

Redução de Qubits em QUBO para o EA-VRP via Agrupamento Geográfico de Passageiros

Clovis Caface e Raphael Camargo

Resumo—Este trabalho apresenta uma abordagem para o Electric Autonomous Vehicle Routing Problem, visando reduzir o número de qubits necessários na aplicação do Quantum Approximate Optimization Algorithm. Para isso, propõe-se o agrupamento geográfico de 1 a 5 passageiros, gerando micro-rotas pick-and-drop e formulando o problema em Quadratic Unconstrained Binary Optimization. Os resultados de simulações indicam redução média de 75% no uso de qubits, aumento da executabilidade e proximidade entre custos clássicos e quânticos, mantendo interpretabilidade e aplicabilidade em dispositivos NISQ.

Palavras-Chave—Veículos elétricos autônomos, Quantum Unconstrained Binary Optimization, QAOA, agrupamento geográfico, otimização quântica. NISQ.

Abstract—This research presents an approach to the Electric Autonomous Vehicle Routing Problem, aiming to reduce the number of qubits required in the application of the Quantum Approximate Optimization Algorithm. To achieve this, we propose the geographic clustering of 1 to 5 passengers, generating pick-and-drop micro-routes and formulating the problem as a Quadratic Unconstrained Binary Optimization. Simulation results indicate an average reduction of 75% in qubit usage, improved executability, and close proximity between classical and quantum costs, while maintaining interpretability and applicability in NISQ devices.

Keywords—Electric Autonomous Vehicle, Quadratic Unconstrained Binary Optimization, Quantum Approximate Optimization Algorithm, geographic clustering, quantum optimization, NISQ.

I. INTRODUÇÃO

Serviços de mobilidade sob demanda (MoD), como aplicativos de transporte tipo Uber e afins, vêm apresentando um rápido crescimento de usuários e a introdução de veículo elétricos autônomos trará vantagens importantes [1] futuramente.

O problema central na operação de frotas por mobilidade elétrica autônoma sob demanda (E-AMoD) assemelha-se a um Problema de Roteamento de Veículos (VRP) tradicional [2], [3], em que é necessário encontrar rotas ótimas para atender pedidos de viagem com uma frota limitada de veículos, considerando restrições como capacidade, janelas de tempo e necessidade de recarga de baterias.

Sabe-se que o VRP e suas variantes, por exemplo, VRP capacitado [4], heterogêneo [5], com janelas de tempo [6], pertencem à classe NP-difícil [7], o que implica complexidade combinatória à medida que o número de viagens e veículos cresce. Além disso, no contexto de E-AMoD, políticas de compartilhamento de viagens têm sido exploradas para

aumentar a eficiência, permitindo que vários usuários sejam transportados simultaneamente se tiverem rotas compatíveis. Estudos recentes demonstram ganhos substanciais com o compartilhamento – por exemplo, Paparella e colaboradores (2025) [8] relataram redução de até 45% no tempo total de viagem dos veículos ao agrupar usuários em viagens compartilhadas. Esses resultados evidenciam o potencial de agrupamento de usuários para melhorar a eficiência de sistemas E-AMoD, embora também aumentem a complexidade do problema de roteamento subjacente.

Neste trabalho, focamos no Problema de Roteamento de Veículos Autônomos Elétricos (EA-VRP), no qual uma frota de veículos elétricos autônomos parte e retorna a um depósito para atender demandas com origem e destino conhecidos. O objetivo é minimizar um custo operacional, tais como distância, tempo ou energia, respeitando que cada solicitação seja atendida exatamente uma vez e que os veículos operem sob limitações de bateria, definido como estado de carga (*SoC*), com possibilidade de paradas em pontos de recarga. Em relação ao VRP tradicional, o EA-VRP adiciona decisões de quando ou onde recarregar e restrições de autonomia, aumentando a complexidade prática do problema e motivando abordagens de redução do espaço de decisão.

Paralelamente, a computação quântica tem se destacado como uma abordagem promissora para resolver problemas de otimização combinatória de forma mais eficiente que os algoritmos clássicos [9], [10]. Em particular, algoritmos quânticos adiabáticos, como o quantum annealing [11], e algoritmos híbrido clássico-quânticos para otimização aproximada, como o algoritmo de otimização aproximada quântica (QAOA) [12], requerem que o problema seja formulado como um Hamiltoniano Ising ou, de forma equivalente, como um problema de Otimização Quadrática Binária Não Restrita (QUBO) [13]. Essa modelagem consiste em definir variáveis binárias que representam as decisões de roteamento, como por exemplo, se um veículo v visita ou não um determinado nó i em uma posição j na rota, e construir uma função objetivo quadrática cujos mínimos correspondam às soluções viáveis ótimas do VRP.

Conforme descrito por Lucas (2014) [14], é possível mapear muitos problemas NP-difíceis para a forma de Ising/QUBO, embora às custas de um aumento polinomial no número de variáveis binárias necessárias. No caso de um problema de rotas, a formulação QUBO típica utiliza uma codificação one-

hot¹ que indica a ordem de visita às localidades, resultando em $O(N^2)$ variáveis binárias para um problema com N destinos (ou $O(k, N^2)$ quando considerados k veículos) [13]. Assim, modelos VRP com dezenas de clientes podem facilmente exigir centenas ou milhares de qubits na representação QUBO [7]. Embora mapeamentos válidos, esses tamanhos excedem em muito as capacidades dos dispositivos quânticos atuais.

A tecnologia quântica disponível ainda é limitada tanto em quantidade de qubits quanto em conectividade e fidelidade dos mesmos [15], [16], [17]. Logo, a aplicação direta de formulações QUBO de grande porte depara-se na impossibilidade prática de acomodar todas as variáveis no hardware quântico presente. Diante disso, surge a necessidade de técnicas que reduzam a quantidade de qubits requerida nas formulações, mantendo ao mesmo tempo a qualidade da solução obtida próximo do ótimo global.

Como EA-VRP trata-se de um problema combinatório de alta complexidade, com espaço de busca exponencial, que na prática, empregam-se métodos exatos apenas para instâncias pequenas e métodos de heurísticas ou meta-heurísticas para casos maiores. Neste trabalho, propomos uma formulação em QUBO e a aplicação do QAOA, mas com um passo essencial: agrupamos de 1 à 5 passageiros por proximidade geográfica para reduzir o espaço de decisão e, conseqüentemente, o número de qubits, inspirados em Paparella et al. [8]. Esse agrupamento preserva interpretabilidade nos grupos, como micro-rotas *pick-and-drop*, buscando manter a viabilidade em simulação ou execução sob orçamento restrito de qubits.

Em resumo, esse estudo busca contribuir com: (i) Uma formulação do EA-VRP agrupado em QUBO, com verificação preliminar de executabilidade; (ii) um protocolo de paridade que compara métodos clássico e quântico no mesmo modelador QUBO; (iii) evidência empírica de que o agrupamento reduz em média $\sim 75\%$ os qubits e eleva a executabilidade; e (iv) análise e discussão sobre como parâmetros, tais como n° de passageiros, veículos e agrupamento, impactam o tamanho do modelo.

II. METODOLOGIA

Todos os experimentos deste trabalho foram conduzidos em um computador com processador *Intel Core i7-1255U* (12ª geração), 16GB de RAM e sistema operacional Ubuntu 24.04LTS.

A. Visão geral

Foi proposto resolver o E-AMoD via otimização quântica sobre um espaço de decisões reduzido por **agrupamento de passageiros** (1–5 passageiro por grupo). Grupos são formados por proximidade geográfica, raio δ , e encadeados por uma heurística *pick-and-drop* do tipo vizinho mais próximo. O problema agrupado é modelado em QUBO e otimizado com QAOA; em paralelo, executamos um solver clássico sobre o mesmo QUBO para paridade clássico×quântico.

¹Codificação *one-hot* é uma técnica de representação em que cada categoria é associada a um vetor binário, no qual apenas uma posição é ativada (valor 1) e todas as demais são desativadas (valor 0), identificando de forma exclusiva cada classe.

B. Geração de instâncias e viabilidade

As instâncias são sintetizadas a partir de quantidade de passageiro N_{pass} , quantidade de depósitos N_{depots} (ou pontos geográficos de espera dos veículos), quantidade de pontos de recargas N_{chargers} e quantidade de veículos N_{veh} . Para maximizar a taxa de instâncias executáveis com orçamento limitado de qubits, foi aplicado um *viés* geométrico que contrai origens/destinos e pontos de recarga em torno do depósito. Antes de rodar qualquer solver, realizamos um *pré-flight*: seguimos apenas se o QUBO for menor ou igual 12 qubits, determinado pelo limite de hardware.

C. Agrupamento e custo intragrupo (*pick-and-drop*)

a) *Formação de grupos*: anexamos vizinhos dentro do raio δ de até um máximo $k_{\text{max}} = 5$ passageiros. Com estrutura de busca espacial é $O(N \log N)$; sem a estrutura de busca espacial, $O(N^2)$.

b) *Sequenciamento intra-grupo*: para $G = \{p_1, \dots, p_k\}$, ordenamos passageiros por vizinhança, iniciando no passageiro mais próximo do depósito. O custo de rota intra-grupo é

$$C(G) = d(D, o(p_1)) + \sum_{j=1}^{k-1} d(d(p_j), o(p_{j+1})) + d(d(p_k), D), \quad (1)$$

onde $o(\cdot)$ e $d(\cdot)$ são origem e destino, e D é o depósito. O custo veículo–grupo agrega $C(G)$ e, se aplicável, penalizações de autonomia. Para estações, usamos $c_{v,r}^R = d(D, R_r) + d(R_r, D)$.

D. Formulação QUBO

a) *Variáveis*: $y_{v,g} \in \{0, 1\}$ indica se o veículo v atende o grupo g ; $z_{v,r} \in \{0, 1\}$ indica uso de estação r (no máx. uma por veículo).

b) *Objetivo*:

$$\min_{y,z} \sum_v \sum_g c_{v,g}^G y_{v,g} + \sum_v \sum_r c_{v,r}^R z_{v,r} + \text{Penalidades}. \quad (2)$$

c) *Restrições (penalidades)*:

- 1) Cada grupo atendido exatamente uma vez: $\forall g : (\sum_v y_{v,g} - 1)^2$ com peso λ_1 .
- 2) Cada veículo atende no máximo um grupo: $\forall v : \sum_g y_{v,g} + 2 \sum_{g < g'} y_{v,g} y_{v,g'}$ com λ_2 .
- 3) No máximo uma estação por veículo: $\forall v : \sum_r z_{v,r} + 2 \sum_{r < r'} z_{v,r} z_{v,r'}$ com λ_3 .
- 4) Autonomia/energia: violações do limiar τ são penalizadas por λ_4 .

E. Método de Otimização e parâmetros

Clássico: foi utilizado `ExactSolver` quando o número de variáveis é pequeno; acima do limiar, foi empregado `Simulated Annealing`, 5000 leituras, como heurística. O custo é retornado por `encoder.cost (bits)`; há *fallback* por energia menos *offset* quando apropriado.

QAOA: Utilizando a biblioteca `Pennylane` com camadas $p = 1$, $steps = 80$, $shots = 1000$ e otimizador `COBYLA`

(`maxiter = 500`), e dispositivo `lightning.qubit`. Uma verificação preliminar de executabilidade rejeita instâncias com mais de 12 qubits.

F. Protocolo experimental

Variamos a quantidade de passageiros $N_{pass} \in \{5, 6, 8, 10\}$, a quantidade de veículos $N_{veh} \in \{1, 2\}$, mantemos a quantidade de depósitos $N_{dep} = 1$ e recargas $N_{rec} \in \{0, 1\}$. Agrupamos passageiros próximos em grupos de até 5, com raio δ adaptado à concentração de passageiros. Para cada cenário, medimos nº de qubits, executabilidade, custo, $\Delta\%$ clássico \times quântico no mesmo problema agrupado, tempo e taxa de soluções válidas, diferenças até 3% são tratadas como empate.

G. Escolha de hiperparâmetros

Adotamos $p = 1$ por limite de qubits/tempo e estabilidade; $p = 2$ é usado em experimentos de remoção de componentes pontuais [18]. Foram testados de 50 a 100 passos, incremento de 10, e adotado 80 passos de otimização por boa convergência em validações preliminares; 1024 *shots* reduzem variância sem tempo excessivo [19]. Em hardware real, *shots* podem ser elevados conforme disponibilidade.

H. Experimento sem agrupamento

Para isolar o efeito do agrupamento, executamos, quando viável, a mesma linha de execução *sem* agrupar. Como o número de qubits cresce substancialmente, muitas instâncias não passam na verificação preliminar de executabilidade; reportamos então apenas os casos que cabem no limite, de até 12–15 qubits, comparando número qubits, executabilidade, tempos e custo. A expectativa, evidenciada nos dados, é pior executabilidade e maior tempo sem agrupamento, confirmando o papel do agrupamento em viabilizar a simulação quântica.

I. Complexidade

Agrupamento $O(N \log N)$ (ou $O(N^2)$ sem índice); intra-grupo $O(k^2)$, $k \leq 5$; montagem do QUBO $O(VG + VR)$; custo do QAOA proporcional a $shots \times steps \times p$ e ao número de qubits, o que justifica a redução via agrupamento.

III. RESULTADOS

Sem esgotar a capacidade de atendimento por veículo, ($G = \lceil N_{pass}/k_{max} \rceil$, k_{max} sendo a quantidade máxima de passageiros por grupo), o tamanho do QUBO cresce como $q_{com} \approx V \cdot \lceil N_{pass}/k_{max} \rceil + V \cdot R$, ao passo que, sem agrupamento, $q_{sem} \approx V \cdot N_{pass} + V \cdot R$. Com a restrição $G \leq V$, há dois regimes: (i) crescimento até $N_{pass} \approx V k_{max}$; (ii) *platô* em $q \approx V^2 + VR$.

A Figura 1 apresenta a relação entre o número de passageiros (N_{pass}) e a quantidade de qubits (*#Qubits*) necessários para a execução do modelo computacional, comparando os cenários com e sem o agrupamento de passageiros, considerando inicialmente $V = 2$ veículos. Observa-se que, ao aumentar V , o ponto de saturação desloca-se para a direita. Além disso,

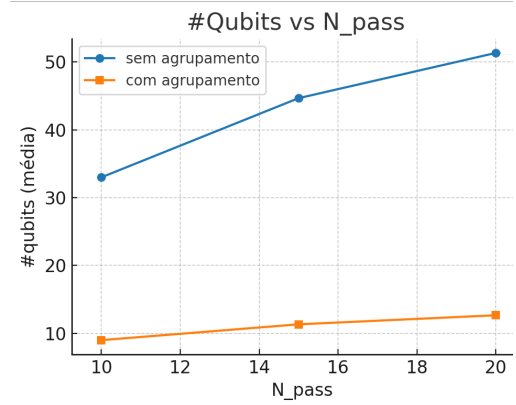


Fig. 1. Relação entre o número de passageiros (N_{pass}) e a quantidade de qubits necessários (*#qubits*) para o modelo, nos cenários com e sem agrupamento de passageiros, considerando $V = 2$ veículos. **Fonte:** Própria, 2025.

aumentar k_{max} , permitindo a formação de grupos maiores, ou ampliar o raio δ , possibilitando a inclusão de passageiros mais distantes em um mesmo grupo, favorece o agrupamento e, portanto, reduz a quantidade de qubits necessária. Por outro lado, reduzir k_{max} ou δ produz o efeito oposto, desfavorecendo o agrupamento e elevando a demanda de qubits. Em média, verificou-se uma redução de aproximadamente 75% no número de qubits quando o agrupamento é aplicado. Tal comportamento é corroborado pela Figura 2, que evidencia a relação entre o número médio de qubits requeridos e a variação no número de passageiros, veículos, depósitos e pontos de recarga considerados na formulação do QUBO, sem a restrição de execução no hardware disponível. Nota-se que, na ausência de agrupamento (curva em azul), o crescimento do número de qubits é acentuado, refletindo diretamente a complexidade combinatória do problema. Em contraste, quando o agrupamento é aplicado (curva em laranja), a taxa de crescimento apresenta-se menos abrupta, indicando que o procedimento de agrupamento atua como um mecanismo de controle da escalabilidade do modelo, aliviando a expansão do espaço quântico requerido para a resolução do problema.

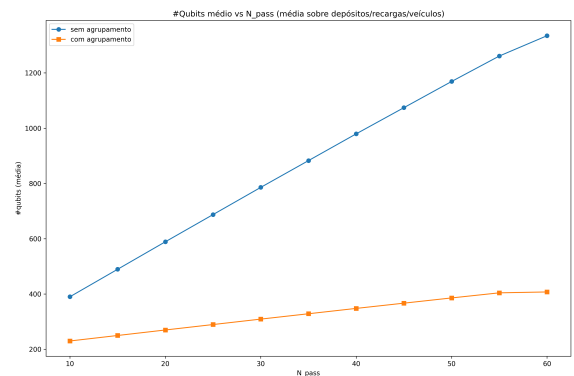


Fig. 2. Crescimento do número médio de qubits em função da quantidade de passageiros, veículos, depósitos e pontos de recarga, sem restrição de executabilidade. Sem agrupamento (azul) observa-se crescimento acentuado, enquanto o agrupamento (laranja) atenua essa expansão, controlando a escalabilidade do modelo. **Fonte:** Própria, 2025.

Essa análise demonstra como o agrupamento pode reduzir

significativamente os recursos quânticos exigidos, tornando a implementação mais viável em hardware real, ou permitindo que mais instâncias permaneçam dentro do limite de executabilidade.




Fig. 3. Histograma do número de amostras (shots) por estado quântico viável para o EA-VRP com $N_{\text{pass}} = 10$, $V = 8$, $R = 1$, $D = 1$. Em vermelho, o primeiro estado viável de menor custo. **Fonte:** Própria, 2025.

Considerando $N_{\text{pass}} = 10$, $V = 8$, $R = 1$ e $D = 1$, a Figura 3 apresenta, em um histograma, quantas vezes cada *bitstring* foi medido. Esses *bitstrings* são posteriormente avaliados: alguns violam restrições e outros se mostram viáveis segundo a função objetivo com penalidades. A barra em vermelho evidencia o primeiro *bitstring* que decodifica para a solução viável de menor custo entre as observadas. Todas as análises foram feitas em ambiente de simulação sem ruído.




Fig. 4. Grafo de uma instância representativa. Em amarelo o depósito, em azul claro as origens, em verde claro os destinos dos passageiros, em azul a origem e em verde o destino dos grupos, as recargas em vermelho e conexões. **Fonte:** Própria, 2025.

Na comparação entre as execuções clássica e quântica do EA-VRP, observou-se que quando os passageiros são agrupados, ambos os métodos convergem para o mesmo *bitstring* viável 100000, resultando em um menor custo de aproximadamente 0,047078, o que mostra consistência entre as abordagens e viabilidade da solução encontrada pelo QAOA dentro do limite de 12 qubits. Contudo, na instância sem agrupamento, o método clássico mantém o mesmo padrão de solução — preservando o *bitstring* e o custo encontrado na versão agrupada — enquanto o QAOA retorna o *bitstring* 000010, que neste caso, não corresponde a uma solução viável, destacando uma limitação do algoritmo quântico ao

lidar com instâncias mais restritas em termos de representação binária e penalidades de restrição. Isso evidencia que o agrupamento não apenas reduz a quantidade de qubits necessária, mas também favorece a convergência do método quântico para soluções factíveis, enquanto na ausência de agrupamento o QAOA pode incorrer em resultados inviáveis, apesar de reproduzir um *bitstring* similar.

Foi observado que (i) O agrupamento reduz fortemente o número de qubits e aumenta a executabilidade das instâncias; (ii) as distribuições indicam que, no mesmo construtor do modelo QUBO agrupado, os custos encontrados por clássico e quântico tendem a se manter próximos em grande parte dos casos; (iii) o grafo de uma instância exemplifica como a contração espacial e o agrupamento simplificam a estrutura de decisão; e (iv) o agrupamento favorece a convergência do método quântico para soluções factíveis.

CONCLUSÃO

Com este trabalho foi possível ver que o agrupamento geográfico de 1–5 passageiros reduz de forma consistente o espaço de decisão e o número de qubits, viabilizando QAOA sob recursos limitados sem perder interpretabilidade operacional, grupos como micro-rotas pick-and-drop. Nos experimentos, observamos redução média de aproximadamente 75% no número de qubits e um aumento expressivo na executabilidade sob o seu limite.

No mesmo formulador QUBO com agrupamento, os métodos clássico e quântico atual tendem a produzir custos próximos, com diferenças na casa de poucos pontos percentuais em grande parte das instâncias. Adicionalmente, o protocolo de paridade (clássico×quântico no mesmo modelo) e a verificação preliminar de executabilidade, filtro por qubits, evitam vieses de comparação e favorecem a reprodutibilidade.

Como limitações, destacamos o porte reduzido das instâncias, restrito pelo orçamento de qubits) o uso de simulador, sem ruído de hardware, e a restrição estrutural do modelo atual que permite no máximo um grupo por veículo, o que pode limitar a generalidade. Ressaltamos ainda que a comparação direta “com vs. sem agrupamento” não é avaliação adequada; por isso adotamos a análise de paridade no mesmo formulador QUBO com agrupamento.

Como trabalhos futuros, propomos aprimorar a modelagem do problema, explorando técnicas que reduzam a complexidade e ampliem a eficiência do uso de qubits. Além disso, pretendemos investigar métodos de agrupamento em ambiente quântico e desenvolver um fluxo de processamento híbrido, visando menor dependência de rotinas clássicas, maior eficiência computacional e melhor escalabilidade.

AGRADECIMENTOS

Agradecimento à Universidade Federal do ABC (UFABC) pela disponibilidade técnica e estrutural e à Universidade Estadual da Região Tocantina do Maranhão (UEMASUL) pelo apoio financeiro para a realização desse trabalho.

REFERÊNCIAS

- [1] G. Zardini, N. Lanzetti, M. Pavone, and E. Frazzoli, “Analysis and control of autonomous mobility-on-demand systems,” *Annual Review of Control, Robotics, and Autonomous Systems*, vol. 5, no. 1, pp. 633–658, 2022.
- [2] F. Rossi, R. Iglesias, M. Alizadeh, and M. Pavone, “On the interaction between autonomous mobility-on-demand systems and the power network: Models and coordination algorithms,” *IEEE Transactions on Control of Network Systems*, vol. 7, no. 1, pp. 384–397, 2019.
- [3] H. Bang and A. A. Malikopoulos, “Congestion-aware routing, rebalancing, and charging scheduling for electric autonomous mobility-on-demand system,” in *2022 American Control Conference (ACC)*, 2022, pp. 3152–3157.
- [4] W.-h. Huang, H. Matsuyama, and Y. Yamashiro, “Solving capacitated vehicle routing problem with quantum alternating operator ansatz and column generation,” *arXiv preprint arXiv:2503.17051*, 2025.
- [5] P. H. V. Penna, A. Subramanian, and L. S. Ochi, “An iterated local search heuristic for the heterogeneous fleet vehicle routing problem,” *Journal of Heuristics*, vol. 19, no. 2, pp. 201–232, 2013.
- [6] R. Spliet and A. F. Gabor, “The time window assignment vehicle routing problem,” *Transportation Science*, vol. 49, no. 4, pp. 721–731, 2015.
- [7] D. Fitzek, T. Ghandriz, L. Laine, M. Granath, and A. F. Kockum, “Applying quantum approximate optimization to the heterogeneous vehicle routing problem,” *Scientific Reports*, vol. 14, no. 1, p. 25415, 2024.
- [8] F. Paparella, K. Chauhan, L. Koenders, T. Hofman, and M. Salazar, “Ride-pooling electric autonomous mobility-on-demand: Joint optimization of operations and fleet and infrastructure design,” *arXiv preprint arXiv:2403.06566*, 2024.
- [9] N. Pirnay, V. Ulitzsch, F. Wilde, J. Eisert, and J.-P. Seifert, “An in-principle super-polynomial quantum advantage for approximating combinatorial optimization problems via computational learning theory,” *Science Advances*, vol. 10, no. 11, p. eadj5170, 2024. [Online]. Available: <https://www.science.org/doi/abs/10.1126/sciadv.adj5170>
- [10] D. Amaro, C. Modica, M. Rosenkranz, M. Fiorentini, M. Benedetti, and M. Lubasch, “Filtering variational quantum algorithms for combinatorial optimization,” *Quantum Science and Technology*, vol. 7, no. 1, p. 015021, 2022.
- [11] R. Hari Krishnakumar, S. Nannapaneni, N. H. Nguyen, J. E. Steck, and E. C. Behrman, “A quantum annealing approach for dynamic multi-depot capacitated vehicle routing problem,” *arXiv preprint arXiv:2005.12478*, 2020.
- [12] E. Farhi, J. Goldstone, and S. Gutmann, “A quantum approximate optimization algorithm,” *arXiv preprint arXiv:1411.4028*, 2014.
- [13] M. Cattelan and S. Yarkoni, “Modeling routing problems in qubo with application to ride-hailing,” *Scientific Reports*, vol. 14, no. 1, p. 19768, 2024.
- [14] A. Lucas, “Ising formulations of many np problems,” *Frontiers in physics*, vol. 2, p. 5, 2014.
- [15] J. Preskill, “Quantum computing in the nisq era and beyond,” *Quantum*, vol. 2, p. 79, 2018.
- [16] B. Wu, X. He, S. Yang, L. Shou, G. Tian, J. Zhang, and X. Sun, “Optimization of cnot circuits on limited-connectivity architecture,” *Physical Review Research*, vol. 5, no. 1, p. 013065, 2023.
- [17] K. Bharti, A. Cervera-Lierta, T. H. Kyaw, T. Haug, S. Alperin-Lea, A. Anand, M. Degroote, H. Heimonen, J. S. Kottmann, T. Menke *et al.*, “Noisy intermediate-scale quantum algorithms,” *Reviews of Modern Physics*, vol. 94, no. 1, p. 015004, 2022.
- [18] I. Gaidai and R. Herrman, “Performance analysis of multi-angle qaoa for $p > 1$,” *Scientific Reports*, vol. 14, no. 1, p. 18911, 2024.
- [19] M. Han, H. Park, and S. Choi, “Quantum zeno monte carlo for computing observables,” *npj Quantum Information*, vol. 11, no. 1, pp. 1–13, 2025.
- [20] C. Caface and R. Yokoingawa, “EA-VRP-QUBO: Quantum routing with passenger grouping,” 2025, accessed: 2025-07-28. [Online]. Available: <https://github.com/mephessivlc/EA-VRP>

IV. DISPONIBILIDADE DE CÓDIGO

O código-fonte completo utilizado neste trabalho encontra-se em Caface e Yokoingawa [20]. O repositório inclui um README com instruções de instalação, dependências e exemplos de uso.