

Planejamento Otimizado de Eletropostos: Uma Abordagem Híbrida com Previsão de Demanda e Otimização Evolucionária para Belo Horizonte

1st Guilherme Luis Soares Santos
Departamento de Informática
Instituto Federal de Minas Gerais
Sabará, Brasil
guilbluis0811@gmail.com

2nd Carlos Alexandre Silva
Departamento de Informática
Instituto Federal de Minas Gerais
Sabará, Brasil
carlos.silva@ifmg.edu.br

3rd Bruno Nonato Gomes
Departamento de Informática
Instituto Federal de Minas Gerais
Sabará, Brasil
bruno.nonato@ifmg.edu.br

Abstract—The rapid growth of the electric vehicle (EV) fleet in Belo Horizonte calls for robust planning of charging infrastructure. This study addresses this challenge by proposing a methodology that integrates demand forecasting models — Polynomial Regression and ARIMA — with a Genetic Algorithm for geospatial optimization of charging stations. Predictive analysis revealed the ARIMA model’s superiority for long-term projections. The resulting geospatial optimization not only meets the projected demand but also maximizes economic viability by prioritizing higher-income regions. The proposed solution recommends installing a 15% surplus of charging stations over the minimum demand, demonstrating that this strategy is economically advantageous and offers valuable insights for smart and sustainable urban planning.

Index Terms—Genetic Algorithms, Demand Forecasting, Geospatial Optimization, ARIMA, Polynomial Regression, Electric Vehicle Charging Stations.

I. INTRODUÇÃO

A substituição de veículos a combustão por modelos elétricos tem se intensificado em todo o mundo, impulsionada por iniciativas ambientais, avanços tecnológicos e estratégias adotadas pelas montadoras para reduzir a poluição gerada por combustíveis fósseis como gasolina e diesel [30]. O Brasil, historicamente relevante no consumo de veículos, passou a integrar esse processo de transformação mais diretamente com a chegada de montadoras como BYD (*Build Your Dreams*) e GWM (*Great Wall Motors*) em 2022 e 2023, respectivamente, sendo responsáveis por 39,7% da frota de elétricos no país em 2024 [2]. Esse cenário provocou uma reação no mercado automotivo nacional, levando fabricantes tradicionais a ampliar suas ofertas de veículos eletrificados e a reduzir preços como forma de competir com as novas marcas [13].

A cidade de Belo Horizonte, assim como diversas regiões do Brasil, ainda não dispõe de infraestrutura adequada para acompanhar o crescimento da frota de veículos elétricos. Em âmbito nacional, a desproporção entre a quantidade de eletropostos e o número de veículos elétricos é significativa: em 2024, o Brasil contava com 12.137 eletrocarregadores disponíveis para atender a 197.944 veículos elétricos que dependem de carregamento externo, considerando apenas mo-

delos BEV (*Battery Electric Vehicle*) e PHEV (*Plug-in Hybrid Electric Vehicle*) [2]. Para fins de comparação, existiam no país 44.224 postos de combustíveis tradicionais [4], que atendem a uma frota de aproximadamente 124 milhões de veículos a combustão [11], mesmo com uma demanda por veículos a combustão sendo 729 vezes maior, esta é atendida de maneira satisfatória. Isso ocorre devido à diferença entre o tempo necessário para abastecimento, sendo de 5 a 10 minutos para um veículo a combustão e de 30 minutos a 8 horas para um veículo elétrico [16].

Entretanto, a expansão da infraestrutura de recarga não deve ocorrer de forma indiscriminada. Diversos fatores precisam ser considerados, como o tipo de carregadores a serem instalados, a capacidade média de atendimento diário de cada unidade, e a localização com maior concentração de veículos elétricos. Diante disso, torna-se necessário o desenvolvimento de uma estratégia de planejamento que permita a instalação otimizada dos eletropostos, baseada em critérios técnicos e na previsão de demanda. Essa abordagem visa não apenas atender as necessidades atuais, mas também preparar a cidade para o crescimento projetado da frota elétrica.

A inteligência artificial tem se consolidado como uma ferramenta essencial em projetos de análise de dados e otimização. Dentre os diversos algoritmos existentes, destacam-se neste trabalho os métodos de aprendizado de máquina. Para a resolução do problema proposto, foi utilizado o Algoritmo Genético (AG), uma meta-heurística de otimização baseada nos princípios da seleção natural e evolução biológica, amplamente utilizada em problemas com grandes espaços de busca. Complementarmente, foram aplicados modelos estatísticos supervisionados — regressão polinomial e o auto-regressivo integrado de médias móveis (ARIMA) — para a análise e previsão da demanda futura por veículos elétricos. Os resultados dessas previsões permitiram estimar a quantidade necessária de estações de recarga, que, posteriormente, foram alocadas de forma otimizada por meio do AG.

Este trabalho tem como objetivo propor uma solução otimizada para a construção e distribuição de estações de recarga de veículos elétricos na cidade de Belo Horizonte,

utilizando o AG para maximizar a cobertura da demanda entre as regiões. A crescente inserção de veículos elétricos no mercado nacional evidencia a necessidade urgente de ampliação da infraestrutura de recarga, uma vez que muitas cidades ainda não possuem estrutura adequada para atender à demanda atual e futura. Espera-se que os resultados obtidos contribuam com o desenvolvimento urbano sustentável e beneficiem tanto os atuais usuários de veículos eletrificados quanto futuros proprietários. Além disso, a metodologia proposta possui potencial de adaptação para outras cidades brasileiras ou contextos internacionais com características semelhantes.

A principal contribuição deste trabalho está na integração de modelos estatísticos de previsão de demanda, baseados em dados da frota elétrica nacional e adaptados ao contexto de Belo Horizonte, com um AG para a alocação geoespacial otimizada de estações de carregamento. Adicionalmente, o trabalho detalha uma abordagem prática para a extração de dados de fontes não estruturadas (imagens e gráficos) utilizando ferramentas de IA generativa, um desafio comum em análises baseadas em dados públicos.

II. REVISÃO BIBLIOGRÁFICA

A. Localização otimizada de eletropostos

Diversos trabalhos na literatura têm explorado técnicas de otimização para alocação eficiente de estações de recarga de veículos elétricos. Em um contexto internacional, Zhou et al. [33] utilizaram o AG, implementado via MATLAB, para otimizar a localização de eletropostos nas cinco maiores cidades da Irlanda. O modelo desenvolvido considera custos econômicos (construção, manutenção e energia), custos de deslocamento e impactos ambientais (emissões de carbono), evidenciando a importância de uma modelagem multivariada e baseada em custo total. A escolha do AG deve-se à sua capacidade de realizar busca global em problemas complexos de planejamento.

Ainda no cenário internacional, Akbari et al. [3] propuseram um modelo baseado em AG para otimização da localização de eletropostos com múltiplos limitadores: energia disponível por estação, tempo médio de carregamento, consumo energético por veículo, distâncias médias diárias, ciclos de carga, e projeções de frota por meio do modelo de *Bass*. Os pontos candidatos incluíram locais com alta circulação ou estacionamento prolongado, como estacionamentos e centros comerciais.

No contexto brasileiro, a pesquisa também tem explorado diferentes abordagens. Silva e Mestria [28] compararam um algoritmo guloso com a meta-heurística *Chemical Reaction Optimization* (CRO) na cidade de Vitória-ES. O objetivo era minimizar o custo de instalação das estações e a distância entre os usuários e os pontos de carregamento. Os resultados demonstraram que o uso de distâncias reais, em detrimento das distâncias euclidianas, e a seleção de locais com alta permanência e visitação, produzem resultados mais realistas. O CRO apresentou desempenho superior ao método guloso, com incremento marginal no tempo computacional.

Também no Brasil, Lima [14], em uma aplicação real em Campinas-SP, comparou a resolução do problema das

p-medianas com a meta-heurística *Teaching-Learning-Based Optimization* (TLBO). O estudo destacou a importância de uma evolução gradual na complexidade dos testes e baseou sua modelagem em dados reais: postos de combustíveis foram considerados pontos candidatos, e a demanda foi estimada com base em agrupamentos (via *k-means*) de vias com radares — consideradas de maior tráfego — além de fatores socioeconômicos e locais prioritários como shoppings e universidades. Os resultados mostraram que, embora o TLBO se aproximasse do *benchmark* (INTLINPROG), seu custo computacional foi significativamente superior, tornando-o inviável para o caso analisado.

Dessa forma, observa-se que os trabalhos anteriores utilizam diversas técnicas de otimização e cenários reais para tratar o problema de localização de eletropostos, mas ainda carecem de abordagens integradas com previsão de demanda futura baseada em dados históricos reais. O presente trabalho avança nesse aspecto ao incorporar modelos de regressão e séries temporais para estimar a evolução da frota elétrica, integrando essa informação a uma estratégia de otimização com o AG.

B. Análise e Previsão de Dados

Modelos de previsão têm sido amplamente utilizados para estimar séries temporais em contextos diversos. Zan e Sellitto [32] aplicaram diferentes técnicas de previsão de demanda, com destaque para a regressão polinomial, em séries de vendas de produtos industriais. Os autores testaram diferentes graus polinomiais (3, 4 e 5), demonstrando a importância de balancear o grau de complexidade do modelo com a qualidade do ajuste, e apontaram o grau 4 como ideal, com base no coeficiente de determinação (R^2) e no erro médio absoluto (MAE), após o tratamento de *outliers*.

Slompo e Morettin [29] aplicaram o modelo auto-regressivo de médias móveis (ARMA) para a previsão da frota de veículos elétricos no Brasil, evidenciando sua eficácia em séries temporais lineares. O modelo, que combina Auto Regressão (AR) e Média Móvel (MA), foi avaliado com base no RMSE, MAE e no Critério de Informação de Akaike (AIC), demonstrando alto desempenho. A eficácia de modelos de séries temporais como o ARMA em contextos similares motivou a escolha do modelo ARIMA, que incorpora a diferenciação para estacionariedade da série neste trabalho.

Zilli et al. [34] avaliaram a aplicabilidade da regressão polinomial para previsão de preços de imóveis, destacando sua precisão e transparência frente às redes neurais artificiais. A comparação foi feita com base no RMSE, sendo a regressão polinomial mais estável nas partições dos dados e com desempenho superior em termos de variabilidade dos erros.

O presente trabalho diferencia-se ao combinar essas técnicas de previsão — regressão polinomial e ARIMA — para estimar a evolução da frota de veículos elétricos em uma cidade brasileira, integrando os resultados à etapa de otimização da localização de eletropostos via AGs.

III. METODOLOGIA

Este trabalho tem como objetivo propor uma solução para a alocação otimizada de eletropostos em Belo Horizonte,

utilizando técnicas de previsão e algoritmos de otimização. Para isso, foram estabelecidos três objetivos principais: (i) estimar a quantidade necessária de eletropostos a partir da evolução da frota de veículos elétricos, (ii) comparar modelos de previsão adequados para esse contexto, e (iii) aplicar um AG para realizar a distribuição otimizada. A Figura 1 apresenta um diagrama da metodologia.




Fig. 1. Diagrama da execução do projeto

A. Coleta de Dados

A etapa inicial consistiu na coleta de dados históricos de vendas de veículos elétricos no Brasil entre janeiro de 2020 e dezembro de 2024, extraídos dos portais da ABVE [2] e da NeoCharge [15]. Como os dados de vendas estavam disponíveis apenas em formato visual (gráficos e tabelas em imagens), foram utilizadas ferramentas de inteligência artificial generativa, como o ChatGPT [19] e o Gemini [10], para a extração automatizada. O processo consistiu na submissão das imagens às IAs, que retornaram os dados em formato vetorial. Após isso, realizou-se uma validação cruzada manual, comparando os dados extraídos com os valores visuais nos portais de origem, assegurando a precisão nas informações utilizadas.

Para estimar a capacidade de atendimento de um eletroposto, adotou-se como base o relatório da *U.S. Department of Energy* [18], que recomenda o uso de três carregadores por estação: dois do tipo lento e um do tipo rápido. Além disso, tomou-se como base também a recomendação da União Europeia de no máximo 1 carregador a cada 10 veículos elétricos.

O mapa da cidade de Belo Horizonte, incluindo suas divisões regionais e os 653 pontos de interesse (POIs) identificados (Figura 2), foi elaborado utilizando informações do GeoServer da prefeitura [6] e dados da API do *OpenStreetMap* [20] obtidos via *Overpass Turbo* [23]. Além disso, com dados e mapa de desigualdades de BH de 2021 da *NossaBH* [17], foi coletada a renda média domiciliar das regiões da cidade,

para identificar as possivelmente mais lucrativas e com maior probabilidade de maior volume de veículos elétricos.




Fig. 2. Mapa de BH com suas regiões e os POIs obtidos (Cada círculo com um número representa um cluster de POIs próximos)

Os pontos de interesse foram definidos como as universidades, faculdades, postos de combustível, hospitais, shoppings e supermercados, por serem locais de grande circulação de automóveis na cidade e por proporcionarem um tempo de permanência de no mínimo 15 minutos [28].

Os custos de instalação e lucro gerados por um eletroposto foram estimados a partir de dados obtidos em uma notícia da GreenV [12], que informa que os custos de um eletroposto pequeno de carregadores lentos seria a partir de R\$ 50.000,00 e um maior com carregadores rápidos poderia ultrapassar os R\$ 300.000,00, sendo considerado para este trabalho R\$ 200.000,00 o custo base, uma média entre esses valores já que os eletropostos instalados nos POIs levam 1 carregador rápido e 2 lentos, e R\$ 50.000,00 os custos extras, representando os custos dos eletropostos adicionais a serem instalados no mesmo local aproveitando a base já construída. A mesma notícia recomenda também uma margem de 10% a 30% de lucro no preço do KWh vendido ao cliente final, sendo considerado R\$ 0,20 neste trabalho.

Outros importantes dados a serem considerados na modelagem são o raio de atendimento entre os eletropostos e a capacidade de cada tipo de POI. No presente trabalho utilizou-se um raio de 500 metros, conforme sugerido no artigo de [7], e as capacidades, como por exemplo 9 eletropostos para shoppings e faculdades e 2 para postos de combustível, foram tomadas como referência o mapa de carregadores de Amsterdam [5] e o de São Paulo [22], por serem duas cidades referência em infraestrutura de carregamento de veículos elétricos.

B. Modelagem Matemática

O problema de otimização busca maximizar uma métrica de lucro líquido ajustado. A formulação matemática é apresentada a seguir.

Conjuntos e Índices:

- $i, j \in N$: Conjunto de $N = 653$ pontos de interesse (POIs) candidatos.

Parâmetros Principais:

- C_i : Capacidade de eletropostos no POI i .
- D : Demanda anual total de eletropostos.
- $R_{\text{reg}(i)}$: Fator de renda da região do POI i .
- L : Lucro diário por eletroposto.
- C_b, C_e : Custos de instalação base e extra, respectivamente.
- P : Penalidade por sobreposição de atendimento (baseado na distância entre os eletropostos).

Variável de Decisão:

- $x_i \in \{0,1\}$: 1 se o POI i for selecionado, 0 caso contrário.

Função Objetivo:

$$\max \left(\left(\sum_{i=1}^N x_i C_i L R_{\text{reg}(i)} \right) \delta_d - \sum_{i=1}^N x_i (C_b + C_e (C_i - 1)) - P \sum_{i=1}^N \sum_{j>i}^N x_i x_j \gamma_{ij} \right) \quad (1)$$

Onde o lucro diário considerado é baseado na utilização de um eletroposto em sua capacidade máxima, 24 horas em todos os carregadores, e os custos são divididos em parcelas diárias em um total de 5 anos, representando uma provável vida útil de um eletroposto [31] e [27].

A função (1) maximiza o **lucro** (ponderado pelo fator de demanda δ_d), subtraindo os **custos** de instalação e a **penalidade** por sobreposição. O fator δ_d ajusta o resultado com base no desvio entre o total de eletropostos instalados ($B = \sum x_i C_i$) e a demanda D . O termo γ_{ij} é 1 se a distância d_{ij} for menor que o raio de 500 metros, e 0 caso contrário. A restrição principal é $x_i \in \{0,1\}$.

C. Modelagem de Previsão

A partir dos dados coletados, foram testados dois modelos estatísticos para prever a evolução da frota: regressão polinomial e ARIMA. A regressão polinomial foi escolhida por sua simplicidade e facilidade de implementação, sendo eficaz em capturar variações não lineares [32]. Esse modelo ajusta uma curva polinomial de grau $n \geq 2$ sobre os dados históricos, com o objetivo de projetar a evolução futura da série.

O modelo ARIMA, amplamente reconhecido por sua robustez em séries temporais, combina três componentes estatísticos [29]: a auto-regressão (AR ou p), a diferenciação para tornar a série estacionária (I ou d), e a média móvel (MA ou q). A estrutura ARIMA(p, d, q) permite capturar tanto padrões lineares quanto ruído aleatório, sendo adequada para séries com tendências e sazonalidade.

D. Avaliação dos Modelos

Ambos os modelos foram avaliados por meio de métricas clássicas de previsão: coeficiente de determinação (R^2), erro médio absoluto (MAE), erro percentual absoluto médio

(MAPE) e raiz do erro quadrático médio (RMSE) [29], [32], [34]. Além disso, a análise de *overfitting* foi realizada com base na diferença entre os erros de treino e teste, e pelo uso da métrica R^2 com validação cruzada (CV- R^2), utilizando validação *k-fold* [9] com $k = 5$ (padrão recomendado da função de validação cruzada via `scikit-learn`).

E. Otimização com Algoritmo Genético

Uma vez estimada a demanda futura, aplicou-se o Algoritmo Genético para otimizar a localização dos eletropostos. O AG é um algoritmo baseado nos princípios da evolução natural, como seleção, cruzamento (*crossover*) e mutação, e é reconhecido por sua eficácia em problemas de busca global com grandes espaços de solução [1].

Nessa implementação cada solução é representada computacionalmente por vetores binários indicando a alocação ou não de eletropostos em um POI, 0 representa a não alocação no POI da posição do vetor e 1 representa o contrário, exemplificado na Figura 3.

$$\begin{bmatrix} POI_1 & POI_2 & POI_3 & POI_4 & POI_5 & POI_6 & POI_7 \\ 0 & 1 & 0 & 1 & 0 & 1 & 0 \end{bmatrix}$$

Fig. 3. Cromossomo de uma solução, representando que os POIs 2, 4 e 6 foram alocados

A população inicial é composta por cromossomos, cada um deles representam uma solução aleatória que atende a demanda anual estimada, e a aptidão (*fitness*) de cada indivíduo é avaliada de acordo com o quão bem a solução atende à demanda de maneira eficiente, representado pela modelagem matemática apresentada anteriormente na sub-seção B.

IV. DESENVOLVIMENTO

O desenvolvimento do trabalho foi realizado na plataforma *Google Colab*, utilizando a linguagem *Python*. Para a execução do AG, empregou-se a biblioteca *PyGAD* [8]. As técnicas de previsão foram implementadas com auxílio da biblioteca *scikit-learn* [21], responsável pela regressão polinomial e pelas métricas de avaliação, e da *statsmodels* [26], utilizada na modelagem ARIMA. Adicionalmente, bibliotecas como *geopandas*, *folium* e *matplotlib* foram utilizadas para georreferenciamento, visualização interativa e geração de mapas, respectivamente.

A. Regressão Polinomial

O modelo de regressão polinomial foi construído a partir da regressão linear, com prévia transformação dos dados de entrada X (datas mensais) e saída Y (frota acumulada de veículos elétricos) para incluir termos polinomiais de graus variados. Os dados foram normalizados para garantir comparabilidade entre as variáveis. Foram testados os graus 2, 3, 4, 5 e 9, com avaliação por métricas de erro e análise de *overfitting*.

Apesar de apresentar métricas absolutas superiores (representando pior desempenho), o modelo de grau 2 foi o único que não evidenciou sobreajuste. Isso foi confirmado pelo valor elevado do R^2 com validação cruzada e pela proximidade entre

Tabela I
COMPARAÇÃO ENTRE GRAUS DA REGRESSÃO POLINOMIAL
(SUBCONJUNTO TESTE)

	Grau 2	Grau 3	Grau 4	Grau 5	Grau 9
MAE	202,10	192,56	126,76	135,46	59,09
MAPE	0,05	0,09	0,04	0,06	0,02
RMSE	260,55	228,58	149,41	152,70	65,97
R2	0,99	1,00	1,00	1,00	1,00
GAP jan/25	7%	1,62%	4%	2%	12%

a previsão para janeiro de 2025 e o valor real calculado a partir da soma dos dados da ABVE e NeoCharge. A Tabela II apresenta os valores relacionados à análise de *overfitting*.

A partir do grau 3, observa-se tendência de sobreajuste, agravando-se nos graus 5 e 9. Nesses casos, o R^2 com validação cruzada foi significativamente inferior ao R^2 de treino, com destaque para o grau 9, cujo valor negativo ($-100,24$) e previsão extremamente irreal para dezembro de 2035 (mais de 48 bilhões de veículos) evidenciam forte instabilidade do modelo.

Tabela II
ANÁLISE DE OVERFITTING – REGRESSÃO POLINOMIAL

	Grau 2	Grau 3	Grau 4	Grau 5	Grau 9
GAP MAE (%)	14,0	7,5	8,25	12,0	31,0
GAP MAPE (%)	16,0	21,0	12,0	25,0	28,0
GAP RMSE (%)	17,0	6,7	4,23	11,0	4,64
GAP R^2 (%)	0,3	0,0	0,01	0,01	0,00
CV- R^2	0,93	0,83	0,92	0,24	$-100,24$
Dez/35 (Previsão)	106.228	305.499	1.932.698	$-2.492.969$	48.617.141.100

B. ARIMA

Para o modelo ARIMA, foi necessário identificar os parâmetros ideais p , d e q para a configuração ARIMA(p , d , q). Inicialmente, o parâmetro d foi definido por meio da análise do gráfico de autocorrelação com diferentes ordens de diferenciação, conforme Figura 4. A segunda diferenciação (linha verde) demonstrou melhor capacidade de remover a tendência, tornando a série estacionária, resultando em $d = 2$.

Em seguida, o valor de q foi definido como 1, a partir do primeiro corte significativo (linha verde na defasagem 1 em relação a área de significância, representado pelo retângulo azul) observado no gráfico de autocorrelação, mostrado na Figura 4. O parâmetro p foi determinado pela análise do gráfico de autocorrelação parcial (PACF), mostrado na Figura 5, que indica correlação significativa apenas na defasagem 1. Dessa forma, a configuração final utilizada foi ARIMA(1, 2, 1).

C. Algoritmo Genético

Os parâmetros utilizados para a execução do AG pode ser conferido na Tabela III. As probabilidades de mutação e cruzamento são baseados em [7] e são comuns na literatura. O processo do AG é repetido iterativamente até atingir o número máximo de gerações. Durante cada uma das gerações são formados 99 filhos através do cruzamento para serem passados




Fig. 4. Gráfico de autocorrelação com diferentes diferenciações




Fig. 5. Gráfico PACF (autocorrelação parcial)

a próxima geração juntamente do melhor parente (*Elitismo*), totalizando assim 100 soluções por população.

Tabela III
PARÂMETROS UTILIZADOS NO AG

Parâmetro	Valor
Gerações	1000
Parentes para Cruzamento	20
Parentes para Elitismo	1
Soluções por População	100
Nº Genes	653 (POIs)
Probabilidade Mutação	5%
Probabilidade Cruzamento	80%

A seleção dos indivíduos para cruzamento e mutação foi realizada por meio do método da roleta, Figura 6, no qual cada cromossomo recebe uma probabilidade proporcional ao seu valor de *fitness*. Um sorteio é então executado repetidamente até que 20 indivíduos sejam selecionados para o cruzamento, este foi implementado com ponto de corte único, Figura 7, em que um índice aleatório é escolhido ao longo de um cromossomo para dividir dois parentes e recombinar suas partes, gerando um novo indivíduo (filho). A mutação adotou a abordagem randômica: caso o indivíduo seja selecionado, um de seus genes é escolhido aleatoriamente e seu valor é invertido (de 0 para 1 ou vice-versa).




Fig. 6. Roleta de indivíduos baseado em suas aptidões




Fig. 7. Cruzamento de corte único baseado em suas aptidões

V. RESULTADOS E DISCUSSÃO

A. Previsão de demanda

A execução dos modelos de previsão resultou em estimativas distintas, especialmente nas projeções de longo prazo. Em dezembro de 2035, por exemplo, a diferença entre os valores

previstos pelos modelos ARIMA e regressão polinomial (grau 2) foi de aproximadamente 10,4%, conforme Tabela IV. Considerando os objetivos de precisão preditiva e estabilidade em extrapolações temporais, optou-se pelo modelo com melhor desempenho nas métricas de avaliação, que apresentou resultados mais consistentes mesmo em horizontes temporais mais distantes. Nesse cenário, o ARIMA apresentou os melhores resultados em termos de MAE, MAPE, RMSE e R^2 , conforme mostrado na Tabela V.

Tabela IV
COMPARAÇÃO DE PREVISÕES ENTRE ARIMA E REGRESSÃO POLINOMIAL

	ARIMA (1,2,1)	Reg. Polinomial (Grau 2)
JAN/25	12.971	12.243
DEZ/25	19.327	16.087
DEZ/26	26.921	21.445
DEZ/35	95.270	106.228

Tabela V
COMPARAÇÃO DE MÉTRICAS DE DESEMPENHO ENTRE OS MODELOS

	ARIMA (1,2,1)	Reg. Polinomial (Grau 2)
MAE	97,68	202,10
MAPE	0,01	0,05
RMSE	137,95	260,55
R^2	0,99	0,99

As Figuras 8 e 9 ilustram visualmente a capacidade preditiva de cada modelo. A linha azul representa os dados históricos acumulados da frota elétrica, enquanto a linha vermelha indica os valores previstos. Observa-se que o ARIMA captura com maior precisão as tendências e a suavidade do crescimento, sem oscilações abruptas.




Fig. 8. Comparação entre dados reais e previsão do modelo ARIMA




Fig. 9. Comparação entre dados reais e previsão da regressão polinomial (grau 2)

Com base nas previsões do modelo ARIMA para os próximos 131 meses, foi possível estimar o número mínimo recomendado de eletropostos para atender à futura demanda da cidade de Belo Horizonte. O cálculo foi baseado na recomendação da União Europeia de, no máximo, um eletrocarregador para cada 10 veículos elétricos [25], assumindo que cada estação contará com três carregadores (sendo ao menos um do tipo rápido).

A Tabela VI apresenta o número estimado de carregadores e eletropostos necessários em diferentes marcos temporais.

É importante destacar que os modelos utilizados consideram apenas a tendência histórica de crescimento da frota,

Tabela VI
ESTIMATIVA DE INFRAESTRUTURA DE RECARGA PARA BELO HORIZONTE

	Carregadores	Tipo Rápido (33%)	Eletropostos
DEZ/25	1.933	637	644
DEZ/26	2.692	888	897
DEZ/35	9.527	3.143	3.175

desconsiderando choques externos como incentivos fiscais ou mudanças regulatórias.

B. Distribuição dos eletropostos

A execução do AG ocorreu com apenas as demandas de 2025 e 2026, isso se deve ao fato de que os pontos de interesse obtidos na coleta de dados representam apenas os locais da atualidade, o que causaria problemas na distribuição dos eletropostos em POIs que podem eventualmente sofrer alterações, como alteração de tamanho ou fechamento, e não contempla também os que poderão ser criados no futuro. Dessa forma seriam gerados resultados muito distantes da realidade para o caso de 2035.

Os resultados otimizados das datas previstas foram respectivamente, para dezembro de 2025 com estimativa de 644 eletropostos, 744 eletropostos foram instalados, 100 (15,5%) a mais, com um lucro diário de R\$ 154.930,73. Para dezembro de 2026 com estimativa de 897 eletropostos, 1.037 eletropostos foram instalados, 140 (15,6%) a mais, o lucro diário foi de R\$ 212.782,23. A convergência do algoritmo e a melhoria da aptidão (*fitness*) ao longo das gerações são ilustradas nas Figuras 10 e 11. Os números a mais de eletropostos nas duas execuções demonstram que existe um benefício em instalar cerca de 15% a mais que a demanda mínima prevista, pois o lucro obtido ultrapassa os custos e penalizações envolvidos no cálculo do *fitness*.




Fig. 10. Melhoria do *fitness* por geração - DEZ 2025




Fig. 11. Melhoria do *fitness* por geração - DEZ 2026

Na Tabela VII é possível observar a distribuição na alocação de pontos de interesse entre as diferentes regiões da cidade, juntamente do total de eletropostos que isso representa. Nas Figuras 12, 13 e 14 é possível visualizar uma comparação entre os mapas resultantes da distribuição dos eletropostos pelo AG e o atual estado da cidade. A tabela e as figuras demonstram um grande aumento no número de locais com carregadores principalmente nas regiões com maior renda, como o centro-sul, pampulha e hipercentro, porém ainda assim instalando em regiões com menor renda permitindo uma distribuição mais abrangente na cidade.

Tabela VII
ALOCÇÃO DE POIS E ELETROPOSTOS POR REGIÃO

Região	Disponíveis (POIs/Eletrop.)	Alocados 2025 (POIs/Eletrop.)	Alocados 2026 (POIs/Eletrop.)
CENTRO-SUL	148 / 641	59 / 269 (41,9%)	65 / 297 (46,3%)
PAMPULHA	92 / 422	29 / 131 (31,0%)	43 / 233 (55,2%)
HIPERCENTRO	22 / 115	8 / 46 (40,0%)	10 / 65 (56,5%)
OESTE	97 / 358	27 / 95 (26,5%)	42 / 144 (40,2%)
LESTE	76 / 283	23 / 75 (26,5%)	31 / 107 (37,8%)
NORDESTE	56 / 207	11 / 35 (16,9%)	19 / 79 (38,2%)
NOROESTE	70 / 240	15 / 45 (18,8%)	19 / 61 (25,4%)
VENDA NOVA	30 / 118	6 / 23 (19,5%)	8 / 30 (25,4%)
BARREIRO	46 / 164	7 / 19 (11,6%)	6 / 17 (10,4%)
NORTE	16 / 53	3 / 6 (11,3%)	2 / 4 (7,5%)
TOTAL	653 / 2601	188 / 744 (28,6%)	245 / 1037 (39,8%)




Fig. 12. POIs alocados - DEZ 2025




Fig. 13. POIs alocados - DEZ 2026

Faculdade Posto de Combustível Hospital Shopping
Supermercado

VI. CONCLUSÃO E TRABALHOS FUTUROS

A partir da análise dos resultados apresentados na Tabela VI, observa-se que a cidade de Belo Horizonte apresenta um déficit significativo de infraestrutura para recarga de veículos elétricos. Para janeiro de 2025, a previsão do modelo ARIMA



Fig. 14. Eletropostos atuais via PlugShare - MAIO 2025

aponta para uma frota de 12.971 VEs em Belo Horizonte (conforme Tabela IV). Aplicando a recomendação de 1 carregador para cada 10 veículos, a demanda estimada seria de aproximadamente 1.297 carregadores. Considerando estações com uma média de 3 carregadores cada, seriam necessários cerca de 432 eletropostos para atender a essa demanda projetada. Comparando com os dados atuais — 200 carregadores instalados, dos quais apenas 24 são do tipo rápido — verifica-se uma razão de 65 veículos por carregador, ultrapassando em mais de seis vezes a recomendação internacional de 10 para 1 [25], o que evidencia um **déficit superior a 80%** na infraestrutura atual.

Os resultados gerados na distribuição de eletropostos de acordo com as demandas previstas para dezembro de 2025 e 2026, Tabela VII e Figuras 12 e 13, reforçam a questão do déficit de infraestrutura da cidade e demonstram uma possível solução otimizada para atender as diferentes regiões de acordo com os seus respectivos fatores de renda populacional, priorizando dessa maneira locais com maior probabilidade de usuários de veículos elétricos.

A metodologia proposta, ao integrar modelos de previsão estatística com um AG para otimização geoespacial, mostrou-se eficaz na estimativa e alocação de eletropostos em cenários urbanos reais. O estudo também contribui metodologicamente ao demonstrar como modelos supervisionados e meta-heurísticas podem ser combinados de forma prática e reprodutível para apoiar decisões estratégicas em infraestrutura urbana inteligente.

Apesar dos resultados promissores, a abordagem atual considera apenas a tendência histórica da frota elétrica, desconsiderando variáveis exógenas como políticas públicas, investimentos privados e avanços tecnológicos. A título de exemplo, a tecnologia em desenvolvimento pela BYD — que promete tempos de recarga comparáveis aos de abastecimento convencional [24] — pode alterar significativamente a dinâmica da demanda por eletropostos.

Como trabalhos futuros sugere-se, para as previsões de demanda a expansão da base de dados com séries temporais mais longas e a incorporação de fatores externos à modelagem preditiva, e, para a distribuição geoespacial, o aprimoramento da função de custo e a exploração de formulações alternativas de otimização. Por exemplo, a aplicação de modelos de cobertura, como o *Maximal Covering Location Problem* (MCLP), poderia oferecer uma perspectiva diferente, focada em maximizar a área ou a demanda atendida, em vez de maximizar o lucro. Tais refinamentos poderiam permitir análises mais robustas e a geração de soluções potencialmente mais eficientes do ponto de vista do serviço ao usuário. A metodologia demonstrou flexibilidade e pode ser replicada em outros contextos urbanos, considerando particularidades locais, e servir como base para formulação de políticas públicas de expansão da infraestrutura elétrica veicular no Brasil.

REFERÊNCIAS

- [1] I. Abuiziah and N. Shakarneh, "A review of genetic algorithm optimization: Operations and applications to water pipeline systems,"

International Journal of Physical, Natural Science and Engineering, vol. 7, pp. 341–347, 12 2013.

- [2] ABVE, “Frotas - ABVE,” Associação Brasileira do Veículo Elétrico (ABVE). Disponível em: <https://abve.org.br/bi-frotas/>, 2024, acessado em: 6 de novembro de 2024.
- [3] M. Akbari, M. Brenna, and M. Longo, “Optimal locating of electric vehicle charging stations by application of genetic algorithm,” *Sustainability*, vol. 10, no. 4, 2018. [Online]. Available: <https://www.mdpi.com/2071-1050/10/4/1076>
- [4] ANP, “Anuário estatístico brasileiro do petróleo, gás natural e biocombustíveis 2024 – seção 3,” Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP). Disponível em: <https://www.gov.br/anp/pt-br/centrais-de-conteudo/publicacoes/anuario-estatistico/anuario-estatistico-brasileiro-do-petroleo-gas-natural-e-biocombustiveis-2024#Se%C3%A7%C3%A3o%203>, 2024, acessado em: 6 de novembro de 2024.
- [5] Chagemap, “Charging stations in amsterdam,” <https://chagemap.com/cities/amsterdam-NL>, 2025, acesso em: 15 maio 2025.
- [6] P. de Belo Horizonte, “Geoserver,” <https://geoservicos.pbh.gov.br/geoserver>, 2024, acessado em: 7 de abril de 2025.
- [7] D. Efthymiou, K. Chrysostomou, M. Morfoulaki, and G. Aifantopoulou, “Electric vehicles charging infrastructure location: a genetic algorithm approach,” *European Transport Research Review*, vol. 9, no. 2, p. 27, 2017. [Online]. Available: <https://doi.org/10.1007/s12544-017-0239-7>
- [8] A. F. Gad, “Pygad: An intuitive genetic algorithm python library,” *Multimedia tools and applications*, vol. 83, no. 20, pp. 58 029–58 042, 2024.
- [9] B. Ghogh and M. Crowley, “The theory behind overfitting, cross validation, regularization, bagging, and boosting: Tutorial,” arXiv:1905.12787 [stat.ML]. Disponível em: <https://arxiv.org/abs/1905.12787>, 2023, acessado em: 10 de abril de 2025.
- [10] Google DeepMind, “Gemini AI –Processamento de imagem e coleta de dados,” Disponível em: <https://gemini.google.com/>, 2024, utilizado para processamento de imagem na coleta de dados de um website. Acessado em: 6 de novembro de 2024.
- [11] Governo Federal, “Frota de veículos 2024 - Senatran,” Ministério dos Transportes — Governo Federal. Disponível em: <https://www.gov.br/transportes/pt-br/assuntos/transito/conteudo-senatran/frota-de-veiculos-2024>, 2024, acessado em: 6 de novembro de 2024.
- [12] GreenV. (2023) Como montar um eletroposto e os benefícios de investir em pontos de recarga. Acessado em: 2 de junho de 2025. [Online]. Available: <https://www.greenv.com.br/blog/como-montar-um-eletroposto-e-os-beneficios-de-investir-em-pontos-de-recarga/>
- [13] Jornal do Carro – Estadão, “Efeito dolphin: Preço dos carros elétricos caiu até R\$ 100 mil em 2023,” Disponível em: <https://jornaldocarro.estadao.com.br/carros/efeito-dolphin-precos-dos-carros-eletricos-caiu-ate-r-100-mil-em-2023/>, 2024, acessado em: 6 de novembro de 2024.
- [14] P. M. Lima, “Alocação ótima de estações de recarga de veículos elétricos,” Dissertação de Mestrado — Pontifícia Universidade Católica de Campinas (PUC-Campinas), Programa de Pós-Graduação em Gestão de Redes de Telecomunicações. Disponível em: https://repositorio.sis.puc-campinas.edu.br/bitstream/handle/123456789/16630/ceatec_ppggrt_me_Lima_PM.pdf, 2022, acessado em: 10 de abril de 2025.
- [15] NeoCharge, “Carros elétricos no brasil - neocharge,” Disponível em: <https://www.neocharge.com.br/carros-eletricos-brasil>, 2024, acessado em: 6 de novembro de 2024.
- [16] NeoCharge, “Diferença entre carro elétrico e carro a combustão interna,” Disponível em: <https://www.neocharge.com.br/tudo-sobre/carro-eletrico/diferenca-carro-eletrico-e-combustao>, 2025, acessado em: 6 de novembro de 2024.
- [17] NossaBH, “Mapa das desigualdades 2021,” NossaBH. Disponível em: <https://nossabh.org.br/uploads/2021/06/Mapa-das-desigualdades-da-RMBH-2021.pdf>, 2021, acessado em: 6 de março de 2025.
- [18] U. D. of Energy, “ZEV Ready Step 10: Complete Site Assessment and Design EVSE,” Disponível em: <https://www.energy.gov/femp/zev-ready-step-10-complete-site-assessment-and-design-evse>, 2025, acessado em: 7 de abril de 2025.
- [19] OpenAI, “ChatGPT - processamento de imagem e coleta de dados,” Disponível em: <https://chat.openai.com/>, 2024, utilizado para processamento de imagem na coleta de dados de um website. Acessado em: 6 de novembro de 2024.
- [20] OpenStreetMap contributors, “Planet dump retrieved from <https://planet.osm.org>,” <https://www.openstreetmap.org>, 2025.
- [21] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perot, and E. Duchesnay, “Scikit-learn: Machine learning in Python,” *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
- [22] PlugShare, “Charging stations in são paulo,” <https://www.plugshare.com/br>, 2025, acesso em: 10 maio 2025.
- [23] M. Raifer, “Overpass api,” <https://overpass-api.de>, 2025, acessado em: 7 de abril de 2025.
- [24] Reuters, “BYD lança tecnologia de bateria para carregar carro elétrico em apenas 5 minutos,” Disponível em: <https://www.infomoney.com.br/business/byd-lanca-tecnologia-de-bateria-para-carregar-carro-eletrico-em-apenas-5-minutos/>, 2025, acessado em: 7 de abril de 2025. Publicado em: *InfoMoney*.
- [25] H. Ritchie, “Which countries have ‘enough’ public chargers for electric cars?” *Sustainability by Numbers*. Disponível em: <https://www.sustainabilitybynumbers.com/p/public-ev-chargers>, 2023, acessado em: 7 de abril de 2025.
- [26] S. Seabold and J. Perktold, “Statsmodels: econometric and statistical modeling with python,” *SciPy*, vol. 7, no. 1, pp. 92–96, 2010.
- [27] S. G. H. Services. (n.d.) Ev chargers: What affects their lifespan and how to install one. Accessed: 2025-07-20. [Online]. Available: <https://sunglowinc.com/ev-chargers-what-affects-their-lifespan-and-how-to-install-one/>
- [28] Y. S. Silva and M. Mestria, “Algoritmos para o problema de localização de estações de carregamento de veículos elétricos,” *Revista Produção Online*, vol. 19, no. 1, pp. 290–320, mar 2019. [Online]. Available: <https://www.producaoonline.org.br/rpo/article/view/3324>
- [29] G. C. Slompo and G. C. Morettin, “Previsão por modelos de séries temporais do licenciamento de veículos elétricos no Brasil,” Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Produção) — Universidade Tecnológica Federal do Paraná (UTFPR), Câmpus Ponta Grossa. Disponível em: https://repositorio.sis.puc-campinas.edu.br/bitstream/handle/123456789/16630/ceatec_ppggrt_me_Lima_PM.pdf, 2021, acessado em: 31 de mar. de 2025.
- [30] X. Sun, Z. Li, X. Wang, and C. Li, “Technology development of electric vehicles: A review,” *Energies*, vol. 13, no. 1, p. 90, 2019.
- [31] U.S. Department of Energy, “Electric vehicle (ev) charger uptime reporting standards,” Disponível em: <https://afdc.energy.gov/laws/13085>, 2022, acessado em: 9 de abril de 2025.
- [32] G. L. Zan and M. A. Sellitto, “Técnicas de previsão de demanda: um estudo de caso triplo com dados de venda de materiais eletromecânicos,” *Revista Gestão da Produção Operações e Sistemas*, no. 3, pp. 95–106, set. 2007. [Online]. Available: <https://revista.feb.unesp.br/gepros/article/view/171>
- [33] G. Zhou, Z. Zhu, and S. Luo, “Location optimization of electric vehicle charging stations: Based on cost model and genetic algorithm,” *Energy*, vol. 247, p. 123437, 2022. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0360544222003401>
- [34] C. A. Zilli, L. F. P. Droubi, and N. Hochheim, “Regressão polinomial e redes neurais artificiais na avaliação de imóveis: um estudo de caso,” *Revista Valorem*, vol. 1, no. 1, p. 82–91, jun. 2022. [Online]. Available: <https://revistavalorem.com/index.php/home/article/view/3>