



OTIMIZAÇÃO MULTI OBJETIVO DE ROTEAMENTO SUSTENTÁVEL DO TRANSPORTE DE CARGAS COM APLICAÇÃO DE SIG E NSGA-III NA MALHA VIÁRIA DO RIO DE JANEIRO

Jéssica Wanderley Souza do Nascimento¹, Cíntia Machado de Oliveira², Gabriel Nakalski Farias¹,
Luís Eduardo Santos Fortes^{1,2}, Glaydston Mattos Ribeiro¹

¹Universidade Federal do Rio de Janeiro (UFRJ), ²Centro Federal de Educação Tecnológica do Rio de Janeiro (CEFET/RJ)

RESUMO

Este estudo propõe um modelo de roteamento inteligente para otimizar, de forma sustentável, o transporte urbano de cargas na malha viária do Rio de Janeiro. Técnicas de Sistemas de Informação Geográfica (SIG) foram integradas a dados geospaciais da infraestrutura viária e parâmetros logísticos para simular diferentes cenários de distribuição. A modelagem adotou uma abordagem de otimização multiobjetivo com o algoritmo evolutivo NSGA-III (*Non-dominated Sorting Genetic Algorithm III*), gerando soluções de Pareto que alinham eficiência operacional e sustentabilidade ambiental. Os critérios incluíram a minimização da distância total percorrida, do tempo de deslocamento e das emissões de gases de efeito estufa (GEE). Os resultados indicaram que o modelo de roteamento proposto reduziu a distância total percorrida em 76,5% (-85,9 km), resultando em um ganho de 30,9% em eficiência logística e uma redução média de 33,1% nas emissões de CO₂ em comparação com o NSGA-II. Essas averiguações reforçam o potencial do modelo como uma ferramenta robusta e replicável para a gestão sustentável do transporte urbano de cargas.

1. CONSIDERAÇÕES INICIAIS

A logística urbana de cargas enfrenta desafios cada vez mais complexos, impulsionados pela crescente demanda por entregas, pela saturação da infraestrutura rodoviária e por requisitos ambientais cada vez mais rigorosos (Nascimento *et al.*, 2025). No contexto da cidade do Rio de Janeiro, a interação entre a configuração geográfica heterogênea e os altos níveis de congestionamento intensifica os impactos ambientais do transporte de cargas, principalmente no que diz respeito às emissões de gases de efeito estufa (GEE), como o dióxido de carbono (CO₂), conforme reportado pelo IPCC (2019).

Diante desse cenário, torna-se imprescindível adotar estratégias que aliem eficiência operacional e sustentabilidade ambiental (Shao *et al.*, 2022). Nesse sentido, o roteamento inteligente, estruturado a partir de variáveis logísticas, espaciais e ambientais, quando integrado a Sistemas de Informação Geográfica (SIG), possibilita não apenas o traçado de rotas otimizadas, como também a mitigação dos impactos ambientais inerentes às operações de distribuição urbana (Wills *et al.*, 2019).

Abordagens contemporâneas apontam que a roteirização inteligente com variabilidade controlada, associada a técnicas de otimização multiobjetivo e apoiada em SIG (considerando características da malha viária como extensão, velocidade média e fatores topográficos) pode resultar em reduções significativas nas emissões urbanas de CO₂ (Jabir *et al.*, 2015; Guan *et al.*, 2022). Apesar desses avanços, persistem lacunas metodológicas no panorama urbano brasileiro, sobretudo em áreas metropolitanas densamente povoadas, como o Rio de Janeiro, onde ainda são incipientes as aplicações em redes viárias complexas que combinem SIG e algoritmos de otimização evolutiva (Konstantakopoulos *et al.*, 2020).

Nesse âmbito, o NSGA-II (*Non-dominated Sorting Genetic Algorithm II*) consolidou-se como uma das principais ferramentas para a resolução de problemas de roteamento ambiental, especialmente no contexto do GVRP (*Green Vehicle Routing Problem*), devido à sua elevada capacidade de convergência e à manutenção da diversidade das soluções obtidas (Deb *et al.*, 2002). Embora robusto para cenários bi ou triobjetivos, o NSGA-II denota limitações quando o número de objetivos ultrapassa três, uma vez que tende a perder seletividade e a gerar soluções com distribuição deficiente no fronte de Pareto (Chupin *et al.*, 2025).

Com o intuito de superar tais limitações, foi proposto o NSGA-III, que incorpora um mecanismo de referência baseado em vetores direcionadores. Esse recurso garante maior dispersão e representatividade das soluções em problemas de alta dimensionalidade, nos quais múltiplos objetivos devem ser considerados simultaneamente. Assim, enquanto o NSGA-II é adequado para problemas de menor dimensionalidade, o NSGA-III revela-se mais apropriado para cenários complexos, propiciando a geração de soluções de Pareto equilibradas em três dimensões essenciais: distância total percorrida, tempo de deslocamento e emissões de CO₂ (Deb e Jain, 2014).

Além disso, convém destacar que a avaliação de algoritmos de otimização multiobjetivo não deve se restringir apenas aos indicadores de desempenho, mas também contemplar métricas de qualidade do conjunto de soluções, aspecto fundamental em estudos comparativos de algoritmos evolutivos, como o NSGA-II e o NSGA-III (Chaudhari *et al.*, 2022).

Em virtude dos fatos mencionados, este estudo tem como objetivo desenvolver e aplicar um modelo de

roteirização inteligente baseado em SIG e otimização multiobjetivo por meio do algoritmo evolutivo NSGA-III, visando à minimização simultânea da distância total percorrida, do tempo total de deslocamento e das emissões de GEE no transporte urbano de cargas no Rio de Janeiro. A proposta busca oferecer uma ferramenta analítica robusta e adaptável para subsidiar decisões estratégicas em políticas públicas de mobilidade e gestão logística urbana sustentável.

2. METODOLOGIA

A metodologia adotada neste estudo foi estruturada em quatro etapas interdependentes que, de forma integrada, possibilitaram o desenvolvimento, a aplicação e a avaliação do modelo de roteamento inteligente no contexto urbano do Rio de Janeiro.

2.1. Coleta e processamento de dados geoespaciais

Inicialmente, foram coletados e estruturados os dados geoespaciais da malha viária urbana do município do Rio de Janeiro. Essa etapa consistiu na extração de informações de base de dados cartográficos e fontes de dados abertos, como o *OpenStreetMap* (OSM), complementados por dados registrados pela Companhia de Engenharia de Tráfego do Rio de Janeiro (CET-Rio), abrangendo o período entre 2018 e 2022. Os critérios considerados incluíram: classificação funcional das vias (hierarquia viária), número de faixas, sentidos de tráfego, limites de velocidade, presença de restrições de tráfego (zonas de restrição de caminhões, áreas escolares, zonas de carga e descarga) e a localização de polos geradores de carga (centros de distribuição, supermercados, centros comerciais e industriais). Posteriormente, os dados foram processados em um ambiente SIG (Sistemas de Informação Geográfica) QGIS 3.34.4 para garantir a topologia consistente das vias, a remoção de duplicatas e a padronização das geometrias.

2.2. Integração com dados operacionais de logística

A segunda etapa consistiu em incorporar os dados logísticos operacionais nos dados geoespaciais, criando assim uma base robusta para a simulação. As informações incluíram: volumes de entrega por destino, janelas de entrega (*time windows*), capacidade de carga dos veículos, frequência de rotas e tipos de veículos utilizados. Tais dados foram coletados a partir da análise de relatórios técnicos, como o Plano de Logística Urbana Sustentável do Rio de Janeiro (2019) e o Inventário Nacional de Emissões Atmosféricas por Veículos Automotores Rodoviários (IBAMA, 2021), além de estudos de caso disponíveis na literatura especializada, como Marujo *et al.*, (2018). Essa integração possibilitou a construção de cenários realistas e aderentes às operações de transporte urbano de cargas.

2.3. Modelo matemático de otimização multiobjetivo

Com a base de dados devidamente consolidada, foram modelados matematicamente os diferentes cenários de roteirização, estruturando o problema como um Problema de Roteamento de Veículos com Múltiplos Objetivos (*Multi-Objective Vehicle Routing Problem* – MOVRP). Para a sua resolução, foi implementado o algoritmo evolutivo NSGA-III (*Non-dominated Sorting Genetic Algorithm III*), amplamente reconhecido por sua eficácia na geração de soluções não dominadas no contexto da Otimização Multiobjetivo, no qual possibilita a geração de soluções de Pareto.

A formulação adotada considerou, de forma simultânea, três critérios de otimização: (i) minimização da distância total percorrida; (ii) minimização do tempo total de deslocamento; e (iii) minimização das emissões de gases de efeito estufa (GEE). As emissões foram estimadas com base nos fatores de emissão estabelecidos tanto pelo IPCC (2019) quanto pelo Inventário Nacional de Emissões, tendo em vista variáveis como o tipo de veículo, a velocidade média operacional e as características da via.

A etapa final consistiu na calibração do modelo, com a definição de parâmetros-chave do algoritmo, como a taxa de cruzamento, a taxa de mutação e o número total de gerações, assegurando tanto a robustez quanto a convergência das soluções encontradas ao longo do processo evolutivo.

O modelo matemático considerou as seguintes variáveis (Equações 1, 2 e 3):

- Minimizar:

$$f_1(x) = \sum_{i=1}^n d_{ij}x_{ij} - \text{distância total percorrida} \quad (1)$$

$$f_2(x) = \sum_{i=1}^n t_{ij}x_{ij} - \text{tempo total de deslocamento} \quad (2)$$

$$f_3(x) = \sum_{i=1}^n e_{ij}x_{ij} - \text{emissões totais de GEE} \quad (3)$$

- Sujeito a:

$$\sum_j x_{ij} = 1, \quad \forall i \neq j \quad (\text{cada cliente deve ser visitado uma vez})$$

$$\sum_i x_{ij} = 1, \quad \forall j \neq i \quad (\text{cada cliente deve ser atendido por uma rota})$$

$$q_k \leq Q, \quad (\text{respeito à capacidade máxima dos veículos})$$

$$a_j \leq t_j \leq b_j, \quad (\text{respeito à janela de tempo } [a_j, b_j])$$

Onde: x_{ij} é a variável binária de decisão (1 se a rota do ponto i ao ponto j for utilizada, 0 caso contrário);

d_{ij} é a distância entre os pontos i e j ;

t_{ij} é o tempo estimado de deslocamento entre os pontos i e j ;

e_{ij} são as emissões estimadas de GEE no trajeto de i para j ;

q_k é a carga atribuída ao veículo k ;

Q é a capacidade máxima do veículo;

a_j, b_j são o início e fim da janela de tempo para o ponto j ;

t_j são o tempo de atendimento no ponto j .

2.4. Comparação entre NSGA-II e NSGA-III

Por fim, foram realizados testes comparativos entre os algoritmos NSGA-II e NSGA-III implementados com parâmetros comuns de configuração, sendo que o NSGA-II utilizou a ordenação não-dominada associada ao *crowding distance*, enquanto o NSGA-III incorporou vetores de referência para maior dispersão em cenários de alta dimensionalidade. As simulações foram realizadas em cenários representativos de redes viárias urbanas, e os resultados foram avaliados usando critérios operacionais (distância, tempo e emissões) e métricas de qualidade das soluções (hipervolume, número de soluções não-dominadas e dispersão).

3. ANÁLISE E DISCUSSÃO DOS RESULTADOS

Após a obtenção das séries espaciais e a integração das camadas temáticas (restrições de tráfego, altimetria, zonas de emissão), o algoritmo NSGA-III foi implementado utilizando a linguagem de programação Python® 3.13.5 com o suporte da biblioteca PyMoo e executado em ambiente computacional com processador Intel® Core™ i7-7500U (6 núcleos e 12 threads, 3,9 GHz), 16 GB de memória RAM, rodando em Microsoft Windows 11 (64 bits). Além disso, o código utilizou o solver PuLP® 2.9.0 para formulação e resolução do modelo de otimização e foi integrado a um sistema de geoprocessamento para extrair as variáveis relevantes nos pontos geográficos correspondentes às soluções propostas.

Com base nessas informações, as rotas otimizadas foram concentradas em vias arteriais de alto tráfego, notadamente a Avenida Brasil e a Linha Vermelha, evitando assim áreas sujeitas a maiores restrições ambientais, como o centro da cidade, zonas hospitalares e áreas adjacentes a instituições de ensino. A escolha dessas rotas se justifica não apenas pela sua capacidade de tráfego (com média de aproximadamente 170.000 veículos por dia na Avenida Brasil e 140.000 na Linha Vermelha) como também pela sua relevância logística e pelo impacto ambiental comparativamente menor associado ao seu uso. Além disso, a análise espacial indicou uma redução na sobreposição entre as rotas e uma distribuição geográfica mais equilibrada, resultando em uma malha logística mais eficiente com menor redundância operacional (Figura 1).

O algoritmo NSGA-III demonstrou desempenho superior ao NSGA-II em todos os critérios avaliados, alcançando reduções médias de 33,1% nas emissões de CO₂ e 76,5% na distância total percorrida (85,9 km), resultando em um ganho de 30,9% na eficiência logística. Em comparação, o NSGA-II apresentou reduções mais modestas, com 12,5% nas emissões, 11,8% na distância percorrida e 15,4% na eficiência logística. Tais

melhorias, diretamente associadas à adoção de rotas otimizadas em termos de topografia, fluxo de tráfego e áreas restritas, destacam a relevância do NSGA-III para contextos urbanos densamente povoados, como o Rio de Janeiro, onde o transporte é responsável por altos níveis de gases de efeito estufa, corroborando evidências de estudos anteriores, como os relatados por Konstantakopoulos *et al.* (2020), sobre o impacto positivo de modelos avançados de roteamento sustentável.




Figura 1: Declividade e topografia por meio do SIG

Na etapa subsequente da análise, a comparação entre os algoritmos evolutivos NSGA-II e NSGA-III evidenciou diferenças relevantes em termos de desempenho operacional e qualidade das soluções geradas. Para além dos indicadores práticos de redução da distância total percorrida, tempo de deslocamento e emissões de CO₂, a avaliação incorporou métricas consolidadas de otimização multiobjetivo, indispensáveis para aferir a distribuição, diversidade e convergência do fronte de Pareto (Tabela 1).

Tabela 1: Indicadores de qualidade do fronte de Pareto

Métrica	NSGA-II	NSGA-III
Hipervolume (HV)	0,68	0,82
nº de soluções não-dominadas	25	38
Espaçamento (Spread)	0,42	0,27
Tempo de convergência (iteração)	120	105
Diversidade do fronte de Pareto	Moderada	Alta
Escalabilidade (nº de objetivos)	Limitada (até 3)	Elevada (>3)

Os resultados evidenciam que o NSGA-III apresentou desempenho superior em todas as métricas de avaliação do conjunto de soluções. O Hipervolume (HV) atingiu um valor de 0,82, em comparação com 0,68 obtido pelo NSGA-II, demonstrando a capacidade do primeiro em explorar o espaço de busca de forma mais abrangente e conciliar objetivos conflitantes de forma mais eficaz. No que se refere ao Número de soluções não-dominadas, o NSGA-III produziu 13 soluções adicionais, ampliando a diversidade de alternativas disponíveis para a tomada de decisão.

Quanto ao Espaçamento (*Spread*), o menor valor registrado no NSGA-III (0,27) indica maior uniformidade na distribuição das soluções e menos ocorrência de lacunas no fronte de Pareto, o que reforça a qualidade da diversidade mantida pelo algoritmo. Por fim, no que concerne ao Tempo de convergência, o NSGA-III alcançou resultados mais robustos, demandando menos iterações para estabilizar o processo evolutivo, aspecto que destaca sua superioridade em termos de eficiência computacional.

4. CONSIDERAÇÕES FINAIS

A implementação do modelo de roteirização inteligente desenvolvido neste estudo gerou avanços expressivos tanto no desempenho logístico quanto na sustentabilidade ambiental, considerando o contexto urbano da cidade



do Rio de Janeiro. A integração de dados geoespaciais da malha viária com parâmetros logísticos específicos, viabilizada pela aplicação de Sistemas de Informação Geográfica (SIG) em conjunto com o algoritmo NSGA-III, permitiu a construção de cenários operacionais realistas com alto potencial de replicabilidade em centros urbanos com características logísticas semelhantes.

Com relação aos resultados obtidos, observou-se uma redução significativa das emissões de CO₂, evidenciando a eficácia da roteirização inteligente tanto no enfrentamento às mudanças climáticas quanto na promoção da mobilidade urbana sustentável. Assim, o modelo proposto não se limita a ganhos quantitativos mensuráveis, mas se consolida como uma ferramenta estratégica de apoio à decisão, capaz de subsidiar a formulação de políticas públicas voltadas para a gestão sustentável da logística urbana.

Para pesquisas futuras, recomenda-se a incorporação de dados em tempo real aplicando tecnologias de Internet das Coisas (IoT), bem como a utilização de algoritmos de *Machine Learning* (ML) para predição de tráfego, visando ampliar a adaptabilidade e precisão dos modelos propostos.

Agradecimentos

Os autores agradecem ao CEFET/RJ, à FAPERJ e ao OPTGIS da COPPE/UFRJ pelo apoio institucional, financeiro e técnico.

REFERÊNCIAS BIBLIOGRÁFICAS

- Chaudhari, P. et al. (2022) Comparison of NSGA-III with NSGA-II for multi objective optimization of adiabatic styrene reactor. *Materials Today: Proceedings*, v. 57, n. 4, p. 1509-1514. DOI: 10.1016/j.matpr.2021.12.047
- Chupin, A. et al. (2025) Multi-objective optimization for intermodal freight transportation planning: a sustainable service network design approach. *Sustainability*, v. 17, n. 12, p. 5541. DOI: 10.3390/su17125541
- Deb, K. et al. (2002) A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, v. 6, n. 2, p. 182-197. DOI: 10.1109/4235.996017
- Deb, K. e Jain, H. (2014) An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, Part I: Solving Problems With Box Constraints. *IEEE Transactions on Evolutionary Computation*, v. 18, n. 4, p. 577-601. DOI: 10.1109/TEVC.2013.2281535
- Guan, J. et al. (2022) Multi-objective optimization for sustainable road network maintenance under traffic equilibrium: Incorporating costs and environmental impacts. *Journal of Cleaner Production*, v. 334, p. 130-103. DOI: 10.1016/j.jclepro.2021.130103
- IBAMA (2021) *Inventário nacional de emissões atmosféricas por veículos automotores rodoviários: Ano-base 2019*. Disponível em: <<https://www.ibama.gov.br>>. Acesso em: 27 jun. 2025.
- IPCC (2019) *2019 Refinement to the 2006 IPCC Guidelines for National Greenhouse Gas Inventories*. Geneva: IPCC Task Force on National Greenhouse Gas Inventories.
- Jabir, E. et al. (2015) Multi-objective Optimization Model for a Green Vehicle Routing Problem. *Procedia - Social and Behavioral Sciences*, v. 189, p. 33-39. DOI: 10.1016/j.sbspro.2015.03.189
- Konstantakopoulos, G. D. et al. (2020) A multiobjective large neighborhood search metaheuristic for the vehicle routing problem with time windows. *Algorithms*, v. 13, n. 10, p. 243. DOI: 10.3390/a13100243
- Marujo, L. G. et al. (2018) Assessing the sustainability of mobile depots: The case of urban freight distribution in Rio de Janeiro, *Transportation Research Part D: Transport and Environment*, v. 62, p. 256-267. DOI: 10.1016/j.trd.2018.02.022
- Nascimento, J. W. S. do. et al. (2025) An integrated intelligent routing approach for the sustainable optimization of urban freight transport in Rio de Janeiro. In *Anais do Congresso Técnico Científico da Engenharia e da Agronomia*. Vitória: CONTECC, 80ª SOEA, p. 1-5.
- Prefeitura da Cidade do Rio de Janeiro (2019) *Plano de logística urbana sustentável do Rio de Janeiro*. Secretaria Municipal de Transportes. Disponível em: <<https://www.rio.rj.gov.br>>. Acesso em: 17 jun. 2025.
- Shao, C. et al. (2022) Multi-objective optimization of customer-centered intermodal freight routing problem based on the combination of DRSA and NSGA-III. *Sustainability*, v. 14, n. 5, p. 2985. DOI: 10.3390/su14052985
- Wills, W. et al. (2019) A simple sinuosity-based method using GPS data to support mitigation policies for public buses GHG emissions. *ArXiv, abs/1907.09335*. DOI: 10.48550/arXiv.1907.09335

Jéssica Wanderley Souza do Nascimento (jessica.souza@ufrj.br)

Gabriel Nakalski Farias (gabriel.farias@pet.coppe.ufrj.br)

Glaydston Mattos Ribeiro (glaydston@pet.coppe.ufrj.br)

Laboratório de Otimização e Sistemas de Informações Geográficas (OPTGIS) do Programa de Engenharia de Transporte (PET) do Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia (COPPE) da Universidade Federal do Rio de Janeiro (UFRJ) – Avenida Horácio Macedo, 2030, Bloco I, Sala 244, Cidade Universitária – Rio de Janeiro, RJ, Brasil

Cíntia Machado de Oliveira (cintia.oliveira@cefet-rj.br)

Luís Eduardo Santos Fortes (luis.fortes@cefet-rj.br)

Departamento de Engenharia de Produção, CEFET/RJ, Unidade Itaguaí – Rod. Gov. Mário Covas, BR-101, s/n – Santana, Itaguaí – RJ, 23812-101