Um Modelo de Otimização Multiobjetivo para o Planejamento Ótimo de Infraestrutura de Carregamento de Veículos Elétricos

Andres L. Sabillon*, Mario A. Mejía*, John F. Franco*

Universidade Estadual Paulista "Júlio de Mesquita Filho" (UNESP), Faculdade de Engenharia, Ilha Solteira.
e-mail: andres.sabillon@unesp.br, mario.andres@unesp.br, fredy.franco@unesp.br.

Abstract: Electric vehicles (EVs) play a crucial role in reducing environmental pollution by helping to decrease reliance on fossil fuels and promote urban sustainability. However, the widespread adoption of these vehicles brings significant challenges, especially in the planning of electric vehicle charging stations (EVCSs). This article introduces a new multi-objective optimization model for efficient planning of EVCSs in urban areas. The model aims to simultaneously minimize investment costs and distances between EVCSs while managing vehicle charging within a maximum wait time limit. The proposed approach incorporates geospatial analysis to model the dynamics of EV travel patterns and user charging preferences. This allows for estimating EV charging demands by subarea and thus planning EVCSs efficiently. The model was tested using sociodemographic data from a medium-sized Brazilian city, and the results validate its ability to determine the optimal size and location of EVCSs to meet EV charging demands.

Resumo: Os veículos elétricos (VEs) desempenham um papel crucial na redução da poluição ambiental ao ajudar a diminuir a dependência de combustíveis fósseis e impulsionar a sustentabilidade urbana. Contudo, a ampla adoção desses veículos traz consigo desafios significativos, especialmente no planejamento de estações de carregamento de veículos elétricos (ECVEs). Este artigo introduz um modelo de otimização multiobjetivo para o planejamento eficiente de ECVEs em áreas urbanas. O modelo busca minimizar simultaneamente os custos de investimento e as distâncias entre as ECVEs, enquanto gerencia o carregamento dos VEs dentro de um limite máximo de tempo de espera. A abordagem proposta incorpora análise geoespacial para modelar as dinâmicas dos deslocamentos dos VEs e as preferências de carregamento dos usuários. Isso permite estimar as demandas de carregamento dos VEs por subárea e, assim, planejar as ECVEs de maneira eficiente. O modelo foi testado utilizando dados sociodemográficos de uma cidade brasileira de médio porte, e os resultados validam sua capacidade de determinar o tamanho e a localização ideais das ECVEs para atender às demandas de carregamento dos VEs.

Keywords: Electric mobility; energy efficiency; geospatial analysis; Markov chains; multiobjective mathematical optimization; planning of electric vehicle charging stations.

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

NOMENCLATURA

α	Parâmetro de combinação convexa que atribui a importância aos objetivos de investimento e distância.
$\beta_{z,j}^{den}$	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.
$\overline{\gamma}$	Máximo de carregadores que podem ser instalados em uma ECVE
δ_t	Tempo de espera para um VE ser carregado em uma 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.
$\sigma_{z,j}$	Possibilidade de que um VE da área z seja carregado na área j.
φ^{ve}	Possibilidade de adoção dos VEs.
A_z^{ad}	Parcela dos habitantes da área z candidatos para comprar um VE.
C^{ve}	Valor médio de energia de carregamento dos VEs.
CF	Custo de instalação de uma ECVE.
$d_{z,k}$	Distância entre o centróide da área z e o local de carregamento k.
$D_{z,p}$	Distância entre o centróide da área z e a ECVE p.
$E_{p,t}^{Dis}$	Energia deslocada ou não atendida por um carregador p no perido t.
$F_{z,t}$	Número de VEs na área z no período t após o deslocamento de carga
H_z^{leg}	Quantidade de habitantes da área z autorizados para possuir um VE.
L	Matriz de decisão de carregamento dos VEs na área z.
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.
p	Índice de ECVE na área z.
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 em um 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.
$s_{z,j}$	Distância entre o centróide da área z e a ECVE de uma área j.
W	Custo de instalação para cada carregador.
X_p	Variável binária de decisão de instalação de uma ECVE.
z, j	Índices de áreas.

1. INTRODUÇÃO

O advento dos veículos elétricos (VEs) está 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).

Embora os VEs ofereçam múltiplos benefícios importantes, sua adoção generalizada ainda enfrenta vários obstáculos. Em primeiro lugar, os custos iniciais elevados desencorajam muitos possíveis compradores (Batista et al., 2015). Além disso, a falta de confiança das pessoas em uma nova tecnologia também contribui para limitar a transição para VEs. Contudo, a escassez de infraestrutura pública para o carregamento das baterias limita significativamente a conveniência do uso de VEs (Pamidimukkala et al., 2024). Por essas razões, espera-se que a adoção de VEs, nas áreas urbanas, seja heterogênea.

A heterogeneidade na adoção de VEs traz consigo vários desafios para o planejamento de estações de carregamento de veículos elétricos (ECVEs). 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 da 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 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.

1.1. Revisão da literatura

Na literatura científica, várias 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), análises de dados geoespaciais para identificar localizações ótimas para ECVEs (Wang et al., 2015a), algoritmos de gestão de carga para otimizar o carregamento dos VEs conforme a demanda e capacidade da rede (Oliinyk 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 cientifica 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 as ECVEs. É vital abordar simultaneamente ambos os aspectos no planejamento de ECVEs, dado que, a minimização dos custos de investimento garante a viabilidade econômica do projeto, enquanto a minimização das distâncias entre as ECVEs promove a acessibilidade e a conveniência dos VEs. Assim, essa abordagem integrada contribui para a aceitação massiva de VEs.

1.2. Contribuições

Este artigo introduz um modelo de programação linear inteira mista multiobjetivo para o dimensionamento adequado e a alocação ótima de infraestrutura de carregamento em áreas urbanas. O modelo proposto visa otimizar simultaneamente os investimentos necessários e as distâncias entre as ECVEs, ao mesmo tempo em que gerencia o tempo de espera máximo para carregamento dos VEs. Uma característica chave dessa abordagem é a integração de ferramentas de análise geoespacial para modelar as dinâmicas de deslocamento dos VEs e as preferências dos usuários em relação ao carregamento dos VEs. Isso possibilita uma estimativa mais precisa das demandas de carregamento dos VEs por áreas, permitindo um planejamento mais eficiente e estratégico dos ECVEs.

1.3. Estrutura do documento

Esse documento tem a seguinte estrutura: Seção 2 descreve o método usado para criar os perfis de demanda de carregamento dos VEs por áreas. Seção 3 apresenta o modelo de otimização proposto para o planejamento eficiente de ECVEs. Seção 4 mostra o estudo de caso e discute os resultados obtidos ao aplicar o método proposto em uma cidade brasileira de médio porte. Seção 5 resume as principais conclusões deste trabalho.

2. CÁLCULO DOS PERFIS DE DEMANDA DE CARREGAMENTO DOS VEs

Para calcular os perfis de demanda de carregamento dos VEs adota-se uma abordagem de análise geoespacial que consiste em subdividir a cidade em estudo em n áreas de acordo com as características residenciais, comerciais e industriais de cada área. Para dividir a cidade, sugere-se utilizar um sistema de informação geográfica, como o ArcGIS. Essa ferramenta facilita o cálculo das dimensões das áreas e os centroides populacionais de cada uma das áreas. Além disso, permite avaliar dados geoespaciais como a densidade de tráfego veicular, locais sem infraestrutura ou subutilizados, locais com maior circulação de veículos, para assim identificar os locais mais adequados para instalar as ECVEs. Deste modo, para cada área é definido um conjunto de locais candidatos para instalar as ECVEs.

O processo para calcular os perfis de demanda de carregamento dos VEs consta de duas etapas. Na primeira etapa se estima o número de compradores potenciais de VEs por áreas. Na segunda etapa se utilizam as cadeias de Markov para modelar as dinâmicas nos deslocamentos dos VEs e as preferências de carregamento dos usuários, para assim calcular os perfis de demanda dos VEs em cada área. Os dados de entrada, os dados de saída e o procedimento realizado em cada etapa são descritos a seguir.

2.1. Etapa 1. Estimativa dos 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 (1).

$$N_z^{ve} = H_z^{leg} \cdot \varphi_z^{ve} \cdot A_z^{ad} \qquad \forall z = 1, \ldots, n \tag{1}$$

Onde H_z^{leg} representa a quantidade de habitantes autorizados para possuir um VE na área z. A_z^{ad} é a percentagem 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.

2.2. Etapa 2. Construção das cadeias de Markov

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 Fig. *1* ilustra a estrutura típica de uma cadeia de Markov de três estados com suas respectivas probabilidades de transferência entre estados.

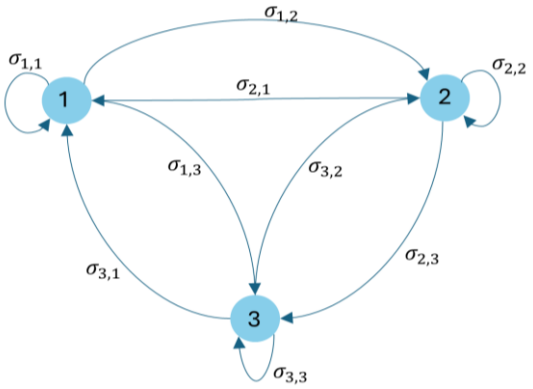

Fig. 1 Representação da cadeia de Markov.

Neste trabalho considera-se que o número de estados da cadeia de Markov é igual ao número de áreas n em que a cidade de estudo é dividida. Assim, os perfis de demanda de carregamento dos VEs, P^d, podem ser calculados usando (2). Note que, o elemento $P_{z,t}^d$ da matriz P^d, representa o perfil de demanda de carregamento dos VEs na área z no período t.

$$[P^d] = [L]^T \cdot \begin{bmatrix} \sigma_{1,1} & \cdots & \sigma_{1,j} & \cdots & \sigma_{1,n} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \sigma_{z,1} & \ldots & \sigma_{z,j} & \cdots & \sigma_{z,n} \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ \sigma_{n,1} & \ldots & \sigma_{n,j} & \cdots & \sigma_{n,n} \end{bmatrix} \cdot P^{ve} \cdot C^{ve} \tag{2}$$

Em que L é uma matriz que representa as preferências dos usuários sobre as decisões de carregamento dos VEs em um determinado horário do dia t, sendo L influenciada pelo comportamento socioeconômico individual de cada usuário de VE. σ é uma matriz que estima a possibilidade de que um VE que pertence a uma área z se desloque para uma área j ou permaneça dentro da área z. Além disso, essa matriz é construída a partir das probabilidades $\sigma_{z,j}$, que representam a probabilidade de que um VE que pertence a área z seja carregado na área j. P^{ve} é um parâmetro que representa a potência demandada pelos VEs. C^{ve} é um parâmetro que define a percentagem média da capacidade da bateria dos VEs que será carregada no ECVE. Note que, a matriz L pode ser calculada conforme é sugerido por (Hu et al., 2021), enquanto $\sigma_{z,j}$ pode ser calculado usando (3).

$$\sigma_{z,j} = \frac{\beta_{z,j}^{dis} \cdot \beta_{z,j}^{den}}{\sum_{j'=1}^{n} \beta_{z,j'}^{dis} \cdot \beta_{z,j'}^{den}} \qquad \forall z, j = 1, \ldots, n \tag{3}$$

Em que $\beta_{z,j}^{dis}$ representa a possibilidade de que um VE que pertence à área z seja carregado na área j em relação à distância a percorrer. $\beta_{z,j}^{den}$ representa a possibilidade de que um VE que pertence à área z seja carregado na área j em relação à densidade de VEs naquela área. Note que, $\beta_{z,j}^{dis}$ pode ser calculada usando (4) e $\beta_{z,j}^{den}$ pode ser calculada usando (5).

$$\beta_{z,j}^{dis} = e^{-0,1 \cdot s_{z,j} \cdot p_z} \qquad \forall z, j = 1, \ldots, n \tag{4}$$

Em que $s_{z,j}$ representa a distância entre o centróide da área z e a ECVE mais próxima da área j. p_z é um fator que quantifica o quão afastados estão os locais candidatos para instalar as ECVEs na área z em relação a seu centróide.

$$\beta_{z,j}^{den} = \frac{1}{log\left(N_z^{ve} \cdot \theta_j\right) + 1} \qquad \forall z, j = 1, \ldots, n \tag{5}$$

O fator θ_j representa a quantidade de VEs presentes na área j, calculado usando (6).

$$\theta_z = \tau \cdot \left(1 - e^{0,3 \cdot N_z^{ve}}\right) \cdot \frac{\mu_z^{inst}}{\mu_z^{cand}} + \gamma \qquad z = 1, \ldots, n, \mu_z^{cand} \geq 1 \tag{6}$$

Em que os parâmetros de ajuste τ e γ controlam, respectivamente, a amplitude e a velocidade da função de cálculo de probabilidades. μ_z^{inst} representa a quantidade de ECVEs instalados na área z. μ_z^{cand} representa a quantidade de locais candidatos para a instalação de ECVEs na área z.

3. MODELO DE OTIMIZAÇÃO

Uma vez calculados os perfis de demanda de carregamento dos VEs, o próximo passo envolve o planejamento eficiente dos ECVEs. Nesse sentido, propõe-se um modelo de programação inteira mista 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.

3.1. Função objetivo

O modelo proposto tem dois objetivos. O primeiro objetivo, mostrado em (7), consiste em minimizar os custos de investimento em ECVEs, 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 binaria X_p é a decisão de instalação da ECVE.

O segundo objetivo, mostrado em (8), consiste em minimizar as distancias entre as ECVEs, Φ^{ECVE}. Note que, Φ^{ECVE} está

constituído pelo parâmetro $D_{z,p}$, que representa a distância entre as ECVEs da área z e o centróide 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.

$$\min\ \Psi^{ECVE} = \sum_{p} (W \cdot \gamma_p + CF \cdot X_p) \tag{7}$$

$$\min\ \Phi^{ECVE} = \sum_{z,p,t} D_{z,p} \cdot F_{z,t} \cdot \beta_{p,z} \tag{8}$$

No planejamento de ECVEs, minimizar simultaneamente os custos de investimento e as distâncias entre as estações é crucial. Reduzir custos atrai investidores e facilita expansões futuras. Por outro lado, diminuir a distância entre as estações otimiza a acessibilidade, incentivando a adoção de VEs e reduzindo as preocupações de autonomia dos motoristas. Esta abordagem promove a eficiência econômica e a aceitação dos usuários, impulsionando a transição para a mobilidade elétrica de forma economicamente viável. Assim, considerar ambos os aspectos, resulta em um planejamento mais equilibrado e eficaz.

3.2. Conjunto de restrições para a instalação de ECVEs

O conjunto de restrições (9)–(16) representa os limites que devem ser respeitados na instalação dos ECVEs.

$$\bar{p}^{\,PL} \leq p^{p}_{max} \cdot \gamma_p \qquad \forall p,t \tag{9}$$

$$0 \leq \gamma_p \leq \bar{\gamma} \cdot X_p \qquad \forall p,t \tag{10}$$

$$P^{PL}_{p,t} \leq \bar{p}^{\,PL} \qquad \forall p,t \tag{11}$$

$$E^{Dis}_{p,t} = E^{Dis}_{p,t-1} + P^{d}_{p,t} \cdot \Delta t - P^{PL}_{p,t} \cdot \Delta t \qquad \forall p,t > 1 \tag{12}$$

$$P^{d}_{p,t} = \sum_{z} P^{d}_{z,t} \cdot \beta_{z,p} \qquad \forall p,t \tag{13}$$

$$\sum_{p} \beta_{z,p} = 1 \qquad \forall z \tag{14}$$

$$E^{Dis}_{p,t} / P^{ve} \leq \delta_t \qquad \forall p,t \tag{15}$$

$$0 \leq \delta_t < \delta_{max} \qquad \forall t > 1 \tag{16}$$

O limite máximo de potência de uma ECVE $\bar{p}^{PL}_{max}$ é definido na equação (9), relacionando a quantidade de carregadores instalados γ_p e a potência máxima de um carregador p^{p}_{max}. A quantidade de carregadores γ_p que podem ser instalados é limitada em (10) 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 $P^{PL}_{p,t}$ é definida na equação (11), 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 $E^{Dis}_{p,t}$, sendo definida em (12) pela relação entre a potência demandada $P^{d}_{p,t}$, o delta de tempo Δt , a razão da potência $P^{PL}_{p,t}$ que o carregador p pode fornecer em um período Δt e a energia não atendida ou deslocada no período anterior $E^{Dis}_{p,t-1}$.

A potência demandada em uma ECVE, $P^{d}_{p,t}$ é definida em (13) 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 (14) 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 (15) como a relação entre a potência dos VEs P^{ve} e a energia não deslocada $E^{Dis}_{p,t}$. Da mesma forma, a equação (16) limita o tempo de espera permitido segundo δ_{max}.

3.3. Abordagem de solução multiobjetivo

A abordagem multiobjetivo fica evidente na função objetivo (17) incorpora os objetivos (7) e (8) em um único objetivo.

$$\min\ \alpha \cdot \Psi^{ECVE} + (1-\alpha) \cdot \Phi^{ECVE} \tag{17}$$

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

A Fig. 2. mostra um fluxograma do método empregado para o planejamento ótimo de ECVEs em áreas urbanas.

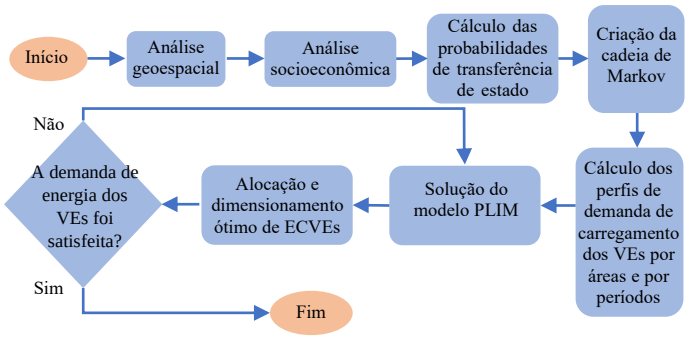

Fig. 2 Fluxograma do processo matemático desenvolvido.

4. CASO DE ESTUDO

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. Cada área foi subdividida em parcelas residencial, comercial e industrial. 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 percentagem média de carregamento, C^{ve}, é de 60% da capacidade da bateria, e a potência de um VE, P^{ve}, é de 36 kW.

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). Por outro lado, 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.

3.1. Resultados

A análise geoespacial e socioeconômica desenvolvida levou em consideração a relação dos fatores de densidade populacional e distância entre as áreas estudadas; esta relação resultou nos perfis de carregamentos dos VEs ilustrados na Fig. 3.

Com os perfis de carregamento dos VEs construídos foi aplicado o modelo de programação linear inteira mista (PLIM), que dimensionou e alocou as ECVEs necessárias para atender a demanda. Para este processo foi considerado um $\alpha = 0{,}89$, resultando na instalação de 17 ECVEs e 272 carregadores, diferindo em tamanho devido ao número de carregadores instalados em cada uma delas, como é ilustrado na Fig. 4. Na Fig. 5. mostra a relação entre os custos de investimento e as distâncias entre os distintos ECVEs e os centroides de todas as áreas. Em complemento, Fig. 6 mostra o comportamento tanto da distância em relação ao α quanto do custo de investimento em relação ao α.

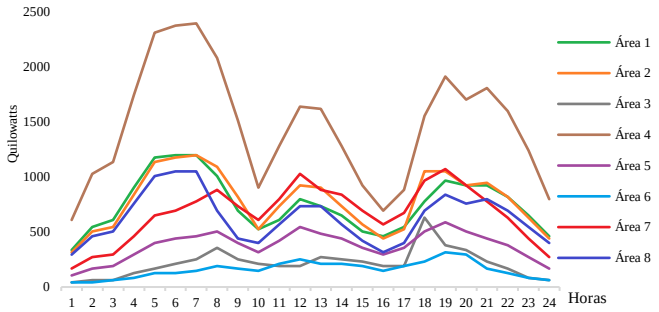

Fig. 3 Perfis de demanda de carregamento dos VEs.

A importância da análise socioeconômica e geoespacial é destacada na Fig. 7, que mostra o tamanho das estações em relação à variação do α, onde podemos encontrar ECVE candidatas, como 2, 7, 10, 17, 22, 23, 24, e 30 que embora pertençam a áreas com densidade populacional muito elevada não possuem localização geoespacial favorável de forma que sua demanda seja absorvida por outras ECVE melhor posicionadas.

Outro aspecto importante a destacar através da aplicação do método desenvolvido é a possibilidade de identificação de ECVEs candidatos como reforço em caso de aumento da demanda, como é o caso dos ECVEs candidatos números 14, 25, 26 e 29 que são instalados sob a priorização da distância usando o parâmetro α.

5. CONCLUSÕES

O crescimento dos veículos elétricos (VEs) tem exigido uma infraestrutura de carregamento adequada para atender à demanda crescente. A alocação estratégica e o dimensionamento preciso das estações de carregamento de veículos elétricos (ECVEs) são cruciais para garantir a eficiência e a viabilidade da rede de carregamento. Este estudo abordou esses desafios por meio de um método baseado em Programação Linear Inteira Mista que considera a análise geoespacial e socioeconômica para otimizar a alocação e dimensionamento das ECVEs.

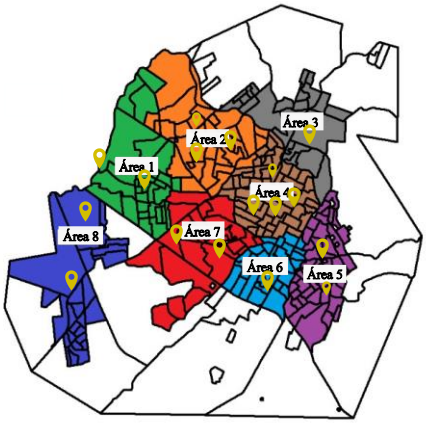

Fig. 4 Mapa de estações de carregamento instaladas.

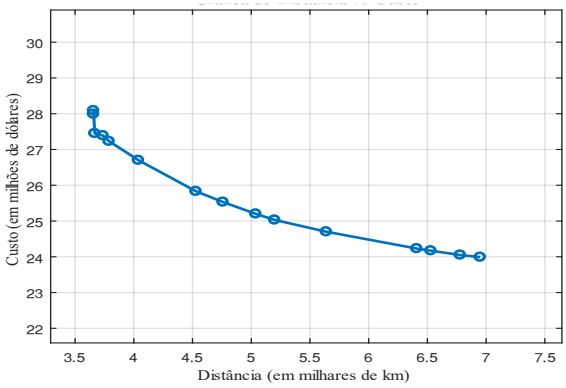

Fig. 5 Relação investimento–distância.

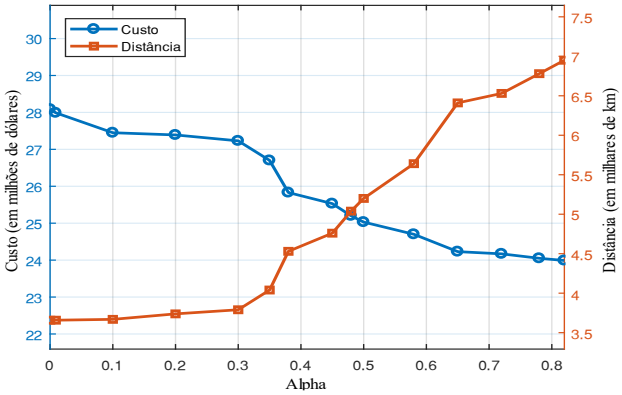

Fig. 6 Custo e distância em referência a α.

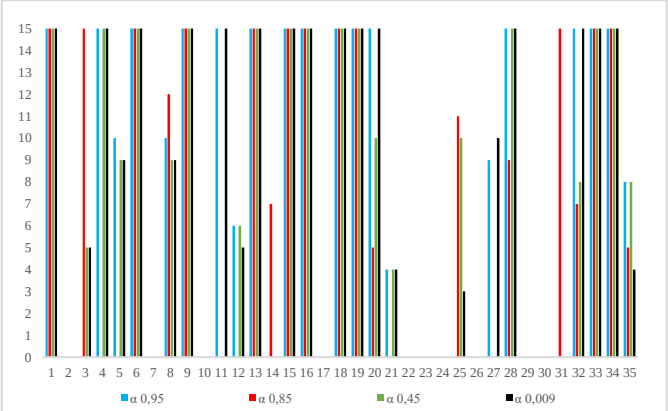

Fig. 7 Número de carregadores instalados em cada ECVE candidata em relação à prioridade de α.

O método incorpora fatores de densidade populacional e distância, além de utilizar cadeias de Markov e ferramentas probabilísticas para prever a demanda de carregamento de VEs. Os resultados do estudo mostraram uma distribuição estratégica das ECVEs, priorizando a eficiência e a satisfação dos usuários de VEs. A análise mostrou uma relação entre a redução de custos de investimento e as distâncias entre os pontos de carregamento e os centroides da cidade.

Os resultados do método proposto indicam que a distribuição estratégica das ECVEs é eficaz para atender às demandas de carregamento dos VEs. Isso se deve à análise geoespacial e socioeconômica, que permitiu a identificação de áreas com maior potencial de adoção de VEs, priorizando a instalação de ECVEs nesses locais. Além disso, possibilitou a identificação de ECVEs candidatas para reforço em caso de aumento da demanda, assegurando a adaptabilidade da infraestrutura de carregamento às necessidades futuras.

Como trabalhos futuros derivados desta pesquisa propõe-se avaliar o impacto das ECVEs na rede elétrica e planificar os reforços necessários para atender as novas demandas. Essa análise será fundamental para garantir a viabilidade e a eficiência a longo prazo do planejamento das ECVEs.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES), código de financiamento 001, pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), sob a concessão 409062/2023-5, e pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), processo 2022/12947-1.

REFERÊNCIAS

Alarcón, F. E., Cawley, A. Mac, & Sauma, E. (2023). Electric mobility toward sustainable cities and road-freight logistics: A systematic review and future research directions. Journal of Cleaner Production, 430, 138959. https://doi.org/10.1016/j.jclepro.2023.138959

AMPL Corporation. (2024). AMPL Optimization Software (2024).

Batista, T., Freire, F., & Silva, C. M. (2015). Vehicle environmental rating methodologies: Overview and application to light-duty vehicles. Renewable and Sustainable Energy Reviews, 45, 192–206. https://doi.org/10.1016/j.rser.2015.01.040

Environmental Systems Research Institute. (2017). ArcGIS (10.5). Environmental Systems Research Institute.

Faustino, F. J., Lopes, J. C., Melo, J. D., Sousa, T., Padilha-Feltrin, A., Brito, J. A. S., & Garcia, C. O. (2023). Identifying charging zones to allocate public charging stations for electric vehicles. Energy, 283, 128436. https://doi.org/10.1016/j.energy.2023.128436

Hu, S., Yang, J., Liao, K., Li, B., & He, Z. (2021). An equivalent method of distributed generation based on discharge behavior of large-scale electric vehicles. 2021 3rd Asia Energy and Electrical Engineering Symposium, 833–838. https://doi.org/10.1109/AEEES51875.2021.9403229

IBM. (2024). IBM ILOG CPLEX Optimization Studio 20.1.0 documentation (20.1.0). IBM.

Jidong Wang, Kaijie Fang, & Wei He. (2015). A research for the interactive behavior between Electric vehicle and residential energy management system based on probability distribution. 2015 6th International Conference on Power Electronics Systems and Applications (PESA), 1–6. https://doi.org/10.1109/PESA.2015.7398897

Lili Gong, Wu Cao, & Jianfeng Zhao. (2017). Load modeling method for EV charging stations based on trip chain. 2017 IEEE Conference on Energy Internet and Energy System Integration (EI2), 1–5.

Maksym Oliinyk, Jaroslav Džmura, & Daniel Pál. (2020). The impact of a electric vehicle charging on the distribution system. Proceedings, 2020 21st International Scientific Conference on Electric Power Engineering (EPE) : EPE 2020, 1–5.

Maria Carmen Falvo, Matteo Manganelli, Cristina Moscatiello, & Francesco Vellucci. (2022). Electrical vehicles and charging stations: State of art and future perspectives. Conference Proceedings 2022 IEEE International Conference on Environment and Electrical Engineering and 2022 IEEE Industrial and Commercial Power Systems Europe (EEEIC/I&CPS Europe) 28 June-1 July 2022, Prague, Czech Republic, 1–7.

Pagany, R., Ramirez Camargo, L., & Dorner, W. (2019). A review of spatial localization methodologies for the electric vehicle charging infrastructure. International Journal of Sustainable Transportation, 13(6), 433–449. https://doi.org/10.1080/15568318.2018.1481243

Pamidimukkala, A., Kermanshachi, S., Rosenberger, J. M., & Hladik, G. (2024). Barriers and motivators to the adoption of electric vehicles: A global review. Green Energy and Intelligent Transportation, 3(2), 100153. https://doi.org/10.1016/j.geits.2024.100153

Semaria Ruiz Alvarez, & Jairo José Espinosa Oviedo. (2019). State of the art in strategies allowing the integration of a shared EVs service and the active participation of EVs with the power network. 2019 IEEE 4th Colombian Conference on Automatic Control (CCAC), 1–6.

Yusuf, J., Jahid Hasan, A. S. M., & Ula, S. (2022). EV penetration impact analysis on transmission system using co-simulation. 2022 IEEE Transportation Electrification Conference and Expo, ITEC 2022, 1154–1158.

Zhiyong Tian, Yi Wang, Chen Tian, Fan Zhang, Lai Tu, & Chengzhong Xu. (2014). Understanding operational and charging patterns of electric vehicle taxis using GPS records. 17th International IEEE Conference on Intelligent Transportation Systems (ITSC), 2472–2479