UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

OTIMIZAÇÃO VIA SIMULAÇÃO APLICADA À LOGÍSTICA REVERSA

Wesley Gabriel de Mendonça Pinto

Itajubá, setembro de 2025

UNIVERSIDADE FEDERAL DE ITAJUBÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

Wesley Gabriel de Mendonça Pinto

OTIMIZAÇÃO VIA SIMULAÇÃO APLICADA À LOGÍSTICA REVERSA

Tese submetida ao programa de Pós-Graduação em Engenharia de Produção como parte dos requisitos para obtenção do Título de Doutor em Ciências em Engenharia de Produção.

Área: Engenharia de Produção

Orientador: Prof. Dr. José Arnaldo Barra Montevechi

Setembro de 2025

Itajubá

AGRADECIMENTO

Cheguei até aqui graças a muita gente especial que caminhou comigo, e meu coração transborda gratidão por cada um.

A Deus, meu primeiro e mais fiel companheiro, que segurou minha mão nos dias em que eu já não tinha forças e soprou coragem quando a vontade era largar tudo.

Pai e irmãos – Donizeti, Carla, Wildner, Cassandra, Cariny e Walker, vocês são meu porto seguro. Desde pequeno, abriram mão de tanta coisa para investir no meu futuro, às vezes até esquecendo de cuidar de vocês mesmos para cuidar de mim. Obrigado por cada conselho, cada "vai dar certo" e cada abraço cheio de afeto.

Ana Paula, minha parceira de vida e de sonhos: celebramos juntos cada vitória e, nos momentos de dificuldade, lá estava você segurando minha ansiedade, revisando textos, lembrando-me de comer, dormir e continuar. Obrigado por acreditar em mim quando nem eu acreditava mais. E, sobretudo, por trazer ao mundo nossos meninos Heitor e Miguel, que chegaram como raios de luz num período turbulento e se tornaram meu motor diário para seguir.

Professor José Arnaldo, meu orientador e grande guia: suas cobranças firmes e sua confiança me ensinaram que "impossível" é só mais uma palavra. Professor Rafael Miranda, obrigado por cada insight que destravou etapas inteiras deste trabalho. E ao Professor Pinho, que apareceu na hora exata para me apoiar no momento mais intenso desta jornada.

Aos amigos do NEEAD, Carlos, Alyson, João Victor, Jonathan, André, Guilherme e Arthur –, companheiros de dias intensos e risadas indispensáveis. E aos parceiros de longe, Gustavo e Afonso, que mostraram que as dificuldades eram coletivas e, por isso mesmo, mais leves de carregar.

À Universidade Federal de Itajubá; às agências CNPq, Capes e Fapemig, que apostaram no meu projeto; à equipe da FlexSim, pela parceria que manteve nosso software sempre atualizado; e à empresa que abriu seus dados e suas portas, além dos gerentes e diretores que me atenderam com tanta boa vontade –, meu sincero agradecimento.

Cada um de vocês colocou um tijolinho nesta conquista. Este trabalho leva meu nome na capa, mas é feito de muitas mãos, abraços, cafés compartilhados e "vai dar certo" genuínos.

Muito, muito obrigado!

Pois dele, por ele e para ele são todas as coisas.
A ele seja a glória
para sempre! Amém.

Romanos 11:36

RESUMO

O crescimento dos resíduos elétricos e equipamentos eletroeletrônicos (REEE) impõe desafios econômicos, ambientais e sociais ao planejamento da logística reversa (LR). Este estudo propõe e aplica uma abordagem de Otimização via Simulação (OvS) para apoiar o roteamento e a alocação de frotas em um Problema de roteamento de veículos com frotas heterogêneas, conciliando custo, emissões de CO_2 e quantidade de coleta. O método integra: (i) preparação de dados (matrizes de distâncias, demandas e custos; características dos veículos); (ii) geração de soluções por Algoritmo Genético (GA) multiobjetivo; e (iii) avaliação estocástica em simulação a eventos discretos (FlexSim), sem realizar uma nova otimização. O pilar social foi operacionalizado exclusivamente como quantidade total coletada (kg) e cobertura de atendimento, e há vínculo com "alimentos perecíveis", ou seja, a cada quilograma coletado, 1 kg de alimento perecível será doado a organizações carentes. Foram avaliados 20 cenários da fronteira não dominada do GA. No Caso 1, que envolveu municípios da Região Metropolitana de São Paulo, um cenário (9) mostrou-se inválido na simulação e não foi considerado na comparação final. Entre os válidos, observaram-se extremos informativos: menor custo de R$ 626,53 (Cenários 13 e 14), com 78,01 $kgCO_2$ e 7.366,74 kg coletados; menor emissão de 74,24 $kgCO_2$ (Cenários 8 e 10), ambos com R$ 631,38 e 7.366,74 kg; e maior coleta de 15.979,03 kg (Cenário 20), com R$ 2.137,76 e 270,21 $kgCO_2$. Em análise por somas ponderadas (normalização min–max), o Cenário 20 destacou-se quando emissão e coleta foram priorizadas conjuntamente, enquanto o Cenário 10 emergiu como solução balanceada (custo baixo, emissão mínima e coleta intermediária). No Caso 2, estruturado com parâmetros distintos de frota, capacidades e matriz de distâncias, buscou-se avaliar a robustez e a escalabilidade do modelo. Os resultados confirmaram que a ferramenta preserva a coerência dos *trade-offs* identificados no primeiro caso, adaptando-se a condições alternativas de operação sem perda de consistência. A análise comparativa evidenciou que o método é aplicável em realidades operacionais diversas, ampliando seu potencial de uso prático na logística reversa. Conclui-se que a OvS com GA multiobjetivo responde positivamente ao problema: filtra soluções inviáveis, explicita os *trade-offs* e entrega um portfólio auditável de alternativas para LR de REEE, alinhando metas econômicas, ambientais e de atendimento. O projeto computacional desenvolvido constitui uma base replicável para adoção prática e para futuras extensões.

Palavras-chave: simulação, otimização via simulação, algoritmo genético, logística reversa, REEE, multiobjetivo.

ABSTRACT

The growth of waste electrical and electronic equipment (WEEE) poses economic, environmental, and social challenges to the planning of reverse logistics (RL). This study proposes and applies a Simulation-based Optimization (OvS) approach to support vehicle routing and fleet allocation in a Heterogeneous Fleet Vehicle Routing Problem (HFVRP), balancing cost, CO_2 emissions, and collection volume. The method integrates: (i) data preparation (distance matrices, demands, and costs, as well as vehicle characteristics); (ii) generation of solutions by a multi-objective Genetic Algorithm (GA); and (iii) stochastic evaluation through discrete-event simulation (FlexSim), without re-optimization. The social dimension was operationalized exclusively as the total collected quantity (kg) and service coverage, with an additional link to "perishable food": for every kilogram of waste collected, one kilogram of perishable food would be donated to charitable organizations. A total of 20 scenarios from the GA's non-dominated frontier were evaluated. In Case 1, which involved municipalities of the Metropolitan Region of São Paulo, one scenario (9) proved invalid during simulation and was excluded from the final comparison. Among the valid ones, informative extremes were observed: the lowest cost was R$ 626.53 (Scenarios 13 and 14), with 78.01 kg CO_2 and 7,366.74 kg collected; the lowest emissions were 74.24 kg CO_2 (Scenarios 8 and 10), both with R$ 631.38 and 7,366.74 kg collected; and the largest collection reached 15,979.03 kg (Scenario 20), with a cost of R$ 2,137.76 and 270.21 kg CO_2. In the weighted sum analysis (min–max normalization), Scenario 20 stood out when emissions and collection were jointly prioritized, whereas Scenario 10 emerged as a balanced solution (low cost, minimum emissions, and intermediate collection). In Case 2, designed with distinct fleet parameters, capacities, and distance matrices, the goal was to evaluate the robustness and scalability of the model. The results confirmed that the tool preserved the consistency of the trade-offs identified in the first case, adapting to alternative operational conditions without loss of coherence. The comparative analysis demonstrated that the method is applicable across diverse operational realities, thereby expanding its practical potential in reverse logistics. It is concluded that OvS combined with a multi-objective GA responds positively to the problem: it filters infeasible solutions, makes trade-offs explicit, and delivers an auditable portfolio of alternatives for WEEE reverse logistics, aligning economic, environmental, and service coverage goals. The computational tool developed constitutes a replicable basis for practical adoption and for future extensions.

Keywords: simulation, optimization via simulation, genetic algorithm, reverse logistics, WEEE, multiobjective.

LISTA DE FIGURAS

Figura 1 – Fluxo logístico.....22
Figura 2 – Campos da Logística.....23
Figura 3 – Fluxo da logística direta e reversa.....25
Figura 4 – Fases de desenvolvimento na abordagem tradicional.....33
Figura 5 – Linha de contorno da função objetivo e figura geométrica da região viável.....35
Figura 6 – Taxonomia da Otimização.....36
Figura 7 – Classificação dos algoritmos meta-heurísticos segundo sua inspiração.....39
Figura 8 – Fluxograma de operacionalização do GA clássico.....41
Figura 9 – Modelo de Simulação.....43
Figura 10 – Interação entre o modelo de simulação com o otimizador.....45
Figura 11 – Como funciona um módulo de otimização integrado a Simulação a Eventos Discretos.....45
Figura 12 – Nuvem de palavras sobre revisão sistemática de literatura na logística reversa..49
Figura 13 – Oportunidades relatados para o uso de otimização via simulação na logística reversa.....50
Figura 14 – Procedimentos realizados nas etapas de Planejamento e Pesquisa/Triagem.....52
Figura 15 – Procedimentos realizados nas etapas de Planejamento e Pesquisa/Triagem.....53
Figura 16 – Trabalhos que utilizaram otimização via simulação aplicada a logística reversa nos últimos anos.....54
Figura 17 – Número de artigos publicados por pesquisador.....55
Figura 18 – Artigos com maior número de citações.....56
Figura 19 – Gráfico de Pareto das principais áreas de aplicação.....58
Figura 20 – Gráfico de Pareto da natureza do problema.....60
Figura 21 – Artigos que utilizaram simulação combinado com otimização.....62
Figura 22 – Artigos que utilizam simulação combinado com otimização.....64
Figura 23 – Tipos de otimização.....66
Figura 24 – Softwares para otimização.....67
Figura 25 – Dimensões da sustentabilidade (Responsabilidade social da Logística Reversa)69
Figura 26 – Classificação da pesquisa.....74
Figura 27 – Etapas seguidas na construção de um projeto de simulação.....77
Figura 28 – Mapeamento da LR dos lixos eletrônicos da Empresa.....80
Figura 29 – Fluxograma para elaboração da OvS multiobjetivo aplicado à logística reversa 88

Figura 30 – Tela inicial do software logístico 91
Figura 31 – Interface de inserção dos dados e manipulação do usuário 91
Figura 32 – Interface de análise dos dados e manipulação do usuário 92
Figura 33 – Interface de roteamento e manipulação do usuário 93
Figura 34 – Interface de roteamento e manipulação do usuário 94
Figura 35 – Grafo das cidades alocadas para a simulação 98
Figura 36 – Interface Flexsim e construção do modelo de simulação 103
Figura 37 – Grafo das cidades alocadas para a simulação 107
Figura 38 – Interface Flexsim e construção do modelo de simulação do caso 2 110

LISTA DE TABELAS

Tabela 1 – Top 10 locais de publicação.....54
Tabela 2 – Top 10 publicações de autores.....55
Tabela 3 - Top 10 Universidades em destaque na busca pelo tema 56
Tabela 4 - Top 10 nacionalidade 57
Tabela 5 - Tabela dos autores relacionado a natureza do problema 61
Tabela 6 - Tabela dos autores relacionados ao tipo de simulação relacionado a área de aplicação e softwares de simulação usado.....63
Tabela 7 - Softwares de simulação X tipos de simulação (continua).....64
Tabela 8 - Softwares de simulação X tipos de simulação (conclusão).....65
Tabela 9 – Objetivos da otimização.....67
Tabela 10 – Algoritmo de otimização 68
Tabela 11 – Algoritmos e Tipos de otimização.....68
Tabela 12 – Dados utilizados para a modelagem de simulação logística.....84
Tabela 13 – Tabela com as características dos veículos.....85
Tabela 14 – Exemplo de Matriz de distância.....85
Tabela 15 – Planejamento experimental para OvS.....96
Tabela 16 – Matriz de distância entre as cidades calculada para o GA.....99
Tabela 17 – Tabela de variável de decisão 100
Tabela 18 – Tabela de parâmetros para o GA 100
Tabela 19 – Tabela de rotas e subrotas.....100
Tabela 20 – Tabela de rotas e subrotas (conclusão) 101
Tabela 21 – Tabela dos resultados das funções objetivo.....103
Tabela 22 –Tabela da normalização das funções objetivo 104
Tabela 23 – Tabela dos pesos usados para normalizar as funções 105
Tabela 24 – Resultados de cada conjunto dos pesos 105
Tabela 25 – Resultados ótimos de cada peso.....106
Tabela 26 – Matriz de distância das cidades do caso 2 108
Tabela 27 – Tabela de rotas e subrotas do caso 2 (continua) 108
Tabela 28 – Tabela de rotas e subrotas do caso 2 (conclusão) 109
Tabela 29 – Tabela dos resultados das funções objetivo do caso 2 (continua) 111

Tabela 30 – Tabela dos resultados das funções objetivo do caso 2 (conclusão) ..... **Erro! Indicador não definido.**
Tabela 31 – Tabela da normalização das funções objetivo do caso 2 111
Tabela 32 – Tabela dos pesos usados para normalizar as funções 112
Tabela 33 – Resultados de cada conjunto dos pesos 113
Tabela 34 – Resultados ótimos de cada peso..... 113

LISTA DE QUADROS

Quadro 1 – Classificação dos algoritmos meta-heurísticos segundo sua inspiração 40
Quadro 2 - Operacionalização do GA em formato algorítmico 42
Quadro 3 – Resumo das principais descobertas relacionado a otimização via simulação aplicado à logística reversa 71
Quadro 4 – Quadro de componentes e variáveis que serão considerados ao sistema de otimização via simulação 79
Quadro 5 – Simbologia utilizada na técnica proposta IDEF-SIM e definição do problema (continua) 81
Quadro 6 – Simbologia utilizada na técnica proposta IDEF-SIM e definição do problema (conclusão) 82

LISTA DE ABREVIAÇÕES

LR – Logística Reversa

ML – *Machine Learning* (Aprendizado de Máquina)

GA – Algoritmo Genético

HFVRP – Problema de roteamento de veículos em frota heterogênea

PNRS – Política Nacional de Resíduos Sólidos

QP – Questão de Pesquisa

RSL – Revisão Sistemática da Literatura

SBA – Simulação Baseada em Agentes

SD – Simulação Contínua

SED – Simulação a Eventos Discretos

UNU – Universidade das Nações Unidas

REEE – Resíduos elétricos e equipamentos eletroeletrônicos

SUMÁRIO

1 INTRODUÇÃO 15

1.1 Contextualização 15

1.2 Justificativa 17

1.3 Problema de pesquisa e objetivos 19

1.4 Delimitação e Contribuições do trabalho 20

1.5 Estrutura do trabalho 20

2 FUNDAMENTAÇÃO TEÓRICA 21

2.1 Contextualização da Logística 21

2.1.1 Logística reversa 24

2.1.2 ESG e ODS em Logística Reversa 27

2.1.3 Problema de roteamento de veículo em Logística Reversa 27

2.2 Simulação 29

2.2.1 Conceitos e definições gerais sobre a simulação 29

2.2.2 Simulação a Eventos Discretos (SED) 32

2.3 Fundamentos de Otimização 35

2.3.1 Conceitos e definições gerais sobre a otimização 35

2.3.2 Taxonomia do método de otimização 36

2.3.3 Meta-heurísticas para otimização 39

2.3.4 Algoritmo Genético (GA) 40

2.4 Otimização via simulação 43

2.5 RSL:Uso da otimização multiobjetivo via simulação aplicada à logística reversa 47

2.5.1 Contextualização 47

2.5.2 Método de Pesquisa: Revisão Sistemática de Literatura 48

2.5.3 Planejamento 48

2.5.4 Pesquisa e Triagem 51

2.5.5 Análise / síntese 53

2.5.6 Apresentação (relatório) 53

2.5.7 Resultados e Discussões 53

2.5.8 Conclusões da RSL da OvS aplicado a LR 71

3 MÉTODO DE PESQUISA 74

3.1 Classificação da pesquisa 74

3.2 Modelagem e Simulação 76

3.2.1 Fase de Concepção 77
3.2.2 Fase de Implementação 86
3.2.3 Fase de Análise 95
4 APLICAÇÃO 98
4.1 Objeto de estudo teórico – Caso 1 98
4.2 Objeto de estudo teórico – Caso 2 107
4.3 Principais resultados obtidos 114
5 CONCLUSÕES FINAIS 118
5.1 CONSIDERAÇÕES FINAIS 121
5.2 TRABALHO FUTUROS 120
REFERÊNCIAS 124
APÊNDICE A - Publicações 129
Artigos em Congressos publicados 129
ANEXO – Código do sistema logístico 130

1 INTRODUÇÃO

1.1 Contextualização

Nota-se uma preocupação crescente com a sustentabilidade, em virtude do aumento significativo na geração de equipamentos elétricos e eletrônicos (EEE) no planeta. Esses equipamentos podem variar desde pequenas peças até dispositivos completos, todos contendo circuitos ou componentes elétricos e eletrônicos. Quando descartados pelo proprietário, passam a ser classificados como resíduos elétricos e equipamentos eletroeletrônico (*Waste from Electrical and Electronic Equipment* – WEEE), ou simplesmente REEE (WAGNER *et al.*, 2022). Estudos recentes de Wagner *et al.* (2022) e Forti *et al.* (2020), mostram que o relatório *The Global E-waste Monitor* (2020) apresentam números recorde de REEE gerados no mundo. Mais recentemente, relatório divulgado em 2024 pela Universidade das Nações Unidas (UNU) evidencia que, entre 2010 e 2022, o volume global de resíduos aumentou 82 %.

Diante desse cenário de crescimento da produção de resíduos eletrônicos em escala global, o Congresso Nacional instituiu, em 2010, a Política Nacional de Resíduos Sólidos (PNRS), sancionada pela Lei nº 12.305, de 2 de agosto de 2010. Com essa lei, o Governo Federal passou a definir princípios, objetivos, instrumentos, diretrizes, metas e ações para o tratamento e a disposição de resíduos sólidos no país (BRASIL, 2010). Entre os conjuntos de regras elaboradas, a logística reversa (LR) surge como instrumento de desenvolvimento econômico e social caracterizado pelo conjunto de ações, de procedimentos e de meios destinados a viabilizar a coleta e a restituição dos resíduos sólidos ao setor empresarial, para reaproveitamento, em seu ciclo ou em outros ciclos produtivos, ou para outra destinação final ambientalmente adequada (BRASIL, 2022).

Estudos recentes apontam que o Brasil possui um problema com a falta de cumprimento da regulamentação e políticas nacionais pelo governo, bem como as incertezas com questões econômicas associadas à logística reversa (BOUZON *et al.*, 2016; DIAS *et al.*, 2018; ECHEGARAY e HANSSTEIN, 2017). Neste sentido, Rogers e Tibben-Lembke, (2001) e Lambert, Riopel e Abdul-Kader (2011) apresentam a LR como processo para o planejamento, implementação e controle do fluxo eficiente e econômico de matérias-primas, desde o ponto de consumo até o ponto de origem, com a finalidade de recapturar seu valor ou melhores práticas de descartes.

A adoção da logística reversa como estratégia corporativa agrega benefícios econômicos, fortalece a reputação socioambiental da organização e impulsiona práticas de sustentabilidade (AGRAWAL; SINGH; MURTAZA, 2015; GOVINDAN *et al.*, 2012).

Kaynak, Koçoğlu e Akgün (2014) acrescentam que a logística reversa é motivada por fatores de competitividade e posicionamento de mercado, pela obtenção de economias diretas, por imperativos ambientais e pela necessidade de atender às exigências legais.

Embora a LR apresente pontos positivos, Agrawal *et al.* (2015) destacam algumas lacunas a serem observadas pela área, como: implementação e adoção, previsões de retornos, terceirização, Rede de LR sobre a perspectiva do mercado secundário e decisão do descarte. Outros desafios enfrentados pela LR estão associados ao trabalho de Bouzon *et al.*(2016) e Bouzon, Govindan e Rodriguez (2015), que identificam barreiras como a falta de integração entre os atores da cadeia, a incerteza quanto ao volume e à qualidade dos retornos, os custos logísticos elevados e a ausência de indicadores claros de desempenho dos fluxos reversos. Esses autores também ressaltam a importância de dispor de ferramentas de apoio à decisão que ajudem a lidar com essas barreiras e tornem o planejamento da LR mais estruturado e transparente. Rachih, Mhada e Chiheb (2019) evidenciam também a necessidade de uma análise descritiva, que combine ferramentas para a solução de problemas complexos enfrentados pelo campo da LR.

Neste sentido, Law (2015) destaca que a simulação é uma das principais ferramentas para auxílio a tomada de decisão em sistemas complexos. A simulação se apresenta com uma técnica adequada na avaliação e previsão de desempenho de sistemas estocásticos, podendo ser utilizada para análise de cenários *"what if"*, testando soluções antes de sua implementação no sistema real, mitigando os riscos associados a tomada de decisão (HELLENO *et al.*, 2015).

Contudo, Amaral *et al.* (2022) pontuam que ao se tratar de inúmeros cenários possíveis, torna-se impraticável avaliá-los em sua totalidade, sendo recomendado a utilização de técnicas de otimização. Considerando ferramentas de apoio à decisão, AMARAL *et al.* (2022) destacam que a Otimização via Simulação (OvS) promove melhores práticas para o auxílio a tomada de decisão. Dessa forma, a OvS trata de um instrumento que auxilia à tomada de decisão, pois captura o relacionamento entre diversas entidades em um sistema complexo no mundo real, permitindo a identificação de melhores soluções para problemas complexos (LIN e CHEN, 2015).

Neste sentido, Rachih, Mhada e Chiheb (2019) ressaltam a importância de integrar ferramentas de otimização com técnicas de simulação para avaliar e aperfeiçoar modelos mais complexos e realistas. Na LR de resíduos elétricos e equipamentos eletroeletrônicos (*Waste Electrical and Electronic Equipment* – WEEE), essa integração torna-se relevante diante de desafios como a dispersão geográfica dos pontos de coleta, a variabilidade da demanda, as restrições operacionais da frota e a necessidade de conciliar aspectos econômicos, ambientais e

sociais. Tais fatores dificultam a obtenção de soluções robustas apenas por meio de modelos determinísticos tradicionais, justificando o uso da OvS para apoiar a tomada de decisão.

Logo, o objetivo principal desta tese, têm em vista, propor um método de OvS para selecionar configurações de roteamento multiveículo, considerando múltiplos objetivos minimização de custos, redução de emissões de CO_2 e maximização da massa coletada no contexto da logística reversa de REEE.

Para compreender a aplicabilidade do método proposto, adotou-se como estudo de caso o fluxo de coleta de REEE proveniente de pontos de entrega voluntária (PEVs) distribuídos na Região Metropolitana de São Paulo. A escolha desse contexto decorre de uma demanda real apresentada por uma empresa multinacional do setor eletroeletrônico, responsável por gerenciar a logística reversa de produtos como *smartphones*, impressoras, *notebooks* e monitores.

Essa empresa mantém PEVs em diversos municípios da região, sendo que Sorocaba atua como centro de consolidação e ponto de partida para as operações de coleta. O problema enfrentado envolve a necessidade de planejar rotas eficientes para múltiplos veículos, atendendo restrições de capacidade e prazos, ao mesmo tempo em que se busca reduzir custos operacionais, minimizar emissões de CO_2 e maximizar a massa coletada.

A cada nova seleção de intervalos de datas, forma-se um cenário logístico distinto, no qual a demanda, a disponibilidade de veículos e a ordem de atendimento dos PEVs variam. Essa incerteza dificulta o planejamento e afeta diretamente os custos, os indicadores ambientais e a eficiência das operações, aspectos que estão intrinsecamente ligados aos pilares econômico, ambiental e social da logística reversa.

Nesse contexto, a complexidade logística intensifica-se progressivamente: a vinculação dinâmica de cidades aos respectivos períodos, a definição do mix de veículos a empregar e a mensuração dos indicadores de desempenho convergem para um problema de elevada dificuldade operacional e analítica.

1.2 Justificativa

O Brasil enfrenta sérios desafios no cumprimento das políticas de resíduos sólidos e na efetiva implementação da LR, o que impacta negativamente aspectos econômicos, sociais e ambientais do país (BOUZON *et al.*, 2016). Além da fragilidade na aplicação da Política Nacional de Resíduos Sólidos (BRASIL, 2010), as incertezas inerentes ao fluxo de retorno de REEE, tanto em volume quanto em distribuição espacial e temporal, complicam o processo decisório do gestor logístico, que deve conciliar prazos, custos operacionais e metas de

sustentabilidade em um ambiente estocástico e dinâmico (AGRAWAL *et al.*, 2015; GOVINDAN *et al.*, 2018)

Na prática, a simulação a eventos discretos (SED) tem sido utilizada para testar, em ambiente computacional, diferentes políticas operacionais antes de sua implementação, permitindo analisar cenários "*what if*" e observar o comportamento de sistemas complexos sob variabilidade operacional (Law, 2015; Helleno *et al.*, 2015). Entretanto, em problemas de roteamento e alocação de frotas em logística reversa, que envolvem vários pontos de coleta, tipos de veículos e restrições operacionais, o número de combinações possíveis cresce de forma exponencial. Nesses casos, torna-se inviável explorar exaustivamente todas as alternativas de decisão por meio de simulações isoladas. A Otimização via Simulação (OvS) passa, então, a ser uma estratégia promissora, pois orienta a busca por soluções satisfatórias em tempo limitado e permite explicitar os compromissos entre múltiplos objetivos (Amaral *et al.*, 2022; Lin e Chen, 2015). Revisões recentes indicam que essa interface entre OvS e logística reversa de REEE ainda é pouco explorada:

- Abid e Mhada (2021) evidenciaram que métodos determinísticos não consideram adequadamente a variabilidade de retornos de REEE, enquanto frameworks OvS oferecem políticas operacionais mais robustas em LR urbana;
- De Alcântara *et al.* (2025) destacaram a escassez de métodos OvS verdadeiramente multiobjetivo capazes de gerar fronteiras de Pareto em cenários estocásticos complexos.
- Além disso, Santoso *et al.* (2005) e Tordecilla *et al.* (2021) reforçam a necessidade de integrar técnicas de otimização meta-heurística a modelos de simulação para tratar efetivamente a incerteza e a dinâmica das operações reversas.

Diante desse cenário, a presente tese justifica-se por preencher as seguintes lacunas:

1. Framework multiobjetivo OvS para REEE: desenvolvimento e validação de um modelo de SED que combine objetivos de custo, emissão de CO_2 e eficiência de coleta na Região Metropolitana de São Paulo;
2. Integração de Algoritmo Genético e Otimização via Simulação: incorporação de um GA híbrido com a OvS para construir soluções de forma eficiente em sistemas estocásticos;
3. Validação empírica em cenários reais: aplicação do modelo a conjuntos dinâmicos de intervalos de datas e frotas heterogêneas, demonstrando ganhos operacionais e ambientais superiores a abordagens puramente heurísticas ou determinísticas.

Com isso, este trabalho busca fornecer ao gestor de LR uma ferramenta de apoio à decisão que seja simultaneamente flexível, escalável e alinhada aos princípios de sustentabilidade e conformidade regulatória.

1.3 Problema de pesquisa e objetivos

Considerando as lacunas identificadas na literatura em especial a escassez de estudos que combinem otimização multiobjetivo e simulação a eventos discretos em logística reversa de REEE, tratando simultaneamente custo, emissões de CO_2 e quantidade coletada esta tese busca responder à seguinte pergunta de pesquisa: como a otimização multiobjetivo via simulação aplicada à logística reversa pode contribuir para decisões mais eficazes por parte do gestor, diante da incerteza dos volumes de retorno e dos limites ambientais de emissões de CO_2?

Nesse contexto, o objetivo geral desta pesquisa é desenvolver e validar uma ferramenta de otimização multiobjetivo via simulação, demonstrando sua aplicabilidade e eficiência na resolução de problemas da logística reversa, com foco na coleta de REEE. Pretende-se, assim, analisar criticamente os pontos fortes e fracos dessa abordagem, ressaltando sua contribuição como apoio à decisão em sistemas de LR e validando sua aplicabilidade prática.

Para alcançar o objetivo geral, estabelecem-se os seguintes objetivos específicos:

1. Realizar uma Revisão Sistemática da Literatura (RSL), a fim de identificar o estado da arte sobre a aplicação da otimização multiobjetivo via simulação na logística reversa de REEE.
2. Desenvolver um modelo de simulação de eventos discretos (SED) que represente o processo de logística reversa considerado, contemplando suas restrições e variáveis operacionais.
3. Definir e implementar um algoritmo de otimização para o roteamento multiveículo no processo de logística reversa.
4. Integrar o algoritmo de otimização ao modelo de simulação, compondo uma abordagem de Otimização via Simulação (OvS) de natureza multiobjetivo.
5. Aplicar e validar a abordagem proposta em estudo de caso real, avaliando indicadores econômicos, ambientais e operacionais relevantes para a logística reversa.
6. Sintetizar e discutir os resultados obtidos, traduzindo os pontos fortes e as limitações da abordagem em recomendações práticas de uso da ferramenta e de políticas de coleta para sistemas de logística reversa.

1.4 Delimitação e Contribuições do trabalho

Esta pesquisa delimita-se à análise do fluxo de REEE provenientes de pontos de entrega voluntária localizados na Região Metropolitana de São Paulo, vinculados a uma empresa multinacional do setor eletroeletrônico, cuja base operacional se situa no município de Sorocaba. O estudo não contempla outros tipos de resíduos nem etapas posteriores à coleta, como reciclagem ou disposição final. A abordagem proposta considera simultaneamente aspectos econômicos, ambientais e operacionais da logística reversa, integrando a simulação a eventos discretos com técnicas de otimização multiobjetivo, por meio da aplicação de algoritmo genético. Tal delimitação justifica-se pela necessidade de desenvolver soluções que aprimorem o planejamento das rotas de coleta, reduzam custos operacionais e impactos ambientais e aumentem a eficiência do sistema, atendendo às demandas específicas do parceiro empresarial e contribuindo para os objetivos da logística reversa.

As contribuições deste estudo são tanto teóricas quanto práticas. Do ponto de vista teórico, o trabalho avança sobre uma lacuna ainda pouco explorada na literatura: a integração entre modelos de roteamento de veículos com frota heterogênea para logística reversa de REEE e técnicas de otimização multiobjetivo acopladas à simulação a eventos discretos. O framework de OvS proposto combina essas duas vertentes em um único modelo, permitindo construir e avaliar, em ambiente estocástico, conjuntos de soluções que explicitam os *trade-offs* entre custo, emissões de CO_2 e quantidade coletada. Na prática, o modelo desenvolvido é aplicável diretamente a situações reais, permitindo melhorias significativas na tomada de decisões estratégicas por gestores logísticos, especialmente no gerenciamento da complexidade associada à operação da logística reversa, contribuindo para a redução dos custos operacionais, a diminuição das emissões de CO_2 e o aumento da eficiência da coleta.

1.5 Estrutura do trabalho

Esta tese tem cinco capítulos. O primeiro capítulo é uma introdução que apresenta o contexto, justificativas, problema de pesquisa, objetivos, delimitação e contribuição do trabalho e estrutura da tese. O segundo capítulo aborda a fundamentação teórica, incluindo logística, logística reversa, simulação e otimização via simulação aplicada à logística reversa, além de apresentar a RSL sobre o tema. O capítulo três apresenta o método de pesquisa e classificação. O quarto capítulo apresenta a abordagem proposta e os resultados parciais da aplicação em estudos teóricos e reais. O capítulo cinco traz as conclusões da pesquisa, seguido pelos anexos e fontes de consulta.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção, será abordado o referencial teórico desta tese, sintetizando o estado da arte sobre o conceito de Logística, logística reversa, simulação, SED e OvS. Para tal, uma RSL abordando o uso da otimização multiobjetivo via simulação para auxílio nas decisões da LR foram considerados, ao qual se utilizou das principais bases de dados, como *Scopus, Science Direct, Web of Science* e *Scielo.*

Para iniciar a fundamentação teórica, serão apresentados os principais conceitos sobre logística, destacando suas características e fluxo logístico. Posteriormente, explorou-se o conceito de logística reversa, bem como as etapas do fluxo direto e reverso deste processo logístico. Além disso, foram apresentadas algumas tendências, vantagens e desvantagens sobre a área em questão. No que diz respeito a simulação, foram exploradas: conceitos e definições gerais sobre a simulação, os tipos de simulações existentes, vantagens e desvantagens que a simulação pode proporcionar. Em seguida, uma apresentação dos principais conceitos relacionados à SED, destacando principalmente as características da técnica, bem como as fases de implementação.

Em relação à OvS, foram apresentados os principais conceitos para otimização mono e multiobjetivo, seu princípio de funcionamento, as principais técnicas e procedimentos de otimização, os principais softwares de otimização existentes no mercado, e, por fim, o método para utilização da OvS.

Por fim, as seções finais apresentam os resultados obtidos pela RSL, abordando o uso da otimização multiobjetivo via simulação aplicada à logística reversa. A partir destes resultados, nota-se que existem vantagens, limitações e oportunidades em destaque sobre a área.

2.1 Contextualização da Logística

Considerando a ampla difusão do termo "logística" na literatura, surge a necessidade de compreender sua origem. Em busca dessa resposta, os autores, Mangan e Lalwani (2016) destacam que a origem do termo logística se firmou na língua inglesa durante século XIX, devido a sua aplicação no ramo militar, pois havia uma preocupação dos comandantes em relação à organização e movimentação do alojamento e fornecimento de tropas e equipamentos.

Embora os autores expliquem sua origem, ainda ficam algumas dúvidas sobre o que é logística. Neste sentido, Martin (2011) define logística como o processo de gerenciar estrategicamente a aquisição, movimentação e armazenamento de materiais, peças e estoques acabados por meio da organização e seus canais de marketing de tal forma que a lucratividade atual e futura seja maximizada por meio do custo benefício eficaz de pedidos.

Já o *Council of Supply Chain Management Professionals* destaca a logística como processo de planejamento, implementação e controle do fluxo eficiente e eficaz de mercadorias, serviços e das informações relativas desde o ponto de origem até o ponto de consumo com o propósito de atender às exigências dos clientes (CSCMP, 2022).

Ballou (2005) sugere que a logística é igualmente um processo, isto é, inclui todas as atividades importantes de bens e serviços direcionado aos consumidores quando e onde estes quiserem adquiri-los. Para o autor, a definição da logística não sugere o processo inteiro, mas sim partes do processo da cadeia de suprimentos.

Farahani *et al.* (2011) enfatizam que o processo logístico tem como o objetivo a obtenção da quantidade e a qualidade certa de materiais (ou serviços) no lugar certo, na hora certa, para o cliente certo e pelo preço certo. Além disso, esse processo logístico se preocupa com dois tipos de fluxos, ou seja, o fluxo físico ou direto e o informacional, conforme ilustrado pela Figura 1.

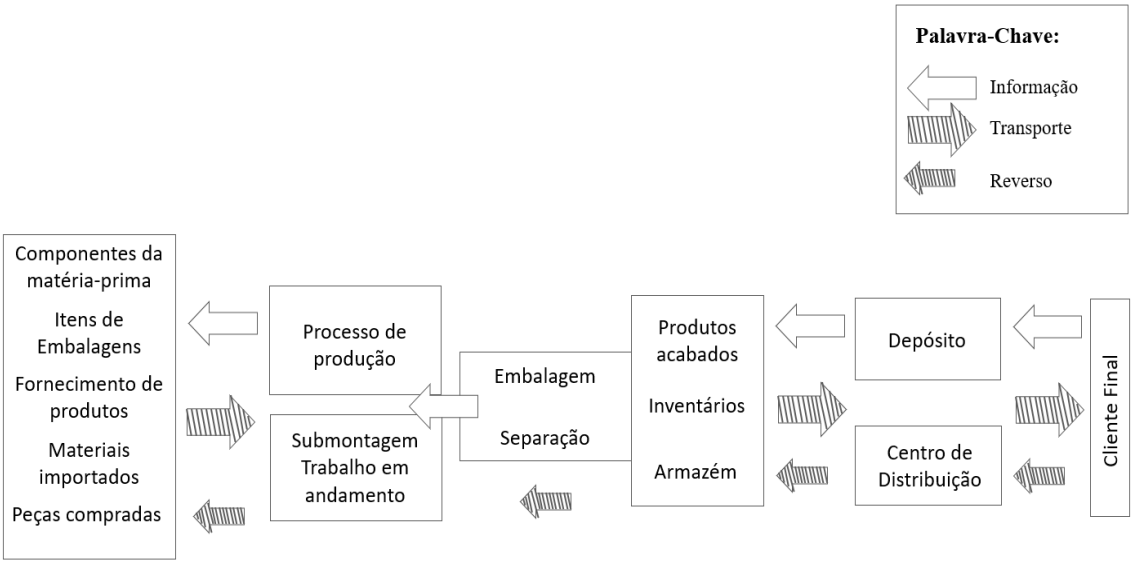

Figura 1 – Fluxo logístico
Fonte – Adaptado de Farahani *et al.*, (2011)

Nota-se, na Figura 1, que esses fluxos estão associados à rede logística. O fluxo físico liga o ponto de origem ao ponto de consumo, enquanto o fluxo de informações percorre o caminho inverso. Considerando o fluxo físico, verifica-se que ele atravessa todo o processo e as atividades dos sistemas logísticos, cujas principais áreas incluem o desenho da rede, a gestão da informação, o transporte, o controle de estoques, a armazenagem, o manuseio de materiais e a embalagem. Destaca-se especialmente, neste contexto, o conceito de logística reversa (LR), tema central deste estudo. A LR envolve o gerenciamento estratégico do fluxo inverso, ou seja, quando mercadorias devolvidas, produtos usados ou embalagens retornáveis precisam retornar ao sistema produtivo para recuperação, descarte adequado, reciclagem ou reaproveitamento.

Essa abordagem é fundamental diante da crescente preocupação global com a sustentabilidade, especialmente considerando-se o significativo aumento de REEE. A logística reversa permite não apenas reduzir o impacto ambiental desses resíduos, mas também recuperar valor econômico através do reaproveitamento de materiais, fortalecendo simultaneamente a reputação socioambiental das organizações (FARAHANI *et al.*, 2011; BOUZON *et al.*, 2016).

Oliveira (2019) classifica a logística em alguns campos que contemplam a maioria de seus macroprocessos, conforme a Figura 2.

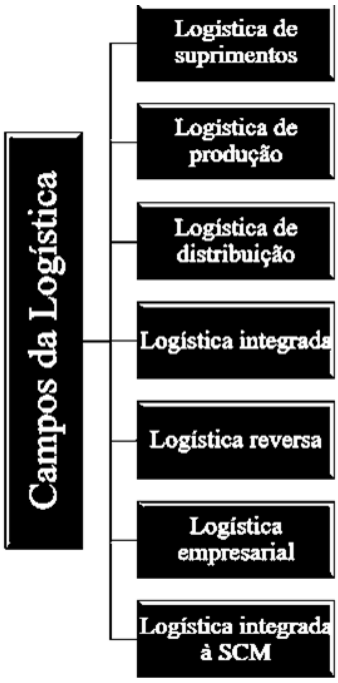

Figura 2 – Campos da Logística
Fonte – Adaptado Oliveira (2019)

Ching (2001) destaca que a logística de suprimentos ou logística *inbound* representa o canal de suprimentos desenvolvido entre a empresa e seus fornecedores com a finalidade de abastecê-la de insumos necessários à viabilização da produção. Já a logística de produção foca nas operações logísticas no âmbito da manufatura/montagem e suas relações com outros setores, tais como: recebimento, armazenagem e distribuição interna de insumos (PORTER, 1985). A Logística de distribuição ou logística *outbound* relaciona-se com a distribuição física dos produtos acabados aos pontos de entrega ou consumo, incluindo comumente atividades de armazenagem (NOVAES, 2007).

A principal função da logística integrada está no vínculo e sincronização de toda CS (cadeia de suprimento) como processo contínuo (BOWERSOX, CLOSS e COOPER, 2012). Para recapturar, criar valor ou realizar eliminação apropriada tem-se a logística reversa, ao qual visa planejar, implementar e controlar a eficiência do fluxo de materiais, estoque em processo, produtos acabados e informações, a um custo adequado, do ponto de consumo ao ponto de

origem (ROGERS e TIBBEN-LEMBKE, 2001). A logística empresarial traz um conjunto de atividades sistemáticas e coordenadas requeridas para providenciar a movimentação física e armazenagem de produtos das instalações dos fornecedores ao mercado consumidor eficientemente (CSCMP, 2013). Por fim, a logística integrada à gestão da cadeia de suprimentos, ou *Supply Chain Management* (SCM), preocupa-se com o relacionamento entre o ponto de origem e o ponto de consumo em atendimento às necessidades dos clientes, visto que o subgrupo SCM planeja, implanta e controla de forma eficiente e efetiva os fluxos diretos e reversos e a armazenagem de bens, serviços e informações (CSCMP, 2013).

Dentre os campos listados da logística, nota-se que a LR vem ganhando bastante destaque no cenário atual. Govindan et al. (2016) destacam que a LR é uma das áreas relativamente significativa discutida em assuntos relacionados à logística e gestão da cadeia de suprimentos em diversos setores. Ao observar a literatura, notam-se diversos trabalhos estão sendo voltados para o campo da LR como destacado por Van Engeland et al., (2020), em que aponta as áreas de roteamento de localização, localização de instalação, questões gerais sobre LR, projeto de rede em logística reversa e projeto de rede em gestão de resíduos com abordagem matemática ou sem.

Rachih, Mhada e Chiheb (2019) apresentam estudos focados em problemas e metodologias para solucionar as adversidades enfrentadas pela LR, bem como problemas de otimização combinatória que vem ganhando interesse por pesquisadores devido à importância na ciência e na indústria. Hosseini et al. (2015) retratam uma revisão de literatura sobre a logística reversa na construção, de tal forma, a impulsionar estudos sobre os stakholders da indústria e a comunidade da construção em geral, bem como difundir as vantagens e barreiras, tendências de pesquisa e pesquisa futuras sob a revisão levantada. Estudos mais recentes, como Radwan et al., (2025) e Valase e Kaur (2026) confirmam essa tendência de crescimento, evidenciando a consolidação da LR como tema atual na agenda de pesquisa em logística e SCM.

A logística reversa tem se tornado um fator decisivo para as organizações, pois trata de uma das diversas áreas que motivam investigações de melhoria para inúmeras dificuldades presentes neste domínio, isto devido à associação deste campo e os impactos ambientais, sociais e econômicos dessas empresas. Logo, o presente trabalho será focado especificamente na área destacada por Farahani *et al.* (2011), ao qual se trata de transportes da logística reversa.

2.1.1 Logística reversa

A LR vem recebendo atenção devido ao seu potencial de recuperação do valor dos produtos usados (POKHAREL e MUTHA, 2009). Zhang *et al.* (2020) ressaltam que isso ocorre devido ao poder de recuperação de produtos em fim de vida, atendendo as exigências

ambientais, direitos e interesse. Com isso, a LR foi foco de diversos trabalhos e ampliou suas definições com o passar do tempo (AGRAWAL, SINGH e MURTAZA, 2015).

Em um mundo cada vez mais consciente dos limites dos recursos naturais, a logística reversa se apresenta como um dos pilares centrais da sustentabilidade corporativa e ambiental. Ao promover o retorno de produtos, materiais e componentes para reuso, remanufatura ou reciclagem, a LR reduz significativamente a extração de novas matérias-primas, diminui a geração de resíduos e mitiga emissões de gases de efeito estufa ao evitar ciclos produtivos completos (BANGUERA ARROYO *et al*., 2023). Além disso, ao recuperar valor econômico de itens que seriam descartados, a LR cria novas fontes de receita e reduz custos de disposição final, reforçando a viabilidade financeira das operações (ALI *et al*., 2018). Por fim, ao engajar consumidores, cooperativas de triagem e pequenas indústrias de reciclagem, a LR contribui para a geração de empregos locais e para o fortalecimento da consciência social sobre consumo e descarte responsáveis, alinhando-se aos três pilares da sustentabilidade: ambiental, econômico e social (TEMITAYO OLUWADAMILOLA ADESOGA *et al*., 2024).

Aït-Kadi *et al.*, (2012) e van Engeland *et al.*, (2020) definem a LR como o processo de planejamento, implementação, controle de fluxo eficiente e economia de matérias-primas, estoque de processo, produtos acabados e informações relacionadas do ponto de consumo ao ponto de origem com o objetivo de recapturar ou criar valor de descarte adequado do produto.

Para ilustrar um fluxo típico de logística reversa, voltado à recaptura de valor ou ao descarte ambientalmente adequado de um produto, a Figura 3 apresenta um esquema de devolução, em que as linhas pontilhadas indicam o percurso de retorno.

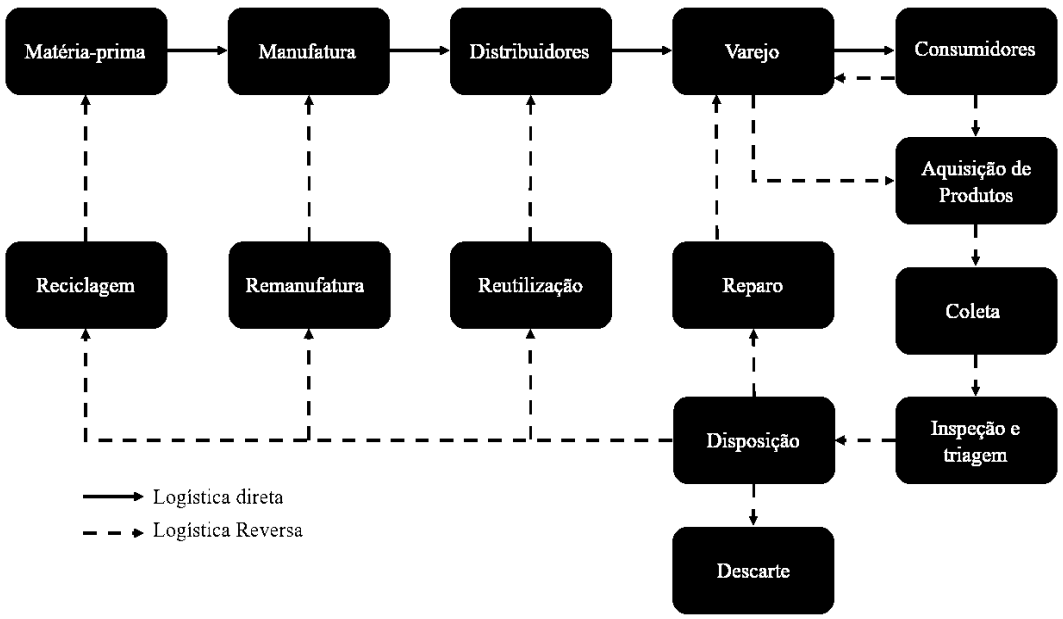

Figura 3 – Fluxo da logística direta e reversa
Fonte – Adaptado de AGRAWAL e SINGH (2019)

Ao observar a Figura 3, nota-se que o processo de logística reversa começa pelos consumidores, onde os produtos passam pela fase de coleta ao qual vão ser descartados. Em seguida, a inspeção e triagem realiza uma avaliação nos produtos descanteados, e passam para a disposição, que existem alguns cominhos para o descarte do produto, ou seja, o rejeite pode seguir as opções de reciclagem, remanufatura, reutilização e reparo, bem como o descarte direto do produto (AGRAWAL e SINGH, 2019).

Neste sentido, a LR mostra-se um caminho alternativo para mitigar os impactos ambientais associados ao descarte de produtos, uma vez que seu objetivo é recapturar valor ou garantir uma destinação final ambientalmente adequada para itens já utilizados. Além disso, Waters (2003) descreve fatores que impulsionaram a difusão da LR, como globalização, número reduzido de fornecedores, concentração de propriedades, adiamento da terceirização, *cross-docking*, entrega direta, outros métodos de redução de estoque, crescentes preocupações ambientais e maior colaboração ao longo da cadeia de abastecimento.

Além das tendências, Jayaraman e Luo (2007) evidenciam algumas vantagens competitivas tangíveis e intangíveis que as organizações podem obter sobre a estratégia da logística reversa, de tal modo a melhorar significativamente o desempenho financeiro da organização, recuperando o valor do produto usado, reduzindo da responsabilidade futuras como taxas de seguro e custos de descartes de clientes, bem com a conscientização ambiental entre clientes, fornecedores e organizações.

Em adição aos benefícios, Jaillon e Poon (2014) e Hosseini *et al.* (2015) destacam que ao se adotar a logística reversa na indústria, a organização aumentará suas vantagens de responsabilidade social que estão associadas as dimensões ambientais, econômicas e sociais. A dimensão ambiental enfatiza a gestão de recursos naturais, enquanto a econômica evidência a gestão do custo-benefício, e por fim, a social que está relacionada a gestão de recursos sociais, incluindo habilidades de pessoas, instituições e valores sociais (AHMED e MCQUAID, 2005; SARKIS, HELMS e HERVANI, 2010).

Em contrapartida, Agrawal, Singh e Murtaza (2015) pontam que a literatura sobre logística reversa ainda apresenta diversas lacunas. Segundo os autores, são raros os estudos voltados a setores como petróleo e gás, bens de consumo e plásticos, bem como pesquisas que tratem de forma mais rigorosa a previsão de devoluções. Há carência de análises que evidenciem o papel de atividades como coleta, transporte, reutilização, reciclagem, reparo e remanufatura no apoio à tomada de decisão. Os autores também indicam oportunidades pouco exploradas, como o uso de abordagens baseadas em teoria do caos, modelos de simulação para projetar redes de logística reversa, estudos sobre o mercado secundário de revenda e

comparações entre diferentes configurações de redes reversas. Por fim, ressaltam a necessidade de modelos de apoio à decisão, tanto operacional quanto estratégico, para a escolha das alternativas de disposição mais adequadas.

2.1.2 ESG e ODS em Logística Reversa

A logística reversa, quando pensada pelos critérios ESG (*Environmental*, *Social* e *Governance*), torna-se muito mais do que um simples fluxo de retorno de produtos: ela se transforma em um mecanismo formal de governança e reporte de impactos socioambientais. No aspecto E (*Environmental*, ambiental), práticas como coleta de REEE e reciclagem de materiais valiosos estão diretamente ligadas às metas do ODS 12 (Consumo e Produção Responsáveis) e do ODS 13 (Ação Contra a Mudança Global do Clima), garantindo a redução de resíduos e emissões por meio de processos ótimos de remanufatura e reuso (JÚNIOR *et al*., 2024).

Já o pilar S (Social) ganha vida na inclusão de cooperativas de catadores e no fortalecimento de empregos verdes, traduzindo-se em contribuições para o ODS 8 (Trabalho Decente e Crescimento Econômico) e para o ODS 11 (Cidades e Comunidades Sustentáveis), ao promover redes de coleta que engajam comunidades locais e geram renda (BANGUERA ARROYO *et al*., 2023). Por fim, o G (governança), reflete-se em sistemas transparentes de monitoramento e auditoria dos fluxos reversos, permitindo às empresas reportar seu desempenho em sustentabilidade com base em indicadores claros e auditáveis (ODS 16) (TEMITAYO *et al*., 2024).

Butt *et al*. (2024) investigam como grandes varejistas estabelecem sistemas robustos de logística reversa, alinhando suas operações a padrões ambientais desejáveis, estabelecendo práticas que minimizam o impacto negativo no meio ambiente. Esses sistemas permitem a recuperação eficiente de produtos, contribuindo para a redução de resíduos e promovendo a reutilização de materiais, essencial em uma economia circular. Além do aspecto ambiental, os varejistas buscam cumprir objetivos sociais e de governança, indo além da simples conformidade regulatória. Butt *et al.* (2024) mostram que, ao integrar práticas de logística reversa com os ODS, as empresas fortalecem sua responsabilidade social, promovendo iniciativa de inclusão e transparência, beneficiando a sociedade e reforçando sua sustentabilidade e competitividade no mercado.

2.1.3 Problema de roteamento de veículo em Logística Reversa

A LR envolve o gerenciamento do fluxo de produtos após o consumo, trazendo-os de volta à origem. Isso inclui atividades como coleta, armazenamento, triagem e processamento

desses itens. Nesse cenário, o Problema de Roteamento de Veículos (VRP) é fundamental, pois determina como planejar rotas eficientes para uma frota limitada, levando em consideração pontos espalhados e respeitando restrições de capacidade e tempo. Ao mesmo tempo, busca-se otimizar custos, qualidade do atendimento e sustentabilidade. Diferente da logística direta, a LR é mais desafiadora devido às maiores incertezas relacionadas à quantidade, à qualidade e ao momento das devoluções, o que aumenta bastante a complexidade do planejamento (LAPORTE, 2009; TOTH; VIGO, 2014).

No caso de REEE, esse desafio ganha urgência: o *Global E-waste Monitor 2024* reporta geração global de 62 Mt em 2022 e tendência de atingir 82 Mt em 2030, com taxas documentadas de reciclagem ainda aquém da necessária, pressão adicional por rotas eficientes e maior cobertura de atendimento (ITU; UNITAR, 2024). Em termos práticos, isso implica combinar eficiência econômica com metas ambientais e regulatórias, em cenários com forte heterogeneidade espacial das coletas.

Conectando teoria e prática, a versão do VRP que costuma descrever a LR é o HFVRP (problema de roteamento de veículos com frota heterogênea) com *pickups* e janelas de tempo, ou seja, uma frota heterogênea que realiza coletas nos pontos e retorna ao depósito. Recentemente, estudos sobre LR e VRP vêm avançando bastante, e já sistematizaram 109 artigos publicados entre 2000 e 2022. Esses trabalhos abordam diferentes modelagens, técnicas de solução e até questões de sustentabilidade, formando um guia atualizado para quem precisa definir escopo, objetivos e dados na área (SAR; GHADIMI, 2023). Ao mesmo tempo, a literatura atual reforça que o conceito de "VRP verde" deixou de ser apenas um nicho para se tornar um tema consolidado na pesquisa, com foco ampliado para emissões, consumo de energia e *trade-offs* em múltiplos objetivos (GARSIDE; DEMIREL; ERDOGAN, 2024).

Para formalizar esse problema de roteamento com frota heterogênea, adotamos uma notação padrão de VRP. Do ponto de vista formal, usamos um grafo $G = (V, A)$, depósito 0, clientes $V\backslash\{0\}$ e frota k. Parâmetros incluem demanda d_i, capacidade Q_k, custo c_{ij}, emissões e_{ij}^k, tempos t_{ij} e janelas $[a_i, b_i]$. As decisões $x_{ij}^k, y_i^k, u_i^k, s_i$ permitem formular objetivos de custo, emissões e massa coletada. Para janelas e tempos variáveis, revisões recentes de VRP dependente do tempo cobrem previsão de viagens e reotimização em tempo real, alinhando o modelo às condições dinâmicas observadas em LR urbana (ADAMO; DELL'ORCO; PERSIANI, 2024). Mantem-se apenas dois marcos clássicos como referência conceitual: MTZ para subtours e janelas/benchmarks. (ADAMO; DELL'ORCO; PERSIANI, 2024).

As medições operacionais precisam refletir a realidade dos dados. As distâncias calculadas por matrizes geodésicas alimentam o custo $c_{ij} = custokm(k) * dist_{ij}$; Quanto às emissões, elas podem ser estimadas de duas formas: usando fatores médios de emissão em g/km, específicos para cada tipo de veículo, uma abordagem transparente e fácil de aplicar em níveis municipais ou por meio de modelos que consideram variáveis como velocidade, carga e consumo, semelhantes aos utilizados no campo do Green/Low-carbon VRP. As revisões atuais ajudam a determinar o nível de detalhamento ideal, levando em conta a disponibilidade de dados e a sensibilidade ambiental do estudo. (ASGHARI; ZOLFAGHARI; AGHAY KHAZAEI, 2021; GARSIDE; DEMIREL; ERDOGAN, 2024).

Quanto aos métodos de solução, a prática de LR demanda escalabilidade. Em vez de exatos puros, predominam meta-heurísticas e estruturas híbridas. Além de guias recentes sobre heurísticas de VRP, um avanço útil é a sistematização dos operadores de ALNS (busca em vizinhança de grande porte adaptativa) baseados em rotinas de remoção e inserção, com evidências do que funciona melhor em diferentes variantes insumo direto para construir um solver robusto para LR (LIU *et al*., 2023; VOIGT; MONTOYA-TORRES; SEPÚLVEDA-GARCÍA, 2025).

Complementarmente às meta-heurísticas como a ALNS, há situações em que apenas otimizar a rota não é suficiente, pois tempos de serviço, filas e janelas de atendimento variam de forma significativa na operação real de LR. Nesses casos, quando se busca robustez frente às variações de tempos de serviço, esperas e janelas, a estratégia de Otimização via Simulação (OvS) permanece atual, mas com ecossistema renovado: tutoriais WSC 2023–2024 mostram avanços em meta-modelagem, alocação de orçamento e incerteza de entrada, facilitando comparar soluções de Pareto “no mundo simulado” antes da escolha final (CORLU *et al*., 2023; LAM, 2024).

2.2 Simulação

2.2.1 Conceitos e definições gerais sobre a simulação

A simulação é uma das principais técnicas de Pesquisa Operacional, com aplicações cruciais em planejamento e otimização de cadeias logísticas (incluindo roteirização de transportes, gestão de estoques e distribuição física), além de manufatura, finanças, serviços e operações militares (LAW 2014). Banks (1998) destaca que essa técnica se baseia na imitação de um ou mais sistemas reais por meio de modelos computacionais, ao qual pode-se inferir sobre os sistemas a partir de simulações. Miranda *et al.* (2017) ressaltam que desde a criação

nos anos de 1950s, a simulação vem sendo aplicada com sucesso para melhoria em processos, modelagem e análise de sistemas complexos que são analiticamente intratáveis.

A simulação por meio da modelagem de processos se tornou um campo de destaque para a engenharia, serviços de saúde, telecomunicações, militares, transporte, dentre outras (FISHMAN, 2001). Além disso, o autor ressalta que essa modelagem consegue oferecer respostas para tomada de decisões em sistemas complexos a um custo baixo. Chwif e Medina (2015) enfatiza que apesar da complexidade dos sistemas reais devido a sua natureza dinâmica e aleatória, a simulação alcança com fidelidade suas principais características e comportamentos, contribuindo com a tomada de decisão mais eficiente e eficaz.

De acordo Chwif e Medina (2015), a simulação pode ser classificada em algumas técnicas básicas que representam o tempo e estado, como: Simulação de Monte Carlo, Simulação Contínua (SD) e Simulação a Eventos Discretos (SED). A simulação de Monte Carlo utiliza números aleatórios para simular um sistema físico e matemático, de modo a estar fora do comportamento do sistema ao longo do tempo. Já a simulação contínua aborda um comportamento temporal em que considera a mudança de estado de um sistema em um intervalo de tempo contínuo. Por outro lado, a simulação a eventos discretos refere-se a mudanças de estado de um sistema, em intervalos discretos de tempo, a partir de ocorrência de eventos (NANCE e SARGENT, 2002; LAW, 2014; CHWIF e MEDINA, 2015).

Macal e North (2014) destacam a existência da Simulação Baseada em Agentes (SBA) que se trata de uma modelagem composta por agentes individuais, autônomos e interativos, isto é, os agentes geralmente representam pessoas ou grupos aos quais interagem entre si, podendo ser de natureza contínua ou discreta. Scheidegger *et al.*, (2018), relatam que as técnicas de simulação em destaque no campo da engenharia industrial e áreas afins, são consideradas a simulação a eventos discretos, baseados em agentes e dinâmica de sistemas.

Em suma, Jeon e Kim (2016) e Kaur e Mittal (2014) ressaltam que a modelagem e simulação constituem uma abordagem adequada para representar processos complexos, incorporando suas configurações e restrições. Esses autores enfatizam que a simulação permite estudar o comportamento do sistema sob diferentes fontes de incerteza e em múltiplos cenários. Pereira *et al.* (2015) e Furthermore e Shannon (1998), pontuam vantagens de se aplicar a simulação, tais como:

- A exploração de *layouts* e *designs* sem comprometer ou desperdiçar recursos para implementação.
- Aplicação de novas políticas de estoque, procedimentos operacionais, regras de decisão e fluxo de informações, sem interromper o funcionamento real do sistema.

- Alteração do tempo, isto é, ao ser executados modelos de simulação por meses ou anos em questão de minutos, permitindo uma análise rápida de longos períodos ou desacelerando o modelo para ver a dinâmica do sistema.
- Reconhecimento de gargalos nos fluxos de informações, materiais e/ou produtos, possibilitando testar opções para melhorá-los.
- Aquisição de conhecimento valioso sobre como o sistema modelado funciona e entender por que certas variáveis são importantes para o desempenho.

Dentro do contexto da LR, a simulação traz benefícios ainda mais direcionados ao gestor logístico como:

- Teste de políticas de coleta e roteirização reversa sem interromper operações reais, permitindo comparar diferentes estratégias de consolidação de devoluções e dimensionamento de veículos (RODRIGUES *et al*., 2025).
- Avaliação do impacto econômico e ambiental de cada rota reversa, quantificando custos de transporte, emissão de CO_2 e tempo de processamento em centros de triagem (RAVICHANDRAN *et al*., 2023).
- Análise de cenários "what-if" para flutuações de volume de devolução, identificando gargalos e testando regras de prioridade de triagem antes de implementar mudanças no sistema real (MONTEVECHI *et al.*, 2010).
- Suporte à decisão sustentável, pois fornece indicadores de desempenho integral (custo, prazo e emissões) para escolher a configuração reversa mais eficiente e alinhada a metas ESG (SUN *et al*., 2024).

Embora a simulação apresente diversas vantagens, também existem limitações que devem ser consideradas. Entre elas, destaca-se o elevado custo da modelagem, que demanda tempo significativo para ser desenvolvida de forma adequada. Além disso, erros humanos podem comprometer a representação do modelo, reduzindo sua utilidade prática. Outro ponto crítico é a necessidade de treinamento especializado para a construção e operação dos modelos, visto que a precisão e a integridade das suposições influenciam diretamente a validade dos resultados. Por fim, a aplicação da simulação em sistemas complexos pode se tornar ainda mais desafiadora, dificultando a obtenção de resultados confiáveis (BANKS *et al.*, 2005 e LAW & KELTON, 2000).

Mesmo a simulação tendo seus prós e contras, Rodič (2017) considera que a técnica vem se consolidando durantes as últimas décadas nos mais diversos setores e áreas de atuação, devido a suas diferentes abordagens. Dentre essas diversas abordagens, existem a integração de ferramentas com à simulação, também conhecida como abordagem híbrida, ao qual possibilita

melhores tomadas de decisão (NEGAHBAN e SMITH, 2014). Entre as abordagens híbridas, podem ser utilizadas em conjunto com a simulação as técnicas de otimização, ferramentas de previsão, algoritmos de inteligência artificial, entre outros (MOURTZIS, 2020).

Neste sentido, nota-se que a simulação evoluiu durante as últimas décadas, tornando uma ferramenta focada em tomadores de decisão e não somente a especialista (URIARTE, NG e MORIS, 2018). Tendo em vista os tipos de simulação, Scheidegger *et al.* (2018) e Uriarte, Ng e Moris (2018), salientam que a SED é técnica de simulação mais adotada, devido ao grande número de aplicações listadas na literatura. Logo, o presente trabalho será focado especificamente na SED ou simplesmente como "simulação" e será combinada com a otimização para tratar um problema de logística reversa.

2.2.2 Simulação a Eventos Discretos (SED)

A simulação a eventos discretos (SED) é uma técnica de modelagem usada para simular o comportamento e o desempenho de sistemas complexos ao longo do tempo. Ele modela sistemas como uma sequência de eventos, onde cada evento representa uma mudança de estado. Nesse tipo de simulação, os eventos ocorrem em pontos discretos no tempo, e a ordem e o tempo desses eventos podem afetar o estado do sistema que está sendo modelado (ROBINSON, 2005).

O objetivo da simulação a eventos discretos é obter *insights* sobre o comportamento do sistema, identificar gargalos, otimizar recursos e tomar decisões informadas. A SED é comumente usado em campos como pesquisa operacional, manufatura e logística, para avaliar o impacto de diferentes decisões de projeto e controle no desempenho do sistema (ROBINSON, 2005). De acordo com Banks *et al.* (2009), a SED pode ser descrita como a representação de um processo ou sistema real, com a observação das suas mudanças ao longo do tempo. O autor também destaca que o comportamento do sistema é avaliado com o passar do tempo com a ajuda de um modelo computacional que, uma vez validado, pode responder a várias perguntas do tipo "E se?".

Tako e Robinson (2010) revelam que estes eventos discretos que ocorrem ao longo do tempo possuem representações por meio de entidades individuais (por exemplo: pessoas, equipamentos de transporte e peças) que se movimentam por filas, atividades e locais. Além disso, Opacic e Sowlati (2017) ressaltam que na maioria dos casos, estes eventos retém uma natureza estocástica. Portanto, ao se considerar elaborar um projeto SED, a literatura apresenta incalculáveis métodos disponíveis (Montevechi *et al.*, 2015) e Banks *et al.* (1998) destacam que

as principais fases adotadas no desenvolvimento seguem uma abordagem tradicional, como ilustra a Figura 4.

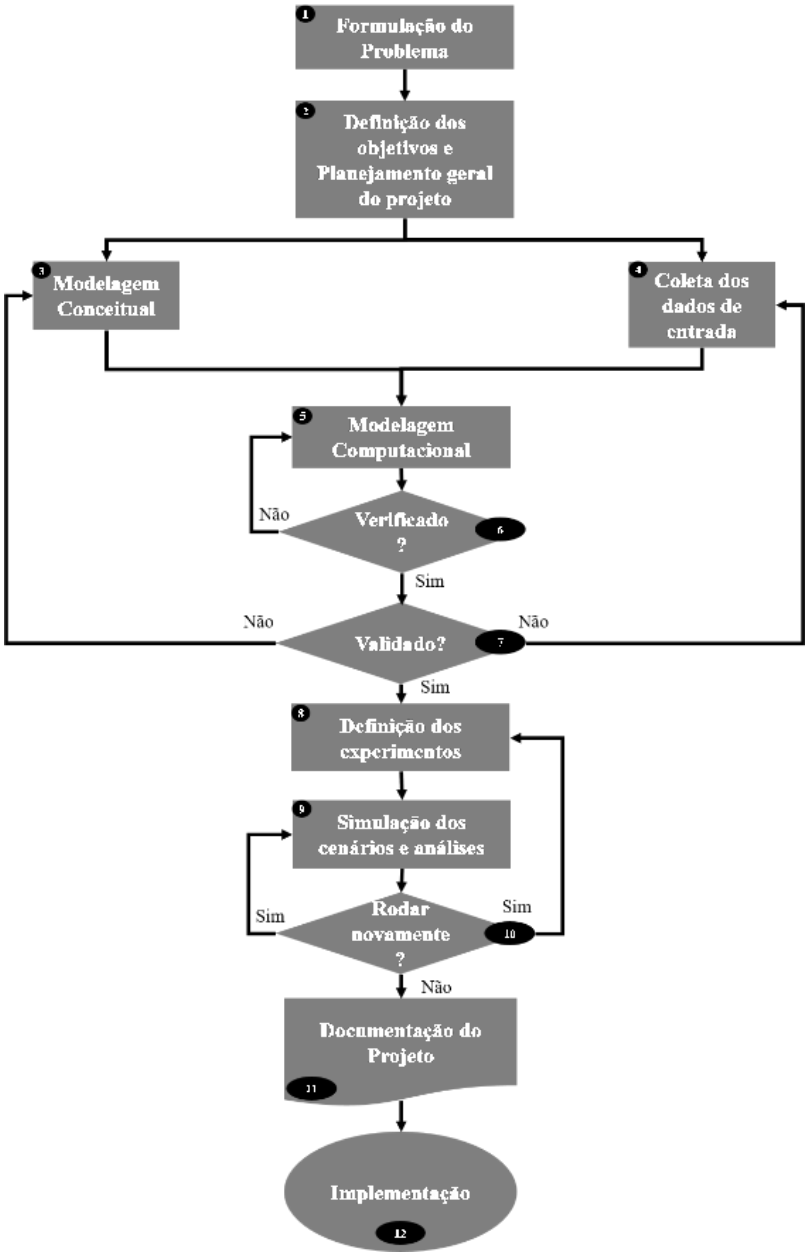

Figura 4 – Fases de desenvolvimento na abordagem tradicional
Fonte – Adaptado de Banks *et al.* (2010)

I. **Formulação do problema:** defini claramente o sistema a ser modelado, os objetivos da simulação e os resultados esperados.
II. **Definição dos objetivos e planejamento geral do projeto:** os objetivos estão relacionados às perguntas que se deseja responder por meio da simulação, enquanto o planejamento geral do projeto foca na estimativa de recursos necessários para sua execução (BANKS *et al.*, 2010; LAW, 2009);
III. **Modelagem conceitual:** a primeira abstração do problema é o modelo conceitual, sendo uma fase crucial para realizar o projeto de simulação, pois será o ponto de partida para

o modelamento computacional (ROBINSON, 2008). Ainda sobre a modelagem conceitual, existem inúmeros métodos e ferramentas para representar o modelo conceitual (GABRIEL *et al.*, 2020);

IV. **Modelagem dos dados de entrada:** trata-se da coleta de informações sobre o sistema, incluindo seus componentes, processos e relacionamentos, bem como distribuições de entrada e métricas de desempenho. Esse processo de identificação e coleta envolve desde a determinação da exatidão, o intervalo de tempo para a amostragem e a formatação dos dados, até a sua aquisição por meio de diferentes métodos (ONGOO e HILL, 2014);

V. **Modelagem computacional:** Esta etapa se trata da tradução do modelo conceitual em uma linguagem de simulação ou modelagem para um simulador. É importante mencionar que os simuladores, os quais são *softwares* específicos para simulação, são dominantes no mercado e tendem a se tornar cada vez mais personalizados e flexíveis para diferentes aplicações (CHWIF e MEDINA, 2015);

VI. **Verificação do modelo:** O propósito da verificação é assegurar que a programação e implementação do modelo computacional estejam precisas, ou seja, conforme as lógicas e normas estabelecidas no modelo conceitual (SARGENT, 2013);

VII. **Validação do modelo:** Sargent (2014) destaca que a validação do modelo visa garantir que seus resultados sejam aceitáveis quanto à precisão e exatidão, bem como adequados para uma determinada finalidade. A técnica a ser utilizada dependerá das características do projeto e da equipe envolvida. (CHWIF e MEDINA, 2015; SARGENT, GOLDSMAN e YAACOUB, 2016);

VIII. **Definição de experimentos:** Balci (2012) diz que a definição dos experimentos é feita após se ter um modelo computacional válido. Nessa etapa, é feito o planejamento da simulação visando obter respostas específicas. Ainda neste ciclo, consideram-se relevantes para cada experimento, assim como as estimativas de custos;

IX. **Simulação de cenários e análise:** Banks *et al.* (2010) destacam que esta etapa se trata do processo de executar experimentos previamente planejados, seguido pela avaliação dos indicadores de desempenho do sistema simulado;

X. **Rodar novamente:** Banks *et al.* (1998) salientam que após avaliar as execuções realizadas, o analista de simulação decide se é necessário realizar mais execuções e se algum outro cenário precisa ser simulado.

XI. **Documentação do projeto:** A documentação adequada em um projeto de simulação é crucial para a comunicação e o aprendizado durante o andamento do projeto. Por meio

dessa documentação possibilita a manutenção, reutilização ou reprodução do modelo de simulação e seus resultados (OSCARSSON e MORIS, 2002; TRIEBIG e KLÜGL, 2009);

XII. Implementação: A última fase de projetos de simulação é sobre a decisão baseada nos resultados alcançados. De acordo com Banks *et al.* (2010), o sucesso desta fase está relacionado com as outras etapas descritas anteriormente e é o motivo principal pelo qual o projeto foi criado.

Ingals (2013) afirma que a SED é uma ferramenta valiosa para apoiar decisões, desde que seja compreendida e utilizada adequadamente. Siebers *et al.* (2010) enfatizam que nos últimos 40 anos, a utilização da SED tem sido uma das principais técnicas empregadas na Pesquisa Operacional.

2.3 Fundamentos de Otimização

2.3.1 Conceitos e definições gerais sobre a otimização

A otimização pode ser entendida como o processo de identificar, dentro de um conjunto de soluções viáveis, aquela que melhor atende a um objetivo específico, seja para minimizar custos, maximizar lucros ou equilibrar parâmetros de desempenho. Esse processo envolve a definição de uma função-objetivo e de um conjunto de restrições, podendo estar associado aos problemas contínuos ou discretos, com ou sem restrições, e de natureza mono ou multiobjetivo (ABRAHAM *et al*., 2025).

Para ilustrar visualmente o conceito de otimização clássico, Dong *et al*. (2021) apresentam em seu trabalho um diagrama de contornos da função-objetivo em conjunto com a região factível, conforme reproduzido na Figura 5.

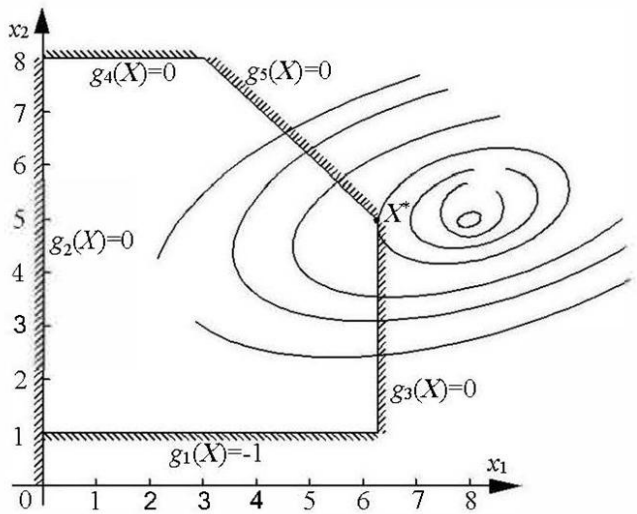

Figura 5 – Linha de contorno da função objetivo e figura geométrica da região viável

Fonte – Dong *et al*. (2021)

Observe que nessa figura estão destacados:

- Contornos da função-objetivo com níveis marcados.
- Região factível delimitada pelas restrições g_i(X), representada por um polígono hachurado.
- Rótulos das restrições g_1 a g_5 posicionados nas arestas correspondentes.
- Ponto ótimo X^* indicado dentro da região.

Ao lidar-se com múltiplos critérios conflitantes, tal como custo versus desempenho ou eficiência energética versus tempo de resposta, entra-se no domínio da otimização multiobjetivo. Nesse caso, não existe uma única "melhor" solução; busca-se, sim, um conjunto de soluções Pareto-ótimas, em que não é possível melhorar um objetivo sem piorar outro (ABRAHAM *et al*., 2025). Com base nos conceitos iniciais de otimização, a seção seguinte apresenta um breve estudo dos métodos categorizados, bem como a taxonomia correspondente dessas abordagens.

2.3.2 Taxonomia do método de otimização

Nesta seção é apresentada a taxonomia da otimização, compreendida como um conjunto de técnicas que auxiliam na seleção do método mais adequado para cada tipo de problema. Abraham *et al.* (2025), apresentam em seu estudo uma classificação segundo cinco dimensões principais, conforme ilustrado na Figura 6: (i) técnica empregada; (ii) tipo de objetivo; (iii) natureza das variáveis; (iv) existência de restrições; e (v) convexidade.

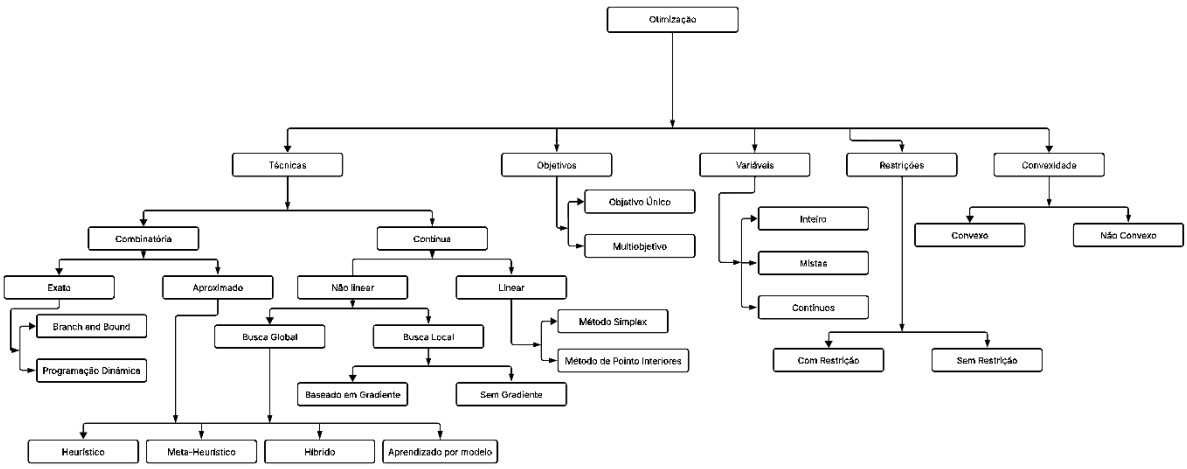

Figura 6 – Taxonomia da Otimização
Fonte – Adaptado de Abraham *et al.* (2025)

Dentre essas dimensões, a primeira refere-se à técnica de otimização a ser utilizada, ao qual depende da natureza das variáveis e da estrutura do problema, nesta classe distinguem-se os métodos:

- Combinatórios: casos em que as decisões envolvem permutações ou atribuições discretas.
    - Os métodos exatos, como Branch & Bound e Programação Inteira, garantem otimalidade, porém têm complexidade exponencial.
    - Os métodos aproximados, reúnem heurísticas clássicas como *Nearest Neighbor* e meta-heurísticas (GA, PSO, ACO), que sacrificam garantias exatas em favor da escalabilidade.
- Contínuos: problemas modelados por variáveis reais.
    - Os métodos Lineares, resolvidos por simplex ou por métodos de pontos-interiores, adequados a funções objetivo e restrições lineares.
    - Os métodos Não-lineares, que empregam métodos de gradiente, Newton ou buscas globais/local, para funções diferenciáveis ou não.

Na segunda dimensão, os problemas de otimização distinguem-se entre monobjetivo e multiobjetivo. Nos casos monobjetivo, busca-se a melhor solução segundo um único critério, abordagem típica em aplicações de planejamento e controle, em que há clareza sobre o que deve ser minimizado ou maximizado. Já na formulação multiobjetivo, considera-se simultaneamente dois ou mais critérios potencialmente conflitantes, de modo a construir o conjunto de soluções de Pareto, no qual qualquer ganho em um dos objetivos somente é possível à custa de perdas em outro. Essa perspectiva permite um entendimento mais amplo das trocas inerentes ao processo decisório, oferecendo ao tomador de decisão alternativas equilibradas entre diferentes metas.

Na terceira dimensão da otimização, as variáveis podem assumir-se como: Contínua, inteiras e mista. Ao caso de serem contínuas, podem assumir qualquer valor real dentro de um intervalo definido. Esse tipo de decisão aparece com frequência em problemas de calibração de modelos físicos ou econômicos, ajuste de parâmetros em funções de resposta e otimização de processos industriais. Se as variáveis forem inteiras, elas podem adotar valores inteiro ou binários, como por exemplo, restrições típicas de roteirização de veículos (SCHEINBERG, 2014). Por fim, ao se falar de variáveis que exploram uma combinação entre contínuas e inteiras, tem-se as varáveis mistas, que está associada a muitos problemas reais e normalmente são solucionados por técnicas que envolvem *Mixed-Integer Programming* (MIP) ou *Mixed-Integer Nonlinear Programming* (MINLP).

A quarta dimensão de um problema de otimização refere-se às restrições que definem o conjunto de soluções viáveis, limitando as variáveis de decisão a um domínio específico. Conforme ilustra a Figura 6, na ausência de vínculos explícitos, o problema se estende por todo o espaço $\mathbb{R}^n$, o que simplifica sua análise, sobretudo quando aplicamos métodos de otimização contínua, como técnicas de gradiente e algoritmos Quase-Newton. Entretanto, essa liberdade pode gerar soluções idealizadas e pouco realistas para aplicações práticas, já que, na maioria dos casos, existem limites físicos, econômicos ou operacionais que não podem ser desprezados. Portanto, incorporar adequadamente as restrições ao modelo é fundamental para garantir resultados significativos e aplicáveis em contextos reais.

Considerando as vantagens e limitações inerentes aos problemas sem restrições, a abordagem restrita impõe vínculos que delimitam o espaço de soluções a um subconjunto factível, garantindo, portanto, que os resultados obtidos atendam aos requisitos práticos e operacionais do problema em questão. Para exemplificar as restrições de um problema de otimização, a equação (1) demonstrará as condições limitantes para o espaço de busca:

$$\begin{aligned} g_i(\mathrm{x}) \leq 0, \mathrm{i} = 1, \ldots, \mathrm{m} \\ h_j(\mathrm{x}) = 0, \mathrm{j} = 1, \ldots, p \end{aligned} \tag{1}$$

Sendo as funções $g_i(\mathrm{x})$ representam restrições de desigualdade e as $h_j(\mathrm{x})$, restrições de igualdade. Essas condições limitam o espaço de busca a uma região factível X=$\{\, x \mid g_i(\mathrm{x}) \leq 0, h_j(\mathrm{x}) = 0 \,\}$. De modo geral, pode-se concluir que a distinção entre elas afeta a modelagem da otimização quanto a escolha do algoritmo, pois uma recorre a busca por todo o espaço livre, enquanto a segunda impõe limites de forma a garantir soluções viáveis para problemas reais.

Por fim, a última dimensão refere-se a forma geométrica da região factível e o formato da superfície da função objetivo, podendo encontrar formas de problemas convexos e não convexos. Em um problema convexo, qualquer mínimo local é automaticamente mínimo global, inclusive a convexidade pode assegurar propriedade de dualidade, facilitando a construção de limites inferiores e superiores que aceleram algoritmos exatos, o que permite utilizar métodos de otimização contínua.

Já problemas não convexos, torna uma região com múltiplos mínimos locais e vales isolados, tornando a difícil tarefa de distinguir pontos locais de globais. Nestes casos, existem estratégias como busca global ou meta-heurísticas tornam-se essenciais, pois combinam a exploração estocástica do espaço de soluções com mecanismos de diversificação, aumentando as chances de escapar de ótimos locais e alcançar soluções mais próximas do ótimo global.

A subseção a seguir abordará uma vertente da otimização centrada exclusivamente nos métodos classificados como meta-heurística, destacando suas principais características e aplicações.

2.3.3 Meta-heurísticas para otimização

Conforme Glover (1986), o termo “meta-heurísticas” resulta da fusão de “meta”, indicando um nível superior de abstração e “heurística”, expressão que descreve métodos de descoberta de soluções. As Meta-heurísticas são estratégias genéricas de otimização, capazes de identificar soluções de alta qualidade em espaços de busca amplos e complexos (RESTREPO-FRANCO *et al*., 2025). Li *et al* (2024) e Rajabi Moshtaghi *et al* (2021), ressaltam que tratadas como algoritmos iterativos e independentes do contexto específico, as meta-heurísticas visam identificar soluções ótimas ou aproximações de elevada qualidade para problemas de otimização, mesmo quando métodos exatos se tornam inviáveis. De modo geral, a meta-heurística pode ser classificadas em quatro grandes categorias de inspiração:

1. Leis inerentes à natureza
2. Fenômenos naturais
3. Mecanismos internos de sistemas
4. Comportamentos biológicos

A Figura 7, apresenta essa classificação, ilustrando exemplos de algoritmos em cada categoria:

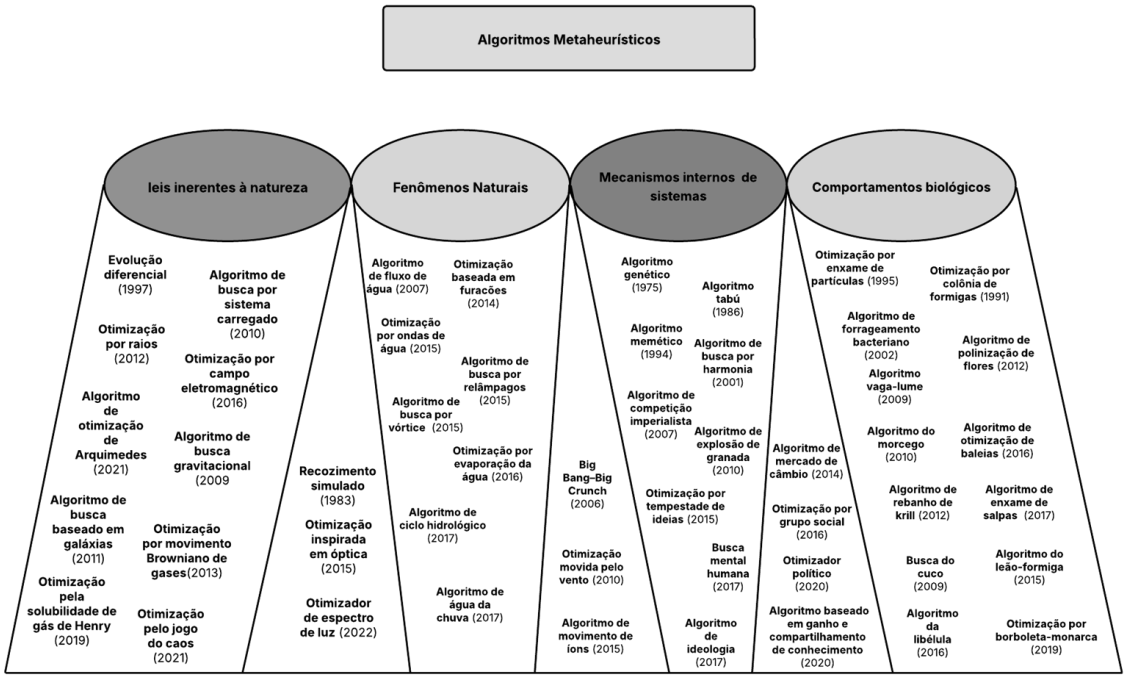

Figura 7 – Classificação dos algoritmos meta-heurísticos segundo sua inspiração
Fonte – Adaptado de LI *et al* (2024)

O Quadro 1 mostra, de forma concisa e comparativa, as quatro categorias de meta-heurísticas, das leis da natureza aos comportamentos biológicos, destacando inspiração, mecanismo de busca e requisitos de implementação.

Quadro 1 – Classificação dos algoritmos meta-heurísticos segundo sua inspiração

Classificação	Inspiração	Mecanismos	Implementação
Leis inerentes à natureza	Princípios físicos ou químicos	Modelagem de forças, energia ou equilíbrio. Desloca "partículas" segundo campos de força ou temperaturas.	Modelagem matemática mais elaborada
Fenômenos naturais	Processos geológicos ou meteorológicos	Simulam ciclos cíclicos ou dinâmicas de fluido/gás como explorações em ondas, evaporação e chuvas.	Modelagem matemática mais elaborada
Mecanismos internos de sistemas	Comportamentos ou mecanismos "intrínsecos" de sistemas artificiais ou conceituais	Usa operadores inspirados em processos de seleção, memória, troca de informações, cruzamento e mutação.	Loops de população e operadores padronizados
Comportamentos biológicos	Dinâmicas coletivas de insetos, aves, peixes ou bactérias	Partilham "informação social" para convergir.	Loops de população e operadores padronizados

Fonte – Próprio Autor

Este breve panorama evidencia a amplitude das meta-heurísticas e o delicado equilíbrio entre exploração e intensificação na busca de soluções eficientes. Os autores Abraham *et al.* (2025), Alorf (2023) e Li *et al* (2024), apresentam em seus trabalhos que o Algoritmo Genético (GA) é destacado como a estratégia mais amplamente empregada na literatura, uma vez que, oferecem uma robustez e processos evolutivos, seleção, recombinação e mutação gerando sucessivas populações de soluções.

Diante desse predomínio e relevância comprovados pelos autores, na Seção 2.3.4 detalha-se sua formulação, principais operadores e estratégias de parametrização, demonstrando porque ele se consolida como uma das abordagens de otimização mais populares.

2.3.4 Algoritmo Genético (GA)

O Algoritmo Genético (GA) é uma técnica de otimização baseada nos princípios da evolução biológica, proposta inicialmente por Holland na década de 1970 (WAYSI NAAMAN *et al*., 2025). Mitchell (1999), apresenta em seu livro que os algoritmos genéticos são mecanismos adaptativos que simulam os princípios da evolução natural para resolver problemas de otimização em espaços complexos.

Inspirado nos mecanismos naturais de seleção, recombinação e mutação, o GA busca soluções ótimas ou quase ótimas em espaços de busca complexos, sendo particularmente eficaz em problemas onde abordagens exatas tornam-se inviáveis devido à sua complexidade computacional (KATOCH *et al*., 2021).

O algoritmo apresenta uma estrutura composta por operadores fundamentais, como codificação genética, função de avaliação (*fitness*), seleção, crossover e mutação, os quais são aplicados iterativamente sobre uma população de soluções candidatas. O processo simula gerações evolutivas, onde soluções mais adaptadas têm maiores chances de gerar descendentes, promovendo uma convergência progressiva para regiões promissoras do espaço de busca (KATOCH *et al*., 2021).

Para ilustrar a operação do algoritmo, a Figura 8 ilustra o fluxo operacional típico de um GA clássico.

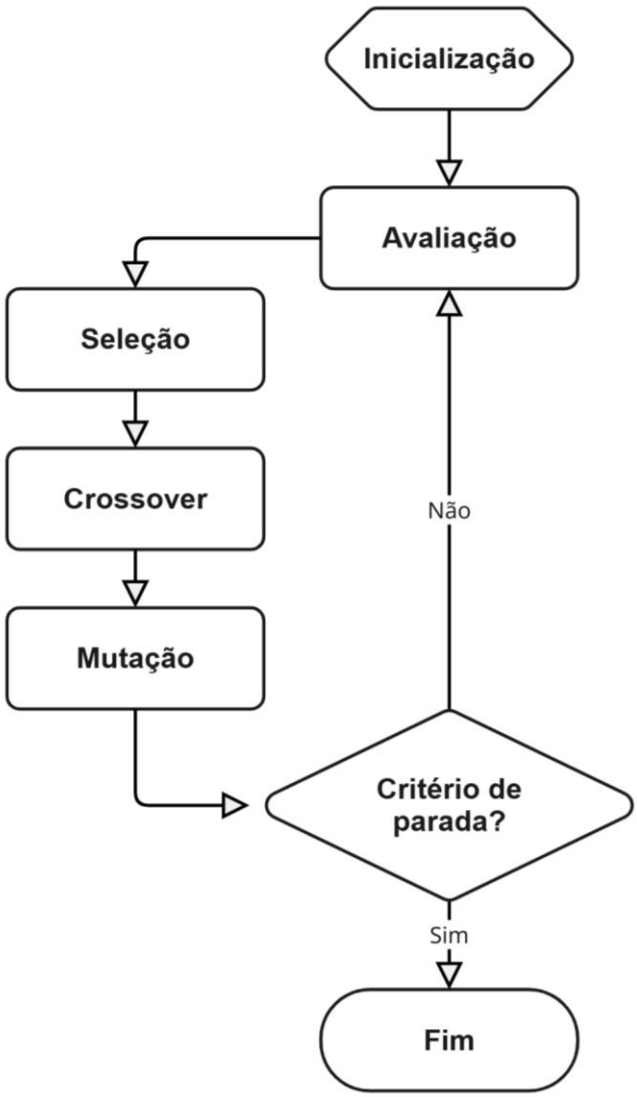

Figura 8 – Fluxograma de operacionalização do GA clássico
Fonte – Adaptado de Waysi Naaman *et al.* (2025)

Em complemento, o pseudocódigo a seguir descreve, de maneira estruturada, a lógica do algoritmo apresentado pela Figura 8.

Quadro 2 - Operacionalização do GA em formato algorítmico

Entrada:
Tamanho da população, *n* Número máximo de iterações, *MAX*
Saída:
Melhor solução global, Y_{bt}
Início Algoritmo
Gerar a população inicial com *n* cromossomos Y_i, onde (i=1, 2, ..., n) Definir o contador de iterações $t = 0$ Calcular o valor de aptidão (fitness) de cada cromossomo **Enquanto** (t < MAX), faça: Selecionar um par de cromossomos da população inicial com base no valor de fitness Aplicar o operador de *crossover* no par selecionado com a probabilidade de cruzamento Aplicar mutação nos descendentes com a probabilidade de mutação Substituir a população antiga pela nova população gerada Incrementar o contador de iteração *t* em 1 **Fim enquanto** Retornar a melhor solução Y_{bt} **Fim Algoritmo**

Fonte – Adaptado de Waysi *et al* (2025)

Para melhor compreender cada etapa presente no fluxograma, será listado e conceituado cada fase:

- Inicialização: Geração aleatória da população inicial de soluções. Essa etapa garante diversidade genética para explorar o espaço de busca de forma eficiente (KATOCH *et al*., 2021).
- Avaliação da aptidão: Cada indivíduo é avaliado por uma função de fitness que representa sua qualidade como solução. Essa função varia conforme o objetivo do problema (TOMAR *et al*., 2023).
- Seleção: Cromossomos com maior aptidão têm maior chance de serem selecionados para reprodução, simulando o princípio de sobrevivência do mais apto (WAYSI *et al* 2025*).*
- *Crossover*: Pares de indivíduos selecionados são recombinados para gerar descendentes. Essa recombinação busca preservar e explorar estruturas vantajosas das soluções (KATOCH *et al.*, 2021).
- Mutação: São introduzidas pequenas alterações nos descendentes com baixa probabilidade, garantindo variabilidade genética e reduzindo o risco de convergência prematura (WAYSI *et al* 2025*).*
- Substituição: A nova geração de indivíduos substitui total ou parcialmente a população anterior, com ou sem elitismo (WAYSI *et al* 2025*).*
- Critério de parada: O processo evolutivo se repete até que um critério de parada seja atendido, como número máximo de gerações ou estagnação da aptidão (TOMAR *et al*., 2023).

- Solução final: O melhor indivíduo gerado ao longo das iterações é retornado como a melhor solução global encontrada.

Com base no estudo levantado sobre GA, nota-se que o algoritmo se destaca como uma abordagem robusta e versátil para problemas de otimização complexos, principalmente em contextos onde métodos exatos são computacionalmente inviáveis. Sua capacidade de equilibrar exploração e intensificação, aliada à flexibilidade dos operadores genéticos, torna-o uma ferramenta poderosa em diversos domínios. As etapas detalhadas aqui evidenciam o seu funcionamento cíclico e adaptativo, o que será essencial para compreender sua aplicação em problemas reais de roteamento, simulação e tomada de decisão, conforme discutido nos próximos capítulos.

2.4 Otimização via simulação

A otimização por meio de simulação (OvS) consiste na combinação de estratégias matemáticas com modelos que reproduzem sistemas do mundo real. Essa abordagem permite antecipar cenários complexos e imprevisíveis antes que ocorram de fato. Métodos tradicionais de otimização, sejam exatos ou heurísticos, geralmente buscam a melhor solução com base em condições fixas. Contudo, ao incorporar a simulação, torna-se possível considerar variáveis inesperadas, como a duração dos serviços, o nível de demanda ou o fluxo de tráfego. Esse recurso oferece uma visão mais flexível e realista de como o sistema pode se comportar diante de diferentes decisões. Carson e Maria (1997) apresentam um exemplo de aplicação dessa metodologia por meio de um modelo de simulação, conforme ilustrado na Figura 9.

Figura 9 – Modelo de Simulação
Fonte - Adaptado de Carson e Maria (1997a)

Nota-se que o modelo de simulação geralmente consiste em n variáveis de entrada $(x_1, x_2, \dots, x_n)$ e m variáveis de saída $\big(f_1(x), f_2(x), \dots, f_m(x)\big)$ ou $y_1, y_2, \dots, y_n$. A otimização desse modelo envolve encontrar a configuração ideal das variáveis de entrada, ou seja, os valores de $x_1, x_2, \dots, x_n$ que maximizem ou minimizem a(s) variável(eis) de saída (CARSON e MARIA, 1997).

Uma vez que o modelo está pronto para uso, o analista pode experimentar diferentes cenários sem afetar o sistema físico, diminuindo o risco e o custo da tomada de decisão. Contudo, o desafio se faz presente quando a quantidade de cenários a serem avaliados é enorme ou mesmo ilimitada, tornando inviável examiná-los em sua totalidade.

Logo, o analista deve utilizar de técnicas mais apropriadas para encontrar a solução ótima para o problema. Para tanto, o uso da OvS em se tornando cada vez mais popular neste contexto (AMARAL *et al.*, 2022a; AMARAN *et al.*, 2016). Para Junior *et al.* (2019), OvS propicia uma melhor alocação de recursos em sistemas de produção novos ou existentes. A OvS captura o relacionamento entre várias entidades de um sistema complexo do mundo real, realizando a identificação de melhores soluções para problemas complexos (LIN E CHEN, 2015).

A literatura nos traz alguns trabalhos envolvendo a otimização via simulação aplicada à área de logística reversa, como os estudos de Harding e Swarnkar (2009) que realizou uma otimização monoobjetivo em conjunto com a simulação a eventos discretos na busca por solucionar um problema de logística reversa que tem como intuito a recuperação de produto. AHLUWALIA e NEMA (2006) desenvolveram seu trabalho aplicando uma otimização multiobjetivo unindo a simulação de Monte Carlo para gerenciamento de resíduo de informática buscando reduzir os riscos ambientais e custos.

Ainda sobre OvS, Amaran *et al.* (2016) ressaltam que a técnica de otimização está sujeito a restrições, no qual é avaliada por meio da simulação estocástica. Carson e Maria (1997) menciona que a OvS avalia soluções por meio de *loops* criado pelo algoritmo de otimização e o modelo de simulação, identificando os melhores valores de entradas para as variáveis de um sistema simulado. Oliveira (2019) ressalta que os principais objetivos dos modelos de simulação e otimização é melhorar o desempenho das variáveis relacionadas ao risco, reduzindo riscos e custos, aumentando os lucros ou determinando os parâmetros das variáveis de decisão. Sawik (2016) complementa que o desempenho é frequentemente obtido por meio do uso de técnicas de otimização.

Dunke e Nickel, (2020b) divide a OvS em quatro métodos: i) classificação e seleção (R&S), ii) busca aleatória e meta-heurísticas, iii) métodos de gradiente direto e iv) metamodelos selecionados conforme as características de cada problema. O método de classificação e seleção são indicados para os casos de espaço de busca discreto com valores limitado de soluções, por outro lado, a busca aleatória e meta-heurísticas são comuns aos casos onde o espaço de busca apresentam alternativas elevadas. Já os métodos de gradiente direto e metamodelos levam consigo uma associação com o espaço de busca e o resultado da simulação, onde métodos de

gradiente direto permitem usar gradientes no processo de busca e os metamodelos podem assumir modelos de superfícies de respostas ou RNAs devido a sua relação mecanicista e captura causal (APRIL *et al.*, 2003; DUNKE e NICKEL, 2020a).

Para exemplificar a combinação entre simulação e otimização e seus princípios de comportamento, Fu (2002) e Better,Glover e Laguna (2007) explicam por meio de uma ilustração como o mecanismo de otimização se coordena com o modelo de simulação, conforme a Figura 10.

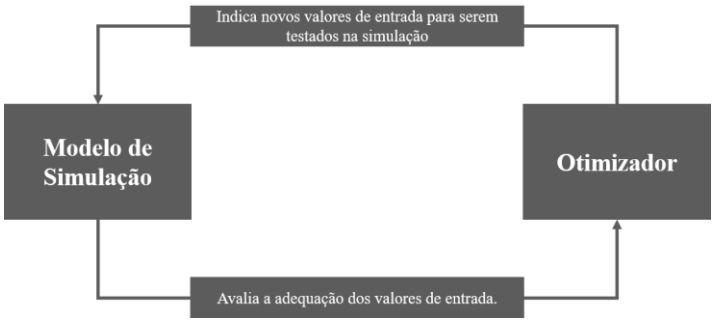

Figura 10 – Interação entre o modelo de simulação com o otimizador
Fonte - Adaptado de Fu (2002) e Better,Glover e Laguna (2007)

Law (2013) apresenta em seu livro um modelo mais aprimorado sobre os princípios de funcionamento de OvS, baseando-se em *softwares* comerciais que contém algoritmos evolucionários e genéticos para otimização de modelos de simulação, denominados como módulos ou pacotes de busca ótima, conforme ilustrado pela Figura 11.

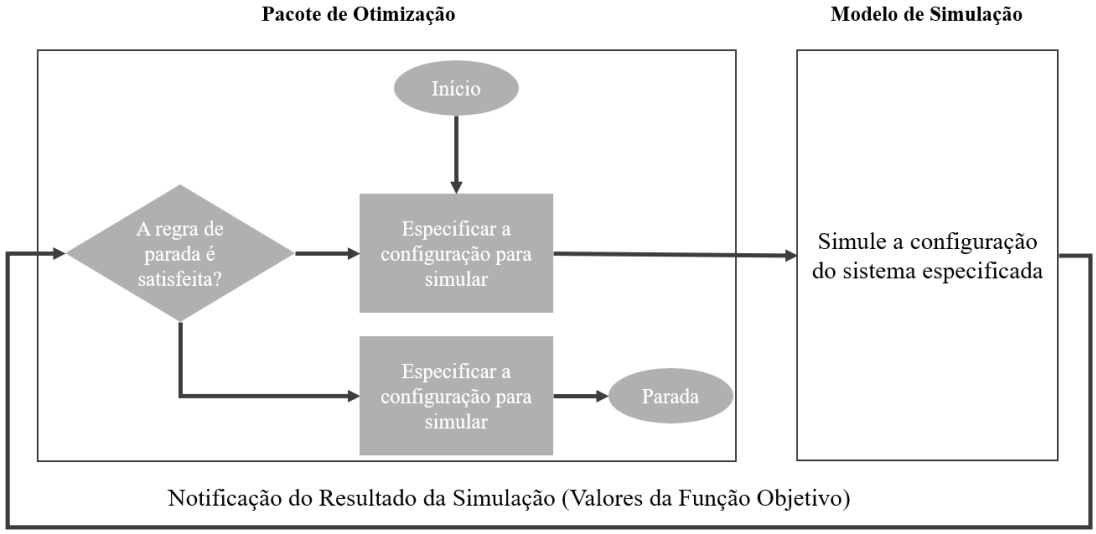

Figura 11 – Como funciona um módulo de otimização integrado a Simulação a Eventos Discretos
Fonte - Adaptado de Law (2013)

O módulo de otimização de software envia as configurações iniciais para o modelo de simulação, incluindo os valores iniciais das variáveis de decisão. Este modelo de simulação realiza operações as quais recebe do módulo de otimização configurado, permitindo avaliar e registrar as estatísticas das variáveis de saída que se deseja otimizar. Em seguida, estes

resultados são transferidos para o módulo de otimização, que usa seu algoritmo de busca para gerar novas configurações para o problema de OvS. Este processo é repetido várias vezes, desde que todas as restrições do sistema sejam satisfeitas, até que o módulo de otimização atinja seu critério de parada (LAW, 2013).

Amaran *et al.*, (2016), demostra que a forma geral para equacionar um problema de OvS pode ser expressa pela equação (2):

$$\begin{gathered} \min \mathbb{E}_{\omega}\left[f(x,y,\omega\right] \\ \text{s.t.}\ \mathbb{E}_{\omega}\left[g(x,y,\omega\right] \leq 0 \\ h(x,y) \leq 0 \\ x_l \leq \mathrm{x} \leq x_u \\ x \in \mathbb{R}^n, y \in \mathbb{D}^m \end{gathered} \tag{2}$$

Em que $\mathbb{E}_{\boldsymbol{\omega}}$ representa o valor esperado da função **f** que pode ser determinada por meio de uma simulação para uma dada instância das entradas contínuas $\boldsymbol{x}$, entradas discretas $\boldsymbol{y}$ e uma realização das variáveis aleatórias na simulação, representadas pelo vetor $\boldsymbol{\omega}$. Similarmente, as restrições estabelecidas pela função vetorial $\boldsymbol{g}$ também são calculadas a cada vez que a simulação é executada. Outras restrições (representadas por $\boldsymbol{h}$) que não envolvem variáveis aleatórias também podem existir, bem como limitações nas variáveis de decisão.

De modo a contribuir ainda mais com esse cenário complexo da OvS, a ideia da função monoobjetivo para um vetor de expectativas, ao qual cada componente representando um critério distinto. Em vez de "apenas" minimizar uma medida, passamos a buscar as soluções que melhor equilibram os objetivos. Nesse contexto, dizemos que uma solução (x^*, y^*) é Pareto-ótima quando não há como melhorar um desses critérios sem sacrificar outro, ou seja, ela faz parte da fronteira de *trade-offs* que melhor reflete as prioridades do decisor, tornando-as uma função de múltiplos objetivo. Para capturar vários critérios simultaneamente, generalizamos a função-objetivo para um vetor de expectativas, expressada pela formulação (3):

$$\begin{gathered} \min \mathrm{F(x,y)} = \left(\mathrm{E}[f_1(\mathrm{x,y},\omega)], \mathrm{E}[f_2(\mathrm{x,y},\omega)], \ldots, \mathrm{E}\left[f_p(\mathrm{x,y},\omega)\right]\right) \\ \text{s.t.}\ \mathrm{E}\left[g_j(\mathrm{x,y},\omega)\right] \leq 0, \text{paraj} = 1, \ldots, \mathrm{m} \\ h_k\ (\mathrm{x,y}) \leq 0, \text{para k} = 1, \ldots, \mathrm{r} \\ x_l \leq \mathrm{x} \leq x_u, \text{com x} \in \mathbb{R}^n, y \in \mathbb{D}^m \end{gathered} \tag{3}$$

Em que:

• E $[f_i(\mathrm{x, y, \omega})]$ é a esperança do i-ésimo critério de desempenho do sistema, definido de acordo com os objetivos do problema em estudo.

• E [g_j(x, y, ω)] ≤ 0 são as restrições sob incerteza.

• h_k (x, y) ≤ 0 são as restrições determinísticas.

• x e y mantêm seus domínios originais.

Dessa forma as soluções de Pareto-ótimas (x^*, y^*), ou seja, aquelas para as quais não existe outra solução (x, y) que melhore simultaneamente todos os componentes de F sem piorar nenhum.

Embora existam resultados encontrados por meio de um processo de OvS, nem sempre são garantidos como sendo ótimos. A eficácia dos resultados depende do método de otimização usado e de suas configurações, incluindo opções, parâmetros e tolerâncias. Embora um software de OvS de alta qualidade possa alcançar soluções próximas ao ideal, a diferença entre o ótimo global e a solução produzida pelo *software* costuma ser insignificante, considerando a otimização de um modelo de simulação estocástico (WANG e SCHONFELD, 2006; MIRANDA, 2015).

Por fim, Júnior (2019) e Maashi, Kendall e Özcan (2015) ressaltam que as técnicas de otimização são projetadas para encontrar boas soluções, explorando tanto soluções viáveis quanto inviáveis. Dependendo do método utilizado, essas técnicas podem incluir estratégias para evitar ótimos locais e encontrar soluções próximas ou iguais ao ótimo global, ou local conhecido até então, de modo que a relação entre tempo e qualidade da solução atenda às expectativas dos tomadores de decisão. Nesse contexto, a combinação entre meta-heurísticas, otimização multiobjetivo e simulação discutida nesta seção oferece a base conceitual que sustenta a abordagem proposta nesta tese para o roteamento de veículos em logística reversa.

2.5 RSL:Uso da otimização multiobjetivo via simulação aplicada à logística reversa

2.5.1 Contextualização

Em busca de explorar o universo da logística reversa, uma revisão sistemática da literatura foi desenvolvida a fim de compreender sobre as áreas de aplicação e seus objetivos, as categorias de simulações usadas, as plataformas enquanto simuladores, os aspectos da sustentabilidade, e por fim, as principais vantagens, limitações e oportunidades para a utilização da otimização via simulação aplicado a logística reversa.

Para responder a essas questões, as próximas seções aprofundam o referencial teórico sobre otimização via simulação aplicada à logística reversa e organizam respostas às principais lacunas identificadas na literatura.

2.5.2 Método de Pesquisa: Revisão Sistemática de Literatura

Diferente da revisão de literatura que permite o desenvolvimento de pesquisas exploratória sem percorrer por uma metodologia, a RSL tem como base responder questões cientificas de forma estruturada, passando por etapas e estudos estruturados da literatura (OLIVEIRA, LIMA e MONTEVECHI, 2016; JUNIOR *et al.*, 2019; SANTOS *et al.*, 2021).

Segundo Sampaio e Mancini (2007), para implementação de uma revisão sistemática de literatura os pesquisadores deverão seguir um protocolo de pesquisa. Nesta tese, realizou-se uma Revisão Sistemática da Literatura (RSL) sobre o uso da otimização via simulação aplicada à logística reversa. O estudo foi conduzido seguindo as etapas propostas por Oliveira, Lima e Montevechi (2016) definição dos objetivos e das questões de pesquisa; elaboração da estratégia de busca e dos critérios de inclusão e exclusão; realização da busca e triagem dos estudos; análise e síntese dos resultados obtidos, incluindo tratamento estatístico quando pertinente; e, por fim, apresentação dos principais achados e conclusões da revisão.

2.5.3 Planejamento

Inicialmente, uma busca pela literatura foi realizada para compreender os principais assuntos centrais referente a própria pesquisa. Sendo assim, uma busca exploratória foi realizada usando a base de dados *Scopus*®, pois se tratar de uma das maiores e principais base de dados multidisciplinar disponível (SCHEIDEGGER *et al.*, 2018; SANTOS *et al.*, 2021). Em um primeiro momento, durante a pesquisa pela *Scopus*® introduziu-se os termos "Logística reversa", "otimização" e "Simulação" aplicando-se a lógica booleana "E", a fim de identificar as principais discussões relacionada à temática. Nesta busca, os esforços foram concentrados em trabalhos voltados para os termos genéricos e não especificados, tomadas de decisão, periódicos científicos e revisados por pares.

Além dos artigos selecionados na primeira fase, também foram incluídas obras adicionais citadas por esses estudos. Com base nesse conjunto de publicações e com o apoio de especialistas em logística reversa, otimização e simulação, foram consolidadas as principais terminologias relacionadas ao tema e definidas as questões de pesquisa (*Research Questions* – RQs) que orientam esta revisão.

Considerando as diferentes abordagens e nomenclaturas encontradas na literatura de logística reversa ao longo dos anos, a RSL revelou diversas frentes de investigação e desafios ainda em aberto nessa área. Os autores como Mar-Ortiz, Adenso-Diaz e González-Velarde (2011) identificaram desafios em LR com abordagem em redes de recuperação para coleta de Equipamentos de resíduo elétrico e eletrônico na região espanhola. Ahluwalia e Nema (2006)

realizaram estudos sobre otimização multiobjetivo no gerenciamento de resíduos de informática, isto é, trouxe uma ferramenta de apoio a decisão para configurar uma solução ótima na instalação do gerenciamento de resíduo de informática.

Um modelo de simulação multi-método que combina abordagens a eventos discretos e baseado em agentes para modelar uma cadeia de suprimento de circuito fechado verde foi desenvolvido a fim de otimizar a incerteza da demanda, custo totais e emissões de gases de efeito estufas (PARSAIYAN *et al.*, 2019). Zhao *et al.*, (2018) realizam simulações em uma cadeia de suprimento verde aplicada a diversos cenários com o intuito de estimular as atividades de recuperação de lixo eletrônico e promover a produção de limpeza, de tal forma a otimizá-la.

Godichaud e Amodeo (2013) desenvolveram um modelo de cadeia de suprimentos de circuito fechado, aplicando otimização multiobjetivo e simulação para determinar as melhores políticas de controle em uma malha fechada multiescala.

Em face às nomenclaturas e abordagens levantadas sobre a LR e de modo a complementar a terminologia, uma nuvem de palavra foi desenvolvida por artigos selecionados de uma revisão exploratória conforme os termos "*Systematic literature review*" e "*Reverse logistics*", para identificar palavras que melhor se enquadra na logística reversa.

Figura 12 – Nuvem de palavras sobre revisão sistemática de literatura na logística reversa
Fonte – Próprio autor

Conforme a Figura 12, nota-se diversos termos associados a logística reversa, tais como: *supply chains*, *sustainable development*, *recycling*, *logistics*, *waste management*, *reverse*

logistics, *closed-loop supply chain*, *solid waste*, etc. Por fim, os autores Islam *et al.*, (2021) apresentam em seu trabalho alguns termos usados para representar a logística reversa, tais como: logística verde, logística sustentável, preocupações ambientais na logística, circuito fechado na logística, logística reversa, e por fim, a cadeia de abastecimento de circuito fechado. Já Plaza-Úbeda *et al.*, (2021) utilizou os seguintes termos: gestão da cadeia de abastecimento, gestão da cadeia de abastecimento verde, logística reversa, logística reversa verde. Ainda Vahabzadeh e Yusuff (2015) realizam em seu trabalho uma comparação dos termos gestão de resíduos e logística verde em relação à logística verde.

Conforme fundamentado, verifica-se que ainda são poucos os estudos que combinam logística reversa com otimização via simulação, especialmente em problemas de roteamento com múltiplos objetivos e incertezas operacionais. A maioria das pesquisas adota modelos determinísticos ou utiliza simulação de forma isolada, sem um *framework* integrado de OvS. Por isso, os trabalhos que de fato empregam otimização via simulação em LR precisam ser analisados, comparados e classificados, de modo a construir uma base teórica sólida sobre essa abordagem. A Figura 13 a seguir demonstrará algumas observações encontradas nessa fase exploratória.

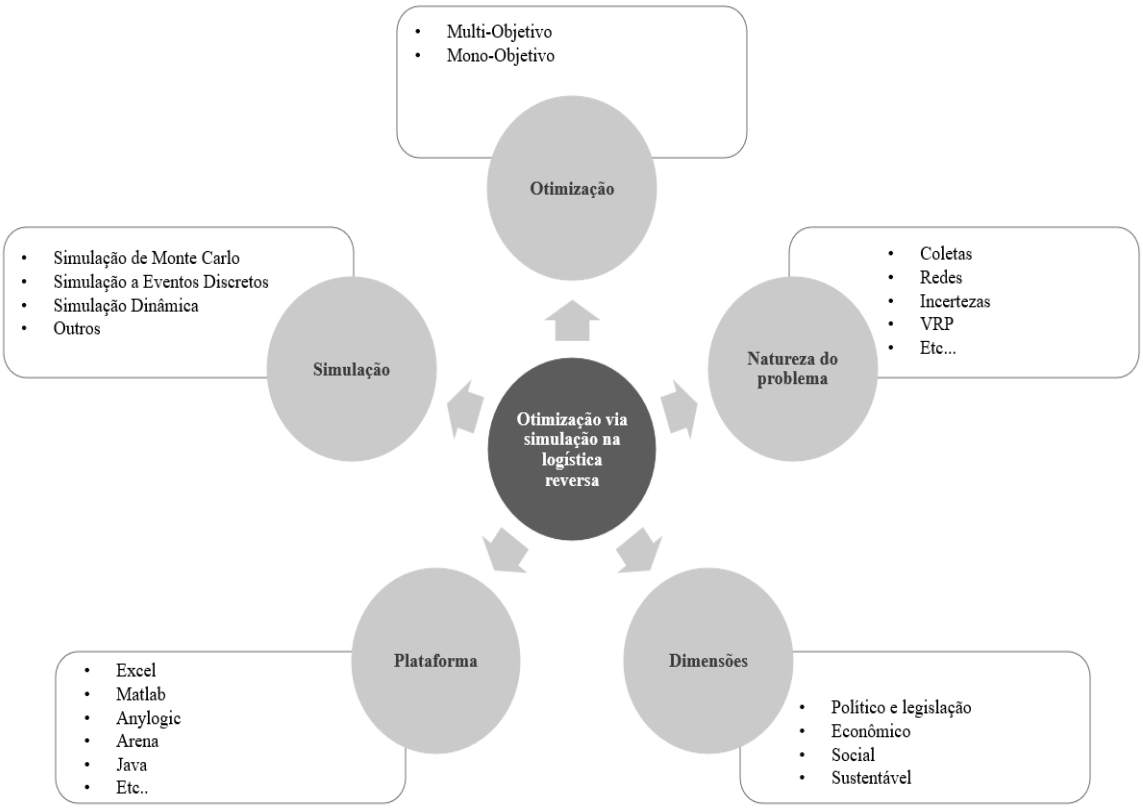

Figura 13 – Oportunidades relatados para o uso de otimização via simulação na logística reversa
Fonte – Próprio autor

Diante das considerações anteriores, esta RSL possui os seguintes objetivos:

- Desenvolver uma pesquisa bibliográfica sobre o uso otimização via simulação na logística reversa;
- Analisar cada trabalho a partir das lacunas mencionadas;
- Criar uma base teórica sólida neste campo de pesquisa;
- Identificar perspectivas futuras.

Uma vez que os objetivos foram definidos, as questões foram formuladas conforme:

- As áreas de aplicação e natureza dos problemas associados ao uso de otimização via simulação na logística reversa?
- Aos tipos de simulações e plataformas usadas como parte da otimização via simulação na logística reversa?
- Aos métodos e plataformas usadas para solucionar problemas complexos em LR aplicando otimização via simulação?
- Aos aspectos da sustentabilidade a otimização via simulação foram explorados na logística reversa?
- As principais vantagens, limitações e oportunidades de pesquisa associada a esta abordagem?

2.5.4 Pesquisa e Triagem

Nesta etapa, foram utilizadas bases de dados previamente selecionadas durante a revisão da literatura. Entre diversas bases existentes, considerou-se cinco (5) bases de dados: *Scopus®, WebofScience®, Scielo®, IEEE Xplore® e Science Direct®*. Em seguida, foram definidas as palavras-chave da busca e, para obter mais precisão nos resultados , a simulação e a otimização foram aplicadas de modo genérica, ou seja, não se estratificou a mesma.

Além disso, os termos que se referem ao o uso de Logística Reversa (LR) foi incluído, sendo: "*reverse supply chain*", "*closed loop supply chain*", "*circular economy*", "*sustainable supply chain*". Lógicas booleanas (*AND* / *OR*) foram utilizadas para obter todas as combinações possíveis entre os termos.

Ainda, foram incluídos os seguintes critérios para considerar o artigo no RSL: (i) os termos pesquisados devem estar presentes no título, resumo ou palavras-chave do artigo; (ii) artigos publicados nos últimos trinta anos, considerando a data final em junho / 2021; (iii) artigos completos publicados em revistas científicas e revisados por pares; (iv) apenas artigos escritos no idioma inglês.

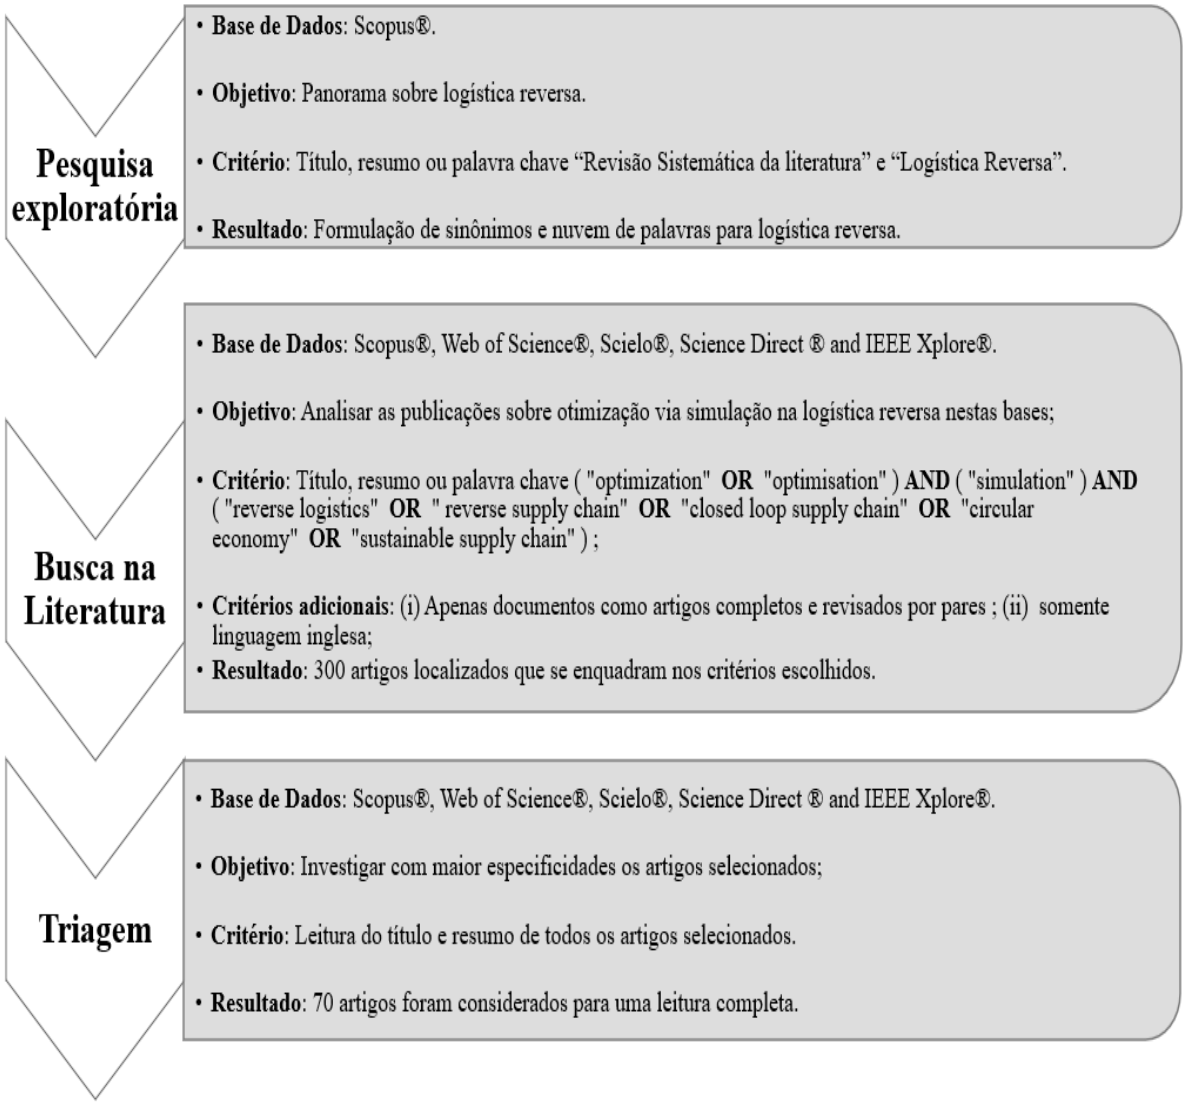

Figura 14 – Procedimentos realizados nas etapas de Planejamento e Pesquisa/Triagem
Fonte – Próprio autor

Em um primeiro momento, foram encontrados 300 artigos que se enquadraram nos critérios de pesquisa, já descontando os artigos duplicados utilizando a biblioteca *bibliometrix* em R (ARIA e CUCCURULLO, 2017). Em seguida, foi realizada uma etapa de triagem com os artigos selecionados, onde os resumos foram lidos para identificar aqueles que se alinham aos objetivos do RSL. Nessa etapa, foram excluídos os artigos que não se enquadravam nos critérios de pesquisa previamente definidos. Após a triagem, 70 artigos foram considerados para leitura na íntegra. Figura 14 resume os procedimentos realizados nas fases de Planejamento e Pesquisa / Triagem e a Figura 15 mostra a distribuição desses artigos nas bases de dados escolhidas.

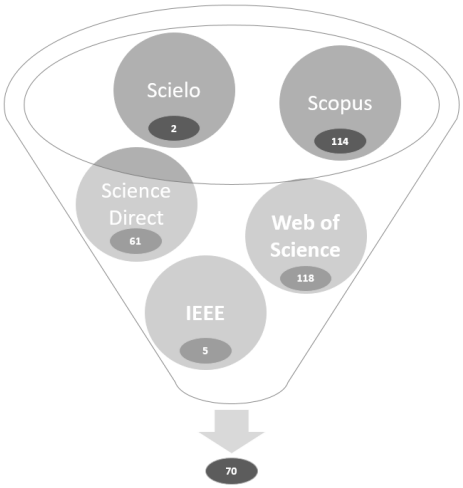

Figura 15 – Procedimentos realizados nas etapas de Planejamento e Pesquisa/Triagem
Fonte – Próprio autor

É importante destacar que o foco desta RSL se restringe à busca de artigos científicos nas principais bases de pesquisa, não tratando de patentes ou qualquer outra forma de registro de produto.

2.5.5 Análise / síntese

A análise e síntese dos resultados foram realizadas em planilha *MSExcel*®. Dessa forma, foi possível extrair informações de todos os 70 artigos lidos. Cada artigo foi registrado em planilha conforme as diretrizes relacionadas aos RQs e os resultados extraídos foram analisados por meio de estatística descritiva. As análises foram baseadas em cada um dos RQs e demonstraram as melhores práticas e as principais perspectivas relacionadas ao uso da otimização via simulação na logística reversa.

2.5.6 Apresentação (relatório)

A apresentação dos resultados será discutida na seção 2.5.7, onde as subseções corresponderão a cada RQ. Tabelas e gráficos foram utilizados para resumir os resultados e auxiliar na sua interpretação. Portanto, as discussões apresentadas serão de extrema importância para entender a evolução da otimização via simulação na logística reversa ao longo dos anos, bem como as perspectivas futuras dessa abordagem. Além do estado atual sobre o tema, são apresentadas discussões sobre as vantagens, limitações e oportunidades de pesquisa quanto uso da otimização via simulação na logística reversa.

2.5.7 Resultados e Discussões

2.5.7.1 Estado da arte

Nesta seção apresentam-se os resultados das questões de pesquisa relacionada a RSL. Em primeiro momento, uma breve análise bibliométricas sobre a quantidade de artigos

publicados por ano. A Figura 16, apresenta uma tendência de crescimento de artigos publicados a partir de 2015, demonstrando que essa área vem ganhando destaque no mundo acadêmico.

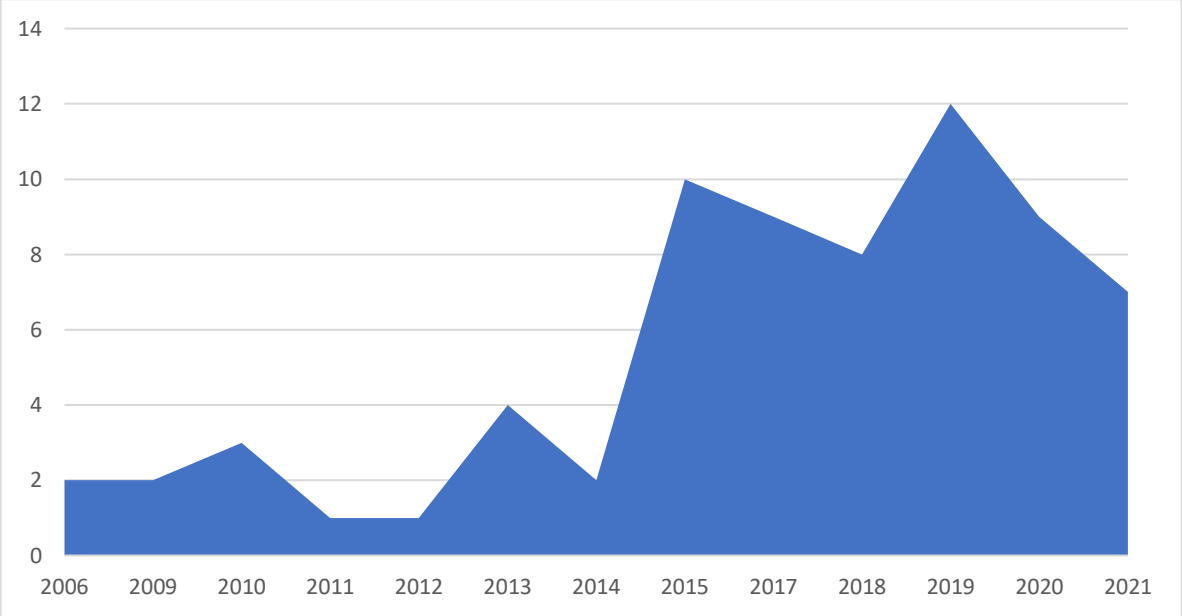

Figura 16 – Trabalhos que utilizaram otimização via simulação aplicada a logística reversa nos últimos anos
Fonte – Próprio autor

Os 70 artigos analisados foram publicados em diversas revistas. A Tabela 1 apresenta os 10 principais periódicos de publicação. Os cinco primeiros representam 35,71% dos artigos publicados por esses periódicos. Além disso, o *Journal of cleaner production* vem se destacando na Tabela 1, representando cerca de 11,43% dos trabalhos de referência ao campo desta pesquisa.

Tabela 1 – Top 10 locais de publicação

Rank	Revista	No.	%	Cum (%)
1	*JOURNAL OF CLEANER PRODUCTION*	8	11,43%	11,43%
2	*INTERNATIONAL JOURNAL OF PRODUCTION ECONOMICS*	5	7,14%	18,57%
3	*INTERNATIONAL JOURNAL OF PRODUCTION RESEARCH*	5	7,14%	25,71%
4	*RESOURCES CONSERVATION AND RECYCLING*	4	5,71%	31,43%
5	*INTERNATIONAL JOURNAL OF BUSINESS PERFORMANCE AND SUPPLY CHAIN MODELLING*	3	4,29%	35,71%
6	*SUSTAINABILITY*	3	4,29%	40,00%
7	*ANNALS OF OPERATIONS RESEARCH*	2	2,86%	42,86%
8	*COMPUTERS & INDUSTRIAL ENGINEERING*	2	2,86%	45,71%
9	*EUROPEAN JOURNAL OF OPERATIONAL RESEARCH*	2	2,86%	48,57%
10	*EXPERT SYSTEMS WITH APPLICATIONS*	2	2,86%	51,43%
	Outros	34	48,57%	100,00%

Fonte – Próprio autor

Também se analisou os trabalhos referentes aos principais pesquisadores, filiações e nacionalidades. A Tabela 2 apresenta os resultados encontrados sobre os artigos publicados por esses pesquisadores, bem como uma lista com os 10 pesquisadores que mais publicaram no eixo dessa pesquisa. Nota-se que foram encontrados 229 autores entre os artigos analisados, ainda observamos que entre os 10 pesquisadores listados existe uma diferença em publicações

entre eles não ultrapassando 2 artigos, o que nos mostra uma pequena produção de artigos associado a esta área.

Tabela 2 – Top 10 publicações de autores

Rank	Autores	No.
1	Fattahi m	2
2	Gupta sm	2
3	Moghaddam ks	2
4	Wang l	2
5	Zolfagharinia h	2
6	Abbas a	1
7	Adenso-diaz b	1
8	Ahluwalia pk	1
9	Ahm shamsuzzoha as	1
10	Alqahtani ay	1
	Outros 219 Pesquisadores	

Fonte – Próprio autor

Em busca de autores com produtividade e impacto de citações nesta área, a Figura 17 apresenta alguns pesquisadores que receberam seus índices com base no conjunto de trabalhos mais citados e o número de citações que eles receberam de outras publicações.

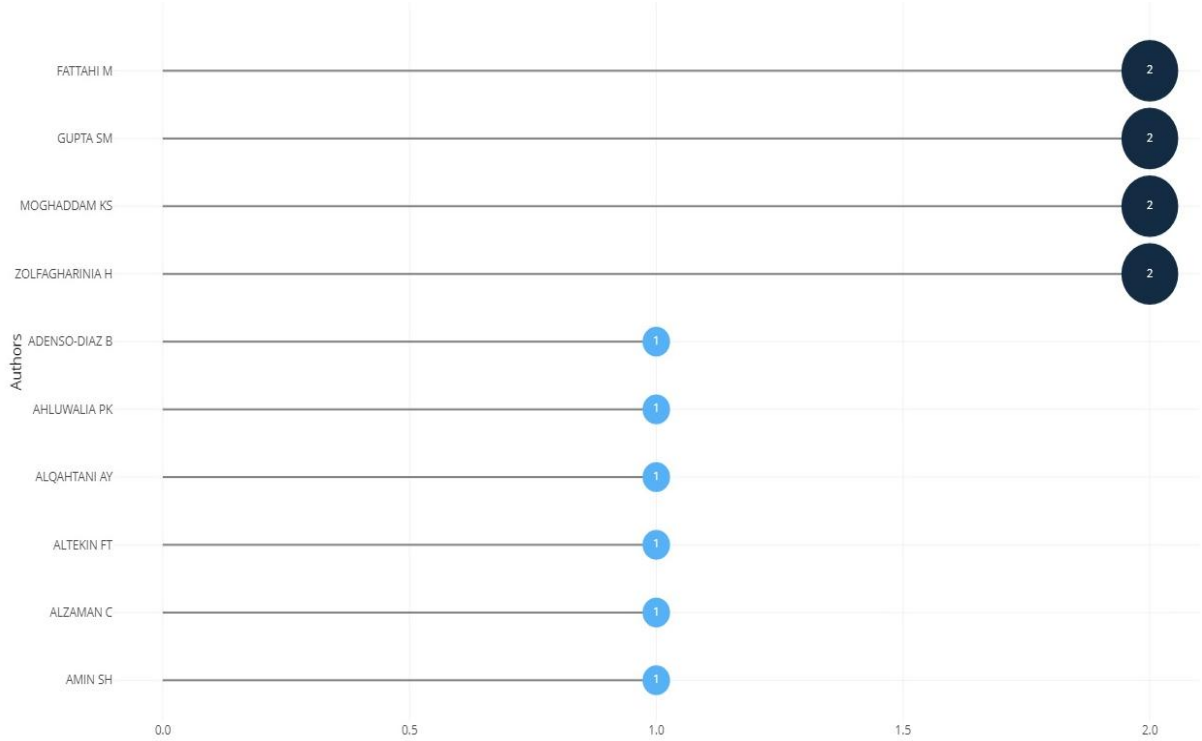

Figura 17 – Número de artigos publicados por pesquisador
Fonte – Próprio autor

Além disso, a figura 18 apresenta os 10 artigos mais citados.

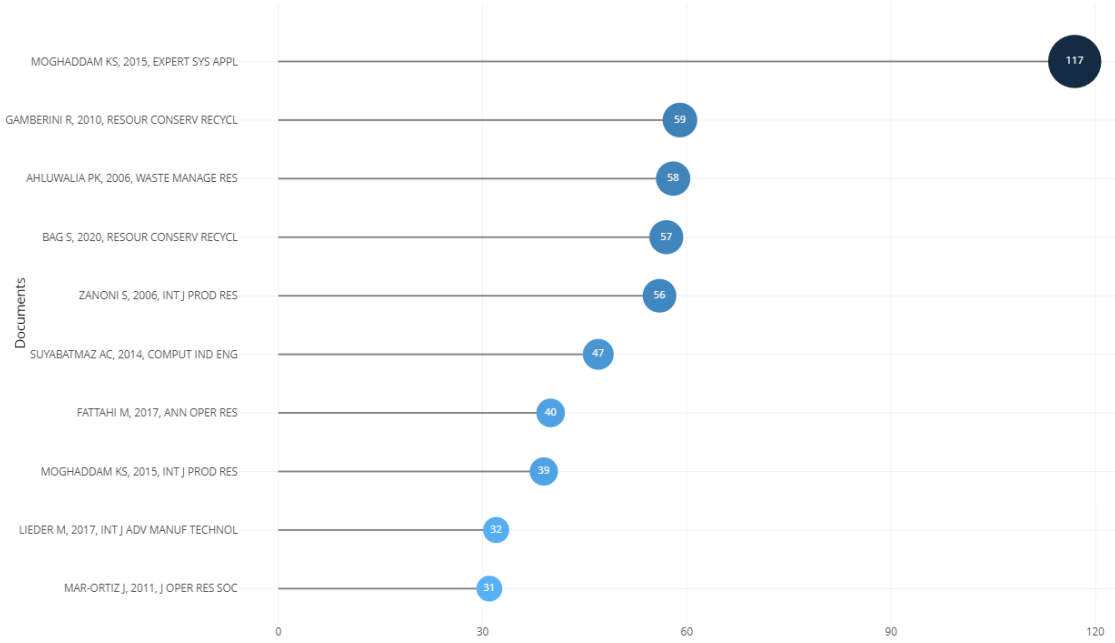

Figura 18 – Artigos com maior número de citações
Fonte – Próprio autor

Ao que se refere a Tabela 3, pode-se chegar a mesma conclusão ao que foi mostrado na tabela anterior, uma vez que, não é possível afirmar que essas filiações sejam referência neste campo.

Tabela 3 - Top 10 Universidades em destaque na busca pelo tema

Rank	Universidades	No.
1	UNIV TECHNOL TROYES	4
2	CONCORDIA UNIV	3
3	HARVARD UNIV	3
4	SABANCI UNIV	3
5	TECH UNIV KOSICE	3
6	UNIV BRIDGEPORT	3
7	UNIVERSITY OF ANTWERP	3
8	UNIVERSITY OF TENNESSEE	3
9	CALIFORNIA STATE UNIVERSITY-FRESNO	2
10	CAMBRIDGE CTR ADV RES AND EDUC SINGAPORE	2
	Outras 99 universidades	

Fonte – Próprio autor

Já a Tabela 4 apresenta os países com maior destaque entre as obras analisadas, nota-se que a China, Estados Unidos e França estão entre as 32 nacionalidades com mais publicações nesta área de pesquisa. Por fim, pode-se compreender que esta área de pesquisa vem ganhando destaque no meio acadêmico global, sendo impulsionada pela necessidade de soluções inovadoras para desafios logísticos, ambientais e tecnológicos. A diversidade de países envolvidos também evidencia o caráter interdisciplinar e internacional da temática, indicando um campo promissor e em constante expansão.

Tabela 4 - Top 10 nacionalidade

Rank	Nacionalidade	No.
1	China	17
2	Usa	16
3	France	6
4	Iran	6
5	Belgium	5
6	Canada	5
7	Uk	4
8	Colômbia	3
9	Italy	3
10	Netherlands	3
	Outras 22 Nacionalidades	

Fonte – Próprio autor

2.5.7.2 Áreas de aplicação e natureza dos problemas usando otimização via simulação aplicado a logística reversa

No que se refere às áreas de aplicação e à natureza dos problemas abordados pelos estudos de otimização via simulação em logística reversa, observa-se uma grande diversidade tanto de contextos quanto de tipos de problema. Com base nos artigos selecionados, as áreas de aplicação foram classificadas da seguinte forma: (i) manufatura (corresponde as atividades relacionadas à produção de bens ou reprodução); (ii) eletrônica (as atividades de recuperação de componentes eletrônicos) ;(iii) não especificado (corresponde aos artigos que não deixaram claro suas atividades); (iv) serviços (atividades relacionadas a serviços gerais, como fornecedores, fabricantes e outros); (v) Agricultura (atividades que envolve a importância do consumo de água, no qual grãos são utilizados para alimentar as pessoas); (vi) construção civil (relacionado as atividades de construção civil); (vii) energia (atividades ligadas ao reaproveitamento de resíduos para geração de energia) e (viii) farmacêutica (relacionada as operações de farmácias); (ix) Outros (as atividades envolvendo estágio em fim de vida do produto e suporte a decisão). Desse modo, a Figura 19 apresenta a distribuição percentual dos artigos entre as diferentes áreas de aplicação, bem como o percentual acumulado dessas áreas.

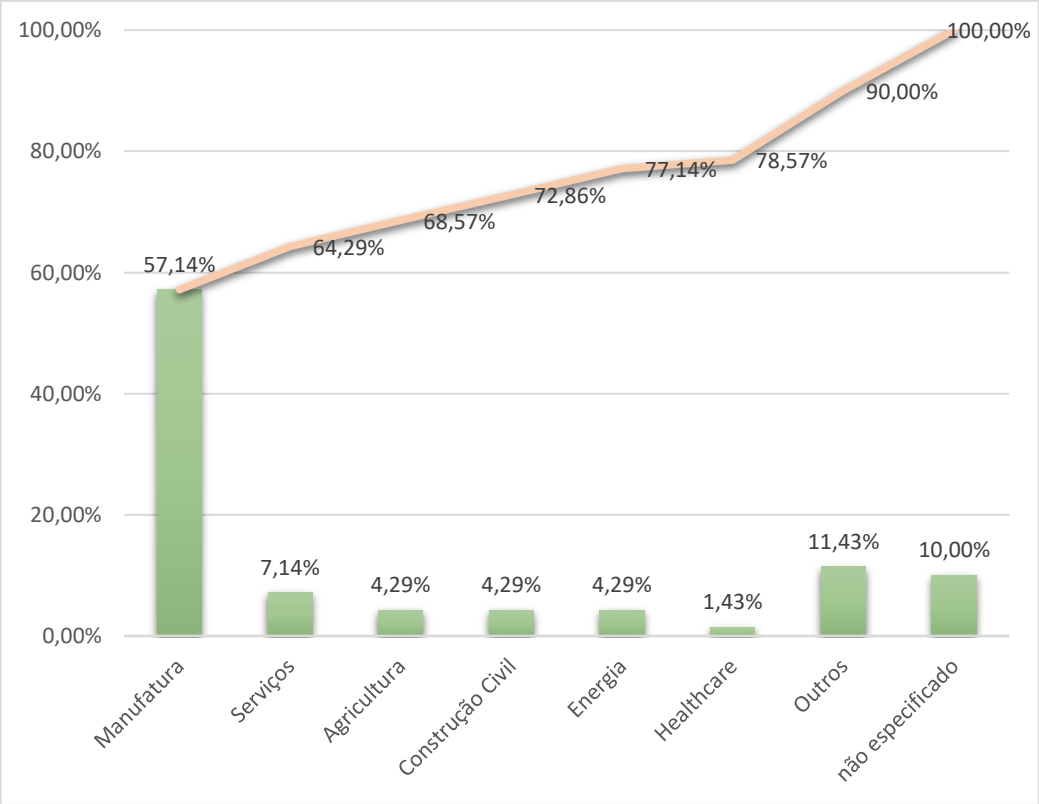

Figura 19 – Gráfico de Pareto das principais áreas de aplicação
Fonte – Próprio autor

Nota-se que três áreas de aplicação vêm se destacando, a manufatura, serviços e agricultura, correspondendo a 68,57% dos artigos relacionados. Neste caso, a manufatura que representa cerca de 57,14% dos artigos apresentam trabalhos que envolve produtos em fim de vida (LIEDER *et al.*, 2017), resíduos domésticos orgânicos (SAKARIKA *et al.*, 2019), remanufatura de peças (TOPCU, BENNEYAN e CULLINANE, 2013) e recuperação de produtos (HARDING e SWARNKAR, 2009). Além disso, cerca de 35,90% dos artigos que envolve a manufatura, está associada a área de eletrônica como o trabalho de (MAR-ORTIZ, ADENSO-DIAZ e GONZÁLEZ-VELARDE, 2011). A área de serviço representa 7,14% dos artigos e abrange a políticas estratégicas (DE FELICE E PETRILLO, 2012) e proposta de plataforma de serviço em nuvens (Ma, Wang e Chen, 2017).

A terceira área mais representativa é a agricultura, com cerca de 4,29%, abrangendo trabalho sobre o abastecimento de trigo (MOTEVALLI-TAHER, PAYDAR E EMAMI, 2020), custo para entrega de biomassa microbiana (LIXIA HE-LAMBERT, SHYLO e BURTON C. ENGLISH *et al.*, 2019) e agro produtos (R. ZHAO *et al.*, 2018). Com os mesmos percentuais de artigos, a área de construção civil apresenta abordagens sobre logística reversa para resíduos de construção e demolição (YANG e CHEN, 2020), separação total dos resíduos (STRAKA *et al.*, 2019) e também a disposição de materiais resultantes dos processos de escavação e demolição (ZÜST *et al.*, 2021a). Na área de energia, a otimização via simulação aplicada à

logística reversa foi utilizada em energia solar (LAMEH *et al.*, 2021), produção de biocombustível (YANG e SHAN, 2021) e avaliação de recuperação de resíduos para energia (WERA) (HARAGUCHI, SIDDIQI e NARAYANAMURTI, 2019). Já a área de *healthcare* tem-se 1,43% dos artigos que abrange processo logístico aplicado a farmácias. Por fim, a categoria "outros" reúne aplicações variadas, como ferramentas de suporte à decisão (HELMDACH, YASENEVA e PARMINDER K. HEER, *et al.*, 2017 e ZOU *et al.*, 2018), estágio de fim de vida (AYDIN *et al.*, 2018) e centro de fornecedores e clientes (SUN, LU e ZHANG, 2019).

Em relação à natureza do problema, o artigo de Abid e Mhada (2021) para classificar diversas dificuldades enfrentadas nesta área, como, por exemplo, problema de roteamento de veículos (VRP), incertezas (INC), planejamento e controle da produção (PCP), controle de inventário (CI), redes (R), recuperação (REC), coleta (C), gestão de retorno (GR), cadeia de abastecimento de circuito fechado (CLSC), cadeia de abastecimento (SC), localização (L), produção e agendamento (PA). Seguindo essa linha, o problema em roteamento de veículos dos autores (Bottani e Casella, 2018) que aplica uma otimização em um modelo de simulação que reproduz um fluxo de itens de transporte retornáveis em uma CLSC, calculando assim o impacto ambiental.

Tratando de problemas de incerteza os estudos de Elia, Gnoni e Tornese (2019), adota uma metodologia baseada em simulação para comparar diferentes alternativas de coletas em resíduos elétricos e equipamentos eletrônicos (REEE). Os pesquisadores Godichaud e Amodeo (2015) apresentam em seu trabalho uma proposta de simulação e otimização para políticas de controle para cadeias de suprimentos multiescala com produtos devolvidos, buscando solucionar questões incertas de devoluções e lead times por se tratar de assuntos complexos. Além disso, os problemas associados a planejamento e controle da produção (PCP), Ma, Wang e Chen (2018) propuseram uma plataforma de serviço em nuvem colaborativa para desenvolver um modelo de cadeia de suprimento de vestuário sob encomenda sustentável, utilizando a simulação baseada em multiagentes para avaliar o modelo.

Os autores Helmdach *et al.* (2017) desenvolveram uma ferramenta de apoio a decisão para problema de controle de inventário aplicando otimização multiobjetivo. Já os autores Fattahi e Govindan (2017) buscam solucionar o problema de redes (R) combinados as incertezas (INC) que surgem na logística direta e reversa, aplicando um modelo de programação linear inteira mista simulando possíveis cenários de demanda e retorno potencial. Suyabatmaz, Altekin e Şahin (2014) combinam, em um único modelo, os problemas de redes (R), coleta (C), localização (L) e incertezas (INC) na logística reversa. Utilizando simulação híbrida, os autores

desenvolvem um modelo de apoio à decisão para lidar com as incertezas em níveis tático e estratégico. Poonam Khanijo Ahluwalia e Nema (2006a) propõem uma ferramenta de apoio a decisão para a gestão de resíduos de computadores com o intuito de solucionar dificuldades relacionadas aos impactos ambientais por métodos rudimentares de recuperação (REC). De modo a complementar ainda mais os problemas enfrentados nestas áreas, a Figura 20 nos mostra o percentual de artigos para cada natureza do problema.

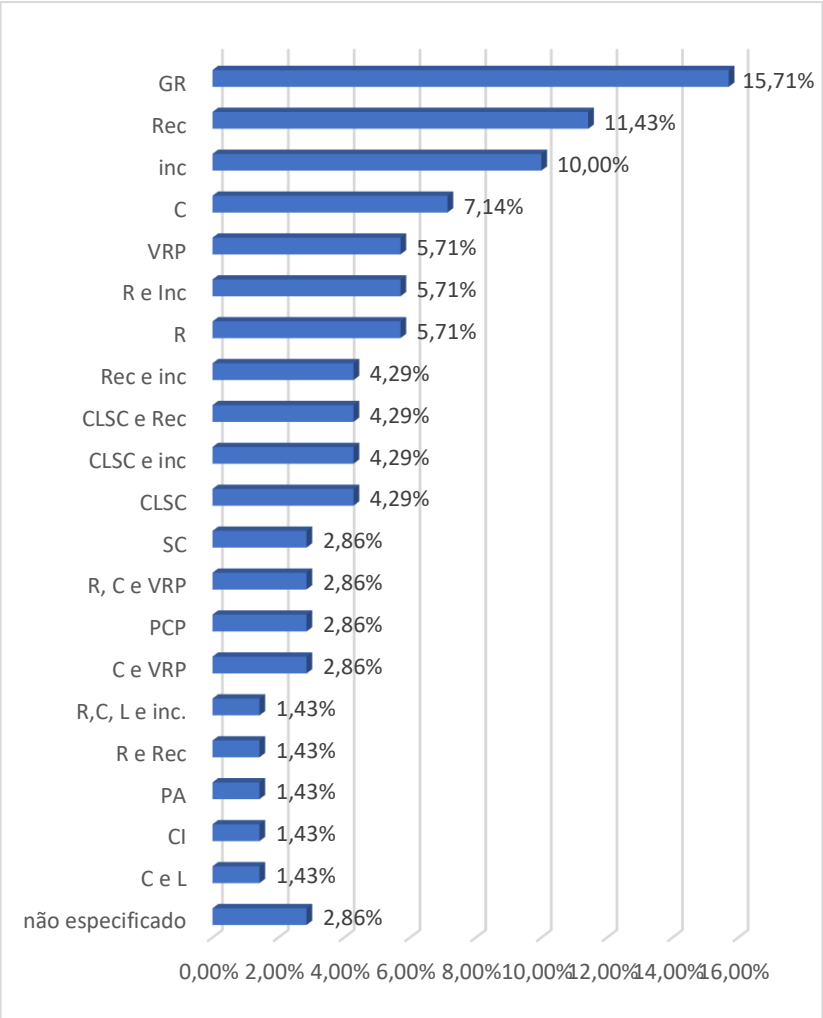

Figura 20 – Gráfico de Pareto da natureza do problema
Fonte – Próprio autor

Nota-se que os cinco primeiros problemas representam cerca de 49,99% dos artigos lidos e estão divididos em gestão de retorno (15,71%), recuperação (11,43%), incertezas (10%), coletas (7,14%) e VRP (5,71%). Por meio da Figura 20, observa-se também que 2,86% dos artigos analisados não especificam o problema. Além disso, a Tabela 5 estratifica os autores por natureza do problema.

Tabela 5 - Tabela dos autores relacionado a natureza do problema

Natureza do problema	Referências
C	Yasel Costa-Salas, Sarache and Überwimmer, (2017); Bottani, Montanari and Rinaldi, (2019); Haraguchi, Siddiqi and Narayanamurti, (2019); Ma *et al.*, (2019); Sun, Lu and Zhang, (2019)
C e L	Shokohyar and Mansour (2013)
C e VRP	Sakarika *et al.*, (2019)
CI	Helmdach *et al.*, (2017)
CLSC	Zolfagharinia *et al.*, (2014); Salmasnia *et al.*, (2015); Parsaiyan, Amiri, Azimi, Taghi, *et al.*, (2019)
CLSC e inc	Georgiadis and Athanasiou, (2013); Sudarto, Takahashi and Morikawa, (2017); Hasani, Eskandarpour and Fattahi, (2018)
CLSC e Rec	M. Godichaud and Amodeo, (2013); Mo, Li and Huang, (2015); Miao, Wang and Chen, (2017)
GR	A. Xanthopoulos and Iakovou, (2009); Berthaut, Gharbi and Pellerin, (2010); de Felice and Petrillo, (2012); Lieder *et al.*, (2017); Zou *et al.*, (2018); Straka *et al.*, (2019); Vondra, Touš and Teng, (2019); Tosarkani, Amin and Zolfagharinia, (2020); Tozanlı, Kongar and Gupta, (2020); Lameh *et al.*, (2021); Yang and Shan, (2021)
Inc	Godichaud and Amodeo, (2015); Kamran S. Moghaddam, (2015); Aydin *et al.*, (2018); Ameli, Mansour and Ahmadi-Javid, (2019); Elia, Gnoni and Tornese, (2019); Motevalli-Taher, Paydar and Emami, (2020); Liao *et al.*, (2021)
PA	Liu *et al.*, (2021)
PCP	Ma, Wang and Chen, (2017); Ebner, Young and Geraghty, (2019)
R	H Gilani *et al.*, (2020); Moghaddam, (2015); Wang *et al.*, (2018); R. Zhao *et al.*, (2018)
R e Inc	Qin and Ji, (2010); Dai and Zheng, (2015); Fattahi and Govindan, (2017); Yang and Chen, (2020)
R e Rec	Harding and Swarnkar, (2009)
R, C e VRP	Gamberini *et al.*, (2010); Mar-Ortiz, Adenso-Diaz and González-Velarde, (2011)
R, C, L e inc.	Suyabatmaz, Altekin and Şahin (2014)
Rec	Zanoni, Ferretti and Tang, (2006); Nikolaidis, (2009); Martinsen and Gulbrandsen-Dahl, (2015); Alqahtani and Gupta, (2017); A Y Alqahtani and Gupta, (2018); Wakiru *et al.*, (2018); Çetinay *et al.*, (2020); Züst *et al.*, (2021)
Rec e inc	Poonam Khanijo Ahluwalia and Nema, (2006); Kusumastuti, Piplani and Lim, (2009); Topcu, Benneyan and Cullinane, (2013)
SC	Kostin *et al.*, (2015); Y. Zhao *et al.*, (2018)
VRP	Bottani and Casella, (2018); Hong *et al.*, (2019); Lixia He-Lambert, Shylo, Burton C. English, *et al.*, (2019); Shamsuzzoha, Ndzibah and Kettunen, (2020)
não especificado	Asensio-Delgado *et al.*, (2020); Bag *et al.*, (2020)

Fonte – Próprio autor

2.5.7.3 Tipo de simulação e plataformas usadas na otimização via simulação

Ao analisar os trabalhos que utilizam otimização via simulação em logística reversa, observa-se o uso de diferentes tipos de simulação e de diversas plataformas de software para construção dos modelos. Cerca de 74% dos artigos analisados pela revisão de literatura apresentam pelo menos um tipo de simulação usada, nota-se também que cerca de 26% dos artigos não relataram um tipo de simulação. A Figura 21 apresenta os tipos de simulações utilizadas para auxiliar na solução dos problemas dos artigos analisados, ao qual a Simulação de Monte Carlo (SMC), Simulação a Eventos Discretos (SED) e Simulação Dinâmica (SD) são os 3 tipos que se destacam, representando cerca de 42 artigos analisados.

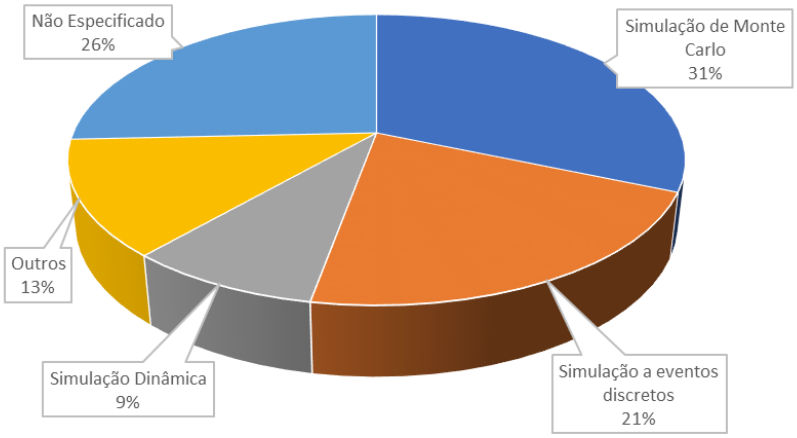

Figura 21 – Artigos que utilizaram simulação combinado com otimização
Fonte – Próprio autor

Sobre aos artigos que trabalham com a simulação de Monte Carlo, a pesquisa de Yang e Chen (2020) que aplicou a simulação para realizar uma investigação de trade-off na rede de logística reversa, ajustando modelos para uma tomada de decisão diante as incertezas. Liu *et al.* (2021) aplica a simulação de Monte Carlo na cadeia de suprimento com o intuito de construir um modelo de aproximação média amostral e um modelo aproximado de programação inteira mista (MIP). Outro autor que aplicou tal ferramenta foi Lixia He-Lambert, Shylo e Burton C. English *et al.* (2019), nesta pesquisa a simulação de Monte Carlo foi aplicada em conjunto com a programação estocástica para avaliar a distribuição do menor custo de biomassa sob demanda incerta do produtor.

No que se refere aos artigos analisados que descrevem a simulação a eventos discretos tem-se o estudo de Tozanlı, Kongar e Gupta (2020), essa pesquisa desenvolve um sistema de desmontagem sob encomendas visando extrair os custos esperados de uma política de troca, modelando imitações padronizadas do uso de produtos inteligentes e seus componentes durante o período de utilização. Mesmo com objetivos diferentes, mas usando a mesma técnica de simulação tem-se a pesquisa Ebner, Young e Geraghty (2019) no qual modela uma cadeia de suprimento em malha fechada com a produção sendo entregue a um mercado aberto que devolve produtos para serem reciclados, remanufaturado e recondicionados. Outro autor que aplica simulação a eventos discretos é Zolfagharinia *et al.* (2014), em sua proposta surge o método de pesquisa de vizinhança variável híbrida que combina a técnica de simulação com algoritmo meta-heurístico para solucionar um novo modelo de controle de estoque para compras conjuntas e remanufatura em uma cadeia de suprimento reversa.

Em terceira posição em destaque se encontra a simulação dinâmica que inclui pesquisas como as de Georgiadis e Athanasiou (2013), nesse estudo os pesquisadores buscam facilitar a tomada de decisão para a gestão de estratégias de investimento em grande escala, considerando

a prontidão de capacidade ou estratégia flexível de baixo volume empregando uma abordagem de otimização dinâmica de sistemas baseados em simulação. Já Miao, Wang e Chen, (2017) desenvolveram um modelo e simularam uma cadeia de suprimento em circuito fechado por meio da simulação dinâmica, com o intuito de solucionar problemas com reciclagem de lixo eletrônico. Mo, Li e Huang, (2015) aplicam uma modelagem de simulação dinâmica na cadeia de suprimento reversa de manufatura em dois estágios, reprodutor e reciclador. Esse modelo de simulação visa analisar a cadeia de suprimento com o propósito de melhorar a estrutura, otimizando parâmetro importante do modelo para reduzir custo de operações e aumento de lucro bruto. Para resumir os tipos de simulações usadas na otimização via simulação aplicada a logística reversa, a tabela 6 estratifica os tipos de simulação em relação às áreas de aplicação.

Tabela 6 - Tabela dos autores relacionados ao tipo de simulação relacionado a área de aplicação e softwares de simulação usado.

Área de aplicação	Simulação de Monte Carlo	Simulação a eventos discretos	Simulação Dinâmica
Agricultura	L He-Lambert *et al.*, 2019	Motevalli-Taher, Paydar and Emami, 2020	R. Zhao *et al.*, 2018
Construção Civil	Yang and Chen, 2020; Züst *et al.*, 2021		
Energia	Haraguchi, Siddiqi and Narayanamurti, 2019		
Farmacêutica		Shamsuzzoha, Ndzibah and Kettunen, 2020	
Manufatura	P K Ahluwalia and Nema, 2006; A Xanthopoulos and Iakovou, 2009; Nikolaidis, 2009; Topcu, Benneyan and Cullinane, 2013; Dai and Zheng, 2015b; Kamran S. Moghaddam, 2015a, 2015b; Bottani, Montanari and Rinaldi, 2019; Sakarika *et al.*, 2019a, 2019b; Vondra, Touš and Teng, 2019b; H. Gilani, Sahebi and Oliveira, 2020; Tosarkani, Amin and Zolfagharinia, 2020; Liao *et al.*, 2021; Liu *et al.*, 2021	Zanoni, Ferretti and Tang, 2006; Harding and Swarnkar, 2009; Gamberini *et al.*, 2010; Zolfagharinia *et al.*, 2014; Alqahtani and Gupta, 2017; Y Costa-Salas, Sarache and Überwimmer, 2017; Ammar Y. Alqahtani and Gupta, 2018; Hasani, Eskandarpour and Fattahi, 2018; Wakiru *et al.*, 2018; Ebner, Young and Geraghty, 2019; Tozanlı, Kongar and Gupta, 2020	(Georgiadis and Athanasiou, 2013; Mo, Li and Huang, 2015b; Miao, Wang and Chen, 2017b; Y. Zhao *et al.*, 2018b)
Serviços		M Godichaud and Amodeo, 2013	Sudarto *et al.*, 2017

Fonte – Próprio autor

Complementando a discussão anterior, as plataformas (*software*) utilizadas para construir modelos de simulação para a otimização via simulação na logística reversa, podem variar de acordo a Figura 4 que demonstra os 10 principais *softwares*, usados para modelar a simulação na logística reversa. Cerca de 69% das publicações incluem: *Excel*®, *Arena*®, *Anylogic*®, *Matlab*®, *Aspen Plus*®, *ExtendSim*®, *gPROMS*®, *Java*®, *ModeFrontier*®,

PowerSim® e outros. Esses pacotes comerciais apresentam uma preferência devido à facilidade de construção de modelos, relatórios customizados, interfaces gráficas e principalmente as disposições de funcionalidades (LU *et al.*, 2019; SANTOS *et al.*, 2021).

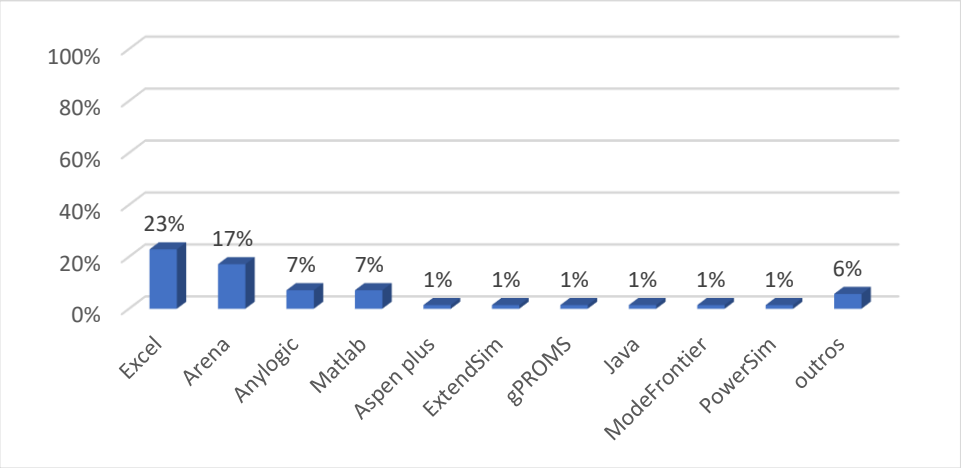

Figura 22 – Artigos que utilizam simulação combinado com otimização
Fonte – Próprio autor

Por fim, os outros 31% das publicações não especificaram a plataforma utilizada para o desenvolvimento dos projetos de simulação.

Tabela 7 - Softwares de simulação X tipos de simulação (continua)

Softwares de simulação	Simulação de Monte Carlo	Simulação a eventos discretos	Simulação Dinâmica	Outros
Anylogic		Shamsuzzoha, Ndzibah and Kettunen, 2020	Sudarto, Takahashi and Morikawa, 2017	Lieder *et al.*, 2017; Elia, Gnoni and Tornese, 2019; Parsaiyan, Amiri, Azimi, Taghi, *et al.*, 2019
Arena		Zanoni, Ferretti and Tang, 2006; Harding and Swarnkar, 2009; Zolfagharinia *et al.*, 2014; Salmasnia *et al.*, 2015; Alqahtani and Gupta, 2017; Ammar Y. Alqahtani and Gupta, 2018; Hasani, Eskandarpour and Fattahi, 2018; Wakiru *et al.*, 2018; Motevalli-Taher, Paydar and Emami, 2020a; Tozanlı, Kongar and Gupta, 2020		

Fonte – Próprio autor

Tabela 8 - Softwares de simulação X tipos de simulação (conclusão)

Softwares de simulação	Simulação de Monte Carlo	Simulação a eventos discretos	Simulação Dinâmica	Outros
Excel	Poonam Khanijo Ahluwalia and Nema, 2006b; A Xanthopoulos and Iakovou, 2009; Nikolaidis, 2009; Topcu, Benneyan and Cullinane, 2013; Dai and Zheng, 2015a; Kamran S. Moghaddam, 2015b, 2015a; Bottani, Montanari and Rinaldi, 2019; Haraguchi, Siddiqi and Narayanamurti, 2019; Lixia He-Lambert, Shylo, Burton C English, *et al.*, 2019; Sakarika *et al.*, 2019a, 2019c; Vondra, Touš and Teng, 2019b; Liao *et al.*, 2021; Züst *et al.*, 2021			
ExtendSim		Ebner, Young and Geraghty, 2019		
gPROMS				
Java				Suyabatmaz, Altekin and Şahin, 2014
Matlab	Hong *et al.*, 2019; Çetinay *et al.*, 2020; Yang and Chen, 2020			Ma *et al.*, 2019
ModeFrontier				
PowerSim			Georgiadis and Athanasiou, 2013	
Promodel		Yasel Costa-Salas, Sarache and Überwimmer, 2017		
Simul8		Gamberini *et al.*, 2010		
Vensim			Y. Zhao *et al.*, 2018	
Visual Slam				Berthaut, Gharbi and Pellerin, 2010
não especificado	Aydin *et al.*, 2018; H. Gilani, Sahebi and Oliveira, 2020; Tosarkani, Amin and Zolfagharinia, 2020; Liu *et al.*, 2021	M. Godichaud and Amodeo, 2013	Mo, Li and Huang, 2015a; Miao, Wang and Chen, 2017a; R. Zhao *et al.*, 2018	Qin and Ji, 2010; Ma, Wang and Chen, 2017; Sun, Lu and Zhang, 2019

Fonte – Próprio autor

2.5.7.4 Tipos de otimizações e plataformas usadas para solucionar problemas em LR usando otimização via simulação

Com base na literatura, os modelos de otimização aplicados à logística reversa podem ser classificados de acordo com o número de objetivos considerados, sendo estes de natureza monoobjetivo ou multiobjetivo (RAO, 2009). A Figura 23 apresenta os tipos de formulações

de otimização adotadas nos estudos analisados. Cerca de 70% dos artigos otimizam um ou mais objetivos específicos relacionados à logística reversa, enquanto aproximadamente 30% dos trabalhos não especificaram o tipo de abordagem utilizada.

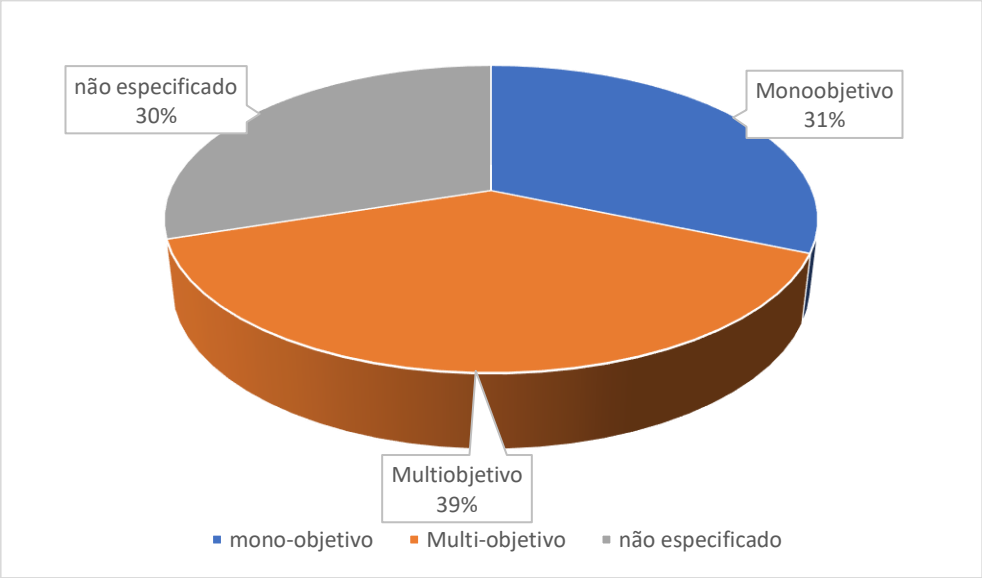

Figura 23 – Tipos de otimização
Fonte – Próprio autor

Considerando ao objetivo da otimização para problemas associados aos artigos analisados, a tabela 9 demonstra que cerca de 17% destes artigos estão solucionando funções de maximização e que 33% dos artigos solucionam funções de minimização. Entre esses artigos, a pesquisa de Lameh *et al.* (2021) que maximiza um problema da área de economia circular, utilizando como software auxiliar o simulador *Aspen plus*®. Além disso, os autores Tosarkani, Amin e Zolfagharinia (2020), solucionam problemas complexos da área de logística reversa utilizando em sua pesquisa uma otimização multiobjetivo, aplicando uma programação linear inteira mista (MILP) por meio do software *CPLEX*®. Enquanto Wang *et al.* (2018) aplica em sua pesquisa uma otimização que maximiza um problema associado a um problema redes na logística reversa, destacando a utilização do software *Matlab*® na construção do algoritmo *simulated anneling* (SA) que soluciona um problema monoobjetivo.

Para os artigos que solucionam problemas de otimização que dispõem como objetivo a minimização, têm-se os autores como Tozanlı, Kongar e Gupta (2020) que empregam em sua pesquisa o software *lingo*® e o algoritmo de programação linear inteira mista (MILP) na solução de um problema envolvendo a gestão de retorno da área de cadeia de suprimento. Também temos a pesquisa Sun, Lu e Zhang (2019b) que aborda um problema na área de logística visando solucionar uma adversidade com a coleta, otimizando uma função multi-objetivo com o intuito de minimizá-la por meio do software *lingo*® e o algoritmo de programação linear inteira mista (MILP), tendo como suporte a simulação difusa. Já 27% dos

artigos analisados resolvem problemas de otimização que envolve funções de maximização e minimização em um mesmo problema.

O estudo realizado pelos autores Gilani, Sahebi e Oliveira (2020) descrevem um problema redes do campo da cadeia de suprimento, os pesquisadores aplicam uma programação linear inteira mista (MILP) por meio do software *CPLEX*® combinando com a simulação de Monte Carlo com intuito de solucionar esse problema. Outra pesquisa que abrange os objetivos de otimização de maximização e minimização é apresentada pelos pesquisadores Yasel Costa-Salas, Sarache e Überwimmer (2017), o estudo aplica uma simulação a eventos discretos utilizando o software *Promodel*® a um problema de coleta do campo de cadeia de suprimento, após a simulação uma função objetivo é extraída para a otimização por meio do software *SimRunner*®, onde é otimizada pelo algoritmo genético (GA). Por fim, têm-se 23% dos artigos lidos como não especificados, isto é, não informando o objetivo da otimização.

Tabela 9 – Objetivos da otimização

Objetivos da Otimização	
MAX	17%
MAX E MIN	27%
MIN	33%
NÃO ESPECIFICADO	23%

Fonte – Próprio autor

A Figura 24 apresenta os softwares de otimização usados nos problemas que envolvem a otimização via simulação na logística reversa. Nota-se que as 5 principais ferramentas incluem: *CPLEX*®, *OPTQUEST*®, *LINGO*®, *MATLAB*® e *ModeFRONTIERTM*®. Esses instrumentos representam cerca de 46% dos softwares utilizados pelos artigos analisados. Percebe-se também que 54% dos artigos lidos não especificam qual software está sendo utilizado.

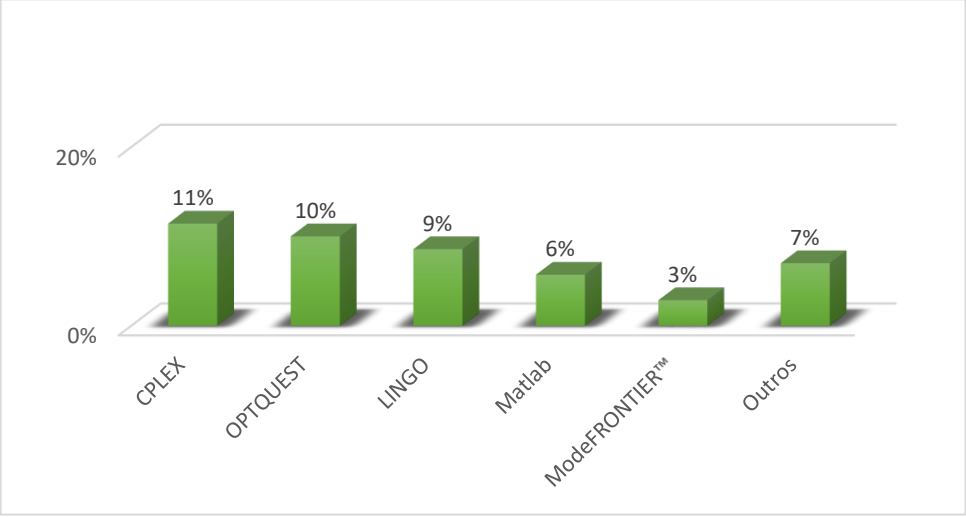

Figura 24 – Softwares para otimização
Fonte – Próprio autor

Quanto as técnicas de otimização, a Tabela 10 apresenta uma série de algoritmos que solucionaram problemas de otimização via simulação aplicado a logística reversa. Entres os algoritmos que se destacam na resolução dos problemas associados a logística reversa foi o algoritmo de programação linear inteira mista *Branch and Bound* com 21,43% dos artigos. Em seguida, o algoritmo genético (GA) representa cerca de 8,57% dos trabalhos lidos na revisão de literatura, ficando com a segunda posição. Por fim, na terceira posição representando 5,71% têm-se os algoritmos híbridos que são combinações de algoritmos em busca de melhores soluções.

Tabela 10 – Algoritmo de otimização

Algoritmos de otimização	
Branch and Bound	21,43%
GA	8,57%
Algoritmo Híbrido	5,71%
Simulated annealing (AS)	4,29%
Goal Programming	1,43%
multi-dimensional golden section search algorithm	1,43%
Redes neurais artificiais	1,43%

Fonte – Próprio autor

Os demais algoritmos que foram utilizados nos artigos são apresentados na tabela, nota-se que o percentil deles se mostram baixos, totalizando 44,29% dos artigos que utilizaram algoritmos para solucionar problemas. Vale Ressaltar que 55,71% dos artigos não especificaram o tipo de algoritmo utilizado na solução de seus problemas.

Tabela 11 – Algoritmos e Tipos de otimização

	Tipos de otimização	
Algoritmos	**Monoobjetivo**	**Multiobjetivo**
Branch and Bound	Lixia He-Lambert *et al.*, 2019a; Mar-Ortiz *et al.*, 2011b; Nikolaidis, 2009; Suyabatmaz *et al.*, 2014; Tozanlı *et al.*, 2020; A. Xanthopoulos and Iakovou, 2009; Yang and Chen, 2020	Poonam Khanijo Ahluwalia and Nema, 2006; H. Gilani *et al.*, 2020; Kostin *et al.*, 2015; Liu *et al.*, 2021; K S Moghaddam, 2015b; Motevalli-Taher *et al.*, 2020a; Sun *et al.*, 2019; Tosarkani *et al.*, 2020
GA	Dai and Zheng, 2015; Harding and Swarnkar, 2009	Aydin *et al.*, 2018; Bottani and Casella, 2018; Yasel Costa-Salas *et al.*, 2017; Ebner *et al.*, 2019
Algoritmo Híbrido	-	Godichaud and Amodeo, 2015; M. Godichaud and Amodeo, 2013; Kusumastuti *et al.*, 2009; Ma *et al.*, 2019
Simulated annealing (AS)	Fattahi and Govindan, 2017; Wang *et al.*, 2018	Ameli *et al.*, 2019
Goal Programming	-	K. S. Moghaddam, 2015
Multi-dimensional golden section Search algorithm	Topcu *et al.*, 2013	-
Redes neurais artificiais	Vondra *et al.*, 2019	-

Fonte – Próprio autor

Em busca de estratificar ainda mais os algoritmos e os tipos de otimização, a Tabela 11 apresenta uma lista de autores que desenvolveram trabalhos relacionando ambas abordagens na solução do problema de pesquisa em questão.

2.5.7.5 Exploração das dimensões sustentáveis aplicando a otimização via simulação na LR

Sudarto *et al.* (2016) descrevem em sua pesquisa o impacto do comportamento da logística reversa como uma responsabilidade social diante do planejamento da capacidade e o ciclo de vida do produto com suas incertezas herdadas, reforçando os resultados frente as três dimensões sustentáveis. Com o intuito de compreender as dimensões onde a sustentabilidade se enquadra na otimização via simulação aplicado a logística reversa, a Figura 25 mostra a dimensão que representa o maior percentual dessa responsabilidade, ou seja, a dimensão econômica e ambiental combinada descreve cerca de 33%.

Dentre os trabalhos quem envolvem as dimensões econômicas e sustentáveis tem-se os autores Sakarika *et al.*, (2019) que em sua pesquisa tem em vista solucionar situações da área da economia circular para maximizar as economias, de modo a reduzir os impactos ambientais, tratando de problemas de transporte e coleta. Já Mar-Ortiz, Adenso-Diaz e González-Velarde (2011) se encontram também dentro dessa dimensão devido a sua pesquisa, isto é, soluciona adversidades na área da logística reversa como redes, coleta e transporte. E por fim, Bottani, Montanari e Rinaldi (2019) apresentam uma pesquisa com dificuldades na logística reversa, especificamente na coleta, ao qual a solução impacta diretamente na dimensão econômica e sustentável.

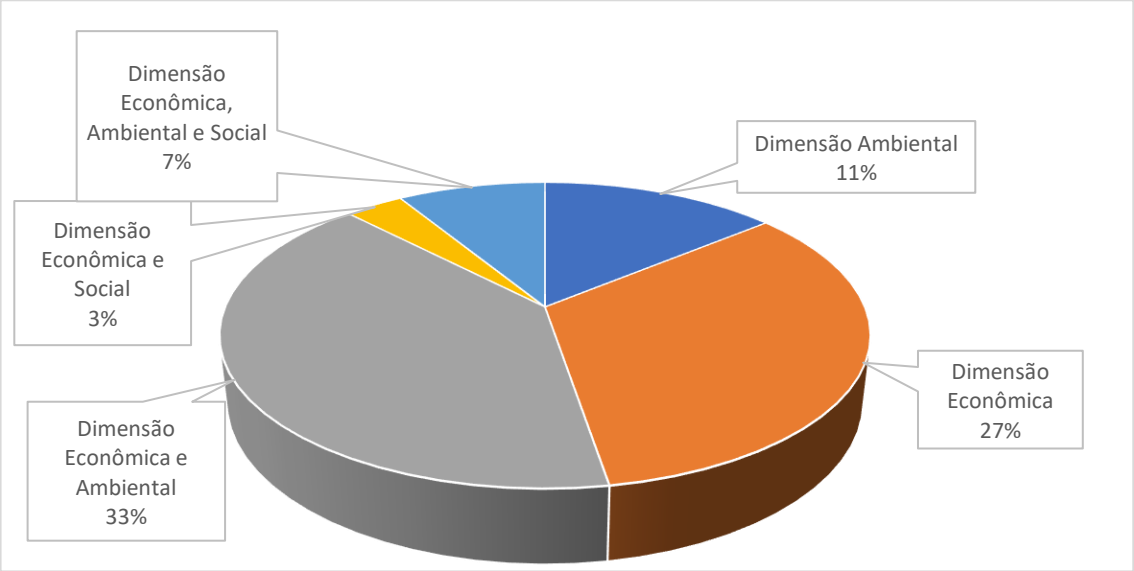

Figura 25 – Dimensões da sustentabilidade (Responsabilidade social da Logística Reversa)
Fonte – Próprio autor

Nota-se que a segunda maior dimensão que aparece na Figura 25 é a econômica, que representa cerca de 27% dos trabalhos analisados. Nesta dimensão, diversas pesquisas foram desenvolvidas em busca de solucionar problemas que incluem: Redes (KAMRAN MOGHADDAM, 2015; WANG *et al.*, 2018), coleta (MA *et al.*, 2019), gestão de recursos (BERTHAUT, GHARBI e PELLERIN, 2010; VONDRA, TOUŠ E TENG, 2019), recuperação (ZANONI, FERRETTI E TANG, 2006; NIKOLAIDIS, 2009; ZÜST *et al.*, 2021), *closed loop supply chain* (CLSC) (ZOLFAGHARINIA *et al.*, 2014; SALMASNIA *et al.*, 2015) e incertezas (GODICHAUD E AMODEO, 2015; KAMRAN S. MOGHADDAM, 2015).

A terceira dimensão a surgir com apenas 11% dos artigos, considera os aspectos ambientais. Nesta dimensão, os pesquisadores Haraguchi, Siddiqi e Narayanamurti (2019) abordam um problema de coleta na área da economia circular, ao qual buscam uma solução por meio da simulação de Monte Carlo. Abaixo dos 7% ficam as dimensões econômica, ambiental e social e econômica e social, no qual possuem problemas voltados: recuperação (ALQAHTANI E GUPTA, 2017), recuperação e closed loop supply chain (CLSC) (M. GODICHAUD E AMODEO, 2013), closed loop supply chain (CLSC) e incerteza (SUDARTO, TAKAHASHI E MORIKAWA, 2017), coleta e local (SHOKOHYAR E MANSOUR, 2013), incerteza(AMELI, MANSOUR e AHMADI-JAVID, 2019 e MOTEVALLI-TAHER, PAYDAR E EMAMI, 2020) e problema de roteamento de veículos (VRP) (HONG *et al.*, 2019). Por fim, tem-se as dimensões não especificadas, ou seja, 19% dos artigos analisados não definem um tipo de dimensão sustentável.

2.5.7.6 Principais vantagens, limitações e oportunidades de pesquisa associada a esta abordagem

Embora o uso da otimização via simulação aplicado na logística reversa vem sendo explorado ao longo dos anos, ainda existem inúmeras oportunidades a serem exploradas tanto em termos práticos quanto teóricos, dadas as dificuldades e desafios ainda associados a essa abordagem. Portanto, os trabalhos considerados nesta RSL foram analisados a partir das vantagens associadas ao uso da otimização via simulação aplicado na logística reversa, as limitações dessa prática, bem como as oportunidades destacadas pelos autores. O quadro 3 resume os principais achados relacionados a esta análise.

Quadro 3 – Resumo das principais descobertas relacionado a otimização via simulação aplicado à logística reversa

	Descobertas
Vantagem	✓ Possibilita uma gestão de estoque, menores acúmulos de demandas de clientes e maior custo-eficácia das operações (EBNER, YOUNG e GERAGHTY, 2019). ✓ Permite uma análise de sensibilidade dos principais parâmetros (MOTEVALLI-TAHER, PAYDAR e EMAMI, 2020). ✓ Permite compreender as dimensões associada a sustentabilidade, de modo a seguir a importância dos aspectos econômicos, ambientais e sociais (KUSUMASTUTI, PIPLANI E LIM, 2009 e ALQAHTANI E GUPTA, 2017). ✓ Permite integração da simulação com otimização de maneira a maximizar ou minimizar um objetivo (A. XANTHOPOULOS E IAKOVOU, 2009; BERTHAUT, GHARBI E PELLERIN, 2010 e GAMBERINI *et al.*, 2010). ✓ Permite avaliar diversos cenários(HARDING E SWARNKAR, 2009).
Limitações	✓ Embora existam ferramentas que auxiliam o processo de otimização via simulação aplicado a logística reversa, muitas vezes são necessários considerar os fatores de incerteza (YANG E CHEN, 2020). ✓ Nota-se uma preocupação com os aspectos ambientais com relação as emissões de gases poluentes na atmosfera, considerando uma limitação com o custo marginal da empresa (BOTTANI E CASELLA, 2018; R. ZHAO *et al.*, 2018 e SUN, LU E ZHANG, 2019). ✓ Obstáculo substancial é localizar novos mercados para coprodutos ou produtos reaproveitados a atender esses mercados com menores custos (LIXIA HE-LAMBERT, SHYLO, BURTON C. ENGLISH, *et al.*, 2019). ✓ Segurança no processo de ponderação subjetiva dos tomadores de decisão em relação aos problemas de tomada de decisão multicritérios, viabilizando algoritmos no decorrer a decisão(KAMRAN S. MOGHADDAM, 2015). ✓ Problemas de otimização de multi-períodos (NIKOLAIDIS, 2009).
Oportunidades	✓ Para direcionar melhor as investigações devem-se aumentar o nível de detalhe na modelagem (GILANI, SAHEBI e OLIVEIRA, 2020). ✓ A combinação da simulação a eventos discretos e o método de otimização NBI - Normal Boundary Intersection, entre outras abordagens otimizantes (OLIVEIRA, 2019). ✓ Além dos obstáculos inerentes relacionados aos custos e aspectos ambientais das organizações, considera-se importante a integração do fator sociais (Yang e Chen, 2020). ✓ Investimento em outras abordagens sustentáveis, como: transporte elétricos e telhados verdes (Hong *et al.*, 2019). ✓ Aplicação de gêmeos digitais para problemas da logística reversa (Züst *et al.*, 2021) ✓ Propor outras abordagens algorítmicas e diretrizes gerais (Topcu, Benneyan e Cullinane, 2013; Yasel Costa-Salas, Sarache e Überwimmer, 2017)

Fonte – Próprio autor

2.5.8 Conclusões da RSL da OvS aplicado a LR

A logística reversa tem se tornado um fator decisivo para as organizações, pois trata de uma das diversas áreas que motivam investigações de melhoria para inúmeras dificuldades presentes neste domínio, isto devido à associação deste campo e os impactos ambientais, sociais e econômicos dessas empresas. Além disso, a otimização via simulação se apresenta como recurso que auxilia estas investigações, de tal maneira a orientar o processo de tomada de decisão.

Dessa forma, observa-se que o número de artigos que abordam essa temática vem crescendo ao longo dos últimos anos, no entanto, esses números por ano se mostram baixo em relação à expectativa de crescimento do campo. Nota-se, também, inúmeras áreas de aplicação e natureza do problema se revelando durante a pesquisa, indicando que o campo é recheado de possibilidades de estudo, destacando-se a logística reversa propriamente dita e a gestão de recurso.

No que diz respeito aos tipos de simulações usadas, presencia-se um grande volume de publicações aplicando a simulação de Monte Carlo, seguido por simulação a eventos discretos e pôr fim a simulação dinâmica. Em relação às plataformas usadas para construir esses modelos de simulação, a maioria dos artigos referiu-se ao uso de softwares comerciais como *Excel®, Arena®* e *Anylogic®,* devido aos recursos disponíveis. Em contrapartida, existe também uma porcentagem de publicações que optaram pelo uso de linguagens de programação para não se limitar somente aos recursos dos softwares comerciais, desenvolvendo ainda mais a capacidade do projeto.

Quanto aos métodos de otimização utilizado pelas pesquisas, a maioria dessas publicações buscam solucionar problemas que envolve multiobjetivo e monoobjetivo. Há também uma definição dos objetivos, isto é, como esses problemas serão resolvidos, seja por maximização, minimização, ou até mesmo realizar ambos. Além dos tipos de otimização, identificaram-se também as principais plataformas utilizadas no desenvolvimento dos modelos. Durante a análise dos estudos, destacaram-se os seguintes softwares: *CPLEX®, OPTQUEST®, LINGO®, MATLAB® e ModeFRONTIER™®* como os mais empregados nas aplicações.

Por fim, no que se refere às dimensões da sustentabilidade associadas ao uso da otimização via simulação na logística reversa, os trabalhos analisados evidenciam uma preocupação recorrente com os aspectos econômicos, ambientais e sociais, reafirmando o papel da logística reversa como agente de responsabilidade socioambiental.

Entre as principais vantagens associadas ao uso da otimização via simulação aplicada a logística reversa temos o fato da contribuição com o planejamento estratégico, tático e operacional das organizações. Além disso, auxilia no processo de tomada de decisão a partir das variáveis atreladas ao problema de pesquisa, permitindo compreender as dimensões da sustentabilidade, de tal forma, a integrar as áreas da simulação e otimização, realizando testes em diversos cenários.

Embora as vantagens se mostraram relevantes a temática, algumas limitações surgem diante a esse campo, um desses obstáculos se encontra no fator incerto de números de caminhões, redes de transporte, demandas, localizações, coletas, entre outros fatores

importantes. Inclusive uma limitação em relação às questões ambientais, isto é, considerar uma margem de lucro das organizações comparado ao impacto ambiental, de modo a reduzir a emissão de gases poluente na atmosfera.

Outra limitação que se levanta é o mercados de coprodutos, ou seja, produtos em que são desenvolvidos por reaproveitamento com custo menores, essa barreira se faz presentes devido à baixa aceitação desta mercadoria pelos consumidores. Além disso, com outras limitações no processo de otimização, isto é, ponderações subjetivas dos tomadores de decisão em problemas multicritérios, em vez de utilizar de algoritmos que auxiliam na decisão, e por fim, o processo de otimização multi-período.

Enfim destacam-se algumas oportunidades neste campo de pesquisa, como a necessidade de melhorar os detalhes de modelagem dos problemas, as dimensões sustentáveis que tratam os aspectos sociais combinadas aos aspectos econômicos e ambientais, repensar em transporte elétricos e telhados sustentáveis, aplicação de gêmeos digitais para problemas logísticos, e por fim, abordar outros algoritmos e diretrizes gerais para o problema em questão. Um ponto importante a ser considerado neste campo de estudo refere-se às técnicas de inteligência artificial, como *machine learning*, *deep learning*, *reinforce learning*, *neural networking artificial*, entre outras. Essas abordagens podem auxiliar também na otimização das soluções complexas que existem neste campo.

Portanto, esta RSL não teve como foco a análise isolada de técnicas específicas de simulação ou de otimização, mas sim uma abordagem abrangente com o intuito de identificar as principais estratégias adotadas na literatura para apoio à tomada de decisão em logística reversa. Os resultados obtidos por meio da revisão sistemática permitiram construir uma base teórica sólida que contempla diversas áreas de aplicação, tipos de problemas e objetivos otimizados.

A partir dessa análise, identificam-se oportunidades relevantes para aprofundar a integração entre simulação e otimização, especialmente sob uma perspectiva multiobjetivo e sustentável, que considere simultaneamente os aspectos econômicos, ambientais e sociais.

Como contribuição para a tese, a RSL revela uma lacuna em abordagens que combinem meta-heurísticas com simulação estocástica aplicada à logística reversa sob incerteza, indicando um potencial promissor para o desenvolvimento de modelos híbridos que otimizem decisões logísticas em ambientes realistas e complexos, o que justifica e orienta a proposta metodológica da presente pesquisa.

3 MÉTODO DE PESQUISA

Neste capítulo, será descrito o método utilizado na elaboração desta tese, categorizando sua natureza, objetivo, abordagem e método. Em seguida, serão fornecidos detalhes sobre os métodos de pesquisa adotados, Experimentação, Modelagem e Simulação, incluindo as suas principais características e etapas. Finalmente, serão apresentadas as etapas seguidas neste trabalho.

3.1 Classificação da pesquisa

A pesquisa pode ser definida como um estudo planejado sobre um problema ou situação, e é o método de abordagem que dá a ela seu aspecto científico (PROVDANOV e FREITAS, 2013). Miguel *et al.*, (2018) ressaltam que a classificação da pesquisa é imprescindível para o direcionamento das atividades a serem executadas e pode ser classificada quanto à sua natureza, seu objetivo, sua abordagem e método adotado. Sendo assim, a Figura 26 representa as principais classificações da presente pesquisa.

Figura 26 – Classificação da pesquisa
Fonte – Adaptado Miguel *et al.* (2018)

Quanto à natureza do problema, a pesquisa pode ser categorizada como (i) básica: cujo objetivo é produzir conhecimento científico sem finalidade prática; ou (ii) aplicada: quando o objetivo é aplicar esses conhecimentos a problemas específicos. De acordo com essas categorizações, a tese em questão pode ser classificada como pesquisa aplicada, pois se trata de um trabalho focado em encontrar uma solução prática, testada em situações teóricas e práticas, e com potencial para ampla implementação em processos produtivos (PROVDANOV e FREITAS, 2013).

Em relação à abordagem, nota-se três tipos, são elas: qualitativa, quantitativa e combinada. Ainda, destacam que a abordagem qualitativa envolve interpretar um fenômeno, buscando descrever e compreender suas variáveis por meio de práticas sem muita ou sem nenhuma quantificação. Já, a abordagem quantitativa começa com teorias, formulando hipóteses, coletando dados por observações, analisando esses dados e produzindo resultados (MIGUEL *et al.*, 2018). Portanto, esta tese adota uma abordagem quantitativa, pois busca mensurar variáveis operacionais de sistemas reais por meio da coleta e análise de dados, execução de experimentos e avaliação dos impactos das decisões no ambiente de simulação. A natureza quantitativa está associada ao uso de ferramentas como modelagem matemática, simulação computacional e experimentação controlada.

Já com relação aos objetivos, Gil (2008) destaca que uma pesquisa pode ser categorizada como: (i) Exploratória, cujo objetivo é compreender e formular hipóteses sobre certos fenômenos; (ii) Descritiva, cujo objetivo principal é descrever propriedades de certos fenômenos; e (iii) Explicativa, quando se concentra em identificar os fatores que afetam certos fenômenos (GIL, 2002). Neste trabalho, a pesquisa é classificada como explicativa, pois tem como objetivo compreender as interações entre variáveis da logística reversa e analisar seus impactos sob diferentes perspectivas. No entanto, também apresenta caráter normativo, uma vez que propõe uma solução otimizada, baseada em modelagem e simulação, que pode ser aplicada para apoiar a tomada de decisão em sistemas reais. Assim, o estudo não apenas explica os fenômenos, mas também propõe uma solução recomendada e justificável com base nos resultados obtidos.

Por fim, Miguel *et al.*, (2018) explicam que, no contexto da abordagem quantitativa, destacam-se três métodos de pesquisa comumente empregados, sendo (i) Pesquisa de Avaliação (*survey*), coleta e analisa informações sobre um fenômeno ou característica com base em questionários ou outros instrumentos aplicados a um grupo específico; (ii) Modelagem e Simulação usa abstrações de sistemas baseadas em modelos com o intuito de identificar problemas, coletar informações, formular hipóteses e ajudar no processo de tomada de decisões.

Sendo assim, o presente trabalho irá se basear nos métodos de Modelagem e Simulação. Com base nesse método, iniciou-se um desenvolvimento de um modelo de simulação para a LR, cujo objetivo será a otimização multiobjetivo via simulação sob as perspectivas econômicas, sociais e ambientais relacionadas à responsabilidade social da LR. Portanto, a próxima seção tem como finalidade apresentar explorar com mais detalhes a experimentação e a modelagem e simulação.

3.2 Modelagem e Simulação

De acordo com Montevechi *et al.* (2015), há vários métodos e estruturas que descrevem as etapas importantes na criação de projetos de simulação. Os autores, destacam que os métodos podem ser divididos em três grandes fases, chamadas de "Concepção", "Implementação" e "Análise".

Para explicar cada fase, Montevechi *et al.* (2020) apresenta a fase de Concepção envolvendo cinco etapas: (I) estabelecer metas e identificar o sistema em questão, (II) construir o modelo conceitual, (III) validar o modelo conceitual, (IV) documentar o modelo conceitual, e (V) preparar os dados de entrada para o modelo. Ao final será obtido o Modelo Conceitual como objeto de pesquisa.

Complementando a fase anterior, a fase de Implementação consiste nas seguintes atividades: (VI) Desenvolvimento do modelo computacional, (VII) Verificação do modelo computacional, (VIII) Configuração dos dados para atualizar o modelo e estabelecer as respostas desejadas, (IX) Criação da conexão com o processo real e (X) Validação do modelo computacional.

Por fim, a Análise é composta pelos seguintes passos: (XI) estabelecimento dos cenários que serão experimentados, (XII) execução desses cenários de forma periódica, e (XIII) realização de análises e tomadas de decisão. Estes passos asseguram o uso frequente do modelo na tomada de decisões. Para demonstrar as etapas a serem seguidos, a Figura 27 será usada como forma de representação desses passos.

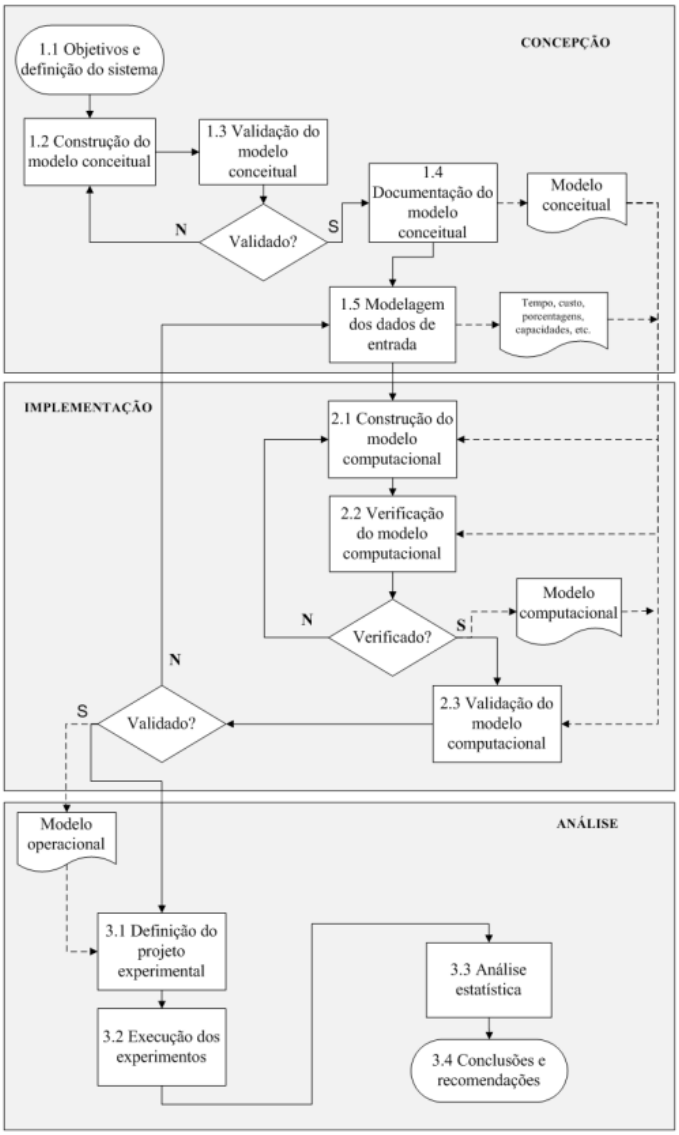

Figura 27 – Etapas seguidas na construção de um projeto de simulação
Fonte – MONTEVECHI *et al.*, (2010)

3.2.1 Fase de Concepção

3.2.1.1 Objetivos, definição do sistema

Nesta etapa inicial, foram estabelecidos os objetivos da pesquisa, que consistem em propor uma abordagem de otimização baseada em simulação aplicada à logística reversa, com ênfase na responsabilidade social. O sistema modelado corresponde ao processo de coleta e redistribuição de materiais pós-consumo, considerando variáveis como demanda coletada, custo operacional e emissão de CO_2. A delimitação do sistema envolveu o mapeamento dos agentes logísticos, pontos de coleta que são as cidades, tipos de veículos e os fluxos logísticos envolvidos.

A escolha deste trabalho em parceria com a uma empresa multinacional do setor de eletroeletrônicos deu-se no âmbito do programa Doutorado Acadêmico para Inovação (DAI),

considerando o interesse da empresa em aprimorar o processo de coleta de resíduos eletrônicos em todo o território nacional. A empresa multinacional enfrenta atualmente desafios significativos relacionados à sua logística reversa, especialmente no que diz respeito à dificuldade de mensurar os custos envolvidos na coleta desses resíduos. Atualmente, o sistema utilizado pela organização considera apenas informações básicas, como as cidades a serem atendidas, as datas de coleta e a quantidade de material a ser recolhido.

Contudo, essa abordagem não contempla variáveis logísticas relevantes, tais como a alocação ótima de veículos, a definição de rotas eficientes e a relação entre capacidade de transporte e custo do deslocamento. Como resultado, a operação torna-se onerosa e pouco transparente, dificultando a avaliação de alternativas mais sustentáveis. Visando contribuir com essa lacuna prática e também com a lacuna teórica, o autor estruturou a revisão de literatura (Capítulo 2) com foco na responsabilidade da logística reversa (LR), destacando a escassez de estudos que tratem de forma integrada os três pilares da sustentabilidade, econômico, ambiental e social, associados à responsabilidade social da LR.

Para a elaboração do modelo conceitual, foram realizadas visitas técnicas à unidade da empresa, onde foi possível observar diretamente o processo de recebimento, triagem e encaminhamento dos resíduos eletrônicos. Embora a empresa atue em todo o território brasileiro, abrangendo uma ampla rede de coleta e logística reversa, este trabalho delimitou-se geograficamente ao estado de São Paulo, com o intuito de tornar o escopo da pesquisa mais viável e garantir maior controle dos dados analisados.

A escolha por essa delimitação também se justifica pelo fato de que, nesta região, a empresa apresenta maior densidade operacional e disponibilidade de registros consolidados sobre os resíduos coletados. Com base nessas informações, foi possível estruturar um modelo conceitual que represente, de forma fiel, a dinâmica da coleta e dos custos associados à logística reversa nesse contexto regional.

Neste sentido, a definição do sistema para realizar a otimização via simulação, aplicada à logística reversa, é estabelecida da seguinte forma:

• Problema: minimizar os custos logísticos (relacionados ao transporte dos veículos) e as emissões de CO_2 provenientes do deslocamento, ao mesmo tempo em que se busca maximizar a quantidade coletada de resíduos eletroeletrônicos. Como consequência direta desse processo, cada quilograma de resíduo coletado é convertido em 1 kg de alimentos doados a instituições sociais, configurando um benefício adicional de caráter socioambiental. Além disso, a otimização contempla a escolha de rotas mais eficientes, reduzindo incertezas operacionais e apoiando o uso racional da frota disponível.

• Cenário real: rotas incertas, capacidade limitada dos veículos e variação na demanda de coleta entre os municípios.

Para estruturar o sistema de otimização via simulação, foram definidos os componentes essenciais do problema logístico, incluindo objetivos, variáveis de decisão, parâmetros e funções objetivo. Esses elementos estão organizados no Quadro 4, o qual sintetiza a modelagem adotada para representar o processo de coleta de resíduos eletroeletrônicos.

Quadro 4 – Quadro de componentes e variáveis que serão considerados ao sistema de otimização via simulação

Componente	Descrição	Tipos
Objetivo Geral	Minimizar custo logístico, emissões de CO_2 e distância; maximizar coleta (kg).	
Variáveis de Decisão	Sequência de visitas por veículo Alocação de veículos por rota	
Parâmetros	Demanda por cidade (kg)	Estocástico
	Capacidade dos veículos (kg)	Fixo
	Distância entre pontos (matriz ou coordenadas geográficas)	Fixo
	Custos por km, emissão por km	Estocástico
Funções Objetivo	**$F_1(x)$:** Custo total (R$)	
	$F_2(x)$: Emissão total (g CO_2)	
	$F_3(x)$: Peso total coletado (kg)	

Fonte – Próprio autor

Dessa forma, a definição dos objetivos, do sistema logístico reverso e dos dados de entrada estabeleceu as bases necessárias para a modelagem do problema de otimização via simulação. Ao considerar múltiplos critérios, custo, emissão de CO_2 e quantidade de resíduos coletados (kg), e adotar uma abordagem realista com dados estocásticos e operacionais, buscou-se refletir com fidelidade os desafios enfrentados pela empresa em sua operação no estado de São Paulo.

Com os elementos fundamentais previamente definidos, a próxima etapa consiste na construção do modelo conceitual, que permite representar de maneira estruturada e lógica o funcionamento do sistema em estudo, suas restrições e inter-relações entre variáveis. Essa modelagem é essencial para a posterior implementação computacional da solução de otimização proposta.

3.2.1.2 Construção do modelo conceitual

A construção do modelo conceitual do sistema de logística reversa de resíduos eletrônicos envolveu o mapeamento minucioso das operações referentes às etapas de entrada, triagem, armazenamento e destinação final dos materiais. Com o objetivo de representar de forma clara e estruturada a dinâmica do sistema estudado, optou-se pela utilização da técnica IDEF-SIM, conforme proposta por Leal (2008) e fundamentada por Montevechi *et al*. (2010).

Essa abordagem foi escolhida por sua adequação à modelagem de sistemas voltados à simulação, oferecendo uma representação mais próxima da lógica exigida na construção do modelo computacional. Diferentemente de ferramentas genéricas, como fluxogramas tradicionais, o IDEF-SIM fornece somente os elementos essenciais à estrutura lógica do sistema, sem a dependência de pacotes específicos de simulação, o que favorece sua aplicação em plataformas diversas, como é o caso do *FlexSim*, utilizado neste trabalho.

O modelo foi elaborado com base em dados na estrutura do processo delineada das observações reais, registros operacionais fornecidos pela organização e análise de documentos que descrevem os fluxos físicos e informacionais da logística reversa. O mapeamento inclui desde a chegada dos resíduos eletrônicos ao ponto de coleta, passando pela etapa de armazenamento, até sua destinação final, seja ela para reuso, reciclagem ou descarte ambientalmente adequado.

A Figura 28 apresenta a representação gráfica do processo modelado segundo a notação IDEF-SIM. O fluxo inicia-se na Cidade 0 (C0), que representa o ponto de origem e retorno dos veículos. A partir desse ponto, os caminhões seguem rotas definidas pelo algoritmo genético (GA) e percorrem as cidades C_1, C_2, ... C_n , onde ocorre a coleta dos resíduos eletroeletrônicos previamente demandados. Após atender às cidades atribuídas, os veículos retornam à Cidade 0, completando o ciclo logístico. Esse modelo conceitual descreve, portanto, o movimento dos resíduos do ponto de coleta até o local central de consolidação (C0), refletindo a dinâmica da logística reversa aplicada. Para maior clareza, o Quadro 5 descreve os símbolos utilizados e os elementos que compõem o diagrama.

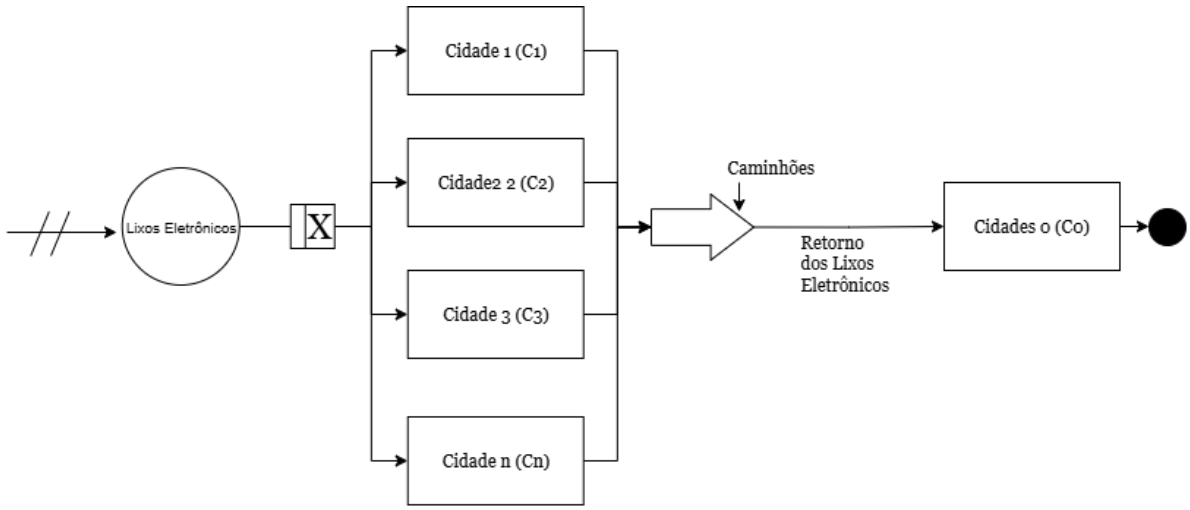

Figura 28 – Mapeamento da LR dos lixos eletrônicos da Empresa
Fonte – Próprio Autor

Observa-se, a partir do mapeamento, que o sistema é iniciado pela entrada de uma entidade: o lixo eletrônico. A quantidade coletada, entretanto, varia de forma imprevisível, não

sendo possível definir uma distribuição estatística fixa para esse fluxo de entrada. Essa variabilidade decorre de fatores como a localização das cidades atendidas, a sazonalidade e a definição das datas de coleta, que são estabelecidas pelo operador logístico. Dessa forma, o sistema apresenta características estocásticas, já que o volume de resíduos eletrônicos coletados depende de variáveis aleatórias externas, tornando impossível prever com exatidão o peso a ser processado em cada operação (MONTEVECHI *et al*., 2010).

Quadro 5 – Simbologia utilizada na técnica proposta IDEF-SIM e definição do problema (continua)

Elementos	Simbologia	Definição	Modelo Atual
Entidades	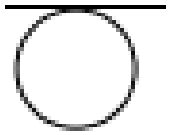	Itens que serão processados pelo sistema, podendo ser matéria-prima, produtos, documentos ou pessoas.	Lixo Eletrônico
Funções		Locais onde a entidade sofrerá alguma ação: postos de trabalho, esteiras de movimentação, filas e estoques. Podem modificar uma entidade, ou mesmo alterar o ritmo desta entidade no fluxo, como uma espera.	Cidades como Ponto de Coletas (PC)
Recursos	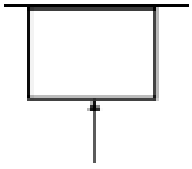	São os elementos (pessoas ou equipamentos) utilizados para executar funções ou movimentar as entidades.	
Controles	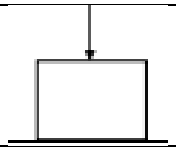	Regras utilizadas nas funções, como sequenciamento, regras de filas e programações.	
Regras para fluxos paralelos e ou alternativos	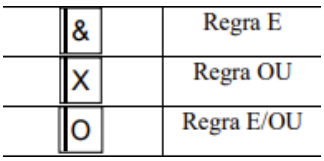	Regra E Regra OU RegraE/OU	Regra aplicada para lógica de transporte, isto é, passa em uma cidade ou mais de uma.
Fluxo da Entidade		Direcionamento da entidade dentro do modelo, caracterizando os momentos de entrada e saída da entidade nas funções.	

Fonte – Adaptado de Leal *et al*. (2008)

Quadro 6 – Simbologia utilizada na técnica proposta IDEF-SIM e definição do problema (conclusão)

Elementos	Simbologia	Definição	Modelo Atual
Movimentação	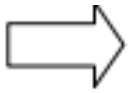	Representa um deslocamento de entidade, no qual o modelador acredita possuir efeito importante sobre o modelo.	
Informação explicativa		Utilizado para inserir no modelo uma explicação, com o objetivo de facilitar o entendimento do mesmo.	
Fluxo de entrada no sistema modelado	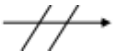	Define a entrada ou criação das entidades dentro do modelo.	
Ponto final do sistema		Define o final de um caminho dentro do fluxo modelado.	

Fonte – Adaptado de Leal *et al*. (2008)

3.2.1.3 Validação do modelo conceitual

A validação de modelos de simulação é uma etapa indispensável para garantir que o modelo represente adequadamente o sistema real, considerando os objetivos a que se propõe. Conforme Sargent (2013), a validação é a determinação de que as teorias e suposições presentes no modelo conceitual são corretas, e que a representação do sistema é razoável para os propósitos do estudo (ÖZTÜRK, 2023).

Diversos autores classificam os tipos de validação em simulação. Balci (1998) apresenta uma taxonomia com mais de 70 métodos de verificação, validação e testes. Estes podem ser organizados em quatro grupos principais (ÖZTÜRK, 2023):

1. Métodos informais: baseados em julgamento humano, como inspeção de código e validação face a face;

Dentro dos métodos informais, destaca-se a validação face a face, definida como a comparação do comportamento do modelo com o sistema real a partir da experiência e julgamento de especialistas. Segundo Öztürk (2023), trata-se de uma técnica utilizada principalmente quando os dados são escassos, o sistema é complexo ou os modelos são altamente interdependentes.

A técnica é amplamente aceita na literatura como um método inicial ou complementar, especialmente eficaz para validar modelos conceituais. De acordo com Sargent (2013), “a validação face a face deve ser realizada já na fase do modelo conceitual”, sendo recomendada para avaliar se a lógica do modelo faz sentido para os especialistas envolvidos.

Diante da diversidade de métodos disponíveis para validar modelos de simulação, a escolha da validação face a face justifica-se tanto pela literatura clássica quanto por estudos recentes. No presente trabalho, essa validação foi conduzida em duas frentes complementares. A primeira ocorreu junto a profissionais da área de logística reversa da empresa parceira, em reuniões presenciais nas quais foram apresentados o modelo conceitual e os resultados das simulações. Nessas interações, os gestores avaliaram se a representação do sistema, as rotas de coleta, os custos logísticos estimados e os níveis de emissão de CO_2 estavam condizentes com a realidade operacional.

A segunda frente envolveu a participação de especialistas em modelagem e simulação, que analisaram a consistência técnica do modelo construído, a adequação da lógica de eventos discretos empregada e a coerência das relações entre variáveis. A partir desse processo integrado de validação prática e técnica, foi possível confirmar a adequação do modelo proposto, assegurando maior robustez e confiabilidade na sua utilização como ferramenta de apoio à decisão.

3.2.1.4 Modelagem dos dados de entrada

Com o intuito de dar suporte à modelagem e simulação do sistema de logística reversa proposto, foram coletados, tratados e organizados dados provenientes dos fluxos logísticos operacionais da empresa parceira. Esses dados compreendem informações relacionadas aos municípios de coleta, unidades federativas, datas, volumes (peso cubado), bem como variáveis temporais, como mês, ano e região.

Adicionalmente, foram obtidos dados operacionais de extrema relevância, fornecidos pelo operador logístico, incluindo a capacidade de carga dos veículos disponíveis, o custo médio por quilômetro rodado e os índices de emissão de CO_2 para cada tipo de veículo. Essas informações foram consideradas essenciais não apenas para compor a base do modelo, mas também para permitir a avaliação dos impactos econômicos e ambientais ao longo das rotas simuladas.

Todos os dados foram inicialmente organizados em planilhas estruturadas, a fim de garantir a padronização e facilitar o tratamento automatizado. Posteriormente, essas planilhas foram integradas ao software desenvolvido no âmbito desta pesquisa, o qual permite a importação dos dados, a construção de grafos logísticos e a preparação da base informacional necessária para execução do modelo de simulação.

A fim de representar o comportamento real do sistema com maior fidelidade, adotou-se a premissa de que as demandas de coleta apresentam natureza estocástica, isto é, sujeitas à

variabilidade ao longo do tempo, em decorrência de fatores externos, como sazonalidade, campanhas de arrecadação e adesão da população ao processo de devolução. Embora a empresa atue em escala nacional, abrangendo um número expressivo de municípios, para fins deste estudo optou-se por utilizar um subconjunto de 10 cidades representativas. Essa delimitação atende a dois critérios principais.

Primeiro, esse recorte garante a viabilidade computacional dos experimentos de otimização via simulação, uma vez que a complexidade do problema cresce exponencialmente com o aumento do número de localidades (fenômeno conhecido como explosão combinatória no Problema de Roteamento de Veículos – VRP). Segundo a seleção de 10 cidades permite testar e avaliar, de forma controlada, o desempenho do algoritmo genético (GA) em cenários com diferentes distâncias, demandas e características de coleta, preservando a representatividade do processo real.

Cabe destacar que essa limitação do conjunto de cidades diz respeito apenas ao desenho experimental adotado nesta pesquisa. O modelo de GA acoplado à simulação é geral e pode ser estendido para um número maior de localidades; o que aumenta, nesse caso, é o esforço computacional necessário para executar o algoritmo, e não uma restrição estrutural da abordagem.

Dessa forma, o recorte adotado não compromete a validade da pesquisa, mas assegura equilíbrio entre realismo e exequibilidade da modelagem computacional. A Tabela 11 exemplifica, de forma ilustrativa, os principais dados associados às coletas realizadas:

Tabela 12 – Dados utilizados para a modelagem de simulação logística

MUNICIPIO	DATA	PESO_COLETA	ID_MUNICIPIO
SOROCABA	07/05/2024	0	1
ITU	07/05/2024	Triangular (0,71;396;68)	2
TATUI	08/05/2024	Triangular (4,75;239,5;73)	3
CAMPINAS	07/05/2024	Triangular (0;1756,08;1445)	4
BARUERI	07/05/2024	Triangular (5,8;421,2;60)	5
ITU	08/05/2024	Triangular (0;1188;283)	6
TATUI	07/05/2024	Triangular (3;8262;239)	7
SÃO PAULO	07/05/2024	Triangular (6;332,5;149)	8
SANTOS	07/05/2024	Triangular (0,71;396;68)	9
ADOLFO	07/05/2024	Triangular (4,75;239,5;73)	10

Fonte – Próprio autor

Para o transporte dessas cargas, foram considerados diferentes perfis de veículos utilizados pela empresa parceira, a qual disponibilizou as informações operacionais referentes à frota. As características englobam a capacidade de carga (kg), o custo médio por quilômetro rodado (R$/km) e a emissão média de CO_2 (g/km). Esses parâmetros foram diretamente

fornecidos pela empresa e inseridos no modelo de forma estocástica, de modo a refletir variações reais de operação. A Tabela 13 apresenta um resumo das especificações consideradas:

Tabela 13 – Tabela com as características dos veículos

ID_Veículo	Veículos	Capacidade (kg)	Custo por Km/Rodado	Emissao_CO2_(g/km)
1	Fiorino	900	Normal (0.59; 0.2)	Normal (200; 50)
2	Van	2700	Normal (3.98; 0.2)	Normal (250; 50)
3	Tres por quatro	6000	Normal (4.35; 0.2)	Normal (400; 50)
4	Toco	13800	Normal (5.15; 0.2)	Normal (600; 50)
5	Truck	15000	Normal (6.35; 0.2)	Normal (800; 50)
6	Carreta	28500	Normal (7.10; 0.2)	Normal (1200; 50)

Fonte – Empresa parceira

Ressalta-se que os parâmetros de custo por quilômetro rodado e emissão de CO_2 foram modelados como distribuições normais. Essa escolha se justifica pelo fato de que tais valores variam de acordo com o ano de fabricação dos veículos, bem como em função do nível de manutenção, consumo de combustível e condições operacionais. Dessa forma, a modelagem probabilística permitiu representar de maneira mais realista a variabilidade existente na frota da empresa parceira.

A partir das informações de latitude e longitude dos municípios, foi construída uma matriz de distâncias entre os pontos de coleta utilizando a linguagem de programação Python, por meio da biblioteca *Geopy* e da função *geodesic()*. Este método, baseado no algoritmo de Karney (2013) e fundamentado no elipsoide WGS-84, permite o cálculo preciso da menor distância geodésica entre dois pontos sobre a superfície da Terra. Neste sentido a tabela 14, apresenta uma representação dos resultados obtidos por uma matriz.

Tabela 14 – Exemplo de Matriz de distância

	C1	**C2**	**C3**	**C4**	**C5**	**C6**	**C7**	**C8**	**C9**	**C10**
C1	0	—	—	—	—	—	—	—	—	—
C2	—	0	—	—	—	—	—	—	—	—
C3	—	—	0	—	—	—	—	—	—	—
C4	—	—	—	0	—	—	—	—	—	—
C5	—	—	—	—	0	—	—	—	—	—
C6	—	—	—	—	—	0	—	—	—	—
C7	—	—	—	—	—	—	0	—	—	—
C8	—	—	—	—	—	—	—	0	—	—
C9	—	—	—	—	—	—	—	—	0	—
C10	—	—	—	—	—	—	—	—	—	0

Fonte – Próprio autor

Trata-se de um método numérico robusto, que emprega séries elípticas e técnicas de integração para determinar a menor distância entre dois pontos, considerando o achatamento da Terra e outros aspectos geodésicos.

Para estimar os custos por quilômetro e as emissões de CO_2 por quilômetro associados ao transporte logístico reverso, adotou-se uma abordagem estocástica, considerando a variabilidade operacional inerente ao uso de diferentes tipos de veículos. Dado que O custo

total por rota (C_{total}) a emissão total de CO_2 (E_{total}) e demanda coletada (D_{total}) são estimados pelas seguintes equações (3 – 5):

$$C_{total} = \sum_{v \in V} D_v * C_v \quad (4)$$

$$E_{total} = \sum_{v \in V} D_v * E_v \quad (5)$$

$$D_{total} = \sum_{v \in V} \sum_{i \in N} d_i * y_{iv} \quad (6)$$

Sendo:

- V: conjunto de veículos utilizados na rota.
- N: conjunto de todas as cidades na rota (exceto o depósito).
- D_v distância total percorrida pelo veículo v dentro da rota.
- E_v emissão de CO_2 emitida pelo veículo v dentro da rota.
- C_v custo por km rodado pelo veículo v dentro da rota.
- C_{total} custo total de transporte da rota.
- E_{total} emissão total de CO_2 gerada pela rota.
- d_i Demanda (peso a ser coletado) na cidade $i \in N$.
- y_i^v: variável binária que indica se o veículo v atendeu a cidade i (1 se sim, 0 se não)

Essas equações foram integradas ao modelo com o propósito de avaliar a viabilidade operacional e os impactos ambientais e econômicos de cada configuração simulada. A incorporação de dados reais, variáveis estocásticas e parâmetros técnicos conferiu ao sistema um alto grau de representatividade frente ao contexto da logística reversa praticada pela empresa parceira.

Com a base de dados organizada e as variáveis devidamente modeladas, foi possível avançar para a fase de implementação do modelo computacional, momento no qual as estruturas conceituais e matemáticas foram traduzidas em algoritmos e fluxos de simulação. A seguir, detalha-se o processo de construção do modelo computacional, abordando as ferramentas, técnicas e decisões adotadas no desenvolvimento do sistema de apoio à decisão proposto.

3.2.2 Fase de Implementação

3.2.2.1 Métodos empregados para elaboração do *Framework*

Para a condução do projeto de OvS, serão usadas algumas técnicas consideradas importantes para elaboração desta tese, são elas:

a) Simulação a eventos discretos (SED): empregada para modelar sistemas reais e recupera dados de entrada e saída.
b) Algoritmos de otimização: usados para encontrar a melhor solução para um determinado problema, seja ele de maximização ou minimização de uma função objetivo.

O algoritmo de otimização foi desenvolvido e utilizado devido à sua adequação ao objeto de estudo desta tese, dado que o problema começa e termina suas viagens em um armazém central, e cada cliente precisa ser atendido por apenas um veículo. O objetivo é designar uma ordem de clientes para cada veículo da frota (uma rota), minimizando a distância total percorrida, de modo que todos os clientes sejam atendidos e a carga total transportada por cada veículo não ultrapasse sua capacidade máxima (MONTAGNÉ, SANCHEZ e STORBUGT, 2020). A segunda abordagem empregada, a Simulação a eventos discreto (SED), é responsável por adequar os objetos de análise, pois eles possuem processos aleatórios e interligados, bem como uma natureza discreta do sistema.

Com base nos estudos realizado por meio da RSL descrito no capítulo (2.5) sobre os algoritmos de otimização, nota-se que vários algoritmos foram listados, como: *Branch and Bound*, heurísticas construtivas e meta-heurísticas como os algoritmos genéticos (GA). Para problemas de objetivo único, recomenda-se o GA com função de aptidão escalar (com penalizações e reparos para garantir viabilidade). Para problemas multiobjetivo, recomenda-se o uso de algoritmos evolucionários multiobjetivo (MOEAs), que tratam diretamente o conjunto de soluções Pareto-ótimas, como NSGA-II/III, SPEA2 ou MOEA/D (AMARAL,2021). Após otimizar a função multiobjetivo, pode-se criar uma Fronteira de Pareto com objetivo de identificar as configurações ideais, baseado nas funções otimizadas.

Neste sentido, o problema abordado neste estudo refere-se à otimização do roteamento de veículos em uma rede de coletas, considerando múltiplos objetivos conflitantes, como custo operacional, emissão de CO_2 e volume total coletado. Para representar o sistema real, foi desenvolvido um modelo de SED, no qual são considerados os fluxos de coleta e entrega, as capacidades dos veículos, as restrições operacionais e a variabilidade da demanda.

O modelo permite avaliar diferentes configurações logísticas, as quais são geradas por meio de algoritmos de otimização e posteriormente avaliadas com base em métricas de desempenho simuladas. Essa abordagem viabiliza a aplicação da técnica de Otimização via Simulação (OvS), permitindo identificar soluções eficientes para o problema proposto.

Para ilustrar o que foi descrito, a Figura 34 está organizado na extração de dados reais com a aplicação de técnicas de simulação e otimização para suporte à tomada de decisão.

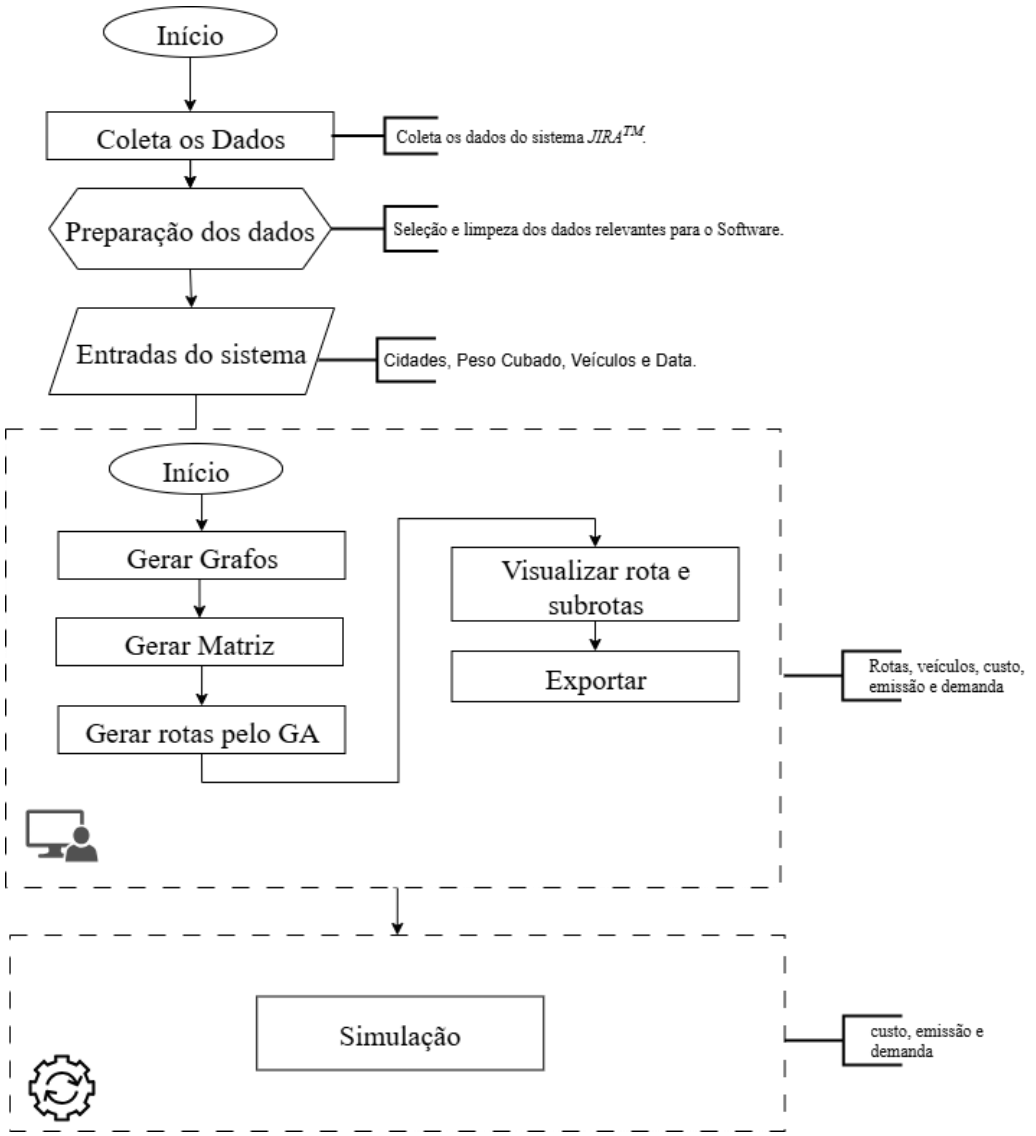

Figura 29 – Fluxograma para elaboração da OvS multiobjetivo aplicado à logística reversa
Fonte - Próprio Autor

Esse fluxograma está organizado em três etapas que conectam a extração de dados reais à aplicação de técnicas de simulação e otimização para suporte à decisão. O processo inicia-se com a extração dos dados a partir da instância corporativa do *Jira* (Atlassian), plataforma utilizada pela empresa parceira para gestão de operações e projetos. Nessa etapa, relatórios foram exportados em formato CSV contendo municípios, datas e quantidades de coleta (kg), além de identificadores utilizados na padronização e integração dos dados com o módulo de otimização.

Nessa etapa, as informações brutas como localidades, datas, quantidades de coleta (kg) e demais atributos operacionais, são filtradas, estruturadas e organizadas para garantir consistência e viabilidade analítica. Ainda nessa fase são definidas as variáveis do problema a serem usadas na otimização via simulação, incluindo conjunto de cidades/rotas, frota de veículos (capacidade em kg, custo em R$/km e emissão em g CO_2/km), cenários/pesos dos

objetivos, matriz de distâncias entre municípios (km), demanda por cidade (kg) e tempos de serviço/carregamento por veículo (min), além das funções-objetivo (FOs) que serão otimizadas: custo logístico (R$), emissões totais de CO_2 (kg) e quantidade de resíduos coletados (kg).

A interação com o usuário ocorre por meio de uma interface gráfica (GUI) desenvolvida em *Tkinter*, a qual permite explorar os dados processados e acionar os módulos do sistema. Nessa interface, o usuário pode aplicar filtros por período, inserir/editar o conjunto de cidades e demandas, gerar o grafo e a matriz de distâncias, parametrizar a frota e os tempos de serviço, executar o GA para gerar rotas, visualizar os resultados em tabelas e mapas interativos e, por fim, exportar os cenários para o *FlexSim* e iniciar a simulação.

Em paralelo, o módulo de otimização foi implementado com um Algoritmo Genético (GA), utilizado para resolver o VRP definindo simultaneamente a sequência de visitas e a alocação de veículos. Os objetivos considerados foram minimizar o custo logístico (R$) e as emissões de CO_2 (g) e maximizar a quantidade de resíduos coletados (kg). A combinação multiobjetivo foi tratada por soma ponderada, com pesos especificados no plano experimental.

Essa abordagem integrada, conhecida como Otimização via Simulação (OvS), permite não apenas analisar o desempenho de diferentes alternativas operacionais, mas também apoiar decisões estratégicas em contextos complexos e incertos.

3.2.2.2 Construção do modelo computacional

A construção do modelo computacional adotou um framework de Otimização via Simulação (OvS) que integra dois modelos complementares: (i) um módulo de otimização em Python, responsável por gerar rotas multiobjetivo para a coleta, e (ii) um módulo de simulação em FlexSim, empregado para validar operacionalmente as rotas propostas sob variabilidade estocástica. Essa separação foi necessária porque o FlexSim, embora adequado para simulação de eventos discretos, não dispõe de recursos nativos para resolver o VRP multiobjetivo com grande espaço de busca; por isso, a otimização é realizada em Python e a validação em FlexSim.

A concepção da interface gráfica e da modelagem computacional baseia-se nas diretrizes teóricas discutidas no Capítulo 2 (Figura 10). Com esse embasamento, desenvolveu-se uma interface gráfica para apoiar a etapa de otimização e facilitar o uso por gestores logísticos, inclusive não familiarizados com programação.

Para atender a esse propósito, utilizou-se Python, dada sua versatilidade e ecossistema científico. A Tkinter foi empregada na criação da GUI, permitindo janelas, menus, botões e tabelas de visualização de dados. No tratamento e análise, a Pandas viabilizou a leitura, estruturação e filtragem de planilhas com demandas por cidade (kg), rotas e características da

frota (capacidade, custo e emissão). No que se refere ao tratamento e análise dos dados, a biblioteca Pandas foi essencial para a leitura, estruturação, filtragem e manipulação de planilhas contendo informações logísticas, como demandas, rotas e características dos veículos. Sua estrutura de *DataFrames* favorece o cruzamento eficiente de grandes volumes de dados e facilita a integração com os demais módulos da aplicação.

Para representar as redes logísticas, foi adotada a biblioteca NetworkX, especializada na criação e análise de grafos. Com ela, foi possível modelar os pontos de coleta e entrega como nós (vértices), conectando-os por meio de arestas ponderadas pelas distâncias geográficas entre os locais, compondo assim um grafo orientado e apropriado para algoritmos de roteamento.

As distâncias entre os municípios foram calculadas em Python com Geopy *geodesic()*. Reconhece-se que a distância rodoviária é a mais adequada para avaliação operacional; contudo, neste estudo utilizou-se a geodésica como *proxy* por razões de viabilidade computacional e reprodutibilidade do processo OvS com muitos cenários do GA. Esse procedimento mantém a consistência comparativa entre soluções (o erro é sistemático) e atende ao objetivo desta fase de seleção e ordenação de cenários.

Para a visualização das rotas em mapas interativos, integrou-se à biblioteca Folium, que permite a sobreposição de trajetos, marcadores e camadas sobre mapas reais baseados na plataforma *Leaflet.js*. Com isso, o usuário pode explorar visualmente as rotas otimizadas, identificar pontos de partida e chegada, e analisar de forma intuitiva o desempenho de cada cenário gerado.

A combinação dessas bibliotecas resultou em uma ferramenta computacional robusta, interativa e acessível, capaz de integrar etapas de entrada de dados, processamento via algoritmos de otimização e visualização dinâmica dos resultados, servindo como apoio à tomada de decisão no contexto da logística reversa.

Para ilustrar, o usuário é recebido por uma tela de boas-vindas do sistema. Ao selecionar a opção “acessar”, ele é direcionado para a interface principal da aplicação, dando início à navegação e utilização das funcionalidades disponíveis, conforme ilustra a Figura 30.

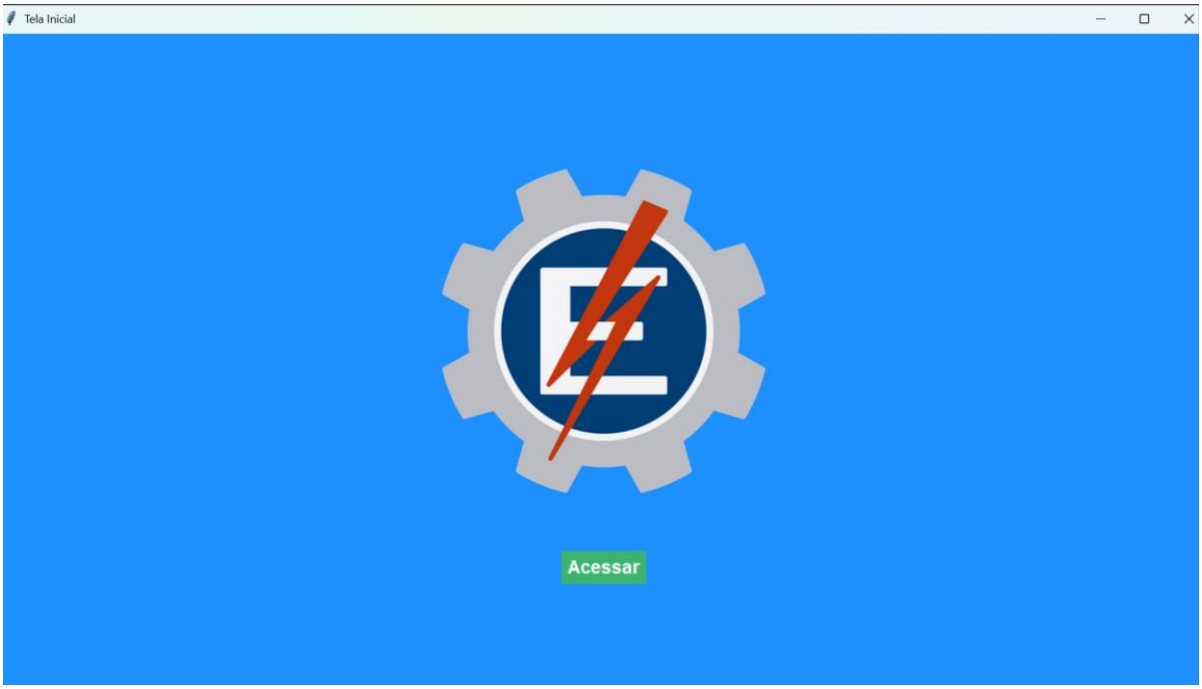

Figura 30 – Tela inicial do software logístico
Fonte – Próprio Autor

Após o acesso ao sistema, a interface é adaptada para o uso do operador logístico. Nesse ambiente, o usuário tem a possibilidade de inserir uma lista de municípios juntamente com suas respectivas demandas, além de aplicar filtros por data. A partir dessas informações, o sistema complementa automaticamente os dados com atributos adicionais, como a localização geográfica (latitude e longitude) de cada cidade, conforme ilustrado na Figura 31.

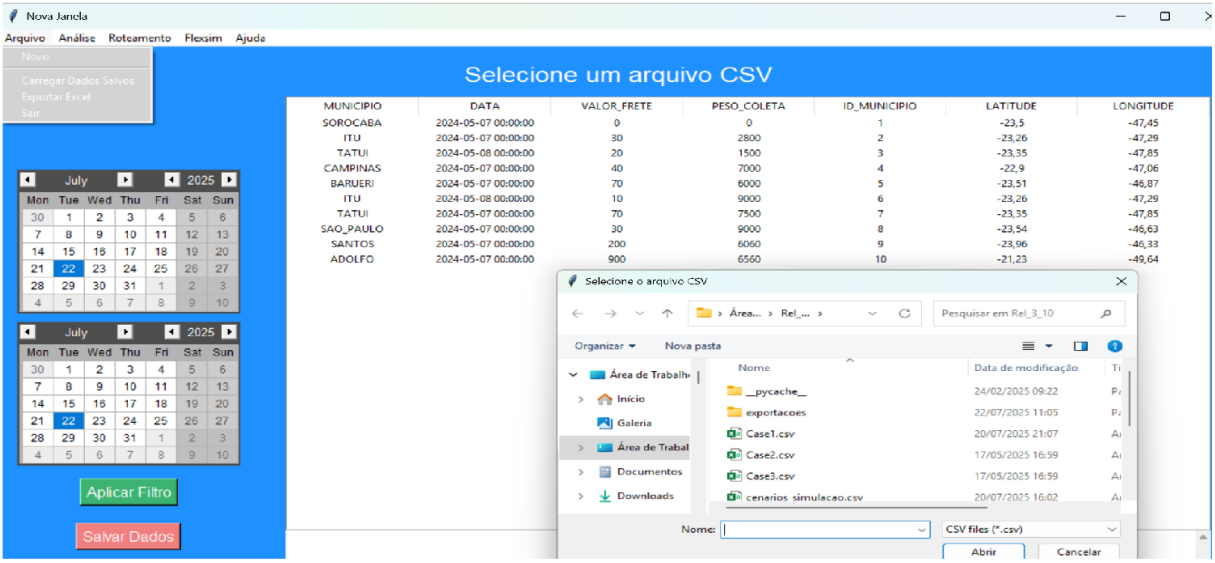

Figura 31 – Interface de inserção dos dados e manipulação do usuário
Fonte – Próprio Autor

Conforme ainda ilustrado na Figura 31, o usuário pode aplicar filtros personalizados e salvar os dados processados. Esses dados servirão de base para a próxima etapa do sistema, na qual são gerados o grafo de conexões logísticas entre os municípios e a respectiva matriz de

distâncias geográficas, elementos essenciais para as análises posteriores, como demonstrado na Figura 32.

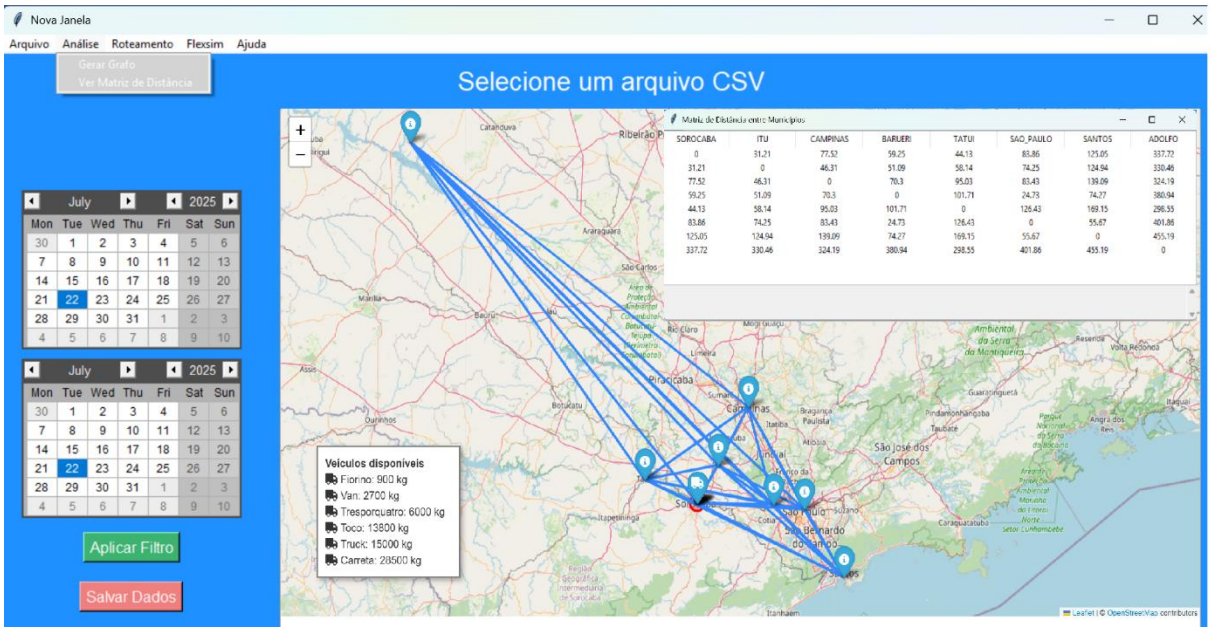

Figura 32 – Interface de análise dos dados e manipulação do usuário
Fonte – Próprio Autor

Nesta etapa resolve-se um VRP de natureza multiobjetivo. O GA determina, de forma simultânea, a sequência de visitas aos municípios e a alocação dos veículos, partindo da Cidade 0 (depósito), atendendo as cidades selecionadas e retornando ao depósito. Por tratar-se de um problema NP-difícil, cujo espaço de busca cresce exponencialmente com o número de localidades, adota-se o GA como meta-heurística capaz de explorar soluções de alta qualidade com viabilidade computacional.

Os objetivos considerados são a minimização do custo logístico (R$) e das emissões totais de CO_2 (g), bem como a maximização da quantidade de resíduos coletados (kg). O modelo incorpora restrições de capacidade dos veículos, atendimento único por cidade e início e término no depósito, utilizando como insumo a matriz de distâncias entre municípios (estimada conforme descrito na subseção de distâncias). A codificação das soluções baseia-se em permutações de cidades com marcadores de veículo; funções de reparo e/ou penalização asseguram a viabilidade quanto à capacidade.

O processo evolutivo emprega seleção por torneio, operadores de crossover e mutação e elitismo para preservação das melhores soluções, sendo os principais parâmetros (tamanho da população, número de gerações e taxas dos operadores, além de pesos/estratégia multiobjetivo) ajustáveis na interface.

Como produto, obtém-se um conjunto de cenários de rotas, cada qual acompanhado de indicadores de custo, emissões, distância total percorrida e massa coletada, que são visualizados

em mapa interativo e exportados para o ambiente de simulação. Esse encadeamento configura o segundo passo do framework de Otimização via Simulação, no qual são avaliadas a viabilidade operacional das rotas geradas e o desempenho do sistema sob variabilidade estocástica.

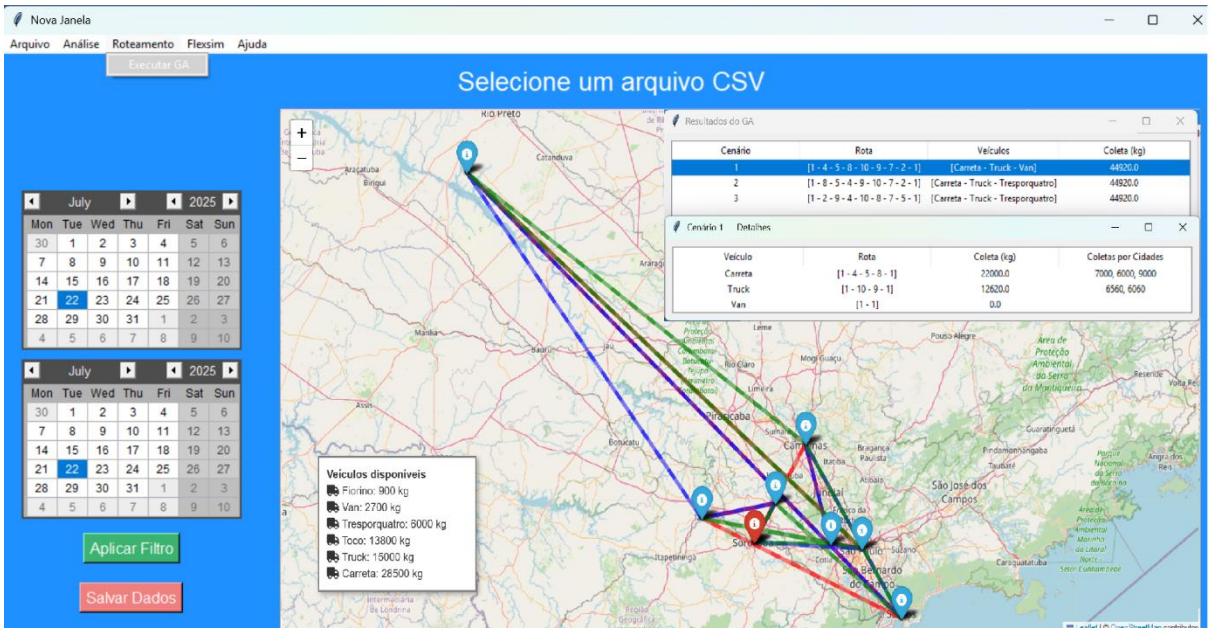

Figura 33 – Interface de roteamento e manipulação do usuário
Fonte – Próprio Autor

A Figura 33 apresenta a integração do módulo de otimização, desenvolvido em *Python*, com o módulo de simulação implementado no *FlexSim*. Para viabilizar a Otimização via Simulação, foi desenvolvido um modelo-base parametrizado no *FlexSim* (.fsm), composto por GlobalTables (cenários, rotas, veículos, matriz de distâncias), recursos (grupos de veículos) e um *ProcessFlow* com rotinas *FlexScript* responsáveis por: (i) importar automaticamente os arquivos produzidos pelo *Python*, (ii) instanciar e parametrizar os recursos (capacidade, custo por km e emissão por km), (iii) atribuir a cada veículo a rota do cenário corrente (início e retorno à Cidade 0), (iv) executar a lógica de coleta e transporte sob variabilidade estocástica e (v) consolidar e exportar os indicadores de desempenho, custo total (R$), emissões de CO_2 (kg) e massa coletada (kg) para arquivo CSV.

No lado do Python, a aplicação exporta os cenários do GA para planilhas/CSVs padronizados (sumário por cenário, detalhamento de rotas e parâmetros de frota) e, em seguida, aciona o *FlexSim* programaticamente (via chamada de sistema/*FlexSimPy*), abrindo o modelo-base, informando os caminhos dos arquivos e disparando a execução até o tempo de simulação definido (ou número de réplicas). Ao término, o *FlexSim* grava os resultados em arquivos que são lidos de volta pelo Python para comparação entre cenários, visualização e tomada de decisão.

Essa arquitetura deixa explícito que não se trata de um “abrir e rodar” simples: o *FlexSim* foi programado para ler os dados do GA, construir o cenário de forma automática, executar a dinâmica operacional e retornar métricas consolidadas. Em outras palavras, o Python otimiza (gera rotas viáveis e eficientes) e o *FlexSim* válida (verifica a exequibilidade e o desempenho sob incerteza), compondo o framework OvS que constitui o núcleo metodológico desta pesquisa.

Figura 34 – Interface de roteamento e manipulação do usuário
Fonte – Próprio Autor

3.2.2.3 Verificação do modelo computacional

Neste estágio da pesquisa, conduziram-se testes de consistência com o intuito de assegurar a robustez do modelo proposto. Foram verificadas as distâncias calculadas entre os pontos geográficos, avaliou-se a coerência entre os volumes coletados e as respectivas capacidades dos veículos, bem como validou-se a lógica empregada na alocação das rotas. Esses procedimentos permitiram garantir que os resultados obtidos refletissem fielmente as restrições e condições do problema real.

3.2.2.4 Validação do modelo computacional

Sargent (2013) define a validação como o processo de determinar se um modelo, dentro de seu domínio de aplicabilidade, possui um comportamento suficientemente preciso e coerente com a realidade que busca representar. Gabriel (2022), apresenta diversas técnicas de validação em seu trabalho, entre elas: análise sensitiva, animação, análise de gráficos, testes estatísticos, validação face-face, teste de Turing, testes de condições extremas, analise de regressão, comparação do modelo simulado com anteriores e comparação dos dados históricos com dados simulados.

Apesar da ampla gama de técnicas disponíveis para a validação de modelos computacionais, algumas delas de caráter mais subjetivo, a abordagem que melhor se alinhou à construção desenvolvida neste trabalho foi a validação face a face. Essa técnica destaca-se por proporcionar uma interação direta entre o modelo e os especialistas, permitindo que estes acompanhem sua execução por meio de recursos visuais, como animações, fluxos em tempo real ou representações gráficas interativas.

Mais do que uma simples ilustração da dinâmica do sistema, a validação visual desempenha um papel fundamental ao facilitar a identificação de comportamentos esperados, desvios operacionais e possíveis incoerências no funcionamento do modelo. Através dessa observação, os avaliadores conseguem fornecer um retorno qualitativo valioso. Como ressaltado por Balci (1998), a credibilidade de um modelo vai além da comprovação estatística: ela está diretamente relacionada à confiança que ele é capaz de transmitir aos seus usuários.

Nesse contexto, técnicas qualitativas, como a avaliação por imagem, contribuem significativamente para fortalecer a confiabilidade do modelo e enriquecer o processo de validação. Balci (1998) reforça que o processo de verificação e validação deve ocorrer ao longo de todo o ciclo de vida da simulação, sendo a validação visual uma das formas mais acessíveis e eficazes de garantir a consistência da estrutura modelada ainda nas fases iniciais de desenvolvimento.

3.2.3 Fase de Análise

3.2.3.1 Definição do projeto experimental

Nesta fase foi especificado o plano experimental do framework de Otimização via Simulação (OvS). O objetivo é avaliar o comportamento do sistema sob diferentes priorizações estratégicas entre custo logístico (R$), emissões de CO_2 (kg) e quantidade coletada (kg). Para isso, variou-se a combinação de pesos utilizada no GA para gerar rotas candidatas, mantendo constantes os demais insumos (frota, matriz de distâncias e parametrizações estocásticas apresentadas nas Tabelas 11 e 12). A Tabela 15 apresenta o planejamento experimental utilizado na OvS, com a definição dos fatores, níveis e variáveis de saída.

Tabela 15 – Planejamento experimental para OvS

Elemento	Descrição	Configuração/níveis
Fator A	Pesos do GA para a função escalar (w_cost, w_CO2, w_soc)	(1,0,0), (0,1,0), (0,0,1), (0,5;0,5;0), (0,5;0;0,5), (0;0,5;0,5), (1/3;1/3;1/3)
Fator B	Parâmetros do GA	tamanho da população, nº de gerações, taxas de crossover e mutação
Controle	Frota e capacidades (kg)	conforme Tabela 12
Controle	Matriz de distâncias	geodésica WGS-84 (Seção 3.2.2), com justificativa/mitigação
Estocasticidade	Demanda por cidade (kg)	distribuição Triangular por município (Tabela 11)
Saídas da simulação	Métricas por cenário	Custo total (R$), Emissão total (kg CO_2), Quantidade coletada (kg) e Distância total (km)

Fonte – Próprio Autor

As combinações de pesos definem cenários de roteamento distintos no GA; cada cenário é posteriormente avaliado por simulação para capturar os efeitos da variabilidade operacional. A comparação entre cenários é realizada por meio de fronteira de Pareto e, quando necessário, por função escalar normalizada coerente com os pesos empregados.

3.2.3.2 Execução dos experimentos

A execução dos experimentos ocorre em duas etapas integradas. Na etapa 1 (otimização), o algoritmo genético é utilizado exclusivamente para definir as rotas: para cada combinação de pesos, o GA produz a melhor solução (sequência de visitas e alocação de veículos com início e retorno ao depósito), respeitando as restrições de capacidade e atendimento único por cidade.

Na etapa 2 (simulação), cada rota gerada é exportada para o *FlexSim* e executada com r réplicas (valor definido na interface), preservando a estocasticidade dos tempos e demandas. O simulador retorna, para cada cenário, custo total, emissões totais e quantidade coletada, além de distância total percorrida; tais resultados são consolidados com intervalos de confiança de 95% e utilizados na comparação dos cenários.

Em síntese, no framework proposto a etapa de otimização e a etapa de simulação são encadeadas, porém mantidas como módulos distintos. Primeiro, o GA resolve o problema determinístico de roteamento e gera um conjunto de cenários candidatos. Em seguida, esses cenários são inseridos no modelo de simulação a eventos discretos, que avalia sua exequibilidade operacional e o desempenho sob variabilidade estocástica. Assim, a otimização não é executada dentro do modelo de simulação, mas é realizada com suporte da simulação, característica da abordagem de OvS adotada neste trabalho.

3.2.3.3 Análise estatística

Utilizou-se análise descritiva para comparar os cenários e calcular indicadores de desempenho como custo total, emissão total de CO_2 e percentual de carga coletada. A interpretação dos dados permitiu identificar tendências e tr*ade-offs* entre os objetivos.

4 APLICAÇÃO

Este capítulo descreve a aplicação do método de Modelagem e Simulação, adotado como abordagem central desta pesquisa. A partir desse método, torna-se possível o desenvolvimento de um modelo representativo do sistema de logística reversa a ser analisado.

Dentro dessa abordagem metodológica, foi implementada OvS como estratégia para resolver um problema logístico com múltiplos objetivos. Conforme destacado por Montevechi *et al.* (2010, 2015), a OvS não constitui um método independente, mas sim uma forma de aplicação da Simulação com foco na obtenção de soluções ótimas ou quase ótimas, por meio da experimentação sistemática de diferentes configurações do modelo.

Com o intuito de organizar esse processo, propõe-se um método composto por três etapas principais: (i) a definição e inicialização do problema; (ii) a elaboração das estratégias de roteamento; e (iii) o desenvolvimento do modelo conceitual e computacional do objeto de estudo.

4.1 Objeto de estudo teórico – Caso 1

Conforme ilustrado na Figura 29, após a etapa de preparação e inserção dos dados no sistema, o gestor logístico inicia o processo de geração dos grafos. Essa representação gráfica tem como objetivo identificar, de forma visual e estruturada, os municípios que compõem as rotas potenciais a serem percorridas pelos veículos de transporte, conforme ilustrado pela Figura 35.

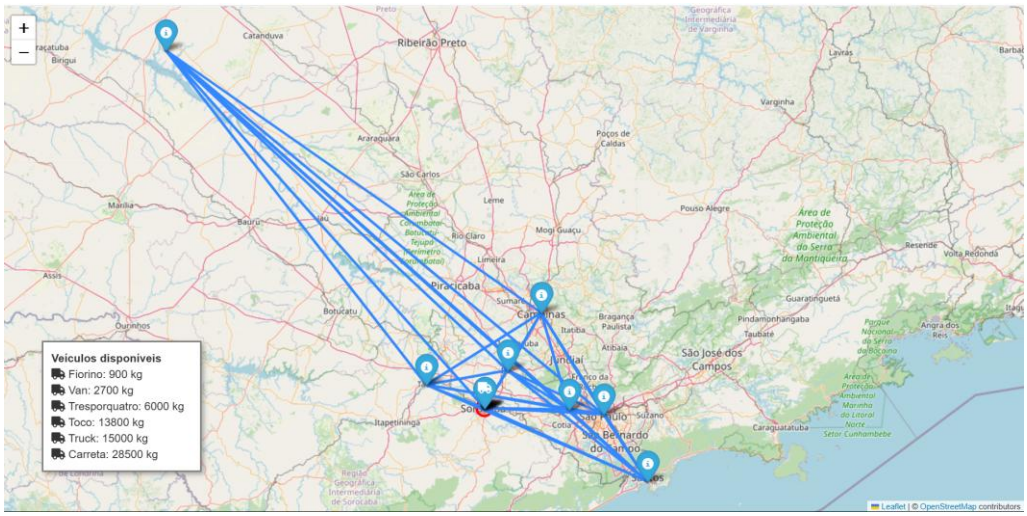

Figura 35 – Grafo das cidades alocadas para a simulação
Fonte - Próprio Autor

Na etapa seguinte, são geradas as matrizes de distâncias pelas coordenadas geográficas latitude(lat) e longitude(lon), que permitem identificar, de forma precisa, as distâncias entre os municípios considerados no estudo. Essa informação é essencial para o planejamento logístico,

uma vez que subsidia a tomada de decisão quanto à definição das rotas mais adequadas. A tabela 16 apresenta a estrutura dessas matrizes e sua função no processo de roteamento.

Tabela 16 – Matriz de distância entre as cidades calculada para o GA

SOROCABA	ITU	CAMPINAS	BARUERI	TATUI	SÃO PAULO	SANTOS	ADOLFO
0	31,21	77,52	59,25	44,13	83,86	125,05	337,72
31,21	0	46,31	51,09	58,14	74,25	124,94	330,46
77,52	46,31	0	70,30	95,03	83,43	139,09	324,19
59,25	51,09	70,30	0	101,71	24,73	74,27	380,94
44,13	58,14	95,03	101,71	0	126,43	169,15	298,55
83,86	74,25	83,43	24,73	126,43	0	55,67	401,86
125,05	124,94	139,09	74,27	169,15	55,67	0	455,19
337,72	330,46	324,19	380,94	298,55	401,86	455,19	0

Fonte - Próprio Autor

Após a geração das matrizes de distância, emprega-se um GA para construir rotas viáveis. O GA decide simultaneamente a sequência de visitas e a alocação de veículos, respeitando o atendimento único por cidade, conservação de fluxo por veículo, capacidade do veículo, carga acumulada e o retorno ao depósito.

Sendo assim, considera-se um problema de roteamento de veículo com frota heterogênea (HFVRP) e um único depósito. Seja $N = \{1, \dots, n\}$ o conjunto de clientes, 0 o depósito e K o conjunto de veículo disponíveis. Cada veículo $k \in K$ possui capacidade Q_k e coeficientes específicos de custo κ_k(R$/km) e emissão ϵ_k (kg CO_2/km). Para cada $i \in N$, q_i denota a demanda (kg). A distância entre dois nós $i, j \in N \cup \{0\}$ é d_{ij}(km).

Neste sentido, as variáveis de decisão estão associadas ao $x_{ijk} \in \{0,1\}$, ao qual vale 1 se o veículo k percorre o arco de i $até$ j e 0 caso contrário. Ainda se encontra nessas variáveis, $y_{ijk} \in \{0,1\}$, ao qual vale 1 se o cliente i é atendido pelo veículo k e 0 caso contrário. Por fim, $u_{ik} \geq 0$ que acumula carga no veículo k ao chegar no cliente i.

De modo a demonstrar a formulação multiobjetivo para o VRP com frota heterogênea aplicada neste trabalho, na qual se minimizam o custo total e a emissão total de CO_2 e maximiza o volume coletado. Denota-se:

$$\min_{x \in S} F(x) = \min_{x \in S} \big(C(x), E(x), -\mathrm{L}\,(x)\big) \tag{7}$$

com

$$\begin{aligned} C(\mathrm{x}) &= \textstyle\sum_{k \in K} \sum_{i,j \in N \cup \{0\}} \kappa_k d_{ij} x_{ijk}\,, \\ E(\mathrm{x}) &= \textstyle\sum_{k \in K} \sum_{i,j \in N \cup \{0\}} \epsilon_k d_{ij} x_{ijk}\,, \\ L(\mathrm{x}) &= \textstyle\sum_{k \in K} \sum_{i \in N} q_i y_{ik} \end{aligned} \tag{8}$$

Sujeito a

$$\begin{gathered}\sum_{k \in K} \sum_{j \in N \cup \{0\}} x_{ijk} = 1, \ \forall i \in N; \\ \sum_{j \in N} x_{0jk} \leq 1, \ \sum_{j \in N} x_{j0k} \leq 1, \ , \ \forall k \in K; \\ \sum_{j \in N \cup \{0\}} x_{ijk} - \sum_{j \in N \cup \{0\}} x_{jik} = 0 \ , \ \forall i \in N, \forall k \in K; \\ \sum_{i \in N} q_i y_{ik} \leq Q_k \ , \ \forall k \in K; \\ \sum_j x_{ijk} = y_{ik}, \sum_j x_{jik} = y_{ik} \ , \ \forall i \in N, \forall k \in K; \\ q_i \leq u_{ik} \leq Q_k, \forall i \in N, \forall k \in K; \\ u_{jk} \geq u_{ik} + q_j - Q_k(1 - x_{ijk}), \ \forall i \neq j \in N, \forall k \in K; \\ x_{ijk}, y_{ik} \in \{0,1\}, \ u_{ik} \geq 0. \end{gathered} \tag{9}$$

A tabela 17, apresenta os fatores que influência na mudança do problema e sua natureza multiobjetivo do problema é tratada por agregação escalar, com pesos definidos no plano experimental após a simulação.

Tabela 17 – Tabela de variável de decisão

	Variável de Decisão	Tipo	Limites
x_1	Rota	Inteiro	**[1 a 10]** Cidades
x_2	Veículo	Texto	**[1 a 6]** Veículos

Fonte – Próprio autor

Ressalta-se ainda que o Algoritmo Genético multiobjetivo foi parametrizado segundo os valores apresentados na Tabela 18.

Tabela 18 – Tabela de parâmetros para o GA

Parâmetro	Valores
Número de gerações	20
Tamanho da população	10
Número de veículos	6
Tamanho do torneio	3
Operador de crossover	*Order Crossover* (OX)
Operador de mutação	*Swap* simples

Fonte – Próprio autor

Sendo assim, a otimização foi feita por dominância de Pareto, sem agregação por pesos. Ao longo das gerações o GA mantém um arquivo de soluções não-dominadas, isto é, rotas em que não é possível reduzir custo ou emissões sem piorar a coleta. Ao final, 20 soluções dessa fronteira para análise e simulação, preservando pontos extremos e intermediários são demonstrada na Tabela 19.

Tabela 19 – Tabela de rotas e subrotas

Cenário	Veículo	Rota (IDs)	Coletas por Cidades (kg)
1	CARRETA	1-10-8-4-2-1	6560, 9000, 7000, 2800
1	TRUCK	1-7-9-1	7500, 6060
1	TRESPORQUATRO	1-5-1	6000
2	CARRETA	1-4-10-7-9-1	7000, 6560, 7500, 6060
2	TRUCK	1-8-5-1	9000, 6000
2	TRESPORQUATRO	1-2-1	2800
3	CARRETA	1-7-4-10-9-1	7500, 7000, 6560, 6060
3	TOCO	1-8-1	9000
3	VAN	1-1	

Fonte – Próprio autor

Tabela 20 – Tabela de rotas e subrotas (conclusão)

Cenário	Veiculo	Rota (IDs)	Coletas por Cidades (kg)
4	CARRETA	1-4-8-5-2-1	7000, 9000, 6000, 2800
4	TOCO	1-9-7-1	6060, 7500
4	TRESPORQUATRO	1-1	
5	CARRETA	1-5-8-7-1	6000, 9000, 7500
5	TOCO	1-9-2-1	6060, 2800
5	TRESPORQUATRO	1-1	
6	CARRETA	1-4-8-10-1	7000, 9000, 6560
6	TOCO	1-9-2-1	6060, 2800
6	VAN	1-1	
7	CARRETA	1-8-5-10-1	9000, 6000, 6560
7	TOCO	1-4-1	7000
7	VAN	1-1	
8	CARRETA	1-8-9-2-10-1	9000, 6060, 2800, 6560
8	TOCO	1-7-1	7500
8	VAN	1-1	
9	CARRETA	1-8-9-2-5-1	9000, 6060, 2800, 6000
9	TOCO	1-10-1	6560
9	TRESPORQUATRO	1-1	
10	CARRETA	1-5-8-9-10-1	6000, 9000, 6060, 6560
10	TOCO	1-7-1	7500
10	TRESPORQUATRO	1-1	
11	CARRETA	1-5-7-2-4-1	6000, 7500, 2800, 7000
11	TOCO	1-9-1	6060
11	VAN	1-1	
12	CARRETA	1-9-5-7-2-1	6060, 6000, 7500, 2800
12	TOCO	1-4-1	7000
12	VAN	1-1	
13	CARRETA	1-4-5-2-9-1	7000, 6000, 2800, 6060
13	TOCO	1-7-1	7500
13	VAN	1-1	
14	CARRETA	1-4-8-9-1	7000, 9000, 6060
14	TOCO	1-7-1	7500
14	VAN	1-1	
15	CARRETA	1-9-7-2-5-1	6060, 7500, 2800, 6000
15	TOCO	1-4-1	7000
15	TRESPORQUATRO	1-1	
16	CARRETA	1-9-5-7-1	6060, 6000, 7500
16	TOCO	1-8-1	9000
16	VAN	1-1	
17	CARRETA	1-5-9-10-4-1	6000, 6060, 6560, 7000
17	TRUCK	1-8-2-1	9000, 2800
17	VAN	1-1	
18	CARRETA	1-4-8-5-1	7000, 9000, 6000
18	TOCO	1-7-9-1	7500, 6060
18	VAN	1-1	
19	CARRETA	1-9-7-2-5-1	6060, 7500, 2800, 6000
19	TOCO	1-4-1	7000
19	TRESPORQUATRO	1-1	
20	CARRETA	1-2-5-10-9-1	2800, 6000, 6560, 6060
20	TRUCK	1-8-1	9000
20	TOCO	1-4-1	7000

Fonte – Próprio autor

Cada cenário corresponde a uma solução não-dominada completa. Como a solução é particionada por veículo, o mesmo número de cenário aparece em três linhas (uma por subrota/veículo) sempre que a rota global é decomposta para atender capacidades e janelas de

serviço. A coluna veículo indica o tipo selecionado para aquela subrota. Em Rota (IDs), os números representam a sequência de municípios. A coluna Coletas por Cidades (kg) traz o vetor de massas coletadas na mesma ordem da rota; a soma desse vetor é a carga da subrota e é verificada contra a capacidade do veículo.

Concluída a etapa de geração das rotas, o sistema procede à exportação automatizada dessas informações para uma base de dados estruturada. A partir desses dados, o modelo de simulação é construído automaticamente, viabilizando a criação de um ambiente computacional que representa fielmente o cenário proposto.

Esse modelo, por sua vez, é alimentado com as rotas previamente otimizadas por meio do GA em Python atuando como camada de busca, gerando um conjunto de soluções não-dominadas (fronteira de Pareto) para o problema de roteamento multiveículo, a partir de um modelo determinístico e agregador (matriz de distâncias, capacidades, partição de rotas por veículo e janelas de serviço básicas). O GA não produz uma "única" rota ótima universal, mas sim um portfólio de alternativas eficientes em termos de custo, emissões de CO_2 e massa coletada, permitindo a execução da simulação com base em soluções já definidas, o que possibilita a análise do desempenho logístico em condições operacionais realistas.

A simulação a eventos discretos (FlexSim) é a camada de avaliação: ela não reotimiza as rotas; recebe as soluções do GA como cenários e as executa sob condições operacionais realistas (tempos de carregamento/descarga, filas, calendários, velocidades variáveis, indisponibilidades, etc.), com múltiplas réplicas para capturar incerteza. Assim, a simulação valida a viabilidade dinâmica das rotas e compara o desempenho estocástico dos cenários, permitindo selecionar a alternativa mais robusta às condições reais. Para ilustrar o processo de simulação ocorrendo, a Figura 36 apresenta o modelo computacional gerado de forma automática, a fim de simular o sistema logístico.

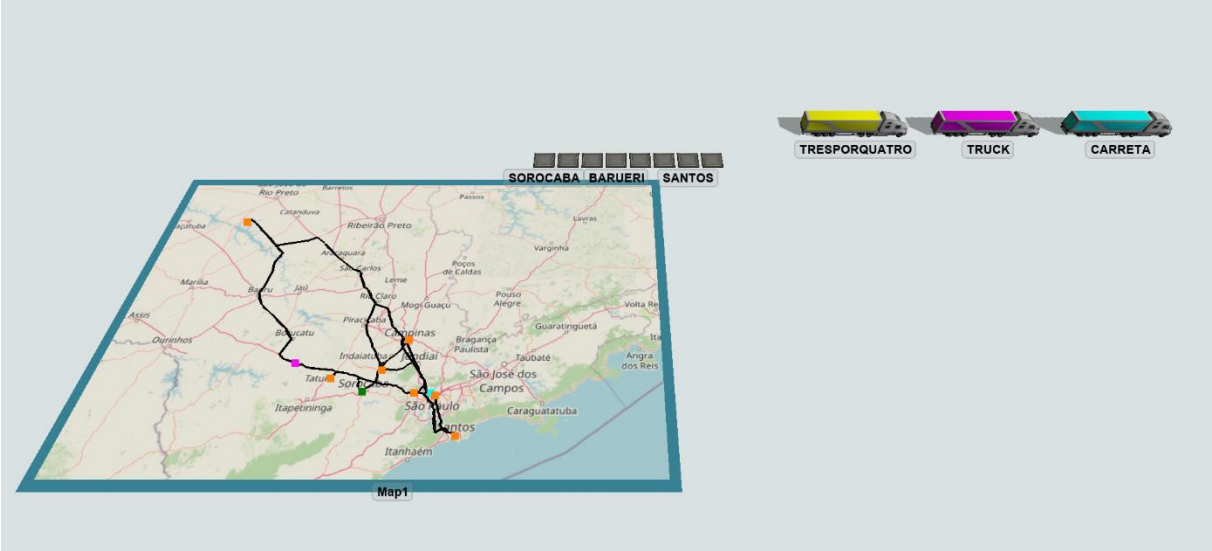

Figura 36 – Interface Flexsim e construção do modelo de simulação
Fonte – Próprio Autor

Em síntese, o GA explora o espaço de soluções, a simulação mede, com variabilidade, como cada ponto dessa fronteira se comporta no sistema realista. Por isso, após o GA, são simulados 20 cenários representativos do espaço de solução visto na Tabela 21, preservando extremos e trade-offs intermediários, foi possível aplicar esse método, que considera pesos atribuídos aos diferentes objetivos analisados (como custo, emissão e volume coletado). Dessa forma, tornou-se viável selecionar, de maneira estruturada e justificada, a melhor solução entre todas as geradas pelo modelo.

Tabela 21 – Tabela dos resultados das funções objetivo

Custo Total (R$)	EmissãoCO_2 (kg)	Total Coletado (Kg)	Cenário
2890,37	362,35	12022,39	Cenário 1
1615,21	194,41	11695,67	Cenário 2
1028,6	120,98	8840,09	Cenário 3
2387,28	259,74	5952,33	Cenário 4
4174,24	608,64	12095,39	Cenário 5
1963,41	230,88	5952,33	Cenário 6
895,91	104,62	6875,63	Cenário 7
631,38	74,24	7366,74	Cenário 8
0	0	0	Cenário 9
631,38	74,24	7366,74	Cenário 10
1741,15	216,8	5952,33	Cenário 11
876,91	110,08	6875,63	Cenário 12
626,53	78,01	7366,74	Cenário 13
626,53	78,01	7366,74	Cenário 14
892,01	107,8	6875,63	Cenário 15
1004,11	123,89	8840,09	Cenário 16
1500,86	200,22	8840,09	Cenário 17
3854,37	563,28	13070,2	Cenário 18
892,01	107,8	6875,63	Cenário 19
2137,76	270,21	15979,03	Cenário 20

Fonte – Próprio Autor

Com o intuito de estabelecer um critério único de avaliação entre os objetivos conflitantes, adotou-se o método das somas ponderadas. Essa abordagem permitiu a

normalização dos objetivos de minimização (custo e emissão de CO_2) e maximização (quantidade coletada), convertendo-os para uma escala comum. A partir disso, tornou-se viável calcular uma função objetivo composta para cada geração do algoritmo genético (GA), considerando os diferentes pesos atribuídos a cada critério.

Para tornar comparáveis os objetivos de naturezas distintas, adotou-se a normalização min–max. Aos objetivos de minimização custo e emissão de CO_2 aplicou-se a Eq. (10), que preserva a ordem do critério (quanto menor o valor original, menor o valor normalizado). Já o objetivo de maximização (quantidade coletada) empregou-se a Eq. (11), que inverte a escala e transforma o ganho em "custo" (quanto maior o valor original, menor o valor normalizado). Assim, todos os termos passam a estar no intervalo [0,1] e podem ser combinados de forma aditiva.

$$x' = \frac{x - min(x)}{max(x) - min(x)} \tag{10}$$

$$x' = \frac{max(x) - x}{max(x) - min(x)} \tag{11}$$

Com isso, todos os valores normalizados passaram a variar entre 0 e 1, sendo que 0 representa o melhor desempenho em cada critério, conforme ilustrado pela tabela 22:

Tabela 22 –Tabela da normalização das funções objetivo

Custo normalizado	Emissão normalizado	Total coletado normalizado
0,692	0,595	0,248
0,387	0,319	0,268
0,246	0,199	0,447
0,572	0,427	0,627
1,000	1,000	0,243
0,470	0,379	0,627
0,215	0,172	0,570
0,151	0,122	0,539
0,000	0,000	1,000
0,151	0,122	0,539
0,417	0,356	0,627
0,210	0,181	0,570
0,150	0,128	0,539
0,150	0,128	0,539
0,214	0,177	0,570
0,241	0,204	0,447
0,360	0,329	0,447
0,923	0,925	0,182
0,214	0,177	0,570
0,512	0,444	0,000

Fonte – Próprio Autor

Após a normalização dos valores obtidos para cada critério de desempenho, foram definidas diferentes combinações de pesos, cada uma representando distintas prioridades entre os objetivos considerados no processo decisório. Essas combinações refletem diferentes estratégias de balanceamento entre critérios como custo operacional, emissão de CO_2 e volume

de carga coletada. A Tabela 23 apresenta a distribuição dos pesos atribuídos em cada cenário, possibilitando a análise comparativa das soluções conforme diferentes perfis de decisão.

Tabela 23 – Tabela dos pesos usados para normalizar as funções

Peso 1	Peso 2	Peso 3
1	0	0
0,5	0,5	0
0,5	0	0,5
0	1	0
0	0,5	0,5
0	0	1
0,33	0,33	0,34

Fonte – Próprio Autor

Com isso, cada cenário e cada combinação de pesos, foi calculado o valor da função objetivo ponderada (F) utilizando a seguinte equação:

$$F_i = w_1 * x'_{i,custo} + w_2 * x'_{i,emissão} + w_3 * x'_{i,coleta} \quad (12)$$

Onde:

- F_i é o valor da função objetivo do cenário i;
- $x'_{i,critério}$ é o valor normalizado do critério;
- w_1, w_2, w_3 são os pesos atribuídos.

A Tabela 24 apresenta os resultados das combinações de pesos na função objetivo, permitindo comparar soluções sob diferentes prioridades e evidenciar os impactos de cada escolha na decisão.

Tabela 24 – Resultados de cada conjunto dos pesos

FO (1_0_0)	FO (0,5_0,5_0)	FO (0,5_0_0,5)	FO (0_1_0)	FO (0_0,5_0,5)	FO (0_0_1)	FO (0,33_0,33_0,34)
0,692	0,644	0,470	0,595	0,421	0,248	0,509
0,387	0,353	0,328	0,319	0,294	0,268	0,324
0,246	0,223	0,347	0,199	0,323	0,447	0,299
0,572	0,499	0,600	0,427	0,527	0,627	0,543
1,000	1,000	0,622	1,000	0,622	0,243	0,743
0,470	0,425	0,549	0,379	0,503	0,627	0,494
0,215	0,193	0,392	0,172	0,371	0,570	0,321
0,151	0,137	0,345	0,122	0,330	0,539	0,273
0,000	0,000	0,500	0,000	0,500	1,000	0,340
0,151	0,137	0,345	0,122	0,330	0,539	0,273
0,417	0,387	0,522	0,356	0,492	0,627	0,469
0,210	0,195	0,390	0,181	0,375	0,570	0,323
0,150	0,139	0,345	0,128	0,334	0,539	0,275
0,150	0,139	0,345	0,128	0,334	0,539	0,275
0,214	0,195	0,392	0,177	0,373	0,570	0,323
0,241	0,222	0,344	0,204	0,325	0,447	0,298
0,360	0,344	0,403	0,329	0,388	0,447	0,379
0,923	0,924	0,553	0,925	0,554	0,182	0,672
0,214	0,195	0,392	0,177	0,373	0,570	0,323
0,512	0,478	0,256	0,444	0,222	0,000	0,316

Fonte – Próprio Autor

Na sequência, os valores ótimos correspondentes às funções de peso foram extraídos e organizados na Tabela 25. Cada valor representa o desempenho da solução em relação ao conjunto específico de pesos aplicados. Ressalta-se que, quanto mais próximo de zero for o valor da função objetivo ponderada, melhor será considerada a solução, uma vez que indica um equilíbrio mais eficiente entre os critérios analisados.

Tabela 25 – Resultados ótimos de cada peso

FOs	Valores
FO (1_0_0)	0,000
FO (0,5_0,5_0)	0,000
FO (0,5_0_0,5)	0,256
FO (0_1_0)	0,000
FO (0_0,5_0,5)	0,222
FO (0_0_1)	0,000
FO (0,33_0,33_0,34)	0,273

Fonte – Próprio Autor

A Tabela 21 apresenta a síntese dos três cenários mais representativos, considerando as respectivas alocações de veículos, cidades atendidas e volume transportado. Embora o GA tenha inicialmente sinalizado o cenário 9 como promissor em quatro combinações de pesos, na etapa de validação/simulação o cenário mostrou-se infrutífero, não retornou resultados operacionais válidos (isto é, não gerou rotas/medições executáveis), indicando ausência de viabilidade prática. Assim, ele foi mantido apenas como referência de sensibilidade do método e não como alternativa recomendada de implementação.

Em contrapartida, o cenário 20 destacou-se nas funções-objetivo FO (0,5_0_0,5) e FO (0_0,5_0,5), que enfatizam o equilíbrio entre emissão e coleta. Nesse arranjo, a Carreta foi alocada às cidades de Itu, Barueri, Adolfo e Santos, somando 15.979,03 kg coletados; adicionalmente, o Truck atendeu São Paulo (9.000 kg) e o Toco, Campinas (7.000 kg). De acordo com a Tabela 17, o cenário apresenta custo total de R$ 2.137,76 e emissão de 270,21 $kgCO_2$. Adotando uma política de doação de alimentos perecíveis de kg, projeta-se 15.979,03 kg de doações derivadas da coleta realizada. Essa configuração revela uma distribuição colaborativa da frota, coerente com as capacidades dos veículos e com foco simultâneo na redução relativa de emissões e no aumento do impacto socioambiental via coleta.

Por fim, o cenário 10 foi a melhor solução na FO (0,33_0,33_0,34), com pesos balanceados entre custo, emissão e coleta. Nessa solução, a Carreta atendeu Barueri, São Paulo, Santos e Adolfo, enquanto Tatuí foi atribuída ao Toco. Conforme a Tabela 17, os resultados foram R$ 631,38 de custo total, 74,24 $kgCO_2$ e de emissão e 7.366,74 kg de coleta. Mantida a mesma política, isso corresponde a 7.366,74 kg em doações de alimentos perecíveis. Essa

alternativa demonstra boa utilização da capacidade (especialmente da Carreta) com desempenho equilibrado entre os três critérios.

A simulação a eventos discretos (FlexSim) constitui a camada de avaliação da abordagem de Otimização via Simulação. O algoritmo genético (GA) é responsável pela busca das soluções de roteamento, gerando diferentes cenários (combinações de rotas e alocação de veículos). Cada cenário é então avaliado no FlexSim, que não altera nem reotimiza as rotas, apenas simula sua operação em condições realistas (tempos de carregamento e descarga, filas, calendários, velocidades variáveis, indisponibilidades de veículos e infraestrutura, entre outros fatores).

Para capturar a incerteza inerente ao sistema, cada cenário foi simulado em R réplicas independentes (com diferentes sementes aleatórias), permitindo estimar o desempenho médio e os intervalos de confiança dos indicadores de custo, emissões de CO_2 e quantidade coletada. Dessa forma, a otimização é dita "via simulação" porque os valores das funções-objetivo utilizados pelo GA derivam das saídas do modelo de simulação, embora o processo de busca das soluções permaneça externo ao simulador.

4.2 Objeto de estudo teórico – Caso 2

Assim como no primeiro caso, após a etapa de preparação e inserção dos dados no sistema, o gestor logístico dá início ao processo de construção dos grafos. Essa representação gráfica tem por objetivo identificar, de maneira estruturada e visual, os municípios que integram as possíveis rotas a serem percorridas pelos veículos de transporte, conforme ilustrado na Figura 37.

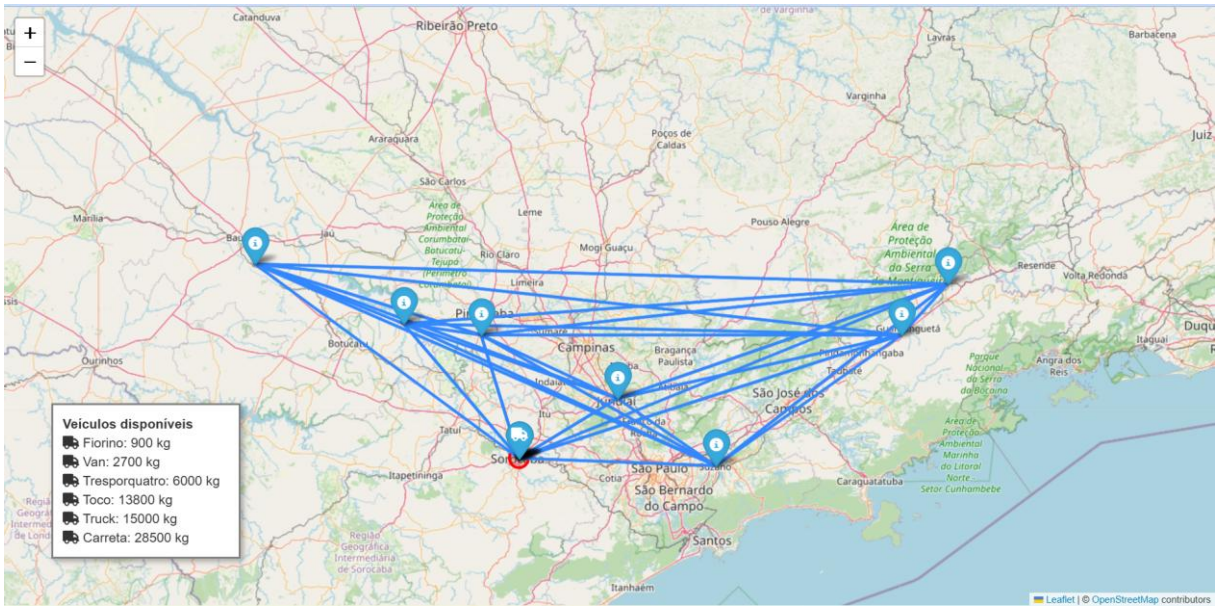

Figura 37 – Grafo das cidades alocadas para a simulação
Fonte – Próprio Autor

Na sequência, procede-se à elaboração das matrizes de distâncias a partir das coordenadas geográficas de latitude (lat) e longitude (lon). Esse procedimento possibilita calcular, de forma precisa, as distâncias entre os municípios considerados no estudo, constituindo um insumo essencial para o planejamento logístico. A Tabela 26 apresenta a configuração dessas matrizes e sua relevância no processo de definição de rotas.

Tabela 26 – Matriz de distância das cidades do caso 2

SOROCABA	AGUDOS	ANHEMBI	APARECIDA	CRUZEIRO	JUNDIAI	SALTINHO	SUZANO
0	194,62	105,2	238,77	275,21	68,22	76,49	116,51
194,62	0	95,25	387,72	413,77	229,85	141,07	298,71
105,2	95,25	0	296,77	325,57	134,64	46,67	203,56
238,77	387,72	296,77	0	40,79	173,29	250,45	135,04
275,21	413,77	325,57	40,79	0	208,28	280,03	175,15
68,22	229,85	134,64	173,29	208,28	0	89,31	70,61
76,49	141,07	46,67	250,45	280,03	89,31	0	159,36
116,51	298,71	203,56	135,04	175,15	70,61	159,36	0

Fonte – Próprio Autor

De modo a explicitar a formulação multiobjetivo do problema de roteamento de veículos com frota heterogênea (HFVRP), adota-se a mesma lógica aplicada no primeiro estudo. Nesse contexto, o modelo busca minimizar simultaneamente o custo total e as emissões de CO_2, ao mesmo tempo em que maximiza o volume coletado. As equações apresentadas anteriormente (7, 8 e 9) descrevem essa estrutura matemática, incorporando as restrições de capacidade, conservação de fluxo, atendimento único por cliente e retorno obrigatório ao depósito.

De forma complementar, mantêm-se também as configurações relacionadas às variáveis de decisão e aos parâmetros do Algoritmo Genético (GA). Assim, as Tabelas 17 e 18, já apresentadas no Caso 1, permanecem válidas neste estudo, assegurando a consistência metodológica entre os dois cenários.

Tabela 27 – Tabela de rotas e subrotas do caso 2 (continua)

Cenário	Veículo	Rota (IDs)	Coletas por Cidades (kg)
1	CARRETA	1-5-9-7-1	6300, 8260, 6750
1	TRUCK	1-8-1	9030
1	TOCO	1-2-1	8030
2	CARRETA	1-5-9-8-1	6300, 8260, 9030
2	TRUCK	1-7-2-1	6750, 8030
2	TOCO	1-10-1	6560
3	CARRETA	1-2-5-9-1	8030, 6300, 8260
3	TRUCK	1-8-1	9030
3	TOCO	1-10-1	6560
4	CARRETA	1-5-9-7-1	6300, 8260, 6750
4	TRUCK	1-2-1	8030
4	TOCO	1-8-1	9030
5	CARRETA	1-5-9-10-7-1	6300, 8260, 6560, 6750
5	TRUCK	1-2-1	8030
5	TOCO	1-8-1	9030

Fonte – Próprio Autor

Tabela 28 – Tabela de rotas e subrotas do caso 2 (continua)

Cenário	Veículo	Rota (IDs)	Coletas por Cidades (kg)
6	CARRETA	1-8-9-7-1	9030, 8260, 6750
6	TRUCK	1-2-5-1	8030, 6300
6	TOCO	1-10-1	6560
7	CARRETA	1-5-2-7-1	6300, 8030, 6750
7	TRUCK	1-9-1	8260
7	TOCO	1-8-1	9030
8	CARRETA	1-5-7-2-1	6300, 6750, 8030
8	TRUCK	1-9-1	8260
8	TOCO	1-8-1	9030

Fonte – Próprio Autor

Na Tabela 28 são apresentadas as rotas e sub-rotas resultantes da aplicação do Algoritmo Genético ao problema em estudo. Cada cenário representa uma solução não-dominada completa, que foi decomposta em sub-rotas para garantir o atendimento das restrições de capacidade e janelas de serviço. Assim, cada cenário aparece em mais de uma linha, correspondendo a cada veículo utilizado na solução.

Concluída a etapa de geração das rotas, as informações são exportadas de maneira automática para uma base de dados estruturada. A partir dessa base, é construído o modelo de simulação, que reproduz o sistema logístico considerado neste estudo e permite avaliar a execução das rotas em ambiente computacional.

Tabela 29 – Tabela de rotas e subrotas do caso 2 (conclusão)

Cenário	Veículo	Rota (IDs)	Coletas por Cidades (kg)
9	CARRETA	1-8-2-7-1	9030, 8030, 6750
9	TRUCK	1-9-5-1	8260, 6300
9	TOCO	1-10-1	6560
10	CARRETA	1-5-2-7-1	6300, 8030, 6750
10	TRUCK	1-8-1	9030
10	TOCO	1-9-1	8260
11	CARRETA	1-5-2-7-1	6300, 8030, 6750
11	TRUCK	1-9-1	8260
11	TOCO	1-4-1	7400
12	CARRETA	1-5-2-7-1	6300, 8030, 6750
12	TRUCK	1-9-1	8260
12	TOCO	1-4-1	7400
13	CARRETA	1-5-2-7-10-1	6300, 8030, 6750, 6560
13	TRUCK	1-4-1	7400
13	TOCO	1-9-1	8260
14	CARRETA	1-5-2-7-1	6300, 8030, 6750
14	TRUCK	1-9-10-1	8260, 6560
14	TOCO	1-8-1	9030
15	CARRETA	1-5-2-7-4-1	6300, 8030, 6750, 7400
15	TRUCK	1-9-10-1	8260, 6560
15	TOCO	1-8-1	9030
16	CARRETA	1-5-2-7-4-1	6300, 8030, 6750, 7400
16	TRUCK	1-9-10-1	8260, 6560
16	TOCO	1-8-1	9030
17	CARRETA	1-5-2-7-4-1	6300, 8030, 6750, 7400
17	TRUCK	1-9-1	8260
17	TOCO	1-8-1	9030

Fonte – Próprio Autor

Tabela 30 – Tabela de rotas e subrotas do caso 2 (conclusão)

Cenário	Veículo	Rota (IDs)	Coletas por Cidades (kg)
18	CARRETA	1-10-2-7-1	6560, 8030, 6750
18	TRUCK	1-9-1	8260
18	TOCO	1-4-1	7400
19	CARRETA	1-2-5-7-1	8030, 6300, 6750
19	TRUCK	1-9-1	8260
19	TOCO	1-4-1	7400
20	CARRETA	1-2-5-7-1	8030, 6300, 6750
20	TRUCK	1-9-1	8260
20	TOCO	1-4-1	7400

Fonte – Próprio Autor

Uma vez definidas as rotas pelo Algoritmo Genético, a simulação a eventos discretos, desenvolvida no FlexSim, atua como camada de avaliação do sistema. Nesse estágio, as soluções não são reotimizadas, mas sim executadas sob condições operacionais realistas, incorporando variáveis como tempos de carregamento e descarregamento. Esse processo, realizado com múltiplas réplicas, tem como objetivo capturar a variabilidade e a incerteza presentes no ambiente logístico real, garantindo maior robustez à análise.

Dessa forma, a simulação valida a viabilidade dinâmica das rotas previamente obtidas pelo GA e permite comparar o desempenho estocástico dos diferentes cenários, oferecendo ao gestor uma visão mais fiel sobre os resultados possíveis em condições práticas. Para ilustrar o processo de simulação ocorrendo, a Figura 38 apresenta o modelo computacional gerado de forma automática, a fim de simular o sistema logístico.

Figura 38 – Interface Flexsim e construção do modelo de simulação do caso 2
Fonte – Próprio Autor

Após a etapa de simulação, foram obtidos os resultados referentes a custo total, emissões de CO_2 e volume coletado em cada cenário avaliado. Esses indicadores permitem mensurar o desempenho de cada alternativa e evidenciam os *trade-offs* entre critérios econômicos, ambientais e sociais. A Tabela 29 sintetiza os valores encontrados, contemplando tanto os

cenários de melhor desempenho quanto aqueles que, embora viáveis, apresentaram resultados menos favoráveis.

Tabela 31 – Tabela dos resultados das funções objetivo do caso 2 (continua)

Custo Total (R$)	EmissãoCO_2 (kg)	Total Coletado (Kg)	Cenário
R$ 3.542,07	434,77	17058,94	Cenário 1
R$ 1.469,15	174,75	6690,21	Cenário 2
R$ 2.626,39	327,09	15559,77	Cenário 3
R$ 3.879,84	502,79	17096,56	Cenário 4
R$ 3.879,84	502,79	17096,56	Cenário 5
R$ 1.461,01	181,92	6690,21	Cenário 6
R$ 2.323,89	295,21	17322,47	Cenário 7
R$ 2.323,89	295,21	17322,47	Cenário 8
R$ 1.472,32	173,13	6690,21	Cenário 9
R$ 2.279,80	286,33	17293,51	Cenário 10
R$ 2.964,09	370,50	15660,12	Cenário 11
R$ 2.964,09	370,50	15660,12	Cenário 12
R$ 3.068,96	391,61	15692,47	Cenário 13
R$ 3.287,52	419,24	15710,73	Cenário 14
R$ 3.287,52	419,24	15710,73	Cenário 15
R$ 3.287,52	419,24	15710,73	Cenário 16
R$ 2.323,89	295,21	17322,47	Cenário 17
R$ 2.964,09	370,50	15660,12	Cenário 18
R$ 2.964,09	370,50	15660,12	Cenário 19
R$ 2.964,09	370,50	15660,12	Cenário 20

Fonte – Próprio Autor

Com o intuito de viabilizar a comparação entre objetivos de naturezas distintas, adotou-se novamente o método das somas ponderadas. Para isso, os resultados foram normalizados por meio da técnica min–max, que ajusta todos os critérios para a mesma escala de [0,1], conforme as equações 10 e 11. Para os objetivos de minimização (custo e emissão), quanto menor o valor original, menor também o valor normalizado. Já no caso da maximização (volume coletado), a escala é invertida, de modo que valores maiores resultem em normalizações menores, preservando a lógica de que 0 representa o melhor desempenho em cada critério.

Com isso, todos os valores normalizados passaram a variar entre 0 e 1, sendo que 0 representa o melhor desempenho em cada critério, conforme ilustrado pela tabela 31:

Tabela 32 – Tabela da normalização das funções objetivo do caso 2(continua)

Custo Total Normalizado	Emissão Normalizado	Total Coletado Normalizado
0,860	0,794	0,025
0,003	0,005	1,000
0,482	0,467	0,166
1,000	1,000	0,021
1,000	1,000	0,021
0,000	0,027	1,000
0,357	0,370	0,000
0,357	0,370	0,000
0,005	0,000	1,000
0,339	0,343	0,003
0,621	0,599	0,156
0,621	0,599	0,156
0,665	0,663	0,153

Fonte – Próprio Autor

Tabela 33 – Tabela da normalização das funções objetivo do caso 2(conclusão)

Custo Total Normalizado	Emissão Normalizado	Total Coletado Normalizado
0,755	0,747	0,152
0,755	0,747	0,152
0,755	0,747	0,152
0,357	0,370	0,000
0,621	0,599	0,156
0,621	0,599	0,156
0,621	0,599	0,156

Fonte – Próprio Autor

Definidos os valores normalizados, estabeleceram-se diferentes combinações de pesos para representar distintas estratégias de decisão. Cada conjunto de pesos expressa uma prioridade específica entre custo, emissão de CO_2 e volume coletado, permitindo analisar o impacto de cada escolha sobre o desempenho logístico. A Tabela 32 apresenta a distribuição desses pesos, que variam desde a ênfase exclusiva em um critério até combinações balanceadas entre os três objetivos.

Tabela 34 – Tabela dos pesos usados para normalizar as funções

Peso 1	Peso 2	Peso 3
1	0	0
0,5	0,5	0
0,5	0	0,5
0	1	0
0	0,5	0,5
0	0	1
0,33	0,33	0,34

Fonte – Próprio Autor

Com isso, cada cenário e cada combinação de pesos, foi calculado o valor da função objetivo ponderada (F) utilizando a seguinte equação:

$$F_i = w_1 * x'_{i,custo} + w_2 * x'_{i,emissão} + w_3 * x'_{i,coleta} \quad (12)$$

Onde:

- F_i é o valor da função objetivo do cenário i;
- $x'_{i,critério}$ é o valor normalizado do critério;
- w_1 , w_2 , w_3 são os pesos atribuídos.

A Tabela 33 apresenta os resultados das combinações de pesos na função objetivo, permitindo comparar soluções sob diferentes prioridades e evidenciar os impactos de cada escolha na decisão.

Tabela 35 – Resultados de cada conjunto dos pesos

FO (1_0_0)	FO (0,5_0,5_0)	FO (0,5_0_0,5)	FO (0_1_0)	FO (0_0,5_0,5)	FO (0_0_1)	FO (0,33_0,33_0,34)
0,860	0,827	0,443	0,794	0,409	0,025	0,554
0,003	0,004	0,502	0,005	0,502	1,000	0,343
0,482	0,474	0,324	0,467	0,316	0,166	0,369
1,000	1,000	0,511	1,000	0,511	0,021	0,667
1,000	1,000	0,511	1,000	0,511	0,021	0,667
0,000	0,013	0,500	0,027	0,513	1,000	0,349
0,357	0,364	0,178	0,370	0,185	0,000	0,240
0,357	0,364	0,178	0,370	0,185	0,000	0,240
0,005	0,002	0,502	0,000	0,500	1,000	0,342
0,339	0,341	0,171	0,343	0,173	0,003	0,226
0,621	0,610	0,389	0,599	0,378	0,156	0,456
0,621	0,610	0,389	0,599	0,378	0,156	0,456
0,665	0,664	0,409	0,663	0,408	0,153	0,490
0,755	0,751	0,453	0,747	0,449	0,152	0,547
0,755	0,751	0,453	0,747	0,449	0,152	0,547
0,755	0,751	0,453	0,747	0,449	0,152	0,547
0,357	0,364	0,178	0,370	0,185	0,000	0,240
0,621	0,610	0,389	0,599	0,378	0,156	0,456
0,621	0,610	0,389	0,599	0,378	0,156	0,456
0,621	0,610	0,389	0,599	0,378	0,156	0,456

Fonte – Próprio Autor

Por fim, os melhores valores correspondentes a cada função objetivo foram extraídos e organizados em uma tabela resumo. Essa síntese permite identificar, de maneira estruturada, quais cenários oferecem maior aderência às diferentes perspectivas estratégicas analisadas, seja priorizando a redução de custos, a mitigação ambiental ou a ampliação do impacto social associado à coleta.

Tabela 36 – Resultados ótimos de cada peso

FOs	Valores
FO (1_0_0)	0,000
FO (0,5_0,5_0)	0,002
FO (0,5_0_0,5)	0,171
FO (0_1_0)	0,000
FO (0_0,5_0,5)	0,173
FO (0_0_1)	0,000
FO (0,33_0,33_0,34)	0,226

Fonte – Próprio Autor

A Tabela 34 apresenta a síntese dos cenários mais representativos do Caso 2, considerando a alocação de veículos, cidades atendidas e respectivos volumes transportados. Entre os resultados, destaca-se que o cenário 6 foi o melhor na função-objetivo FO (1_0_0), priorizando exclusivamente o custo. Nesse arranjo, a Carreta percorreu a rota *1-4-8-10-1*, atendendo Cruzeiro (7.000 kg), Aparecida (9.030 kg) e Suzano (6.560 kg). O Toco foi responsável pela rota *1-9-2-1*, coletando em Saltinho (6.750 kg) e Agudos (8.030 kg), enquanto a Van foi alocada ao município de Anhembi (9.030 kg). O resultado global foi de R$ 1.461,01

de custo, 181,92 kgCO_2 de emissões e 6.690,21 kg de coleta, configurando-se como a solução mais econômica entre todas.

Já o cenário 17 destacou-se na função FO (0_0,5_0,5), que equilibra emissão e coleta. Nesse caso, a Carreta executou a rota *1-5-2-7-4-1*, coletando em Jundiaí (6.300 kg), Anhembi (8.030 kg), Suzano (6.750 kg) e Cruzeiro (7.400 kg). O Truck percorreu *1-9-1*, atendendo Saltinho (8.260 kg), e o Toco foi direcionado para Aparecida (9.030 kg). Essa configuração resultou em R$ 2.323,89 de custo, 295,21 kgCO_2 de emissões e 17.322,47 kg de coleta, representando uma solução de maior impacto social, com significativa massa coletada e níveis de custo e emissão aceitáveis.

Por fim, o cenário 10 foi o melhor avaliado na função FO (0,33_0,33_0,34), que busca equilíbrio entre os três critérios. Nesse arranjo, a Carreta percorreu a rota *1-5-2-7-1*, coletando em Jundiaí (6.300 kg), Anhembi (8.030 kg) e Suzano (6.750 kg). O Truck ficou responsável por Saltinho (8.260 kg), e o Toco foi alocado a Aparecida (9.030 kg). Os resultados foram R$ 1.472,32 de custo, 173,13 kgCO_2 de emissões e 6.690,21 kg de coleta, configurando-se como uma alternativa robusta e balanceada.

De modo geral, os resultados do Caso 2 evidenciam que diferentes cenários atendem a diferentes prioridades: o cenário 6 como a melhor alternativa econômica, o cenário 17 como a solução de maior impacto socioambiental e o cenário 10 como a opção de equilíbrio entre os critérios. Nesse sentido, o objetivo da abordagem proposta não é impor um único cenário "ótimo", mas disponibilizar ao gestor um portfólio de alternativas eficientes na fronteira de Pareto, permitindo que a escolha final seja feita estrategicamente pela organização.

4.3 Principais resultados obtidos

O presente trabalho teve como propósito central investigar, propor e aplicar uma abordagem inovadora para o problema de roteamento de veículos no contexto da logística reversa de REEE. A pesquisa foi motivada pelos crescentes desafios econômicos, ambientais e sociais relacionados à gestão desse tipo de resíduo, cuja complexidade exige soluções mais abrangentes do que aquelas tradicionalmente utilizadas no planejamento logístico. Nesse sentido, a tese procurou integrar métodos de otimização, simulação e análise multiobjetivo em uma plataforma computacional capaz de apoiar, de maneira prática e sistemática, a tomada de decisão por parte de gestores logísticos.

O percurso metodológico da pesquisa iniciou-se com a Revisão Sistemática da Literatura (RSL), que permitiu mapear o estado da arte sobre logística reversa, problemas de roteamento de veículos heterogêneos (HFVRP) e técnicas de otimização via simulação (OvS).

Essa etapa inicial revelou lacunas importantes, como a ausência de estudos que integrassem algoritmos de otimização multiobjetivo a ferramentas de simulação a eventos discretos, sobretudo em aplicações voltadas à logística reversa de REEE. A RSL serviu, assim, como fundamento científico para a construção do modelo conceitual e computacional desenvolvido ao longo desta tese, ao mesmo tempo em que posicionou a pesquisa em relação às contribuições teóricas pretendidas.

A partir desse diagnóstico, foi estruturada uma formulação matemática do problema, contemplando múltiplos objetivos: a minimização do custo total, a minimização das emissões de dióxido de carbono (CO_2) e a maximização da quantidade total coletada. As restrições incluíram a capacidade dos veículos, a conservação de fluxo, a atribuição única de atendimento às cidades e o retorno obrigatório ao depósito central. Essa formalização contribui para a literatura de otimização em logística reversa ao oferecer um modelo específico para o HFVRP, considerando simultaneamente dimensões econômicas, ambientais e sociais, o que o diferencia de trabalhos anteriores com foco em apenas um ou dois desses aspectos.

No âmbito da contribuição teórica, a pesquisa avança ao consolidar a integração entre otimização via algoritmos genéticos (GA) e simulação a eventos discretos (SED) como abordagem para problemas complexos de logística reversa. O GA multiobjetivo foi projetado para explorar diferentes cenários de roteamento, gerando soluções não dominadas segundo os critérios de custo, emissão e coleta. Essa integração responde a um desafio recorrente identificado na literatura: a dificuldade de aliar modelos matemáticos de otimização a ambientes de simulação capazes de capturar a variabilidade e a estocasticidade presentes em sistemas reais. Dessa forma, a tese contribui para o desenvolvimento científico ao propor uma estrutura metodológica replicável em outros contextos de pesquisa e aplicação.

Do ponto de vista metodológico, a principal inovação reside no desenvolvimento de um software próprio em Python, dotado de interface gráfica e integração direta com o ambiente FlexSim. Esse sistema permite a leitura e filtragem de dados a partir de arquivos CSV, a construção de matrizes de distâncias geográficas, a geração de grafos representativos das rotas, a aplicação de heurísticas e algoritmos genéticos multiobjetivo e a exportação de resultados em diferentes formatos (Excel, CSV). Além disso, a ferramenta gera mapas interativos com rotas otimizadas, utilizando a biblioteca Folium, e integra os cenários diretamente a modelos de simulação no FlexSim. Esse nível de integração metodológica é raro na literatura, representando uma contribuição original que alia otimização, visualização e simulação em um único ambiente computacional.

O modelo computacional proposto oferece ainda flexibilidade de parametrização, permitindo que o usuário configure pesos para os diferentes objetivos (custo, emissão, social), taxas de crossover e mutação, tamanho de população, número de gerações e quantidade de veículos disponíveis. Essa flexibilidade amplia a aplicabilidade da ferramenta, uma vez que possibilita ao gestor logístico adaptar o modelo a diferentes contextos operacionais e restrições específicas.

No plano prático, a pesquisa demonstrou a aplicabilidade da abordagem por meio de dois estudos de caso complementares. O primeiro (Caso 1) envolveu municípios da Região Metropolitana de São Paulo, explorando a coleta de resíduos eletroeletrônicos em diferentes cenários de demanda e restrições veiculares. Esse estudo de caso evidenciou como a integração entre otimização e simulação pode apoiar gestores na escolha entre cenários de menor custo, menor emissão ou maior quantidade coletada, fornecendo uma base clara para a análise de trade-offs. O segundo (Caso 2), por sua vez, foi estruturado em um contexto alternativo, com modificações na frota, nas capacidades e nas matrizes de distância, a fim de avaliar a robustez e a escalabilidade do modelo. Esse segundo estudo permitiu verificar a consistência das soluções em condições distintas, reforçando a capacidade da ferramenta em se adaptar a diferentes realidades operacionais. A análise conjunta dos dois casos confirma que o modelo é aplicável tanto em cenários locais quanto em configurações mais complexas, ampliando o alcance prático da proposta.

Essa vinculação inovadora amplia o impacto da proposta, ao conectar a eficiência logística a um benefício direto para a sociedade, reforçando o caráter multidimensional da sustentabilidade. Ao operacionalizar essa dimensão, a pesquisa aproxima o modelo acadêmico das demandas reais de empresas e organizações que buscam alinhar desempenho econômico, responsabilidade ambiental e engajamento social.

De maneira integrada, os resultados da pesquisa confirmam que a combinação entre otimização e simulação constitui uma estratégia eficaz para enfrentar os desafios da logística reversa. A tese contribui, portanto, em três níveis complementares:

- No plano teórico, ao oferecer uma formulação específica para o HFVRP multiobjetivo em logística reversa e ao consolidar a integração entre GA e SED como abordagem de pesquisa;
- No plano metodológico, ao desenvolver um software inovador, flexível e replicável, que integra algoritmos de otimização, simulação e visualização de resultados em uma mesma plataforma;

- No plano prático, ao aplicar a abordagem em dois estudos de caso reais e complementares, fornecendo evidências concretas de sua aplicabilidade e relevância para gestores logísticos, além de incorporar uma dimensão social de grande importância.

Como resultado, esta tese não apenas preenche lacunas identificadas na literatura, mas também disponibiliza uma ferramenta de apoio à decisão que pode ser aplicada em diferentes cenários de logística reversa. O software desenvolvido, ao integrar otimização multiobjetivo e simulação, representa uma contribuição para a área, capaz de apoiar tanto a pesquisa acadêmica quanto a prática profissional.

Em síntese, as contribuições desta pesquisa transcendem a formulação matemática ou o desenvolvimento computacional isolados, ao propor um caminho integrado e orientado para a realidade dos sistemas logísticos. O modelo oferece condições para que gestores tomem decisões mais informadas, equilibrando custos, impactos ambientais e benefícios sociais, ao mesmo tempo em que abre espaço para novos desdobramentos acadêmicos. Assim, a tese se coloca como uma referência no campo da logística reversa de resíduos eletroeletrônicos, ao articular teoria, método e prática em uma abordagem coesa e inovadora.

5 CONCLUSÕES

Esta pesquisa enfrentou o desafio contemporâneo de planejar a LR de REEE conciliando objetivos potencialmente conflitantes, tais como custos, emissões de CO_2 e quantidade coletada. A questão central que guiou o trabalho foi: em que medida um Algoritmo Genético (GA) multiobjetivo, acoplado a um modelo de simulação a eventos discretos, consegue apoiar a seleção de rotas e a alocação de frotas na LR, produzindo soluções factíveis e balanceadas entre custo, emissões e atendimento? A integração entre GA e simulação foi realizada em duas etapas sequenciais, em linha com a lógica da Otimização via Simulação (OvS), embora sem realimentação automática da simulação para a reotimização das rotas.

A Revisão Sistemática da Literatura (RSL) indicou duas lacunas principais. A primeira diz respeito à integração prática entre modelos de otimização e simulação, ainda pouco explorada no contexto da logística reversa. A segunda refere-se à escassez de estudos que tratem explicitamente as compensações entre objetivos (custo, emissões, coleta), prevalecendo análises monoobjetivo. Em resposta a essas lacunas, estruturou-se um método em três etapas: definição e inicialização do problema, envolvendo matrizes de distâncias, demandas e custos, bem como as características da frota heterogênea; geração de soluções por GA multiobjetivo para um HFVRP com depósito único; e avaliação estocástica em simulação, realizada no FlexSim, sem reotimização, utilizando as rotas fornecidas pelo GA como cenários experimentais.

Foram avaliados 20 cenários provenientes da fronteira não dominada do GA. Um deles revelou-se inválido na simulação, sendo mantido apenas como referência de sensibilidade do método. Entre os cenários válidos, observaram-se resultados extremos bastante informativos. O menor custo total foi de R$ 626,53 (Cenários 13 e 14), com 78,01 kg de CO_2 emitidos e 7.366,74 kg coletados. As menores emissões foram de 74,24 kg de CO_2 (Cenários 8 e 10), ambos com custo de R$ 631,38 e a mesma quantidade coletada. A maior coleta atingiu 15.979,03 kg (Cenário 20), com custo de R$ 2.137,76 e emissão de 270,21 kg de CO_2. Esses números evidenciam claramente o espaço de compromisso: reduzir custos e emissões concentra a operação em rotas mais curtas e cargas medianas, enquanto maximizar a coleta exige veículos de maior capacidade e rotas mais extensas, elevando custos e emissões.

Para permitir a comparação de critérios de natureza distinta, aplicou-se a normalização min–max e o método das somas ponderadas. As combinações de pesos testadas refletiram perfis de decisão realistas. Nessas análises, o Cenário 20 destacou-se quando emissão e coleta foram priorizadas conjuntamente (FO 0,5–0–0,5 e FO 0–0,5–0,5), com distribuição de frota que

alocou a carreta para Itu, Barueri, Adolfo e Santos (15.979,03 kg), o truck para São Paulo (9.000 kg) e o toco para Campinas (7.000 kg). Já a solução de compromisso mais equilibrada entre os três objetivos (FO 0,33–0,33–0,34) foi o Cenário 10, com custo de R$ 631,38, emissão de 74,24 kg de CO_2 e 7.366,74 kg coletados, configurando um ponto de baixo custo e baixa emissão com atendimento intermediário.

A amplitude observada entre os cenários revela margens expressivas de melhoria. Em termos de custo, a variação foi de R$ 626,53 a R$ 4.174,24, sendo possível obter reduções superiores a 80% ao migrar de combinações desfavoráveis para soluções eficientes. Em emissões, a faixa de 74,24 a 608,64 kg de CO_2 indica potenciais reduções acima de 85%. Em coleta, a variação de 5.952,33 para 15.979,03 kg mais que duplica a massa atendida quando se privilegiam rotas e veículos de maior capacidade. Em síntese, o método permite ao decisor navegar por frentes de Pareto mensuráveis, escolhendo conscientemente entre custo mínimo, emissões mínimas ou maior cobertura social.

Além do primeiro estudo de caso, centrado em municípios da Região Metropolitana de São Paulo, foi conduzido um segundo estudo (Caso 2), estruturado com parâmetros distintos de frota, capacidades e matriz de distâncias. O objetivo foi verificar a escalabilidade e a robustez do modelo diante de condições alternativas. O Caso 2 demonstrou que o método mantém consistência mesmo em contextos mais complexos, reforçando sua aplicabilidade em diferentes realidades da logística reversa. A análise comparativa entre os dois casos indica que o modelo não apenas se adapta a cenários variados, mas também preserva a coerência dos *trade-offs* identificados, confirmando a utilidade da abordagem para gestores em situações diversas.

A pesquisa apresenta três contribuições centrais. (i) No plano metodológico, formaliza uma abordagem de Otimização via Simulação (OvS) para um HFVRP de logística reversa, integrando um Algoritmo Genético multiobjetivo a um modelo de simulação a eventos discretos em um fluxo reprodutível de solução. (ii) Organiza de forma clara as funções-objetivo e seus pesos, permitindo visualizar os *trade-offs* entre custo, emissões de CO_2 e nível de atendimento. (iii) No plano computacional, disponibiliza um sistema com interface gráfica capaz de ler dados reais ou realistas, gerar rotas multiveículo sobre mapas, exportar cenários e consolidar resultados em tabelas e visualizações para apoio à análise.

As implicações gerenciais são diretas. Em contextos com metas de sustentabilidade, soluções como o Cenário 10 ilustram baixo custo e baixa emissão com atendimento consistente, úteis para políticas de descarbonização associadas a restrições orçamentárias. Em políticas que priorizam impacto social e amplitude de coleta, o Cenário 20 demonstra como expandir o atendimento mantendo custos e emissões em níveis controlados. Quando a restrição dominante

é orçamentária, os cenários de menor custo, como os Cenários 13 e 14, servem como referência operacional mínima com emissões reduzidas. A inclusão do Caso 2 reforça esse conjunto de implicações, pois evidencia que a ferramenta pode ser aplicada em diferentes redes logísticas e contextos de decisão, sem perda de eficiência ou de transparência nos resultados.

Algumas limitações devem ser reconhecidas. O modelo considerou um único depósito; os custos e as emissões foram calculados a partir de fatores médios de custo/km e emissão/km para cada tipo de veículo, sem representação explícita de sua variabilidade; janelas de tempo estritas, múltiplas viagens por turno e outras restrições operacionais não foram incluídas nesta fase; e a demanda foi tratada como determinística no horizonte analisado. Essas simplificações foram adequadas para demonstrar a viabilidade do método, mas restringem a generalização para redes maiores e mais voláteis.

Em síntese, o objetivo do trabalho foi alcançado: mostrou-se que uma abordagem de Otimização via Simulação (OvS), que integra um Algoritmo Genético multiobjetivo a um modelo de simulação a eventos discretos, constitui um apoio consistente à tomada de decisão em logística reversa de REEE. A solução proposta oferece um conjunto de rotas alternativas equilibradas entre custo, emissões e nível de atendimento. O sistema computacional desenvolvido, alinhado à literatura e às necessidades práticas, constitui uma base sólida para desdobramentos futuros, tanto em pesquisas acadêmicas quanto em aplicações industriais.

5.1 Trabalho futuros

A continuidade desta pesquisa pode avançar em múltiplas frentes complementares:

1. Enriquecimento do problema e dos dados
   - Múltiplos depósitos: modelar redes com mais de um ponto de consolidação, inclusive transferência entre nós.
   - Janelas de tempo e tempos de serviço: evoluir para VRPTW (problema de roteamento de veículos com janelas de tempo) e variantes, incorporando atendimento por períodos, limitações de jornada de motoristas e tempos de carga e descarga.
2. Avanços algorítmicos e de otimização
   - Algoritmos de otimização: comparar o GA atual com outras meta-heurísticas.
   - Meta-heurísticas: integrar programação inteira e linear para refinar soluções do GA.
   - Controle adaptativo de operadores: ajustar dinamicamente taxas de cruzamento e mutação conforme a diversidade populacional.

- Paralelização e *budget* de simulação: paralelizar avaliações e empregar metamodelos para reduzir o custo computacional do OvS.

3. Integração ampliada com simulação e decisão
   - Gestão de cenários e *dashboards*: disponibilizar visualização interativa de frentes de Pareto, *what-if* e filtros por metas (budget, metas de CO_2, cobertura mínima).
   - Métodos multicritério: apoiar a escolha final entre soluções não dominadas com AHP ou NBI, registrando preferências dos decisores.
4. Engenharia de dados e integração com GIS/IoT
   - Dados abertos de mobilidade e tráfego em tempo real;
   - Instrumentação IoT para fechar o ciclo de calibração do simulador e da otimização.

Ao perseguir essas direções, o sistema desenvolvido proposto evolui de um protótipo acadêmico robusto para um sistema de apoio à decisão completo, apto a operar em ambientes reais de logística reversa, gerar ganhos econômicos tangíveis, reduzir emissões e ampliar o alcance social das coletas contribuindo, em última instância, para políticas de economia circular e para o cumprimento de metas ESG.

5.2 Considerações finais

A pesquisa concentrou-se no planejamento da logística reversa de resíduos de equipamentos eletroeletrônicos, buscando conciliar critérios potencialmente conflitantes, como custo, emissões de CO_2 e volume coletado. A questão central foi como apoiar a decisão gerencial em um ambiente com múltiplos objetivos e incertezas operacionais. Para respondê-la, desenvolveu-se e avaliou-se uma abordagem que integra um Algoritmo Genético multiobjetivo a um modelo de Simulação a Eventos Discretos, em linha com a lógica da Otimização via Simulação (OvS), na qual a otimização gera cenários candidatos que são posteriormente avaliados em simulação.

O objetivo geral de disponibilizar uma ferramenta metodológica e computacional capaz de explicitar os compromissos entre metas econômicas, ambientais e sociais foi alcançado por meio de um sistema que gera cenários, analisa seu desempenho sob variabilidade e oferece evidências objetivas para a escolha de políticas de roteamento e alocação de frotas. Os objetivos específicos foram tratados de forma articulada: iniciaram-se com o exame teórico e a revisão sistemática da literatura, evoluíram para a modelagem e implementação computacional da abordagem proposta e culminaram na sua aplicação e validação em estudos de caso. Em primeiro lugar, a revisão sistemática estruturou o estado da arte sobre OvS em logística reversa e roteamento veicular, identificando lacunas relevantes, entre elas a integração ainda limitada

entre modelos de otimização e simulação operacional e a exploração restrita dos *trade-offs* entre custo, emissões e nível de serviço.

Em seguida, desenvolveu-se o modelo de simulação para representar, com maior fidelidade, as condições operacionais de coleta e retorno de resíduos. O ambiente contemplou tempos de processamento, formação de filas e restrições de capacidade, funcionando como um banco de provas das soluções propostas pela otimização. Paralelamente, especificou-se e implementou-se o algoritmo de otimização para um problema de roteamento multiveículo heterogêneo, com estruturas de dados apropriadas, operadores genéticos compatíveis e uma função de aptidão que combina custo, emissões e quantidade coletada segundo diferentes configurações de pesos. Assim, a camada de geração de soluções explorou o espaço de possibilidades e produziu conjuntos de alternativas não dominadas.

A integração entre otimização e simulação consolidou a estratégia de Otimização via Simulação. As rotas sugeridas pelo algoritmo genético foram avaliadas na simulação sem reotimização, o que permitiu aferir a robustez das soluções frente a variações operacionais e comparar, de modo transparente, diferentes preferências na função objetivo. O processo resultante mostrou-se consistente para gerar e triar políticas, explicitar compromissos entre custo, emissões e coleta e descartar, de forma automática, configurações inviáveis do ponto de vista operacional.

A aplicação com dados reais reforçou a utilidade prática do método. Trabalhou-se com municípios, demandas e frotas concretas, obtendo-se cenários pertencentes à fronteira não dominada que foram subsequentemente validados no ambiente estocástico. Em alguns casos, alternativas que se mostravam promissoras na etapa de otimização revelaram inviabilidade na simulação, o que evidencia a importância de incorporar variabilidade ao processo decisório. Em outros, observou-se coerência entre os estágios, com cenários capazes de equilibrar metas e apresentar maior potencial de implementação. A leitura integrada, articulada por veículo e por cidade, oferece ao gestor um panorama operativo acionável para alocação de frotas, planejamento de coletas e estimativas de custos e emissões.

Além do ganho metodológico, a pesquisa disponibiliza um software integrado que reúne importação de dados, construção de grafos, cálculo de matrizes de distância, heurísticas e algoritmo genético, avaliação em simulação e visualização de rotas e resultados. Esse artefato aproxima a modelagem acadêmica das demandas da prática gerencial, ao organizar parâmetros e saídas de forma rastreável e reprodutível. Em termos teóricos, a integração entre otimização multiobjetivo e simulação a eventos discretos torna explícitos e quantificáveis os *trade-offs*

inerentes ao problema, constituindo um caminho robusto e extensível para aplicações de roteamento em logística reversa.

Importa ainda assinalar as delimitações do escopo. A investigação concentrou-se em um fluxo específico de resíduos e não abarcou etapas posteriores à coleta, como triagem detalhada e reciclagem. Essas escolhas metodológicas privilegiaram a profundidade do estudo no estágio de roteamento e a consistência da integração entre otimização e simulação. Não obstante, a abordagem preserva generalidade suficiente para ser transferida a outros contextos, desde que se mantenham a estrutura multiobjetivo e a validação estocástica. Ademais, a explicitação dos pesos e a leitura das trocas entre objetivos permitem calibrar prioridades conforme diretrizes institucionais, regulatórias ou sociais, incluindo metas de redução de emissões e de cobertura de atendimento.

Por fim, o objetivo geral foi alcançado e os objetivos específicos foram cumpridos de maneira coerente e cumulativa. A revisão sistemática fundamentou o método, o algoritmo genético multiobjetivo produziu soluções relevantes, a simulação confirmou a viabilidade dinâmica e a aplicação empírica demonstrou a pertinência do framework no ambiente real. Conclui-se que a Otimização via Simulação, ao integrar a geração e a validação de soluções em um mesmo fluxo analítico, oferece uma base confiável e adaptável para decidir entre alternativas com diferentes ênfases em custo, emissões e quantidade coletada, mitigando incertezas e ampliando a probabilidade de implementação bem-sucedida.

REFERÊNCIAS

ABRAHAM, O. L.. Multi-Objective Optimization Techniques in Cloud Task Scheduling: A Systematic Literature Review. IEEE Access, v. 13, n. January, p. 12255–12291, 2025.

ADAMO, T.; DELL'ORCO, M.; PERSIANI, A. A review of recent advances in time-dependent vehicle routing. *European Journal of Operational Research*, 2024. DOI: 10.1016/j.ejor.2024.05.024.

AGRAWAL, S.; SINGH, R. K. Analyzing disposition decisions for sustainable reverse logistics: Triple Bottom Line approach. Resources, Conservation and Recycling, v. 150, n. March, p. 104448, 2019.

AGRAWAL, S.; SINGH, R. K.; MURTAZA, Q. A literature review and perspectives in reverse logisticsResources, Conservation and RecyclingElsevier, , 2015.

AHLUWALIA, P. K.; NEMA, A. K. Multi-objective reverse logistics model for integrated computer waste management. Waste Management and Research, v. 24, n. 6, p. 514–527, 2006.

AHMED, A.; MCQUAID, R. W. Entrepreneurship, management, and sustainable development. World Review of Entrepreneurship, Management and Sustainable Development, v. 1, n. 1, p. 6–30, 2005.

ALI, A. H. The Role Of Sustainability In Reverse Logistics For Returns And Recycling. Archives of Business Research, v. 6, n. 7, p. 12–33, 2018.

ALORF, A. A survey of recently developed metaheuristics and their comparative analysis. Engineering Applications of Artificial Intelligence, v. 117, n. March 2022, p. 105622, 2023.

AMARAL, J. V. S. DO. Otimização Baseada em Metamodelos: Uma Abordagem para Metamodelagem em Simulação a Eventos Discretos. Itajubá: [s.n.]. Disponível em: <https://repositorio.unifei.edu.br/jspui/handle/123456789/2288>.

AMARAL, J. V. S. DO *et al.* Metamodel-based simulation optimization: A systematic literature review. Simulation Modelling Practice and Theory, 2022a.

AMARAN, S. Simulation optimization: a review of algorithms and applications. Annals of Operations Research, v. 240, n. 1, p. 351–380, 2016.

APRIL, J. Practical introduction to simulation optimization. Winter Simulation Conference Proceedings, v. 1, n. January, p. 71–78, 2003.

ASGHARI, M.; ZOLFAGHARI, S.; AGHAY KHAZAEI, M. Green vehicle routing problem: A state-of-the-art review. *International Journal of Production Economics*, v. 235, 2021. DOI: 10.1016/j.ijpe.2021.108107.

BALCI, O. Verification, validation, and accreditation. 1998 Winter Simulation Conference. Proceedings (Cat. No.98CH36274). Anais...IEEE, 1998. Disponível em: <http://ieeexplore.ieee.org/document/744897/>

BALCI, O. A life cycle for modeling and simulation. Simulation, v. 88, n. 7, p. 870–883, 2012.

BALLOU, R. H. GERENCIAMENTO DA CADEIA DE SUPRIMENTOS/LOGÍSTICA EMPRESARIAL. Porto Alegre: [s.n.].

BANGUERA ARROYO, L. Á. The importance of Reverse Logistics and Green Logistics for Sustainability in Supply Chains. Journal of business and entrepreneurial studie, v. 7, n. 4, p. 46–72, 23 out. 2023.

BANKS, J. Handbook of Simulation: Principles, Methodology, Advances, Aplications and Practice. 1. ed. Atlanta: Georgia Institute of Technology, 1998.

BANKS, J. Discrete Event System Simulation. 5. ed. New Jersey: Pearson Prentice Hall, 2010.

BARRA MONTEVECHI, J. A. A Method Proposal for Conducting Simulation Projects in Industry 4.0: A Cyber-Physical System in an Aeronautical Industry. 2020 Winter Simulation Conference (WSC). Anais...IEEE, 14 dez. 2020. Disponível em: <https://ieeexplore.ieee.org/document/9384041/>

BETTER, M.; GLOVER, F.; LAGUNA, M. Advances in analytics: Integrating dynamic data mining with simulation optimization. IBM Journal of Research and Development, v. 51, n. 3–4, p. 477–487, 2007.

BOUZON, M.Identification and analysis of reverse logistics barriers using fuzzy Delphi method and AHP. Resources, Conservation and Recycling, v. 108, p. 182–197, 2016.

BOUZON, M.; GOVINDAN, K.; RODRIGUEZ, C. M. T. Reducing the extraction of minerals: Reverse logistics in the machinery manufacturing industry sector in Brazil using ISM approach. Resources Policy, v. 46, p. 27–36, 2015.

CARSON, Y.; MARIA, A. Simulation optimization. Proceedings of the 29th conference on Winter simulation - WSC '97. Anais...New York, New York, USA: ACM Press, 1997.

CAUCHICK MIGUEL, P. A. METODOLOGIA DE PESQUISA EM ENGENHARIA DE PRODUÇÃO E GESTÃO DE OPERAÇÕES. [s.l.] Elsevier Editora Ltda, 2018.

CHWIF, L.; MEDINA, A. C. Modelagem e Simulação de Eventos Discretos: Teoria & Aplicações. 4 ed ed. Rio de Janeiro: Elsevier, 2015.

CORLU, C. G. *et al.* Efficient hybrid simulation optimization via graph neural network metamodeling. In: *Proceedings of the 2023 Winter Simulation Conference*. Piscataway: IEEE, 2023. p. 1–12.

DIAS, P. Waste electric and electronic equipment (WEEE) management: A study on the Brazilian recycling routes. Journal of Cleaner Production, v. 174, p. 7–16, 2018.

DONG, Z. Research and Application of Back Propagation Neural Network-Based Linear Constrained Optimization Method. IEEE Access, v. 9, p. 126579–126594, 2021.

DUNKE, F.; NICKEL, S. Neural networks for the metamodeling of simulation models with online decision making. Simulation Modelling Practice and Theory, v. 99, n. August 2019, p. 102016, 2020.

ECHEGARAY, F.; HANSSTEIN, F. V. Assessing the intention-behavior gap in electronic waste recycling: the case of Brazil. Journal of Cleaner Production, v. 142, p. 180–190, 2017.

FARAHANI, R. Z. Logistics Operations and Management. [s.l.] Elsevier, 2011. v. 262

FISHMAN, G. S. Discrete-Event Simulation: modeling, programming and analysis. 1. ed. New York: Springer, 2001.

FORTI, V. The Global E-waste Monitor 2020: Quantities, Flows, and Resources. [s.l: s.n.].

FU, M. C. Optimization for simulation: Theory vs. Practice. INFORMS Journal on Computing, v. 14, n. 3, p. 192–215, ago. 2002.

GABRIEL, G. T. Good practices and deficiencies in conceptual modelling: A systematic literature review. Journal of Simulation, v. X, p. 1–17, 2020.

GABRIEL, G. T. Validação de modelos computacionais: um estudo integrando Generative Adversarial Networks e Simulação a Eventos Discretos. [s.l.] UNIFEI - UNIVERSIDADE FEDERAL DE ITAJUBÁ, 2022.

GALVÃO SCHEIDEGGER, A. P. An introductory guide for hybrid simulation modelers on the primary simulation methods in industrial engineering identified through a systematic review of the literature. Computers and Industrial Engineering, v. 124, n. July, p. 474–492, 2018a.

GARSIDE, A. K.; DEMIREL, N.; ERDOGAN, S. A recent review of solution approaches for green vehicle routing problems (2016–2023). *Sustainable Production and Consumption*, v. 44, 2024, p. 1–21. DOI: 10.1016/j.spc.2024.01.007.

GIL, A. C. Como elaborar projetos de pesquisa. 1. ed. São Paulo: Atlas, 2002a.

GIL, A. C. Métodos e técnicas de pesquisa social. 6ª ed. São Paulo: [s.n.]. v. 264

GLOVER, F. Future paths for integer programming and links to artificial intelligence. Computers and Operations Research, v. 13, n. 5, p. 533–549, 1986.

GOVINDAN, K. Analysis of third party reverse logistics provider using interpretive structural modeling. International Journal of Production Economics, v. 140, n. 1, p. 204–211, 2012.

GOVINDAN, K.; BOUZON, M. From a literature review to a multi-perspective framework for reverse logistics barriers and drivers. Journal of Cleaner Production, v. 187, p. 318–337, 2018.

GOVINDAN, K.; PAAM, P.; ABTAHI, A. R. A fuzzy multi-objective optimization model for sustainable reverse logistics network design. Ecological Indicators, v. 67, p. 753–768, 1 ago. 2016.

HARDING, J. A.; SWARNKAR, R. Modelling and optimisation of a product recovery network. International Journal of Sustainable Engineering, v. 2, n. 1, p. 40–55, 2009.

HELLENO, A. L. Integrating value stream mapping and discrete events simulation as decision making tools in operation management. International Journal of Advanced Manufacturing Technology, v. 80, n. 5–8, p. 1059–1066, 2015.

ITU; UNITAR. *The Global E-waste Monitor 2024*. Geneva/Bonn, 2024. Disponível em: https://www.itu.int/en/ITU-D/Environment/Pages/Publications/The-Global-E-waste-Monitor-2024.aspx. Acesso em: 28 ago. 2025. ITU

JÚNIOR, W. T. DE S. Proposta de redução do tempo computacional em problemas de otimização via simulação a eventos discretos integrando metaheurísticas, aprendizagem de máquina e paralelismo. [s.l.] Universidade federal de Itajubá - UNIFEI, 2019.

KARNEY, C. F. F. Algorithms for geodesics. Journal of Geodesy, v. 87, n. 1, p. 43–55, 2013.

KATOCH, S.; CHAUHAN, S. S.; KUMAR, V. A review on genetic algorithm: past, present, and future. [s.l.] Multimedia Tools and Applications, 2021. v. 80

KAYNAK, R.; KOÇOĞLU, İ.; AKGÜN, A. E. The Role of Reverse Logistics in the Concept of Logistics Centers. Procedia - Social and Behavioral Sciences, v. 109, p. 438–442, 2014.

LAM, H. Simulation optimization under input uncertainty (tutorial). In: *Proceedings of the 2024 Winter Simulation Conference*. Piscataway: IEEE, 2024.

LAW, A. M. How to build valid and credible simulation models. Proceedings of the 2009 Winter Simulation Conference M. Anais...Austin, TX: 2009.

LAW, A. M. Simulation Modeling and Analysis. Fifth Edit ed. [s.l.] McGraw-Hill, 2013.

LI, G. Review of the metaheuristic algorithms in applications: Visual analysis based on bibliometrics. Expert Systems with Applications, v. 255, n. PD, p. 124857, 2024.

LIN, J. T.; CHEN, C. M. Simulation optimization approach for hybrid flow shop scheduling problem in semiconductor back-end manufacturing. Simulation Modelling Practice and Theory, v. 51, p. 100–114, 2015.

LIU, F. *et al.* Heuristics for vehicle routing problem: A survey and recent advances. *arXiv preprint*, 2023.

MAASHI, M.; KENDALL, G.; ÖZCAN, E. Choice function based hyper-heuristics for multi-objective optimization. Applied Soft Computing, v. 28, p. 312–326, 2015.

MARTIN, C. Logistics & Supply Chain Management 4th Ed. [s.l: s.n.]. v. 48

MIGUEL, P. A. C. Metodologia de pesquisa em Engenharia de Produção e Gestão de operações. 3. ed. Rio de Janeiro: Elsevier, 2018.

MILLER, C. E.; TUCKER, A. W.; ZEMLIN, R. A. Integer programming formulation of traveling salesman problems. *Journal of the ACM*, v. 7, n. 4, p. 326–329, 1960. SOLOMON, M. M. Algorithms for the VRPTW. *Operations Research*, v. 35, n. 2, p. 254–265, 1987.

MIRANDA, R. D. C. Rafael de Carvalho Miranda. [s.l.] Universidade federal de Itajubá - UNIFEI, 2015.

MITCHELL, M. An Introduction to Genetic Algorithms. [s.l.] The MIT Press, 1999. v. 24

MONTAGNÉ, R.; SANCHEZ, D.; STORBUGT, H. VRPy: A Python package for solving a range of vehicle routing problems with a column generation approach. Journal of Open Source Software, v. 5, n. 55, p. 2408, 2020.

MONTEVECHI, J. A. B. Conceptual modeling in simulation projects by mean adapted IDEF: An application in a Brazilian tech company. Proceedings of the 2010 Winter Simulation Conference. Anais...IEEE, dez. 2010. Disponível em: <http://ieeexplore.ieee.org/document/5678908/>

MONTEVECHI, J. A. B. Identification of the main methods used in simulation projects. Proceedings of the 2015

Winter Simulation Conference. Anais...Huntington Beach, CA: IEEE, 2015.

MOURTZIS, D. Simulation in the design and operation of manufacturing systems: state of the art and new trends. International Journal of Production Research, v. 58, n. 7, p. 1927–1949, 2020.

NEGAHBAN, A.; SMITH, J. S. Simulation for manufacturing system design and operation: Literature review and analysis. Journal of Manufacturing Systems, v. 33, p. 241–261, 2014.

NIELSEN, P. *et al.* A systematic review of vehicle routing problems and models in multi-echelon distribution networks. *Journal of King Saud University – Computer and Information Sciences*, 2024. (Early view).

OLIVEIRA, J. B. DE. Gestão de Riscos Logísticos em Cadeias de Suprimentos: Otimização via Metamodelo de Simulação. [s.l.] Universidade Federal de Itajubá, 2019.

OPACIC, L.; SOWLATI, T. Applications of discrete-event simulation in the forest products sector: A review. Forest Products Journal, v. 67, n. 3–4, p. 219–229, 2017.

OSCARSSON, J.; MORIS, M. U. Documentation of discrete event simulation models for manufacturing system life cycle simulation. Proceedings of the 2002 Winter Simulation Conference. Anais...2002.

ÖZTÜRK, S. Face Validation in Large-Scale Simulation Projects. Mugla Journal of Science and Technology, v. 9, n. 1, p. 24–33, 2023.

PEREIRA, T. F. Integrating soft systems methodology to aid simulation conceptual modeling. International Transactions in Operational Research, v. 22, n. 2, p. 265–285, 2015.

POKHAREL, S.; MUTHA, A. Perspectives in reverse logistics: A reviewResources, Conservation and Recycling, fev. 2009.

PROVDANOV, C. C.; FREITAS, E. C. DE. Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico. [s.l: s.n.].

RACHIH, H.; MHADA, F. Z.; CHIHEB, R. Meta-heuristics for reverse logistics: A literature review and perspectives. Computers and Industrial Engineering, v. 127, n. November 2018, p. 45–62, 2019.

RADWAN, H. et al. Sustainable Reverse Logistic Networks Performance Assessment. JES. Journal of Engineering Sciences, v. 54, n. 1, p. 0–0, 9 set. 2025.

RAJABI MOSHTAGHI, H.; TOLOIE ESHLAGHY, A.; MOTADEL, M. R. A Comprehensive Review on Meta-Heuristic Algorithms and their Classification with Novel Approach. Journal of Applied Research on Industrial Engineering, v. 8, n. 1, p. 63–89, 2021.

RAVICHANDRAN, K. Reverse Logistics Network Design for Sustainability: A Case Study in Indian Manufacturing. *Sustainability*, v. 15, n. 4, p. 32250, 2023. DOI: https://doi.org/10.3390/su150432250

RESTREPO-FRANCO, A. M.; VALENCIA-RODRÍGUEZ, O.; TORO-OCAMPO, E. M. The vehicle routing problem as applied to residential solid waste collection operations: Systematic literature review. International Journal of Industrial Engineering Computations, v. 16, n. 1, p. 197–220, 2025.

ROBINSON, S. Discrete-event simulation: From the pioneers to the present, what next? Journal of the Operational Research Society, v. 56, n. 6, p. 619–629, 2005.

ROBINSON, S. Conceptual modelling for simulation Part II: A framework for conceptual modelling. Journal of the Operational Research Society, v. 59, n. 3, p. 291–304, 2008.

RODIČ, B. Industry 4.0 and the New Simulation Modelling Paradigm. Organizacija, v. 50, n. 3, p. 193–207, 2017.

RODRIGUES, T. P. et al. A Discrete Event Simulation Approach for Reverse Logistics of Solid Waste: A Case Study. *Machines*, v. 9, n. 2, p. 54, 2024. DOI: https://doi.org/10.3390/machines9020054

SAR, K.; GHADIMI, P. A systematic literature review of the vehicle routing problem in reverse logistics operations. *Computers & Industrial Engineering*, v. 177, 109011, 2023. DOI: 10.1016/j.cie.2023.109011.

SARGENT, R. G. An introduction to verification and validation of simulation models. Proceedings of the 2013 Winter Simulation Conference - Simulation: Making Decisions in a Complex World, WSC 2013, p. 321–327, 2013.

SARGENT, R. G. An interval statistical procedure for use in validation of simulation models. Journal of Simulation, v. 9, p. 1–6, 2014.

SARGENT, R. G.; GOLDSMAN, D. M.; YAACOUB, T. T. M. K. Roeder, P. I. Frazier, R. Szechtman, E. Zhou, T. Huschka, and S. E. Chick, eds. Proceedings of the 2016 Winter Simulation Conference. Anais...Arlington, Virginia: 2016.

SARKIS, J.; HELMS, M. M.; HERVANI, A. A. Reverse logistics and social sustainability. Corporate Social Responsibility and Environmental Management, v. 17, n. 6, p. 337–354, nov. 2010.

SAWIK, T. On the risk-averse optimization of service level in a supply chain under disruption risks. International Journal of Production Research, v. 54, n. 1, p. 98–113, 2016.

SCHEINBERG, K. Vehicle Routing. Philadelphia, PA: Society for Industrial and Applied Mathematics, 2014.

SUN, X. et al. A two-level decision support framework integrating multiobjective optimization and dynamic simulation for sustainable reverse logistics network design. *International Journal of Advanced Manufacturing Technology*, v. 130, p. 1509–1526, 2024. DOI: https://doi.org/10.1007/s00170-024-14121-6

TAKO, A. A.; ROBINSON, S. Model development in discrete-event simulation and system dynamics: An empirical study of expert modellers. European Journal of Operational Research, v. 207, n. 2, p. 784–794, 2010.

TEMITAYO OLUWADAMILOLA ADESOGA Review of reverse logistics practices and their impact on supply chain sustainability. International Journal of Science and Research Archive, v. 12, n. 2, p. 162–168, 2024.

TOMAR, V.; BANSAL, M.; SINGH, P. Metaheuristic Algorithms for Optimization: A Brief Review. Engineering Proceedings, v. 59, n. 1, p. 1–16, 2023.

TRIEBIG, C.; KLÜGL, F. Elements of a documentation framework for agent-based simulation models. Cybernetics and Systems, v. 40, n. 5, p. 441–474, 2009.

URIARTE, A. G.; NG, A. H. C.; MORIS, M. U. Supporting the lean journey with simulation and optimization in the context of Industry 4.0. Procedia Manufacturing, v. 25, p. 586–593, 2018.

VALASE, A.; KAUR, A. Returns Management and Reverse Logistics in Omnichannel Supply Chain: A Systematic Review and Future Research Agenda from a Closed Loop Supply Chain Perspective. In: [s.l.] Elsevier Ltd, 2026. v. 3p. 69–121.

VOIGT, S.; MONTOYA-TORRES, J. R.; SEPÚLVEDA-GARCÍA, D. A review and ranking of operators in adaptive large neighborhood search for vehicle routing. *European Journal of Operational Research*, 2025. DOI: 10.1016/j.ejor.2024.10.019.

WAGNER, M. REGIONAL E-WASTE MONITOR: For Latin-America, results for the 13 countries participating in project UNIDO-GEF 5554. p. 274, 2022.

WAYSI NAAMAN, D.; TAHIR AHMED, B.; IBRAHIM, M. Optimization by Nature : A Review of Genetic Algorithm Techniques. The Indonesian Journal of Computer Science, v. 14, n. 1, p. 268–284, 2025.

ZHANG, X.; LI, Z.; WANG, Y. A review of the criteria and methods of reverse logistics supplier selectionProcessesMDPI AG, , 1 jun. 2020.

ZHANG, W.; YANG, H. A study of the weighting method for a certain type of multicriteria optimization problem. Computers & Structures, v. 79, n. 31, p. 2741-2749, 2001.

APÊNDICE A - Publicações

Artigos em revistas aceitos

PINTO, W. G. M.; MONTEVECHI, J. A. B.; MIRANDA, R. DE C.; SANTOS, C. H.; PEREIRA, A. B. M. Optimisation via simulation applied to reverse logistics: a systematic literature review. **International Journal of Simulation Modelling**, 2023.

Artigos em Congressos publicados

PINTO, W. G. M.; MIRANDA, R. DE C.; SANTOS, C. H.; AMARAL, J. V. S.; PEREIRA, A. B. M. **Otimização via simulação aplicado a logística reversa: Uma revisão sistemática de literatura**. In: ENEGEP 2022 Encontro Nacional de Engenharia de Produção. **Anais**... FOZ DO IGUACU/SP – BRASIL: 2022.

GUIMARAES, L. M.; MONTEVECHI, J. A. B.; PINTO, W. G. M. **Aplicação da simulação a eventos discretos em projeto de aumento da capacidade produtiva de uma fábrica de lanternas**. In: LIV Simpósio Brasileiro de Pesquisa Operacional, 2022, Juiz de Fora. **Anais** do LIV Simpósio Brasileiro de Pesquisa Operacional, 2022.

SILVA, C. M. P.; MORAES, F. T. F.; MELLO, C. H. P.; PINTO, PINTO, W. G. M.; AMARAL, J. V. S. **Aplicação de Simulação Computacional para tomada de decisão em um Laboratório de Análises Clínicas do município de Itajubá, MG**. In: ENEGEP 2022 Encontro Nacional de Engenharia de Produção 2022. **Anais**... FOZ DO IGUACU/SP – BRASIL: 2022.

GARLETTI, B. V. G.; PINTO, W. G. M.; LEAL, FABIANO; MONTEVECHI, J. A. B. **Estudo de caso da aplicação da Simulação como ferramenta de otimização no setor de serviço.** In: ENEGEP - Encontro Nacional de Engenharia de Produção 2021, **Anais**...Online, Brasil: 2021.

GARLETTI, B.; PINTO, W. G. M. **Estudo de caso da implementação de um ambiente logístico como ferramenta para redução do ramp-up operacional**. In: Encontro Nacional de Engenharia de Produção - Enegep, 2020. **Anais**... FOZ DO IGUACU/SP – BRASIL: 2020.

ANEXO – Código do sistema logístico

```
import tkinter as tk
from tkinter import filedialog, messagebox
from tkinter import ttk
from tkcalendar import Calendar
from PIL import Image, ImageTk
import pandas as pd
import networkx as nx
import folium
from io import BytesIO
import webbrowser
from geopy.distance import geodesic  # Importar para calcular a distância
import math
import itertools
import mysql.connector
from mysql.connector import Error
import os
from datetime import datetime
import numpy as np
import random
import folium
import webbrowser
import os
from folium.plugins import AntPath
import random
import subprocess
from datetime import datetime, timedelta
import shutil



def dentro_da_janela(hora):
    """Retorna True se a hora estiver dentro da janela permitida"""
```

```
    manha = hora.time() >= datetime.strptime("08:00", "%H:%M").time() and hora.time() < datetime.strptime("12:00", "%H:%M").time()
    tarde = hora.time() >= datetime.strptime("14:00", "%H:%M").time() and hora.time() < datetime.strptime("18:00", "%H:%M").time()
    return manha or tarde


# Arquivo CSV fixo para coordenadas
COORD_CSV_PATH = "coordenadas.csv"
VEHICLE_CSV_PATH = "tab_veiculo.csv"  # Caminho para o arquivo CSV dos veículos

# Variáveis globais
matriz_distancias = None
G = None  # Grafo será global para permitir acesso entre funções

# Variáveis globais para armazenar os dados carregados, o intervalo de datas e o dataframe salvo
df = None
df_salvo = None  # Dataframe para armazenar as informações salvas
cal_inicio = None
cal_fim = None
tree = None  # Variável global para a tabela
df_veiculos = pd.read_csv(VEHICLE_CSV_PATH, sep=';')  # DataFrame dos veículos
matriz_distancia = None

# resultados do GA / roteamento
global_best_routes    = None
global_best_fitness   = None
global_totais         = None
global_params         = None

# para exportação / visualização
municipios_ids        = {}
distancias            = {}
veiculos_selecionados = {}
```

```
# Função para abrir a nova janela e fechar a janela principal
def acessar():
    root.destroy()  # Fecha a janela principal
    nova_janela()  # Abre a nova janela


# Função para carregar um arquivo CSV e exibir o calendário para o filtro
def carregar_csv():
    global df
    file_path = filedialog.askopenfilename(
        filetypes=[("CSV files", "*.csv")], title="Selecione o arquivo CSV"
    )
    if file_path:
        try:
            df = pd.read_csv(file_path, sep=';')


            # Garantir que a coluna 'DATA' esteja presente e no formato dd/mm/yyyy
            if 'DATA' in df.columns:
                df['DATA'] = pd.to_datetime(df['DATA'], format='%d/%m/%Y', errors='coerce')  # Converte a coluna de DATA para o formato datetime


                # Realizar o merge com o DataFrame de coordenadas (Latitude e Longitude)
                # Mantendo todas as colunas do DataFrame carregado (df) e adicionando Latitude e Longitude
                df = pd.merge(df, df_coord[['MUNICIPIO', 'LATITUDE', 'LONGITUDE']], on='MUNICIPIO', how='left')


                # Atualizar a tabela com os dados completos, incluindo Latitude e Longitude
                atualizar_tabela(df)  # Atualiza a tabela com os dados completos do CSV, incluindo coordenadas
            else:
                messagebox.showerror("Erro", "O arquivo CSV não contém uma coluna 'DATA' para filtrar.")
        except Exception as e:
            messagebox.showerror("Erro", f"Falha ao carregar o arquivo CSV.\nErro: {str(e)}")


# Função para mostrar o calendário, botão de filtro e tabela
def mostrar_calendario_e_tabela():
    global cal_inicio, cal_fim, tree
```

```
    # Limpar a área de exibição anterior (se houver)
    for widget in display_frame.winfo_children():
        widget.destroy()

    # Frame para os calendários ficarem lado a lado
    cal_frame = tk.Frame(display_frame, bg="dodgerblue")
    cal_frame.pack(side="left", padx=20, pady=10)

    # Calendário para data de início
    cal_inicio = Calendar(cal_frame, selectmode="day", date_pattern="dd/mm/yyyy", showweeknumbers=False)
    cal_inicio.pack(pady=5)

    # Calendário para data de fim
    cal_fim = Calendar(cal_frame, selectmode="day", date_pattern="dd/mm/yyyy", showweeknumbers=False)
    cal_fim.pack(pady=5)

    # Botão para aplicar o filtro
    btn_filtrar = tk.Button(cal_frame, text="Aplicar Filtro", command=aplicar_filtro, bg="mediumseagreen", fg="white", font=("Arial", 12))
    btn_filtrar.pack(pady=10)

    # Botão para salvar os dados filtrados
    btn_salvar = tk.Button(cal_frame, text="Salvar Dados", command=salvar_dados, bg="lightcoral", fg="white", font=("Arial", 12))
    btn_salvar.pack(pady=10)

    # Criar o frame para a tabela de dados
    table_frame = tk.Frame(display_frame, bg="white", width=400, height=200)  # Definindo altura e largura menores
    table_frame.pack(side="left", fill=tk.BOTH, expand=True, padx=20)

    # Adicionar o Treeview para exibir os dados do CSV
    tree = ttk.Treeview(table_frame, height=6)  # Definindo a altura da tabela (número de linhas visíveis)
    tree.pack(fill=tk.BOTH, expand=True)
```

```
    # Adicionar a barra de rolagem vertical à tabela
    scrollbar = ttk.Scrollbar(table_frame, orient="vertical", command=tree.yview)
    tree.configure(yscroll=scrollbar.set)
    scrollbar.pack(side="right", fill="y")

# Função para aplicar o filtro de datas e mostrar os resultados filtrados na tabela
def aplicar_filtro():
    global df, cal_inicio, cal_fim, tree

    # Verificar se o CSV foi carregado antes de aplicar o filtro
    if df is None:
        messagebox.showerror("Erro", "Por favor, carregue um arquivo CSV antes de aplicar o filtro.")
        return

    data_inicio = cal_inicio.get_date()
    data_fim = cal_fim.get_date()

    # Garantir que as datas de início e fim estejam no formato datetime
    data_inicio = pd.to_datetime(data_inicio, format='%d/%m/%Y')
    data_fim = pd.to_datetime(data_fim, format='%d/%m/%Y')

    # Verifica se o dataframe contém a coluna 'DATA' e filtra pelo intervalo
    if 'DATA' in df.columns and pd.api.types.is_datetime64_any_dtype(df['DATA']):
        # Filtrar o dataframe com base no intervalo de datas
        df_filtrado = df[(df['DATA'] >= data_inicio) & (df['DATA'] <= data_fim)]
        if not df_filtrado.empty:
            atualizar_tabela(df_filtrado)
        else:
            messagebox.showinfo("Aviso", "Nenhum dado encontrado no intervalo selecionado.")
    else:
        messagebox.showerror("Erro", "O arquivo CSV não contém uma coluna de DATA válida para filtrar.")

# Função para atualizar a tabela com base nos dados filtrados ou completos
```

```
def atualizar_tabela(df):
    global tree

    # Limpar os dados anteriores da tabela
    for row in tree.get_children():
        tree.delete(row)

    # Definir as colunas da tabela com base no dataframe
    tree["columns"] = list(df.columns)
    tree["show"] = "headings"  # Esconder a coluna vazia padrão

    # Configurar as colunas e cabeçalhos
    for col in tree["columns"]:
        tree.heading(col, text=col)  # Cabeçalho da coluna
        tree.column(col, anchor="center", width=80)  # Definir largura reduzida para as colunas

    # Inserir os novos dados na tabela
    for index, row in df.iterrows():
        tree.insert("", "end", values=list(row))

# Função para salvar os dados filtrados em um dataframe global
def salvar_dados():
    global df, df_salvo, tree

    # Verificar se há dados na tabela antes de salvar
    if tree.get_children():
        # Salvar os dados atuais do dataframe filtrado
        df_salvo = pd.DataFrame([tree.item(row)["values"] for row in tree.get_children()], columns=list(df.columns))

        print("Esse dados são do salvar \n",  df_salvo.columns)

        messagebox.showinfo("Sucesso", "Dados salvos com sucesso!")
    else:
        messagebox.showerror("Erro", "Não há dados para salvar!")
```

```
    return df_salvo

################################################                                    Excel
#################################################3
# Função para salvar os dados filtrados em um arquivo Excel automaticamente
def exportar_para_excel_automatico():
    global df_salvo

    # Verificar se há dados salvos para exportar
    if df_salvo is not None and not df_salvo.empty:
        # Criar um nome de arquivo automático com base na data e hora
        timestamp = datetime.now().strftime("%Y%m%d_%H%M%S")
        default_directory = os.path.join(os.getcwd(), "exportacoes")  # Pasta padrão para salvar
        os.makedirs(default_directory, exist_ok=True)  # Criar a pasta se não existir
        file_path = os.path.join(default_directory, f"dados_exportados_{timestamp}.xlsx")

        try:
            # Exportar o DataFrame para Excel
            df_salvo.to_excel(file_path, index=False)
            messagebox.showinfo("Sucesso", f"Dados exportados automaticamente para {file_path}!")
        except Exception as e:
            messagebox.showerror("Erro", f"Erro ao exportar os dados para Excel: {str(e)}")
    else:
        messagebox.showerror("Erro", "Não há dados salvos para exportar.")

#############################################################################################

# Função para carregar os dados salvos em uma nova janela
def carregar_dados_salvos():
    global df_salvo, df_coord

    if df_salvo is not None:  # Verificar se há dados salvos
        nova_janela_dados_salvos(df_salvo, df_coord)  # Chamar a função para criar a nova janela
        print("Ao carregar aparece Esse dados salvos \n", df_salvo.columns)
```

```
    else:
        messagebox.showerror("Erro", "Nenhum dado foi salvo.")  # Mostrar erro se não houver dados salvos

def nova_janela_dados_salvos(df_salvo,df_coord):
    nova_root = tk.Toplevel()  # Cria uma nova janela
    nova_root.title("Dados Salvos")
    nova_root.geometry("800x600")

    # Frame para a tabela dos dados salvos
    table_frame = tk.Frame(nova_root, bg="white")
    table_frame.pack(fill=tk.BOTH, expand=True, padx=20, pady=20)

    # Mesclar os dados salvos com o dataframe coordenadas (df_coord)
    try:
        df_merged = pd.merge(df_salvo,df_coord, on="MUNICIPIO", how="left")

        # Adicionar o Treeview para exibir os dados salvos
        tree_salvo = ttk.Treeview(table_frame, height=10)  # Definir a altura da tabela
        tree_salvo.pack(fill=tk.BOTH, expand=True)

        # Adicionar a barra de rolagem vertical à tabela
        scrollbar_salvo = ttk.Scrollbar(table_frame, orient="vertical", command=tree_salvo.yview)
        tree_salvo.configure(yscroll=scrollbar_salvo.set)
        scrollbar_salvo.pack(side="right", fill="y")

        # Atualizar a tabela com os dados mesclados
        tree_salvo["columns"] = list(df_merged.columns)
        tree_salvo["show"] = "headings"  # Esconder a coluna vazia padrão

        # Configurar as colunas e cabeçalhos
        for col in tree_salvo["columns"]:
            tree_salvo.heading(col, text=col)  # Cabeçalho da coluna
            tree_salvo.column(col, anchor="center", width=100)  # Definir largura das colunas
```

```
        # Inserir os dados mesclados na tabela
        for index, row in df_merged.iterrows():
            tree_salvo.insert("", "end", values=list(row))

    except Exception as e:
        messagebox.showerror("Erro", f"Erro ao mesclar os dataframes:\n{e}")

# Função para abrir a janela de geração de grafo

def gerar_grafo(df_salvo, df_coord):
    global G, matriz_distancias
    # 1) Montar o grafo
    G = nx.Graph()
    for _, row in df_salvo.iterrows():
        municipio = row["MUNICIPIO"]
        coord = df_coord[df_coord["MUNICIPIO"] == municipio]
        if coord.empty:
            messagebox.showwarning("Aviso", f"Município {municipio} sem coordenadas.")
            continue
        lat = float(str(coord["LATITUDE"].values[0]).replace(",", "."))
        lon = float(str(coord["LONGITUDE"].values[0]).replace(",", "."))
        G.add_node(municipio, pos=(lat, lon))

    # 2) Criar mapa centrado no primeiro nó
    first_lat, first_lon = next(iter(nx.get_node_attributes(G, "pos").values()))
    mapa = folium.Map(location=[first_lat, first_lon], zoom_start=6)

    # 3) Adicionar marcadores de municípios
    for node, (lat, lon) in nx.get_node_attributes(G, "pos").items():
        if node.upper() == "SOROCABA":
            # Destacar Sorocaba como ponto de partida
            folium.CircleMarker(
                [lat, lon],
                radius=10,
```

```
            color="red",
            fill=True,
            fill_color="red",
            popup=f"{node} (Partida)"
        ).add_to(mapa)
    else:
        folium.Marker(
            [lat, lon],
            popup=node,
            icon=folium.Icon(color="blue", icon="info-sign")
        ).add_to(mapa)

# 4) Gerar matriz de distâncias e traçar linhas
municipios = list(G.nodes)
matriz_distancias = pd.DataFrame(index=municipios, columns=municipios)
for o in municipios:
    for d in municipios:
        if o == d:
            matriz_distancias.loc[o, d] = 0
        else:
            lat1, lon1 = G.nodes[o]["pos"]
            lat2, lon2 = G.nodes[d]["pos"]
            dist = round(geodesic((lat1, lon1), (lat2, lon2)).kilometers, 2)
            matriz_distancias.loc[o, d] = dist
            folium.PolyLine(
                locations=[(lat1, lon1), (lat2, lon2)],
                tooltip=f"{dist} km"
            ).add_to(mapa)

# 5) Marcadores de veículos no depósito (Sorocaba)
depo = df_coord[df_coord["MUNICIPIO"].str.upper() == "SOROCABA"]
if not depo.empty:
    lat_dep = float(str(depo["LATITUDE"].values[0]).replace(",", "."))
    lon_dep = float(str(depo["LONGITUDE"].values[0]).replace(",", "."))
```

```
    for _, veic in df_veiculos.iterrows():
        nome = veic["Caminhoes"]
        popup = (
            f"<b>{nome}</b><br>"
            f"Capacidade: {veic['Cap_Peso_Cubado']} kg<br>"
            f"Custo médio: R$ {veic['Custo_medio']} /km<br>"
            f"Emissão: {veic['Emissao_CO2_(g/km)']} g/km"
        )
        folium.Marker(
            [lat_dep, lon_dep],
            popup=popup,
            icon=folium.Icon(icon="truck", prefix="fa")
        ).add_to(mapa)
else:
    messagebox.showwarning("Aviso", "Depósito (SOROCABA) não encontrado em coordenadas.")

# 6) Legenda fixa de veículos
entries = ""
for _, veic in df_veiculos.iterrows():
    nome = veic["Caminhoes"]
    cap  = veic["Cap_Peso_Cubado"]
    entries += f"<i class='fa fa-truck'></i> {nome}: {cap} kg<br>"
legend_html = f"""
 <div style="
   position: fixed;
   bottom: 50px;
   left: 50px;
   width: 200px;
   background-color: white;
   border:2px solid grey;
   z-index:9999;
   font-size:14px;
   padding: 10px;
   box-shadow: 3px 3px 6px rgba(0,0,0,0.3);
```

```
    ">
      <b>Veículos disponíveis</b><br>
      {entries}
    </div>
    """
    mapa.get_root().html.add_child(folium.Element(legend_html))

    # 7) Salvar matriz e mapa
    matriz_distancias.to_csv("matriz_distancia_municipios.csv")
    buf = BytesIO()
    mapa.save(buf, close_file=False)
    buf.seek(0)
    with open("grafo_mapa.html", "wb") as f:
        f.write(buf.read())
    webbrowser.open("grafo_mapa.html")

    messagebox.showinfo("Sucesso", "Grafo e matriz gerados com veículos e legenda no mapa.")
    return G

# Função para exibir a matriz de distância em uma nova janela
def exibir_matriz_distancia():
    global matriz_distancias, G
    if G is None:
        messagebox.showerror("Erro", "O grafo precisa ser gerado primeiro.")
        return

    if matriz_distancias is None:
        gerar_matriz_distancia()  # Calcular a matriz se ainda não foi criada

    # Criar uma nova janela para exibir a matriz de distância
    janela_matriz = tk.Toplevel()
    janela_matriz.title("Matriz de Distância entre Municípios")
    janela_matriz.geometry("800x600")
```

```
    # Frame para a tabela da matriz de distância
    frame_tabela = tk.Frame(janela_matriz)
    frame_tabela.pack(fill=tk.BOTH, expand=True)

    # Treeview para exibir a matriz de distância
    tree = ttk.Treeview(frame_tabela)
    tree["columns"] = list(matriz_distancias.columns)
    tree["show"] = "headings"

    # Configurar as colunas
    for col in matriz_distancias.columns:
        tree.heading(col, text=col)
        tree.column(col, anchor="center", width=100)

    # Inserir os dados da matriz no Treeview
    for idx, row in matriz_distancias.iterrows():
        tree.insert("", "end", text=idx, values=list(row))

    tree.pack(fill=tk.BOTH, expand=True)

    # Adicionar uma barra de rolagem
    scrollbar = ttk.Scrollbar(frame_tabela, orient="vertical", command=tree.yview)
    tree.configure(yscroll=scrollbar.set)
    scrollbar.pack(side="right", fill="y")

# Função para calcular a matriz de distância
def gerar_matriz_distancia():
    global matriz_distancias, G
    # Verificar se o grafo G foi criado
    if G is None or len(G.nodes) == 0:
        messagebox.showerror("Erro", "O grafo precisa ser gerado primeiro.")
        return

    # Criar a matriz de distância vazia
```

```
    municipios = list(G.nodes)
    matriz_distancias = pd.DataFrame(index=municipios, columns=municipios)

    # Preencher a matriz de distância
    for origem in G.nodes:
        for destino in G.nodes:
            if origem == destino:
                matriz_distancias.loc[origem, destino] = 0  # Distância de uma cidade para ela mesma é zero
            else:
                lat_orig, lon_orig = G.nodes[origem]["pos"]
                lat_dest, lon_dest = G.nodes[destino]["pos"]
                distancia = geodesic((lat_orig, lon_orig), (lat_dest, lon_dest)).kilometers
                matriz_distancias.loc[origem, destino] = round(distancia, 2)  # Armazenar a distância com 2 casas decimais

    if matriz_distancias.isnull().values.any():
        messagebox.showerror("Erro", "A matriz de distâncias não foi preenchida corretamente.")
    return

def load_vehicle_data():
    global df_veiculos
    try:
        df_veiculos = pd.read_csv(VEHICLE_CSV_PATH, sep=';')

        required_columns = ['Caminhoes', 'Cap_Peso_Cubado', 'Custo_medio', 'Emissao_CO2_(g/km)']
        for col in required_columns:
            if col not in df_veiculos.columns:
                raise KeyError(f"Coluna {col} não encontrada no arquivo de veículos.")

        print("Dados dos veículos carregados com sucesso.")
    except (FileNotFoundError, KeyError) as e:
        messagebox.showerror("Erro", f"Não foi possível carregar o arquivo de veículos ou colunas estão faltando.\n{e}")
```

```
def algoritmo_genetico(num_geracoes, tamanho_pop, num_veiculos,
                       cidades, capacidades, dist_matrix, peso_maximo,
                       combinations_pesos=None, top_n=5):
    import random
    from datetime import datetime, timedelta

    # mapeia nome→índice na matriz
    index_map = {cidade.strip().upper(): i for i, cidade in enumerate(cidades)}

    if combinations_pesos is None:
        combinations_pesos = [
            (0.3, 0.4, 0.3), (0.5, 0.3, 0.2), (0.2, 0.5, 0.3),
            (1, 0, 0), (0, 1, 0), (0, 0, 1)
        ]

    fitness_history = []

    # função que retorna só as métricas brutas
    def calcula_metricas(rota_nomes, veiculos):
        # idem ao seu fitness_multiveiculo, mas retornando (custo, emissão, coleta)
        rota_ids = [municipios_ids[n.strip().upper()] for n in rota_nomes]
        nomes_norm = [n.strip().upper() for n in rota_nomes]
        # 1) soma distâncias e atualiza hora (igual)
        distancia_total = 0.0
        hora = datetime.strptime("08:00", "%H:%M")
        for i in range(len(nomes_norm)-1):
            ia, ib = index_map[nomes_norm[i]], index_map[nomes_norm[i+1]]
            d = dist_matrix[ia][ib]
            distancia_total += d
            dur = timedelta(minutes=(d/80)*60)
            hora += dur
            # janelas… (igual)
            if hora.time() >= datetime.strptime("18:00","%H:%M").time():
```

```
            hora = hora.replace(hour=8,minute=0) + timedelta(days=1)
        elif hora.time() >= datetime.strptime("12:00","%H:%M").time():
            hora = hora.replace(hour=14,minute=0)
        elif hora.time() <  datetime.strptime("08:00","%H:%M").time():
            hora = hora.replace(hour=8,minute=0)
        hora += timedelta(minutes=90)

    # 2) partition para obter custo_total, emissao_total e coleta_total
    partes = partition_route_by_vehicle(rota_ids, rota_nomes, veiculos)
    custo_total = sum(p["custo"]     for p in partes)
    emissao_total = sum(p["emissao"] for p in partes)
    coleta_total = sum(p["collected"] for p in partes)

    return custo_total, emissao_total, coleta_total

# população inicial (igual)
pop = [[cidades[0]] + random.sample(cidades[1:], len(cidades)-1) + [cidades[0]]
       for _ in range(tamanho_pop)]

for gen in range(num_geracoes):
    w_cost, w_em, w_soc = combinations_pesos[gen % len(combinations_pesos)]

    # 1) coleta métricas brutas de toda a pop
    raw = []
    for ind in pop:
        veics = selecionar_veiculos_para_rota(ind)
        c, e, s = calcula_metricas(ind, veics)
        raw.append((ind, veics, c, e, s))

    # 2) encontra máximos para normalizar
    max_c = max(c for _,_,c,_,_ in raw) or 1.0
    max_e = max(e for _,_,_,e,_ in raw) or 1.0
    max_s = max(s for _,_,_,_,s in raw) or 1.0
```

```
    # 3) calcula fitness normalizado
    fits = []
    for ind, veics, c, e, s in raw:
        cn = c / max_c
        en = e / max_e
        sn = s / max_s
        fitness = w_cost*cn + w_em*en - w_soc*sn
        fits.append(fitness)

    # 4) salva melhor da geração
    fitness_history.append({
        "generation": gen+1,
        "weights": (w_cost, w_em, w_soc),
        "best_fitness": max(fits)
    })

    # 5) seleção, crossover e mutação (igual usando fits normalizados)
    selected = []
    for _ in pop:
        aspirantes = random.sample(list(zip(pop, fits)), 3)
        aspirantes.sort(key=lambda x: x[1], reverse=True)
        selected.append(aspirantes[0][0])

    # ... rest of OX + mutação para gerar próxima pop ...

# Avaliação final top_n (sem re-normalizar — ou com o mesmo esquema)
resultados_finais = []
for ind, veics, c, e, s in raw:  # ou na pop final, recalc raw
    avals = []
    for wc, we, ws in combinations_pesos:
        cn, en, sn = c/max_c, e/max_e, s/max_s
        avals.append({
            "pesos": (wc, we, ws),
            "fitness": wc*cn + we*en - ws*sn
```

```
            })
        resultados_finais.append({
            "rota": ind,
            "veiculos": veics,
            "avaliacoes": avals
        })

    resultados_finais.sort(key=lambda x: x["avaliacoes"][0]["fitness"], reverse=True)
    return resultados_finais[:top_n], fitness_history




def selecionar_veiculos_para_rota(rota_nomes):
    """
    Retorna um conjunto de caminhões cuja soma de capacidades >= demanda da rota.
    Primeiro tenta todas as combinações mínimas; se não encontrar, faz um fallback greedy.
    """
    # 1) calcula a demanda total (ignora o depósito, que é rota_nomes[0])
    demanda = sum(
        df_salvo[df_salvo["MUNICIPIO"] == muni]["PESO_COLETA"].values[0]
        for muni in rota_nomes
        if muni != rota_nomes[0]
    )

    # 2) lista de (nome, capacidade)
    veics = list(df_veiculos[["Caminhoes", "Cap_Peso_Cubado"]].to_records(index=False))
    # ordena por capacidade decrescente
    veics.sort(key=lambda x: x[1], reverse=True)

    # 3) tente encontrar combinações mínimas de tamanho crescente
    combos = []
    for k in range(1, len(veics)+1):
        for subset in itertools.combinations(veics, k):
```

```
            if sum(v[1] for v in subset) >= demanda:
                combos.append(subset)
        if combos:
            break  # já achou combinações mínimas

    if combos:
        # escolhe aleatoriamente uma das combinações mínimas
        escolhida = random.choice(combos)
        return [v[0] for v in escolhida]
    else:
        # Fallback greedy: vai somando caminhões até cobrir a demanda
        soma = 0
        escolhidos = []
        for nome, cap in veics:
            escolhidos.append(nome)
            soma += cap
            if soma >= demanda:
                messagebox.showwarning(
                    "Seleção de Veículos",
                    f"Nenhuma combinação exata encontrada; usando fallback greedy com {len(escolhidos)} caminhões."
                )
                break
        return escolhidos


def ga_vrp(num_geracoes, tamanho_pop, num_veiculos,
           capacidades, distancias_dict, peso_maximo,
           combinations_pesos=None, top_n=5):
    # 1) monta matriz e cidades
    df_dist = pd.DataFrame(distancias_dict).astype(float)
    cidades = list(df_dist.index)
    matriz = df_dist.loc[cidades, cidades].values

    # 2) chama uma só vez o GA pedindo top_n
    resultados_finais, fitness_history  = algoritmo_genetico(
```

```
    num_geracoes, tamanho_pop, num_veiculos,
    cidades, capacidades, matriz, peso_maximo,combinations_pesos=combinations_pesos, top_n=top_n)

    # 3) converte e seleciona veículos
    id_map = {r["MUNICIPIO"].upper(): r["ID_MUNICIPIO"]
              for _,r in df_salvo.iterrows()}



    melhores_rotas_nomes = resultados_finais

    cenarios = []
    for r in melhores_rotas_nomes:
        rota_ids = []
        for n in r["rota"]:
            if isinstance(n, str):
                rota_ids.append(id_map[n.upper()])
            elif isinstance(n, dict) and "MUNICIPIO" in n:
                rota_ids.append(id_map[n["MUNICIPIO"].upper()])
            else:
                raise ValueError(f"Formato inesperado em r['rota']: {n}")
        cenarios.append({
            "route": rota_ids,
            "vehicles": r["veiculos"],
            "avaliacoes": r["avaliacoes"]  # <-- agora incluído!
        })

    return cenarios

def mostrar_mapa_cenarios():
    import folium
    from folium.plugins import AntPath

    # Centro do mapa (SOROCABA)
    depo = df_coord[df_coord["MUNICIPIO"].str.upper() == "SOROCABA"].iloc[0]
```

```
centro = (
    float(str(depo["LATITUDE"]).replace(",", ".")),
    float(str(depo["LONGITUDE"]).replace(",", "."))
)
mapa = folium.Map(location=centro, zoom_start=7)
cores = ["red", "blue", "green", "purple", "orange", "darkred"]

for i, sol in enumerate(cenarios_ga):
    coords = []
    nomes = []
    for idm in sol["route"]:
        muni = df_salvo[df_salvo["ID_MUNICIPIO"] == idm]["MUNICIPIO"].iloc[0]
        coord = df_coord[df_coord["MUNICIPIO"] == muni].iloc[0]
        lat = float(str(coord["LATITUDE"]).replace(",", "."))
        lon = float(str(coord["LONGITUDE"]).replace(",", "."))
        coords.append((lat, lon))
        nomes.append(muni)

    # Rota em movimento (animada)
    AntPath(
        coords,
        color=cores[i % len(cores)],
        weight=5,
        delay=800,
        dash_array=[10, 20],
        pulse_color=cores[i % len(cores)],
    ).add_to(mapa)

    # Marcadores coloridos
    for j, (lat, lon) in enumerate(coords):
        nome = nomes[j]
        cor = "red" if j == 0 or j == len(coords) - 1 else "blue"
        folium.Marker(
            location=[lat, lon],
```

```
            popup=nome,
            icon=folium.Icon(color=cor, icon="info-sign")
        ).add_to(mapa)

# Legenda com os veículos
entries = ""
for _, veic in df_veiculos.iterrows():
    nome = veic["Caminhoes"]
    cap = veic["Cap_Peso_Cubado"]
    entries += f"<i class='fa fa-truck'></i> {nome}: {cap} kg<br>"

legend_html = f"""
 <div style="
   position: fixed;
   bottom: 50px;
   left: 50px;
   width: 220px;
   background-color: white;
   border:2px solid grey;
   z-index:9999;
   font-size:14px;
   padding: 10px;
   box-shadow: 3px 3px 6px rgba(0,0,0,0.3);
 ">
   <b>Veículos disponíveis</b><br>
   {entries}
 </div>
"""
mapa.get_root().html.add_child(folium.Element(legend_html))

# Exporta e abre
mapa.save("cenarios_ga_map.html")
webbrowser.open("cenarios_ga_map.html")
```

```
def rotear():
    global cenarios_ga, municipios_ids
    # guards
    if matriz_distancias is None or df_salvo is None:
        messagebox.showerror("Erro","Gere grafo e salve intervalo antes")
        return

    # --- INICIALIZA MUNICIPIOS_IDS AQUI ---
    municipios_ids = {
        row["MUNICIPIO"].strip().upper(): row["ID_MUNICIPIO"]
        for _, row in df_salvo.iterrows()
    }

    # parâmetros (pode colocar inputs na GUI depois)
    N = 5  # top-N
    params = {
        "num_geracoes": 5,
        "tamanho_pop": 10,
        "num_veiculos": len(df_veiculos),
        "capacidades": df_veiculos["Cap_Peso_Cubado"].tolist(),
        "distancias_dict": matriz_distancias.to_dict(),
        "peso_maximo": df_salvo["PESO_COLETA"].sum(),
        "top_n": N
    }
    cenarios_ga = ga_vrp(**params)
    mostrar_tabela_ga()
    mostrar_mapa_cenarios()

def mostrar_avaliacoes_por_pesos():
    if not cenarios_ga:
        messagebox.showerror("Erro", "Execute o GA antes de visualizar as avaliações.")
        return

    janela = tk.Toplevel()
```

```
janela.title("Avaliação por Pesos - Multiobjetivo")
janela.geometry("900x500")

cols = ("Cenário", "Pesos (C,E,S)", "Fitness")
tree = ttk.Treeview(janela, columns=cols, show="headings", height=20)
for c in cols:
    tree.heading(c, text=c)
    tree.column(c, anchor="center", width=200)
tree.pack(fill=tk.BOTH, expand=True, padx=10, pady=10)

dados_exportar = []

for i, cenario in enumerate(cenarios_ga, start=1):
    avaliacoes = cenario.get("avaliacoes", [])
    for av in avaliacoes:
        pesos = av["pesos"]
        fitness = av["fitness"]
        peso_str = f"({pesos[0]:.2f}, {pesos[1]:.2f}, {pesos[2]:.2f})"
        tree.insert("", "end", values=(i, peso_str, f"{fitness:.4f}"))

        dados_exportar.append({
            "Cenario": i,
            "Peso_Custo": pesos[0],
            "Peso_Emissao": pesos[1],
            "Peso_Coleta": pesos[2],
            "Fitness": fitness
        })

# Scrollbar
scroll = ttk.Scrollbar(janela, orient="vertical", command=tree.yview)
tree.configure(yscrollcommand=scroll.set)
scroll.pack(side="right", fill="y")

# Botão para exportar
```

```
    def exportar_dados():
        df_export = pd.DataFrame(dados_exportar)
        export_dir = os.path.join(os.getcwd(), "exportacoes")
        os.makedirs(export_dir, exist_ok=True)
        path = os.path.join(export_dir, "avaliacoes_por_pesos.xlsx")
        try:
            df_export.to_excel(path, index=False)
            messagebox.showinfo("Exportado", f"Arquivo gerado com sucesso:\n{path}")
        except Exception as e:
            messagebox.showerror("Erro", f"Erro ao exportar:\n{e}")

    botao_exportar = tk.Button(janela, text="Exportar para Excel", command=exportar_dados,
                               bg="dodgerblue", fg="white", font=("Arial", 12, "bold"))
    botao_exportar.pack(pady=10)

def partition_route_by_vehicle(rota_ids, rota_nomes, veics):
    """
    Divide a rota (excluindo depósito final) entre os veículos,
    sem jamais ultrapassar a capacidade de cada um. Calcula custo e emissão.
    """
    detalhes = []
    seq_ids   = rota_ids[1:-1]
    seq_nomes = rota_nomes[1:-1]
    idx = 0
    total = len(seq_ids)

    for v in veics:
        veiculo_row = df_veiculos[df_veiculos["Caminhoes"].str.strip().str.upper() == v.strip().upper()]
        if veiculo_row.empty:
            print(f"[ERRO] Veículo '{v}' não encontrado em df_veiculos.")
            continue

        cap = float(veiculo_row["Cap_Peso_Cubado"].values[0])
        custo_km = float(veiculo_row["Custo_medio"].values[0])
```

```
emissao_km = float(veiculo_row["Emissao_CO2_(g/km)"].values[0])

carga = 0.0
sub_ids   = [rota_ids[0]]
sub_nomes = [rota_nomes[0]]

while idx < total:
    pid, pnome = seq_ids[idx], seq_nomes[idx]
    peso = float(df_salvo.loc[df_salvo["MUNICIPIO"]==pnome, "PESO_COLETA"].iloc[0])
    if carga + peso <= cap:
        sub_ids.append(pid)
        sub_nomes.append(pnome)
        carga += peso
        idx += 1
    else:
        break

sub_ids.append(rota_ids[0])
sub_nomes.append(rota_nomes[0])

# Calcular distância, custo e emissão da sub-rota
dist = 0
for i in range(len(sub_nomes)-1):
    a = sub_nomes[i]
    b = sub_nomes[i+1]
    if a in matriz_distancias and b in matriz_distancias[a]:
        dist += float(matriz_distancias[a][b])
    else:
        print(f"[ERRO] Distância ausente entre {a} e {b}")
        return []

custo_total = dist * custo_km
emissao_total = dist * emissao_km
```

```
            pesos_por_cidade = []
            for cid in sub_nomes[1:-1]:
                peso = df_salvo.loc[df_salvo["MUNICIPIO"] == cid, "PESO_COLETA"].iloc[0]
                pesos_por_cidade.append(peso)

            detalhes.append({
                "vehicle": v,
                "route_ids": sub_ids,
                "route_nomes": sub_nomes,
                "collected": carga,
                "custo": custo_total,
                "emissao": emissao_total,
                "Coletas_por_Cidades_kg": pesos_por_cidade
            })

            if idx >= total:
                break

        if idx < total:
            restante = total - idx
            messagebox.showwarning(
                "Atenção",
                f"{restante} cidade(s) não alocada(s) — capacidade insuficiente nos veículos selecionados."
            )

        return detalhes

    def mostrar_detalhes_cenario(c_index):
        """
        Abre uma janela listando, para o cenário c_index:
        - Cada veículo
        - Sua rota específica
        - A coleta feita
        """
```

```
    sol = cenarios_ga[c_index]
    # converte IDs de volta em nomes para particionamento
    id2mun = {
        row["ID_MUNICIPIO"]: row["MUNICIPIO"]
        for _,row in df_salvo.iterrows()
    }
    rota_nomes = [ id2mun[i] for i in sol["route"] ]
    detalhes = partition_route_by_vehicle(sol["route"], rota_nomes, sol["vehicles"])

    win = tk.Toplevel()
    win.title(f"Cenário {c_index+1} — Detalhes")
    cols = ("Veículo", "Rota", "Coleta (kg)", "Coletas por Cidades")
    tree = ttk.Treeview(win, columns=cols, show="headings", height=len(detalhes))
    for c in cols:
        tree.heading(c, text=c)
        tree.column(c, anchor="center", width=200)
    tree.pack(fill=tk.BOTH, expand=True, padx=10, pady=10)

    for d in detalhes:
        rota_str = "[{}]".format(" - ".join(map(str, d["route_ids"])))
        tree.insert("", "end",
                    values=(d["vehicle"],"[{}]".format(" - ".join(map(str, d["route_ids"]))),
                            f"{d['collected']:.1f}",
                             ", ".join(map(str, d["Coletas_por_Cidades_kg"])),
                             rota_str, f"{d['collected']:.1f}"))

# 3) Função que monta a janela e o Treeview “Cenários | Rotas | Veículos”
def mostrar_tabela_ga():
    janela = tk.Toplevel()
    janela.title("Resultados do GA")
    janela.geometry("800x400")

    # Colunas: adiciona “Coleta (kg)”
    cols = ("Cenário", "Rota", "Veículos", "Coleta (kg)")
```

```
tree = ttk.Treeview(janela, columns=cols, show="headings", height=10)
for c in cols:
    tree.heading(c, text=c)
    tree.column(c, anchor="center", width=180)
tree.pack(fill=tk.BOTH, expand=True, padx=10, pady=10)

# Preenche cada cenário
for i, sol in enumerate(cenarios_ga, start=1):
    # Rota e veículos como antes
    rota_str = "[{}]".format(" - ".join(map(str, sol["route"])))
    veic_str = "[{}]".format(" - ".join(sol["vehicles"]))
    # soma total de coleta da rota
    total = sum(
        df_salvo.loc[df_salvo["ID_MUNICIPIO"] == idm, "PESO_COLETA"].iloc[0]
        for idm in sol["route"] if idm != sol["route"][0]
    )
    tree.insert("", "end",
                values=(i, rota_str, veic_str, f"{total:.1f}"))

# Scrollbar vertical
scroll = ttk.Scrollbar(janela, orient="vertical", command=tree.yview)
tree.configure(yscrollcommand=scroll.set)
scroll.pack(side="right", fill="y")

# Quando clicar duas vezes num cenário, abre o detalhe
def on_double_click(event):
    sel = tree.selection()
    if not sel: return
    idx = int(tree.item(sel,"values")[0]) - 1  # índice em cenarios_ga
    mostrar_detalhes_cenario(idx)

tree.bind("<Double-1>", on_double_click)
```

```
def visualizar_para_simulacao():
    if not cenarios_ga:
        messagebox.showerror("Erro", "Execute o GA antes de visualizar os dados.")
        return

    # Janela de resumo
    win = tk.Toplevel()
    win.title("Detalhes para Simulação - FlexSim")
    win.geometry("900x400")

    cols = ("Cenário","Distância (km)","Custo (R$)","Emissão (g CO2)","Coleta (kg)","Veículos")
    tree = ttk.Treeview(win, columns=cols, show="headings", height=10)
    for c in cols:
        tree.heading(c, text=c)
        tree.column(c, anchor="center", width=140)
    tree.pack(fill=tk.BOTH, expand=True, padx=10, pady=10)

    # Preenche cada cenário
    for i, sol in enumerate(cenarios_ga, start=1):
        rota_ids = sol["route"]
        veics    = sol["vehicles"]

        # Distância total
        dist_total = 0
        for a,b in zip(rota_ids, rota_ids[1:]):
            mun_a = df_salvo.loc[df_salvo["ID_MUNICIPIO"]==a, "MUNICIPIO"].iloc[0]
            mun_b = df_salvo.loc[df_salvo["ID_MUNICIPIO"]==b, "MUNICIPIO"].iloc[0]
            dist_total += matriz_distancias.loc[mun_a, mun_b]

        # Coleta total
        coleta_total = sum(
            df_salvo.loc[df_salvo["ID_MUNICIPIO"]==a, "PESO_COLETA"].iloc[0]
            for a in rota_ids if a!=rota_ids[0]
        )
```

```
    # Custo e emissão totais
    custo_total = 0
    emissao_total = 0
    for a,b in zip(rota_ids, rota_ids[1:]):
        mun_a = df_salvo.loc[df_salvo["ID_MUNICIPIO"]==a, "MUNICIPIO"].iloc[0]
        mun_b = df_salvo.loc[df_salvo["ID_MUNICIPIO"]==b, "MUNICIPIO"].iloc[0]
        d = matriz_distancias.loc[mun_a, mun_b]
        # supondo custo_medio e emissao em df_veiculos para o primeiro veículo
        vm = df_veiculos.set_index("Caminhoes").loc[veics[0]]
        custo_total  += d * float(vm["Custo_medio"])
        emissao_total+= d * float(vm["Emissao_CO2_(g/km)"])

    tree.insert("", "end", iid=i-1,
                values=(
                  i,
                  f"{dist_total:.1f}",
                  f"{custo_total:.1f}",
                  f"{emissao_total:.1f}",
                  f"{coleta_total:.1f}",
                  ", ".join(veics)
                ))


# Scrollbar
scroll = ttk.Scrollbar(win, orient="vertical", command=tree.yview)
tree.configure(yscrollcommand=scroll.set)
scroll.pack(side="right", fill="y")

# Duplo-clique abre detalhes por veículo
def on_dbl(event):
    sel = tree.selection()
    if not sel: return
    idx = int(sel[0])
```

```
    mostrar_detalhes_cenario(idx)  # já existente

tree.bind("<Double-1>", on_dbl)

 # EXPORTAÇÃO AUTOMÁTICA DOS DADOS VISUALIZADOS
try:
    dados_export = []
    for i, sol in enumerate(cenarios_ga, start=1):
        rota_ids = sol["route"]
        veics = sol["vehicles"]

        dist_total = 0
        for a, b in zip(rota_ids, rota_ids[1:]):
            mun_a = df_salvo.loc[df_salvo["ID_MUNICIPIO"] == a, "MUNICIPIO"].iloc[0]
            mun_b = df_salvo.loc[df_salvo["ID_MUNICIPIO"] == b, "MUNICIPIO"].iloc[0]
            dist_total += matriz_distancias.loc[mun_a, mun_b]

        coleta_total = sum(
            df_salvo.loc[df_salvo["ID_MUNICIPIO"] == a, "PESO_COLETA"].iloc[0]
            for a in rota_ids if a != rota_ids[0]
        )

        custo_total = 0
        emissao_total = 0
        for a, b in zip(rota_ids, rota_ids[1:]):
            mun_a = df_salvo.loc[df_salvo["ID_MUNICIPIO"] == a, "MUNICIPIO"].iloc[0]
            mun_b = df_salvo.loc[df_salvo["ID_MUNICIPIO"] == b, "MUNICIPIO"].iloc[0]
            d = matriz_distancias.loc[mun_a, mun_b]
            vm = df_veiculos.set_index("Caminhoes").loc[veics[0]]
            custo_total += d * float(vm["Custo_medio"])
            emissao_total += d * float(vm["Emissao_CO2_(g/km)"])

        dados_export.append({
            "Cenario": i,
```

```
            "Distancia_km": round(dist_total, 2),
            "Custo_R$": round(custo_total, 2),
            "Emissao_CO2_g": round(emissao_total, 2),
            "Coleta_kg": round(coleta_total, 2),
            "Veiculos": ", ".join(veics)
        })

    df_export = pd.DataFrame(dados_export)

    # Caminho de exportação
    export_dir = os.path.join(os.getcwd(), "exportacoes")
    os.makedirs(export_dir, exist_ok=True)
    file_path = os.path.join(export_dir, "dados_visualizacao_simulacao.csv")

    df_export.to_csv(file_path, sep=';', index=False, encoding='utf-8')
    print(f"[Completo] Tabela de visualização exportada para: {file_path}")

  except Exception as e:
    print("[Erro ao exportar tabela de visualização]:", e)




def exportando_para_flexsim_via_excel():
  """
  Exporta:
   - Excel com abas "Sumario" e "Detalhes" (sem coluna Pesos)
   - CSVs individuais: Cenários, Detalhes, Matriz_Distancia, Cidades_IdCidades, IntervaloFiltrado
   - Finalmente, abre o modelo no FlexSim
  """
  global cenarios_ga, df_salvo, matriz_distancias, df_coord
  import os, subprocess, shutil, pandas as pd

  # 0) Verifica se há cenários
```

```
if not cenarios_ga:
    messagebox.showerror("Erro", "Nenhum cenário gerado para exportar.")
    return

# 1) Cria diretórios
default_dir = os.path.join(os.getcwd(), "exportacoes")
os.makedirs(default_dir, exist_ok=True)
csv_dir = os.path.join(default_dir, "csvs_por_aba")
os.makedirs(csv_dir, exist_ok=True)

excel_path = os.path.join(default_dir, "cenarios_flexsim.xlsx")

# --- 2) Monta o SUMÁRIO de cenários (sem Pesos) ---
rows_sum = []
for idx, sol in enumerate(cenarios_ga, start=1):
    rota_str = "-".join(map(str, sol["route"]))
    rows_sum.append({
        "Cenario": idx,
        "Rota (IDs)": rota_str,
        "Veiculos": ", ".join(v.upper() for v in sol["vehicles"])
    })
df_sum = pd.DataFrame(rows_sum)

# --- 3) Monta os DETALHES (sem Pesos) ---
id2mun = {row["ID_MUNICIPIO"]: row["MUNICIPIO"] for _, row in df_salvo.iterrows()}

detalhe_rows = []
for idx, sol in enumerate(cenarios_ga, start=1):
    rota_ids   = sol["route"]
    rota_nomes = [id2mun.get(i, "") for i in rota_ids]

    # para cada combinação de pesos, mas não armazenamos o peso na saída
    for av in sol["avaliacoes"]:
        for d in partition_route_by_vehicle(rota_ids, rota_nomes, sol["vehicles"]):
```

```
        raw_rota = "-".join(map(str, d["route_ids"]))  # ex: "1-9-4-6-1"
        detalhe_rows.append({
            "Cenario":            idx,
            "Veiculo":            d["vehicle"].upper(),
            "Rota (IDs)":         raw_rota,
            "Coleta (kg)":        d["collected"],
            "Coletas_por_Cidades": ", ".join(map(str, d["Coletas_por_Cidades_kg"]))
        })
df_det = pd.DataFrame(detalhe_rows)

# --- 4) Exporta para Excel com xlsxwriter e formata "Rota (IDs)" como texto ---
try:
    with pd.ExcelWriter(excel_path, engine="xlsxwriter") as writer:
        df_sum.to_excel(writer, sheet_name="Sumario", index=False)
        df_det.to_excel(writer, sheet_name="Detalhes", index=False)

        workbook  = writer.book
        worksheet = writer.sheets["Detalhes"]

        # cria formato texto para prevenir conversão no Excel
        text_fmt = workbook.add_format({'num_format': '@'})

        # localização zero-based da coluna "Rota (IDs)" no df_det
        col_idx = df_det.columns.get_loc("Rota (IDs)")

        # aplica formato texto à coluna inteira
        worksheet.set_column(col_idx, col_idx, None, text_fmt)

    # exporta também como CSV
    csv_sum_path = os.path.join(default_dir,   "cenarios_flexsim_sumario.csv")
    csv_det_path = os.path.join(default_dir,   "cenarios_flexsim_detalhes.csv")

    df_sum.to_csv(csv_sum_path, sep=';', index=False, encoding='utf-8')
    df_det.to_csv(csv_det_path, sep=';', index=False, encoding='utf-8')
```

```
    # --- 5) Cria cópia do CSV de detalhes sem alterações de formato ---
    copy_csv = os.path.join(default_dir, "cenarios_flexsim_detalhes_copy.csv")
    shutil.copyfile(csv_det_path, copy_csv)

    messagebox.showinfo(
        "Sucesso",
        f"Arquivos exportados com sucesso:\n\n"
        f"{excel_path}\n{csv_sum_path}\n{csv_det_path}\n{copy_csv}"
    )
except Exception as e:
    messagebox.showerror("Erro", f"Falha ao exportar arquivos:\n{e}")
    return

    # 5) Exporta CSVs individuais
try:
    # Prepara versões CSV para impedir conversão indesejada das rotas
    df_sum_csv = df_sum.copy()
    df_det_csv = df_det.copy()
    df_sum_csv["Rota (IDs)"] = df_sum_csv["Rota (IDs)"].apply(lambda s: f"'{s}")
    df_det_csv["Rota (IDs)"] = df_det_csv["Rota (IDs)"].apply(lambda s: f"'{s}")

    # Cenários e Detalhes
    df_sum_csv.to_csv(os.path.join(csv_dir, "Cenarios.csv"), index=False, sep=';', encoding='utf-8')
    df_det_csv.to_csv(os.path.join(csv_dir, "Detalhes.csv"), index=False, sep=';', encoding='utf-8')

    # Matriz de Distância
    df_matriz = matriz_distancias.reset_index().rename(columns={"index": "Cidade"})
    df_matriz.to_csv(
        os.path.join(csv_dir, "Matriz_Distancia.csv"),
        index=False, sep=';', encoding='utf-8', decimal=',', float_format='%.6g'
    )

    # Cidades com IDs, latitude e longitude
```

```
    df_cidades = pd.DataFrame({"MUNICIPIO": matriz_distancias.index})
    id_map = {r["MUNICIPIO"]: r["ID_MUNICIPIO"] for _, r in df_salvo.iterrows()}
    df_cidades["ID_MUNICIPIO"] = df_cidades["MUNICIPIO"].map(id_map)
    df_cidades = df_cidades.merge(
        df_coord[['MUNICIPIO', 'LATITUDE', 'LONGITUDE']],
        on='MUNICIPIO', how='left'
    )
    df_cidades.to_csv(
        os.path.join(csv_dir, "Cidades_IdCidades.csv"),
        index=False, sep=';', encoding='utf-8', decimal=',', float_format='%.6g'
    )

    # Intervalo filtrado original
    df_salvo.to_csv(
        os.path.join(csv_dir, "IntervaloFiltrado.csv"),
        index=False, sep=';', encoding='utf-8'
    )

    messagebox.showinfo("Sucesso", f"CSVs exportados em: {csv_dir}")
except Exception as e:
    messagebox.showerror("Erro", f"Falha ao exportar CSVs:{e}")
    return
"""
# 6) Abre FlexSim com o modelo
prog = r"C:/Program Files (x86)/FlexSim Version Selector/FlexSimVersionSelector.exe"
fsm = r"C:/Users/yelse/OneDrive/Área de Trabalho/Rel_3_10/Tese_Final.fsm"
if not os.path.isfile(prog):
    messagebox.showerror("Erro", f"Executável não encontrado:{prog}")
    return
if not os.path.isfile(fsm):
    messagebox.showerror("Erro", f"Modelo não encontrado:{fsm}")
    return
try:
    subprocess.Popen([prog, fsm])
```

```
    except Exception as e:
        messagebox.showerror("Erro ao abrir FlexSim", str(e))
"""



def otimizar_via_simulacao():
    """
    Loop de simulação para cada cenário gerado pelo GA:
    1) Gera Rotas.csv com colunas [Seq, Veiculo, Rota (IDs)]
    2) Chama o FlexSim uma única vez
    3) Lê o CSV de resultados com {Custo, Emissao, Coleta}
    4) Consolida tudo em um Excel
    """
    import os, subprocess
    import pandas as pd
    from tkinter import messagebox
    global cenarios_ga, df_salvo, partition_route_by_vehicle

    if not cenarios_ga:
        messagebox.showerror("Erro", "Execute o GA antes de rodar a simulação.")
        return

    program = r"C:/Program Files (x86)/FlexSim Version Selector/FlexSimVersionSelector.exe"
    model   = r"C:/Users/yelse/OneDrive/Área de Trabalho/Rel_3_10/Tese_Final_Ajuste_Python_new.fsm"

    base_dir = os.path.join(os.getcwd(), "exportacoes", "csvs_por_aba")
    os.makedirs(base_dir, exist_ok=True)
    result_file = "Resultados_Cenario.csv"
    output_xlsx = os.path.join(os.getcwd(), "exportacoes", "consolidado_simulacao.xlsx")

    all_results = []
    id2mun = {r["ID_MUNICIPIO"]: r["MUNICIPIO"] for _, r in df_salvo.iterrows()}

    # Gera Rotas.csv apenas uma vez (último cenário sobrescreve o arquivo, se necessário)
```

```
    for i, sol in enumerate(cenarios_ga, start=1):
        rows = []
        ids = sol["route"]
        nomes = [id2mun.get(j, "") for j in ids]
        parts = partition_route_by_vehicle(ids, nomes, sol["vehicles"])
        for seq, part in enumerate(parts, start=1):
            rows.append({
                "Seq": seq,
                "Veiculo": part["vehicle"].upper(),
                "Rota (IDs)": "-".join(map(str, part["route_ids"])),
                "Coletas_por_Cidades": ", ".join(map(str, part["Coletas_por_Cidades_kg"]))
            })
        df_r = pd.DataFrame(rows)
        path_r = os.path.join(base_dir, "Rotas.csv")
        df_r.to_csv(path_r, index=False, sep=';', encoding='utf-8')

    try:
        subprocess.Popen([program, model])
    except Exception as e:
        messagebox.showerror("Erro ao chamar FlexSim", str(e))
        return




# Adicionar a opção "Ver Matriz de Distância" no menu de "Análise"
def nova_janela():
    global display_frame, matriz_distancias
    matriz_distancias = None  # Variável global para armazenar a matriz de distância

    nova_root = tk.Tk()
    nova_root.title("Nova Janela")
    nova_root.geometry("1920x1080")
    nova_root.configure(bg="dodgerblue")
```

```
    # Criando o menu na nova janela
    menu_bar = tk.Menu(nova_root, bg="LightGrey", fg="white", tearoff=0)
    nova_root.config(menu=menu_bar)

    # Criando o menu "Arquivo"
    arquivo_menu = tk.Menu(menu_bar, tearoff=0, bg="LightGrey", fg="white")
    menu_bar.add_cascade(label="Arquivo", menu=arquivo_menu)
    arquivo_menu.add_command(label="Novo", command=carregar_csv)
    arquivo_menu.add_separator()
    arquivo_menu.add_command(label="Carregar Dados Salvos", command=carregar_dados_salvos)
    arquivo_menu.add_command(label="Exportar Excel", command=exportar_para_excel_automatico)
    arquivo_menu.add_command(label="Sair", command=nova_root.quit)

    # Criando o menu "Análise"
    analise_menu = tk.Menu(menu_bar, tearoff=0, bg="LightGrey", fg="white")
    menu_bar.add_cascade(label="Análise", menu=analise_menu)
    analise_menu.add_command(label="Gerar Grafo", command=lambda: gerar_grafo(df_salvo, df_coord))
    analise_menu.add_command(label="Ver Matriz de Distância", command=exibir_matriz_distancia)  # Opção para ver a matriz de distância

    # 1) Dentro de nova_janela(), logo depois de criar os outros menus:
    roteamento_menu = tk.Menu(menu_bar, tearoff=0, bg="LightGrey", fg="white")
    menu_bar.add_cascade(label="Roteamento", menu=roteamento_menu)
    roteamento_menu.add_command(label="Executar GA", command=rotear)

    # Criando o menu "Flexsim"
    analise_menu = tk.Menu(menu_bar, tearoff=0, bg="LightGrey", fg="white")
    menu_bar.add_cascade(label="Flexsim", menu=analise_menu)
    analise_menu.add_command(label="Visualizar dados", command=visualizar_para_simulacao)
    analise_menu.add_command(label="Exportar", command=exportando_para_flexsim_via_excel)
    analise_menu.add_command(label="rodar no flexsim", command=otimizar_via_simulacao)

    roteamento_menu.add_command(label="Ver Avaliações por Pesos", command=mostrar_avaliacoes_por_pesos)
```

```
    # Criando o menu "Ajuda"
    ajuda_menu = tk.Menu(menu_bar, tearoff=0, bg="LightGrey", fg="white")
    menu_bar.add_cascade(label="Ajuda", menu=ajuda_menu)
    ajuda_menu.add_command(label="Sobre", command=lambda: print("Informações sobre o programa"))

    # Texto de boas-vindas na nova janela
    label = tk.Label(nova_root, text="Selecione um arquivo CSV", font=("Arial", 20), bg="dodgerblue", fg="white")
    label.pack(pady=10)

    # Frame para exibir o conteúdo do CSV e o calendário
    display_frame = tk.Frame(nova_root, bg="dodgerblue")
    display_frame.pack(fill=tk.BOTH, expand=True)

    mostrar_calendario_e_tabela()

    nova_root.mainloop()

# Configurando a janela principal
root = tk.Tk()
root.title("Tela Inicial")
root.geometry("1920x1080")
root.configure(bg="dodgerblue")

try:
    df_coord = pd.read_csv(COORD_CSV_PATH, sep=';')
except FileNotFoundError:
    messagebox.showerror("Erro", f"Arquivo {COORD_CSV_PATH} não encontrado.")
    exit()

# Criando um frame para centralizar os elementos
frame = tk.Frame(root, bg="dodgerblue")
frame.place(relx=0.5, rely=0.5, anchor="center")
```

```
# Carregando e redimensionando a logo para 400x400
image = Image.open("unifei-1.png")
image = image.resize((400, 400), Image.ANTIALIAS)
logo = ImageTk.PhotoImage(image)

# Centralizando a logo
logo_label = tk.Label(frame, image=logo, bg="dodgerblue")
logo_label.pack(pady=10)

# Botão de acesso direto com cor mediumseagreen e texto branco em negrito, sem borda
acesso_button = tk.Button(
    frame,
    text="Acessar",
    command=acessar,
    font=("Arial", 14, "bold"),
    bg="mediumseagreen",
    fg="white",
    bd=0
)
acesso_button.pack(pady=20)

# Executando a aplicação
root.mainloop()
```