

Modelos e Técnicas de Otimização de Estações de Recarga em Sistemas de Bicicletas Elétricas Compartilhadas: Um Mapeamento Sistemático

Leonel da Rocha¹, Leonardo S. Zavadzki¹, Nádia P. Kozevitch¹

¹Universidade Tecnológica Federal do Paraná (UTFPR)
Av. Sete de Setembro, 3165 - Rebouças - CEP 80230-901 - Curitiba – Brasil

{leonelr,leonardoz}@alunos.utfpr.edu.br, nadiap@utfpr.edu.br

Abstract. *The expansion of shared electric bike systems poses challenges for the strategic location of charging stations, requiring the integration of operational data, spatial analysis, and optimization models. This paper presents a systematic mapping conducted under the PRISMA 2020 protocol to identify location models, decision criteria, and computational techniques applied to the problem. Twenty-four studies (2013–2024) were analyzed, covering MILP, heuristics, GIS-MCDM, and machine learning approaches. As a contribution, highlighting gaps in real-time data usage and uncertainty-aware modeling.*

Resumo. *A expansão dos sistemas de bicicletas elétricas compartilhadas impõe desafios à localização estratégica de estações de recarga, demandando integração entre dados operacionais, análise espacial e otimização. Este artigo apresenta um mapeamento sistemático, conduzido segundo o protocolo PRISMA 2020, para identificar modelos, critérios e técnicas computacionais aplicadas ao problema. Foram analisados 24 estudos (2013–2024), abrangendo MILP, heurísticas, GIS-MCDM e aprendizado de máquina. Como contribuição, evidenciando lacunas no uso de dados em tempo real e na modelagem sob incerteza.*

1. Introdução

A expansão dos sistemas de bicicletas elétricas compartilhadas tem ampliado o alcance da mobilidade urbana sustentável, ao mesmo tempo em que introduz novos desafios relacionados à localização estratégica de estações de recarga. Diferentemente dos sistemas tradicionais, a dependência de infraestrutura elétrica impõe restrições operacionais associadas à autonomia das baterias, padrões espaço-temporais de demanda e custos logísticos [Zhou et al., 2022; Bassolas et al., 2024].

A operação desses sistemas gera grandes volumes de dados, incluindo registros de viagens, níveis de bateria, informações georreferenciadas e integração com transporte público [Costa Lima et al., 2023]. A análise desses dados exige a combinação de técnicas de otimização, métodos de tomada de decisão multicritério e ferramentas de Sistemas de Informação Geográfica (SIG), frequentemente formuladas como problemas de programação inteira ou modelos híbridos de predição e otimização [Bahadori et al., 2022; Yue et al., 2024].

Apesar do avanço das pesquisas, observa-se fragmentação nas abordagens adotadas, com variações significativas nos critérios considerados, nas técnicas computacionais empregadas e na forma de integração entre dados espaciais, temporais e

operacionais. Além disso, aspectos como modelagem sob incerteza e uso de dados em tempo real ainda são pouco explorados [Nikiforiadis et al., 2020].

Diante desse cenário, este artigo apresenta um mapeamento sistemático da literatura, conduzido conforme o protocolo PRISMA 2020 [Page et al., 2021], com o objetivo de responder às seguintes questões: (i) quais modelos de localização têm sido aplicados; (ii) quais critérios influenciam a decisão; e (iii) quais técnicas computacionais são utilizadas na resolução desses problemas. Como principal contribuição, o trabalho organiza os critérios de localização em quatro dimensões — demanda, infraestrutura urbana, fatores operacionais e aspectos socioambientais — articuladas sob a perspectiva de integração de dados espaciais e temporais para suporte computacional à decisão. Ao sistematizar modelos e técnicas sob o enfoque de dados, o estudo fornece subsídios para o desenvolvimento de soluções mais robustas e integradas em contextos urbanos.

2. Fundamentação Teórica e Trabalhos Relacionados

Sistemas de bicicletas compartilhadas (BSS) e sua versão eletrificada (E-BSS) constituem infraestrutura relevante para mobilidade urbana sustentável [Zhou et al., 2022]. A introdução de bicicletas elétricas amplia o alcance do modal, mas impõe restrições associadas à autonomia das baterias, necessidade de recarga e maior complexidade operacional [Bassolas et al., 2024].

A operação desses sistemas gera dados de alta granularidade espaço-temporal, incluindo registros de viagens, níveis de bateria, localização geográfica e integração com bilhetagem eletrônica [Costa Lima et al., 2023; Yu et al., 2021]. Esses dados constituem a base para formulação e avaliação de modelos de localização, permitindo alinhar decisões estratégicas aos padrões reais de demanda.

Nesta direção, problemas de localização de estações possuem natureza intrinsecamente espacial. Ferramentas de Sistemas de Informação Geográfica (SIG) permitem integrar variáveis como densidade populacional, uso do solo, acessibilidade e proximidade ao transporte público [Bahadori et al., 2022; García-Palomares et al., 2012].

A integração entre SIG e métodos multicritério (GIS-MCDM) possibilita combinar múltiplos fatores em mapas de adequação espacial, apoiando a seleção de locais candidatos. Técnicas de análise de rede também são empregadas para modelar distâncias reais de deslocamento e conectividade urbana.

Do ponto de vista de modelagem, a definição de estações é frequentemente formulada como problema de otimização combinatória, envolvendo modelos como MCLP, p-Mediana e p-Centro [Staněk et al., 2023; Yue et al., 2024]. Tais formulações são usualmente resolvidas por Programação Linear Inteira Mista (MILP) ou Programação Inteira, com apoio de *solvers* comerciais.

Em cenários de maior escala, heurísticas e metaheurísticas — como Algoritmos Genéticos, PSO e *Simulated Annealing* — são utilizadas para obter soluções aproximadas [Lamontagne et al., 2023]. Técnicas de clustering (K-means, Mean-shift, DBSCAN) auxiliam na identificação de padrões de demanda [Lei et al., 2023; Chowdhury et al., 2023].

Mais recentemente, abordagens híbridas integram previsão de demanda por aprendizado de máquina e otimização subsequente (predict-then-optimize), além de técnicas de Aprendizado por Reforço Profundo (DRL) para adaptação dinâmica [Zhou et al., 2022; von Wahl et al., 2022; Yue et al., 2024].

Os estudos sobre localização e operação de sistemas de bicicletas compartilhadas evoluíram de modelos estáticos baseados em cobertura para abordagens que integram dados operacionais e técnicas avançadas de otimização.

No contexto de modelagem probabilística, Bassolas et al. (2024) analisaram a variabilidade espaço-temporal dos níveis de bateria em sistemas de e-bikes por meio de Cadeias de Markov, demonstrando a influência da demanda e da topografia sobre a disponibilidade energética. O estudo evidencia a importância da modelagem dinâmica para suporte à decisão.

A integração de dados multimodais também tem sido explorada. Costa Lima et al. (2023) utilizaram registros de bilhetagem eletrônica e dados de empréstimo de bicicletas para identificar padrões de integração ônibus–bicicleta, evidenciando o papel do big data na análise de deslocamentos urbanos.

Em termos de otimização, Yue et al. (2024) propuseram um modelo de Cobertura Máxima (MCLP) aprimorado com função de tolerância de distância, resolvido por Aprendizado por Reforço Profundo (DRL). A abordagem combina previsão implícita de demanda e otimização adaptativa, superando métodos heurísticos tradicionais.

De forma geral, observa-se uma transição de modelos estáticos para estratégias baseadas em dados, com crescente uso de técnicas híbridas que integram previsão, otimização e análise espacial. No entanto, as abordagens permanecem heterogêneas quanto aos critérios considerados e à integração entre dados espaciais, temporais e operacionais, reforçando a necessidade de sistematização.

3. Mapeamento Sistemático

O mapeamento sistemático foi conduzido conforme as diretrizes do protocolo PRISMA 2020. A busca foi realizada em maio de 2025 nas bases Google Scholar, Scopus e Web of Science, utilizando combinações de termos relacionados a bike-sharing, electric bike, charging station location, optimization e GIS.

Foram considerados artigos revisados por pares publicados entre 2013 e 2024 que apresentassem abordagem quantitativa aplicada à localização de estações. Trabalhos puramente conceituais ou sem validação empírica foram excluídos. Após aplicação dos critérios de elegibilidade, 24 estudos compuseram o conjunto final analisado. O fluxo de identificação, triagem e inclusão é apresentado na Figura 1.




Figura 1 – Fluxograma da Identificação, triagem e inclusão.

3.1. Modelos e Técnicas Computacionais

Os estudos analisados empregam predominantemente modelos de otimização combinatória para definição da localização de estações. Observa-se forte presença de formulações baseadas em Cobertura Máxima (MCLP), p-Mediana e Programação Linear Inteira Mista (MILP) [Staněk et al., 2023; Yue et al., 2024].

Em cenários de maior escala, heurísticas e metaheurísticas — como Algoritmos Genéticos e PSO — são utilizadas para reduzir custo computacional [Lamontagne et al., 2023]. Abordagens baseadas em aprendizado de máquina vêm sendo integradas à etapa de previsão de demanda, especialmente com técnicas de Aprendizado por Reforço Profundo (DRL), permitindo adaptação dinâmica [Zhou et al., 2022; von Wahl et al., 2022; Yue et al., 2024].

Métodos híbridos que combinam SIG com análise multicritério (GIS-MCDM) também são recorrentes, sobretudo quando múltiplos fatores espaciais são considerados [Bahadori et al., 2022; García-Palomares et al., 2012].

A síntese das principais abordagens é apresentada na Tabela 1.

Categoria	Principais Métodos	Descrição / Aplicação	Referência
Métodos Exatos	Programação Linear Inteira Mista (<i>MILP</i>), Programação Inteira Pura, Programação Inteira Não Linear	Modelos matemáticos que buscam a solução ótima considerando todas as restrições. Muito utilizados para problemas de pequena e média escala. <i>Solvers</i> comuns: <i>CPLEX</i> , Gurobi.	Staněk et al. (2023); Yue et al. (2024)
Heurísticas	Algoritmos Gulosos (<i>Greedy</i>), Busca Local, Busca em Vizinhança Variável (<i>VNS</i>)	Estratégias rápidas que oferecem soluções aceitáveis sem garantia de otimalidade. Indicadas quando a agilidade é mais importante que a perfeição.	Staněk et al. (2023); Yue et al. (2024)
Metaheurísticas	Algoritmos Genéticos (<i>GA</i>), <i>Particle Swarm Optimization</i> (<i>PSO</i>), <i>Simulated Annealing</i> (<i>SA</i>), <i>GRASP</i> , Colônia de Formigas, <i>Whale Optimization Algorithm</i>	Técnicas inspiradas em processos naturais ou físicos, aplicadas a problemas de grande escala e alta complexidade. Buscam soluções próximas do ótimo em tempo viável.	Cintrano et al. (2024); Yue et al. (2024); von Wahl et al. (2022)
Métodos Híbridos	Combinações de heurísticas/metaheurísticas, integração GIS-MCDM, modelos “ <i>predict-then-optimize</i> ”	Integram diferentes técnicas para potencializar vantagens específicas. Exemplo: IA para prever demanda combinada a heurísticas para otimizar a localização.	Zhou et al. (2022); Nikiforiadis et al. (2020)
Aprendizado de Máquina / IA	Redes Neurais Artificiais, <i>Deep Learning</i> , <i>Random Forest</i> , SVM, <i>Deep Reinforcement Learning</i>	Usadas para previsão de demanda, detecção de padrões espaciais e otimização adaptativa em tempo real. Adequadas para grandes volumes de dados.	Yue et al. (2024); Bassolas et al. (2024); von Wahl et al. (2022)

Técnicas de Análise Espacial	Sistemas de Informação Geográfica (SIG), Análise Espacial Multicritério (GIS-MCDM), Modelos de Gravidade	Análises geoespaciais para avaliar cobertura, acessibilidade, integração modal e áreas prioritárias para novas estações.	García-Palomares et al. (2012); Bahadori et al. (2022); Ayyildiz (2022)
Técnicas de Agrupamento e Estatísticas	<i>K-means</i> , <i>Mean-shift</i> , <i>DBSCAN</i> , <i>KD-Tree</i> , Regressão, Análise Estatística	Identificam padrões de concentração de demanda e agrupam áreas com características semelhantes, apoiando decisões estratégicas.	Fraley & Raftery (2002); Chowdhury et al. (2023); Lei et al. (2023)

Tabela 1 – Síntese das técnicas e modelos identificados.

3.2. Critérios de Decisão para Localização

A análise dos estudos permitiu organizar os critérios utilizados em quatro dimensões principais:

- Demanda: densidade populacional, padrões OD e séries temporais de viagens [Lei et al., 2023; Yu et al., 2021].
- Infraestrutura: uso do solo, proximidade a transporte público e rede ciclovária [Bahadori et al., 2022].
- Operacionais: custos de instalação, rebalanceamento e capacidade [Lamontagne et al., 2023].
- Socioambientais: equidade territorial e sustentabilidade [Bassolas et al., 2024].

A organização hierárquica desses fatores é apresentada na Figura 2, que sintetiza a taxonomia derivada do mapeamento.

3.3. Tendências e Lacunas Identificadas

A análise dos 24 estudos selecionados evidencia predominância de abordagens baseadas em modelos de otimização combinatória para localização de estações de bicicletas elétricas compartilhadas. Formulações como Maximum Covering Location Problem (MCLP), p-mediana e Programação Linear Inteira Mista (MILP) são amplamente empregadas para maximizar cobertura de demanda ou minimizar custos operacionais [Staněk et al., 2023; Yue et al., 2024]. Embora garantam soluções ótimas, tais modelos apresentam limitações de escalabilidade quando aplicados a grandes conjuntos de dados urbanos.

Para mitigar essa limitação, diversos trabalhos adotam heurísticas e metaheurísticas, como Algoritmos Genéticos, Particle Swarm Optimization (PSO) e Simulated Annealing, visando reduzir o custo computacional com perda controlada de optimalidade [Lamontagne et al., 2023]. Essas abordagens mostram-se adequadas a cenários com múltiplas restrições e grande número de variáveis.

Observa-se também crescente incorporação de técnicas de aprendizado de máquina, principalmente para previsão de demanda e ajuste dinâmico das decisões locais. Modelos baseados em Aprendizado por Reforço Profundo (DRL) permitem adaptação contínua às variações espaço-temporais da demanda [Zhou et al., 2022; von Wahl et al., 2022; Yue et al., 2024], sinalizando transição de modelos estáticos para arquiteturas preditivas e adaptativas.

No âmbito espacial, a integração entre Sistemas de Informação Geográfica (SIG) e métodos multicritério (GIS-MCDM) é recorrente, possibilitando combinar variáveis como densidade populacional, uso do solo e proximidade ao transporte público [Bahadori et al., 2022; García-Palomares et al., 2012]. Essa integração amplia a capacidade de incorporar dados heterogêneos no processo decisório.

Aspecto analisado	Principais achados	Implicações	Recomendações
Planejamento de estações de recarga	Processo complexo que depende de localização estratégica e análise de demanda	Má distribuição pode gerar baixa adesão e uso ineficiente	Aplicar algoritmos de otimização com base em dados de mobilidade
Tempo de carga das <i>e-bikes</i>	Varia de ~3h a 8h conforme a bateria e o carregador	Longos tempos de carga reduzem a disponibilidade operacional	Investir em carregadores rápidos ou sistemas de troca de baterias
Custos e infraestrutura	Alto custo inicial de instalação e manutenção	Risco de inviabilidade econômica em fases iniciais	Adotar planejamento por fases e parcerias público-privadas
Sustentabilidade e impacto ambiental	Emissões indiretas de CO ₂ dependem da matriz energética	Pode comprometer benefícios ambientais	Utilizar energia renovável e gestão eficiente das baterias

Tabela 2 – Principais achados e recomendações

Em termos de dados utilizados, os estudos exploram predominantemente registros históricos de viagens, informações demográficas e atributos espaciais. Contudo, a incorporação de dados em tempo real ainda é limitada, especialmente no que se refere a níveis de bateria e dinâmica operacional [Bassolas et al., 2024; Yu et al., 2021]. Essa lacuna indica oportunidade para maior integração entre modelagem de dados espaço-temporais e otimização.

De forma geral, os trabalhos convergem para soluções híbridas que combinam previsão de demanda, análise espacial e otimização. Entretanto, observa-se heterogeneidade na definição de critérios e ausência de padronização metodológica, reforçando a necessidade de sistematização e de estruturas de dados robustas para suporte à tomada de decisão em mobilidade urbana. A Tabela 2 apresenta uma síntese dos métodos, critérios e tendências identificados na literatura analisada.

Dentre os principais desafios listados na literatura, podemos citar que a localização de estações de bicicletas elétricas compartilhadas reside na integração de dados heterogêneos — espaciais, temporais e operacionais — em modelos de decisão escaláveis. Embora formulações como MCLP e MILP sejam amplamente utilizadas [Staněk et al., 2023; Yue et al., 2024], sua aplicação em ambientes urbanos de grande porte é limitada pelo crescimento combinatório das variáveis e restrições. Heurísticas e metaheurísticas reduzem o custo computacional [Lamontagne et al., 2023], mas frequentemente sacrificam garantias de optimalidade. Nesse contexto, a área enfrenta o desafio de conciliar desempenho algorítmico, qualidade da solução e eficiência no gerenciamento de grandes volumes de dados.

Outro achado relevante refere-se à crescente incorporação de técnicas de aprendizado de máquina para previsão de demanda e adaptação dinâmica das decisões. Abordagens baseadas em Aprendizado por Reforço Profundo (DRL) têm sido empregadas para lidar com variações espaço-temporais e incertezas operacionais [Zhou et al., 2022; von Wahl et al., 2022; Yue et al., 2024]. Contudo, a maioria dos estudos ainda depende predominantemente de dados históricos agregados, com baixa exploração de fluxos em tempo real, como níveis de bateria e padrões dinâmicos de uso [Bassolas et al., 2024; Yu et al., 2021]. Isso evidencia a necessidade de arquiteturas de dados capazes de suportar ingestão contínua, atualização incremental e processamento eficiente.

Por fim, observa-se heterogeneidade na definição e organização dos critérios de decisão, especialmente na integração entre variáveis de demanda, infraestrutura e fatores socioambientais [Bahadori et al., 2022; García-Palomares et al., 2012]. A ausência de padronização metodológica dificulta comparações entre estudos e reprodutibilidade dos resultados. Esses fatores reforçam que o avanço da área depende não apenas de novas formulações matemáticas, mas do desenvolvimento de modelos de dados, esquemas espaço-temporais e mecanismos de integração que sustentem análises robustas e replicáveis em larga escala.

4. Conclusão

Este trabalho apresentou um mapeamento sistemático da literatura sobre localização de estações de recarga em sistemas de bicicletas elétricas compartilhadas, analisando 24 estudos publicados entre 2013 e 2024. A revisão evidenciou predominância de modelos baseados em otimização combinatória, especialmente formulações MILP e variantes de cobertura, bem como crescente incorporação de técnicas de aprendizado de máquina para previsão de demanda e adaptação dinâmica.

A análise revelou três achados centrais: (i) dependência significativa de dados históricos agregados, com limitada exploração de fluxos em tempo real; (ii) heterogeneidade na definição e organização dos critérios de decisão; e (iii) desafios de

escalabilidade em ambientes urbanos de grande porte. Embora abordagens híbridas integrem SIG, previsão e otimização, ainda há lacunas na modelagem unificada de dados espaciais, temporais e operacionais.

Como contribuição, este estudo sistematiza modelos, técnicas e critérios, oferecendo visão do estado da arte e identificando oportunidades de pesquisa. Os fatores listados reforçam que o avanço da área depende do desenvolvimento de arquiteturas capazes de suportar dados espaço-temporais de alta granularidade, atualização contínua e integração entre camadas analíticas e de otimização.

Como trabalhos futuros, destacam-se: (i) integração de incerteza e variabilidade dinâmica nos esquemas de dados; e (ii) definição de benchmarks e padrões de representação que favoreçam reprodutibilidade e comparabilidade entre estudos.

Referências

- AYILDIZ, E. Multicriteria decision-making methods in sustainable urban mobility planning. *Sustainability*, v. 14, n. 3, 2022.
- BAHADORI, M.; et al. GIS-based multicriteria analysis for bike-sharing station location. *Journal of Transport Geography*, v. 96, 2022.
- BASSOLAS, A.; et al. Spatiotemporal variability and prediction of e-bike battery levels in bike-sharing systems. *Journal of Cleaner Production*, 2024.
- CHOWDHURY, S.; et al. Density-based clustering for urban mobility data. *Applied Sciences*, v. 13, n. 2, 2023.
- CINTRANO, C.; CHICANO, F.; ALBA, E. Using metaheuristics for the location of bicycle stations. *Applied Soft Computing*, 2024.
- COSTA LIMA, J.; et al. Big data integration of bike-sharing and bus systems in Fortaleza. *Transport Policy*, v. 132, 2023.
- FRALEY, C.; RAFTERY, A. Model-based clustering, discriminant analysis, and density estimation. *Journal of the American Statistical Association*, v. 97, n. 458, p. 611–631, 2002.
- GARCÍA-PALOMARES, J. C.; et al. GIS-based planning of bike-sharing systems. *Transportation Research Part A*, v. 49, 2012.
- LAMONTAGNE, J.; et al. Optimising electric vehicle charging station placement using advanced discrete choice models. *INFORMS Journal on Computing*, v. 35, n. 5, p. 1195–1213, 2023.
- LEI, T.; et al. Clustering approaches for bike-sharing demand. *Journal of Transport Geography*, v. 109, 2023.
- NIKIFORIADIS, A.; et al. Hybrid approaches for bike-sharing optimization. *Transportation Research Procedia*, v. 47, 2020.
- PAGE, M. J.; et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, 2021.

- STANĚK, R.; et al. Optimization models for bike-sharing station location. Transportation Research Part C, v. 149, 2023.
- VON WAHL, A.; et al. Deep reinforcement learning for bike-sharing optimization. Transportation Research Part C, v. 143, 2022.
- YU, H.; et al. Big data analytics for bike-sharing demand prediction. Transportation Research Part C, v. 128, 2021.
- YUE, X.; et al. Deep reinforcement learning for e-scooter and bike-sharing optimization. Transportation Research Part C, v. 152, 2024.
- ZHOU, Y.; et al. Predict-then-optimize approaches for bike-sharing. Sustainable Cities and Society, v. 85, 2022.