado.
Δt	Duração de um período.
θ_z	Fator de ponderação da quantidade de VEs que pertencem à área z .
μ_z^{inst}	Quantidade de ECVE instaladas na área z .
μ_z^{cand}	Quantidade de locais candidatos para a instalação de ECVE na área z .
ρ_r	Grau de pertencimento das variáveis econômicas associadas às funções fuzzy para o critério econômico.
$\sigma_{z,j}$	Possibilidade de que um VE da área z seja carregado na área j .
$\tau_{e,\alpha}$	Valor correspondentes as funções fuzzy para o critério econômico.
$\tau_{e,\rho}$	Valor correspondentes as funções fuzzy para o critério econômico.
$\tau_{d,\delta}$	Valor calculado para a função de dependência.
φ^{ve}	Possibilidade de adoção dos VEs.
ω_i	Peso assinado a cada critério dentro do método.
A_z^{ad}	Parcela dos habitantes da área z candidatos para comprar um VE.

b_n	Limites dentro dos conjuntos fuzzy em relação a centroide econômico.
C^{ve}	Valor médio de energia de carregamento dos VEs.
CF	Custo de instalação de uma ECVE.
$d_{z,k}$	Distância entre o centroide da área z e o local de carregamento k .
D	Valor final para o critério de dependência na rede.
$D_{z,p}$	Distância entre o centroide da área z e a ECVE p .
d_n	Limites dentro dos conjuntos fuzzy em relação a centroide populacional.
E	Valor final para o critério econômico.
$E_{p,t}^{Dis}$	Energia deslocada ou não atendida por um carregador p no período t .
$F_{z,t}$	Quantidade de VEs da área z no período t após o processo de deslocamento.
G	Valor final para o critério geoespacial de cada candidato.
H_z^{leg}	Quantidade de habitantes da área z autorizados para possuir um VE.
h_n	Limites dentro dos conjuntos fuzzy em relação a distância.
L	Matriz de decisão de carregamento dos VEs na área z .
l_i	Limites dentro dos conjuntos fuzzy em relação a robustez econômica.
m_z	Número de ECVE na área z .
n	Número de áreas em que a cidade é dividida.
N_z^{ve}	Número de VEs na área z .
N_{ca}	Valor dos candidatos dentro dos conjuntos fuzzy em relação a dependência do candidato da rede elétrica.
p	Índice de ECVE na área z .
p^c	Valor dos candidatos dos conjuntos fuzzy em relação ao centroide econômico.
p_z	Fator de afastamento das ECVE na área z .
p^d	Matriz de perfis de demanda de carregamento dos VEs.
$p_{p,t}^d$	Potência demandada num carregador p em um período t .
p_{max}^p	Potência máxima de um carregador de VEs.

$\bar{p}^{PL}$	Limite máximo de potência de uma ECVE.
$p_{p,t}^{PL}$	Potência do carregador p no período t .
p^{ve}	Potência de um VE.
q	Valor dos candidatos dos conjuntos fuzzy em relação ao centroide econômico.
$s_{z,j}$	Distância entre o centroide da área z e a ECVE de uma área j .
s	Valor dos candidatos dos conjuntos fuzzy em relação ao tráfego.
t_n	Limites dentro dos conjuntos fuzzy em relação ao tráfego.
V	Valor final de cada candidato no processo fuzzy.
W	Custo de instalação para cada carregador.
X_p	Variável binária de decisão de instalação de uma ECVE.
z	Índices de áreas.
z_n	Limites dentro dos conjuntos fuzzy em relação a dependência do candidato da rede elétrica.

SUMÁRIO

1	INTRODUÇÃO	11
1.1	REVISÃO DA LITERATURA	13
1.2	OBJETIVOS	16
1.3	CONTRIBUIÇÕES	17
1.4	ESTRUTURA DO DOCUMENTO	18
2	CONCEITOS BÁSICOS E FUNDAMENTOS TEÓRICOS.....	19
2.1	ANÁLISE ESPACIAL	19
2.2	LOGICA FUZZY	21
2.2.1	Critérios de postulação de localidades.....	21
2.2.2.1	Critério geoespacial	22
2.2.2.2	Critério econômico	27
2.2.2.3	Critério de dependência	31
2.2.2	Atribuição de graus de adesão e cálculo de valores finais	32
3	MÉTODO PROPOSTO PARA O PROBLEMA DE ALOCAÇÃO E DIMENSIONAMENTO.....	34
3.1	OTIMIZAÇÃO MATEMÁTICA.....	34
3.2	ETAPA 1. ESTIMAÇÃO DOS PERFIS DE DEMANDA DOS VES.....	35
3.2.1	Compradores potenciais de VEs	36
3.2.2	Perfis de demanda dos VEs.....	36
3.2.3	Probabilidades dos estados da cadeia de Markov	38
3.2.4	Matriz de decisão dos usuários de VEs.....	41
3.3	ETAPA 2. IDENTIFICAÇÃO DE LOCAIS CANDIDATOS PARA A INSTALAÇÃO DE ECVES.....	43
3.3.1	Identificação de locais candidatos	44
3.3.2	Seleção de locais candidatos.....	44
3.4	ETAPA 3. DIMENSIONAMENTO E ALOCAÇÃO ÓTIMA DAS ECVES	46

3.4.1	Função objetivo.....	46
3.4.2	Restrições para a instalação de ECVEs.....	47
3.4.3	Abordagem de solução multiobjetivo.....	48
4	RESULTADOS	52
4.1	RESULTADOS DA ETAPA 1.....	57
4.2	RESULTADOS DA ETAPA 2.....	58
4.3	RESULTADOS DA ETAPA 3.....	59
4.4	DISCUSSÕES	62
4.5	LIMITAÇÕES DO MÉTODO PROPOSTO.....	63
5	CONCLUSÕES.....	65
	REFERÊNCIAS.....	68
	APÊNDICE – Trabalhos Desenvolvidos durante o Mestrado.....	75

1 INTRODUÇÃO

Os veículos elétricos (VEs) estão promovendo uma revolução na mobilidade urbana, com impactos positivos na preservação ambiental. Ao substituir os veículos movidos a combustíveis fósseis, os VEs desempenham um papel crucial na redução das emissões de poluentes atmosféricos (Alarcón *et al.*, 2023). Isso não só melhora a qualidade do ar, mas também contribui para mitigar as mudanças climáticas e impulsionar a transição para uma matriz energética mais limpa e sustentável (Semaria; Espinosa, 2019). Além disso, dependendo das fontes de energia utilizadas para carregar as baterias, os benefícios ambientais dos VEs podem ser ainda mais expressivos.

Apesar dessas vantagens, a adoção generalizada dos VEs enfrenta desafios significativos. Por um lado, a falta de conscientização da população sobre seus benefícios e os custos iniciais mais elevados afetam a decisão de compra (Pamidimukkala *et al.*, 2024). Por outro lado, as preocupações com a autonomia dos VEs, devido à escassez de estações de recarga pública, constituem uma barreira relevante para sua disseminação (Krishna, 2021). Portanto, a instalação de eletropostos públicos torna-se essencial para promover a adoção em massa de VEs e viabilizar a transição para um sistema de transporte mais sustentável.

A heterogeneidade na adoção de VEs traz consigo vários desafios para o planejamento de estações de carregamento de veículos elétricos (ECVEs) (Chen *et al.*, 2012). A ausência de padrões claros na adoção de VEs, respeito a quantidades e localizações, dificulta a previsão das necessidades de carregamento dos VEs nas diferentes subáreas de uma cidade (Pagany *et al.*, 2019).

Como resultado, algumas ECVEs podem ser subutilizadas enquanto outras podem enfrentar sobrecarga. Para lidar com esse problema, a análise geoespacial surge como uma ferramenta eficaz. Ao mapear a densidade populacional e os potenciais compradores de VEs, ela ajuda a identificar áreas com alta demanda e permite guiar os investimentos em ECVEs de forma eficiente (Faustino *et al.*, 2023). Essa abordagem possibilita a otimização da localização e do tamanho apropriado das ECVEs, facilitando uma transição adequada para a mobilidade elétrica. A disponibilidade de ECVEs é crucial para garantir que a adoção de VEs ocorra de forma ampla e sustentável. Por um lado, a distribuição geográfica dessas estações deve ser estrategicamente planejada para atender às demandas energéticas de uma frota em expansão, evitando congestionamentos e garantindo a conveniência para os usuários (Garau; Torsater, 2021a). Por outro lado, é necessário equilibrar os custos de instalação e operação dessas estações com a viabilidade econômica e as limitações orçamentárias de investidores e

autoridades locais. Essa dualidade evidencia a necessidade de ferramentas robustas que auxiliem no planejamento integrado e na otimização dessa infraestrutura.

O planejamento de ECVes é, por natureza, um problema multidimensional. Ele envolve aspectos técnicos, como a capacidade de fornecimento energético e a conectividade com a rede elétrica; geoespaciais, como a proximidade a polos de tráfego intenso e a acessibilidade para diferentes perfis de usuários; e socioeconômicos, como a viabilidade de instalação em áreas com diferentes níveis de renda e densidade populacional (Jawad; Liu, 2023). Além disso, a imprevisibilidade da demanda futura adiciona um elemento de incerteza que é abordado por meio de modelos que incorporam métodos de análise robustos, como a lógica fuzzy e a simulação probabilística (Park *et al.*, 2019).

Diante do exposto, este estudo propõe uma abordagem integrada que combina estimativas de perfis de demanda energética, análises geoespaciais e socioeconômicas, além de técnicas de lógica fuzzy para classificar e priorizar locais candidatos à instalação de estações de recarga. A identificação e a seleção desses locais são complementadas por um modelo de programação linear inteira mista (PLIM), projetado para otimizar a alocação e o dimensionamento das estações com base em dois objetivos principais: minimizar as distâncias entre as estações e reduzir os custos de investimento. Essa abordagem integrada não apenas aspectos técnicos e econômicos, mas também fatores sociais e espaciais, tornando o modelo flexível e adaptável a diferentes contextos urbanos e regionais.


Os resultados obtidos em um estudo de caso detalhado demonstram a aplicabilidade e a relevância da metodologia proposta. O modelo identifica locais estratégicos para a instalação de estações de recarga, atendendo às necessidades dos usuários de forma eficiente e econômica, ao mesmo tempo que promove a equidade no acesso à infraestrutura. Além disso, os critérios e métodos utilizados oferecem uma base metodológica sólida, que pode ser adaptada para atender às demandas específicas de diferentes cidades e regiões.

Em um contexto no qual a mobilidade elétrica desempenha um papel cada vez mais central nas políticas de planejamento urbano e ambiental, a contribuição deste estudo destaca-se por propor uma solução abrangente e escalável para um problema de relevância global. A combinação de métodos avançados de análise com uma abordagem prática e orientada para resultados posiciona este trabalho como um marco no planejamento de infraestrutura de recarga de VEs, fornecendo uma base sólida para futuras pesquisas e aplicações práticas.

1.1 REVISÃO DA LITERATURA

A abordagem multiagente em redes elétricas não é um tema novo na literatura existente; na verdade, há uma ampla gama de documentos que abordam agentes em diversas estratégias dentro do mercado energético. Neste vasto conjunto de informações, observa-se que os fornecedores de energia renovável em larga escala estão emergindo como os principais participantes destinados a dominar o mercado no futuro próximo (Gao *et al.*, 2021). A Figura 1 apresenta uma comparação do trabalho com abordagens de planejamento de ECVE semelhantes às apresentadas neste trabalho.

Figura 1 – Trabalhos publicados por ano com abordagens semelhantes às apresentadas neste documento.



Fonte: Alarcón *et al.*, 2023.

Projeta-se que este mercado emergente seja capaz de operar sob a influência contínua de tecnologias emergentes. Essas tecnologias permeiam todos os níveis do mercado, transformando até mesmo os consumidores em agentes ativos. Entre esses diversos agentes, destacam-se os VEs, que por si só representam um setor ambicioso e crucial para os próximos anos (Sharma *et al.*, 2015).

Em um mercado relativamente emergente como o dos VEs, há uma diversidade de partes interessadas envolvidas em seu desenvolvimento (Falvo *et al.*, 2022). De um lado, destaca-se o submercado de fabricação de VEs, que engloba as empresas fabricantes desses veículos, seus fornecedores de insumos e os agentes responsáveis pela distribuição, além dos usuários finais.

Por outro lado, encontra-se o submercado das entidades ou agentes que fornecerão energia para esses VEs. Este grupo inclui empresas geradoras de energia, entidades reguladoras, ECVEs, agentes técnicos e instaladores, entre outros (Radu *et al.*, 2019).

A literatura sobre o planejamento de ECVEs tem evoluído com a aplicação de diferentes métodos que buscam otimizar o uso da infraestrutura existente e direcionar o investimento em novos pontos de carregamento. Entre as principais abordagens, destacam-se os modelos de otimização matemática, que visam minimizar os custos associados à instalação de ECVEs e maximizar a cobertura da rede, assegurando que os pontos de recarga sejam adequados para os padrões de demanda e o comportamento dos usuários (Karmaker *et al.*, 2023).

Esses modelos são fundamentais, pois buscam identificar a localização mais eficiente de ECVEs, levando em consideração o custo de instalação e manutenção, bem como a proximidade das estações com áreas de alta demanda. Diferentemente de abordagens heurísticas ou baseadas apenas em critérios empíricos, a otimização matemática permite explorar um grande número de combinações possíveis e identificar soluções que minimizem custos e maximizem a cobertura da demanda de forma sistemática e eficiente. Dessa forma, contribui para o planejamento de redes de carregamento que atendam melhor às necessidades dos usuários (Kumar *et al.*, 2024).

As limitações dos modelos tradicionais de otimização incluem a falta de flexibilidade para lidar com as dinâmicas e incertezas das áreas urbanas e a falta de integração entre dados espaciais e socioeconômicos (Ehsan ali; Yang Qiang, 2019). Embora muitos estudos se concentrem em otimizar a localização das ECVEs, considerando apenas critérios técnicos e de custo, não dão importância aos fatores como a diversidade econômica das regiões e as preferências dos usuários locais, que podem afetar diretamente a eficácia e a aceitação dos ECVEs (Viswanath *et al.*, 2022).

A falta de uma abordagem holística pode resultar em uma alocação subótima de recursos e na subestimação das necessidades reais da população, comprometendo a adoção em massa de VEs e a eficácia da infraestrutura de carregamento (Romero *et al.*, 2003). Nesse contexto, uma abordagem holística refere-se a um modelo que considera de forma integrada múltiplos fatores que influenciam a viabilidade da infraestrutura de recarga, incluindo aspectos técnicos, econômicos, sociais e espaciais. Por exemplo, a adoção de VEs depende não apenas da disponibilidade de eletropostos, mas também de fatores socioeconômicos, como a renda e o acesso à informação, que influenciam o comportamento dos consumidores na escolha de adotar essa tecnologia (Smith, 2022).

A integração de todos esses elementos no mercado de VEs tem sido tema de diversas abordagens ao longo do tempo, desde estratégias que visam o bem-estar da rede e seu planejamento adequado até aquelas que priorizam a reestruturação e o impacto econômico. (Illing; Warweg, 2015). O comportamento desses agentes é outro aspecto que impacta diretamente o mercado de VEs (Wang *et al.*, 2020). Na literatura, existem abordagens que promovem a inclusão desses agentes de forma gradual, começando pela transição do planejamento centralizado para uma abordagem descentralizada (Jiawei Zhang *et al.*, 2018). Essas abordagens consideram o impacto das decisões desses agentes na rede elétrica, destacando a importância de compreender como suas ações podem influenciar o sistema de maneira integrada e eficiente (Sharma *et al.*, 2015).

De acordo com o impacto desses agentes na rede, seu comportamento pode ser classificado como cooperativo ou competitivo (Weckx *et al.*, 2014). Dentro de uma abordagem competitiva, esses agentes baseiam suas ações e decisões em estratégias que consideram tanto os aspectos da rede elétrica quanto os do mercado consumidor (Gao *et al.*, 2021). Por outro lado, em uma abordagem cooperativa, a colaboração entre agentes pode permitir a otimização de recursos e a mitigação de desafios técnicos. Independentemente da abordagem adotada, os agentes terão sempre a relação custo-benefício como prioridade em todas as suas decisões. Nesse contexto, diversas estratégias de investimento foram propostas nos últimos anos para enfrentar as dificuldades técnicas e econômicas associadas à instalação e gestão de ECVEs (Bagheri Tookanlou *et al.*, 2020).

Uma das vantagens do planejamento multiagente cooperativo é a coordenação entre os agentes, garantindo que o sistema opere dentro dos limites de segurança, reduzindo os custos de fornecimento de energia e atendendo à demanda dos usuários (Yan *et al.*, 2022). Neste tipo de planejamento, é comum desenvolver um sistema hierárquico entre os agentes, onde os agentes no topo da hierarquia atuam como controladores de demanda, enquanto os agentes em níveis hierárquicos inferiores se encarregam de satisfazer as necessidades dos usuários (Saner *et al.*, 2022).

Múltiplas abordagens têm sido propostas para lidar com os desafios do planejamento de ECVEs (Falvo *et al.*, 2022). Esses métodos incluem modelos de otimização para o dimensionamento apropriado de ECVEs (Lili Gong *et al.*, 2017), análise de dados geoespaciais para identificar a localização ótima para ECVEs (Jidong Wang *et al.*, 2015), algoritmos de gestão de carga para otimizar o carregamento dos VEs conforme a demanda e capacidade da rede (Oliynyk *et al.*, 2020), bem como técnicas de planejamento urbano que integram as ECVEs no desenho de cidades inteligentes e sustentáveis (Zhiyong *et al.*, 2014).

Embora na literatura científica existem propostas para abordar o planejamento de ECVEs, não foram encontrados trabalhos que abordem simultaneamente a minimização dos custos de investimento e a minimização das distâncias entre a origem das cargas e as ECVEs (Ni; Lo, 2020). É vital abordar ambos os aspectos no planejamento da infraestrutura de carregamento, dado que, a minimização dos custos de investimento garante a viabilidade econômica do projeto, enquanto a minimização das distâncias entre a origem das cargas e as ECVEs promove a conveniência e a acessibilidade para os usuários. Essa abordagem integrada contribui para a aceitação dos VEs (DaviS; Edwards, 2021).

Apesar dos avanços significativos na pesquisa sobre VEs e seu impacto no setor de transporte, persistem várias lacunas na literatura que precisam ser abordadas para alcançar um correto dimensionamento e alocação de ECVEs.

Em primeiro lugar, a interação de diferentes agentes dentro do mercado de VEs, como fabricantes, fornecedores de energia, estações de recarga e consumidores, ainda não foi explorada de maneira exaustiva (Yusuf *et al.*, 2022). A literatura atual tem se concentrado principalmente em modelos isolados desses agentes, sem considerar adequadamente a dinâmica complexa e cooperativa que poderia otimizar tanto a infraestrutura de recarga quanto a adoção de VEs.

Adicionalmente, a pesquisa existente não aborda de maneira integral o impacto econômico da transição para VEs. Especificamente, faltam estudos detalhados sobre os custos associados à infraestrutura de recarga e como esses podem ser mitigados por meio de economias de escala e políticas de incentivo. A promoção da aquisição de VEs também precisa ser explorada mais a fundo, especialmente em termos de como as políticas governamentais e os programas de subsídios podem influenciar diferentes segmentos da população (Olinyk *et al.*, 2020).

Embora a literatura atual forneça uma base sólida, é essencial aprofundar nessas áreas para facilitar uma adoção mais eficaz e eficiente dos VEs e garantir uma infraestrutura de recarga bem dimensionada e estrategicamente localizada.

1.2 OBJETIVOS

O objetivo principal desse trabalho é desenvolver um modelo de otimização matemática para o planejamento de infraestrutura de carregamento de VEs incluindo análise espacial e considerando a coexistência de múltiplos proprietários para a infraestrutura de carregamento. Para atingir este objetivo, propõe-se desenvolver estratégias específicas que

abordem tanto os aspectos técnicos quanto as dinâmicas relacionadas aos diferentes proprietários envolvidos. Nesse contexto, os objetivos específicos são:

- Realizar um levantamento bibliográfico dos métodos propostos para o planejamento da infraestrutura de carga de VEs, identificando as abordagens existentes e suas limitações;
- Desenvolver um algoritmo baseado em cadeias de Markov para estimar a demanda energética dos VEs, utilizando dados reais de mobilidade e considerando as variações temporais e espaciais no uso desses veículos;
- Propor um método para identificar locais potenciais para a instalação de ECVEs, utilizando estudos geoespaciais e socioeconômicos, aliado à aplicação de lógica fuzzy para classificar e priorizar os melhores locais candidatos;
- Desenvolver uma formulação matemática para determinar a localização e a capacidade ótimas das ECVEs, utilizando PLIM com o objetivo de minimizar a distância total percorrida pelos usuários até as estações e os custos de investimento na infraestrutura de recarga.
- Validar o modelo proposto por meio de um estudo de caso, aplicando-o a dados reais de uma cidade brasileira de porte médio e avaliando os resultados obtidos em termos de eficiência e viabilidade.

1.3 CONTRIBUIÇÕES

As principais contribuições desse trabalho são:

- Um algoritmo baseado em cadeias de Markov para estimar a demanda energética dos VEs, utilizando dados reais de mobilidade e levando em consideração as variações temporais e espaciais no uso desses veículos;
- Um método para a identificação de locais potenciais para a instalação de ECVEs, realizado por meio de estudos geoespaciais e socioeconômicos. O método aplica lógica fuzzy para classificar e priorizar os melhores locais candidatos;
- Um modelo matemático para determinar a localização e capacidade ótimas das ECVEs, utilizando programação linear inteira mista, com o objetivo de minimizar a distância total percorrida pelos usuários até as estações e os custos de investimento necessários para a construção dessa infraestrutura.

1.4 ESTRUTURA DO DOCUMENTO

Este documento está organizado em cinco capítulos, conforme detalhado a seguir:

O capítulo 1 apresenta a introdução, que é dividida em quatro subseções: a primeira trata da revisão bibliográfica, seguida pelos objetivos da pesquisa, pelas contribuições do trabalho e, por fim, pela estrutura do documento.

O capítulo 2 descreve os conceitos básicos e os fundamentos teóricos utilizados para a construção desta dissertação. Apresenta conceitos sobre análise espacial, os fundamentos teóricos das cadeias de Markov, logica fuzzy e otimização matemática.

O capítulo 3 detalha o método proposto para a alocação e dimensionamento ótimo das ECVEs. Nessa seção, são discutidos, em subseções, cada uma das etapas que compõem o método proposto: a construção dos perfis de carga de VEs, a identificação dos locais candidatos para a instalação de ECVEs, assim como a função objetivo e o conjunto de restrições do modelo de otimização utilizadas para atingir eficientemente os objetivos estabelecidos.

O capítulo 4 apresenta os resultados do estudo de caso, que aplica o método proposto a dados de uma cidade brasileira de porte médio.

O capítulo 5 expõe as conclusões e sugere direções para trabalhos futuros com base nos resultados obtidos neste estudo.

2 CONCEITOS BÁSICOS E FUNDAMENTOS TEÓRICOS

Este capítulo apresenta os conceitos básicos e os fundamentos teóricos utilizados para desenvolver o método proposto nesta dissertação de mestrado. São abordadas as principais ferramentas e técnicas que sustentam a pesquisa, incluindo a análise espacial, que permite entender a distribuição geográfica dos dados, para modelagem de processos estocásticos; a lógica fuzzy, que lida com a imprecisão e incerteza; e a otimização matemática, aplicada para encontrar soluções eficientes e balanceadas. Esses conceitos são integrados para propor um modelo robusto no dimensionamento e alocação de ECVEs.

2.1 ANÁLISE ESPACIAL

A análise espacial é uma área da geografia e das ciências espaciais que se ocupa do estudo e interpretação dos dados geográficos, levando em conta a localização, a distribuição e a relação entre diferentes fenômenos no espaço. Ela utiliza métodos e técnicas estatísticas, matemáticas e computacionais para examinar padrões espaciais e determinar como fatores geográficos e ambientais influenciam a distribuição de determinados eventos ou elementos em uma área geográfica. A análise espacial é fundamental para resolver problemas que envolvem a gestão do território, a infraestrutura urbana, os recursos naturais e outros aspectos do espaço físico (Mahmoudi; Ruppert Filho, 2021a).

No contexto das cidades e das redes de transporte, a análise espacial é especialmente útil para entender como a disposição geográfica dos elementos impacta o funcionamento de sistemas urbanos complexos, como a distribuição de ECVEs. Esse tipo de análise envolve o uso de dados geoespaciais, como mapas de infraestrutura viária, densidade populacional, dados demográficos e informações sobre a mobilidade urbana. Com isso, é possível identificar padrões e relações entre as variáveis geográficas e as necessidades dos usuários de VEs, ajudando no planejamento eficiente e na alocação estratégica dessas estações de carregamento (Ying Lu *et al.*, 2018).

A análise espacial oferece uma série de ferramentas que podem ser aplicadas ao processo de dimensionamento e alocação de ECVE, ajudando a otimizar o uso dos recursos disponíveis e atender da melhor forma possível à demanda dos usuários. Algumas das principais formas de aplicar a análise espacial nesse contexto incluem:

- **Identificação de áreas com alta demanda:** A análise espacial permite examinar a distribuição geográfica de veículos elétricos, identificando áreas com maior concentração de usuários ou pontos de alta circulação. Ao combinar

dados de tráfego, densidade populacional e localização de pontos comerciais e residenciais, é possível identificar locais onde a demanda por estações de carregamento será maior, facilitando a localização de pontos estratégicos para sua instalação.

- **Otimização da cobertura de serviço:** Um dos principais objetivos da alocação de estações de carregamento é garantir que os motoristas de VEs possam acessar facilmente um ponto de carregamento. A análise espacial ajuda a determinar a melhor maneira de distribuir as estações de forma que a cobertura geográfica seja maximizada, garantindo que as estações sejam acessíveis em um intervalo razoável de distância. Isso pode ser feito através da análise de redes de ruas e avenidas, identificando os melhores locais de instalação para otimizar o acesso.
- **Modelagem da acessibilidade e tempos de espera:** A análise espacial também pode ser aplicada para modelar a acessibilidade dos usuários às estações de carregamento e o tempo de espera necessário para carregar o veículo. Usando algoritmos de rede de transporte, é possível estimar os tempos de deslocamento até as estações de carregamento em diferentes pontos da cidade e ajustar a localização das estações para reduzir esses tempos, otimizando a experiência do usuário.
- **Planejamento e simulação de cenários:** Outra aplicação da análise espacial no dimensionamento e alocação de estações de carregamento é a simulação de diferentes cenários de crescimento da frota de veículos elétricos e da demanda por estações de carregamento. A partir de modelos espaciais, é possível prever como a distribuição de VEs e a demanda por carregamento mudará ao longo do tempo, permitindo um planejamento de longo prazo mais eficaz.

Em resumo, a análise espacial é uma ferramenta essencial para o planejamento e dimensionamento de redes de estações de carregamento de veículos elétricos, permitindo otimizar a alocação dessas estações com base em dados geográficos e operacionais. Isso contribui para uma rede de carregamento mais eficiente, acessível e economicamente viável, que atenda melhor às necessidades dos motoristas de VEs e incentive a transição para a mobilidade elétrica (Garau; Torsater, 2021).

2.2 LÓGICA FUZZY

A lógica fuzzy, ou lógica difusa, é uma abordagem matemática que lida com a imprecisão e a incerteza, permitindo representar variáveis que não são estritamente verdadeiras ou falsas, mas sim com valores intermediários. Ao contrário da lógica clássica, que opera com valores binários (verdadeiro ou falso), a lógica fuzzy utiliza graus de verdade, variando entre 0 e 1, o que permite modelar problemas mais próximos à realidade, onde as informações podem ser vagas ou imprecisas (Lazaroiu *et al.*, 2020). No contexto da identificação de locais para a instalação de ECVEs, a lógica fuzzy pode ser extremamente útil. Ao usar critérios espaciais, como a proximidade de rodovias, centros urbanos e zonas de alta circulação, e critérios econômicos, como o custo de instalação e o retorno sobre investimento, a lógica fuzzy pode processar essas variáveis de forma mais flexível (Garcia-Trivino *et al.*, 2016).

Por exemplo, em vez de determinar um local como “adequado” ou “inadequado”, o sistema pode atribuir uma pontuação fuzzy com base em diferentes combinações de fatores. Isso possibilita uma avaliação mais completa e realista, levando em conta a variabilidade dos dados e as diferentes prioridades envolvidas, e ajudando a escolher os melhores locais para a instalação das estações de forma otimizada e eficiente.

2.2.1 Critérios de postulação de localidades

A literatura existente aborda essa problemática de diversas maneiras. Entre as abordagens populares, destacam-se aquelas que utilizam métodos semelhantes aos aplicados na localização de sistemas de energias renováveis (Aydin *et al.*, 2013) bem como as que se baseiam na seleção de locais para agricultura biológica (Karaşan *et al.*, 2020). Outra abordagem relevante envolve a aplicação de programação linear inteira e lógica fuzzy, utilizando funções de pertinência triangulares (Wan *et al.*, 2019).

O mercado de ECVEs refere-se ao setor em que diferentes agentes, como operadoras de infraestrutura de carregamento e fornecedores de energia, competem pela instalação e operação de pontos de carregamento para veículos elétricos.


A abordagem proposta neste trabalho promove uma livre postulação, onde qualquer entidade pode se inscrever como candidata para a instalação de ECVEs. Cada postulante que pretenda candidatar-se neste mercado deverá atender a três critérios definidos nesta seção. Esses critérios visam equilibrar as oportunidades de todos os candidatos, além de fortalecer suas principais vantagens competitivas.

2.2.2.1 Critério geoespacial

Sob a perspectiva de uma análise de mercado, torna-se evidente que a localização de uma ECVE deve ser escolhida estrategicamente, considerando o fluxo de veículos. O principal desafio nessa questão reside na dificuldade de aplicar essas abordagens no mundo real (Garcia-Trivino *et al.*, 2016b). Considerando as abordagens na literatura, foram desenvolvidas duas funções de pertinência triangulares, classificando três conjuntos fuzzy em cada uma delas: Próximo, Médio e Distante, em relação ao centroide da população exemplificado na

Figura 2.

Figura 2 – Exemplo de três funções difusas de carácter triangular.



Fonte: Elaborado pelo autor.

Função de dependência triangular em relação ao centroide da população. Esta função de dependência triangular relaciona a localização de cada candidato com o centroide populacional. Seu objetivo é classificar os candidatos com base na exposição de usuários de VEs que não realizam trajetos próximos ao candidato, considerando que suas rotinas estão mais concentradas ao redor do centroide populacional.

Esta função de dependência triangular é particularmente relevante no contexto do planejamento de ECVEs, pois permite priorizar candidatos situados em áreas de maior densidade populacional, alinhadas com o centroide da região. Essa abordagem reflete a dinâmica das atividades humanas, concentradas em torno do centroide populacional, onde a demanda potencial por ECVEs tende a ser mais elevada. Assim, a função desempenha um papel fundamental ao identificar candidatos que oferecem maior acessibilidade e conveniência aos usuários de VEs.


Adicionalmente, a aplicação desta função possibilita diferenciar candidatos localizados em áreas periféricas ou afastadas do centroide populacional, mas que ainda desempenham um papel relevante no sistema. A forma triangular da função permite atribuir

valores graduais, reconhecendo a importância de candidatos que atendem a rotas ou fluxos específicos, mesmo que não estejam em proximidade imediata ao centroide. Essa abordagem assegura que as localidades com potencial estratégico sejam consideradas no processo de seleção.

Por fim, ao incorporar a função de dependência triangular, é possível realizar uma avaliação mais justa e equilibrada, considerando tanto a densidade populacional quanto a conectividade geográfica. Essa análise detalhada contribui para um planejamento mais inclusivo, garantindo que regiões de menor densidade populacional ou com características particulares de deslocamento não sejam excluídas do sistema. Dessa forma, a função reforça a robustez do método proposto, promovendo uma infraestrutura de carregamento que atende às necessidades reais dos usuários de VEs. A

Figura 3 ilustra a posição dos candidatos dentro da área 1 em relação ao centroide populacional.

Figura 3 – Candidatos dentro da área 1 em relação ao centroide populacional



Fonte: Elaborado pelo autor.

Para calcular a distância da localização de cada candidato ao centroide populacional d_{cp} , e garantir o percurso mínimo, foram utilizadas diferentes ferramentas de geolocalização.

Os limites dentro dos conjuntos fuzzy são definidos através de percentis. O cálculo destes percentis é calculado conforme detalhado em (1). Essa estratégia permite estabelecer os limites dos conjuntos fuzzy considerando todos os candidatos na área de estudo, proporcionando uma distribuição equitativa em relação aos limites.

$$P_k = \frac{k}{100} \cdot (n + 1) \quad (1)$$

O parâmetro k representa o ponto de corte onde ocorre a mudança na atribuição linguística do conjunto fuzzy, enquanto o parâmetro n representa o número total de candidatos.

O estabelecimento dos valores de distância do candidato ao centroide da população que entram no conjunto fuzzy denominado *Próximo* são denotados em (2).

$$\mu_{Próximo}(h) = \begin{cases} 1 & \text{se } h \leq d_1, \\ \frac{d_2 - h}{d_2 - d_1} & \text{se } d_1 < h \leq d_2, \\ 0 & \text{se } h > d_2 \end{cases} \quad (2)$$

Os limites estabelecidos pelos parâmetros d_1 , d_2 , e h o valor do cada candidato dentro da função, pertencentes à função triangular, são calculados por meio da aplicação de percentis, conforme a equação (1).

O cálculo do conjunto nebuloso denominado *Médio* é calculado utilizando a função (3).

$$\mu_{Médio}(h) = \begin{cases} \frac{h - d_1}{d_2 - d_1} & \text{se } d_1 \leq h \leq d_2, \\ 1 & \text{se } d_2 < h \leq d_3, \\ \frac{d_4 - h}{d_4 - d_3} & \text{se } d_3 < h \leq d_4, \\ 0 & \text{se } h < d_1 \text{ ou } h > d_4 \end{cases} \quad (3)$$

Os limites estabelecidos pelos parâmetros d_1 , d_2 , d_3 , d_4 e h o valor do cada candidato dentro da função, pertencentes à função triangular, são calculados por meio da aplicação de percentis, conforme a equação (1).

Da mesma forma, o cálculo do conjunto nebuloso denominado *distante* é calculado por (4).

$$\mu_{distante}(h) = \begin{cases} 0 & \text{se } h \leq d_3, \\ \frac{h - d_3}{d_4 - d_3} & \text{se } d_3 < h \leq d_4, \\ 1 & \text{se } h > d_4 \end{cases} \quad (4)$$

Os limites estabelecidos pelos parâmetros d_3 , d_4 e h o valor do cada candidato dentro da função, pertencentes à função triangular, são calculados por meio da aplicação de percentis, conforme a equação (1).

Função de dependência triangular em relação a rota de tráfego mais movimentada. A proximidade a vias de alto tráfego é um fator crucial na seleção de locais para ECVEs (Yandulskii *et al.*, 2018). A exposição a um fluxo elevado de veículos maximiza a

probabilidade de recarga, além de influenciar diretamente na acessibilidade e visibilidade das estações. Para um candidato, é essencial que os usuários percebam sua estação como de fácil acesso e conveniente (Wang *et al.*, 2023).

Além disso, a inclusão dessa função permite capturar a relevância estratégica de vias alternativas conectadas à rota principal. Candidatos localizados em pontos de interseção ou próximos a rotas auxiliares podem oferecer conveniência adicional para os usuários, especialmente durante períodos de congestionamento ou mudanças de itinerário. A função triangular possibilita uma avaliação contínua e gradativa, refletindo diferentes níveis de acessibilidade em relação à via de maior tráfego, promovendo um planejamento mais abrangente e eficiente.

Outro ponto relevante é que a função triangular permite adaptar o método de avaliação às características dinâmicas das vias de tráfego. Ao contrário de um ponto fixo como o centroide, as rotas possuem extensão e variabilidade, o que exige um modelo flexível para representar adequadamente a influência do fluxo de veículos (H. J. Anderson, 2020). Isso assegura que a análise não esteja limitada a um único ponto de proximidade, mas abranja toda a área de influência da via, oferecendo uma visão mais realista da conectividade entre os candidatos e os usuários de VEs.

Por fim, essa abordagem contribui diretamente para a equidade na avaliação dos candidatos, ao considerar diferentes cenários de tráfego e acessibilidade. Ao adotar a função triangular, é possível identificar localidades que, embora não estejam diretamente adjacentes à rota principal, ainda oferecem benefícios substanciais devido à proximidade relativa e à interligação com outras vias. Esse nível de detalhamento garante que a seleção final de candidatos para as ECVs maximize o impacto e a eficiência da infraestrutura planejada, atendendo a um público mais amplo e diverso.

Um cálculo similar ao realizado em relação ao centroide populacional é desenvolvido para as distâncias entre a localização do candidato e a rota de tráfego com maior fluxo de veículos. A principal diferença é que o centroide é um ponto específico, enquanto a rota de tráfego mais movimentada se estende ao longo de uma parte da área (Guang; Chengbi, 2016).

Um exemplo ilustrativo da exposição dos candidatos pode ser observado na Figura 4, onde a rota de tráfego de veículos com maior afluência é destacada em azul. A rota mais próxima a essa para cada candidato é realçada em vermelho, e, caso exista uma rota alternativa para cada agente, esta é destacada em amarelo.

Figura 4 – Mapa de rotas de tráfego com maior tráfego na área 1



Fonte: Elaborado pelo autor.

Para o cálculo da distância dos candidatos até a rota de tráfego com maior afluência, foram consideradas tanto a distância mínima nas vias principais quanto suas alternativas. Essa distância, d_{rt} , foi calculada utilizando ferramentas de geolocalização, levando em conta diferentes cenários de tráfego.

Não obstante, não é viável aplicar três funções triangulares para definir os valores linguísticos para uma via de tráfego, uma vez que essa via não é um ponto exato, como um centroide, mas pode se estender por várias partes da área de estudo.

Para representar a continuidade de uma via de tráfego e proporcionar flexibilidade na avaliação, é mais adequado utilizar uma única função triangular. Isso se deve ao fato de que os candidatos podem estar localizados em locais distantes entre si, mas ainda assim próximos à via com maior fluxo de veículos.

Essa atribuição de valores linguísticos por meio da aplicação de uma única função triangular $\beta_{única}(s)$, calculada em (5).

$$\beta_{única}(s) = \begin{cases} 0 & \text{se } s \leq t_1 \text{ ou } s \geq t_3, \\ \frac{s - t_1}{t_2 - t_1} & \text{se } t_1 < s < t_2, \\ \frac{t_3 - s}{t_3 - t_2} & \text{se } t_2 \leq s < t_3 \end{cases} \quad (5)$$

Os limites estabelecidos pelos parâmetros t_1 , t_2 , t_3 e s o valor de cada candidato dentro da função, pertencentes à função triangular, são calculados por meio da aplicação de percentis, conforme a equação (1).

Considera-se que os limites dentro da função triangular são definidos por percentis, utilizando (1).

2.2.2.2 Critério econômico

Um aspecto importante para qualquer entidade que participe em um mercado público é a exposição a usuários de diferentes setores (Nourbakhsh *et al.*, 2016). No mercado de VEs, estar próximo ao centroide econômico da região facilita o acesso a uma base de usuários com maior poder aquisitivo, o que, por sua vez, aumenta a rentabilidade das estações devido à maior exposição e, consequentemente, a uma demanda esperada mais elevada (Kumar; Channi, 2024).

Outro aspecto relevante ao considerar a proximidade com o centroide econômico é que ele tende a ter uma melhor infraestrutura urbana (Karmaker *et al.*, 2023), o que pode reduzir tanto os custos de investimento quanto os custos operacionais para os candidatos que se encontram próximos ou dentro de seus limites.

Além do aspecto financeiro, a proximidade ao centroide econômico também se destaca como um fator estratégico devido à infraestrutura superior que essas áreas frequentemente oferecem. Regiões próximas a esse ponto costumam contar com melhores redes de energia, sistemas de transporte mais integrados e serviços públicos mais acessíveis. Esses elementos não apenas simplificam a instalação de ECVs, mas também reduzem os custos contínuos de operação e manutenção, aumentando a atratividade do local tanto para investidores quanto para operadores.

De maneira complementar, o centroide econômico é um reflexo da dinâmica comercial e empresarial da região, representando os polos de maior atividade econômica. Localizar estações de recarga nessas áreas permite capturar o fluxo constante de usuários que frequentam centros comerciais, escritórios e espaços corporativos. Isso favorece a criação de uma rede de recarga bem integrada às necessidades urbanas e contribui para fortalecer a percepção de conveniência e utilidade entre os usuários de VEs.

Função de dependência triangular em relação ao centroide econômico. Na abordagem apresentada, a proximidade de cada candidato ao centro econômico é considerada um ponto forte, pois garante uma elevada exposição aos usuários, mesmo sem a necessidade de estar localizado próximo a uma rota de tráfego importante (Praveen *et al.*, 2016).


Essa visualização destaca como a proximidade ao centroide econômico desempenha um papel estratégico na viabilidade dos candidatos. Mesmo para aqueles que não estão localizados diretamente dentro do centroide, a relativa proximidade pode assegurar o atendimento a uma base de usuários economicamente ativa.

Esse fator é crucial em regiões urbanas densamente povoadas, onde o centroide econômico concentra grande parte das atividades comerciais e empresariais, funcionando como um polo de atração para diversos tipos de usuários.

A utilização de uma função de dependência triangular nesse contexto permite uma análise mais balanceada, valorizando os candidatos mais próximos ao centroide, mas sem desconsiderar aqueles localizados em áreas adjacentes. Essa abordagem é especialmente útil para evitar uma concentração excessiva de estações de recarga em um único ponto, promovendo uma distribuição mais equitativa e estratégica da infraestrutura.

Uma visualização da exposição de todos os candidatos ao centroide econômico pode ser apreciada na Figura 5, onde somente um dos candidatos está localizado dentro do centroide econômico.

Figura 5 – Mapa da localização dos candidatos presentes na área 1 em relação ao centroide econômico.



Fonte: Elaborado pelo autor.

Sob este enfoque, uma das dificuldades de se situar dentro do centroide econômico é a falta de espaço necessário para a instalação de uma ECVEs (Morro-Mello *et al.*, 2019).

O tamanho do centroide econômico de cada subárea, neste enfoque, foi calculado utilizando ferramentas de rastreamento geoespacial e econômico, assim como a distância mínima, considerando todas as vias para cada candidato.

Para a atribuição do valor linguístico próximo, foi utilizado um cálculo semelhante ao aplicado em relação ao centroide populacional. Essa atribuição é calculada por meio de (6).

$$\rho_{próximo}(p) = \begin{cases} 1 & \text{se } p^c \leq b_1, \\ \frac{b_2 - p^c}{b_2 - b_3} & \text{se } b_1 < p^c \leq b_2, \\ 0 & \text{se } p^c > b_2 \end{cases} \quad (6)$$

Os limites estabelecidos pelos parâmetros b_1 , b_2 e p^c o valor do cada candidato dentro da função, pertencentes à função triangular, são calculados por meio da aplicação de percentis, conforme a equação (1).

O cálculo para a atribuição de valores para os candidatos localizados a uma distância considerada média até o centroide econômico é detalhado em (7).

$$\rho_{Médio}(p) = \begin{cases} \frac{p - b_1}{b_2 - b_1} & \text{se } b_1 \leq p^c \leq b_2, \\ 1 & \text{se } b_2 < p^c \leq b_3, \\ \frac{b_4 - p}{b_4 - b_3} & \text{se } b_3 < p^c \leq b_4, \\ 0 & \text{se } p^c < b_1 \text{ o } p^c > b_4 \end{cases} \quad (7)$$

Os limites estabelecidos pelos parâmetros b_1 , b_2 , b_3 , b_4 e p^c o valor do cada candidato dentro da função, pertencentes à função triangular, são calculados por meio da aplicação de percentis, conforme a equação (1).

Para os candidatos que se localizam em um intervalo de distância considerado distante, os valores linguísticos são atribuídos utilizando (8).

$$\rho_{distante}(p) = \begin{cases} 0 & \text{se } p^c \leq b_3, \\ \frac{p^c - b_3}{b_4 - b_3} & \text{se } b_3 < p^c \leq b_4, \\ 1 & \text{se } p^c > b_4 \end{cases} \quad (8)$$

Os limites estabelecidos pelos parâmetros b_3 , b_4 e p^c o valor do cada candidato dentro da função, pertencentes à função triangular, são calculados por meio da aplicação de percentis, conforme a equação (1).

Função de dependência triangular com base na robustez económica de cada candidato. Os altos custos na instalação de ECVEs e os custos de manutenção são fatores de grande preocupação para qualquer entidade interessada em se candidatar à instalação de uma ECVEs. Para cada candidato, é crucial conhecer as dimensões dos investimentos e, consequentemente, sua posição econômica a esse respeito (Zhao *et al.*, 2021).

A instalação de uma ECVEs considerada grande exige um investimento considerável, mas também proporciona uma alta remuneração econômica (Guo, 2021). Em contrapartida, a instalação de uma estação considerada pequena envolve um menor risco de investimento, mas resulta em uma menor remuneração econômica.

O retorno econômico do investimento e os custos de manutenção são a principal preocupação em qualquer mercado, e no mercado de ECVEs não é diferente (Karmaker; RAJU Ahmed, 2019). Essa preocupação gera a necessidade de ter uma referência quanto à robustez econômica.

Esse desafio é abordado na abordagem apresentada por meio da aplicação de três funções de dependência triangular, com as atribuições linguísticas de alto, médio e débil. Os limites edessas funções, l_i , são definidos por parâmetros que simbolizam os preços de instalação de estações de tamanho grande, médio e pequeno. Em contrapartida, o parâmetro C_{ca} é definido de acordo com a capacidade econômica de cada agente. A classificação linguística considerada como baixo é calculada utilizando (9).

$$\alpha_{baixo}(q) = \begin{cases} 1 & \text{se } q \leq l_1, \\ \frac{q - l_1}{l_2 - l_1} & \text{se } l_1 < q < l_2 \\ \frac{l_4 - q}{l_4 - l_3} & \text{se } l_2 \leq q < l_3 \\ 0 & \text{se } q < l_3 \end{cases} \quad (9)$$

A classificação para os candidatos denominada *Médio* é calculada utilizando (10). Os limites estabelecidos pelos parâmetros l_1, l_2, l_3, l_4 e q o valor do cada candidato dentro da função, pertencentes à função triangular, são calculados por meio da aplicação de percentis, conforme a equação (1).

$$\alpha_{Médio}(q) = \begin{cases} 0 & \text{se } q \leq l_1, \\ \frac{C_{ca} - l_1}{l_2 - l_1} & \text{se } l_1 < q < l_2 \\ \frac{l_4 - q}{l_5 - l_3} & \text{se } l_2 \leq q < l_3 \\ 0 & \text{se } q < l_3 \end{cases} \quad (10)$$

Os limites estabelecidos pelos parâmetros l_1, l_2, l_3, l_4, l_5 e q o valor do cada candidato dentro da função, pertencentes à função triangular, são calculados por meio da aplicação de percentis, conforme a equação (1).

Finalmente, os candidatos que têm como objetivo abranger a maior demanda deverão assumir custos mais elevados de investimento e manutenção. O cálculo para a atribuição linguística de capacidade econômica com alta robustez é desenvolvido utilizando (11).

$$\alpha_{alto}(q) = \begin{cases} 0 & \text{se } q \leq l_3, \\ \frac{q - l_3}{l_4 - l_3} & \text{se } l_3 < q < l_4 \\ \frac{l_5 - q}{l_5 - l_4} & \text{se } l_4 \leq q < l_5 \\ 1 & \text{se } q \geq l_5 \end{cases} \quad (11)$$

Os limites estabelecidos pelos parâmetros l_1, l_2, l_3, l_4, l_5 e q o valor do cada candidato dentro da função, pertencentes à função triangular, são calculados por meio da aplicação de percentis, conforme a equação (1).

2.2.2.3 Critério de dependência

Manter a estabilidade da rede elétrica é crucial para garantir a eficiência do sistema. Em sistemas existentes, é essencial a correta distribuição de ECVEs para assegurar que os usuários possam abastecer-se de maneira eficiente. Nesse contexto, as entidades que desejam se candidatar para a instalação de estações de recarga devem considerar o reforço da rede, se necessário. Dado que reforçar uma rede existente envolve um alto investimento econômico, que pode ser inviável ou de baixa rentabilidade, uma abordagem colaborativa teria resultados mais favoráveis para todos os candidatos que se beneficiariam de um possível reforço.

Para superar esse desafio, considera-se a análise de um critério de dependência para todos os candidatos. Esse critério avalia como a localização de cada candidato na rede influencia os custos associados ao reforço e manutenção da rede.

Uma alta densidade de candidatos em uma mesma barra ou em barras subsequentes pode reduzir significativamente o custo por agente, já que o custo de reforço é distribuído entre mais usuários. Dessa forma, os candidatos situados em áreas com maior densidade de agentes recebem uma classificação mais alta neste critério, evidenciando sua capacidade de contribuir de maneira eficiente para o sistema elétrico e de compartilhar os custos de forma mais equitativa.

Função de dependência triangular com base na dependência do candidato da rede elétrica. Para atribuir valores linguísticos na avaliação da viabilidade de um candidato com relação à sua posição na rede elétrica, foi desenvolvida uma função de dependência triangular, cujos limites são definidos pelos parâmetros z_i , que representam a quantidade mínima, média e alta de candidatos presentes em cada subárea. Por outro lado, o parâmetro N_{ca} simboliza o número de candidatos em uma barra.

Cabe ressaltar que a aplicação de uma ou três funções triangulares dependerá do tamanho da área de estudo. Quanto maior a área de estudo, maior será o número de candidatos presentes e, conseqüentemente, será necessária uma análise de sensibilidade mais detalhada.

O cálculo para a atribuição linguística do critério de dependência é detalhado na equação (12).

$$\delta_{dependência}(N_{ca}) = \begin{cases} 0 & \text{se } N_{ca} \leq z_1 \\ \frac{N_{ca} - z_1}{z_2 - z_1} & \text{se } z_1 < N_{ca} \leq z_2 \\ 1 & \text{se } z_2 < N_{ca} \leq z_3 \\ \frac{z_3 - N_{ca}}{z_3 - z_2} & \text{se } z_2 < N_{ca} \leq z_3 \\ 0 & \text{se } N_{ca} > z_3 \end{cases} \quad (12)$$

Os limites estabelecidos pelos parâmetros z_1 , z_2 , z_3 , e N_{ca} o valor do cada candidato dentro da função, pertencentes à função triangular, são calculados por meio da aplicação de percentis, conforme a equação (1).

2.2.2 Atribuição de graus de adesão e cálculo de valores finais

De acordo com Papathanasiou *et al.* (Papathanasiou; Ploskas, 2018), o método de escala linear é a melhor opção para distribuir igualmente os graus de adesão entre todas as funções triangulares dentro de uma função de dependência, estes sendo detalhados pelo parâmetro $\tau_{i,j}$, para todos os i critérios e r funções de pertinência.

Esse método permite uma avaliação precisa e equitativa dos candidatos ao assegurar que a variação nos graus de adesão não favoreça indevidamente nenhuma função específica. Essa abordagem é particularmente importante em sistemas de lógica nebulosa aplicados a cenários de tomada de decisão, onde a precisão na distribuição de valores entre as funções de pertinência pode impactar diretamente os resultados finais e a qualidade das decisões tomadas.

Adicionalmente, a utilização do método de escala linear também reduz a subjetividade na definição dos graus de adesão, tornando o processo mais transparente e replicável. Tal característica é essencial em aplicações que demandam rigor científico, como a alocação de recursos e a seleção de candidatos para projetos de infraestrutura, garantindo que os critérios utilizados sejam justos e baseados em parâmetros bem definidos.

Outro benefício significativo está relacionado à flexibilidade do método, que permite sua aplicação em diferentes contextos e tipos de dados. Isso torna o método uma ferramenta versátil para lidar com problemas complexos, especialmente em sistemas multiagente e em

situações em que há múltiplos critérios e funções triangulares sobrepostas a serem avaliadas simultaneamente.

O cálculo do valor final G para o critério geoespacial é detalhado em (13). Onde μ_r e β_r são os graus de pertencimento da variável geoespacial para as funções fuzzy específicas e $\tau_{g,\mu}$ e $\tau_{g,\beta}$ são os valores correspondentes a essas funções.

$$G = \mu_r \cdot \tau_{g,\mu} + \beta_r \cdot \tau_{g,\beta} \quad (13)$$

Sendo está uma soma dos valores obtidos em relação aos graus de pertencimento para cada função fuzzy. Onde ρ_r e α_r são os graus de pertencimento das variáveis econômicas associadas às funções fuzzy para o critério econômico e $\tau_{e,\rho}$ e $\tau_{e,\alpha}$ são os valores correspondentes a essas funções.

Para o critério econômico, o valor final E é calculado por meio da equação (14).

$$E = \rho_r \cdot \tau_{e,\rho} + \alpha_r \cdot \tau_{e,\alpha} \quad (14)$$

O critério de dependência D , por outro lado, contém uma única função de dependência, sendo seu valor final obtido por meio da equação (15). Onde δ_r representa o grau de pertencimento para a função de dependência e $\tau_{d,\delta}$ é o valor calculado para esta função.

$$D = \delta_r \cdot \tau_{d,\delta} \quad (15)$$

Devido à variação na relevância dos critérios, é essencial a atribuição de valores diferenciados para cada um deles. No método implementado, é proposta a atribuição de valores com base na importância relativa de cada critério, considerando fatores prioritários em diferentes cenários (Figueira *et al.*, 2005).

O cálculo da pontuação final V de cada um dos candidatos é detalhado na equação (16), sendo está uma soma da relação entre os valores finais obtidos em cada critério e o peso ω_i atribuído a cada um deles.

$$V = \omega_i \cdot G + \omega_i \cdot E + \omega_i \cdot D \quad (16)$$

3 MÉTODO PROPOSTO PARA O PROBLEMA DE ALOCAÇÃO E DIMENSIONAMENTO

3.1 OTIMIZAÇÃO MATEMÁTICA

A otimização matemática é um campo da matemática aplicada que busca encontrar a melhor solução para um problema, considerando restrições e objetivos específicos. Basicamente, trata-se de um processo que envolve a maximização ou minimização de uma função matemática, levando em consideração uma série de variáveis e condições que limitam as possibilidades de escolha. Esses problemas podem ser abordados com diversos métodos, dependendo da complexidade e da natureza do sistema (Swann, 1969).

No contexto do planejamento de ECVs, a otimização matemática pode ser aplicada no dimensionamento e na alocação dessas estações em uma rede. O objetivo principal é determinar o número ótimo de estações de carregamento e suas localizações estratégicas de forma que o custo total seja minimizado e a cobertura do serviço seja maximizada. Além disso, é possível levar em conta aspectos como a demanda de carga, a capacidade das estações, o tempo de espera dos usuários e os custos de instalação e manutenção. A otimização matemática ajuda a equilibrar todos esses fatores para criar uma rede de estações de carregamento eficiente, acessível e economicamente viável (Gupta, 2021).

A otimização multiobjetivo é uma abordagem de otimização que envolve a resolução de problemas com múltiplos objetivos que podem ser conflitantes entre si. Diferente da otimização tradicional, que visa otimizar um único objetivo, a otimização multiobjetivo busca encontrar um equilíbrio entre diferentes metas, como custo, eficiência, desempenho e sustentabilidade. Essa técnica é amplamente utilizada em problemas complexos, onde não existe uma única solução que satisfaça todos os objetivos de forma ótima, mas sim um conjunto de soluções alternativas, chamadas de soluções de Pareto. Por exemplo, ao planejar a instalação de estações de carregamento de VEs, os objetivos podem ser, ao mesmo tempo, reduzir os custos de instalação e maximizar a cobertura do serviço, o que pode gerar um *trade-off*. A otimização multiobjetivo permite que esses objetivos sejam tratados de forma simultânea e busque as melhores soluções possíveis, considerando as interações entre eles (Fong; Nguyen, 2021).

Uma das maneiras de resolver um problema multiobjetivo é através da conversão dos objetivos em um único objetivo por meio da ponderação. Cada objetivo recebe um peso que reflete sua importância relativa no problema. A partir disso, uma função objetivo combinada é

formulada, e técnicas de otimização tradicionais podem ser aplicadas para encontrar a solução ótima. A ponderação dos objetivos permite que o processo de decisão seja mais transparente e controlável, dando flexibilidade para priorizar certos aspectos do problema enquanto ainda se mantém a busca por uma solução balanceada (Abdmouleh *et al.*, 2017).

O metodo proposta é composta por três etapas. Na primeira, são estimados os perfis de demanda dos VEs por areas. Na segunda, os locais candidatos para a instalação das ECVEs são identificados com base em critérios geoespaciais específicos de cada área. Por fim, na terceira etapa, um modelo de otimização matemática é aplicado para determinar o dimensionamento e a alocação ótima das ECVEs, considerando os resultados das etapas anteriores. A seguir, detalham-se os dados de entrada, as etapas do processo e os respectivos dados de saída de cada etapa.

3.2 ETAPA 1. ESTIMAÇÃO DOS PERFIS DE DEMANDA DOS VES

Para estimar os perfis de demanda de carregamento dos VEs, adota-se uma abordagem baseada em análise geoespacial, que consiste em subdividir a cidade em estudo em n áreas, considerando suas características residenciais, comerciais e industriais. Para essa divisão, recomenda-se o uso de um sistema de informação geográfica (SIG), como o ArcGIS, que facilita o cálculo das dimensões das áreas e a identificação dos centroides populacionais. Além disso, essa ferramenta permite analisar dados geoespaciais, como a densidade do tráfego veicular, a existência de locais sem infraestrutura ou subutilizados e as áreas com maior circulação de veículos, auxiliando na identificação dos locais mais adequados para a instalação das ECVEs. Assim, para cada área, define-se um conjunto de locais candidatos à implantação das estações.

A escolha das cadeias de Markov para modelar a dinâmica dos deslocamentos dos VEs e as preferências de carregamento dos usuários baseia-se em sua capacidade de capturar de maneira eficiente a evolução probabilística dos estados do sistema ao longo do tempo. As cadeias de Markov são especialmente úteis nesse contexto, pois permitem modelar o comportamento de usuários que, ao longo de suas rotas diárias, alteram suas necessidades de carregamento em função de diferentes fatores, como o tempo de uso do veículo, a disponibilidade de infraestrutura de carregamento e as características geoespaciais da cidade. Além disso, o modelo de Markov é ideal para representar transições de estados entre áreas de carga e consumo, uma vez que a probabilidade de um usuário necessitar de carga em um determinado ponto depende apenas do estado anterior, simplificando o processo de previsão

dos perfis de demanda. Essa abordagem probabilística, portanto, oferece uma representação precisa e escalável das variáveis dinâmicas que influenciam a demanda por estações de carregamento.

A estimação dos perfis de demanda de carregamento dos VEs ocorre em dois passos. No primeiro, estima-se o número de compradores potenciais de VEs por área. No segundo, utilizam-se cadeias de Markov para modelar a dinâmica dos deslocamentos dos VEs e as preferências de carregamento dos usuários, possibilitando o cálculo dos perfis de demanda em cada área. A seguir, são apresentados os dados de entrada, os dados de saída e o procedimento adotado em cada passo.

3.2.1 Compradores potenciais de VEs

O número de compradores potenciais de VEs é estimado por meio de uma análise de potencial de mercado dos VEs em cada área. Para isto são usados dados socioeconômicos da população local. Além disso, são utilizados dados sobre o número de veículos tradicionais registrados até 2024 na área de estudo. A partir das informações socioeconômicas da população, é realizada uma classificação da população local em diferentes estratos, abrangendo categorias como baixo, médio-baixo, médio, médio-alto e alto. Para cada estrato, é atribuída uma porcentagem de potencial de aquisição de VEs, φ_z^{ve} , com base no poder de compra da população local. Assim, o número de VEs que poderiam ser adotados na área z , N_z^{ve} , é calculado usando (17).

$$N_z^{ve} = H_z^{leg} \cdot \varphi_z^{ve} \cdot A_z^{ad} \quad \forall z = 1, \dots, n \quad (17)$$

sendo que H_z^{leg} representa a quantidade de habitantes autorizados para possuir um VE na área z . A_z^{ad} é a porcentagem de habitantes da área z com poder aquisitivo para comprar um VE.

Uma vez estimada a quantidade de VEs que podem ser adquiridos em cada área, prossegue-se a utilizar as cadeias de Markov para desenvolver um modelo dinâmico no tempo que permita estimar os deslocamentos dos VEs, as preferências de carregamentos dos usuários de VEs, e assim, estimar os perfis de demanda dos VEs em cada área.


3.2.2 Perfis de demanda dos VEs

A necessidade de recarregar um VE é influenciada por diversas características tanto do próprio veículo quanto do ambiente em que ele opera. Durante o processo de recarga, o usuário leva em conta principalmente dois elementos: a porcentagem de carga da bateria do

veículo e o tempo necessário para completar a recarga. As cadeias de Markov são construídas a partir de um conjunto de estados e as probabilidades de transferência entre esses estados (YUSUF *et al.*, 2022). A Figura 6 ilustra a estrutura típica de uma cadeia de Markov de três estados com suas respectivas probabilidades de transferência entre estados.

Com base nesse conceito, foi construída uma matriz de transição de $n \times n$, na qual cada estado representa uma das n áreas analisadas dentro da região de estudo. Cada elemento dessa matriz indica a probabilidade de transição de uma área para outra, refletindo a dinâmica espacial e as possíveis mudanças na distribuição da demanda por infraestrutura de carregamento de veículos elétricos. Essa abordagem permite modelar o comportamento estocástico dos agentes dentro do sistema, possibilitando uma análise mais precisa das interações entre as áreas e a previsão de padrões futuros na alocação de estações de carregamento.

Figura 6 – Representação da cadeia de Markov.



Fonte: Elaborado pelo autor.

Essa matriz, permitirá determinar a probabilidade de um VE que pertence a uma área i seja carregado em outra área j , $\sigma_{i,j}$. As probabilidades de transição de cada estado da cadeia são construídas com base em duas funções de probabilidade: a probabilidade $\beta_{i,j}^{dis}$ de que um VE que pertença à área i seja carregado na área j em relação à distância a percorrer, e probabilidade $\beta_{i,j}^{den}$ de que um VE que pertence à área i seja carregado na área j em relação à densidade de VEs naquela área,.

3.2.3 Probabilidades dos estados da cadeia de Markov

Para realizar uma análise espacial precisa, implementa-se uma análise baseada em coordenadas geográficas. A distância média normalizada entre todos os pontos de carregamento existentes em uma área i em relação ao seu centroide, v_i , e calculada usando (18).

$$v_i = \frac{\frac{1}{m_i} \sum_{k=1}^{m_i} d_{i,k} - \min\{d_{i,1}, \dots, d_{i,m_i}\}}{\max\{d_{i,1}, \dots, d_{i,m_i}\} - \min\{d_{i,1}, \dots, d_{i,m_i}\}} \quad \forall i = 1, \dots, n \quad (18)$$

O fator que quantifica que tão afastados estão os locais candidatos para instalar as ECVEs na área i em relação a seu centroide, p_i , é calculado usando (19). Esse fator tem como objetivo reduzir a probabilidade de que um VE atribuído a uma área i carregue em outra área j . Para isto, é levada em consideração a distância v_i e o tamanho de cada área estudada, z_i . Em outras palavras, quanto maior a distância v_i de uma área, menor será a probabilidade de que um VE seja carregado nessa área.

$$p_i = 1 - z_i \cdot v_i \quad \forall i = 1, \dots, n \quad (19)$$

A equação (19) é projetada para que a função diminua conforme a distância média normalizada aumenta. Dessa forma, a probabilidade de carregamento dentro de uma mesma área pode ser ajustada, levando em consideração o seu tamanho.

A probabilidade de que um VE que pertença à área i seja carregado na área j em relação à distância a percorrer, $\beta_{i,j}^{dis}$, é calculada usando (20).


$$\beta_{i,j}^{dis} = e^{f_{dis} \cdot s_{i,j} \cdot p_i} \quad \forall i, j = 1, \dots, n \quad (20)$$

onde, f_{dis} representa um fator de sensibilidade relacionado à distância.

Esto indica que indica a probabilidade varia de forma inversa, segundo uma exponencial decrescente, com a distância. $s_{i,j}$ representa a distância entre o centroide de uma área i e o ponto de carregamento mais próximo de uma área j (Jidong Wang *et al.*, 2015).

A construção da equação (20) baseia-se na necessidade de que a função diminua rapidamente com o aumento da distância entre centroides e a distância entre carregadores e seus respectivos centroides como ilustrado na Figura 7. Matematicamente, essa equação garante que as probabilidades de carregamento diminuam exponencialmente em relação à distância, tornando menos provável que os usuários de VE optem por carregar em ECVEs distantes.

Figura 7 – Probabilidade de carga associada à distância em relação a $s_{i,j}$.



Fonte: Elaborado pelo autor.

Uma distribuição estratégica de VEs é considerada em relação à densidade populacional. Com base nesta distribuição dos VEs, um fator de quantidade de VEs assinados à área i , θ_i , é definido em (21), que corresponde à relação entre a quantidade de ECVEs instaladas na área i , μ_i^{inst} , e a quantidade de locais candidatos para a instalação de ECVEs na área i , μ_i^{cand} (onde todas as áreas tenham pelo menos um ponto candidato a ser instalado), o número de veículos na área N_i^{ve} e os parâmetros de controle τ , δ e γ que funcionam como controle de amplitude, de sensibilidade e de velocidade.

$$\theta_i = \tau \cdot (1 - e^{\delta \cdot N_i^{ve}}) \cdot \frac{\mu_i^{inst}}{\mu_i^{cand}} + \gamma \quad \forall i = 1, \dots, n; \mu_i^{cand} \geq 1 \quad (21)$$

A equação (21) foi criada para garantir que θ_i permaneça dentro de um intervalo coerente. Como θ_i representa um fator relacionado à quantidade de VEs alocados à área i , valores superiores a 1 poderiam indicar uma saturação ou superlotação da infraestrutura. Para evitar essa interpretação ambígua, pode-se impor um limite superior a θ_i , garantindo que permaneça no intervalo desejado. Dessa forma, a equação (21) poderia ser modificada incluindo


o operador de mínimo para restringir θ_i a um valor máximo de 1, garantindo a coerência do modelo.

Do mesmo modo, na equação (21), a presença do termo exponencial garante que a influência do número de VEs na ponderação seja não linear, aumentando rapidamente no início e depois se estabilizando. Isso é crucial para capturar o efeito de saturação. Áreas com um maior número de VEs atribuídos terão um aumento de peso mais rápido até certo ponto.

Na Figura 8 é apresentada a variação de θ_i em função do número de veículos elétricos N_i^{ve} na área i . Conforme N_i^{ve} aumenta, θ_i também cresce, atingindo um valor assintótico. Isso indica que áreas com maior densidade de veículos elétricos tendem a apresentar um valor mais elevado de θ_i .

Nota-se ainda que, para $N_i^{ve} = 0$, o valor de θ_i é igual a 0,5. Esse comportamento representa a condição mínima do parâmetro, garantindo que mesmo em áreas sem veículos elétricos a função mantenha um valor de referência, possivelmente associado a uma base fixa da infraestrutura existente ou a um fator mínimo considerado no modelo. Por outro lado, a relação entre estações candidatas e instaladas tem um efeito de proporcionalidade, onde a influência da infraestrutura existente é equilibrada em comparação com o potencial de expansão.

Figura 8 – Gráfica de distribuição de θ_i .



Fonte: Elaborado pelo autor.

A probabilidade de que um VE que pertença à área i seja carregado na área j em relação à densidade de VEs naquela área e representada por $\beta_{i,j}^{den}$ é definida em (22), onde uma relação o número de VEs na área i N_i^{ve} com o fator de quantidade de veículos θ_j .

$$\beta_{i,j}^{den} = \frac{1}{\log(N_i^{ve} \cdot \theta_j) + 1} \quad \forall i, j = 1, \dots, n \quad (22)$$

A aplicação da parcela logarítmica na função (23) introduz um crescimento logarítmico no denominador, o que significa que a probabilidade diminuirá lentamente com o aumento do número de VEs relacionados ao fator θ_j . Esta relação logarítmica garante que as áreas com elevado número de VEs ou aquelas que possuem um elevado valor do fator θ_j tenham uma probabilidade menor, refletindo matematicamente que áreas já saturadas são menos preferidas para carregamento por um usuário.

A equação (23) foi construída com a abordagem de modelar de forma precisa e realista a densidade dos VEs e os fatores que afetam a probabilidade de carregamento em diferentes áreas. Ao adicionar 1 no denominador de (22) controla-se o decaimento, evitando assim a sobrecarga em áreas específicas. Essa abordagem assegura que a distribuição dos VEs seja equilibrada, refletindo a demanda de maneira eficaz e sustentável.

A partir das definições anteriores, a probabilidade de transição entre os estados i e j é representada como $\sigma_{i,j}$ e corresponde à probabilidade de que um VE que pertença à área i seja carregado na área j . Essa probabilidade é proporcional à relação de probabilidades de densidade e de distância, sendo normalizada de acordo com (23).

$$\sigma_{i,j} = \frac{\beta_{i,j}^{dis} \cdot \beta_{i,j}^{den}}{\sum_{h=1}^n \beta_{i,h}^{dis} \cdot \beta_{i,h}^{den}} \quad \forall i, j = 1, \dots, n \quad (23)$$


3.2.4 Matriz de decisão dos usuários de VEs

Em áreas urbanas, mais de 90% da população que possui veículo desloca-se diariamente de suas residências para diversos pontos da cidade a fim de realizar atividades laborais ou comerciais. Estas atividades têm duração média de 60 a 180 minutos no caso das atividades comerciais, e de 240 a 420 minutos no caso das atividades laborais (Mahmoudi; Ruppert, 2021).

O deslocamento diário da população é claramente perceptível tanto no fluxo econômico entre diferentes regiões quanto na curva horária de demanda energética de uma cidade (Bustos-Turu *et al.*, 2016). Uma análise superficial da Figura 9 revela que os picos de

demanda ocorrem durante os horários comerciais e de trabalho convencionais em todos os sistemas elétricos no Brasil (ONS).

Figura 9 – Curva comparativa horária de demanda energética de sistemas diferentes.



Fonte: Operador Nacional do Sistema Elétrico.

O tempo médio de recarga completa de um veículo elétrico, considerando um processo de recarga lenta, varia entre 180 e 420 minutos. Esse tempo é influenciado por fatores críticos, como o nível de carga inicial da bateria do usuário e a capacidade energética da estação de carregamento utilizada. No entanto, em estações de recarga rápida, o tempo necessário para carregar a bateria de 30% a 80% pode ser reduzido para aproximadamente 15 minutos, dependendo do modelo do veículo elétrico e das especificações da estação de carregamento (Aljaidi *et al.*, 2019).

Com base nestes dados já conhecidos, torna-se claro que os usuários de VEs que residem em áreas urbanas estarão mais propensos a realizar a recarga de seus VEs quando estiverem em áreas onde possam dispor de mais de uma hora, especialmente se essa atividade for rotineira.

A matriz L representa a decisão dos usuários de carregar seus VEs em um determinado horário do dia. Note-se que, essa matriz L é influenciada pelo comportamento socioeconômico individual dos usuários de VEs (Hu *et al.*, 2021).

O elemento $L_{a,t}$ da matriz L ilustrada na equação (24) foi formulada para capturar a probabilidade de decisão dos usuários em cada uma das 8 áreas da cidade ao longo dos 24 períodos do dia. Ela considera a distribuição da população entre três categorias: residencial,

industrial e comercial, em cada área da cidade. Em cada área a , o percentual de população em cada categoria de uso é representado por $P_{a,c}$, onde c pode ser residencial, industrial ou comercial.

Além disso, a matriz leva em consideração o percentual da população de cada categoria que decide carregar seu VE durante os diferentes períodos do dia, sendo essa decisão representada por $\rho_{c,t}$. Onde $P_{a,c}$ é o percentual de população na área a pertencente à categoria c (residencial, industrial ou comercial), e $\rho_{c,t}$ é o percentual de usuários da categoria c dispostos a carregar seus VEs no período t .

$$L_{a,t} = \sum_{c \in \{\text{residencial}, \text{industrial}, \text{comercial}\}} P_{a,c} \cdot \rho_{c,t} \quad (24)$$

Dado que o elemento da matriz $\sigma_{i,j}$ estima as probabilidades de carregamento dos VEs de uma área i para uma área j ou para si mesma, a matriz $L_{a,t}$ estima o momento em que estes VEs serão carregados.

Em um estudo realista, seria bastante desafiador estimar a quantidade de carga que todos os usuários de VE possuem em uma cidade específica quando optam por recarregar. Da mesma forma, se estiver sendo construído um perfil de demanda, estimar a potência de carregamento de cada ponto de carregamento da cidade é bastante complexo. Considerando isso, estabelecem-se tanto o parâmetro de potência dos VEs, P^{ve} , e um parâmetro C^{ve} que define a porcentagem média da capacidade da bateria dos VEs que será carregada nas estações.

Uma matriz de perfis de demanda de carregamento dos VEs, w , pode ser calculada usando (25). Note que essa matriz é o resultado da relação entre a matriz de decisão de carregamento dos VEs, L , a matriz de estimativa de probabilidade de mudança de estado de Markov σ (construída a partir das probabilidades $\sigma_{i,j}$).

$$w = L_{a,t} \cdot \begin{bmatrix} \sigma_{1,1} & \dots & \sigma_{1,j} & \dots & \sigma_{1,n} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \sigma_{i,1} & \dots & \sigma_{i,j} & \dots & \sigma_{i,n} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \sigma_{n,1} & \dots & \sigma_{n,j} & \dots & \sigma_{n,n} \end{bmatrix} \cdot P^{ve} \cdot C^{ve} \quad \forall i, j = 1, \dots, n \quad (25)$$

3.3 ETAPA 2. IDENTIFICAÇÃO DE LOCAIS CANDIDATOS PARA A INSTALAÇÃO DE ECVES

Uma vez estimados os perfis de demanda de carregamento dos VEs, a seguinte etapa consiste na identificação de locais candidatos para a instalação de ECVES usando análise geoespacial e lógica fuzzy. O método proposto aborda a seleção de locais ideais para a

instalação de ECVes por meio de uma abordagem multicritério estruturada em dois passos. Detalhes sobre os dois passos seguidos são fornecidos a seguir.

3.3.1 Identificação de locais candidatos


No primeiro passo, aplica-se a lógica fuzzy para avaliar os locais candidatos com base em três critérios principais: geoespacial, econômico e de dependência. Para definir esses critérios, são realizadas análises detalhadas por meio de softwares de posicionamento e rastreamento geográfico, além da utilização de dados de instituições regionais e pesquisas na área de estudo.

3.3.2 Seleção de locais candidatos

No segundo passo, os resultados obtidos para cada critério são consolidados em uma tabela que apresenta a pontuação global de cada candidato. Os valores de pertencimento derivados das funções fuzzy são combinados e ponderados conforme a importância relativa de cada critério, determinada pelos pesos previamente atribuídos. Com isso, os candidatos são classificados de acordo com suas pontuações finais, sendo os de maior pontuação considerados os mais adequados para a instalação das ECVes.

A Figura 10 ilustra de forma detalhada o processo, desde a coleta de dados até a seleção final, proporcionando uma visão clara dos dois primeiros passos do método proposto.

Figura 10 – Fluxograma do método de identificação de locais candidatos de ECVEs.



Fonte: Elaborado pelo autor.

3.4 ETAPA 3. DIMENSIONAMENTO E ALOCAÇÃO ÓTIMA DAS ECVES

Uma vez estimados os perfis de demanda de carregamento dos VEs e os locais candidatos para a instalação das EVCS, o próximo passo envolve o planejamento eficiente dos ECVEs. Nesse sentido, propõe-se um modelo de PLIM para determinar o tamanho adequado e a localização ótima dos ECVEs necessários para atender às demandas de carregamento dos VEs em cada área. Detalhes sobre o modelo proposto são fornecidos a seguir.

3.4.1 Função objetivo

O modelo de otimização matemática proposto tem dois objetivos. Dependendo da abordagem escolhida para o planejamento, a seleção do objetivo a ser alcançado deve ser cuidadosamente considerada. Nesta perspectiva, propõe-se uma abordagem multiobjetivo. Se for adotada uma abordagem multiagente, a prioridade será dada ao objetivo econômico; no entanto, se o planejamento centralizado for considerado, ambos os objetivos deverão ser priorizados igualmente.

O primeiro objetivo, mostrado em (26), consiste em minimizar os custos de investimento em ECVE, Ψ^{ECVE} . Note que, Ψ^{ECVE} está composto pelo parâmetro W que representa o custo de um carregador de VE, e o parâmetro CF que representa o custo de instalação de uma ECVE. Além disso, a variável inteira γ_p representa a quantidade de carregadores instalados na ECVE, e a variável binária X_p representa a decisão de instalação da ECVE.

O segundo objetivo, mostrado em (27), consiste em minimizar as distâncias entre os EVCS, Φ^{ECVE} . Note-se que, Φ^{ECVE} está constituído pelo parâmetro $D_{z,p}$, que representa a distância entre as ECVEs da área z e o centroide dessa área. O parâmetro $F_{z,t}$, que representa a quantidade de VEs na área z no período t . Além disso, a variável contínua $\beta_{p,z}$ representa a demanda de carregamento dos VEs absorvida pela ECVE p da área z .

$$\text{minimizar } \Psi^{ECVE} = \sum_p (W \cdot \gamma_p + CF \cdot X_p) \quad (26)$$

$$\text{minimizar } \Phi^{ECVE} = \sum_{z,p,t} D_{z,p} \cdot F_{z,t} \cdot \beta_{p,z} \quad (27)$$

3.4.2 Restrições para a instalação de ECVEs

O conjunto de restrições (28)–(34) representa os limites que devem ser respeitados na instalação dos ECVEs.

$$\bar{p}^{PL} \leq p_{max}^p \cdot \gamma_p \quad \forall p, t \quad (28)$$

$$0 \leq \gamma_p \leq \bar{\gamma} \cdot X_p \quad \forall p, t \quad (29)$$

$$P_{p,t}^{PL} \leq \bar{p}^{PL} \quad \forall p, t \quad (30)$$

$$E_{p,t}^{Dis} = E_{p,t-1}^{Dis} + P_{p,t}^d \cdot \Delta t - P_{p,t}^{PL} \cdot \Delta t \quad \forall p, t > 1 \quad (31)$$

$$P_{p,t}^d = \sum_z P_{z,t}^d \cdot \beta_{z,p} \quad \forall p, t \quad (32)$$

$$\sum_p \beta_{z,p} = 1 \quad \forall z \quad (33)$$

$$E_{p,t}^{Dis} / p_{ve} \leq \delta_t < \delta_{max} \quad \forall p, t \quad (34)$$

O limite máximo de potência de uma ECVE $\bar{p}_{max}^{PL}$ é definido em (28), relacionado a quantidade de carregadores instalados γ_p e a potência máxima de um carregador p_{max}^p . A quantidade de carregadores γ_p que podem ser instalados é limitada em (29) através da relação da quantidade máxima de carregadores de uma ECVEs $\bar{\gamma}$ e a variável de decisão binária X_p que decide se um ECVE será instalado ou não.

A potência de uma ECVE $P_{p,t}^{PL}$ é definida em (30), sendo limitado pelo limite máximo de potência de uma ECVE $\bar{p}^{PL}$. A energia deslocada ou não atendida em um período t em uma ECVE p é representada por $E_{p,t}^{Dis}$, sendo definida em (31) pela relação entre a potência demandada $P_{p,t}^d$, o delta de tempo Δt , a razão da potência $P_{p,t}^{PL}$ que o carregador p pode fornecer em um período Δt e a energia não atendida ou deslocada no período anterior $E_{p,t-1}^{Dis}$.

A potência demandada num ECVE $P_{p,t}^d$ é definida em (32) através da relação da potência demandada de cada área $P_{z,t}$ e da variável $\beta_{z,p}$, que simboliza uma fração da demanda de uma área vizinha absorvida pelo carregador. A soma de todas as frações de demanda absorvidas pelas ECVEs é detalhada em (33) onde a soma das variáveis $\beta_{z,p}$ deve ser igual a

toda a demanda. Por sua vez, um tempo de espera para cada usuário é definido em (34) como a relação entre a potência dos VEs P^{ve} e a energia não deslocada $E_{p,t}^{Dis}$.


3.4.3 Abordagem de solução multiobjetivo

A equação (35) incorpora os objetivos (26) e (27) em um único objetivo.

$$\text{minimizar } \alpha \cdot \Psi^{ECVE} + (1 - \alpha) \cdot \Phi^{ECVE} \quad (35)$$

Note-se que, um conjunto de soluções pode ser obtido para o problema de planejamento variando o parâmetro α de 0 até 1.

Figura 11 – Fluxograma do processo desenvolvido.




Fonte: Elaborado pelo autor.

4 RESULTADOS

O método proposto foi testado usando informações socioeconômicas da população da cidade de Presidente Prudente, SP, Brasil. A área urbana dessa cidade foi dividida em 8 áreas como ilustrado na Figura 12. Cada área foi subdividida em parcelas residencial, comercial e industrial como e apresentado na Figura 13. Atualmente, na cidade há aproximadamente 183.507 veículos de combustão interna. Sob um cenário otimista, e através de uma relação de poder de compra e veículos registrados, espera-se que até 2030, 4592 VEs sejam adotados.

Por outro lado, para efeitos práticos, considera-se que independentemente do estado de carga dos VEs no momento de chegar ao ECVE, a porcentagem média de carregamento, C^{ve} , é de 60% da capacidade da bateria, e a potência de um VE, P^{ve} , é de 36 kW.


Figura 12 – Mapa da cidade de Presidente Prudente dividido por áreas.



Fonte: Elaborado pelo autor.

O processamento de dados de entrada para a construção dos perfis de demanda de carregamento dos VEs foi feito usando o software ArcGIS 10.5 (Environmental systems research institute, 2017). Enquanto, o modelo matemático foi implementado no software AMPL (AMPL Corporation, 2024) e resolvido usando o solver CPLEX (IBM, 2024). As simulações foram executadas em um computador com processador AMD Ryzen 9 5950X de 3,4 GHz e 32 GB de RAM.

Figura 13 – Classificação atribuída por áreas.



Fonte: Elaborado pelo autor.

A seleção das localidades candidatas para a instalação de ECVE foi fundamentada em uma análise criteriosa de aspectos técnicos, econômicos e de uso estratégico. Foram priorizados pontos que apresentassem elevado fluxo de veículos ou padrões consistentes de permanência, como postos de combustível, centros comerciais e grandes supermercados.


Essas localidades foram consideradas devido à sua capacidade de atrair potenciais usuários de VE, assegurando um nível de demanda adequado para justificar o investimento em infraestrutura de carregamento. Além disso, foram analisados os padrões de mobilidade e as características socioeconômicas das regiões adjacentes, o que permitiu identificar locais com maior probabilidade de atender às necessidades de proprietários de VE e estimular a adoção dessa tecnologia.

Outro aspecto fundamental na seleção foi a capacidade econômica e financeira dos possíveis operadores das ECVEs. Foi dada preferência a grandes redes comerciais, como postos de combustível e supermercados de grande porte, que possuem os recursos necessários para arcar com os custos iniciais de instalação e manutenção da infraestrutura, bem como para contribuir ativamente no desenvolvimento de um ecossistema sustentável de mobilidade elétrica.

Esse enfoque garante que as localidades escolhidas não apenas atendam aos critérios de acessibilidade e conveniência, mas também contem com a solidez financeira necessária para operar de forma eficiente e sustentável a longo prazo.

Uma análise geoespacial desenvolvida a partir da consideração da relação entre os fatores de densidade populacional e distância entre as áreas estudadas ilustrado na Figura 14.


Figura 14 – Mapa dos centroides populacionais de cada subárea de Presidente Prudente.



Fonte: Elaborado pelo autor.

Por outro lado, a análise socioeconômica com base em informações e relatórios de crescimento econômico de entidades estatais da região resultou na localização dos centroides populacionais, centroides econômicos como ilustrado na Figura 15.

Figura 15 – Mapa dos centroides econômicos de cada subárea de Presidente Prudente.



Fonte: Elaborado pelo autor.


Da mesma forma, foi desenvolvida uma análise do tráfego de veículos e rastreamento do rotas importantes nos horários de maior movimentação veicular, monitorados em tempo real por meio de software de rastreamento e GPS, como mostrado na Figura 16.

Considerando todos os aspectos que un candidato precisa para converter-se em agente ativo aplicados na área de estudo, identificaram-se até 26 entidades distintas distribuídas por toda a cidade, as quais já possuem infraestruturas existentes ilustrados na

Tabela 1 e ilustrados na

Figura 17. Essas entidades operam em diversas subáreas, o que viabiliza uma abordagem competitiva multiagente para o planejamento de infraestrutura de ECVes.

Figura 16 – Mapa de rotas mais importantes de Presidente Prudente.



Fonte: Elaborado pelo autor.


Tabela 1 – Candidatos presentes

Candidatos presentes em diferentes áreas com infraestruturas existentes.

Agentes potenciais	Área 1	Área 2	Área 3	Área 4	Área 5	Área 6	Área 7	Área 8
Franquia de supermercado 1	✓	✓				✓	✓	
Franquia de supermercado 2		✓	✓				✓	
Franquia de supermercado 3	✓		✓	✓				✓
Proprietário do estacionamento 1				✓				
Proprietário do estacionamento 2				✓		✓		
Proprietário do estacionamento 3				✓		✓		
Proprietário do estacionamento 4				✓			✓	
Estação existente 1							✓	
Estação existente 2								✓
Franquia de shopping 1				✓				
Franquia de shopping 2					✓			
Franquia de shopping 3						✓		

Fonte: Elaborado pelo autor.

Figura 17 – Mapa da cidade do Presidente prudente



Fonte: Elaborado pelo autor.

Na análise espaço-temporal realizada neste estudo, identificaram-se pontos estratégicos para a instalação de ECVEs. Essas localizações estratégicas abrangem todas as subáreas previamente delimitadas, levando em conta os aspectos geográficos mencionados anteriormente nesta seção para a implantação das ECVEs.

Para otimizar a abordagem, serão considerados três agentes externos como candidatos, os quais não possuem infraestrutura existente ilustrados na Tabela 2. No entanto, esses agentes externos são especialistas no mercado e possuem capacidade econômica para instalar ECVEs em locais disponíveis.

O conhecimento técnico desses agentes tanto na instalação quanto na gestão dos ECVEs pode facilitar a implementação de um sistema multiproprietário hierárquico competitivo. Atualmente, dois ECVEs estão operacionais e são geridos por entidades distintas.

O entendimento do mercado, da região e da demografia são elementos cruciais para estabelecer uma posição sólida dentro de uma abordagem competitiva. No entanto, é a capacidade da rede elétrica que determinará quantos agentes podem ser instalados em uma determinada área.

O candidato a agente ativo no mercado deve ter a capacidade de acolher um número considerável de veículos ou utilizadores durante um período de 1 a 3 horas. Além disso, é importante que disponha de espaço suficiente para atender aqueles usuários que utilizarão o serviço apenas por um curto período. A

Tabela 3 apresenta o tamanho das vagas de estacionamento dos potenciais candidatos a agentes.

Tabela 2 – Potenciais novos agentes

Agentes potenciais	Locais potenciais para novas estações.							
	Área 1	Área 2	Área 3	Área 4	Área 5	Área 6	Área 7	Área 8
Estação existente 1	✓					✓		
Estação existente 2		✓						
Candidato externo 1		✓		✓	✓		✓	
Candidato externo 2	✓			✓		✓		✓
Candidato externo 3				✓	✓			✓

Fonte: Elaborado pelo autor.

Tabela 3 – Tamanho dos potenciais agentes presentes


Agentes potenciais	Tamanho dos potenciais agentes presentes.			
	de 50 a 200 veículos	de 200 a 500 veículos	de 500 a 800 veículos	excede 800 veículos
Franquia de supermercado 1	✓	✓		
Franquia de supermercado 2	✓	✓	✓	
Franquia de supermercado 3	✓	✓		
Proprietário do estacionamento 1		✓		
Proprietário do estacionamento 2	✓		✓	
Proprietário do estacionamento 3		✓		
Proprietário do estacionamento 4	✓	✓		
Agente existente 1	✓			
Agente existente 2	✓			
Franquia de shopping 1				✓
Franquia de shopping 2				✓
Franquia de shopping 3				✓

Fonte: Elaborado pelo autor.

4.1 RESULTADOS DA ETAPA 1

A análise geoespacial e socioeconômica desenvolvida na secção 2 levou em consideração a relação dos fatores de densidade populacional e distância entre as áreas estudadas, esta relação resultou em um perfil de carga ilustrado na Figura 18.

Figura 18 – Perfis de demanda de carregamento dos VEs.



Fonte: Elaborado pelo autor.

Com base no perfil agregado de VEs gerado a partir da análise geoespacial e socioeconômica, foi possível identificar e modular a necessidade de estações de carga em cada área da cidade.

Esse perfil serviu como referência para o processo de avaliação, orientando a candidatura e a seleção das entidades mais adequadas por meio da aplicação da lógica fuzzy, garantindo que a distribuição das ECVEs fosse alinhada à demanda projetada para cada região.

4.2 RESULTADOS DA ETAPA 2

Na avaliação dos critérios estabelecidos, um total de 26 entidades se candidatou. Destas, 9 se destacaram ao obter as melhores pontuações, indicando sua maior adequação para a instalação de ECVEs. Esses resultados são apresentados na Figura 19 e fornecem uma base sólida para as conclusões derivadas do método proposto.


A Figura 21 apresenta um mapa de calor para cada um dos critérios avaliados: geoespacial, econômico e de dependência. Esses mapas de calor ilustram a distribuição e a intensidade dos valores atribuídos a cada candidato dentro de suas respectivas áreas.

Ao analisar as áreas com maior concentração de cores intensas, é possível identificar os candidatos que se destacam em cada critério, facilitando a visualização das zonas mais favoráveis para a instalação de ECVEs.

O resultado do método proposto para a classificação de candidatos tornou-se a base de dados de entrada para o modelo de PLIM, que dimensiona as ECVEs. Segundo os critérios do

autor, apenas os candidatos que alcançaram uma pontuação superior a 0,25 na tabela final de classificação serão considerados como candidatos para dimensionamento.

Figura 19 – Resultados dos candidatos na avaliação do logica fuzzy




Fonte: Elaborado pelo autor.

Ressalta-se que existe a possibilidade de que todos os candidatos sejam inseridos no modelo de PLIM para o dimensionamento, caso o usuário assim deseje (como deveria ocorrer em um mercado aberto). No entanto, para que essa opção seja implementada, o usuário do modelo deve levar em consideração motivações não econômicas ou que não estejam orientadas pela lógica de competição de mercado por parte dos candidatos.

4.3 RESULTADOS DA ETAPA 3

A Figura 22 apresenta os resultados do modelo de PLIM, que representa a etapa final da metodologia estruturada proposta. Em vez de uma única solução ótima, a abordagem gerou uma fronteira eficiente de soluções apresentada na Figura 20, representando diferentes *trade-offs* entre os objetivos considerados.

Figura 20 – Fronteira de Pareto para alocação de ECVes



A escolha de $\alpha = 0,45$ como a solução de destaque dentro da fronteira de Pareto se justifica pelo equilíbrio entre custo de investimento e cobertura de distância. A fronteira de Pareto representa diferentes compromissos entre investimento e cobertura, onde soluções com valores menores de α reduzem significativamente o custo, mas também comprometem a cobertura, enquanto valores maiores aumentam a distância coberta com um crescimento expressivo no investimento. Para $\alpha = 0,45$, a solução selecionada proporciona uma cobertura de aproximadamente 4,76 mil km, com um investimento de cerca de R\$ 25,53 milhões, garantindo uma distribuição estratégica das estações de carregamento e maximizando a cobertura sem elevar excessivamente os custos.

Além disso, evita extremos não desejáveis, como custos proibitivos sem ganhos proporcionais em cobertura ou uma infraestrutura ineficaz devido a uma cobertura insuficiente. Com $\alpha = 0,45$, foi possível instalar 9 estações de carregamento bem distribuídas em toda a área de estudo, garantindo que os pontos de carregamento estejam posicionados estrategicamente para otimizar o atendimento à demanda projetada. Essas estações representam os candidatos à instalação de infraestrutura de carregamento melhor preparados segundo os resultados do processo de seleção de candidatos, assegurando que apenas as localizações mais

eficientes e viáveis sejam escolhidas. Dessa forma, essa solução se destaca por sua eficiência na alocação de recursos, garantindo uma infraestrutura robusta e economicamente viável para o suporte ao crescimento da mobilidade elétrica.

Figura 21 – Mapa de calor dos critérios avaliados.


Candidato	Área	Critério Geoespacial	Critério Econômico	Critério de dependência	Pontuação
2	1				
3					
1					
6	2				
5					
4					
9	3				
8					
7					
14	4				
13					
11					
12					
10					
15	5				
19	6				
16					
17					
18					
23	7				
22					
21					
20					
26	8				
25					
24					

Escala de intensidade verde de muito baixa a muito alta, onde V é o valor final do candidato em cada critério avaliado.

$V < 15\%$	$15\% < V < 30\%$	$30\% < V < 45\%$	$45\% < V < 60\%$	$60\% < V < 75\%$	$75\% < V$
------------	-------------------	-------------------	-------------------	-------------------	------------

Fonte: Elaborado pelo autor.

Figura 22 – Resultados do modelo de otimização.



Fonte: Elaborado pelo autor.

4.4 DISCUSSÕES

Os resultados obtidos a partir da método proposta fornecem uma visão abrangente e estruturada sobre a viabilidade e alocação estratégica de estações de carregamento de veículos elétricos (ECVEs) na cidade de Presidente Prudente, SP. A integração de análises geoespaciais, socioeconômicas e de mobilidade demonstrou ser um instrumento eficaz na identificação dos locais mais apropriados para a implantação dessa infraestrutura, garantindo um alinhamento com a demanda projetada.

Um dos principais aspectos a serem destacados é a seleção de candidatos baseada na lógica fuzzy, que permitiu classificar as 26 entidades conforme sua adequação às necessidades do sistema de carregamento. A identificação de nove candidatos prioritários evidencia que a metodologia aplicada foi capaz de filtrar as opções mais robustas considerando fatores espaciais, econômicos e estruturais. Os mapas de calor apresentados na Figura 23 corroboram essa seleção ao ilustrar a distribuição e intensidade dos critérios analisados, proporcionando uma compreensão clara sobre as áreas mais favoráveis.

A incorporação do modelo de PLIM permitiu dimensionar as ECVEs de forma otimizada, considerando a relação entre oferta e demanda. A solução ótima obtida, com a instalação de nove estações distribuídas estrategicamente e capacidade variando de dois a cinco pontos de carregamento, demonstra a eficiência da metodologia proposta. O parâmetro $\alpha = 0,45$ utilizado reforça a abordagem balanceada entre investimentos e cobertura da demanda, evitando sobrecarga em determinados pontos e garantindo a viabilidade econômica da infraestrutura planejada.

Outro aspecto relevante diz respeito à participação dos agentes externos no processo de planejamento. A inclusão de três candidatos sem infraestrutura prévia, mas com expertise no mercado, amplia as possibilidades de expansão do sistema, permitindo uma abordagem mais flexível e alinhada à dinâmica do mercado de mobilidade elétrica. Essa diversificação na composição dos agentes reforça a natureza competitiva do modelo e possibilita uma adaptação mais eficiente a cenários futuros de crescimento da demanda.

Por fim, a metodologia adotada não apenas favorece a distribuição racional das ECVEs, mas também estabelece um referencial para estudos futuros voltados ao aprimoramento de redes de carregamento veicular. A possibilidade de expansão da modelagem, considerando um número maior de candidatos e variáveis dinâmicas como incentivos fiscais e padrões de uso de VEs, pode contribuir para o refinamento do método e sua aplicação em diferentes contextos urbanos. Dessa forma, o estudo apresenta não apenas uma solução viável para Presidente Prudente, mas também uma abordagem replicável para outras regiões em processo de eletrificação da frota veicular.

4.5 LIMITAÇÕES DO MÉTODO PROPOSTO

Dentre as limitações do método proposto, destaca-se a etapa de coleta de dados, particularmente na construção do perfil de carga, que pode ser influenciada pela qualidade das informações socioeconômicas obtidas por meio de pesquisas.

No caso apresentado, a cidade analisada possui um porte reduzido, o que facilita a obtenção de dados detalhados e sua atualização frequente. No entanto, em cidades de grande porte, a coleta dessas informações pode ser menos precisa ou estar desatualizada, comprometendo a representatividade dos dados utilizados no modelo.

Outra limitação a ser considerada está no processo de seleção de candidatos. Em municípios menores, o número de candidatos que atendem aos critérios necessários para a instalação de estações de recarga de veículos elétricos tende a ser reduzido. Já em cidades maiores, onde há uma quantidade significativamente maior de entidades interessadas em participar do processo de candidatura, o método pode ser desafiado pela complexidade da seleção.

No entanto, essa limitação pode ser mitigada ao aplicar o método em etapas, inicialmente avaliando candidatos por áreas específicas, permitindo que os mais bem classificados avancem para uma fase subsequente em cenários de alta demanda.

Por fim, o procedimento proposto para a distribuição e o dimensionamento das estações de recarga também pode ser objeto de debate em relação às limitações de seus resultados. Embora a formulação matemática tenha sido desenvolvida de forma genérica para ser aplicável a diferentes redes elétricas, sua eficiência poderia ser aprimorada com a incorporação de parâmetros específicos que se ajustam às características particulares de cada rede analisada. Esses parâmetros adaptativos poderiam incluir, por exemplo, a capacidade de cada ponto da rede, a variação da demanda local e as condições operacionais específicas, permitindo que o modelo responda de forma mais precisa às particularidades do sistema elétrico. Dessa forma, os resultados seriam mais sensíveis e eficazes, refletindo com maior exatidão as condições reais da rede.

5 CONCLUSÕES

O crescimento acelerado da frota de veículos elétricos (VEs) exige a implementação de uma infraestrutura de carregamento robusta, eficiente e adaptável, capaz de atender à demanda crescente. A integração de diferentes abordagens metodológicas, como a PLIM, lógica fuzzy e cadeias de Markov, demonstra ser essencial para a criação de soluções inovadoras no planejamento e dimensionamento das ECVEs. Este estudo abordou os desafios do planejamento de ECVEs de forma holística, levando em consideração os fatores geoespaciais, socioeconômicos e a dinâmica das redes elétricas. A análise geoespacial, combinada com métodos probabilísticos, como as cadeias de Markov, forneceu uma visão detalhada sobre as demandas de carregamento dos VEs, considerando características específicas da população e o comportamento de consumo de energia. Isso permitiu uma modelagem mais precisa das necessidades de infraestrutura de carregamento, refletindo a interação entre a penetração dos VEs, o consumo de energia e as características socioeconômicas da região.

A aplicação de métodos avançados possibilitou uma estimativa precisa de 4.600 VEs na cidade de Presidente Prudente, evidenciando a importância de uma abordagem dinâmica e realista para o planejamento de ECVEs. Além disso, a incorporação da lógica fuzzy, por meio da função de pertinência triangular, permitiu uma avaliação mais refinada e adaptativa dos locais para a instalação das ECVEs, considerando múltiplos critérios imprecisos e variáveis. Esse método, ao integrar a análise geoespacial com a lógica fuzzy, revelou-se eficaz para classificar e priorizar as áreas com maior potencial de adoção de VEs, promovendo uma alocação estratégica dos recursos. A flexibilidade e precisão proporcionadas por essa abordagem tornam-na uma ferramenta valiosa para o planejamento sustentável e eficiente da infraestrutura de carregamento.

A proposta híbrida que combina a lógica fuzzy com a PLIM representa um avanço significativo ao abordar a otimização simultânea do local e do dimensionamento das ECVEs, considerando as restrições financeiras e a redução do tempo de espera dos usuários. A metodologia não só otimiza os custos operacionais e de investimento, como também promove uma distribuição espacial mais eficiente das estações, levando em conta fatores socioeconômicos e geográficos.

Além disso, embora não tenha sido possível verificar a adaptabilidade do modelo a uma grande diversidade de cenários de planejamento, como o planejamento em larga escala ou o reforço de uma rede deficiente, os testes realizados confirmaram sua eficácia em cenários de

crescimento controlado. Os resultados demonstraram que o método proposto apresenta rápida adaptabilidade nessas condições, garantindo uma alocação equilibrada e eficiente dos recursos, evitando concentrações excessivas e favorecendo a distribuição otimizada das estações de carga.

A transparência e a equidade no processo asseguram que cada participante seja avaliado de maneira justa, contribuindo para um mercado acessível e competitivo. Em suma, este estudo demonstrou que a combinação de métodos como a lógica fuzzy, MILP e análise geoespacial pode fornecer soluções eficazes e sustentáveis para o planejamento e dimensionamento de ECVes.

A capacidade de adaptação às mudanças nas condições locais, a otimização do tempo de espera dos usuários e a consideração de múltiplos fatores geoespaciais e socioeconômicos são aspectos cruciais para o sucesso da infraestrutura de carregamento de VEs.

Utilizando a abordagem e os dados apresentados nesta pesquisa, diversos trabalhos futuros podem ser considerados.

- Incluir a motivação não econômica dos candidatos participantes no mercado de VEs, por meio da aplicação de simulações de Monte Carlo, que permitiria uma análise mais detalhada das preferências e decisões dos agentes, considerando incertezas e variabilidade nas condições do mercado e comportamentos dos usuários.

Este aspecto poderia proporcionar uma modelagem mais realista, levando em conta fatores como a conscientização ambiental, incentivos governamentais e outros elementos que não sejam puramente econômicos, mas que influenciam diretamente as escolhas e o posicionamento dos agentes no mercado de infraestrutura de recarga.

- Explorar a inclusão de energia distribuída ou de carregadores inversores no modelo, o que poderia otimizar o uso da infraestrutura existente e reduzir custos com a construção de novas instalações.

A integração de fontes de energia renováveis, como painéis solares, poderia ser incorporada ao planejamento das estações de recarga, permitindo uma abordagem mais sustentável e resiliente.

- Adaptar o modelo a cenários mais dinâmicos ou não reestruturáveis, onde as condições de mercado e a distribuição geoespacial da demanda poderiam mudar ao longo do tempo. Nesse caso, a flexibilidade do modelo permitiria ajustes contínuos nas alocações e dimensionamentos das estações, garantindo que o sistema se adapte de forma eficiente a variáveis como o aumento da frota

de VEs ou alterações nas políticas públicas relacionadas à mobilidade sustentável.

REFERÊNCIAS

- ABDMOULEH, Z.; GASTLI, A.; BEN-BRAHIM, L.; HAOUARI, M.; AL-EMADI, N. A. Review of optimization techniques applied for the integration of distributed generation from renewable energy sources. **Renewable Energy**, Dohav. 113, p. 266-280, 2017. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1364032116307432>. Acesso em: 5 set. 2023.
- ALARCÓN, F. E.; CAWLEY, A. Mac; SAUMA, E. Electric mobility toward sustainable cities and road-freight logistics: A systematic review and future research directions. **Journal of Cleaner Production**, [s. l.], v. 430, p. 138959, 2023.
- ALJAIDI, M.; ASLAM, N.; KAIWARTYA, O. Optimal placement and capacity of electric vehicle charging stations in urban areas: Survey and open challenges. *In*: IEEE JORDAN INTERNATIONAL JOINT CONFERENCE ON ELECTRICAL ENGINEERING AND INFORMATION TECHNOLOGY (JEEIT), 2019, Amman. **Anais [...]**. Amman: IEEE, 2019. p. 238–243.
- AMPL Corporation. **AMPL Optimization Software**. Versão 2024. [S. l.: s. n.], 2024.
- AYDIN, N. Y.; KENTEL, E.; SEBNEM DUZGUN, H. GIS-based site selection methodology for hybrid renewable energy systems: A case study from western Turkey. **Energy Conversion and Management**, [s. l.], v. 70, p. 90–106, 2013.
- BAGHERI TOOKANLOU, M.; MARZBAND, M.; SUMAITI, A.; MAZZA, A. Cost-benefit analysis for multiple agents considering an electric vehicle charging/discharging strategy and grid integration. *In*: IEEE MEDITERRANEAN ELECTROTECHNICAL CONFERENCE (MELECON), 20., 2020, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2020. p. 19–24.
- BUSTOS-TURU, G.; VAN DAM, K. H.; ACHA, S.; MARKIDES, C. N.; SHAH, N. Simulating residential electricity and heat demand in urban areas using an agent-based modelling approach. *In*: IEEE INTERNATIONAL ENERGY CONFERENCE (ENERGYCON), 2016, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2016. p. 1–6.
- CHEN, Y.; DE, H. Z.; PARRA, L.; HESS, F. Dynamic simulation of EV fast charging with integration of renewables. *In*: IEEE INTERNATIONAL ELECTRIC VEHICLE CONFERENCE, 2012, Greenville. **Anais [...]**. Greenville: IEEE, 2012. p. 1–5.
- EHSAN ALI; YANG QIANG. State-of-the-art techniques for modelling of uncertainties in active distribution network planning: A review. **Applied Energy**, Hangzhou, v. 239, n. 3, p. 1509–1523, 2019.
- ENVIRONMENTAL SYSTEMS RESEARCH INSTITUTE. **ArcGIS**: versão 10.5. Redlands: Environmental Systems Research Institute, 2017.
- FALVO, M. C.; MANGANELLI, M.; MOSCATIELLO, C.; VELLUCCI, F. Electrical vehicles and charging stations: state of art and future perspectives. *In*: IEEE INTERNATIONAL CONFERENCE ON ENVIRONMENT AND ELECTRICAL ENGINEERING; IEEE INDUSTRIAL AND COMMERCIAL POWER SYSTEMS EUROPE (EEEIC / I&CPS EUROPE), 2022, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2022. p. 1–7.

FAUSTINO, F. J.; LOPES, J. C.; MELO, J. D.; SOUSA, T.; PADILHA-FELTRIN, A.; BRITO, J. A. S.; GARCIA, C. O. Identifying charging zones to allocate public charging stations for electric vehicles. **Energy**, [s. l.], v. 283, p. 128436, 2023.

FIGUEIRA, J.; GRECO, S.; EHROGOTT, M. **Multiple criteria decision analysis: state of the art surveys**. New York, NY: Springer New York, 2005. 2005.v. 78.

GAO, X.; CHAN, K. W.; XIA, S.; ZHANG, X.; ZHANG, K.; ZHOU, J. A multiagent competitive bidding strategy in a pool-based electricity market with price-maker participants of wpps and ev aggregators. **IEEE Transactions on Industrial Informatics**, [s. l.], v. 17, n. 11, p. 7256–7268, 2021.

GARAU, M.; TORSATER, B. N. Agent-based analysis of spatial flexibility in ev charging demand at public fast charging stations. *In*: IEEE MADRID POWERTECH; 2021a, [s. l.]. **Proceedings** [...]. [S. l.]: Institute of Electrical and Electronics Engineers Inc., 2021.

GARAU, M.; TORSATER, B. N. Agent-based analysis of spatial flexibility in EV charging demand at public fast charging stations. *In*: IEEE MADRID POWERTECH, 2021b, [s. l.]. **Proceedings** [...]. [S. l.]: Institute of Electrical and Electronics Engineers Inc., 2021. Disponível em: Acesso em: 21 fev. 2024.

GARCIA-TRIVINO, P.; FERNANDEZ-RAMIREZ, L. M.; TORREGLOSA, J. P.; JURADO, F. Fuzzy logic control for an electric vehicles fast charging station. *In*: INTERNATIONAL SYMPOSIUM ON POWER ELECTRONICS, ELECTRICAL DRIVES, AUTOMATION AND MOTION (SPEEDAM), 2016a, [s. l.]. **Anais** [...]. [S. l.]: IEEE, 2016. p. 1099–1103.

GARCIA-TRIVINO, P.; FERNANDEZ-RAMIREZ, L. M.; TORREGLOSA, J. P.; JURADO, F. Fuzzy logic control for an electric vehicles fast charging station. *In*: INTERNATIONAL SYMPOSIUM ON POWER ELECTRONICS, ELECTRICAL DRIVES, AUTOMATION AND MOTION (SPEEDAM), 2016b, [s. l.]. **Anais** [...]. [S. l.]: IEEE, 2016. p. 1099–1103.

GUANG, L.; CHENGBI, Z. Location planning of charging station for electric vehicle based on urban traffic flow. *In*: CHINA INTERNATIONAL CONFERENCE ON ELECTRICITY DISTRIBUTION (CICED), 2016, [s. l.]. **Anais** [...]. [S. l.]: IEEE, 2016. p. 1–5.

GUO, J. New method of energy charging station site selection based on fuzzy evaluation. *In*: CHINESE CONTROL AND DECISION CONFERENCE (CCDC), 33., 2021, [s. l.]. **Anais** [...]. [S. l.]: IEEE, 2021. p. 3896–3901.

H. J. ANDERSON. The environmental benefits of electric vehicles: a comprehensive e review. **Journal of Cleaner Production**, [s. l.], v. 256, n. 1, p. 1–12, 2020.

HU, S.; YANG, J.; LIAO, K.; LI, B.; HE, Z. An equivalent method of distributed generation based on discharge behavior of large-scale electric vehicles. *In*: ASIA ENERGY AND ELECTRICAL ENGINEERING SYMPOSIUM (AEEES), 3., 2021, Chengdu. **Anais** [...]. Chengdu: IEEE, 2021. p. 833–838.

IBM. **IBM ILOG CPLEX Optimization Studio 20.1.0 documentation**: versão 20.1.0. [S. l.]: IBM, 2024.

ILLING, B.; WARWEG, O. Analysis of international approaches to integrate electric vehicles into energy market. *In: INTERNATIONAL CONFERENCE ON THE EUROPEAN ENERGY MARKET (EEM)*, 12., 2015, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2015. p. 1–5.

J. K. DAVIS; P. L. EDWARDS. Infrastructure needs for electric vehicles: a review of charging station deployment. **Energy Policy**, [s. l.], v. 138, n. 1, p. 111–123, 2021.

JAWAD, S.; LIU, J. electrical vehicle charging load mobility analysis based on spatial-temporal model in traffic-distribution networks. *In: PANDA FORUM ON POWER AND ENERGY (PANDAFPE)*, 2023, [s. l.]. **Anais [...]**. [S. l.]: Institute of Electrical and Electronics Engineers Inc., 2023. p. 700–704.

JIAWEI ZHANG; SHIWEI XIA; KA WING CHAN. Decentralized automatic load management of EV charging network. *In: IET INTERNATIONAL CONFERENCE ON ADVANCES IN POWER SYSTEM CONTROL, OPERATION AND MANAGEMENT (APSCOM)*, 11., 2018, [s. l.]. **Anais [...]**. [S. l.]: Institution of Engineering and Technology, 2018.

JIDONG WANG; KAIJIE FANG; WEI HE. A research for the interactive behavior between electric vehicle and residential energy management system based on probability distribution. *In: INTERNATIONAL CONFERENCE ON POWER ELECTRONICS SYSTEMS AND APPLICATIONS (PESA)*, 6., 2015, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2015. p. 1–6.

KARAŞAN, A.; KAYA, İ.; ERDOĞAN, M. Location selection of electric vehicles charging stations by using a fuzzy MCDM method: a case study in Turkey. **Neural Computing and Applications**, [s. l.], v. 32, n. 9, p. 4553–4574, 2020.

KARMAKER, A. K.; RAJU AHMED, Md. Fuzzy logic based optimization for electric vehicle charging station in bangladesh. *In: INTERNATIONAL CONFERENCE ON ADVANCES IN SCIENCE, ENGINEERING AND ROBOTICS TECHNOLOGY (ICASERT)*, 1., 2019, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2019. p. 1–5.

KARMAKER, A. K.; STURMBERG, B.; BEHRENS, S.; HOSSAIN, M. J.; POTA, H. Characterizing electric vehicle plug-in behaviors using customer classification approach. *In: IEEE INTERNATIONAL CONFERENCE ON ENERGY TECHNOLOGIES FOR FUTURE GRIDS (ETFG)*, 2023, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2023. p. 1–6.

KRISHNA, G. Understanding and identifying barriers to electric vehicle adoption through thematic analysis. **Transportation Research Interdisciplinary Perspectives**, [s. l.], v. 10, p. 100364, 2021.

KUMAR, P.; CHANNI, H. K. Optimal site selection and economic scheduling of electric vehicle charging station using homer: A case study of Tohana, Haryana. *In: INTERNATIONAL CONFERENCE ON ADVANCES IN ELECTRICAL, COMPUTING, COMMUNICATION AND SUSTAINABLE TECHNOLOGIES (ICAECT)*, 4., 2024, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2024. p. 1–6.

KUMAR, R.; VERMA, M.; KULKARNI, A. Optimizing bidirectional EV charger with rapid charging architecture using fuzzy logic control. *In: INTERNATIONAL CONFERENCE FOR*

INNOVATION IN TECHNOLOGY (INOCON), 3., 2024, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2024. p. 1–6.

LAZAROIU, C.; ROSCIA, M.; SAADATMANDI, S. Blockchain and fuzzy logic application in ev's charging. *In*: INTERNATIONAL CONFERENCE ON RENEWABLE ENERGY RESEARCH AND APPLICATION (ICRERA), 9., 2020, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2020. p. 315–320.

LILI GONG; WU CAO; JIANFENG ZHAO. Load modeling method for EV charging stations based on trip chain. *In*: IEEE CONFERENCE ON ENERGY INTERNET AND ENERGY SYSTEM INTEGRATION (EI2), 2017, [s. l.]. **Anais [...]**. [S. l.: s. n.], 2017. p. 1–5.

MAHMOUDI, E.; RUPPERT FILHO, E. Spatial-temporal prediction of electric vehicle charging demand in realistic urban transportation system of a mid-sized city in Brazil. *In*: INTERNATIONAL CONFERENCE ON ELECTRICAL AND ELECTRONICS ENGINEERING (ICEEE), 8., 2021a, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2021. p. 168–173.

MAKSYM OLIINYK; JAROSLAV DŽMURA; DANIEL PÁL. The impact of a electric vehicle charging on the distribution system. *In*: INTERNATIONAL SCIENTIFIC CONFERENCE ON ELECTRIC POWER ENGINEERING (EPE), 20., 2020, Prague. **Proceedings [...]**. Prague: IEEE, 2020. p. 1–5.

MARIA CARMEN FALVO; MATTEO MANGANELLI; CRISTINA MOSCATIELLO; FRANCESCO VELLUCCI. Electrical vehicles and charging stations: State of art and future perspectives. *In*: IEEE INTERNATIONAL CONFERENCE ON ENVIRONMENT AND ELECTRICAL ENGINEERING; IEEE INDUSTRIAL AND COMMERCIAL POWER SYSTEMS EUROPE (EEEIC/I&CPS EUROPE), 2022, Prague. **Proceedings [...]**. Prague: IEEE, 2022. p. 1–7.

MORRO-MELLO, I.; PADILHA-FELTRIN, A.; MELO, J. D.; CALVIÑO, A. Fast charging stations placement methodology for electric taxis in urban zones. **Energy**, [s. l.], v. 188, p. 116032, 2019.

NI, X.; LO, K. L. A Methodology to model daily charging load in the EV charging stations based on monte carlo simulation. *In*: INTERNATIONAL CONFERENCE ON SMART GRID AND CLEAN ENERGY TECHNOLOGIES (ICSGCE), 2020, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2020. p. 125–130.

NOURBAKSH, M. S.; MANSHAEI, M. H.; RAHMAN, M. A.; SAAD, W. Electric vehicle consumption markets: An economic analysis. *In*: IEEE GLOBAL CONFERENCE ON SIGNAL AND INFORMATION PROCESSING (GLOBALSIP), 2016, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2016. p. 906–910.

PAGANY, R.; RAMIREZ CAMARGO, L.; DORNER, W. A review of spatial localization methodologies for the electric vehicle charging infrastructure. **International Journal of Sustainable Transportation**, [s. l.], v. 13, n. 6, p. 433–449, 2019.

PAMIDIMUKKALA, A.; KERMANSHACHI, S.; ROSENBERGER, J. M.; HLADIK, G. Barriers and motivators to the adoption of electric vehicles: a global review. **Green Energy and Intelligent Transportation**, [s. l.], v. 3, n. 2, p. 100153, 2024.

PAPATHANASIOU, J.; PLOSKAS, N. **Multiple criteria decision aid**. Cham: Springer International Publishing, 2018. 2018.v. 136.

PARK, J.; SIM, Y.; LEE, G.; CHO, D.-H. A Fuzzy logic based electric vehicle scheduling in smart charging network. *Em: IEEE ANNUAL CONSUMER COMMUNICATIONS & NETWORKING CONFERENCE (CCNC)*, 16., 2019, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2019. p. 1–6.

PRAVEEN, V.; KOUSALYA, K.; PRASANNA KUMAR, K. R. A nearest centroid classifier based clustering algorithm for solving vehicle routing problem. *In: INTERNATIONAL CONFERENCE ON ADVANCES IN ELECTRICAL, ELECTRONICS, INFORMATION, COMMUNICATION AND BIO-INFORMATICS (AEEICB)*, 2., 2016, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2016. p. 414–419.

Q. L. FONG; R. H. NGUYEN. Spatial optimization for electric vehicle charging stations: A review of methods and techniques. **Journal of Urban Planning and Development**, [s. l.], v. 147, n. 2, p. 0402–1023, 2021.

R. N. SMITH. Predictive models for electric vehicle charging demand and optimal station location. **Transportation Research Part C: Emerging Technologies**, [s. l.], v. 132, n. 1, p. 103–120, 2022.

RADU, A.-T.; EREMIA, M.; TOMA, L. Participation of the electric vehicles in the balancing market. *In: ELECTRIC VEHICLES INTERNATIONAL CONFERENCE (EV)*, 2019, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2019. p. 1–6.

REQUIA, W. J.; MOHAMED, M.; HIGGINS, C. D.; ARAIN, A.; FERGUSON, M. How clean are electric vehicles? Evidence-based review of the effects of electric mobility on air pollutants, greenhouse gas emissions and human health. **Atmospheric Environment**, [s. l.], v. 185, p. 64–77, 2018.

ROMERO, R.; ROCHA, C.; MANTOVANI, M.; MANTOVANI, J. R. S. Analysis of heuristic algorithms for the transportation model in static and multistage planning in network expansion systems. **IEE Proceedings: Generation, Transmission and Distribution**, New York, v. 150, n. 5, p. 521–526, 2003.

S. P. GUPTA. Optimization models for electric vehicle charging station placement: A case study. **Operations Research Perspectives**, [s. l.], v. 8, n. 1, p. 100–115, 2021.

SANER, C. B.; TRIVEDI, A.; SRINIVASAN, D. A cooperative hierarchical multi-agent system for ev charging scheduling in presence of multiple charging stations. **IEEE Transactions on Smart Grid**, [s. l.], v. 13, n. 3, p. 2218–2233, 2022.

SEMARIA RUIZ ALVAREZ; JAIRO JOSÉ ESPINOSA OVIEDO. State of the art in strategies allowing the integration of a shared EVs service and the active participation of EVs

with the power network. *Em: IEEE COLOMBIAN CONFERENCE ON AUTOMATIC CONTROL (CCAC)*, 41., 2019, Medellin. **Anais [...]**. Medellin: IEEE, 2019. p. 1–6.

SHARMA, A.; SRINIVASAN, D.; TRIVEDI, A. A decentralized multiagent system approach for service restoration using DG islanding. **IEEE Transactions on Smart Grid**, [s. l.], v. 6, n. 6, p. 2784–2793, 2015.

SWANN, W. H. A survey of non-linear optimization techniques. **FEBS Letters**, Amsterdam, v. 2, suppl., p. S39–S55, 1969.

VISWANATH, B.; KHATOD, D. K.; PADHY, N. P. Optimal vehicle-to-grid (V2G) scheduling of plug-in electric vehicles (PEVs) for grid peak demand management: a state-of-the-art review. *In: IEEE INTERNATIONAL CONFERENCE ON POWER ELECTRONICS, DRIVES AND ENERGY SYSTEMS (PEDES)*, 2022, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2022. p. 1–6.

WAN, Y.; CAO, W.; WANG, L. A prediction method for EV charging load based on fuzzy inference algorithm. *In: CHINESE CONTROL CONFERENCE (CCC)*, 2019, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2019. p. 2803–2808.

WANG, S.; DU, L.; LI, Y. Decentralized volt/var control of EV charging station inverters for voltage regulation. *In: 2020 IEEE TRANSPORTATION ELECTRIFICATION CONFERENCE & EXPO (ITEC)*, 2020, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2020. p. 604–608.

WANG, S.; XIANG, Y.; HU, H.; TONG, J.; TANG, C.; TIAN, Z. Fuzzy classification based charging route planning for massive electric vehicles considering traffic congestion. *In: 2023 PANDA FORUM ON POWER AND ENERGY (PANDAFPE)*, 2023, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2023. p. 1547–1551.

WECKX, S.; D'HULST, R.; CLAESSENS, B.; DRIESSENSAM, J. Multiagent charging of electric vehicles respecting distribution transformer loading and voltage limits. **IEEE Transactions on Smart Grid**, [s. l.], v. 5, n. 6, p. 2857–2867, 2014.

YAN, L.; CHEN, X.; CHEN, Y.; WEN, J. A cooperative charging control strategy for electric vehicles based on multiagent deep reinforcement learning. **IEEE Transactions on Industrial Informatics**, [s. l.], v. 18, n. 12, p. 8765–8775, 2022.

YANDULSKII, A.; KURSON, O.; BOSAK, A.; KONDRATIEV, S.; KUZNIETSOV, A. improvement of electric charging station efficiency using situation-dependent fuzzy algorithms. *In: IEEE INTERNATIONAL CONFERENCE ON ELECTRICAL SYSTEMS FOR AIRCRAFT, RAILWAY, SHIP PROPULSION AND ROAD VEHICLES; INTERNATIONAL TRANSPORTATION ELECTRIFICATION CONFERENCE (ESARS-ITEC)*, 2018, [s. l.]. **Anais [...]**. [S. l.]: IEEE, 2018. p. 1–6.

YING LU; SHAOQUN SONG; YONGMING WANG; FENG CHEN; ZHAOHAO DING. Traffic-aware energy management for EV charging aggregator considering spatial and temporal load distribution. *In: IEEE CONFERENCE ON ENERGY INTERNET AND ENERGY SYSTEM INTEGRATION*, 2, 2018, Beijing. **Anais [...]**. Beijing: IEEE, 2018. p. 1–6.

YUSUF, J.; JAHID HASAN, A. S. M.; ULA, S. EV penetration impact analysis on transmission system using co-simulation. *In: IEEE TRANSPORTATION ELECTRIFICATION CONFERENCE AND EXPO (ITEC) 2022, Anaheim. Anais [...].* Anaheim: Institute of Electrical and Electronics Engineers Inc., 2022. p. 1154–1158.

ZHAO, Z.; XU, M.; LEE, C. K. M. Capacity planning for an electric vehicle charging station considering fuzzy quality of service and multiple charging options. **IEEE Transactions on Vehicular Technology**, [s. l.], v. 70, n. 12, p. 12529–12541, 2021.

ZHIYONG TIAN; YI WANG; CHEN TIAN; FAN ZHANG; LAI TU; CHENGZHONG XU. Understanding operational and charging patterns of electric vehicle taxis using GPS records. *In: INTERNATIONAL IEEE CONFERENCE ON INTELLIGENT TRANSPORTATION SYSTEMS (ITSC)*, 17, 2014, Qingdao. **Anais [...].** Qingdao: IEEE, 2014. p. 2472–2479.

APÊNDICE – TRABALHOS DESENVOLVIDOS DURANTE O MESTRADO

ANTUNEZ, Andres Luis Sabillon; ALZATE, Mario Andrés Mejía; FRANCO, John Fredy Franco. APLICAÇÃO DE CADEIAS DE MARKOV PARA A ESTIMATIVA ESPAÇO-TEMPORAL DE PERFIS DE CARREGAMENTO DE VEÍCULOS ELÉTRICOS.. In: Anais do VIII ERMAC Regional 9 - Ilha Solteira. Anais...Ilha Solteira(SP) FEIS - Unesp, 2024. Disponível em: <https://www.even3.com.br/anais/viiiiermacr9/832043-APLICACAO-DE-CADEIAS-DE-MARKOV-PARA-A-ESTIMATIVA-ESPACO-TEMPORAL-DE-PERFIS-DE-CARREGAMENTO-DE-VEICULOS-ELETRICOS>. Acesso em: 10/04/2025

ANTUNEZ, Andres Luis Sabillon; ALZATE, Mario Andrés Mejía; FRANCO, John Fredy Franco. IDENTIFICAÇÃO DE LOCAIS CANDIDATOS PARA ESTAÇÕES DE CARREGAMENTO DE VEÍCULOS ELÉTRICOS USANDO ANÁLISE GEOESPACIAL E LÓGICA FUZZY. In: XV Congreso Latino-Americano de Generación y Transmisión de Energía Eléctrica – Mar del plata, Argentina, 2024.

ANTUNEZ, Andres Luis Sabillon; ALZATE, Mario Andrés Mejía; FRANCO, John Fredy Franco. UM MODELO DE OTIMIZAÇÃO MULTIOBJETIVO PARA O PLANEJAMENTO ÓTIMO DE INFRAESTRUTURA DE CARREGAMENTO DE VEÍCULOS ELÉTRICOS. In: XXV Congresso Brasileiro de Automática – Rio de Janeiro, Brasil, 2024. Disponível em: https://www.sba.org.br/cba2024/papers/paper_3040.pdf.

ANTUNEZ, Andres Luis Sabillon; ALZATE, Mario Andrés Mejía; FRANCO, John Fredy Franco. OPTIMAL SITING AND SIZING OF EV CHARGING STATIONS USING FUZZY LOGIC AND MULTI-OBJECTIVE OPTIMIZATION. In: 9th IEEE Texas Power and Energy Conference (TPEC 2025) – College station Texas, United States, 2025.