

LOCALIZAÇÃO DE PONTOS DE ABASTECIMENTO DE HIDROGÊNIO VERDE EM TERESINA-PI: UMA ABORDAGEM BASEADA EM GRAFOS COM VALIDAÇÃO POR HEURÍSTICA GULOSA E ALGORITMO GENÉTICO

Gustavo Soares Bezerra¹, Paulo Antônio L. de M. N. Lino¹, José Augusto Santos Costa², Renata da Conceição Rocha², Iulle de Macedo Guerra Neves¹, Mauro Antonio Guimarães Clark¹

¹ Universidade Estadual do Piauí (UESPI), Curso de Engenharia Elétrica, Teresina, Brasil (gustavobezerra@aluno.uespi.br)

² Universidade Estadual do Piauí (UESPI), Curso de Tecnologia em Energias Renováveis, Teresina, Brasil

Resumo: Este trabalho aborda a localização de postos de hidrogênio verde em Teresina por meio do Problema do Conjunto Dominante em grafos. Foram aplicados um algoritmo guloso e um algoritmo genético para identificar o menor conjunto de postos capaz de cobrir toda a rede dentro de uma distância máxima. Os resultados mostraram convergência entre os métodos, indicando robustez da solução e potencial de aplicação no planejamento urbano e energético.

Palavras-chave: Hidrogênio verde; Algoritmo genético; Conjunto dominante; Otimização; Planejamento urbano.

INTRODUÇÃO

A intensificação das mudanças climáticas e a necessidade de redução das emissões de gases de efeito estufa têm impulsionado, nas últimas décadas, a busca por alternativas energéticas mais sustentáveis. Nesse contexto, acordos internacionais como o Acordo de Paris reforçam o compromisso global com a redução das emissões de carbono e incentivam a adoção de tecnologias energéticas limpas.

Entre as alternativas propostas para a descarbonização do setor de transportes, o hidrogênio verde tem se destacado como uma solução promissora. Produzido a partir de fontes renováveis, esse combustível apresenta grande potencial para substituir combustíveis fósseis em diversas aplicações, contribuindo significativamente para a redução do impacto ambiental associado à mobilidade urbana (Nadaleti et al., 2022).

Apesar de suas vantagens, a viabilização dessa tecnologia depende diretamente do desenvolvimento de uma infraestrutura eficiente de distribuição e abastecimento. Um dos principais desafios nesse processo consiste em determinar a localização estratégica dos postos de abastecimento, de forma a garantir acesso adequado ao combustível

e, simultaneamente, minimizar os custos relacionados à instalação e operação dessas unidades.

Nesse cenário, técnicas de otimização e modelos matemáticos desempenham papel fundamental no planejamento da infraestrutura energética. Dentre esses modelos, destaca-se o Problema do Conjunto Dominante, oriundo da teoria dos grafos, que permite identificar subconjuntos mínimos de pontos capazes de cobrir toda a rede dentro de uma determinada distância (Zhou et al., 2021). Essa abordagem tem sido amplamente utilizada em problemas de localização de facilidades e planejamento urbano.

No estudo conduzido por Clark et al. (2025), o problema de localização dos postos de abastecimento foi abordado por meio de uma heurística gulosa aplicada ao Problema do Conjunto Dominante. Nessa abordagem, a cada iteração, seleciona-se o vértice que cobre o maior número de vértices ainda não dominados, resultando em soluções computacionalmente eficientes e viáveis para o conjunto de dados analisado. Entretanto, algoritmos gulosos possuem natureza determinística e podem apresentar limitações associadas à convergência para ótimos locais, uma vez que decisões tomadas em etapas iniciais influenciam



diretamente a qualidade da solução final (Nazaret et al., 2025).

Por outro lado, algoritmos genéticos pertencem à classe das metaheurísticas evolutivas e apresentam maior capacidade de exploração do espaço de soluções. Por meio de operadores como seleção, cruzamento e mutação, essas técnicas permitem a geração de novas combinações ao longo das gerações, aumentando a probabilidade de obtenção de soluções próximas do ótimo global (Goldberg, 1989). Essa característica torna os algoritmos genéticos particularmente adequados para problemas de otimização combinatória complexos (Kamran et al., 2023).

Diferentemente de abordagens tradicionais que buscam comparar o desempenho entre métodos, este trabalho adota uma perspectiva complementar. Em vez de estabelecer superioridade entre algoritmos, propõe-se a utilização conjunta de uma heurística gulosa e de um algoritmo genético como mecanismo de validação cruzada das soluções obtidas.

Assim, o objetivo deste estudo é analisar a robustez das soluções para o problema de localização de postos de hidrogênio verde na cidade de Teresina, investigando a convergência entre diferentes técnicas de otimização e discutindo o papel da estrutura espacial do problema na qualidade das soluções encontradas.

REFERENCIAL TEÓRICO

O desenvolvimento de soluções eficientes para o planejamento da infraestrutura de abastecimento de hidrogênio verde exige a integração de diferentes áreas do conhecimento, como transição energética, teoria dos grafos e otimização combinatória. Nesse contexto, torna-se necessário compreender não apenas a relevância do hidrogênio verde como alternativa sustentável, mas também os modelos matemáticos e computacionais capazes de auxiliar na tomada de decisão sobre a localização estratégica dos pontos de abastecimento.

Além disso, a escolha adequada de métodos de solução influencia diretamente a qualidade e a confiabilidade dos resultados obtidos. Técnicas heurísticas e metaheurísticas têm sido amplamente aplicadas em problemas de localização de facilidades, especialmente quando se trata de instâncias reais e de grande porte, nas quais métodos exatos apresentam elevada complexidade computacional.

Dessa forma, este referencial teórico aborda os principais conceitos que fundamentam este trabalho, incluindo o papel do hidrogênio verde no

planejamento energético, o Problema do Conjunto Dominante como modelo de cobertura em grafos, o funcionamento da heurística gulosa, a aplicação de algoritmos genéticos e a importância da verificação de consistência entre diferentes métodos de otimização.

• Hidrogênio verde e planejamento energético

O hidrogênio verde tem emergido como um dos principais vetores energéticos no contexto da transição para uma economia de baixo carbono. Diferentemente do hidrogênio convencional, produzido a partir de combustíveis fósseis, o hidrogênio verde é obtido por meio da eletrólise da água utilizando fontes renováveis, como energia solar e eólica, resultando em um processo com emissões praticamente nulas de carbono (Nadaleti et al., 2022).

Sua aplicação no setor de transportes é considerada estratégica, especialmente para segmentos de difícil eletrificação, como transporte pesado e de longa distância. Além disso, o hidrogênio pode ser armazenado e transportado, funcionando como um vetor energético complementar às fontes intermitentes (Lumbers et al., 2022).

No entanto, a adoção em larga escala dessa tecnologia depende fortemente da implantação de uma infraestrutura adequada de produção, armazenamento e distribuição. A localização dos postos de abastecimento desempenha papel central nesse processo, pois influencia diretamente fatores como custo logístico, acessibilidade e viabilidade econômica (Zhou et al., 2021; Li et al., 2020).

Problemas dessa natureza são frequentemente modelados como problemas de localização de facilidades (facility location problems), nos quais se busca determinar a melhor posição de instalações para atender uma determinada demanda. Esses problemas podem assumir diferentes formas, como p-mediana, cobertura máxima, conjunto dominante e localização de centros, dependendo dos objetivos e restrições considerados (Farahani et al., 2021).

• Problema do Conjunto Dominante

O Problema do Conjunto Dominante é um problema clássico da teoria dos grafos, com ampla aplicação em áreas como redes de comunicação, planejamento urbano, monitoramento de sistemas e localização de facilidades (Kaznatcheev et al., 2025).

Dado um grafo $G=(V,E)$, um conjunto dominante $D \subseteq V$ é definido como um subconjunto de vértices tal que todo vértice do grafo pertence a D ou é adjacente a pelo menos um vértice de D . O objetivo



é encontrar o menor conjunto dominante possível, caracterizando um problema de minimização.

Formalmente:

$$\min |D| \text{ sujeito a } \forall v \in V, v \in D \text{ ou } \exists u \in D \text{ tal que } (u, v) \in E$$

Esse problema é classificado como NP-difícil, o que implica que não existem algoritmos polinomiais conhecidos para sua resolução exata em todos os casos (Higl et al., 2026). Como consequência, abordagens heurísticas e metaheurísticas são frequentemente empregadas para lidar com instâncias de grande escala.

No contexto de localização de postos de abastecimento, o conjunto dominante pode ser interpretado como o conjunto mínimo de pontos capazes de garantir cobertura total de uma rede, considerando um raio máximo de atendimento. Essa modelagem permite transformar um problema geográfico contínuo em um problema discreto tratável computacionalmente.

- **Heurística Gulosa**

Algoritmos gulosos constituem uma classe de métodos heurísticos que constroem soluções de forma incremental, tomando decisões localmente ótimas a cada etapa (Cormen et al., 2009). No contexto do Problema do Conjunto Dominante, a abordagem gulosa consiste em selecionar iterativamente o vértice que maximiza o número de vértices ainda não cobertos.

Essa estratégia é particularmente atrativa devido à sua simplicidade de implementação e baixo custo computacional, sendo capaz de produzir soluções rapidamente, mesmo em instâncias de grande porte. Em muitos casos, heurísticas gulosas apresentam desempenho satisfatório, especialmente quando a estrutura do problema favorece decisões locais bem alinhadas com o ótimo global.

Entretanto, a principal limitação desses algoritmos reside no fato de que as decisões tomadas em etapas iniciais não são revisadas posteriormente. Isso pode levar a soluções subótimas, especialmente em problemas onde a escolha local não reflete a melhor estratégia global (García, 2025).

No contexto do conjunto dominante, estudos mostram que a heurística gulosa pode apresentar bons resultados em grafos densos ou altamente conectados, mas pode ter desempenho inferior em grafos esparsos ou com estrutura irregular (Li et al., 2020).

Apesar dessas limitações, algoritmos gulosos são frequentemente utilizados como baseline em estudos de otimização, servindo como referência para avaliação de métodos mais sofisticados.

- **Algoritmos Genéticos**

Os algoritmos genéticos são metaheurísticas baseadas nos princípios da seleção natural e da genética evolutiva (Goldberg, 1989). Nessa abordagem, um conjunto de soluções candidatas, denominado população, evolui ao longo de várias gerações, sendo submetido a operadores inspirados em processos biológicos, como seleção, cruzamento e mutação.

Cada solução é representada por um cromossomo, que codifica uma possível resposta para o problema. A qualidade de cada solução é avaliada por meio de uma função de aptidão (*fitness*), que orienta o processo evolutivo.

A principal vantagem dos algoritmos genéticos está na sua capacidade de realizar uma busca global no espaço de soluções, explorando múltiplas regiões simultaneamente. Isso reduz a probabilidade de convergência para ótimos locais, uma limitação comum em métodos determinísticos (Cervantes-Ojeda et al., 2023).

Além disso, algoritmos genéticos são altamente flexíveis e podem ser adaptados para diferentes tipos de problemas, incluindo aqueles com múltiplos objetivos, restrições complexas e espaços de busca não lineares (Dang et al., 2025).

No cenário do Problema do Conjunto Dominante, algoritmos genéticos têm sido utilizados para explorar combinações de vértices que dificilmente seriam alcançadas por heurísticas tradicionais, especialmente em instâncias de grande escala ou com múltiplos critérios (Cervantes-Ojeda et al., 2023).

No entanto, essa maior capacidade exploratória vem acompanhada de um custo computacional mais elevado, uma vez que múltiplas soluções são avaliadas ao longo de diversas gerações. Dessa forma, o uso de algoritmos genéticos deve ser cuidadosamente balanceado com os requisitos de tempo e complexidade do problema (Liu et al., 2025).

- **Verificação de consistência entre métodos**

Em problemas de otimização combinatória, a avaliação da qualidade de uma solução nem sempre é trivial, especialmente quando não se conhece a solução ótima global. Nesse contexto, a utilização de múltiplos métodos para resolver o mesmo problema pode fornecer evidências adicionais sobre a confiabilidade dos resultados.

A convergência de diferentes algoritmos para soluções semelhantes ou idênticas pode ser interpretada como um indicativo de robustez, sugerindo que a solução encontrada não é um artefato

específico de um método, mas sim uma característica estrutural do problema (Cervantes-Ojeda et al., 2023).

Essa abordagem, tem sido utilizada em diversas áreas da otimização para aumentar a confiança nos resultados obtidos, especialmente em aplicações práticas onde decisões são baseadas diretamente nas soluções encontradas.

No contexto deste trabalho, a utilização conjunta de uma heurística gulosa e de um algoritmo genético permite explorar tanto estratégias locais quanto globais de busca, proporcionando uma análise mais abrangente do espaço de soluções.

MATERIAIS E MÉTODOS

A metodologia adotada neste trabalho foi estruturada em etapas sequenciais, envolvendo a obtenção e tratamento da base de dados, a modelagem do problema e a aplicação dos algoritmos de solução. A Figura 1 apresenta o fluxo metodológico adotado neste estudo.



Figura 1: Fluxo metodológico.

• Base de dados

A base de dados utilizada neste estudo é composta pelas coordenadas geográficas (latitude e longitude) dos postos de abastecimento localizados no município de Teresina. Esses dados foram obtidos a partir de registros da relação oficial de postos de combustíveis disponibilizada pela Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP), obtida por meio do portal do Centro de Dados Públicos (CDP). A partir dessa fonte, foi reunida uma lista textual contendo nomes e endereços de aproximadamente 230 postos de abastecimento localizados no município de Teresina.

• Geocodificação dos endereços

Com o objetivo de converter os endereços coletados em coordenadas geográficas, foi desenvolvido um script em linguagem Python utilizando bibliotecas que acessam o serviço de geocodificação do

OpenStreetMap. Esse processo permitiu transformar cada endereço em um par de coordenadas geográficas, representado por latitude e longitude.

Durante essa etapa, foram realizados ajustes no código para lidar com divergências de formatação dos endereços, registros incompletos e retornos imprecisos da interface de programação de aplicações (API) utilizada pelo serviço de geocodificação. Esses ajustes foram necessários para melhorar a taxa de sucesso na obtenção das coordenadas corretas.

• Filtragem e tratamento dos dados

Após a obtenção das coordenadas geográficas, foi realizado um processo de limpeza e validação dos dados. Nessa etapa foram removidos:

- Registros duplicados;
- Coordenadas incorretas;
- Pontos localizados fora dos limites do município;
- Entradas inconsistentes ou repetidas.

Além disso, foi realizada uma reorganização geral da base de dados, incluindo a padronização das nomenclaturas e a verificação manual da localização de cada ponto.

Após as etapas de tratamento e filtragem dos dados, foi obtida uma base final contendo aproximadamente 230 postos válidos, representando a distribuição espacial dos estabelecimentos no município.

• Modelagem do problema

O problema de localização dos postos de abastecimento foi modelado como um grafo $G=(V,E)$ em que cada vértice $v \in V$ representa um posto de abastecimento. Uma aresta $(u,v) \in E$ é estabelecida entre dois vértices quando a distância entre os respectivos postos é menor ou igual a uma distância máxima de cobertura previamente definida.

Nesse contexto, busca-se encontrar um subconjunto mínimo de vértices capazes de cobrir todos os demais vértices do grafo. Esse problema é conhecido na teoria dos grafos como Problema do Conjunto Dominante.

• Algoritmo Guloso

O algoritmo guloso utilizado neste trabalho é uma abordagem heurística baseada na construção iterativa de soluções, tomando decisões locais com o objetivo de obter uma solução global eficiente. No contexto do Problema do Conjunto Dominante, o algoritmo busca selecionar, a cada passo, o vértice que maximize a cobertura dos vértices ainda não dominados.



Inicialmente, considera-se o conjunto de todos os vértices do grafo como não cobertos. Em seguida, o algoritmo seleciona iterativamente os vértices que possuem maior capacidade de cobertura, ou seja, aqueles que dominam o maior número de vértices ainda não atendidos. Após cada seleção, os vértices cobertos são removidos do conjunto de vértices não dominados, e o processo se repete até que todos os vértices do grafo estejam cobertos.

O Algoritmo 1 apresenta o pseudocódigo do algoritmo guloso utilizado neste trabalho.

Algoritmo 1 Algoritmo Guloso Genérico

```

1: Entrada: Conjunto de candidatos  $C$ , função objetivo  $f$ , critério de
   seleção  $s$ .
2: Saída: Conjunto solução  $S$  que maximiza/minimiza  $f$ .
3:  $S \leftarrow \emptyset$  (Inicializar conjunto solução vazio).
4: Ordenar os candidatos em  $C$  de forma decrescente com base no critério  $s$ .
5: Enquanto  $C \neq \emptyset$  e  $S$  não for uma solução completa faça:
6:   Escolher o melhor candidato  $x \in C$  (o primeiro da lista ordenada).
7:   Remover  $x$  de  $C$ .
8:   Se  $S \cup \{x\}$  é uma solução viável então:
9:      $S \leftarrow S \cup \{x\}$ .
10:  Fim Se
11: Fim Enquanto
12: Retornar  $S$ .
```

O algoritmo inicia com um conjunto vazio de vértices selecionados. A cada iteração, é escolhido o vértice que cobre o maior número de vértices ainda não dominados. Esse vértice é então adicionado ao conjunto dominante, e todos os vértices por ele cobertos são marcados como atendidos.

Esse processo continua de forma iterativa até que não existam mais vértices não cobertos. Ao final, obtém-se um conjunto dominante que garante a cobertura de toda a rede.

O critério utilizado para a escolha dos vértices baseia-se na maximização da cobertura local. Em cada etapa, é selecionado o vértice que domina o maior número de vértices ainda não cobertos, considerando tanto o próprio vértice quanto seus vizinhos no grafo. Essa estratégia permite reduzir rapidamente o número de vértices não dominados, conduzindo a uma solução eficiente em termos de cobertura.

A solução final é representada como um subconjunto de vértices do grafo, correspondente aos postos selecionados para compor o conjunto dominante. Esse conjunto garante que todos os demais vértices estejam cobertos direta ou indiretamente, de acordo com o raio de cobertura estabelecido.

- Algoritmo genético

O algoritmo genético utilizado neste trabalho é uma metaheurística inspirada no processo de evolução natural, amplamente empregada na resolução de problemas de otimização combinatória. Nesse método, cada solução candidata é representada por um indivíduo codificado como um vetor binário, no qual cada posição indica a seleção ou não de um

posto de abastecimento. Inicialmente, é gerada uma população de soluções aleatórias, que são avaliadas por meio de uma função de aptidão (*fitness*). Em seguida, o algoritmo evolui ao longo de várias gerações por meio da aplicação de operadores genéticos, como seleção, cruzamento e mutação, buscando soluções cada vez mais eficientes.

O Algoritmo 2 apresenta o pseudocódigo do algoritmo genético utilizado neste trabalho.

Algoritmo 2 Seleção Otimizada de Postos

```

1: Entrada: Grafo  $G(V,E)$ , tamanho da população  $N$ , número de
   gerações  $G_{max}$ , taxa de mutação  $p_m$ .
2: Saída: Melhor solução encontrada (conjunto dominante).
3: 1. Inicializar população  $P$  com  $N$  indivíduos aleatórios.
4: 2. Para cada indivíduo em  $P$ , calcular o fitness.
5: 3. Para  $t = 1$  até  $G_{max}$  faça:
6:   3.1 Selecionar indivíduos de  $P$  (seleção).
7:   3.2 Aplicar cruzamento para gerar descendentes.
8:   3.3 Aplicar mutação nos descendentes.
9:   3.4 Avaliar fitness dos novos indivíduos.
10:  3.5 Atualizar população  $P$  com os melhores indivíduos.
11: 4. Retornar o melhor indivíduo da população.
```

O algoritmo genético é uma técnica de otimização inspirada no processo de evolução natural, baseada em mecanismos como seleção, cruzamento e mutação. Nesse método, cada solução candidata é representada como um indivíduo de uma população, sendo avaliada por meio de uma função de aptidão (*fitness*), que mede a qualidade da solução.

Inicialmente, uma população de soluções é gerada aleatoriamente. Em seguida, ao longo de várias gerações, os indivíduos mais aptos são selecionados e combinados para gerar novas soluções, enquanto operadores de mutação introduzem diversidade na população. Esse processo iterativo permite que o algoritmo explore diferentes regiões do espaço de busca, aumentando a probabilidade de encontrar soluções próximas do ótimo global. No contexto deste trabalho, cada indivíduo é representado por um vetor binário que indica quais postos são selecionados. A função de fitness foi definida de forma a penalizar soluções que não cobrem todos os vértices, ao mesmo tempo em que minimiza o número de postos utilizados.

Cada indivíduo da população é representado por um vetor binário de tamanho n , onde n corresponde ao número total de postos considerados. Em cada posição do vetor:

- Valor **1** indica que o posto foi selecionado como ponto de abastecimento;
- Valor **0** indica que o posto não foi selecionado.

Essa representação permite codificar diferentes combinações possíveis de postos candidatos.

A função de *fitness* foi definida com o objetivo de minimizar o número de postos selecionados, garantindo simultaneamente a cobertura de todos os vértices do grafo. Para isso, foi adotada a função de avaliação descrita na Equação 1:

$$Fitness = (\text{postos não cobertos}) * 1000 + N(\text{postos selecionados}) \quad (1)$$

Essa formulação penaliza fortemente soluções que não garantem cobertura completa da rede, incentivando o algoritmo a buscar configurações viáveis com o menor número possível de postos.

Os principais parâmetros utilizados na execução do algoritmo genético foram: população de 200 indivíduos, 500 gerações, elitismo de 3 indivíduos, taxa de mutação 8% e taxa de cruzamento de 85%. Esses parâmetros foram definidos de forma experimental, buscando equilibrar a qualidade das soluções encontradas e o tempo de processamento necessário para a execução dos experimentos.

RESULTADOS E DISCUSSÃO

Com o objetivo de avaliar o desempenho da abordagem proposta, os resultados obtidos com o algoritmo genético foram comparados com aqueles produzidos pelo algoritmo guloso aplicado anteriormente ao mesmo problema. No estudo conduzido por Clark et al. (2025), o Problema do Conjunto Dominante foi utilizado para selecionar um conjunto mínimo de postos capazes de cobrir toda a rede de estabelecimentos da cidade de Teresina, utilizando uma heurística gulosa baseada na escolha iterativa do vértice com maior cobertura.

Para a realização dos experimentos computacionais, foi utilizada a base georreferenciada contendo 230 postos de abastecimento localizados no município de Teresina. Esses dados foram utilizados como entrada para a construção do grafo que representa a rede de postos analisada.

Os experimentos foram conduzidos conforme a Tabela 01 considerando diferentes valores para a distância máxima de cobertura entre os postos. Foram avaliados cinco cenários distintos:

Tabela 1: Comparação entre os algoritmos guloso e genético para diferentes raios de cobertura, considerando o número de postos selecionados, proporção e tempo de execução.

Algoritmo	Raio	Postos escolhidos	Conjunto Dominante	Proporção (%)	Tempo (s)
Guloso	10km	2	[68,152]	0,87%	0,04
Genético	10km	2	[68, 152]	0,87%	3,31
Guloso	7km	4	[11, 44, 124, 216]	1,73%	0,04
Genético	7km	4	[11, 44, 124, 216]	1,73%	3,17
Guloso	5km	5	[3,85,88,198,228]	2,17%	0,04
Genético	5km	5	[3, 85, 88, 198, 228]	2,17%	3,54
Guloso	3km	12	[0, 6, 40, 44, 45, 117, 135, 170, 213, 219, 220, 229]	5,21%	0,06
Genético	3km	12	[0, 6, 40, 44, 45, 117, 135, 170, 213, 219, 220, 229]	5,21%	3,59
Guloso	1km	47	[0, 3, 4, 5, 7, 11, 19, 21, 30, 41, 44, 46, 53, 58, 63, 73, 75, 76, 87, 88, 95, 99, 100, 110, 128, 134, 138, 146, 154, 156, 162, 170, 178, 183, 190, 197, 199, 205, 206, 207, 213, 216, 224, 225, 227, 228, 229]	20,43%	0,08
Genético	1km	47	[0, 3, 4, 5, 7, 11, 19, 21, 30, 41, 44, 46, 53, 58, 63, 73, 75, 76, 87, 88, 95, 99, 100, 110, 128, 134, 138, 146, 154, 156, 162, 170, 178, 183, 190, 197, 199, 205, 206, 207, 213, 216, 224, 225, 227, 228, 229]	20,43%	5,7

A partir dos dados obtidos, observa-se que os algoritmos Guloso e Genético apresentaram resultados idênticos em todas as instâncias analisadas. Para cada valor de raio considerado (10 km, 7 km, 5 km, 3 km e 1 km), ambos os métodos selecionaram exatamente: o mesmo número de postos; o mesmo conjunto dominante; a mesma proporção em relação ao total de postos

Essa coincidência de resultados indica que, apesar das diferenças nas abordagens, sendo o algoritmo guloso baseado em decisões locais imediatas e o algoritmo genético inspirado em processos evolutivos, ambos convergiram para a mesma solução para o problema proposto. Isso sugere que a solução encontrada é estável e consistente dentro do conjunto de dados utilizado,

podendo representar uma solução ótima ou muito próxima do ótimo global.

Outro ponto relevante é que essa equivalência se manteve em todos os cenários testados, independentemente do raio de cobertura. Isso reforça a ideia de que, para essa configuração específica do problema, não houve divergência entre os métodos quanto à qualidade da solução encontrada.

Além disso, os resultados evidenciam um comportamento esperado: à medida que o raio de cobertura diminui, aumenta a quantidade de postos necessários para cobrir toda a região, o que implica diretamente no crescimento do tamanho do conjunto dominante e, conseqüentemente, da proporção em relação ao total de postos disponíveis. Esse padrão confirma a coerência do modelo adotado e a correta implementação dos algoritmos.

Por fim, a análise demonstra que, embora os algoritmos utilizem estratégias distintas para explorar o espaço de soluções, ambos foram capazes de identificar exatamente as mesmas soluções para todas as instâncias avaliadas, evidenciando consistência nos resultados obtidos.

• Análise dos mapas gerados

Como os conjuntos de postos selecionados foram idênticos para ambos os algoritmos em todos os valores de raio analisados, os mapas correspondentes ao algoritmo guloso e ao algoritmo genético coincidem para cada cenário. Dessa forma, são apresentadas, em sequência, as Figuras 2 a 6, correspondentes aos mapas para os raios de 1 km, 3 km, 5 km, 7 km e 10 km, cada uma ilustrando um dos cenários analisados.




Figure 2: Distribuição espacial dos postos selecionados e áreas de cobertura para raio de 10 km utilizando o algoritmo guloso/algoritmo genético.




Figure 3: Distribuição espacial dos postos selecionados e áreas de cobertura para raio de 7 km utilizando o algoritmo guloso/algoritmo genético.




Figure 4: Distribuição espacial dos postos selecionados e áreas de cobertura para raio de 5 km utilizando o algoritmo guloso/algoritmo genético.




Figure 5: Distribuição espacial dos postos selecionados e áreas de cobertura para raio de 3 km utilizando o algoritmo guloso/algoritmo genético.




Figure 6: Distribuição espacial dos postos selecionados e áreas de cobertura para raio de 1 km utilizando o algoritmo guloso/algoritmo genético.

Ao analisar os diferentes cenários de raio de cobertura (10 km, 7 km, 5 km, 3 km e 1 km), observa-se um padrão claro tanto nos resultados numéricos quanto na distribuição espacial apresentada nos mapas. À medida que o raio diminui, há um aumento significativo no número de postos necessários para garantir a cobertura total da rede, passando de apenas 2 postos no cenário de 10 km para 47 postos no cenário de 1 km.

Nos cenários com raios maiores, como 10 km e 7 km, os mapas evidenciam que poucos postos são suficientes para cobrir praticamente toda a área urbana. Os círculos de cobertura são amplos e apresentam grande sobreposição, abrangendo tanto regiões centrais quanto periféricas. Os pontos selecionados tendem a ocupar posições estratégicas, permitindo que grandes porções da cidade sejam atendidas simultaneamente.

À medida que o raio é reduzido para valores intermediários, como 5 km e 3 km, observa-se nos mapas uma maior dispersão dos postos selecionados. As áreas de cobertura tornam-se menores, o que reduz a sobreposição entre os círculos e exige uma distribuição mais equilibrada dos pontos ao longo da cidade. Nesse estágio, já é possível identificar uma divisão mais clara do espaço urbano em regiões de cobertura, com cada posto atendendo áreas mais específicas.

No cenário mais restritivo, com raio de 1 km, os mapas mostram uma alta densidade de postos selecionados, concentrados principalmente nas regiões com maior número de estabelecimentos. As áreas de cobertura são bastante reduzidas e praticamente não apresentam sobreposição significativa, o que exige uma distribuição muito mais granular para garantir que todos os vértices do grafo sejam dominados.

Além disso, em todos os cenários analisados, verifica-se que os algoritmos guloso e genético produziram exatamente os mesmos conjuntos dominantes, tanto em termos de quantidade quanto na escolha dos postos. Essa coincidência reforça a consistência das soluções encontradas e indica que, para a base de dados considerada, ambos os métodos convergiram para a mesma configuração de cobertura.

CONCLUSÃO

Os resultados obtidos indicam que é possível garantir a cobertura total da rede com um número reduzido de postos, especialmente nos cenários com maior raio de cobertura. Para o raio de 10 km, apenas dois postos (0,87% do total) foram suficientes para cobrir toda a rede, enquanto para 7 km foram necessários quatro postos (1,73%) e, para 5 km, cinco postos (2,17%). À medida que o raio diminui, observa-se um aumento mais acentuado na quantidade de postos selecionados, chegando a 12 postos (5,21%) para 3 km e 47 postos (20,43%) para 1 km, evidenciando a influência direta da distância de cobertura na configuração das soluções.

A comparação entre os algoritmos revelou que ambos foram capazes de encontrar soluções equivalentes nos cenários analisados, tanto em termos do número de postos selecionados quanto na composição dos conjuntos dominantes. No entanto, o algoritmo guloso apresentou desempenho computacional superior, com tempos de execução significativamente menores, o que o torna uma alternativa eficiente para aplicações práticas com características semelhantes.

Por outro lado, o algoritmo genético, apesar de apresentar maior custo computacional, destaca-se pela sua capacidade de explorar o espaço de soluções de forma mais ampla, sendo particularmente promissor para extensões do problema que envolvam múltiplas restrições, objetivos adicionais ou maior complexidade estrutural.

Adicionalmente, a análise espacial por meio dos mapas gerados permitiu validar visualmente a eficiência das soluções, evidenciando a relação entre o raio de cobertura e a distribuição dos postos selecionados. Essa abordagem integrada reforça a aplicabilidade do modelo como ferramenta de apoio ao planejamento urbano e energético.

Dessa forma, conclui-se que a modelagem baseada em grafos, aliada a técnicas de otimização, constitui uma estratégia eficaz para o planejamento da infraestrutura de hidrogênio verde, contribuindo para o desenvolvimento de soluções sustentáveis e eficientes no contexto da transição energética.



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

- CERVANTES-OJEDA, Jorge; GÓMEZ-FUENTES, María C.; FRESÁN-FIGUEROA, Julian A. Applying genetic algorithms to validate a conjecture in graph theory: the minimum dominating set problem. **Computación y Sistemas**, v. 27, n. 4, p. 1089-1097, 2023.
- CORMEN, Thomas H.; LEISERSON, Charles E.; RIVEST, Ronald L.; STEIN, Clifford. Introduction to Algorithms. 3. ed. Cambridge: MIT Press, 2009.
- CLARK, Mauro Antônio Guimarães; NEVES, Iulle de Macedo Guerra; COSTA, José Augusto Santos; ROCHA, Renata da Conceição; LINO, Paulo Antônio L. de M. N.; BEZERRA, Gustavo Soares. Otimização da localização de pontos de abastecimento de hidrogênio verde utilizando o problema do conjunto dominante. In: Congresso Internacional Ciência e Sociedade (2. CICS), 2025, Teresina. **Anais [...]**. Teresina: UNIFSA, 2025.
- DANG, Qianlong; HONG, Xinkang; SUN, Xianpeng. A dynamic tri-stage framework with neural network-assisted search for constrained multi-objective optimization. **Expert Systems with Applications**, v. 267, p. 126202, 2025.
- GARCÍA, Andrea. Greedy algorithms: a review and open problems. **Journal of Inequalities and Applications**, v. 2025, n. 1, p. 11, 2025.
- GOLDBERG, David E. **Genetic Algorithms in Search, Optimization, and Machine Learning**. Redig. Mass.: Addison-Wesley, 1989.
- HIGL, Hendrik. Analysis of a random local search algorithm for dominating set. **arXiv preprint arXiv:2601.11841**, 2026.
- KAMRAN, M.; RAUGEI, M.; HUTCHINSON, A. Elementos críticos para uma transição energética bem-sucedida: uma revisão sistemática. **Renewable and Sustainable Energy Transition**, v. 4, p. 100068, 2023.
- KAZNATCHEEV, Artem. Non-greedy local search can solve uniquely oriented valued constraint satisfaction problems in polynomial time. **arXiv preprint arXiv:2505.12345**, 2025.
- KAZNATCHEEV, Artem; ALFEREZ, Sofia Vazquez. Greed is slow on sparse graphs of oriented valued constraints. **arXiv preprint arXiv:2506.11662**, 2025.
- LI, Jonathan; POTRU, Rohan; SHAHROKHI, Farhad. A performance study of some approximation algorithms for computing a small dominating set in a graph. **Algorithms**, v. 13, n. 12, p. 339, 2020.
- LIU, Kejia; TENG, Yiping; LIU, Fang. A study of gene expression programming algorithm for dynamically adjusting the parameters of genetic operators. **PLoS ONE**, v. 20, n. 6, p. e0321711, 2025.
- LUMBERS, B.; BARLEY, J.; PLATTE, F. Low-emission hydrogen production via the thermocatalytic decomposition of methane for the decarbonisation of iron ore mines in Western Australia. **International Journal of Hydrogen Energy**, v. 47, n. 37, p. 16347-16361, 2022.
- NADALETI, Willian César; DE SOUZA, Eduarda Gomes; LOURENÇO, Vitor Alves. Green hydrogen pathways and alternatives: towards renewable energy transition in South American regions – Part B. **International Journal of Hydrogen Energy**, v. 47, n. 1, p. 1-15, 2022.
- NAZARET, Achille; BLEI, David. Extremely greedy equivalence search. **arXiv preprint arXiv:2502.19551**, 2025.
- ZHOU, J.; WU, Y.; TAO, Y.; GAO, J.; ZHONG, Z.; XU, C. Geographic information big data-driven two-stage optimization model for location decision of hydrogen refueling stations: an empirical study in China. **Energy**, v. 225, p. 120330, 2021.