

SISTEMA INTELIGENTE DE CLASSIFICAÇÃO DE LOCAIS PRIORITÁRIOS PARA INSTALAÇÃO DE ESTAÇÕES DE RECARGA DE VEÍCULOS ELÉTRICOS UTILIZANDO K-NEAREST NEIGHBORS (KNN)

Renata da Conceição Rocha¹, Lana Késsia dos Santos Silva¹, José Augusto Santos Costa¹, Gustavo Soares Bezerra², Mauro Antônio Guimarães Clark², Iulle de Macedo Guerra Neves²

¹ Universidade Estadual do Piauí (UESPI), Curso de Tecnologia em Energias Renováveis, Teresina, Brasil (renatarocha1997@aluno.uespi.br)

² Universidade Estadual do Piauí (UESPI), Curso de Engenharia Elétrica, Teresina, Brasil

Resumo: O presente estudo tem como objetivo a implementação de um sistema de otimização de pontos de recarga de veículos elétricos em Teresina-PI utilizando o algoritmo KNN (K-Nearest Neighbors). Para tal finalidade, foram coletados dados de latitude e longitude de 230 postos de combustíveis. Esses dados foram processados em Python e os resultados indicaram que o algoritmo é bastante eficiente na sugestão de locais estratégicos, levando em consideração fatores como distância e densidade de vizinhos.

Palavras-chave: Planejamento urbano; Logística otimizada; Mobilidade elétrica; K-Nearest Neighbors; Eletropostos

INTRODUÇÃO

A matriz energética brasileira caracteriza-se historicamente por uma participação expressiva de fontes renováveis, superando significativamente as médias globais de sustentabilidade (THE RIO TIMES, 2026). No elemento central dessa estrutura, a exploração do potencial hidroelétrico consolidou-se como o principal vetor de desenvolvimento, aproveitando a predominância de rios de planalto e o elevado volume de vazão para suprir as demandas nacionais (THE RIO TIMES, 2026). Entretanto, essa configuração de matriz energética, embora robusta, revelou vulnerabilidades críticas diante de fatores geopolíticos e climáticos ao longo das décadas.

Na década de 1970, o cenário energético global foi abalado pelos choques do petróleo no Oriente Médio, expondo a fragilidade do Brasil em relação à dependência de combustíveis fósseis importados. Como resposta estratégica para diversificar a matriz de transportes e energia primária, o Governo Federal instituiu o Proálcool (Programa Nacional do Álcool) em 1975, incentivando a produção de etanol a partir da cana-de-açúcar para substituir a gasolina (EPE, 2023). Esse movimento não apenas reduziu a dependência externa, mas também inseriu a biomassa como um componente permanente estratégico na matriz energética do país.

Apesar dos avanços na área de combustíveis, a segurança do suprimento elétrico – um subsistema vital da matriz energética – enfrentou um colapso em 2001. O episódio conhecido como “Apagão” foi provocado pela combinação de escassez hídrica e insuficiência de investimentos em infraestrutura, forçando a adoção de medidas rígidas de racionamento (SANTOS; PINTO, 2021). Esse evento evidenciou que a estabilidade energética nacional não poderia mais repousar quase exclusivamente sobre a fonte hidrelétrica, exigindo uma reestruturação imediata do planejamento setorial.

Como consequência direta dessa necessidade de diversificação, o Programa de Incentivo às Fontes Alternativas (PROINFA) foi criado em 2002, marcando a expansão das fontes eólica e solar na matriz nacional. O programa encontrou condições ideais de implementação na região Nordeste, onde a alta incidência de radiação solar e a constância dos ventos oferecem uma complementaridade técnica essencial à geração hídrica (BEZERRA, 2021).

Dessa forma, a matriz energética brasileira evoluiu para um modelo mais resiliente e multisetorial, integrando novas tecnologias para garantir a segurança e a continuidade do desenvolvimento nacional. Nesse contexto, o estado do Piauí emergiu como um dos protagonistas da transição energética para uma economia de baixa



emissão de carbono no Brasil. A localização privilegiada do estado, situada em uma área de transição entre o Semiárido e o Meio-Norte, confere-lhe índices de irradiação solar global superiores à média nacional, além de corredores de ventos constantes com baixa turbulência (ANEEL, 2023). Essas características naturais transformaram o território piauiense em um polo de atração para investimentos estruturantes em parques eólicos e complexos fotovoltaicos de multigigawatt.

A relevância estratégica do Piauí consolidou-se na última década, quando o estado passou a figurar entre os maiores produtores de energia limpa do país. Segundo dados setoriais, a integração de grandes projetos de geração centralizada no semiárido piauiense não apenas auxilia no suprimento da demanda do Subsistema Nordeste, mas também contribui para a estabilidade do Sistema Interligado Nacional (SIN), durante os períodos de sazonalidade hídrica (ABSOLAR, 2024).

Atualmente, a urgência pela descarbonização vem impulsionando uma transição energética acelerada para a frota de Veículos Elétricos (VE). Esse mercado apresenta expansão vigorosa tanto no panorama global quanto no brasileiro, com vendas que superaram 17 milhões de unidades em 2024 – um crescimento de 25% comparado ao ano anterior. De acordo com a Agência Internacional de Energia (IEA, 2025), foram atingidas marcas históricas, pois pela primeira vez os veículos elétricos representaram mais de 20% das vendas totais de carros no mundo em 2024.

Nesse contexto, a eletrificação veicular é um dos pilares para o cumprimento das metas do Acordo de Paris e dos Objetivos de Desenvolvimento Sustentável (ODS) da ONU, dado seu potencial de mitigação de Gases do Efeito Estufa (GEE) e a promoção de uma mobilidade urbana sustentável. A adoção dessa tecnologia converge diretamente para três frentes dos ODS: a ODS 7 (Energia Limpa e Acessível), ao fomentar a substituição de combustíveis fósseis por renováveis; a ODS 11 (Cidades e Comunidades Sustentáveis), pela melhoria na qualidade do ar e redução de poluição sonora; e a ODS 13 (Ação Contra a Mudança Global do Clima), focada na descarbonização atmosférica.

A relevância desse tema foi ratificada na Conferência das Nações Unidas Sobre Mudanças Climáticas (COP30), realizada em Belém em 2025, que posicionou o Brasil como protagonista no debate sobre a preservação da biodiversidade e cumprimento das metas de emissão líquida zero (IPCC, 2025). Contudo, a consolidação dessa revolução energética exige uma infraestrutura de recarga robusta. Projeções da Empresa de Pesquisa Energética indicam que, até 2035, o Brasil contará com cerca de 3,7 milhões de

veículos elétricos em circulação, elevando a demanda energética para 7,8TWh (EPE, 2021).

A eletromobilidade, nesse cenário, é destacada como uma alternativa para a descarbonização, com forte crescimento do número de veículos leves, segundo o PDE (Plano Decenal de Expansão). Estudos da EPE mostram que a eletrificação das frotas de ônibus e caminhões também está em análise, visando também a inserção no transporte de carga. Essa expansão demanda um planejamento rigoroso quanto à localização dos pontos de recarga.

Em sua obra sobre Veículos Elétricos e Híbridos, Denton (2022) caracteriza a infraestrutura de recarga como um suporte crítico para garantir a funcionalidade dos veículos elétricos, reiterando que o planejamento estratégico é crucial para garantir a confiança do consumidor e viabilizar o mercado, exigindo estudos técnicos e de impacto. O autor enfatiza que, na ausência de uma rede de suprimento resiliente e planejada, a difusão tecnológica é severamente comprometida.

Pesquisas conduzidas sobre a análise logística e planejamento urbano para a inserção de eletropostos no estado do Rio de Janeiro, pelo Grupo de Estudos do Setor Elétrico (GESEL-UFRJ), evidenciam que a cidade do Rio de Janeiro concentra 63% dos eletropostos do estado, com foco em áreas com maior poder aquisitivo e comercial. Esse dado reflete o que os pesquisadores chamam de “concentração espacial por renda”, pois a infraestrutura de recarga está localizada em bairros com maior Índice de Desenvolvimento Humano (IDH).

A maioria desses postos de recarga estão localizados em shoppings, supermercados e centros empresariais, evidenciando um déficit de cobertura na Zona Norte e na Baixada Fluminense, onde segundo os pesquisadores, há uma barreira socioeconômica para a democratização da eletromobilidade. O referido grupo de pesquisa também empregou o Sistema de Informação Geográfica (SIG) e modelagem de localização para identificar áreas estratégicas com base na densidade demográfica. A metodologia aplicada otimizou a instalação de eletropostos visando cobertura máxima e minimização de custos de deslocamento, assegurando acessibilidade aos usuários (UNIVERSIDADE FEDERAL DO RIO DE JANEIRO, 2021).

Todavia, o planejamento para a implementação dessa rede em capitais como Teresina enfrenta desafios inerentes à complexidade do planejamento urbano regional, que carece de diretrizes que integrem a infraestrutura de combustíveis fósseis já estabelecida à nova demanda elétrica. O problema central reside na identificação de locais que minimizem o “deserto de carregamento”, considerando as especificidades

socioespaciais da capital piauiense (MOURA et al., 2024).

Nesse contexto, a aplicação de métricas de vizinhança para o planejamento de infraestrutura de capitais do Nordeste, como Teresina, apresenta-se como uma lacuna científica necessária para a interiorização da mobilidade elétrica. Outras investigações científicas demonstraram a integração de Inteligência Artificial (IA), Geoprocessamento (GEO) e Sensoriamento Remoto (SR) para monitoramento e classificação da cobertura vegetal na Amazônia.

O estudo de Silva e Souza Junior (2025) utilizou o algoritmo *K-Nearest Neighbors* (KNN) e *Random Forest* para gestão ambiental, no qual o KNN apresentou uma elevada acurácia em comparação ao *Random Forest*. A eficiência observada pelos autores do estudo fundamentou-se na capacidade do KNN de processar relações de vizinhança imediata sem a necessidade de generalizações rígidas.

Nessa pesquisa, essa mecânica é transportada de uma classificação convencional para um modelo de otimização espacial: o algoritmo analisa a proximidade entre os 230 postos e os polos de interesse, utilizando a Fórmula de Haversine para calcular distâncias geodésicas precisas, permitindo que o sistema identifique locais prioritários com base na densidade local de serviços, otimizando a distribuição da rede de recarga para minimizar lacunas de cobertura na malha urbana.

Sob essa ótica, o KNN destaca-se como um avaliador robusto para análise espacial, devido a sua eficiência algorítmica e versatilidade no tratamento de problemas não lineares (SOUZA; ALMEIDA, 2024). Diferente de abordagens puramente teóricas, a solução aqui apresentada fundamenta-se na análise de proximidade e densidade para fundamentar um modelo de localização eficiente. Nesse sentido, o conceito de Cidades Inteligentes evolui para um ecossistema onde a infraestrutura urbana é otimizada por meio de tecnologias emergentes e análise de dados em larga escala.

Dessa forma, a implementação de redes de eletropostos exige modelos de decisão precisos que considerem a distribuição espacial e a demanda energética, integrando a mobilidade elétrica ao tecido digital da cidade. A principal contribuição deste artigo reside na metodologia de seleção inteligente de postos de combustíveis já existentes para a conversão e integração de eletropostos.

Essa estratégia visa otimizar a infraestrutura urbana atual, reduzindo custos de implementação e aproveitando pontos estratégicos já consolidados no fluxo logístico da cidade (SMART CITIES COUNCIL, 2025). O estudo busca transformar a rede

de postos de combustíveis pré-existent na capital em uma base lógica para a localização estratégica dessas estações.

MATERIAIS E MÉTODO

Esta pesquisa estruturou-se a partir do levantamento georreferenciado (latitude e longitude) dos postos de combustíveis em Teresina PI, integrando-os a dados urbanos de fluxo viário e pontos de interesse (comércios) extraídos da plataforma *OpenStreetMap*. Após a coleta, os registros passaram por um tratamento rigoroso e padronização para o Sistema Internacional de Unidades (SI) com o auxílio da biblioteca *Numpy* para a manipulação de matrizes e cálculos estatísticos.

O procedimento fundamentou-se em uma análise de cruzamento espacial, utilizando a Fórmula de Haversine para cálculos de distância e criação de zonas de influência (*buffers*) para contabilizar a densidade comercial e conectividade viária de cada ponto. Através de um protótipo computacional em linguagem *Python*, aplicou-se o algoritmo KNN e um modelo de pontuação (*score*) baseado nos critérios de acessibilidade, demanda e cobertura.

Por fim, o modelo foi submetido a um processo de validação por meio da comparação com pontos aleatórios, o que permitiu avaliar a sua eficácia e demonstrar, através de visualização cartográfica, a viabilidade do uso de inteligência de dados para posicionar Teresina como um polo estratégico de eletromobilidade regional. A Figura 1 ilustra uma visão global dos processos utilizados na realização desta pesquisa.



Figura 1: Fluxo metodológico para a seleção de locais otimizados para a instalação de eletropostos em Teresina.

Seguindo esta lógica, a metodologia utilizada foi dividida nas seguintes seções:

- Base de dados

A fase inicial do estudo concentrou-se no levantamento sistemático e no mapeamento dos postos de combustíveis na cidade de Teresina. A amostragem compreendeu 230 estabelecimentos, distribuídos de forma estratificada entre as zonas Norte, Sul, Leste, Sudeste e Centro. A escolha dessa amostra visou

garantir a representatividade espacial em diferentes densidades demográficas, permitindo uma análise mais robusta da infraestrutura municipal.

A base de dados foi extraída do Pannel Dinâmico de Consultas da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP, 2024), que fornece o registro cadastral atualizado, endereço completo e a situação operacional dos revendedores e varejistas de Teresina. Para a obtenção das coordenadas geográficas (latitude e longitude), utilizou-se o *software Google Earth*, por meio da técnica de vetorização sobre imagens de satélite de alta resolução, adotando-se o sistema de coordenadas geodésicas WGS 84 (FITZ, 2023). A modelagem da malha viária e a identificação de pontos de interesse comercial foram executadas por meio da biblioteca OSMnx, que permite a extração de dados estruturados do *OpenStreetMap* (OSM) para caracterizar a dinâmica socioeconômica do entorno.

- Cálculo de distâncias

Nesta etapa, a métrica de distância escolhida para a conversão das coordenadas geográficas em distâncias lineares (quilômetros) foi a Fórmula de *Haversine*, que, diferente da Distância Euclidiana, considera a curvatura da Terra através do cálculo do arco de círculo máximo, o que é essencial para garantir a precisão em análises de redes urbanas e logística, minimizando distorções ao adotar o raio médio terrestre de 6371,0 km.

Dadas as coordenadas de dois pontos, $P_1 (\phi_1, \lambda_1)$ e $P_2 (\phi_2, \lambda_2)$, foi realizada a conversão dos valores de graus decimais para radianos (ϕ e λ). A variação entre os pontos foi estabelecida conforme as Equações 1 e 2:

$$\Delta \phi = \phi_2 - \phi_1 \quad (1)$$

$$\Delta \lambda = \lambda_2 - \lambda_1 \quad (2)$$

A aplicação da métrica de distância esférica permitiu calcular o parâmetro a , representando o quadrado da metade da corda entre os pontos, utilizando as funções de seno e cosseno conforme expresso na Equação 3:

$$a = \sin^2\left(\frac{\Delta \phi}{2}\right) + \cos(\phi_1) \cdot \cos(\phi_2) \cdot \sin^2\left(\frac{\Delta \lambda}{2}\right) \quad (3)$$

Em seguida, o ângulo central entre os dois pontos, denotado por c , foi obtido através da função de arco tangente de dois argumentos (*atan2*), garantindo maior robustez numérica ao cálculo, conforme mostrado na Equação 4:

$$c = 2 \cdot \text{atan2}(\sqrt{a}, \sqrt{1-a}) \quad (4)$$

Por fim, a distância linear d entre os dois pontos foi calculada multiplicando-se o ângulo central pelo raio médio da Terra (R), descrito na Equação 5:

$$d = R \cdot c \quad (5)$$

- Análise de densidade

A análise da distribuição espacial e da concentração dos pontos de interesse fundamentou-se no conceito do algoritmo *K-Nearest Neighbors* (KNN), uma técnica de aprendizado de máquina baseada em instâncias, aplicado neste estudo de forma não supervisionada. O KNN opera sob a premissa de que objetos próximos no espaço possuem características ou relações de vizinhança que permitem inferir propriedades locais, como a densidade, sem a necessidade de um treinamento prévio com dados rotulados.

Para esta análise, a definição do parâmetro k foi estabelecida em 3 ($k=3$), valor que permite capturar a dinâmica da vizinhança imediata entre os postos de combustíveis. A lógica de processamento foi implementada em linguagem *Python*, conforme detalhado no pseudocódigo da Algoritmo 1:

Algoritmo 1

Pseudocódigo de Seleção de Postos	
1:	configurar $k \leftarrow 3, top_n \leftarrow 25$ e cidade "Teresina, Piauí"
2:	pontos $\leftarrow$ ler coordenadas de "coordenadas_unicas.txt"
3:	grafo $\leftarrow$ baixar malha viária de cidade via OSMnx
4:	comercio $\leftarrow$ obter pontos de interesse (amenity, shop)
5:	para cada posto _i em pontos faça
6:	distancias $\leftarrow$ lista vazia
7:	para cada posto _j em pontos faça
8:	se $i \neq j$ então
9:	$d \leftarrow \text{haversine}(\text{posto}_i, \text{posto}_j)$
10:	armazenar d em distancias
11:	fim-se
12:	fim-para
13:	ordenar distancias de forma crescente
14:	media_knn $\leftarrow$ média das k menores distancias
15:	densidade _i $\leftarrow 1/\text{media_knn}$ (se media_knn > 0)
16:	fim-para
17:	para cada via em grafo faça
18:	se via.tipo em ['motorway', 'trunk'] então fluxo $\leftarrow 5$
19:	senão se via.tipo é 'primary' então fluxo $\leftarrow 4$
20:	senão se via.tipo é 'secondary' então fluxo $\leftarrow 3$
21:	senão fluxo $\leftarrow 1$
22:	fim-se
23:	fim-para
24:	para cada p em pontos faça
25:	dist $\leftarrow$ distancia mínima



```

26:   buffer ← área de influencia ao redor de p (0.005)
27:   score_com ← contagem de comércio
28:   score_fluxo ← média de fluxo
29:   S ← (0.5 · dist) + (0.25 · score_com) + (0.25 ·
   score_fluxo)
30:   armazenar (p, S) em lista_avaliacao
31: fim-para
32: ordenar lista_avaliacao por S de forma decrescente
33: top_postos ← selecionar os primeiros top_n postos
34: comparar média de S (otimizado) com média de S (aleatório)
35: gerar relatório “relatório_final.txt” e mapa interativo
   “mapa_postos_otimizados.html”

```

A densidade (ρ) de cada ponto foi determinada pelo inverso da distância média dos k vizinhos mais próximos. Matematicamente, a fórmula aplicada para cada posto i foi expressa pela Equação 6:

$$\rho_i = \frac{1}{\frac{1}{k} \sum_{j=1}^k d_{ij}} \quad (6)$$

Em que ρ_i representa o índice de densidade do ponto analisado, k é o número de vizinhos considerados e d_{ij} corresponde à Distância de Haversine específica entre o ponto de referência i e seu j -enésimo vizinho mais próximo. Essa abordagem permite que postos situados em zonas de alta concentração apresentem um *score* de densidade superior, fundamentando a seleção dos locais com maior potencial estratégico para a instalação da infraestrutura de recarga.

- Modelo multicritério de decisão

A seleção de locais prioritários foi regida por uma análise multicritério, metodologia que permite a integração de variáveis de naturezas distintas em um único indicador de viabilidade. A utilização de modelos ponderados é essencial no planejamento espacial, pois permite que o tomador de decisão atribua pesos específicos a fatores como visibilidade viária, suporte comercial e isolamento geográfico, transformando dados heterogêneos em um *ranking* objetivo de priorização.

O *score* final (S) de cada candidato foi definido pela função expressa na Equação 7:

$$S = 0.5 \cdot D + 0.25 \cdot N + 0.25 \cdot F \quad (7)$$

Em que D representa o isolamento geográfico do posto candidato em relação à rede já existente (*distancia_minima*), N reflete o suporte de infraestrutura e conveniência para o usuário (*score_com*) e F indica o potencial de fluxo de veículos e visibilidade do local (*score_fluxo*).

- Análise espacial

A análise espacial foi estruturada para transpor a visualização de pontos isolados para uma compreensão profunda da área de influência direta de cada estabelecimento, utilizando técnicas avançadas de geoprocessamento. Para tal finalidade, aplicou-se a criação de zonas de entorno, conhecidas como *buffers* com um raio de 0,005 graus (aproximadamente 550 metros) a partir das coordenadas de cada posto.

A utilização de zonas de influência é considerada superior à análise puramente pontual, pois permite mensurar a interação real entre o objeto de estudo e o seu contexto urbano imediato, simulando com maior fidelidade o alcance de deslocamento de usuários e a abrangência de serviços de apoio no entorno do local de recarga. Dentro dessas áreas de influência, o modelo executou o processamento de interações espaciais para a extração de variáveis multidimensionais.

Primeiramente, utilizou-se a biblioteca *Shapely* para realizar o cruzamento geométrico entre o polígono do *buffer* e a camada de pontos de interesse (POIs) comerciais e de serviços. Esta etapa fundamentou-se no conceito de que a viabilidade de um eletroposto está intrinsecamente ligada à oferta de conveniências adjacentes, as quais mitigam a percepção de tempo de espera durante a recarga do veículo.

Simultaneamente, a análise interceptou o grafo de vias contido em cada zona de influência, atribuindo pesos diferenciados conforme a classificação funcional das vias no *OpenStreetMap*. A integração da hierarquia viária nesta análise espacial justifica-se pela necessidade de identificar locais com alta visibilidade e acessibilidade técnica, garantindo que os pontos selecionados funcionem como nós estratégicos e eficientes dentro da rede de transporte urbana. A manipulação sistemática desses objetos geométricos e o cálculo de suas relações topológicas asseguram que o modelo multicritério subsequente opere sobre indicadores que reflitam a complexidade do tecido urbano.

- Seleção dos postos

O processo de seleção final dos locais para a instalação de eletropostos foi consolidado por meio de uma rotina de ordenação sistemática e filtragem baseada no



desempenho agregado. Após a atribuição de *scores* individuais a cada um dos candidatos da base de dados, os registros foram estruturados em uma matriz contendo identificação, coordenadas geográficas e o respectivo valor de utilidade.

A utilização de métodos de ranqueamento é fundamental no planejamento de redes de infraestrutura, pois permite transformar uma análise de múltiplas variáveis em uma lista de prioridades clara e isenta de viés subjetivo, facilitando a tomada de decisão logística. A seleção seguiu um critério de corte de $top_n = 25$, isolando os postos que tiveram maior desempenho cumulativo no modelo multicritério.

Essa abordagem de seleção baseou-se na premissa de que a rede inicial deve ser composta de pontos que apresentem, simultaneamente, o melhor equilíbrio entre baixa concorrência imediata (maior isolamento espacial) e alta atratividade de entorno (densidade comercial e fluxo viário). A consolidação desses resultados em um mapa, destacados na cor verde, permitiu a visualização estratégica da futura rede e serviu como base para a etapa de validação.

- Avaliação

A etapa final de avaliação foi delineada para validar a robustez e a eficácia do modelo de seleção proposto, assegurando que as recomendações superem o desempenho de distribuições casuais ou não planejadas. Para isso, utilizou-se uma metodologia de comparação estatística baseada na criação de um grupo de controle composto por uma amostra aleatória de postos da base original, com dimensão idêntica à do grupo otimizado ($n = 25$).

A aplicação de testes comparativos entre cenários otimizados e cenários randômicos é um procedimento padrão em ciência da informação geográfica para mensurar o ganho de eficiência logística e a relevância das variáveis multicritério escolhidas no planejamento das redes. A métrica central de sucesso foi definida pela comparação das médias aritméticas dos *scores* finais entre os dois grupos.

Adicionalmente, calculou-se a variação percentual de ganho, permitindo quantificar o incremento na qualidade da rede de infraestrutura de recarga. Esse rigor avaliativo é fundamental para garantir que a transição para a mobilidade elétrica em Teresina seja amparada por um modelo de localização-alocação que minimize riscos de ociosidade e maximize a conveniência para o usuário final, consolidando a validade científica da metodologia empregada.

RESULTADOS E DISCUSSÃO

A aplicação do modelo sobre a base de dados da cidade de Teresina permitiu a espacialização de 230 pontos candidatos. O mapa resultante revelou uma concentração primária de postos de combustíveis ao longo dos eixos radiais que conectam o Centro às zonas Leste e Sul. A plotagem dos 25 postos selecionados (*top_25*) demonstrou que o algoritmo evitou a sobreposição em áreas saturadas, identificando locais que, embora inseridos em contextos de alta densidade comercial, mantêm um distanciamento geodésico calculado pela Fórmula de *Haversine* que otimiza a área de cobertura da rede. Na Tabela 1 são apresentadas as coordenadas geográficas dos postos selecionados pelo algoritmo.

Tabela 1: Coordenadas dos postos selecionados

Posto Selecionado	Latitude	Longitude
P102	-5,09046	-42,8167
P103	-5,08998	-42,8105
P99	-5,09297	-42,8081
P111	-5,08746	-42,805
P92	-5,09668	-42,8159
P13	-5,08704	-42,8035
P15	-5,08637	-42,8035
P96	-5,09562	-42,8041
P101	-5,09263	-42,8015
P100	-5,09291	-42,8012
P114	-5,08685	-42,8225
P130	-5,08102	-42,8153
P83	-5,09993	-42,8116
P123	-5,0815	-42,8101
P117	-5,08512	-42,7998
P129	-5,08103	-42,8108
P93	-5,09643	-42,8019
P76	-5,10462	-42,7528
P128	-5,08106	-42,7912
P132	-5,08045	-42,7893
P133	-5,0804	-42,791
P82	-5,10156	-42,7528
P116	-5,0861	-42,8239
P171	-5,07031	-42,7801
P172	-5,07015	-42,7786

Os melhores pontos destacados no mapa coincidem com as avenidas principais da cidade, sugerindo que a visibilidade e acessibilidade são subprodutos naturais da métrica de fluxo estimado

implementada. A Figura 2 apresenta os pontos plotados e selecionados no mapa:




Figura 2: Mapa com os 25 postos selecionados

A eficácia da metodologia foi quantificada através da comparação direta entre o cenário otimizado e uma seleção aleatória. A Tabela 2 apresenta as médias obtidas para as variáveis que compõem o *score* final:

Tabela 2: Comparação de Desempenho (médias)

Cenários	Score Total	Comércio	Fluxo
Aleatório 1	11,20	43,28	1,50
Aleatório 2	13,53	52,56	1,55
Aleatório 3	10,00	38,48	1,51
Aleatório 4	12,6	48,84	1,56
Aleatório 5	23,59	92,80	1,55
Otimizado	50,81	201,48	1,74

De acordo com as premissas da análise quantitativa espacial, a superioridade estatística do grupo selecionado em relação aos cenários aleatórios comprova que o algoritmo foi capaz de filtrar as melhores janelas de oportunidade em termos de viabilidade viária, oferta comercial e distanciamento estratégico. É importante ressaltar que os valores apresentados para o cenário de controle foram obtidos por meio de cinco amostragens aleatórias distintas de postos, o que confere maior robustez à validação e reduz possíveis distorções causadas pela natureza estocástica do processo.

Observa-se inicialmente que o **Score Total** do cenário otimizado atingiu o valor médio de **50,81**, enquanto os cinco cenários aleatórios apresentaram valores significativamente inferiores: **11,20**, **13,53**, **10,00**, **12,60** e **23,59**. Mesmo considerando o melhor cenário aleatório, o modelo otimizado apresentou desempenho superior a duas vezes, demonstrando que a seleção realizada não ocorreu de forma casual, mas

sim orientada por critérios espaciais consistentes. Esse resultado confirma que os pontos escolhidos apresentam maior viabilidade para a implantação da infraestrutura de recarga elétrica.

Na métrica de Comércio, a diferença torna-se ainda mais expressiva. O cenário otimizado apresentou média de 201,48, enquanto os cenários aleatórios registraram 43,28, 52,56, 38,48, 48,84 e 92,80. Esse aumento substancial indica que os postos selecionados estão inseridos em regiões com maior concentração de estabelecimentos comerciais e de serviços, fator extremamente relevante para a experiência do usuário durante o tempo de recarga do veículo. A presença de farmácias, supermercados, restaurantes e centros comerciais aumenta a atratividade do eletroposto e melhora sua viabilidade econômica e operacional.

Em relação ao Fluxo, embora a variação numérica pareça menor, ela possui elevada relevância prática. Os cenários aleatórios apresentaram valores entre 1,50 e 1,56, enquanto o cenário otimizado alcançou 1,74. Isso demonstra que os postos selecionados estão localizados em vias de maior hierarquia urbana, como avenidas principais e corredores estruturais da cidade, garantindo maior visibilidade, acessibilidade e circulação de veículos. No contexto do planejamento urbano, essa característica é fundamental para ampliar a utilização da infraestrutura instalada.

A sinergia entre o alto fluxo estimado e a elevada densidade de comércios reflete a tendência de centralidades lineares em Teresina, onde o comércio se desenvolve ao longo das grandes avenidas. Identificar essas regiões como estratégicas é fundamental para a transição energética, pois garante que o eletroposto não seja apenas um ponto de recarga, mas um elemento integrado ao cotidiano da população, aproveitando infraestruturas já consolidadas para minimizar custos de implementação e maximizar a utilidade pública.

CONCLUSÃO

O presente estudo apresentou uma metodologia científica estruturada e replicável para a seleção estratégica de locais destinados à instalação de estações de recarga de veículos elétricos na cidade de Teresina. Através da integração de geoprocessamento, análise multicritério e do algoritmo *K-Nearest Neighbors* (KNN), foi possível transpor a infraestrutura de combustíveis fósseis já consolidada para um modelo logístico otimizado de eletromobidade. A aplicação da Fórmula de *Haversine* e a análise de zonas de influência (*buffers*) garantiram que a seleção dos 25 pontos prioritários não fosse apenas uma projeção teórica baseada em algoritmos isolados, mas uma resposta às dinâmicas urbanas de fluxo viário e densidade comercial da capital piauiense.



Os resultados da validação estatística confirmaram a eficácia do modelo, que superou significativamente o cenário de seleção aleatória em todos os indicadores. O expressivo ganho na densidade comercial dos postos selecionados demonstra que a metodologia é capaz de identificar locais que ofereçam conveniência e suporte ao usuário, mitigando os desafios inerentes ao tempo de espera durante a recarga. Além disso, a priorização de vias de alta hierarquia assegura a visibilidade e acessibilidade, buscando a rentabilidade econômica e social da rede.

Portanto, o sistema inteligente proposto consolida-se como uma ferramenta de suporte à decisão para viabilizar a descarbonização urbana em Teresina, aproveitando pontos logísticos já consolidados para reduzir custos e contribuir com a transição energética. Ao alinhar a infraestrutura urbana às metas de sustentabilidade, o estudo contribui diretamente para a melhoria da qualidade ambiental e para a modernização do ecossistema de transporte local, garantindo uma rede de recarga eficiente e integrada ao cotidiano da população. Para o aprimoramento e evolução desta pesquisa, recomendam-se a incorporação de dados populacionais e evolução do modelo para técnicas de aprendizado supervisionado, com a utilização de bases de dados históricas e uso de algoritmos de otimização avançada, visando o equilíbrio técnico entre a minimização de impactos ambientais e a máxima eficiência energética da malha urbana.

AGRADECIMENTOS

Os autores deste presente artigo agradecem à Universidade Estadual do Piauí (UESPI) pelo suporte institucional e pela infraestrutura acadêmica disponibilizada para a realização deste estudo. Expressa-se também, um agradecimento especial ao Núcleo de Formação e Pesquisa em Energias Renováveis e Telecomunicações do Piauí (NUFPERPI), pelo apoio técnico e pelo ambiente de fomento à pesquisa e inovação tecnológica, fundamentais para a viabilização deste trabalho.

REFERÊNCIAS

ABSOLAR – ASSOCIAÇÃO BRASILEIRA DE ENERGIA SOLAR FOTOVOLTAICA. **Infográfico: Energia Solar Fotovoltaica no Brasil**. São Paulo: ABSOLAR, 2024.

ANEEL – AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Relatório de Informações do Sistema de Geração do Brasil (SIGEL)**. Brasília: ANEEL, 2023.

BRASIL. Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP). **Painel Dinâmico de Consultas: Postos Revendedores e Varejistas**. Brasília, DF: ANP, 2024. Disponível em:

<https://www.gov.br/anp/pt-br>. Acesso em: 18 abr. 2026.

BEZERRA, F. D. Oportunidades para o Nordeste em energia eólica. **Caderno Setorial ETENE**, Fortaleza, v. 6, n. 177, 2021. Disponível em: <https://www.bnb.gov.br>. Acesso em: 18 abr. 2026.

BRASIL. Ministério de Minas e Energia. **Balanço Energético Nacional 2023: Ano base 2022**. Rio de Janeiro: EPE, 2023.

DENTON, T. **Veículos elétricos e híbridos: tecnologia, sistemas e manutenção**. Tradução: Luiz Alberto Bertolucci Jr. 1. Ed. São Paulo: Blucher, 2022.

EMPRESA DE PESQUISA ENERGÉTICA. **Recursos Energéticos: Mobilidade Elétrica**. Brasília, DF: EPE, 2021. (Nota Técnica PR 01/21). Disponível em: <https://www.epe.gov.br>. Acesso em: 18 abr. 2026.

FITZ, P. R. **Geoprocessamento e Análise Espacial: conceitos e aplicações**. 2. Ed. São Paulo: Oficina de Textos, 2023.

INTERNATIONAL ENERGY AGENCY (IEA). **Global EV Outlook 2025: Transport and energy transitions**. Paris: IEA, 2025. Disponível em: <https://www.iea.org>. Acesso em: 18 abr. 2026.

IPCC. **Climate Change 2025: Mitigation of Climate Change**. Geneva: IPCC, 2025.

MOURA, M. O. et al. **Desafios da Mobilidade Elétrica em Cidades de Médio Porte: Integração e Infraestrutura Urbana**. 1. Ed. São Paulo: Blucher, 2024.

REIS, L. B. dos. **Geração de Energia Elétrica**. 4. Ed. Barueri: Manole, 2021.

THE RIO TIMES. Brazil Renewable Energy 2026: Wind, Solar and Green Hydrogen. *The Rio Times*, 14 abr. 2026. Disponível em: <https://www.riotimesonline.com/brazil-renewable-energy-2026-guide/>. Acesso em: 28 abr. 2026.

SANTOS, G. F.; PINTO, H. S. (org.). **A Crise do Setor Elétrico de 2001: 20 anos depois**. 1. Ed. Rio de Janeiro: Synergia, 2021.

SILVA, M. P. da; SOUZA JUNIOR, G. N. de. Inteligência Artificial para o Monitoramento e Previsão de Riscos de Desmatamento na Amazônia Legal. In: **ANAIS DO VI COBICET**. Evento online, 2025.

SMART CITIES COUNCIL. **Smart Cities Readiness Guide: Integrating Electric Mobility and Urban Infrastructure**. Washington, DC: SCC, 2025. Disponível em: <https://www.smartcitiescouncil.com>. Acesso em: 18 abr. 2026.



SOUZA, R. T.; ALMEIDA, J. F. **Inteligência Artificial e Análise Espacial: Métodos e Aplicações em Redes Urbanas**. 1. Ed. Curitiba: Editora Acadêmica Brasil, 2024.

UNIVERSIDADE FEDERAL DO RIO DE JANEIRO. Grupo de Estudos do Setor Elétrico. **Análise da Infraestrutura de Recarga de Veículos Elétricos no Estado do Rio de Janeiro**. Rio de Janeiro: GESEL/UFRJ, 2021.