

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA DE PRODUÇÃO E SISTEMAS**

JÚLIO CÉSAR FERREIRA

**OTIMIZAÇÃO NA DISTRIBUIÇÃO LOGÍSTICA: UMA NOVA ABORDAGEM PARA
O PROBLEMA DE ROTEAMENTO *GREEN* DE VEÍCULOS MULTI-OBJETIVO**

CURITIBA

2020

JÚLIO CÉSAR FERREIRA

**OTIMIZAÇÃO NA DISTRIBUIÇÃO LOGÍSTICA: UMA NOVA ABORDAGEM PARA
O PROBLEMA DE ROTEAMENTO *GREEN* DE VEÍCULOS MULTI-OBJETIVO**

Projeto de Tese apresentado ao Programa de Pós-Graduação em Engenharia de Produção e Sistemas, da Pontifícia Universidade Católica do Paraná, como requisito parcial à obtenção do título de Doutor em Engenharia de Produção e Sistemas.

Orientadora: Prof.^a Dr.^a Maria Teresinha Arns Steiner.

**CURITIBA
2020**

Dados da Catalogação na Publicação
Pontifícia Universidade Católica do Paraná
Sistema Integrado de Bibliotecas – SIBI/PUCPR
Biblioteca Central
Edilene de Oliveira dos Santos CRB-9/1636

F383o
2020
Ferreira, Júlio César
Otimização na distribuição logística : uma nova abordagem para o problema de roteamento *green* de veículos multi-objetivo / Júlio César Ferreira, orientadora, Maria Teresinha Arns Steiner. -- 2020
189 f. : il. ; 30 cm

Tese (doutorado) – Pontifícia Universidade Católica do Paraná, Curitiba, 2020.
Bibliografia: f. 171-182

1. Engenharia da produção. 2. Logística – Aspectos ambientais. 3. Otimização matemática. 4. Algoritmos. 5. Transportes - Modelos matemáticos. I. Steiner, Maria Teresinha Arns. II. Pontifícia Universidade Católica do Paraná.
Programa de Pós- Graduação em Engenharia de Produção e Sistemas. III. Título

CDD. 20. ed. – 658.78



Pontifícia Universidade Católica do Paraná
Escola Politécnica
Programa de Pós-Graduação em Engenharia de Produção e
Sistemas

TERMO DE APROVAÇÃO

Júlio César Ferreira

OTIMIZAÇÃO NA DISTRIBUIÇÃO LOGÍSTICA: UMA NOVA ABORDAGEM PARA O PROBLEMA DE ROTEAMENTO GREEN DE VEÍCULOS MULTI- OBJETIVO

Tese aprovada como requisito parcial para obtenção do grau de Doutor no Curso de Doutorado em Engenharia de Produção e Sistemas, Programa de Pós-Graduação em Engenharia de Produção e Sistemas, da Escola Politécnica da Pontifícia Universidade Católica do Paraná, pela seguinte banca examinadora:

Presidente da Banca
Prof.^a Dra. Maria Teresinha Arns Steiner
(Orientador)

Prof. Dr. Prof. Dr. Gilberto Reynoso Meza
(Membro Interno)

Prof. Dr. Prof. Osiris Canciglieri Junior
(Membro Interno)

Prof. Dr. Paulo Henrique Siqueira
(Membro Externo / UFPR)

Prof. Dr. Pedro José Steiner Neto
(Membro Externo / UFPR)



Curitiba, 23 de julho de 2020.

Rua Imaculada Conceição, 1155 - Prado Velho – CEP: 80215-901 - Curitiba - Paraná - Brasil
Tel: +55 41 3271-2579 www.pucpr.br/ppgeps

RESUMO

A distribuição logística acarreta em muitos custos para as organizações e, desta forma, as oportunidades de otimização nesta área são sempre muito bem-vindas. O objetivo deste trabalho é apresentar uma proposta geral de solução em otimização na distribuição logística *green*, ou seja, uma nova abordagem para a otimização multi-objetivo de problemas de roteamento de veículos com considerações ambientais, aqui chamado de *Multi-objective Optimization for Green Vehicle Routing Problem* (MOOGVRP) e, também, de uma proposta composta por vários algoritmos de otimização, incluindo algoritmos híbridos aqui propostos, comparativamente, para a resolução de MOOGVRP. No referencial teórico foi realizado um levantamento referente aos dados bibliométricos (revisão bibliométrica) e a análise de conteúdo (revisão sistemática) para obter um panorama sobre a temática proposta. Já a metodologia adotada foi dividida em quatro etapas para resolver problemas do tipo MOOGVRP e ilustrada em dois estudos de caso: distribuição de jornais e transporte de funcionários e, também, em instâncias da literatura. A Etapa 1 da metodologia, “tratamento dos dados”, abordou a assimetria dos roteiros e outras particularidades; a Etapa 2, a “modelagem matemática”; a Etapa 3, as “abordagens meta-heurísticas” (híbridas ou não), mais especificamente: NSGA-II (*Non-dominated Sorting Genetic Algorithm II*), MOPSO (*Multi-Objective Particle Swarm Optimization*), CWNSGA-II (*Savings de Clarke & Wright com o Non-dominated Sorting Genetic Algorithm II*) e CWTSNSGA-II (*Savings de Clarke & Wright, Tabu Search e Non-dominated Sorting Genetic Algorithm II*); por fim, a Etapa 4, a “análise dos resultados”, onde ocorre a comparação entre os algoritmos. Quanto ao estudo de caso 1, distribuição de jornais, o algoritmo proposto CWNSGA-II demonstrou superioridade quanto aos demais. A otimização alcançada para este estudo de caso 1 foi de 19,9% para a FO₁ (minimização da emissão de CO₂) com consequente e mesmo percentual de minimização da distância total e 87,5% para a FO₂ (minimização da diferença da demanda). O estudo de caso 2, transporte de funcionários, restringiu seus roteiros quanto a limitação de tempo, sendo este um dos principais problemas enfrentados. Utilizando os mesmos parâmetros da solução corrente, obteve-se a otimização de 5,2% para a FO₁ e 11,4% quanto a FO₂. Aqui o algoritmo proposto CWNSGA-II, também demonstrou superioridade quanto aos demais. Adicionalmente foi testado um cenário complementar atendendo as restrições solicitadas pela empresa. Quanto às instâncias da literatura, observa-se que as derivações do NSGA-II (CWNSGA-II e CWTSNSGA-II) apresentaram resultados superiores quando ao próprio NSGA-II e MOPSO.

Palavras-chave: Otimização Multi-objetivo para Problema de Roteamento de Veículos *Green*. Problema de Roteamento de Veículos (PRV). Otimização Multi-objetivo. Logística Verde.

ABSTRACT

Logistical distribution entails many costs for organizations and, therefore, optimization opportunities in this area are always very welcome. The objective of this paper is to present a general purpose optimization solution in the distribution green logistics, that is, thus a new approach to Multi-objective Optimization for Green Vehicle Routing Problem (MOOGVRP) and, and, also, of a proposal composed by several optimization algorithms, including hybrid algorithms proposed here, comparatively, for the resolution of MOOGVRP. In the theoretical framework, a survey was carried out referring to bibliometric data (bibliometric review) and content analysis (systematic review) to obtain an overview of the proposed theme. The methodology adopted was divided into four steps to solve problems of the MOOGVRP type and illustrated in two case studies: newspaper distribution and employee transportation and, also, in instances of literature. Step 1 of the methodology, "data processing", addressed the asymmetry of scripts and other special features; Step 2, "mathematical modeling"; Step 3, the "meta-heuristic approaches" (hybrid or not), more specifically: NSGA-II (Non-dominated Sorting Genetic Algorithm II), MOPSO (Multi-Objective Particle Swarm Optimization), CWNSGA-II (Clarke & Wright Savings with Non-dominated Sorting Genetic Algorithm II) and CWTSNSGA-II (Clarke & Wright Savings, Tabu Search and Non-dominated Sorting Genetic Algorithm II); finally, Step 4, the "results analysis", where the comparison between the algorithms takes place. As for case study 1, newspaper distribution, the proposed CWNSGA-II algorithm showed superiority over the others. The optimization achieved for this case study 1 was 19.9% for FO_1 (minimizing CO_2 emissions) with consequent and even minimization percentage of the total distance and 87.5% for FO_2 (minimizing the demand difference). Case study 2, employee transportation, restricted their scripts in terms of time limitation, this being one of the main problems faced. Using the same parameters as the current solution, the optimization of 5.2% for FO_1 was obtained and 11.4% for FO_2 . Here the proposed CWNSGA-II algorithm, also demonstrated superiority as the others. Additionally, a complementary scenario was tested, considering the restrictions requested by the company. As for the instances of literature, it is observed that the NSGA-II derivations (CWNSGA-II and CWTSNSGA-II) presented superior results when compared to NSGA-II and MOPSO.

Keywords: Multi-objective Optimization for Green Vehicle Routing Problem (MOOGVRP). Vehicle Routing Problem (VRP). Multi-objective Optimization (MOO). Green logistic.

AGRADECIMENTOS

Agradeço primeiramente a Deus por tudo que Ele me deu, por tudo o que eu passei, pelas bênçãos, aprendizados, fracassos e as vitórias. Principalmente por esta conquista tão marcante na minha vida.

Pelos meus pais e minha irmã, que sempre me apoiaram e me incentivaram a estudar e a lutar pelos meus sonhos. O meu agradecimento especial é para a minha mãe, Maria de Fátima Antoneli Ferreira, pois sempre me incentivou e por seu amor de mãe. Além disso, por ser a única aqui em casa que entende quando eu digo que “preciso estudar!”. Também, ao apoio dos meus amigos, aos que me ajudaram de alguma forma e demais familiares.

Agradeço a todos os professores que tive no PPGEPS no decorrer de meu Mestrado e Doutorado e, demais programas de pós-graduação por onde passei, que foram cruciais para o meu desenvolvimento profissional e como cidadão.

Agradeço a Letícia Brito e Wesley Silva por fornecerem a base de dados de seus TCC's para o desenvolvimento dos estudos de caso desta tese. Também sou grato pela oportunidade que tive de auxiliá-los de alguma forma em seus projetos de pesquisa.

Agradeço a minha orientadora, Prof.^a Dr.^a Maria Teresinha Arns Steiner, pela sua competência, dedicação, paciência, orientações, profissionalismo e por acreditar no meu potencial. Além disso, por me direcionar nesta jornada acadêmica, onde tive o privilégio de ser seu orientado na graduação, mestrado e agora no doutorado. Obrigado por todos os ensinamentos!

Agradeço a banca examinadora da qualificação e defesa, por suas valiosas contribuições para a evolução deste projeto.

Por fim, agradeço a PUCPR por todo apoio e, também, à CAPES e pela bolsa concedida.

LISTA DE ILUSTRAÇÕES

Figura 1.1 - Fonte de emissão segundo o <i>Inventory of U.S. Greenhouse Gas Emissions</i>	20
Figura 2.1 – Área de distribuição das assinaturas: 5 municípios.....	27
Figura 2.2 – Cronograma de atividades da gráfica.....	28
Figura 2.3 – Endereços dos clientes da gráfica.....	31
Figura 2.4 – Representação dos roteiros da solução atual da gráfica.....	33
Figura 2.5 – Endereços dos funcionários do primeiro turno	36
Figura 2.6 – Roteirização atual das rotas	37
Figura 3.1 - Número de publicações por ano relacionado ao PRV.....	40
Figura 3.2 – Fluxograma da filtragem dos artigos	42
Figura 3.3 - Distribuição por ano das 76 publicações da amostra sobre o MOOGVRP	43
Figura 3.4 - Quantidades: do número de autores (lado esquerdo); do tipo de artigo (centro) e dos artigos publicados em periódicos voltados à sustentabilidade (lado direito) dentre os 76 da amostra.....	44
Figura 3.5 - Países que têm contribuído para o MOOGVRP.....	45
Figura 3.6 - Frequência dos termos do protocolo de pesquisa nos títulos, resumos e palavras-chaves dos 76 artigos.....	47
Figura 3.7 - Relação da amostra da pesquisa sobre as taxonomias do MOO-VRP com considerações ambientais	48
Figura 3.8 - Tipo de frota utilizada pela amostra de 70 artigos.....	49
Figura 3.9 - Abordagens multi-objetivos mais utilizadas no MOOGVRP pela amostra dos 70 artigos.....	49
Figura 3.10 - Procedimentos de solução mais utilizados no MOOGVRP.....	50
Figura 3.11 - Procedimentos de solução (lado esquerdo), número de objetivos (centro) e Meta-heurísticas utilizadas (lado direito).....	51
Figura 3.12 - <i>Softwares</i> (lado esquerdo) e Linguagens utilizados implementação computacional mais utilizadas (lado direito).....	52
Figura 3.13 - Objetivos mais utilizados nos problemas MOO aplicados ao VRPFuel, PRP e VRPRL dos 70 artigos.....	53
Figura 4.1 – Exemplo de um Problema de Roteamento de 5 roteiros e único depósito	74

Figura 4.2 – Passos do Algoritmo dos <i>Savings</i> de Clarke e Wright	79
Figura 4.3 - Passos do Algoritmo Inserção do mais próximo	80
Figura 4.4 – Pseudocódigo de um Algoritmo Genético	81
Figura 4.5 – Cruzamento de dois pontos	82
Figura 4.6 – Exemplo de uma mutação binária simples.....	82
Figura 4.7 - Pseudocódigo da meta-heurística Busca Tabu.....	83
Figura 4.8 – Estrutura básica da otimização mono e multi-objetivo	85
Figura 4.9 – Exemplo de fronteira de Pareto no espaço de objetivos factíveis	87
Figura 4.10 – Exemplo de dominância Pareto.....	88
Figura 4.11 – Exemplo de fronteira de Pareto.....	88
Figura 4.12 – Exemplo de método ϵ -restrito.....	90
Figura 4.13 – Procedimento <i>Fast-non-dominated-sorting</i>	95
Figura 4.14 – Representação gráfica do procedimento Crowding Distance.....	95
Figura 4.15 – Procedimento <i>Crowding Distance</i>	96
Figura 4.16 – Esquema do procedimento NSGA-II	97
Figura 4.17 – Procedimentos do Algoritmo NSGA-II	97
Figura 4.18 – Procedimento do Algoritmo MOPSO.....	98
Figura 4.19 – Exemplos de tipos de conflitos em um problema multi-objetivo	100
Figura 4.20 – Exemplo de hipervolume.....	101
Figura 4.21 – Espaço de conseqüências	103
Figura 5.1 – Fragmentação da Av. República Argentina nos pontos macro 3, 4 e 5	106
Figura 5.2 – Exemplo de coleta do tempo e distância entre pontos macro	107
Figura 5.3 – Exemplo do tratamento dos dados para o transporte de funcionários com 4 ônibus.....	108
Figura 5.4 – Exemplo de <i>crossover</i>	113
Figura 5.5 – Exemplo de <i>Swap</i>	114
Figura 5.6 – Fluxograma do algoritmo NSGA-II implementado.....	115
Figura 5.7 – Exemplo de cálculo da posição ($P' = P + v$).....	116
Figura 5.8 – Exemplo da velocidade através de duas posições.....	117
Figura 5.9 – Fluxograma do algoritmo MOPSO implementado.....	118
Figura 5.10 – Fluxograma do algoritmo CWNSGA-II implementado (lado esquerdo) e aplicação do C&W na solução (lado direito).....	119
Figura 5.11 – Fluxograma do algoritmo CWTSNSGA-II implementado	121

Figura 5.12 – Etapas nas iterações do algoritmo CWTSNSGA-II implementado	121
Figura 5.13 – Fluxograma procedimento adotado em cada cenário.	122
Figura 5.14 – Exemplo de interpretação da solução	123
Figura 6.1 – Comparativo das rodadas iniciais do Estudo de Caso 1, algoritmo NSGA-II.....	125
Figura 6.2 – Fronteira de Pareto com a poluição inicial e final (lado esquerdo) e fronteira de Pareto (lado direito), através da técnica NSGA-II	126
Figura 6.3 – Fronteira de Pareto com a poluição inicial e final (lado esquerdo) e fronteira de Pareto (lado direito), através da técnica MOPSO	127
Figura 6.4 – Fronteira de Pareto com a poluição inicial e final (lado esquerdo) e fronteira de Pareto (lado direito), através da técnica CWNSGA-II.....	128
Figura 6.5 – Fronteira de Pareto com a poluição inicial e final (lado esquerdo) e fronteira de Pareto (lado direito), através da técnica CWTSNSGA-II.....	129
Figura 6.6 – Análise das fronteiras de Pareto entre as técnicas utilizadas no Cenário 1	130
Figura 6.7 – Função Utilidade aplicada na fronteira de Pareto dominante do Estudo de caso 1.....	131
Figura 6.8 – Comparação da solução corrente x otimizada para o Estudo de Caso 1	132
Figura 6.9 – Avaliação de conflito entre as FOs do Estudo de caso 1, através do CWNSGA-II.....	133
Figura 6.10 – Comparativo das rodadas iniciais do Estudo de Caso 2, algoritmo NSGA-II.....	135
Figura 6.11 – Fronteira de Pareto com a poluição inicial e final (lado esquerdo) e fronteira de Pareto (lado direito), através da técnica NSGA-II, no Estudo de Caso 2	136
Figura 6.12 – Fronteira de Pareto com a poluição inicial e final (lado esquerdo) e fronteira de Pareto (lado direito), através da técnica MOPSO, no Estudo de Caso 2	137
Figura 6.13 – Fronteira de Pareto com a poluição inicial e final (lado esquerdo) e fronteira de Pareto (lado direito), através da técnica CWNSGA-II, Estudo de Caso 2	138
Figura 6.14 – Fronteira de Pareto com a poluição inicial e final (lado esquerdo) e fronteira de Pareto (lado direito), através da técnica CWTSNSGA-II.....	139

Figura 6.15 – Análise das fronteiras de Pareto entre as técnicas utilizadas no Estudo de Caso 2.....	140
Figura 6.16 – Função Utilidade aplicada na fronteira de Pareto dominante do Estudo de caso 2.....	142
Figura 6.17 – Comparação da solução corrente (esquerda) x otimizada (direita) para o Estudo de Caso 2.....	144
Figura 6.18 – Avaliação de conflito entre as FOs do Estudo de Caso 2, através do CWNSGA-II.....	145
Figura 6.19 – Análise das fronteiras de Pareto obtidas por CWNSGA-II para o Cenário 2 - ideal.....	147
Figura 6.20 – Comparação da solução corrente (esquerda) x otimizada (direita) para o Estudo de Caso 2 - Ideal.....	150
Figura 6.21 – Tempo de processamento.....	155
Figura 6.22 – Quantidade de soluções nas Fronteiras de Pareto.....	158
Figura 6.23 – Percentual de soluções não-dominadas.....	160
Figura 6.24 – Distância ideal média (MID).....	162
Figura 6.25 – Hipervolume.....	164
Figura 6.26 – Instância A-n65-k9.....	165

LISTA DE TABELAS

Tabela 2.1 – Pontos macros para a distribuição da gráfica.....	30
Tabela 2.2 - Roteiros para a solução atual da gráfica	32
Tabela 2.3 - Situação atual das rotas.....	37
Tabela 3.1 - Periódicos mais utilizados	44
Tabela 3.2 - Instituições que mais contribuíram para o MOOGVRP	46
Tabela 3.3 – Os 11 artigos mais citados da amostra MOOGVRP.....	72
Tabela 4.1 - Limites admissíveis de gases poluentes para motocicletas	104
Tabela 4.2 - Emissões médias de CO ₂ do transporte urbano	104
Tabela 5.1 - Situação atual das rotas.....	108
Tabela 5.2 – Características dos algoritmos (Estudo de Caso 1–EC1 e Estudo de Caso 2–EC2).....	112
Tabela 6.1 – Avaliação das fronteiras de Pareto.....	125
Tabela 6.2 – Avaliação das fronteiras de Pareto.....	130
Tabela 6.3 – Comparativo entre a solução atual e a proposta	131
Tabela 6.4 – Descrição do roteiro proposto para o Estudo de Caso 1	133
Tabela 6.5 – Informações obtidas por meio das funções objetivo, através da técnica CWNSGA-II, do Estudo de Caso 1.....	134
Tabela 6.6 – Estratificação da capacidade atribuída em cada sub- <i>tour</i> das soluções, através da técnica CWNSGA-II, do Estudo de Caso 1.....	134
Tabela 6.7 – Avaliação das fronteiras de Pareto.....	135
Tabela 6.8 – Avaliação das fronteiras de Pareto.....	141
Tabela 6.9 – Comparativo entre a solução atual e as soluções propostas	141
Tabela 6.10 – Estratificação da capacidade atribuída em cada sub- <i>tour</i> da solução atual e das soluções otimizadas, através da técnica CWNSGA-II, do Estudo de Caso 2, com limite de percurso em 127 min.....	142
Tabela 6.11 – Estratificação do tempo atribuído em cada sub- <i>tour</i> da solução atual e das soluções otimizadas, através da técnica CWNSGA-II, do Estudo de Caso 2, com limite de percurso em 127 min	143
Tabela 6.12 – Descrição do roteiro proposto para o Estudo de Caso 2 (G=Garagem; F=Fábrica).....	145
Tabela 6.13 – Parâmetros para avaliação realística do Estudo de Caso 2	146

Tabela 6.14 – Informações obtidas por meio das funções objetivo, através da técnica CWNSGA-II, do Estudo de Caso 2 – ideal	148
Tabela 6.15 – Estratificação da capacidade atribuída em cada sub- <i>tour</i> da solução atual e das soluções otimizadas, através da técnica CWNSGA-II, do Estudo de Caso 2 – Ideal, com limite de percurso em 90 min	149
Tabela 6.16 – Estratificação do tempo atribuído em cada sub- <i>tour</i> da solução atual e das soluções otimizadas, através da técnica CWNSGA-II, do Estudo de Caso 2 – Ideal, com limite de percurso em 90 min	149
Tabela 6.17 – Valores atribuídos para os parâmetros do NSGA-II, MOPSO e CWNSGA-II	152
Tabela 6.18 – Tempo de processamento	154
Tabela 6.19 – Número de veículos	156
Tabela 6.20 – Quantidade de soluções nas Fronteiras de Pareto	157
Tabela 6.21 – Percentual de dominância nas soluções	159
Tabela 6.22 – Distância ideal média (MID)	161
Tabela 6.23 – Hipervolume	163
Tabela 6.24 – Média e Desvio Padrão dos dados analisados	166

LISTA DE QUADROS

Quadro 3.1 - Resumo dos 76 artigos relacionados ao MOOGVRP.....	66
Quadro 4.1 - Principais variações do VRP.....	77
Quadro 4.2 – Relação da terminologia do Algoritmo Genético com a Biologia	79
Quadro 4.3 - Principais variações do Algoritmo Genético Multiobjetivo	90
Quadro 5.1 – Metodologia para a resolução de MOOGVRP: estudos de caso.....	104

LISTA DE ABREVIATURAS E SIGLAS

ABC	<i>Artificial Bee Colony</i>
ACO	<i>Ant Colony Optimization</i>
ACS	<i>Ant Colony System</i>
AG	Algoritmo Genético
AHP	<i>Analytic Hierarchy Process</i>
ALNS	<i>Adaptive Large Neighborhood Search</i>
AMOSAS	<i>Achieved Multi-Objective Simulated Annealing</i>
AMOVNS	<i>Adapted Multi-Objective Variable Neighborhood Search</i>
AMPL	<i>A Mathematical Programming Language</i>
AUGMENCON	<i>Augment constraint algorithm</i>
BEG-NSGA-II	<i>Bee evolutionary algorithm guiding nondominated sorting genetic algorithm II</i>
BIOBAB	<i>Bi-Objective Branch-And-Bound</i>
BOTRDP	<i>Bi-Objective Turning Restriction Design Problem</i>
BT	Busca Tabu
BTL-VRPTW	<i>Biobjective time, load and path-dependent VRP with time windows</i>
C&W	Algoritmo de Clarke & Wright
CAPEAS	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CCO	<i>Crowded-Comparison Operator</i>
CD	<i>Crowding Distance</i>
CI	Congresso Internacional
CN	Congresso Nacional
CO	Monóxido de Carbono
CO ₂	Dióxido de carbono
CPLEX	Simplex method as <i>implemented in the C programming language</i>
CVRP	<i>Capacitated VRP</i>
CWNSGA-II	<i>Savings de Clarke & Wright com o Non-dominated Sorting Genetic Algorithm II</i>
CWTSNSGA-II	<i>Savings de Clarke & Wright, Tabu Search e Non-dominated Sorting Genetic Algorithm II</i>
DM	<i>Decision Maker</i>
DMOEA	<i>Dynamic Multi-objective Evolutionary Algorithm</i>
DVRP	<i>Dynamic VRP</i>
ESMPO	<i>Evolution-Strategy-based Memetic Pareto Optimization</i>
FNS	<i>Fast Nondominated Sorting</i>
FO ₁	Função Objetivo 1
FO ₂	Função Objetivo 2
FO	Função Objetivo
F-GVRP	<i>Fuel efficient Green Vehicle Routing Problem</i>
FP	Fronteira de Pareto
FU	Função Utilidade
FVRP	<i>Fuzzy VRP</i>
GA	<i>Genetic Algorithm</i>

GAMS	<i>General Algebraic Modeling System</i>
GCHLRP	<i>Green City Hub Location Routing Problem</i>
G&JM	<i>Algoritmo de Gillett & Johnson Modificado</i>
GHG	<i>Greenhouse Gases</i>
G-MoMaVRP	<i>Green Multi-objective Multi-attribute VRP</i>
G-OLRP	<i>Green Open LRP</i>
Green-ITTRP	<i>Green Inter-Terminal Truck Routing Problem</i>
GVRP	<i>Green Vehicle Routing Problem</i>
GVROP	<i>Green Vehicle Routing Optimization Problem</i>
HC	<i>Hidrocarbonetos</i>
HM	<i>Hybrid Method</i>
IRP	<i>Inventory Routing Problem</i>
J	<i>Jornal</i>
JR	<i>Jornal com Revista</i>
LINGO	<i>Language for interactive General Optimizer</i>
LRP	<i>Location Routing Problem</i>
LRPFT	<i>LRP with Full Truckloads</i>
LRPTW	<i>LRP with Time Window</i>
MAA	<i>Modelo de Agregação Aditivo</i>
MatLab	<i>MATrix LABoratory</i>
MDVRP	<i>Multi-depot VRP</i>
MDPVRPI	<i>Multi-Depot Periodic VRP with Inter-depot routes</i>
MEA	<i>Multi-objective Evolutionary Algorithm</i>
MEVRP	<i>Multi-echelon VRP</i>
MHPV	<i>Multi-objective hybrid approach</i>
MIP	<i>Mixed Integer Programming</i>
MILP	<i>Mixed Integer Linear Programming</i>
MINLP	<i>Mixed Integer Non-Linear Programming</i>
MOGA	<i>Multiple Objective Genetic Algorithm</i>
MOGA-II	<i>Multi-Objective GA of kind II</i>
MOO	<i>Multi-Objective Optimization</i>
MOOGVRP	<i>Multi-Objective Optimization for Green Vehicle Routing Problem</i>
MOPSO	<i>Multi-Objective Particle Swarm Optimization</i>
MOSPOOLS	<i>Multi-objective smart pool search</i>
MPVRP	<i>Multi-Period VRP</i>
MRFCVRPs	<i>Multiobjective route based fuel consumption VRPs</i>
NO _x	<i>Óxidos de nitrogênio</i>
NPGA	<i>Niched Pareto Genetic Algorithm</i>
NP-Hard	<i>Não-Polinomial-Difícil</i>
NSGA	<i>Non-dominated Sorting Genetic Algorithm</i>
NSGA-II	<i>Non-dominated Sorting Genetic Algorithm II</i>
NRGA	<i>Non-dominated Ranking Genetic Algorithm</i>
OVRP	<i>Open VRP</i>
PAES	<i>Pareto-Archived Evolution Strategy</i>
PCV	<i>Problema do Caixeiro Viajante</i>
PESA	<i>Pareto Envelope-based Selection Algorithm</i>

PESA-II	<i>Region-based Selection in Evolutionary Multiobjective Optimization</i>
PF	<i>Pareto Front</i>
PFGA	<i>Pareto Front Aenetic Algorithms</i>
PLIB	<i>Programação Linear Inteiro Binário</i>
PMS-NSDEs	<i>Parallel Multi-Start Non-dominated Sorting Differential Evolution</i>
PO	<i>Pesquisa Operacional</i>
PPRP-TW	<i>Production and PRP with Time Window</i>
PRP	<i>Pollution Routing Problem</i>
PRV	<i>Problema de Roteamento de Veículos</i>
PSO	<i>Particle Swarm Optimization</i>
RDGA	<i>Rank-Density Based Genetic Algorithm</i>
RDMOVR	<i>Robust Dynamic Multi-Objective Vehicle Routing</i>
RWGA	<i>Random Weighted Genetic Algorithm</i>
SA	<i>Simulated Annealing</i>
SLPSO	<i>Hybrid Self-Learning PSO</i>
SPEA	<i>Strength Pareto Evolutionary Algorithm</i>
SPEA-II	<i>Region-based Selection in Evolutionary, Multiobjective Optimization</i>
SSA	<i>Salp Swarm Algorithm</i>
SVRP	<i>Scheduling in VRP</i>
TDVRP	<i>Time-dependent VRP</i>
TVa-PSOGMO	<i>Particle swarm optimization with greedy mutation operator along with time varying acceleration</i>
UAV	<i>Unmanned Aerial Vehicle</i>
US EPA	<i>United States Environmental Protection Agency</i>
VEGA	<i>Vector Evaluated Genetic Algorithm</i>
VNSGA-II	<i>Variable Neighborhood Search based non-dominated sorting Genetic Algorithm II</i>
VRP	<i>Vehicle Routing Problem</i>
VRPFuel	<i>VRP Fuel consumption</i>
VRPPD	<i>VRP with Pickup and Delivery</i>
VRPRL	<i>Vehicle Routing Problem in Reverse Logistic</i>
VRPS	<i>VRP Stochastic</i>
VRPSPD	<i>VRP with Simultaneous Pickups and Deliveries</i>
VRPTW	<i>VRP with Time Windows</i>
WBGA	<i>Weight-based Genetic Algorithm</i>
WM	<i>Weight Method</i>
2E-LRP	<i>Two-echelon LRP</i>
2E-LRPTW	<i>Two-echelon LRP with Time-Windows</i>

LISTA DE SÍMBOLOS

a	Alternativa
A	Arestas (ou arcos) do grafo
b	Veículo
B	Conjunto de veículos
$BTmax$	Número máximo de iterações sem melhora em s^*
C_1	Constante de aceleração 1
C_2	Constante de aceleração 2
c_{ij}	Custo da origem i até o destino
Cap_b	Capacidade do veículo b
d_{ij}	Distância da Origem i até o destino j
D_j	Demanda j
ε	Parâmetros de entrada
$f(.)$	Vetor das funções objetivo
$f_k(.)$	Vetor das funções objetivo de dimensão k
\mathcal{F}_i	Fronteira de Pareto i
G	Conjunto de um grafo
$g(.)$	Conjunto de restrições de desigualdade de dimensão m
$gbest$	Melhor partícula da população
$h(.)$	Conjunto de restrições de igualdade de dimensão p
i	Origem
l	Número de soluções em \mathcal{F}_i
l_{GD}	Indicador de distância
l_{PSE}	Indicador de porcentagem de soluções eficientes
$IterT$	Número de iterações na temperatura T
$ltmax$	Número máximo de iterações
j	Destino
k	Variável auxiliar para i, j ou a ' k -exima dimensão'
L	Endereço mais próximo
LT	Lista Tabu
m	Tamanho da dimensão
$MelhorIter$	Iteração mais recente que forneceu s^*
mov	Movimento
n	Número de endereços. Em multi-objetivo, o tamanho da dimensão.
N	Subconjunto do conjunto de vértices (cidades) V . Em multi-objetivo, o tamanho da população.
O_i	Origem i
p	Em multi-objetivo, o tamanho da dimensão. Para o NSGA-II representa uma solução
$pbest$	Melhor versão da partícula
P	Conjunto de soluções de pais p
q	Representa uma solução
Q	Conjunto de soluções de filhos q
r	Distância máxima de um cliente designado a uma facilidade
r_1	Número aleatório uniforme 1

r_2	Número aleatório uniforme 2
R	Conjunto de soluções de pais P e filhos Q
Ref	Conjunto de referência Z
NR_{des}	Número de restrições de desigualdade
NR_{igu}	Número de restrições de igualdade
N_{val}	Número de variáveis
s	Solução (roteiro)
s_o	Solução inicial
s'	Nova solução (perturbação ou busca local da solução)
s^*	Melhor solução obtida até então
S_p	Conjunto de soluções dominado por p
scw_{ij}	<i>Savings</i> da origem i até o destino j
t	Contador
T	Temperatura corrente
$U(.)$	Valor da Utilidade
$u.a.$	Unidade de área
v	Vértice (ou nó) do grafo
V	Conjunto de vértices (ou nós) do grafo
$valor$	Valor da alternativa
vel	Velocidade da partícula
w_i	Peso do vértice i
x_{ij}	Variável de decisão do endereço da origem i até o destino j
x_{ij}^b	Variável de decisão do endereço da origem i , até o destino j , com o veículo b
X	Região factível no espaço das funções objetivo. Domínio das variáveis de decisão x
y_i^b	Demanda do cliente i atendido pelo veículo b
z_k	Vetor das funções objetivo de dimensão k
Z	Vetor das funções objetivo de dimensão k . Imagem de X . Domínio das funções objetivo.
α	Fator de redução para o decréscimo da temperatura T
$\sigma(.)$	Número de transmissão
Δf	Varição da função objetivo

SUMÁRIO

1 INTRODUÇÃO	20
1.1 OBJETIVOS.....	23
1.1.1 Objetivo Geral	23
1.1.2 Objetivos Específicos	23
1.2 JUSTIFICATIVA.....	23
1.3 METODOLOGIA DA PESQUISA	24
1.4 CONTRIBUIÇÃO	24
1.5 ESTRUTURA DO TRABALHO	25
2 DESCRIÇÃO DO PROBLEMA	27
2.1 ESTUDO DE CASO 1 – DISTRIBUIÇÃO DE JORNAIS	27
2.2 ESTUDO DE CASO 2 – TRANSPORTE DE FUNCIONÁRIOS	34
3 REVISÃO SISTEMÁTICA	39
3.1 <i>GREEN PRV</i>	39
3.2 REVISÃO BIBLIOMÉTRICA DA LITERATURA	40
3.2.1 Procedimentos Metodológicos	40
3.2.2 Dados Bibliométricos	42
3.3 TRABALHOS CORRELATOS.....	53
3.3.1 <i>Pollution Routing Problem</i>	53
3.3.2 <i>Vehicle Routing Problem Fuel</i>	58
3.3.3 <i>Vehicle Routing Problem in Reverse Logistic</i>	61
3.3.4 Outros Trabalhos	64
3.3.5 Resumo dos artigos relacionados ao MOOGVRP	65
4 FUNDAMENTAÇÃO TEÓRICA	74
4.1 PROBLEMA DE ROTEAMENTO DE VEÍCULOS (VRP)	74
4.1.1 Modelagem Matemática para o VRP	74
4.1.2 Variações do VRP	77
4.2 PROCEDIMENTOS HEURÍSTICOS E META-HEURÍSTICOS	79
4.2.1 Algoritmo dos <i>Savings</i> de Clarke e Wright (<i>Savings</i> de C&W)	79
4.2.2 Algoritmo da Inserção do mais próximo	79
4.2.3 Algoritmo Genético	80
4.2.4 Busca Tabu	82
4.3 OTIMIZAÇÃO MULTI-OBJETIVO	84
4.3.1 Dominância e Fronteira de Pareto	86

4.3.2 Weighted Method	89
4.3.3 Método ε-restrito	89
4.3.4 Algoritmo Genético Multi-objetivo	90
4.3.4.1 Algoritmo NSGA II	94
4.3.5 Algoritmo MOPSO	98
4.3.6 Métodos de avaliação da solução	99
4.3.6.1 Avaliação de conflito de uma função multiobjectivo.....	100
4.3.6.2 Hipervolume	100
4.3.6.3 Indicador de distância (I_{GD}).....	101
4.3.6.4 Porcentagem de soluções eficientes (I_{PSE}).....	101
4.4 ANÁLISE DE DECISÃO	102
4.4.1 Modelo de Agregação Aditivo	102
4.4.2 Teoria da Utilidade	103
4.5 CONSIDERAÇÕES AMBIENTAIS DO CAPÍTULO	103
5 METODOLOGIA PROPOSTA	105
5.1 ETAPA 1: “TRATAMENTO” DOS DADOS	105
5.1.1 Estudo de Caso 1 – Distribuição de Jornal	105
5.1.2 Estudo de Caso 2 – Transporte de Funcionários	107
5.2 ETAPA 2: MODELAGEM MATEMÁTICA PARA O MOOGVRP	109
5.3 ETAPA 3: ABORDAGENS META-HEURÍSTICAS	111
5.3.1 NSGA-II	112
5.3.2 MOPSO	115
5.3.3 Algoritmo Híbrido CWNSGA-II	119
5.3.4 Algoritmo Híbrido CWTSNSGA-II	120
5.4 ETAPA 4: ANÁLISE DOS RESULTADOS	122
6 OBTENÇÃO, DISCUSSÃO E ANÁLISE DOS RESULTADOS	124
6.1 ESTUDO DE CASO 1: DISTRIBUIÇÃO DE JORNAIS	124
6.1.1 NSGA-II	124
6.1.2 MOPSO	126
6.1.3 CWNSGA-II	127
6.1.4 CWTSNSGA-II	128
6.1.5 Análise dos Resultados	129
6.2 ESTUDO DE CASO 2: TRANSPORTE DE FUNCIONÁRIOS	134
6.2.1 NSGA-II	135

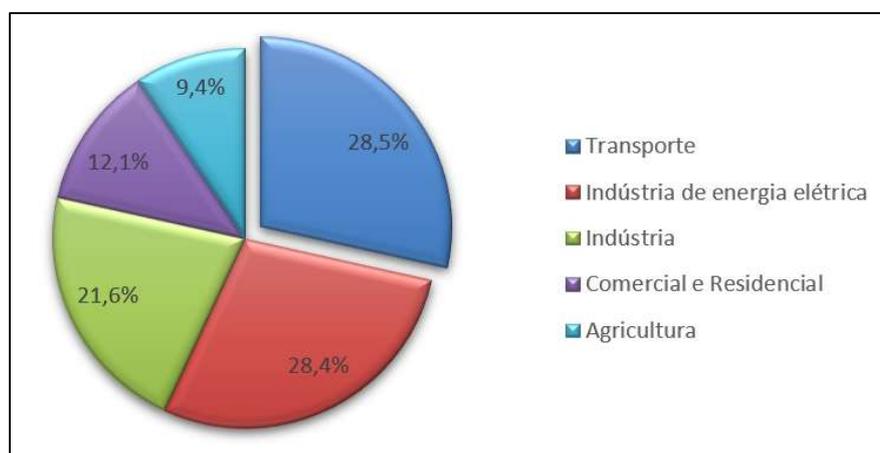
6.2.2 MOPSO	137
6.2.3 CWNSGA-II	138
6.2.4 CWTSNSGA-II.....	139
6.2.5 Análise dos Resultados	140
6.2.6 Atendendo aos requisitos do Estudo de Caso 2	146
6.3 INSTÂNCIAS DA LITERATURA	151
6.3.1 Métricas Avaliativas.....	152
6.3.2 Análise das Instâncias da literatura.....	153
7 CONCLUSÃO	167
REFERÊNCIAS.....	171

1 INTRODUÇÃO

Os congestionamentos nos grandes centros urbanos mostram-se como um fator preocupante por gerar prejuízos econômicos, diminuição da produtividade de forma global e um impacto negativo para o meio ambiente (BAUZA *et al.*, 2010). Uma questão básica do gerenciamento logístico é definir configurações de distribuição capazes de atender de forma econômica os pontos de demanda, oferecendo níveis de serviço cada vez mais qualificados, em termos de capacidade de atendimento em um intervalo de tempo cada vez menor (BALLOU, 2001).

De acordo com o relatório publicado pela *United States Environmental Protection Agency (US EPA, 2018)*, as fontes de *greenhouse gases* (GHG ou gases de efeito estufa) incluem cinco setores principais: transporte, energia, indústria, comercial e residencial e agricultura, conforme a Figura 1.1, que mostra os seus respectivos percentuais. Neste trabalho será dada ênfase à “fatia” referente aos Transportes (28,5%). Ao estratificar esta “fatia” encontra-se: CO₂ (Dióxido de Carbono) proveniente da combustão de combustíveis fósseis (27,4%), substituição de substâncias que destroem a camada de ozônio (0,7%), combustão móvel (0,3%) e utilização não energética de combustíveis (0,1%), dentre os quais serão aqui abordadas as questões referentes à CO₂ proveniente da combustão de combustíveis fósseis e a combustão móvel.

Figura 1.1 - Fonte de emissão segundo o *Inventory of U.S. Greenhouse Gas Emissions and Sinks* em 2016.



Fonte: US EPA (2018).

Neste contexto, podemos encontrar na literatura diversos trabalhos que abordam a otimização do consumo de combustível (Abad et al., 2018; Poonthalir e Nadarajan, 2018), emissão de CO₂ (Ebrahimi, 2018; Fathollahi-Fard et al., 2018), os dois casos simultaneamente (Amer et al., 2016) e outras abordagens (Ghezavati e Beigi, 2016; Fu et al., 2017) aplicadas aos *Vehicle Routing Problems*.

O Problema de Roteamento de Veículos (PRV; *Vehicle Routing Problem* – VRP), proposto por Dantzig e Ramser (1959), tem grande importância para uma eficaz distribuição logística (VALIDI et al., 2015; POONTHALIR e NADARAJAN, 2018). Têm ocorrido muitas evoluções para o VRP, considerado NP-*hard*, a fim de atender às necessidades complexas da vida real, como janelas de tempo para coleta e entrega de mercadorias e/ou pessoas, tempos de viagem dependentes do tempo (refletindo tráfego e congestionamento), entrada de informações que se alteram dinamicamente ao longo do tempo, dentre muitas outras. De forma complementar, o VRP *Green* analisa as atividades de roteamento levando em consideração aspectos ambientais (SAWIK et al., 2017a; TORO et al., 2017a e SOLEIMANI et al., 2018).

Nas últimas décadas, vem ocorrendo um grande aumento na quantidade de publicações relacionadas ao VRP. Paralelamente, o poder computacional tem apresentado evolução crescente em seu desempenho, contribuindo e estimulando o aumento da pesquisa e desenvolvimento nesta e em outras áreas. Mesmo assim, ainda é difícil resolver problemas de grande porte de forma exata, sendo que muitas vezes se faz necessário recorrer a procedimentos heurísticos e meta-heurísticos (BRAEKERS et al., 2016).

Os algoritmos heurísticos e meta-heurísticos são procedimentos alternativos em relação aos métodos exatos devido ao seu alto custo computacional. Os métodos heurísticos procuram alcançar os resultados para os problemas rapidamente, mas não garantem que a solução obtida seja a solução ótima. Por outro lado, os métodos meta-heurísticos normalmente não se “prendem” a ótimos locais e buscam o ótimo global (TÁVORA, 2011 e DETRO 2013).

Já a área de Otimização com Múltiplos Objetivos (*Multi-Objective Optimization*; MOO) trata do processo de otimizar dois ou mais objetivos

conflitantes de forma simultânea sujeitos a restrições (KUMAR *et al.*, 2016). Ao procurarmos por soluções em problemas MOO, chega-se a um ponto em que, ao tentar melhorar um objetivo, os outros são prejudicados; tem-se neste caso, o que se denomina “fronteira de Pareto”. Portanto, uma solução será considerada Pareto eficiente (Pareto ótimo ou não dominada) se não puder ser eliminada da consideração por conta de outra solução que melhore um dos objetivos sem piorar os demais. Desta forma, o objetivo de um problema MOO é encontrar soluções não dominadas e quantificar os *trades-off* na satisfação entre os diferentes objetivos estabelecidos (MIETTINEN, 1999; EHRGOTT *et al.*, 2012 e STEINER *et al.*, 2015).

O *Multi-objective Optimization for Green Vehicle Routing Problem* (Problema de Roteamento de Veículos Multi-objetivo *Green*, MOOGVRP) tem como proposta combinar o VRP, técnicas de MOO e as considerações ambientais a fim de gerar roteirizações economicamente e ambientalmente factíveis. Neste contexto, muitos pesquisadores têm adequado seus procedimentos de solução para atender a questões, tais como, as relacionadas a custos, tempo de percorrida, emissão de CO₂, consumo de combustível, logística reversa e impactos ambientais (LIN *et al.*, 2014; AMER *et al.*, 2016; ENTEZAMINIA *et al.*, 2016; NOROUZI *et al.*, 2017; GONG *et al.*, 2018; WANG *et al.*, 2018a).

Para ilustrar a abordagem aqui dada ao MOOGVRP, é realizada a análise de um problema de coleta e/ou entrega de jornais. Neste contexto, uma abordagem multi-objetivo poderá auxiliar no processo de tomada de decisão complexa de forma a atender os objetivos a serem alcançados (RAMOS *et al.*, 2014 e STEINER NETO *et al.*, 2017).

Uma vez apontada a importância do estudos sobre esta abordagem, definiu-se o seguinte problema de pesquisa a ser investigado: **Determinar e apresentar uma proposta geral de conjunto de técnicas da Pesquisa Operacional (PO) para a solução do Problema de Roteamento Veículos, incorporando uma abordagem Multi-objetivo com Considerações Ambientais?**

1.1 OBJETIVOS

Esta seção apresenta os objetivos do trabalho que estão divididos em geral e específicos.

1.1.1 Objetivo Geral

O objetivo deste trabalho é apresentar uma proposta geral de solução em otimização na distribuição logística, isto é, uma nova abordagem para o problema de roteamento *green* de veículos multi-objetivo (*Multi-objective Optimization for Green Vehicle Routing Problem*, MOOGVRP), aplicado em dois estudos de caso (problemas de distribuição de jornais e de coleta de funcionários), além de instâncias da literatura.

1.1.2 Objetivos Específicos

Os objetivos específicos podem ser descritos da seguinte forma:

- a) Definir as principais técnicas exatas, heurísticas e meta-heurísticas da área de PO que envolvem o Problema de Roteamento de Veículos com abordagens Multi-objetivos;
- b) Determinar as principais abordagens ambientais, ou seja, *Green*, sobre o problema apresentado;
- c) Pesquisar junto a literatura os principais conceitos e oportunidades de avanço científico para o desenvolvimento deste trabalho;
- d) Desenvolver procedimento de solução para o MOOGVRP, através de abordagem meta-heurística;
- e) Gerar e analisar cenários, onde será realizada a comparação da solução adotada pela empresa estudada com os métodos propostos e, também, quanto às instâncias da literatura.

1.2 JUSTIFICATIVA

A solução proposta trará vantagens para as empresas que vierem a adotar a metodologia aqui proposta e, também para seus clientes. As

empresas de distribuição ou transporte de funcionários poderão atender seus clientes em um prazo menor, a custos mais baixos (economia esta que poderá ser repassada aos clientes), respeitando o meio ambiente, maximizando o desempenho e o lucro, e minimizando as emissões de CO₂. Além disso, a possibilidade de melhor se auto organizar trará vantagens competitivas em relação às empresas concorrentes. Já os usuários poderão ser atendidos mais rapidamente e a um custo mais baixo, ou seja, de uma forma mais satisfatória.

1.3 METODOLOGIA DA PESQUISA

A natureza desta pesquisa é aplicada, porque visa contribuir para a solução de problemas reais e de suas necessidades, por meio da fundamentação teórica, aplicação, análise e conclusões. Além disso, busca gerar um processo/conhecimento que possui uma aplicação imediata. A abordagem da pesquisa é quantitativa, pois traduz em números todos os dados necessários para analisar e obter conclusões. O objetivo da pesquisa é exploratório, porque visa proporcionar maior familiaridade com o problema, com a finalidade de torná-lo mais explícito e aprimorar as ideias e as atividades. Para os procedimentos técnicos foram realizados dois estudos de caso (COSTA e COSTA, 2011).

Por fim, deve-se enfatizar que a veracidade dos dados obtidos é de fundamental importância, com a finalidade de se apresentar resultados que ofereçam reais melhorias para a solução do problema em questão.

1.4 CONTRIBUIÇÃO

As principais contribuições deste trabalho são:

- a) Visão geral estruturada de trabalhos recentes sobre VRP com considerações ambientais (MOOGVRP);
- b) Análise de trabalhos com abordagens multi-objetivos: *Vehicle Routing Problem Fuel consumption* (VRP com consumo de combustível, PRVFuel), *Pollution Routing Problem* (Problema de Roteamento de Poluição, PRP) e *Vehicle Routing Problem in Reverse Logistic* (VRP em Logística Reversa, VRPRL);

- c) Abordagem dada ao estudo: minimização da distância de percorrida que acarreta a minimização do consumo de combustível e de emissão de GHG. Além disso, a homogeneização da demanda por meio da minimização da diferença absoluta da demanda pela sua média;
- d) Planejamento de roteirização de coleta e entrega de mercadorias (estudo de caso 1) e, também, de transporte de funcionários (estudo de caso 2) voltado a facilitar a execução factível da atividade;
- e) Para a coleta dos dados foi considerado a assimetria das distâncias de percorrida e conseqüentemente dos tempos de trajeto, ao invés da usuais pontos distâncias Euclidianos simétricas;
- f) No estudo de caso 1, na definição os pontos macros (uma simplificação dos dados coletados) foi avaliada, considerando as direções das vias ao invés dos pontos médios ou por meio de alguma forma de atribuição de pesos;
- g) No estudo de caso 2, a adequação da solução do roteiro restrito à limitação da capacidade de passageiros no transporte e tempo máximo de trajeto;
- h) Procedimentos meta-heurísticos de solução;
- i) Em todos os aspectos anteriormente apresentados estão embutidas considerações ambientais, que são aqui tratadas como mecanismo para a consciente tomada de decisão.

1.5 ESTRUTURA DO TRABALHO

O trabalho está estruturado em sete capítulos. Além deste Capítulo 1, o Capítulo 2 contempla a descrição do problema a ser estudado que irá ilustrar a metodologia adotada, seguido pelo Capítulo 3 que trata da revisão bibliométrica e sistemática da literatura, focada em levantar de forma quantitativa e qualitativa respectivamente os mais diversos trabalhos encontrados sobre o tema, visando a definição do escopo da metodologia. No Capítulo 4 é apresentada a fundamentação teórica para o desenvolvimento do trabalho.

Já o Capítulo 5 aborda a metodologia e tratamentos dos dados para os dois estudos de caso propostos para a resolução do problema. No Capítulo 6

estão apresentados e discutidos os resultados e, por fim, o Capítulo 7 descreve as conclusões da pesquisa.

2 DESCRIÇÃO DO PROBLEMA

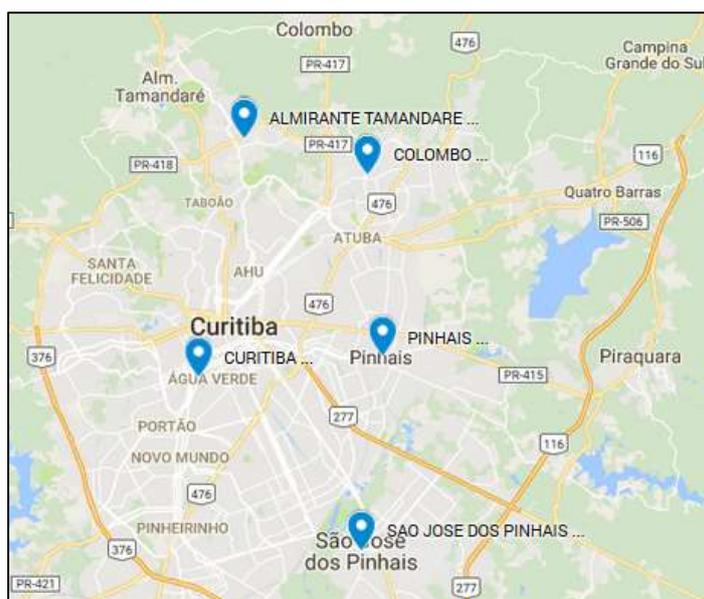
Neste capítulo serão apresentados dois estudos de caso fazendo uso da abordagem aqui proposta: o primeiro se refere a distribuição/entrega de jornais e o segundo ao transporte fretado de funcionários.

2.1 ESTUDO DE CASO 1 – DISTRIBUIÇÃO DE JORNAIS

O presente estudo de caso, utilizado para ilustrar a metodologia aqui adotada para a resolução de um MOOGVRP, é referente ao processo de distribuição de jornais e revistas realizada por uma gráfica localizada no município de Curitiba-PR, aqui chamada de gráfica.

Atualmente, a gráfica entrega o jornal em cinco municípios pertencentes a Curitiba e sua região metropolitana (Curitiba, Colombo, Almirante Tamandaré, Pinhais e São José de Pinhais), todas no Estado do Paraná, conforme apresentado na Figura 2.1. A distribuição do jornal é dividida entre as regiões Norte e Sul. A média de entrega é de 18 mil assinaturas e 1,4 mil exemplares para os pontos de venda avulsa (banquinhas de jornais, panificadoras, mercados, entre outros).

Figura 2.1 – Área de distribuição das assinaturas: 5 municípios



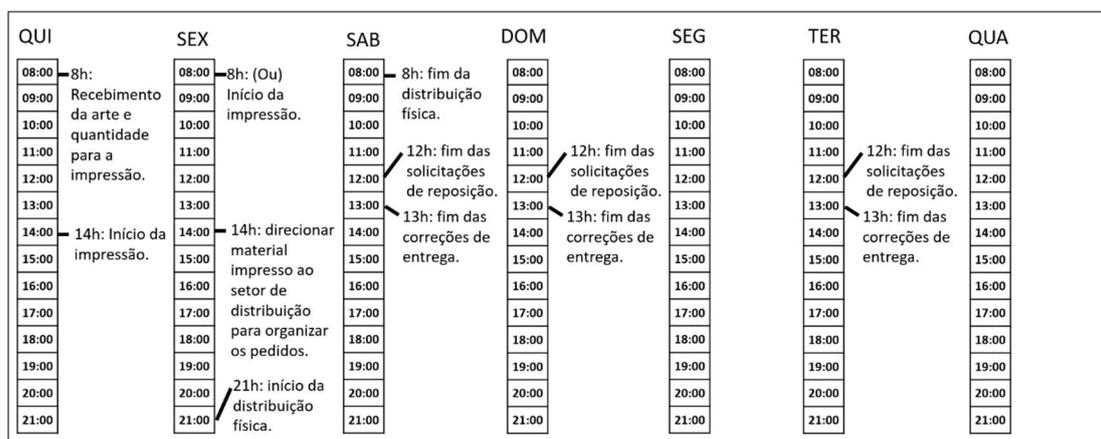
Fonte: Adaptado de *Google Maps*.

Neste trabalho será abordará apenas a distribuição de assinaturas do centro de distribuição da regional Sul, que envolve a região sul do município de Curitiba e os municípios de Pinhais e São José dos Pinhais, com cerca de 8,5 mil assinaturas. Vale destacar que, atualmente, esta distribuição é realizada por 40 entregadores que fazem o uso de motocicletas. Uma particularidade ocorre no roteiro do centro de Curitiba, sendo este é realizado com bicicletas, devido à dificuldade de estacionar o veículo para a entrega.

A gráfica é responsável por fazer a impressão e distribuição dos jornais e revistas da empresa solicitante. Os clientes recebem em suas residências o “Jornal” (J) ou “Jornal com Revista” (JR). A gráfica recebe a “arte” do jornal e a quantidade a ser produzida todas as 5as.-feiras de cada semana. Nas 6as.-feiras, ou na 5a.-feira se houver tempo, é realizada a impressão destes jornais e revistas até as 14h e direcionado para o setor de distribuição. Neste mesmo dia, no setor de distribuição, ocorre a organização dos pedidos de Jornais e Revistas. Por fim, a distribuição física ocorre a partir das 21h das 6as.-feiras, sendo que as entregas são finalizadas por volta das 8h de sábado.

Após esse horário, ocorrem as solicitações de reposições, isto é, jornais não entregues ou entregues em locais inadequados, que são enviados ao distribuidor por meios de *tickets* abertos (reclamação) pela central de atendimento ou pelo assinante da empresa solicitante. As reposições solicitadas no sábado até 12h, são realizadas no mesmo dia até às 13h. O mesmo ocorre no domingo e na 3ª.-feira. As solicitações realizadas após esse período, são feitas no próximo final de semana. A Figura 2.2 sintetiza o processo descrito.

Figura 2.2 – Cronograma de atividades da gráfica



Fonte: O autor.

A cada reposição realizada, a gráfica tem um custo, sendo que são em média 50 reposições por edição. Com base na listagem de entrega enviada na semana, o departamento de distribuição tem a responsabilidade de fazer as etiquetas para colocar em todos os jornais daquela região e elaborar a divisão dos roteiros utilizados que, para a regional Sul, totalizam 89 setores. Estes são agrupados por quantidade de assinantes dentro do setor, além da informação se a entrega será apenas o J ou o JR.

Foi desenvolvida a análise de um setor no bairro Água Verde, na região de Curitiba, que contém 479 endereços. Este setor é realizado por um único entregador, que inicia a sua rota em um determinado ponto da Rua Petit Carneiro e que tem como final, um ponto na Av. República Argentina. O setor tem como apoio um depósito móvel (um furgão) que estoca os jornais na Rua Dario Veloso, onde o entregador poderá realizar o “recarregamento” de jornais. Vale destacar que esta rua também contém pontos de entrega. O tempo total de entrega tem, em média de 2h, variando conforme a experiência do entregador.

A fim de simplificar a base de dados com os 479 pontos de entrega, a gráfica estabeleceu “48 pontos macros” (ou fragmentos de ruas) como referência. Esta forma de tratamento dos dados será explicada com mais detalhes no Capítulo 4.

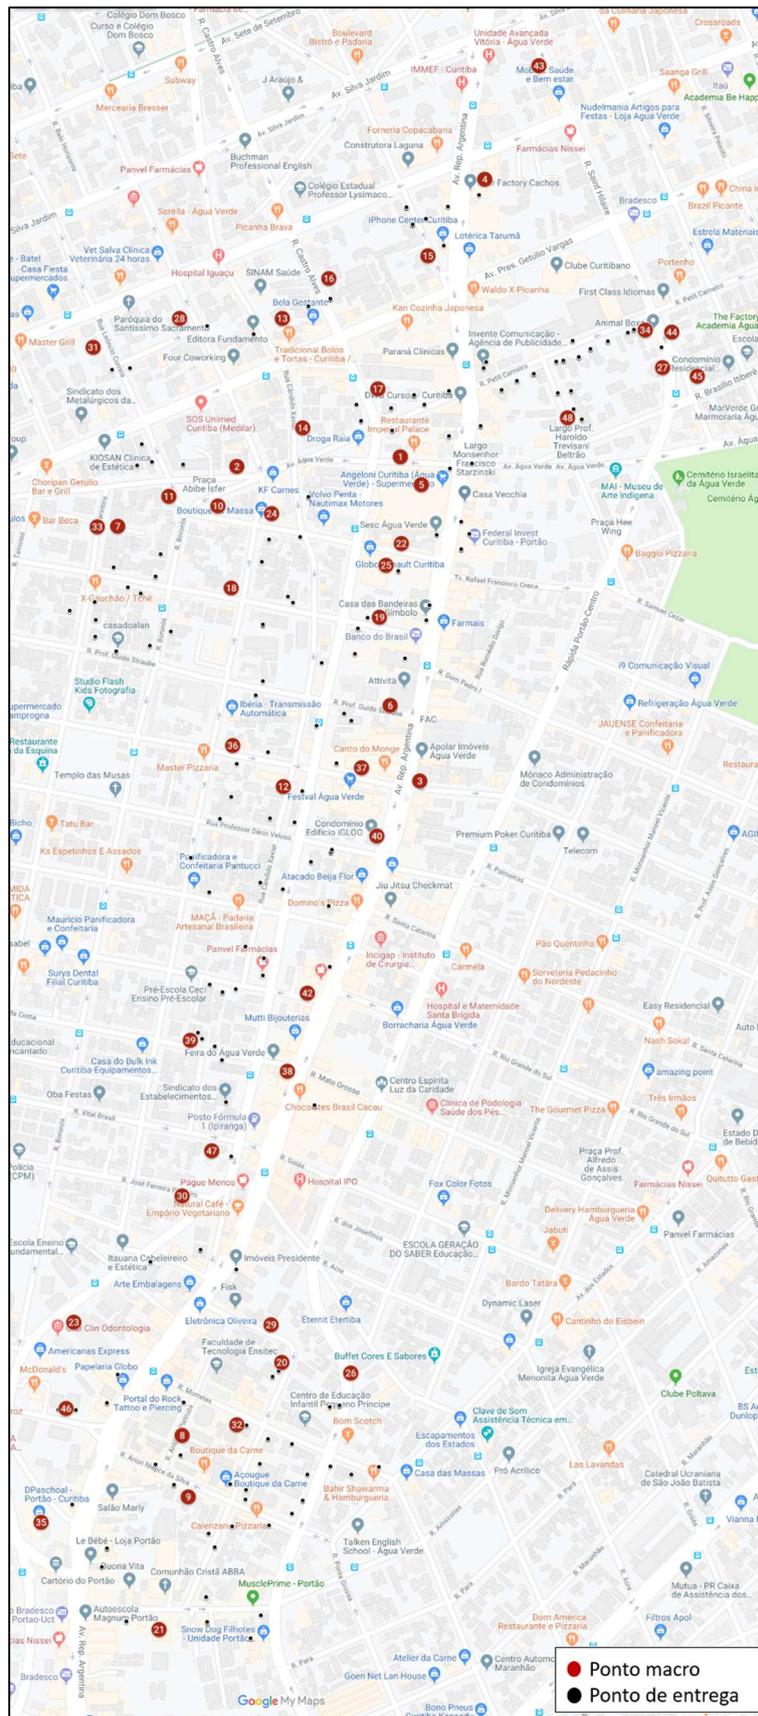
Na Tabela 2.1 estão apresentados cada um dos 48 pontos macros (fragmentos de rua), o número inicial e final do respectivo fragmento do logradouro, a quantidade de jornais (J), quantidade de revistas (R) e a soma da quantidade de itens (J+R) a serem entregues nos respectivos logradouros. A partir disso serão realizados os roteamentos das motocicletas. A Figura 2.3 apresenta os 479 endereços do roteiro (em preto) e os 48 pontos macro (em bordo).

Tabela 2.1 – Pontos macros para a distribuição da gráfica

Ref.	Logradouro	Nº ini.	Nº fim	J	R	J+R
1	Avenida Água Verde, Curitiba	1602	2000	4	2	6
2	Avenida Água Verde, Curitiba	2001	2468	1	0	1
3	Avenida República Argentina, Curitiba	334	790	27	13	40
4	Avenida República Argentina, Curitiba	791	1249	15	9	24
5	Avenida República Argentina, Curitiba	1278	2815	16	6	22
6	Rua Prof. Guido Straube, Curitiba	1	510	10	5	15
7	Rua Agostinho Narezi, Curitiba	1	20	1	1	2
8	Rua Antônio Pietruza, Curitiba	1	356	8	2	10
9	Rua Arion Niepce da Silva, Curitiba	1	9999	3	1	4
10	Rua Ary Guimaraes, Curitiba	1	100	1	0	1
11	Rua Bororos, Curitiba	1	252	5	2	7
12	Rua Candido Xavier, Curitiba	500	814	3	2	5
13	Rua Candido Xavier, Curitiba	815	1199	9	5	14
14	Rua Candido Xavier, Curitiba	1340	1730	4	1	5
15	Rua Carneiro Lobo, Curitiba	1	153	27	15	42
16	Rua Castro Alves, Curitiba	387	637	12	3	15
17	Rua Castro Alves, Curitiba	639	9999	11	7	18
18	Rua Cel. Ottoni Maciel, Curitiba	1	300	21	7	28
19	Rua Cel. Ottoni Maciel, Curitiba	301	600	12	5	17
20	Rua Eng. Arthur Bettet, Curitiba	1	500	29	18	47
21	Rua Eng. Niepce Silva, Curitiba	1	489	27	8	35
22	Rua Eurides Cunha, Curitiba	1	399	6	3	9
23	Rua Francisco Frischmann, Curitiba	1001	2599	6	5	11
24	Rua Guaianazes, Curitiba	1	300	1	0	1
25	Rua Guararapes, Curitiba	1000	2377	13	8	21
26	Rua Guilherme Pugsley, Curitiba	706	706	9	5	14
27	Rua Guilherme Pugsley, Curitiba	2301	3500	13	6	19
28	Rua Herculano Carlos Franco de Souza, Curitiba	500	899	16	5	21
29	Rua Joao Geara, Curitiba	1	157	17	2	19
30	Rua Jose Ferreira Pinheiro, Curitiba	1	136	1	1	2
31	Rua Leôncio Correia, Curitiba	350	615	6	4	10
32	Rua Morretes, Curitiba	1	499	15	9	24
33	Rua Parintins, Curitiba	1	299	10	7	17
34	Rua Petit Carneiro, Curitiba	801	1500	92	55	147
35	Rua Presidente Arthur da S. Bernardes, Curitiba	2251	9967	1	1	2
36	Rua Prof. Álvaro Jorge, Curitiba	239	295	8	2	10
37	Rua Prof. Álvaro Jorge, Curitiba	1	238	7	1	8
38	Rua Prof. Brasílio Ovídio da Costa, Curitiba	1	180	5	4	9
39	Rua Prof. Brasílio Ovídio da Costa, Curitiba	181	241	2	1	3
40	Rua Prof. Dario Velloso, Curitiba	7	282	18	9	27
41	Rua Prof. Octávio Da Silveira, Curitiba	1	600	1	0	1
42	Rua Prof. Ulisses Vieira, Curitiba	1	222	9	4	13
43	Rua Saint Hilaire, Curitiba	161	182	2	1	3
44	Rua Saint Hilaire, Curitiba	645	645	2	1	3
45	Rua Saint Hilaire, Curitiba	739	739	3	2	5
46	Rua Sylvio Zeny, Curitiba	1	100	1	1	2
47	Rua Vital Brasil, Curitiba	96	193	2	2	4
48	Travessa Percy Withers, Curitiba	1	130	21	7	28
Total:				533	258	791

Fonte: O autor.

Figura 2.3 – Endereços dos clientes da gráfica



Fonte: Adaptado de Google Maps.

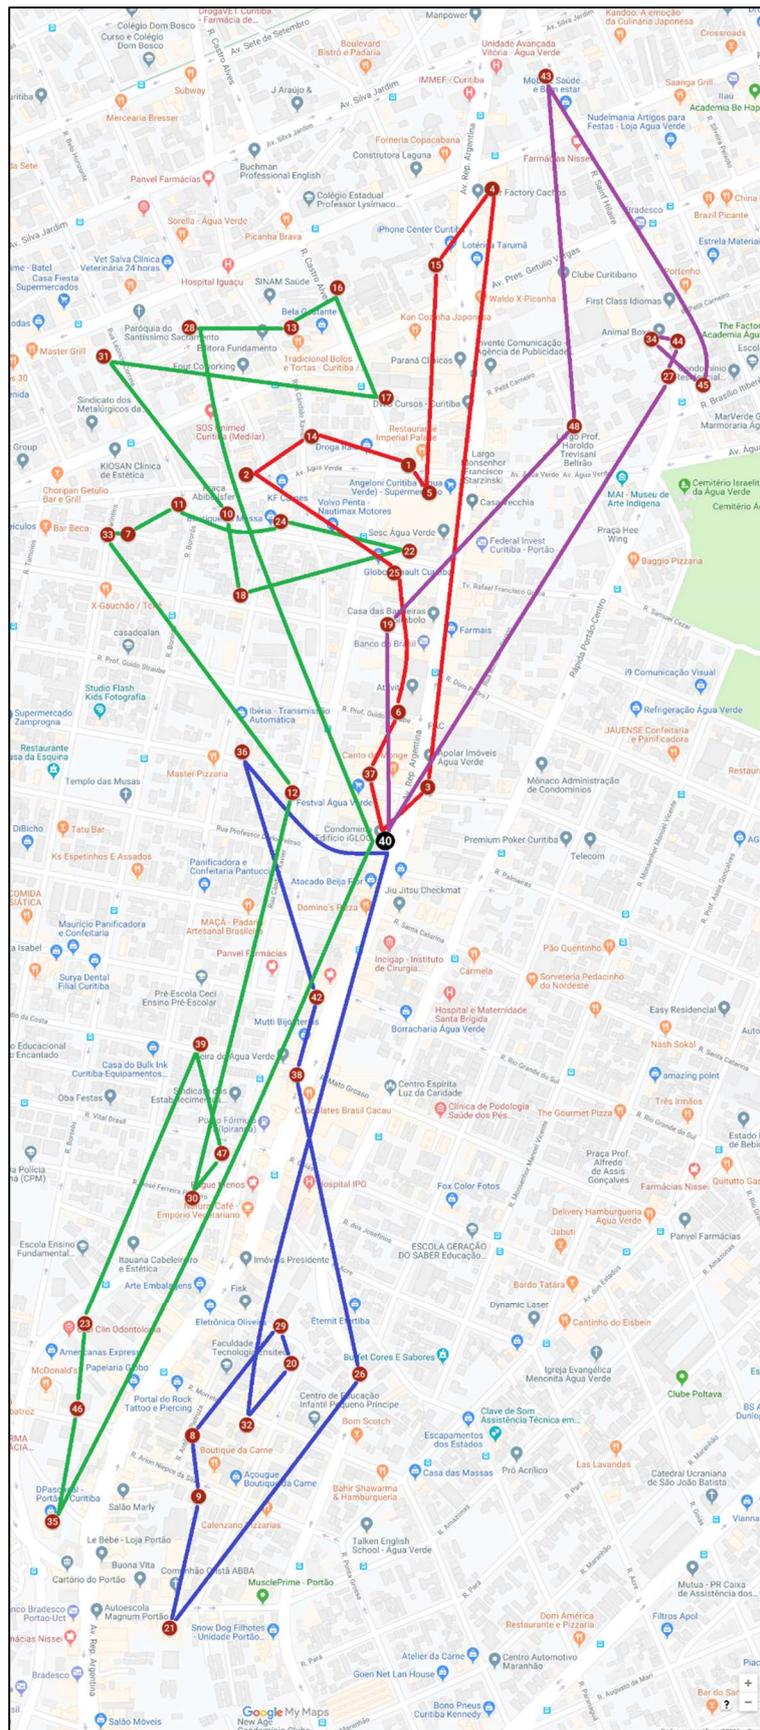
A Tabela 2.2 apresenta a Solução Atual adotada pela gráfica, que apresenta os roteiros, as distâncias de percorrida, os tempos de trajeto e as capacidades utilizadas dos veículos. A Figura 2.4 mostra a representação gráfica da respectiva roteirização.

Tabela 2.2 - Roteiros para a solução atual da gráfica

Referência	Distância (km)	Tempo (min)	Capacidade	Roteiro
Roteiro 1 (azul)	7,1	24,9	212	0-40-32-20-29-8-9-21-26-38-42-36-0
Roteiro 2 (verde)	12,7	45,0	172	0-35-46-23-39-47-30-12-33-7-11-24-22-18-10-31-17-16-13-28-0
Roteiro 3 (vermelho)	5,9	24,2	201	0-37-6-25-2-14-1-5-15-4-3-0
Roteiro 4 (roxo)	5,4	19,3	206	0-19-48-43-45-34-44-27-0
Total	31,1	113,2	791	-

Fonte: O autor.

Figura 2.4 – Representação dos roteiros da solução atual da gráfica



Fonte: O autor.

Vale ressaltar algumas considerações do problema a respeito da gráfica:

- a) Os funcionários trabalham em escalas, a fim de atender o processo de impressão e distribuição dos jornais;
- b) Não existe uma sequência operacional estabelecida para a entrega dos jornais, ou seja, o entregador é responsável pela sequência de entrega do seu setor;
- c) Não existe janela de tempo, ou horários fixados pelos clientes para o recebimento dos J ou JR (todos os clientes aceitam ser atendidos até o período matutino de sábado);
- d) Existe a oportunidade de os clientes solicitarem o reenvio do jornal, caso o mesmo não seja entregue ou não esteja em boas condições;
- e) Não foi estabelecido um limite de volume da capacidade do veículo, embora o ideal seja de até 210 volumes;
- f) Ocorreram situações em que o motoboy visivelmente levou mais jornais do que a capacidade da moto;
- g) Não foi estabelecida uma duração máxima para os roteiros;
- h) Para a rota específica deste estudo, o entregador está dedicado a realizar apenas a entregas dos J e, também, JR;
- i) A empresa tem autonomia para utilizar os roteiros do setor da forma que melhor lhe convier;
- j) Os percursos são, em sua maioria, assimétricos, pois no município de Curitiba-PR, existem muitas ruas de sentido único;
- k) O caso do “encalhe”, (ou seja, o jornal que não foi vendido) e das “entregas de bicicleta” não serão abordados nesta pesquisa.

2.2 ESTUDO DE CASO 2 – TRANSPORTE DE FUNCIONÁRIOS

O segundo estudo de caso é referente ao processo de transporte de passageiros (funcionários) para uma fábrica e, também, será utilizado para ilustrar a metodologia aqui adotada para a resolução de um MOOGVRP.

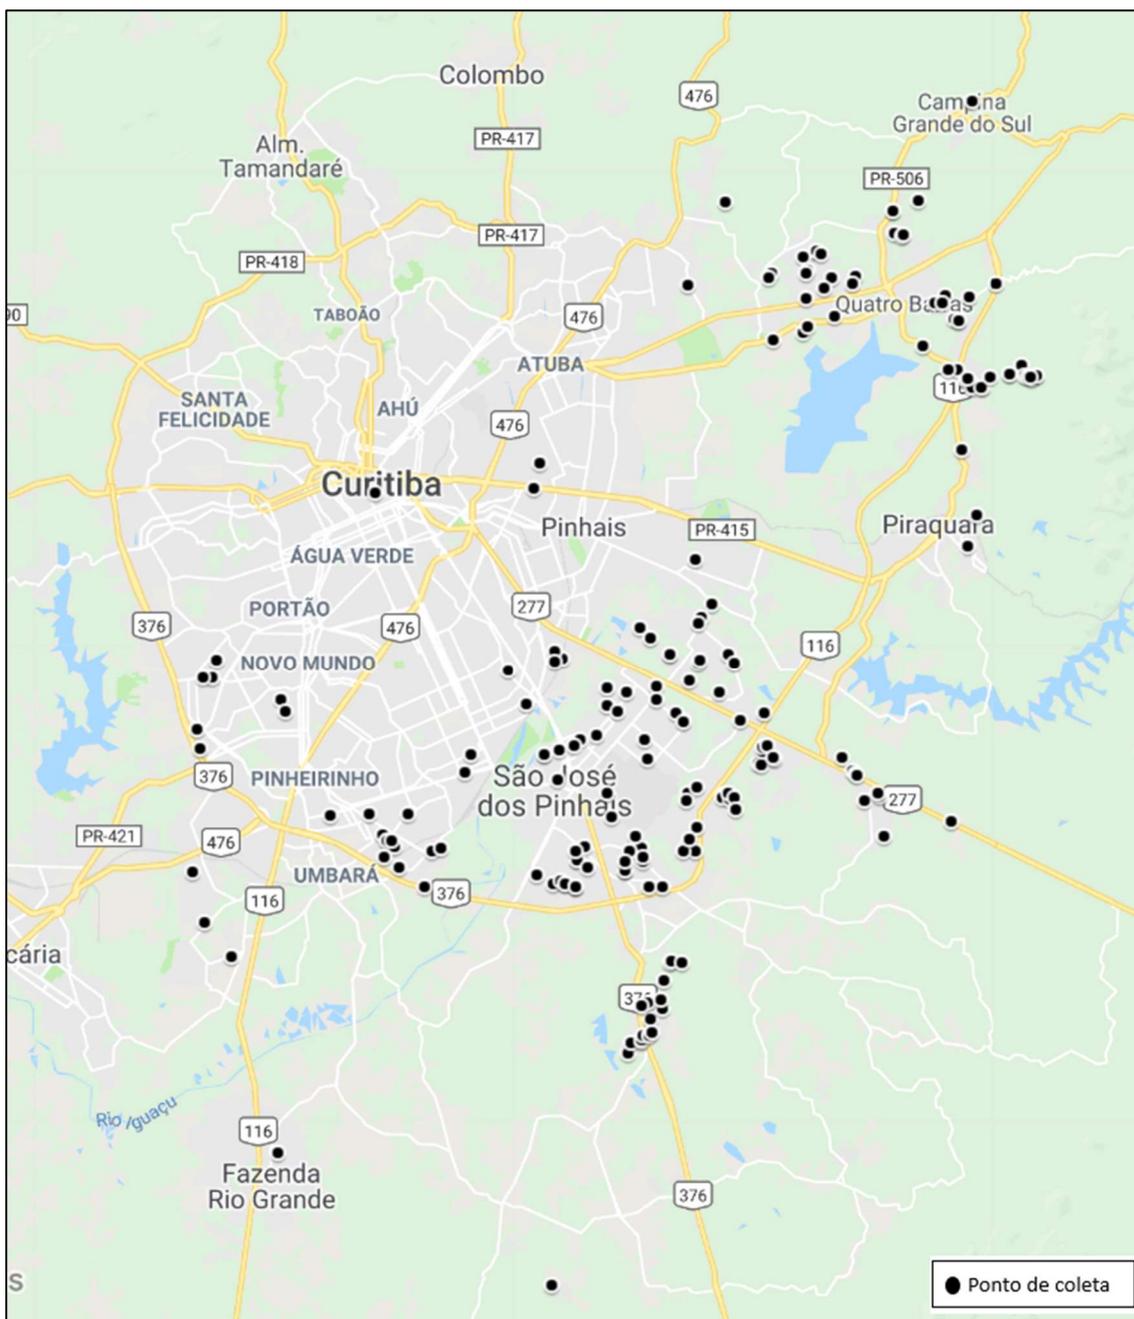
No município de São José dos Pinhais-PR está localizada uma empresa de transporte de passageiros, cujo negócio principal é o transporte de

funcionários no trajeto “casa para empresa” e vice-versa. Esse transporte ocorre geralmente em turnos, acompanhando os horários de entrada e saída dos turnos dos funcionários da empresa. O primeiro turno é das 6:00h até as 14:00h, o segundo é das 14:00h até as 22:00h, o terceiro é das 22:00h até as 6:00h do dia seguinte, por fim, o quarto turno ocorre no horário administrativo. Sendo assim, existem 8 grupos de rotas necessárias a serem executadas.

O tamanho de cada grupo de rotas varia de acordo com a demanda de funcionários. No contexto inicial, a empresa utiliza para o transporte micro-ônibus com capacidade para 31 passageiros, estando a divisão e definição dos roteiros restrita a essa capacidade e aos endereços dos funcionários que utilizam a rota. Destaca-se que existe um tempo limite de permanência de uma hora e trinta minutos dos funcionários dentro dos ônibus, tempo esse que atualmente não é cumprido na maioria das rotas executadas pela empresa em todos os turnos.

O grupo de rotas selecionado para análise é o de funcionários do primeiro turno em seu trajeto de ida de “casa para a empresa”. Nesse grupo de rotas, são utilizados atualmente 8 veículos. São transportados 199 funcionários que residem em Curitiba-PR e região metropolitana (São José dos Pinhais, Campina Grande do Sul, Quatro Barras e Colombo) até a empresa localizada em São José do Pinhais-PR. A Figura 2.5 apresenta os pontos de coleta (endereços) dos funcionários.

Figura 2.5 – Endereços dos funcionários do primeiro turno



Fonte: O autor.

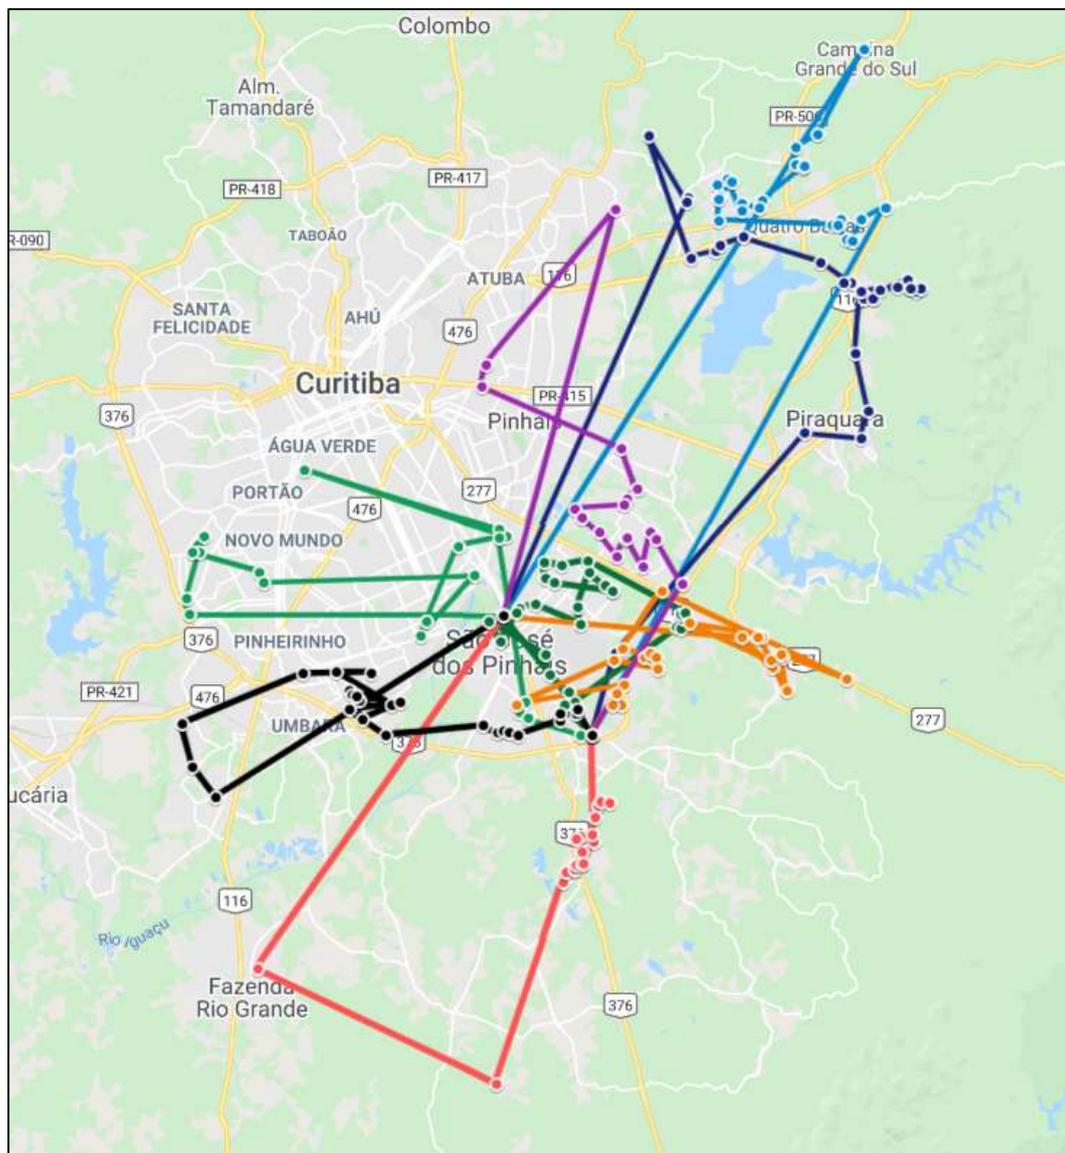
A Tabela 2.3 apresenta um resumo da situação atual, considerando o respectivo roteiro (linha), a quantidade de passageiros, a taxa de ocupação do veículo, o tempo de percurso para a coleta dos funcionários (aqui não é considerado o tempo que leva da garagem até o primeiro ponto de coleta) e a distância total do percurso correspondente. A Figura 2.6 apresenta os roteiros executados por ocasião da pesquisa.

Tabela 2.3 - Situação atual das rotas

Referência	Passageiros	Ocupação (%)	Tempo de coleta (min)	Distância total (km)
Linha 1	26	83,8	74	78
Linha 2	31	100,0	84	65
Linha 3	32	103,2	90	60
Linha 4	20	64,5	85	59
Linha 5	27	87,1	72	73
Linha 6	18	58,0	90	72
Linha 7	30	96,7	80	73
Linha 8	18	58,1	90	87

Fonte: O autor.

Figura 2.6 – Roteirização atual das rotas



Fonte: O autor.

Destaca-se ainda que há um acordo que estabelece que os funcionários podem ser obrigados a se deslocar até 250 metros de sua residência para ter a facilidade do transporte fretado. Esse detalhe poderia gerar uma economia grande de deslocamento em cada linha caso fosse praticado em todo o seu potencial. Porém, o fato de que, para o grupo de rotas analisado, o horário que a rota é executada ocorre em torno de 4 e 5 horas da manhã, tornando inseguro o deslocamento de muitos usuários do transporte devido à localização de suas casas e ao fato de que há muitas funcionárias mulheres entre os usuários.

Vale ressaltar algumas considerações a respeito da empresa, além das já descritas anteriormente:

- a) Não existe janela de tempo;
- b) Preferencialmente, o percurso não deve ultrapassar uma hora e trinta minutos (90min);
- c) O ônibus tem um limite de capacidade de 31 lugares mais o motorista;
- d) Não há restrições que impeçam que determinados endereços pertençam a um mesmo roteiro;
- e) Não foi estabelecido que os roteiros devessem estar obrigatoriamente equilibrados (balanceados, ou seja, com aproximadamente a mesma demanda);
- f) A empresa tem autonomia para utilizar os roteiros da forma que lhe for conveniente e;
- g) Os percursos são, em sua maioria, assimétricos, pois nos municípios analisados existem muitas ruas de sentido único.

3 REVISÃO SISTEMÁTICA

Neste capítulo será abordado o *Green PRV*, a revisão bibliométrica da literatura relacionada ao tema aqui abordado e alguns trabalhos correlatos.

3.1 *Green PRV*

Para abordar o *Green VRP* neste trabalho, foi utilizada a classificação proposta por Lin et al. (2014). Assim, o *Green VRP* ficou classificado como: *VRPFuel*, *Pollution Routing Problem (PRP)* e *VRP in Reverse Logistics*.

O *VRPFuel* trata da otimização do consumo de energia no transporte e da redução do consumo de combustível; o Problema de Roteamento da Poluição (*PRP*) visa escolher um esquema de roteamento de veículos com uma quantidade menor de poluição, em particular, com a redução de emissões de GHG, podendo também incluir objetivos mais amplos que refletem ao custo ambiental. Já o *VRP in Reverse Logistics (VRPRL)* concentra-se nos aspectos de distribuição da logística reversa. O *VRPRL*, por sua vez, é subdividido em quatro categorias: *Selective Pickups with Pricing*, *Waste Collection*, *End-of-life Goods Collection* e *Simultaneous Distribution and Collection*.

a) *Selective Pickups with Pricing* (Coleta seletiva com preços) - É caracterizado por selecionar somente pontos de retirada rentáveis para visitar e fazer a operação de coleta mais lucrativa possível.

b) *Waste Collection* (Recolha de resíduos) - A gestão de resíduos, incluindo a evasão de resíduos, reutilização e reciclagem, é um processo chave na proteção do meio ambiente e na conservação de recursos.

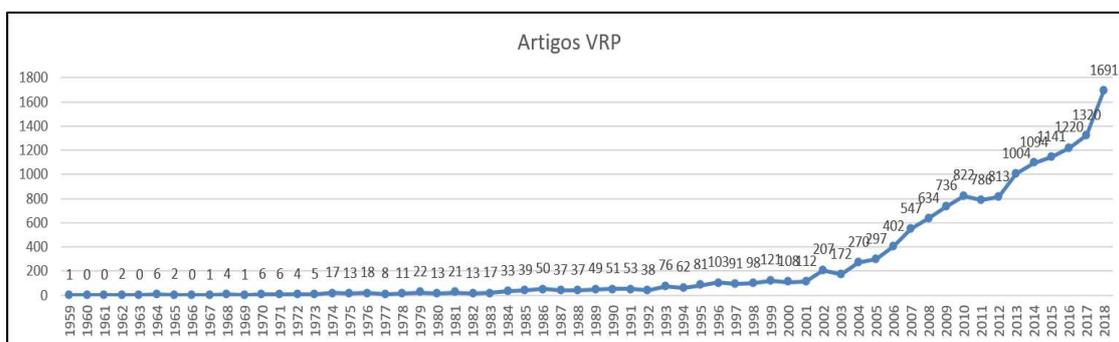
c) *End-of-life Goods Collection* (Coleção de bens de fim de vida) – Trata do recolhimento de alguns componentes dos produtos em fim de vida para beneficiar o fabricante original, pois os materiais ou componentes reciclados permanecem funcionais após posterior eliminação ou remanufatura.

d) *Simultaneous Distribution and Collection* (Distribuição e coleta simultânea) – Trata do *VRP* com entrega e coleta simultânea e é formulado como um processo de distribuição da logística reversa.

3.2 REVISÃO BIBLIOMÉTRICA DA LITERATURA

Com base na revisão da literatura pode-se dizer que o assunto de VRP é bastante relevante para os pesquisadores, como pode ser observado pelo número de artigos publicados na base da Scopus de acordo com a Figura 3.1, de 1959 a 2018. A Figura 3.1 foi obtida a partir dos resultados do protocolo de pesquisa (definido na seção 3.2.1 mais adiante) utilizado no *site* da Scopus, por conta da facilidade de realizar análises gráficas da amostra. O crescimento de publicações vem se acentuando cada vez mais desde 2002, com cerca de 200 publicações até 2018, com aproximadamente 1.700 publicações.

Figura 3.1 - Número de publicações por ano relacionado ao PRV



Fonte: o autor.

Nas seções a seguir são apresentados os procedimentos metodológicos para a definição do protocolo de pesquisa e a análise bibliométrica do MOOGVRP.

3.2.1 Procedimentos Metodológicos

Para a revisão bibliométrica desta pesquisa, o protocolo de busca consistiu dos seguintes passos:

- (1) Inicialmente, ficou estabelecido com “corte do tempo”, o período de 2012 a 2018, com o intuito de compreender quais são as discussões recentes a respeito do tema analisadas pela academia;
- (2) Seleção de base de dados: foi utilizada uma base de dados brasileira da CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior), que

reúne e disponibiliza conteúdo científico internacional para instituições de ensino e pesquisa no Brasil, composta por 38.000 periódicos, 532 bases de dados de referência, incluindo o *Cambridge Journals Online*, o *Emerald Insight Emerald*, o *IEEE Xplore*, o *Scopus* (Elsevier), o *Science Direct*, o *SpringerLink*, o *Taylor & Francis* e outros mais, além de livros, enciclopédias, normas técnicas, estatísticas e conteúdo audiovisual (SZEJKA et al., 2017).

(3) O inglês foi adotado com idioma para os artigos selecionados;

(4) Foram pesquisados somente periódicos (artigos);

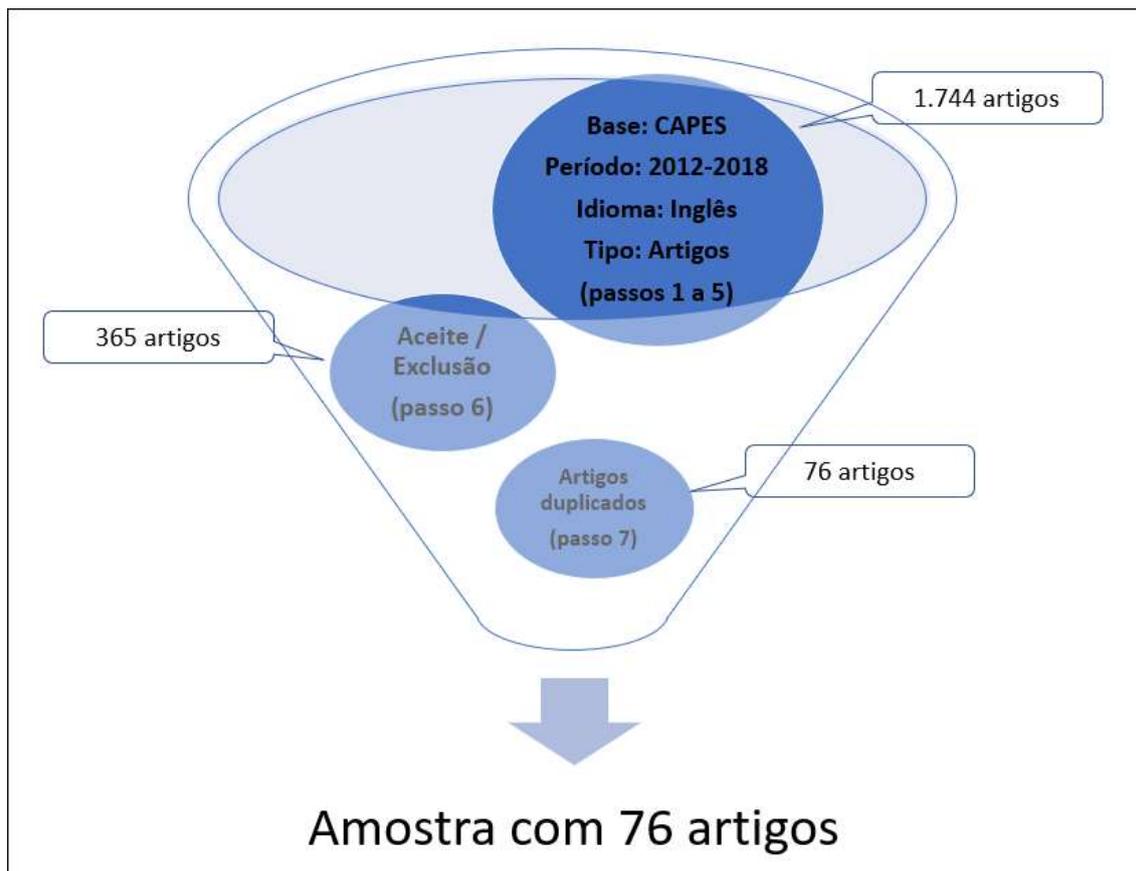
(5) As palavras-chaves, assim como os operadores lógicos utilizados foram: “*green vehicle routing problem*” OR “*pollution routing problem*” OR “*vehicle routing problem in reverse logistics*”, sendo estes obrigatoriamente relacionados com “*multiobjective*” OR “*multi-objective*” OR “*bi-objective*”. Também foram consideradas as possíveis variações de sufixo nos termos utilizados;

(6) Como critério de aceite ficou estabelecido que: (i) o resultado de pesquisa deveria apresentar, além dos termos citados, estar relacionado aos assuntos “*green vehicle routing problem*”, “*pollution routing problem*” ou “*vehicle routing problem in reverse logistics*”, sendo todos de caráter “multi-objetivo”. Para isso foram avaliados os títulos e resumos; (ii) poderiam ser artigos de revisão, modelagem matemática, melhoria de algoritmo ou estudos de caso relacionados ao tema proposto. Já os critérios de exclusão ficaram estabelecidos da seguinte forma: (i) resultados de pesquisa não relacionados ao tema proposto; (ii) não possuir texto completo disponível;

(7) Retirar artigos duplicados.

A partir do protocolo apresentado obteve-se 1.744 resultados de pesquisa, que após o filtro do protocolo resultou em 76 artigos, de 38 periódicos, para a amostra da pesquisa. A Figura 3.2 apresenta o fluxograma da filtragem dos artigos.

Figura 3.2 – Fluxograma da filtragem dos artigos



Fonte: O autor.

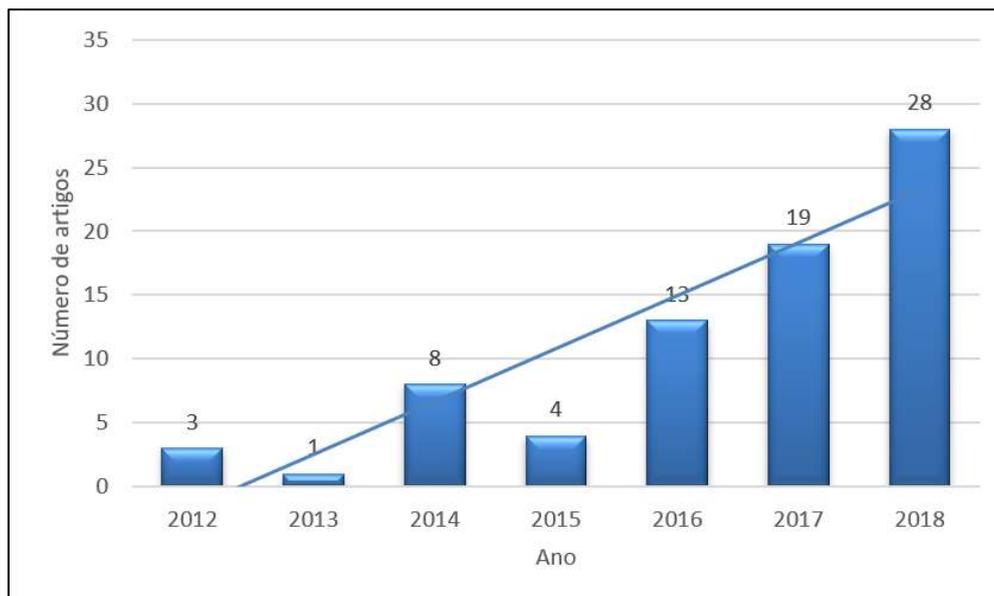
A partir desta seleção dos artigos foi realizada uma análise crítica do escopo da pesquisa, onde buscou-se responder a duas questões:

- 1) Quais as pesquisas mais relevantes em relação ao MOOGVRP?
- 2) Quais são as tendências em relação ao MOOGVRP que possam nortear pesquisas futuras?

3.2.2 Dados Bibliométricos

Seguindo o procedimento apresentado na seção 3.2.1 anterior, a amostra desta pesquisa ficou composta por 76 artigos. A Figura 3.3 mostra que o número de artigos sobre o tema proposto tem sido crescente com o passar dos anos, a partir de 2012 até 2018.

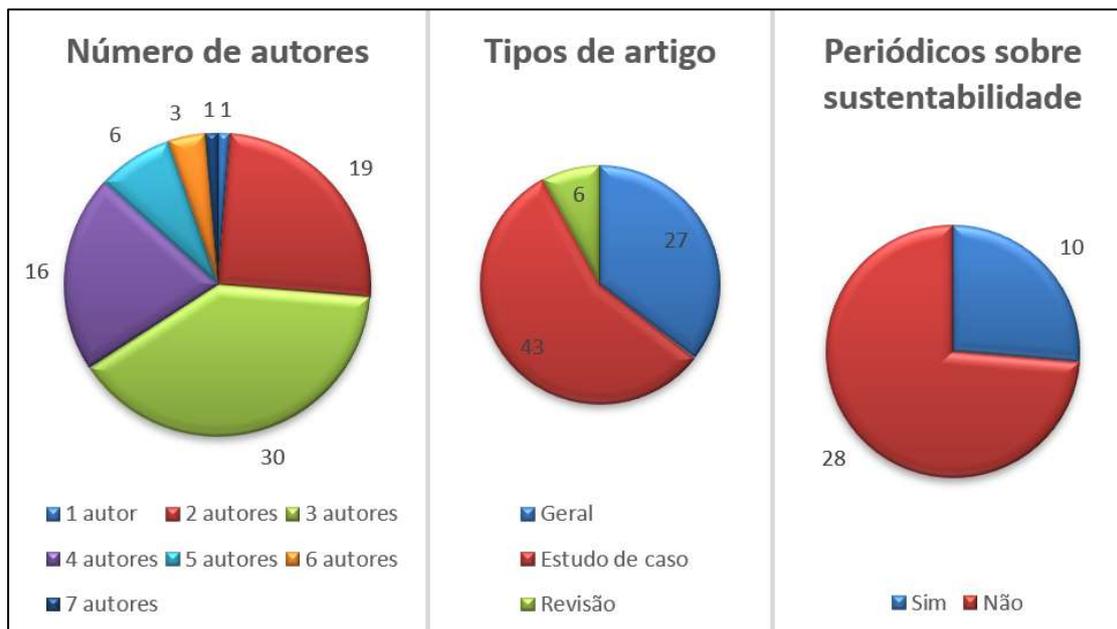
Figura 3.3 - Distribuição por ano das 76 publicações da amostra sobre o MOOGVRP



Fonte: O autor.

Na Figura 3.4 têm-se as quantidades do número de autores (lado esquerdo); dos tipos de artigo (centro) e dos artigos publicados em periódicos voltados à sustentabilidade (lado direito) dentre os 76 artigos da amostra. Pode-se observar que os artigos com dois, três e quatro autores correspondem a 86% da amostra, o que evidencia a existência de grupos de pesquisa ou trabalhos desenvolvidos em ambientes acadêmicos. Do total de artigos, 27 (36% do total) foram classificados em Geral, 43 (57%) em Estudos de caso e 6 (8%) em Revisões. Foi verificado, ainda, que apenas 10 dos 38 periódicos dos artigos da amostra focam questões relacionadas à considerações ambientais (mais especificamente, mostram interesse em aspectos ambientais, sustentabilidade, ecologia, fabricação verde, ambiente e contextos relacionados): *Applied Energy*, *Computers & Operations Research*, *Decision Science Letters*, *Ecological Indicators*, *International Energy & Environment*, *Journal of Cleaner Production*, *Journal of Manufacturing Systems*, *Journal of Manufacturing Technology Management*, *Sustainability* e *Transportation Research Part D*.

Figura 3.4 - Quantidades: do número de autores (lado esquerdo); do tipo de artigo (centro) e dos artigos publicados em periódicos voltados à sustentabilidade (lado direito) dentre os 76 da amostra



Fonte: O autor.

A Tabela 3.1 apresenta a listagem dos periódicos mais utilizados na amostra. Vale destacar que os periódicos marcados com (*) consideram aspectos da sustentabilidade.

Tabela 3.1 - Periódicos mais utilizados

Periódico	Quantidade
<i>Journal of Cleaner Production*</i>	9
<i>Transportation Research Part E</i>	8
<i>Mathematical Problems in Engineering*</i>	6
<i>European Journal of Operational Research</i>	4
<i>Computers & Industrial Engineering, Expert Systems with Applications and International Journal of Production Economics e Transportation Research Part D*</i>	3
<i>Annals of Operations Research, IEEE*, Journal of Industrial Engineering International, Omega (United Kingdom), Operational Research e Transportation Research Part C</i>	2
Outros	23

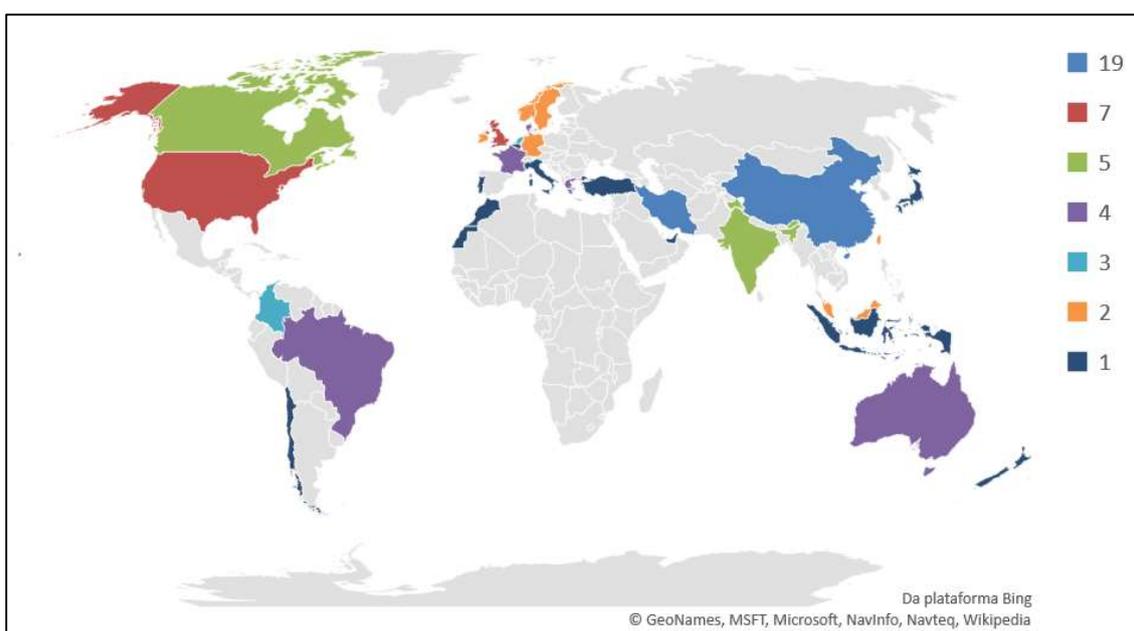
Fonte: O autor.

Outros: *Applied Computational Intelligence and Soft Computing, Applied Energy, Applied Mathematics and Computation*, Applied Soft Computing, Complexity, Computers & Operations Research, Decision Science Letters, Dyna*, Ecological Indicators, Energy Systems**,

*Engineering Applications of Artificial Intelligence**, *Grey Systems: Theory and Application*, *International Energy & Environment*, *International Journal of Advanced Research in Computer Science*, *International Journal of Industrial Engineering Computations*, *International Journal of Supply and Operations Management*, *Journal of Manufacturing Systems*, *Journal of Manufacturing Technology Management**, *Networks*, *Optimization Letters*, *Sensors*, *Transportation Research Part A** e *Transportation Research Part B*.

Já a Figura 3.5 apresenta a frequência de publicação dos 31 países participantes da amostra de 76 artigos. Vale destacar que a China, o Irã, os Estados Unidos e o Reino Unido, contribuíram com 19, 19, 7 e 7 artigos respectivamente.

Figura 3.5 - Países que têm contribuído para o MOOGVRP



Fonte: O autor.

A Tabela 3.2 apresenta a listagem das afiliações relacionadas à amostra de pesquisa, considerando as instituições, centros de pesquisa e empresas de onde os autores estão vinculados. Observe-se que vários artigos contemplam mais do que uma afiliação. Em destaque estão três universidades do Irã, *University of Tehran*, *Iran University of Science and Technology* e *Islamic Azad University*, com 6, 5 e 5 artigos respectivamente.

Tabela 3.2 - Instituições que mais contribuíram para o MOOGVRP

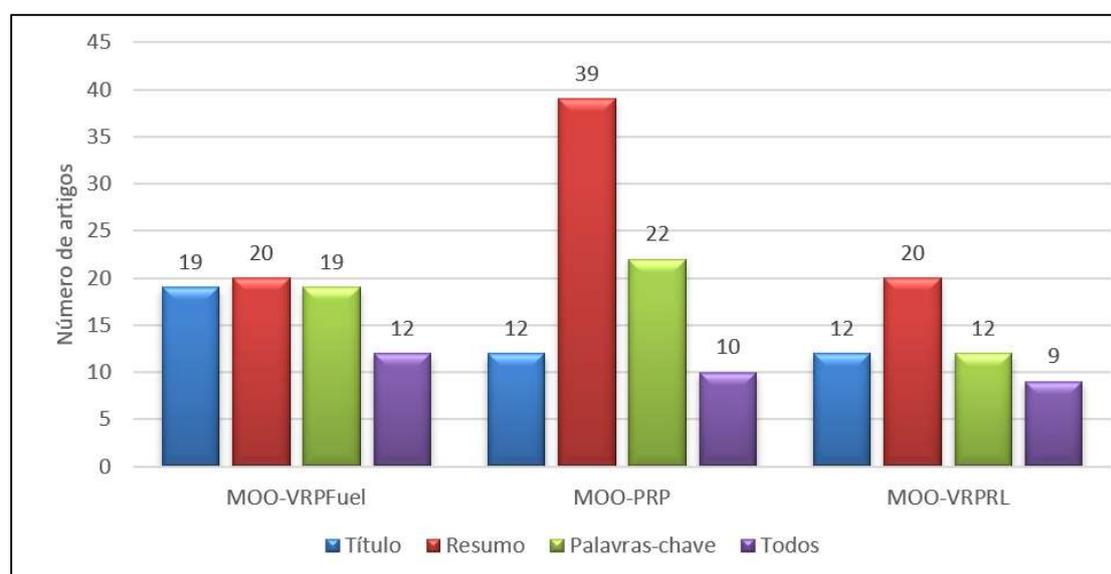
Afiliação	Quantidade
<i>University of Tehran</i>	6
<i>Iran University of Science and Technology and Islamic Azad University</i>	5
<i>Aristotle University of Thessaloniki, Universidade Federal de Minas Gerais and University of Southern Denmark</i>	3
<i>Aalborg University, Amirkabir University of Technology, Eindhoven University of Technology, EMLYON Business School, Hunan University, The Hong Kong Polytechnic University, Universidad Tecnológica de Pereira, Universidade Estadual Paulista Júlio de Mesquita Filho and University of Southampton.</i>	2
Outros.	96

Fonte: O autor.

Outros: 2CRRC Zhuzhou Institute Co., Ltd.; Allame Tabataba'i University Business School; Arts et Métiers Paris Tech; Athens University of Economics and Business; Beijing University of Aeronautics and Astronautics; Canada Research Chair in Distribution Management, Interuniversity Research Centre on Enterprise Networks, Logistics, and Transportation; Chang'an University; China University of Mining and Technology; Chongqing Jiaotong University; Dalian Maritime University; Democritus University of Thrace; Dongbei University of Finance and Economics; Dublin City University; Dublin City University Business School; Erasmus University Rotterdam; ESC Rennes School of Business; Faculty of Engineering (Turkey); Fujian Agriculture and Forestry University; Fuzhou University; Grupo da Causa Humana; HEC Montréal; Hefei University of Technology; Hunan University of Science and Technology; Ibn Zohr University; IEAv – Institute for Advanced Studies; Indian Institute of Technology; Institución Universitaria CEIPA; Instituto de Pesquisa e Desenvolvimento de Tecnologias; Instituto Universitário de Lisboa; Isfahan University of Technology; Jeppesen Manager Government and Military Aviation; K. N. Toosi University; K. N. Toosi University of Technology; Karlsruhe Institut für Technologie; Kharazmi University; Lancaster University Management School; Liverpool John Moores University; Luleå University of Technology; Missouri University of Science and Technology; Nagoya University; Nanyang Technological University; Narvik University College; National Chi Nan University; National Institute of Industrial Engineering; North Carolina A&T State University; Oregon State University; Pontificia Universidad Católica de Valparaíso; PSG College of Technology; Rayalaseema University; S K University; Shandong University of Science and Technology; Shanghai Jiao Tong University; Shanghai Maritime University; Sichuan University; Singapore Institute of Manufacturing Technology; Southwest Jiaotong University; Swinburne University of Technology; Tarbiat Modares University; Technical University of Crete; Technische Universität Dresden; The Fuzhou University of Management; The Southeast University of Economics and Management; The University of Auckland; The University of Hong Kong; The Wuhan University of Technology; Tongji University; UAE University; Universidad de San Buenaventura; Universidad Nacional de Colombia; Universidade de Lisboa; Universidade do Estado do Rio de Janeiro; Universidade Federal de Ouro Preto; Universidade Federal Fluminense; Universidade Nova de Lisboa; Universitat Politècnica de València; Université de Lyon; Università Tunku Abdul Rahman; University of British; University of Connecticut; University of Delhi; University of East Anglia; University of Electronic Science and Technology; University of Hamburg; University of Huddersfield; University of Memphis; University of New South Wales; University of Science and Technology of Mazandaran; University of Sheffield; University of Vienna Oskar-Morgenstern-Platz; University of Washington; University of Wisconsin–Madison; University of Southern Denmark; Vienna University of Economics and Business Welthandelsplatz; Wageningen University; Zhejiang Gongshang University and Zhejiang University of Technology.

A Figura 3.6 apresenta o percentual da presença dos termos (ou termos aproximados) do protocolo de pesquisa nos títulos, resumos, palavras-chaves e, também, simultaneamente nos três anteriores. Neste contexto, o grupo VRPFuel contém 28 artigos, o PRP com 41, VRPRL com 20 artigos, todos multi-objetivo. Esta relação fica mais clara na Figura 3.7. Esta análise é de grande importância para a pesquisa, pois é por meio destes termos que os pesquisadores concretizam a amostra de seus trabalhos. Pode-se notar que a maior frequência dos termos se concentra no resumo dos artigos e que são poucos os trabalhos que contêm os termos de pesquisa nos três campos.

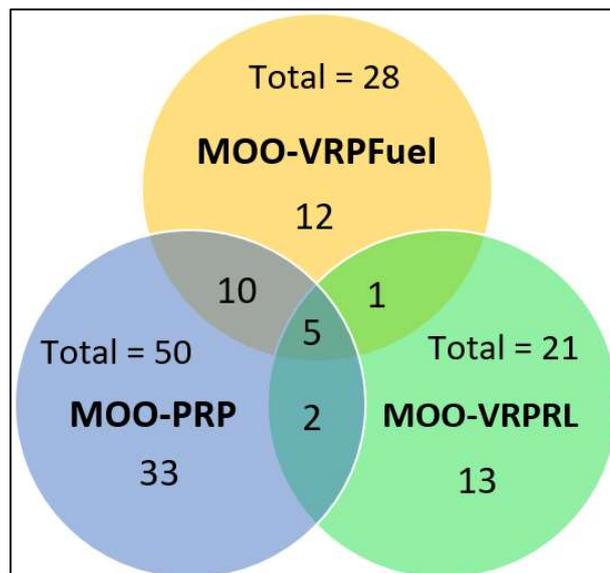
Figura 3.6 - Frequência dos termos do protocolo de pesquisa nos títulos, resumos e palavras-chaves dos 76 artigos



Fonte: O autor.

A Figura 3.7 apresenta as relações entre as taxonomias do VRP com as considerações ambientais abordadas. Foi observado que alguns autores desconsideram a taxonomia ou acabam “confundindo” o objetivo do VRPFuel com o PRP, onde o primeiro tem o objetivo de reduzir o consumo de energia (ou a bateria, alternativamente) ou combustível e o segundo busca a minimização da emissão de GHG, principalmente o CO₂.

Figura 3.7 - Relação da amostra da pesquisa sobre as taxonomias do MOO-VRP com considerações ambientais

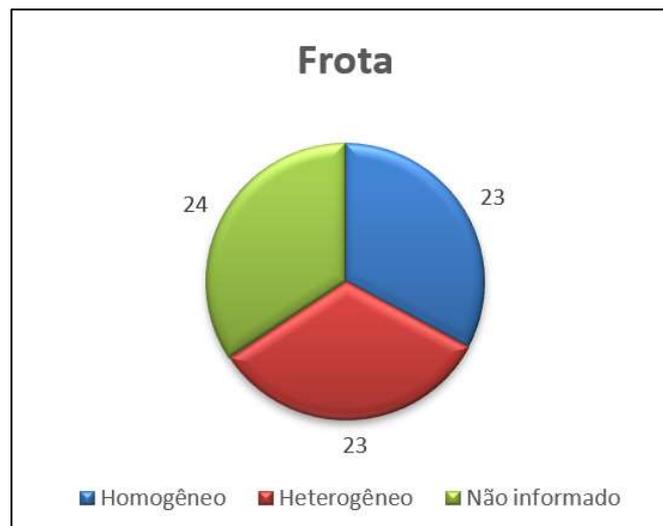


Fonte: O autor.

Observe-se nesta Figura 3.7 (círculo amarelo), que 28 artigos da amostra abordam o VRPFuel; 10 deles abordam o VRPFuel em conjunto com o PRP; 5 deles abordam o VRPFuel em conjunto com o PRP e, também, com o VRPRL e, finalmente, 1 artigo aborda o VRPFuel em conjunto com o VRPRL. De forma análoga pode-se realizar a interpretação dos demais círculos (à esquerda e à direita).

As Figuras 3.8 a 3.13 estão relacionados aos artigos categorizados em Aplicação Geral e Estudos de Caso (70 artigos). Os artigos de revisão (6 artigos) não serão considerados nestas figuras por conta de sua vasta abrangência. Na Figura 3.8, tem-se a classificação da frota (homogênea ou heterogênea) pelos artigos da amostra. Em função da limitação de alcance, em contextos práticos, foi necessário adotar uma solução híbrida, ou seja, parte da frota com combustível alternativo e parte com combustível padronizado, isso é, a gasolina, entre outras variações (DEMIR et al., 2014a).

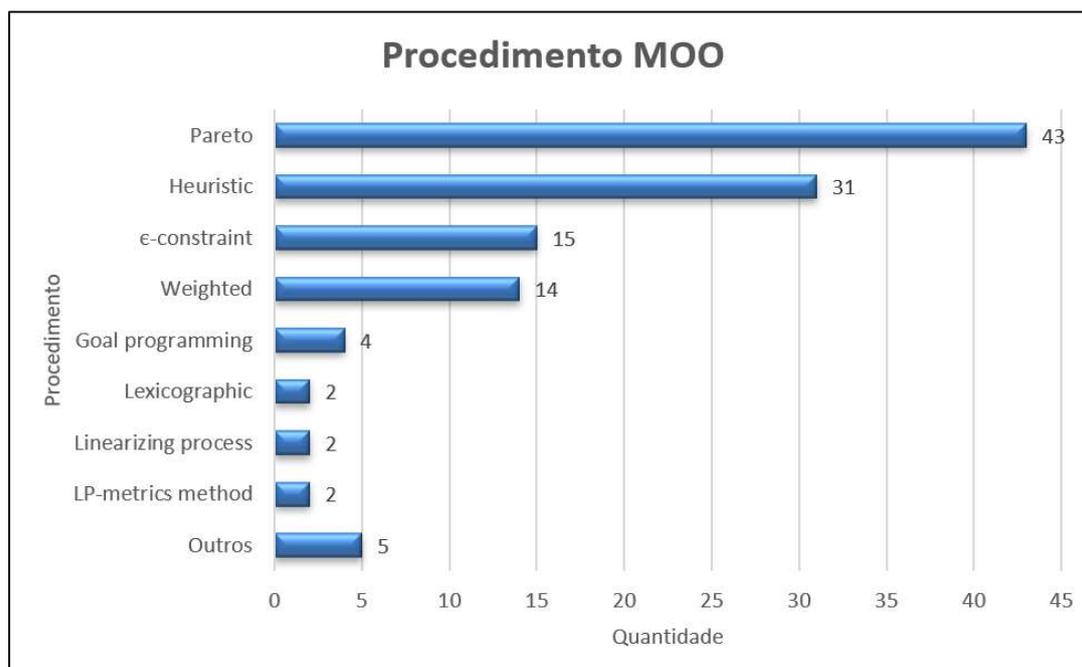
Figura 3.8 - Tipo de frota utilizada pela amostra de 70 artigos



Fonte: O autor.

Em relação aos procedimentos de MOO, Figura 3.9, pode-se verificar uma predominância no uso do Pareto para analisar a dominância ou não-dominância das soluções obtidas. Na sequência está ranqueado o uso de procedimentos heurísticos, ϵ -constraint e *weighted*. Observe-se que vários artigos contemplam mais o que um procedimento.

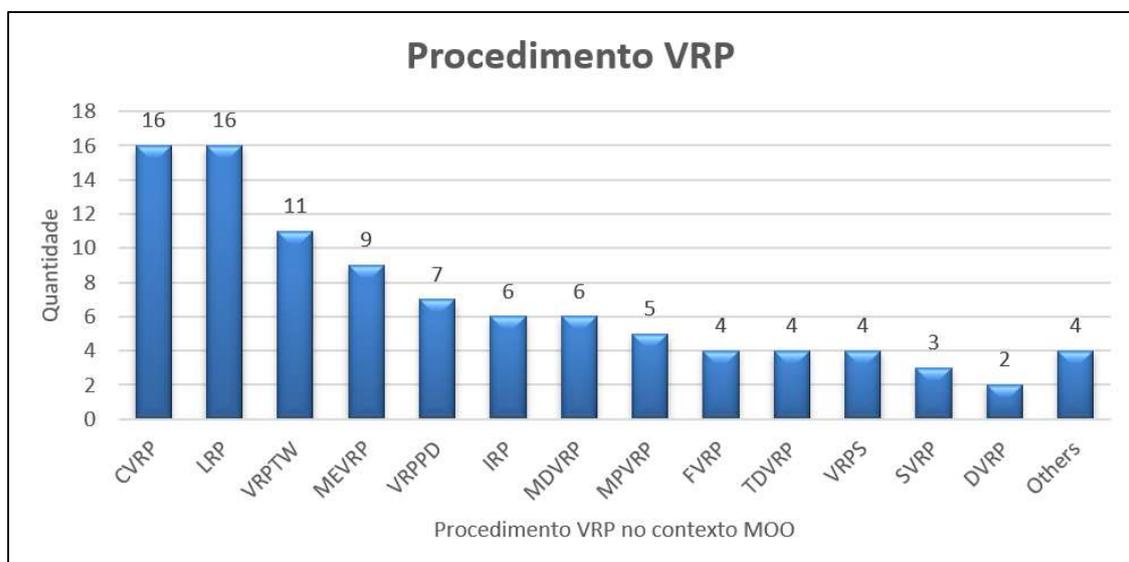
Figura 3.9 - Abordagens multi-objetivos mais utilizadas no MOOGVRP pela amostra dos 70 artigos



Fonte: O autor.

Quanto aos procedimentos de VRP, Figura 3.10, deve-se levar em consideração que um mesmo problema pode conter mais de uma variante, como os trabalhos desenvolvidos por Ramos et al., 2014; Ghezavati e Beigi, 2016; Govindan et al., 2016; Rabbani et al., 2018. O *Location Routing Problem* (LRP) e o caso clássico (*Capacitated VRP*) apresentaram a maior frequência de uso na amostra, seguido por *Time Windows*, *Multi-echelon* e *Pickup and Delivery*.

Figura 3.10 - Procedimentos de solução mais utilizados no MOOGVRP

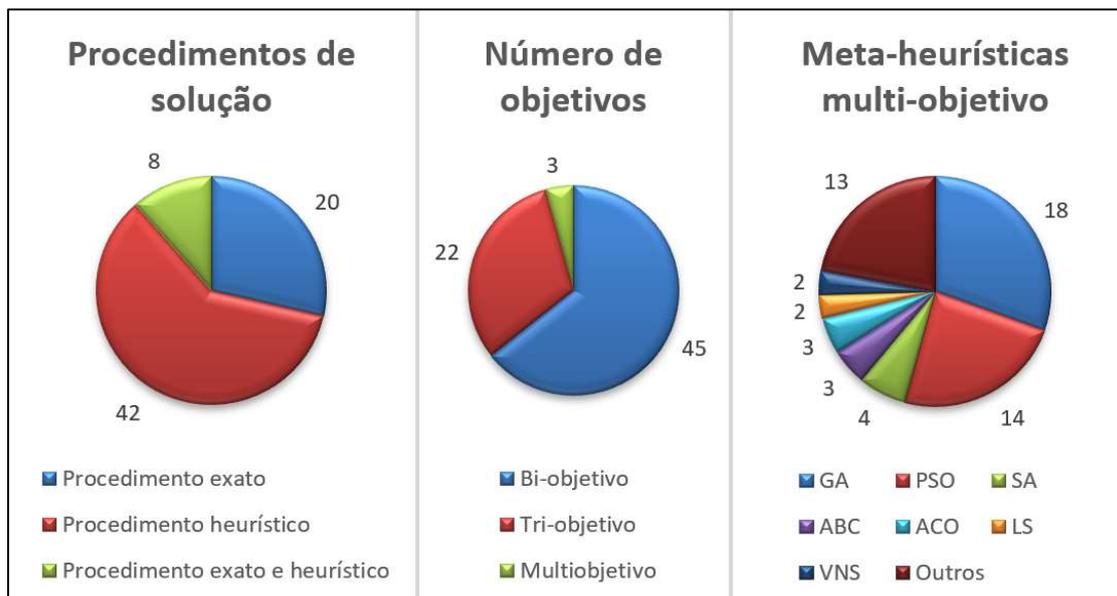


Fonte: O autor.

Legenda: CVRP (*Capacitated VRP*), DVRP (*Dynamic VRP*), FVRP (*Fuzzy VRP*), IRP (*Inventory Routing Problem*), LRP (*Location Routing Problem*), MDVRP (*Multi-depot VRP*), MPVRP (*Multi-period VRP*), MEVRP (*Multi-echelon VRP*), SVRP (*Scheduling in VRP*), TDVRP (*Time-dependent VRP*), VRPPD (*VRP with Pickup and Delivery*), VRPS (*VRP Stochastic*) e VRPTW (*VRP with Time Windows*).

A Figura 3.11 (lado esquerdo) apresenta a quantidade no uso de procedimentos exatos, heurísticos ou ambos para os 70 artigos. A Figura 3.11 (centro) descreve que 64% dos artigos analisados apresentaram abordagem com apenas dois objetivos. A Figura 3.11 (lado direito) apresenta a quantidade do uso dos procedimentos heurísticos no contexto de MOO. Pode-se observar que as técnicas derivadas dos algoritmos populacionais são predominantes, onde *Genetic Algorithm* (Algoritmo Genético, GA) e *Particle Swarm Optimization* (Otimização por Enxame de Partículas, PSO) correspondem a 54%.

Figura 3.11 - Procedimentos de solução (lado esquerdo), número de objetivos (centro) e Meta-heurísticas utilizadas (lado direito)

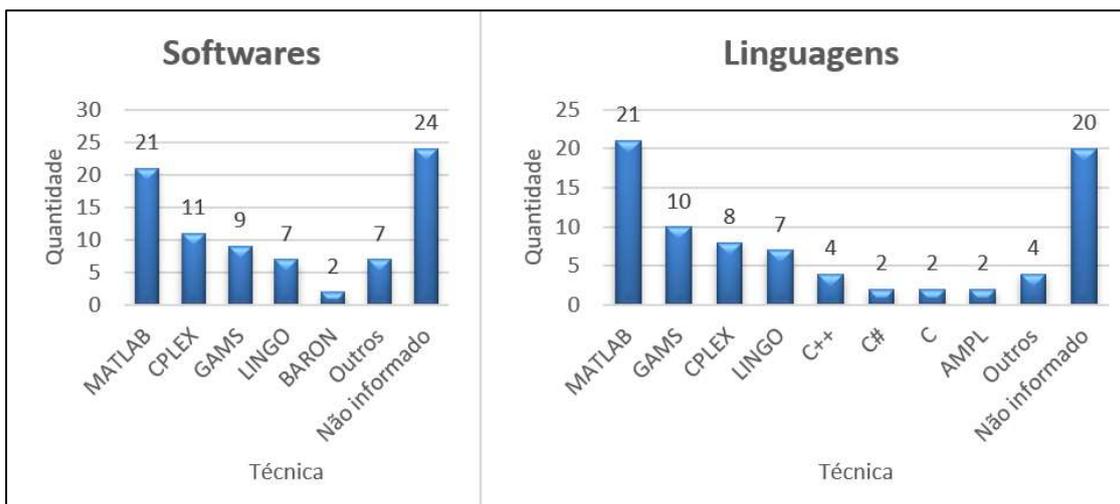


Fonte: O autor.

Legenda: ABC (*Artificial Bee Colony*), ACO (*Ant Colony Optimization*), GA (*Genetic Algorithm*), LS (*Local Search*), PSO (*Particle Swarm Optimization*), SA (*Simulated Annealing*), VNS (*Variable Neighborhood Search*).

A Figura 3.12 apresenta os *softwares* mais utilizados e as respectivas linguagens para os 70 artigos. Vale destacar que um artigo pode ter utilizado mais de um *software* ou linguagem, sendo que alguns *softwares* aceitam diferentes linguagens. Alguns autores relataram apenas o *software*, outros apenas a linguagem, também houve trabalhos desprovidos destas informações.

Figura 3.12 - *Softwares* (lado esquerdo) e Linguagens utilizadas implementação computacional mais utilizadas (lado direito)

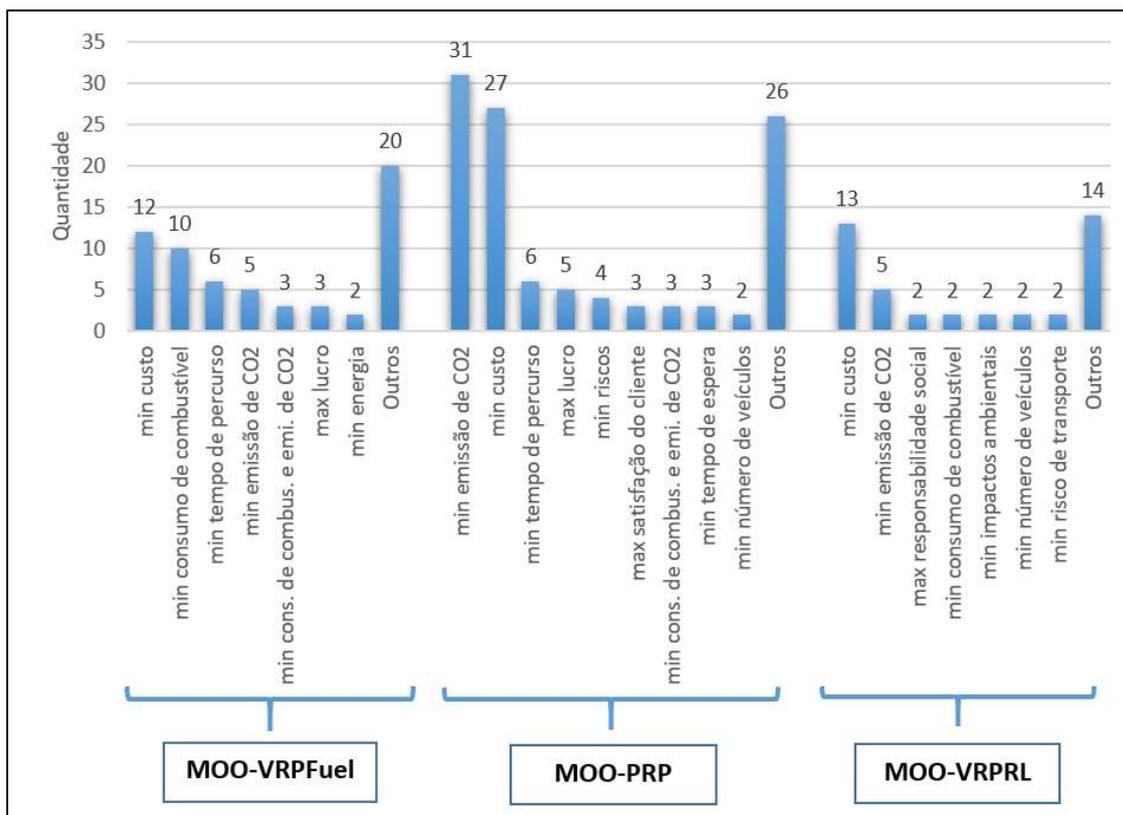


Fonte: O autor.

Legenda: AMPL (*A Mathematical Programming Language*), CPLEX (*simplex method as implemented in the C programming language*), GAMS (*General Algebraic Modeling System*), LINGO (*Language for Interactive General Optimizer*) e MATLAB (*MATrix LABoratory*).

A Figura 3.13 apresenta as principais funções objetivo utilizadas nos 70 trabalhos analisados. Elas foram agrupadas em VRPFuel (à esquerda), PRP (centralizado) e VRPRL (à direita). Nota-se que todas priorizam a minimização dos custos. No caso do VRPFuel, a minimização do consumo de combustível está entre os principais objetivos; o mesmo acontece para o PRP com a minimização de CO₂.

Figura 3.13 - Objetivos mais utilizados nos problemas MOO aplicados ao VRPFuel, PRP e VRPRL dos 70 artigos



Fonte: O autor.

3.3 TRABALHOS CORRELATOS

Nesta seção são apresentados breves relatos da amostra dos 76 artigos desta pesquisa com destaque às categorias VRPFuel, PRP e VRPRL, no contexto da otimização multi-objetivo. Os trabalhos estão apresentados em ordem cronológica e conforme as interligações entre as categorias apresentadas na Figura 3.7. Na sequência os trabalhos de revisão e os artigos mais citados.

3.3.1 *Pollution Routing Problem*

Dos 76 trabalhos da amostra, aqui estão somente sobre o *Pollution Routing Problem* (PRP) “puros”, descritos a seguir. Vale destacar que foram encontrados 51 artigos sobre o PRP, entretanto, os artigos pendentes fazem relação com as outras taxonomias e serão descritos nas próximas seções.

Ehrgott et al., 2012, apresentaram um estudo de caso sobre o roteamento de bicicletas aplicado na Nova Zelândia. O problema buscou minimizar o tempo de viagem e maximizar a adequação das rotas utilizadas. Foi utilizada uma ferramenta online para o case analisado e para os trabalhos futuros, os autores sugerem acrescentar o ciclismo em contextos multimodais.

Chen et al., 2013, propuseram um case onde trataram de um modelo bi-objetivo baseado em filas para reduzir o acúmulo de caminhões em portos; os autores buscaram minimizar o número de chegadas de caminhões e o tempo de espera e, para isso, aplicaram o *Pareto front genetic algorithms based heuristic* (PFGA) e o compararam com o *non-dominated sorting GA of kind II* (NSGA-II). Já Govindan et al., 2014, apresentaram o *two-echelon location-routing problem with time-windows* (2E-LRPTW), aplicado em um estudo de caso para tratar da distribuição de alimentos perecíveis. Os autores utilizaram o *multi-objective particle swarm optimization* (MOPSO); *adapted multi-objective variable neighborhood search* (AMOVNS) and the *multi-objective hybrid approach* (MHPV).

Buscando resolver de forma genérica o *bi-objective turning restriction design problem* (BOTRDP), Long et al., 2014, utilizaram uma versão modificada do ABC, que, por conta do aprimoramento do processo de *crossover*, foi superior ao desempenho do *non-dominated sorting GA of kind* (NSGA). O Pareto ótimo foi aplicado para analisar a relação entre a minimização do congestionamento de tráfego e da poluição ambiental. Validi et al., 2014, propuseram uma distribuição sustentável e multi-objetivo para o transporte de leite na Irlanda, considerando a minimização de custos e emissão de CO₂. Apresentaram um modelo de *mixed integer linear programming* (MILP) e resolveram o problema por procedimentos derivados do GA: *multi-objective GA of kind II* (MOGA-II), NSGA-II e *'Hybrid' combining GA and sequential quadratic programming*. O problema foi resolvido em duas fases, sendo que a primeira tratou da roteirização da distribuição do fornecedor para a indústria e, a segunda, da indústria para a distribuição.

Com a abordagem *multi-objective transportation routing problem* com *multi-depot* de forma genérica para o contexto de roteamento de materiais perigosos, Alexiou e Katsavounis, 2015, atribuíram pesos aos três objetivos de minimização (custos, emissão de poluição e riscos); fizeram uso de um

algoritmo *branch-and-bound*. Schaefer e Konur, 2015, apresentaram um problema de roteamento de inventário bi-objetivo, buscando a minimização de custos e da emissão de CO₂. A abordagem foi *reduction to a single-objective formulation*.

Com a proposta de um *vehicle routing soft with time-windows for multiple environmental vehicle types*, Yang et al., 2015, formularam um GA híbrido que buscou minimizar custos de distribuição, maximizar a satisfação do cliente e minimizar a poluição ambiental (ou seja, emissão de CO₂). Foi constatado que a velocidade do veículo possui forte correlação com a poluição ambiental e com o custo operacional e que, por outro lado, a capacidade de carga influencia em todos os objetivos propostos. Yin et al., 2016, apresentaram um *bi-objective mathematical formulation for the cross-docking with the noted new challenges*, onde os autores abordaram a roteirização e *scheduling*. Para resolver o *non linear integer model*, foi utilizada uma hiper-heurística baseada no ACO e aplicada o *weighting scheme*. Os autores sugerem o uso do NSGA-II ou MOEA/D.

Com a abordagem *eco-routing navigation*, Zeng et al., 2016, combinaram o *weight method* e o algoritmo do caminho *k-shortest* a um modelo bi-objetivo aplicado na cidade de Toyota, Japão, onde os autores buscaram minimizar a emissão de CO₂ e o tempo trajeto. Dentre os principais resultados pode-se observar que no caminho ecológico houve redução do tempo de viagem e emissão de CO₂ (16,95% e 6,98%, respectivamente) e a quilometragem foi sutilmente maior (0,3 km). Tricoire e Parragh, 2017, apresentaram o *green city hub location routing problem* (GCHLRP), utilizado em um exemplo numérico, aplicado um *framework* do ε -*constraint*, além de algoritmos exatos, o *bi-objective branch-and-bound* (BIOBAB) e *2-opt*, com o objetivo de minimizar os custos e a emissão de CO₂.

Com a proposta do *green inter-terminal truck routing problem* (Green - ITTRP), Heilig et al., 2017, aplicaram o *achieved multi-objective simulated annealing* (AMOS), a fim de minimizar os custos, tempo de trajeto e emissão de CO₂. O algoritmo foi aplicado em um sistema de suporte à decisão baseado em *PSO* para resolver o problema de tráfego. Rahimi et al., 2017, apresentaram um modelo estocástico *Multi-objective IRP*, o adaptaram ao *Fuzzy* e depois o aplicaram no NSGA-II. Esta implementação em *Matlab* teve

como objetivos maximizar o lucro, minimizar os atrasos e a emissão de CO₂. Os autores buscaram uma alternativa para distribuição verde de produtos perecíveis. Guo et al., 2017, propuseram o *robust dynamic multi-objective vehicle routing* (RDMOVR), onde, em duas fases foi aplicado o MOPSO e posteriormente o Pareto ótimo, buscando minimizar a emissão de CO₂ o tempo de espera e o número de veículos.

Com a construção de um modelo matemático *fuzzy* para a seleção de fornecedores de uma cadeia logística de circuito fechado, Govindan et al., 2017, objetivaram minimizar custos, emissão de CO₂ e maximizar o desempenho dos fornecedores. Para encontrar uma solução viável foi utilizado o *weighted max-min approach* no software LINGO. Al-e-hashem et al., 2017, apresentaram o *L-shaped method* para resolver o *bi-objective stochastic transshipment-enabled inventory routing problem*. Os autores buscaram minimizar o custo da cadeia logística e a emissão de GHG e, para isso, utilizaram um procedimento heurístico, além do *compromise programming*.

Com a abordagem *two-echelon location routing problem* (2E-LRP), Ouhader e Kyal, 2017, objetivaram realizar uma combinação entre as decisões de Localização e Roteamento das Instalações no contexto de distribuição sustentável de frete urbano sob Colaboração horizontal. Os autores programaram o problema de MILP no *Matlab*, por meio da técnica multi-objetivo ε -*constraint*, onde buscaram minimizar os custos e a emissão de CO₂ e maximizar as oportunidades de trabalho, atendendo ao tripé da sustentabilidade. Como resultados, o aspecto social não foi beneficiado e em trabalhos sugere-se a comparação entre métodos de alocação e o uso de frota heterogênea. Hammad et al., 2017, apresentaram um *case* da Áustria sobre *urban facility location problem*, que tratou da poluição sonora. O *Mixed Integer Non-Linear Programming* (MINLP) foi resolvido como um PLIM, por meio do ε -*constraint* com o *Decomposition of Benders*.

Asadi et al., 2018, apresentaram o *bi-objective stochastic location-inventory-routing model for microalgaebased biofuel supply chain*. Como procedimento de solução exata foi utilizado o ε -*constraint*, já para o caso meta-heurístico os MOPSO e NSGA-II. Este estudo de caso de distribuição logística teve a finalidade de minimizar custos e a emissão de CO₂. Já Chen et al., 2018, apresentaram um *case* que aborda o *location-routing problem with full*

truckloads (LRPFT), aplicado em um modelo bi-objetivo para reduzir a emissão de CO₂. Para isso os autores utilizaram o NSGA-II-TS (NSGA-II com *Tabu Search*). Costa et al., 2018, desenvolveram uma heurística de pesquisa local em duas fases de Pareto.

O *stochastic multi-objective location-allocation-routing problem considering sustainability aspects and quantity discounts* foi aplicado por Ebrahimi, 2018 na cadeia logística de circuito fechado para produção de pneus. O case foi resolvido pelo *software* LINGO com a técnica multi-objetivo ϵ -*constraint*, onde o autor buscou minimizar os custos a emissão de CO₂ e maximizar a capacidade de resposta da rede integrada. A sua principal contribuição está na técnica de roteirização abordando a seleção dos fornecedores, sendo esta uma lacuna identificada na literatura pelo autor. O estudo pode ser aprimorado por meio de outras técnicas exatas e/ou heurísticas, considerando riscos e/ou abordagem *Fuzzy*.

Fathollahi-Fard et al., 2018, abordaram o *bi-objective green home health care routing problem*, ou seja, uma formulação de MILP bi-objetivo, considerando o custo total de transporte, a distância e a poluição ambiental no atendimento médico de pessoas idosas. Para solucionar o problema proposto, os autores utilizaram a linguagem JAVA na adaptação das meta-heurísticas SA, *Salp Swarm Algorithm* (SSA) e algumas variações híbridas, com a utilização do procedimento multi-objetivo ϵ -*constraint*. Os autores realizaram uma análise de sensibilidade por meio da fronteira de Pareto Ótimo.

Com a proposta de *evolution-strategy-based memetic pareto optimization* (ESMPO), uma variação multi-objetivo do VRP com *pickup time*, Guo et al., 2018, buscaram minimizar os custos e a emissão de CO₂ por meio de um PPNL. Os autores relatam a necessidade de considerações mais realísticas em trabalhos futuros. Liu et al., 2018, apresentaram o *green vehicle routing optimization problem* (GVROP), um MILP. Para tanto, os autores fizeram uso do *Hybrid Quantum Immune Algorithm*.

Com a proposta de *stochastic time-dependent green capacitated vehicle routing and scheduling problem with a time window*, Rabbani et al., 2018, compararam o procedimento exato desenvolvido por meio do *software* GAMS com a meta-heurística SA. Para os procedimentos multi-objetivos foi utilizado o *TH method*. Assim, buscaram minimizar os custos, a poluição de tráfego, a

insatisfação dos clientes e, também, maximizar a confiabilidade dos veículos. Sun et al., 2018, propuseram uma abordagem de programação *fuzzy* dependente do tempo em um problema de roteamento multimodal *green*. Teoh et al., 2018, desenvolveram um algoritmo de evolução diferencial para reduzir emissões de CO₂ e riscos.

Validi et al., 2018, apresentaram um *case* propondo o *three-echelon bi-objective Analytic Hierarchy Process (AHP) - integrated location-routing model*, por meio de um problema de MIP aplicado ao MOGA-II, que buscou minimizar a emissão de CO₂ e os custos. Já Zapata-Cortes et al., 2018, compararam três modelagens matemáticas, considerando custos, inventários e emissão de CO₂. Por fim, Zhang et al., 2018, propuseram uma aplicação para a logística de emergência.

3.3.2 Vehicle Routing Problem Fuel

São os trabalhos que trataram puramente do VRPFuel. Demir et al., 2014b abordaram o *bi-objective Pollution-Routing Problem*, onde aplicaram o ϵ -*constraint* em conjunto com o *weighting method* ao *adaptive large neighborhood search algorithm* (ALNS), além de um *hybrid method* (HM), buscando otimizar o consumo de combustível e o tempo de trajeto. Por meio do *multiobjective route based fuel consumption vehicle routing problems* (MRF-CVRPs), Psychas et al., 2016, utilizaram o *pareto front* (PF) aplicado ao *parallel multi-start non-dominated sorting differential evolution algorithms* (PMS-NSDEs) para minimizar o custo da rota, o tempo de trajeto e o consumo de combustível. Rao et al., 2016, apresentaram o *efficient two-objective hybrid local search algorithm*, um problema de MIP visando minimizar os custos e o consumo de combustível. Os autores mensuraram o consumo de combustível pelo grau de inclinação da estrada.

Com o *biobjective time, load and path-dependent vehicle routing problem with time windows* (BTL-VRPTW), Androutsopoulos e Zografos, 2017, utilizaram o *software* CPLEX como meio para utilizar o algoritmo baseado no *ant colony system* (ACS), buscando minimizar o tempo de percorrida e o consumo de combustível. Coelho et al., 2017, propuseram o *multi-objective green UAV (Unmanned Aerial Vehicle) routing problem*, ou seja, uma

distribuição logística por meio de drones. Com o modelo de MILP proposto, ficaram definidos sete objetivos: minimizar a distância; min tempo de trajeto; min o número de drones (veículos); maximizar a velocidade do veículo; min a quantidade de energia para completar a carga da bateria; min o tempo de registro de coleta e min o tempo de registro de entrega. Os autores utilizaram o *black-box dynamic search algorithm* e a meta-heurística *multi-objective smart pool search* (MOSPOOLS). Por fim, os autores sugerem a ampliação dessa aplicação a *smart cities*.

Hassanzadeh e Rasti-Barzoki, 2017, apresentaram um modelo matemático bi-objetivo, levando em consideração a programação de produção e o roteamento de veículos, a fim de minimizar consumo de recursos e os atrasos na entrega. O modelo também pode reduzir a emissão de CO₂. Para isso, um novo GA foi desenvolvido, sendo esse o *variable neighborhood search based non-dominated sorting genetic algorithm II* (VNSGA-II).

Com um *modified* PSO, Norouzi et al., 2017, objetivaram minimizar os custos e o consumo de combustível. Assim, os autores conseguiram otimizar, como consequência, as emissões de GHG, os tempos de viagem e a distância. Rani e Reddy, 2017, trataram do *multi-objective fuzzy shortest path selection for green routing and scheduling problems*. Já Abad et al., 2018, apresentaram uma aplicação geral para o *bi-objective model for pickup and delivery PRP with integration and consolidation shipments in crossdocking system*. Como procedimento de solução foram utilizados o *non-dominated ranking genetic algorithm* (NRGA), NSGA-II e MOPSO. Os algoritmos foram tratados objetivando a minimização dos custos e do consumo de combustível. A contribuição principal está na utilização do *cross-docking* que pode ser aplicado no carregamento, triagem ou descarga; além disso, os autores relataram que ainda há muito a ser estudado nesta linha de pesquisa.

Com a proposta do *fuel efficient green vehicle routing problem* (F-GVRP), uma extensão do GVRP, Poonthalir e Nadarajan, 2018, buscaram minimizar custos e o consumo de combustível. O problema foi resolvido de forma exata pelo *goal programming* e de forma meta-heurística pelo *particle swarm optimization with greedy mutation operator along with time varying acceleration* (TVa-PSOGMO). O objetivo foi estudar o comportamento das funções objetivo sob diferentes circunstâncias. Os autores consideraram

restrições de velocidade constantes e variadas, sendo que a minimização do consumo de combustível ocorreu em um ambiente de velocidade variável. Rau et al., 2018, utilizaram uma aplicação do MOPSO no problema de roteamento de inventário cíclico verde. Por fim, Wang et al., 2018a, propuseram um VRP com janela de tempo e múltiplos depósitos.

Na sequência são abordados os artigos que fazem um elo entre o VRPFuel e o PRP. Neste contexto, Khoo e Teoh, 2014, apresentam uma abordagem *bi-objective dynamic programming* para o planejamento de frotas *green* de companhias aéreas. Os autores utilizaram a abordagem multi-objetivo *Lexicographic optimization* com o objetivo de maximizar o lucro operacional de compra ou locação de aeronaves e minimizar o índice de *Green Fleet Index*, sendo que este está relacionado à redução do consumo de combustível, de emissões de gases poluentes e do ruído gerado pelas aeronaves. Amer et al., 2016, apresentaram o *multi-objective cost function and dynamics route planning*, para tratar do congestionamento de tráfego. Foi utilizado o *weighted sum method* como base para o SA para minimizar tempo de trajeto, o consumo de combustível e a emissão de CO₂. O algoritmo proposto foi até 19,22% melhor em seu comparativo com outras técnicas.

Por meio do *multi-objective sustainable load planning model for intermodal transportation*, modelo de MIP solucionado pelo software LINGO com base no *goal programming*, Baykasoğlu e Subulan, 2016, objetivaram: minimizar os custos totais, o tempo de trajeto e a emissão de CO₂. Foi realizado um estudo de caso sobre a distribuição logística europeia. Kumar et al., 2016, apresentaram o *production and pollution routing problems with time window* (PPRP-TW), onde implementaram o *hybrid Self-Learning Particle Swarm Optimization* (SLPSO). Os autores buscaram minimizar custos e consumo de combustível (e, conseqüentemente, as emissões de CO₂). O algoritmo proposto apresentou melhor desempenho comparativamente ao NSGA-II.

Com o *green hub network under soft time-windows*, onde foi utilizado o *dual lexicographic max–min approach*, Niknamfar e Niaki, 2016, solucionaram exemplos numéricos. Os autores sugerem o uso de algoritmos meta-heurísticos e Pareto Ótimo. Rad e Nahavandi, 2018, apresentaram um modelo genérico de cadeia logística nomeado de *Closed-loop green supply chain*

network Carbon dioxide emission Quantity discount Multi-objective Transport mode selection. Foi utilizada a técnica multi-objetivo *Lp-metrics* no modelo de MILP para ser solucionado com o CPLEX. Os objetivos foram minimizar custos, emissão de CO₂ e maximizar a satisfação dos clientes.

Com o *green open location-routing problem* (G-OLRP), um problema de MILP, Toro et al., 2017a, fizeram uso do ε -restrito, visando minimizar os custos e o consumo de combustível e emissão de CO₂. Por fim, os autores verificaram a necessidade de outras abordagens para o cálculo do consumo de combustível. Toro et al., 2017b, abordaram o *Green Capacitated LRP*, onde apresentam uma contribuição considerando a localização integrada de vários depósitos e veículos heterogêneos. O modelo MILP foi resolvido pelo ε -constraint clássico, com o objetivo de minimizar custos e a emissão de GHG. Por fim, Shui e Szeto, 2018, propuseram um problema dinâmico de reposicionamento de bicicleta verde.

3.3.3 *Vehicle Routing Problem in Reverse Logistic*

Já esta seção aborda os trabalhos da amostra voltados para o VRPRL. Além disso é abordada a relação com os casos já descritos anteriormente (VRPFuel e PRP).

O *multi-objective LRP of reverse logistics based on grey relational analysis with entropy weight*, proposto por Liu et al., 2012, foi solucionado por meio do algoritmo MOPSO. Ramos et al., 2014, resolveram um estudo de caso sobre *recyclable waste collection system*, em Portugal, mais especificamente, a 19 municípios rurais. Este problema de logística reversa foi modelado como *multi-depot periodic VRP with inter-depot routes* (MDPVRPI) no qual foi utilizada a técnica multi-objetivo ε -constraint. Os pesquisadores visaram atender ao tripé da sustentabilidade, considerando a minimização dos custos, da emissão de CO₂ e a maximização das horas de trabalho.

Um modelo matemático *multi-period* de programação dinâmica bi-objetivo que buscou otimizar o desempenho de longo prazo de um sistema municipal no gerenciamento de resíduos sólidos, foi apresentado por Yu et al., 2015. Para isso, os autores utilizaram a técnica multi-objetivo *weighted sum utility method*, onde minimizaram os custos e a poluição. Entezaminia et al.,

2016, abordaram uma aplicação genérica de logística reversa para o *multi-objective multi-period multi-product multi-site aggregate production planning*. Os autores utilizaram o *LP-metrics method*, procurando minimizar os custos da cadeia de suprimentos e maximizar a pontuação ambiental, onde o AHP foi utilizado para obter o indicador mais adequado que descreve o impacto ambiental dentre as alternativas de produção.

Um modelo multiobjectivo *Fuzzy* foi proposto por Govindan et al., 2016, para tratar do VRP *multi-echelon e multi-period in Reverse Logistic*. Os autores compararam uma abordagem do PSO com o ε -constraint. Aplicaram o modelo em um case de sistema de reciclagem de seringas médicas, com o objetivo de minimizar custos, impactos ambientais e maximizar a responsabilidade social. Rabbani et al., 2016, utilizaram as técnicas multi-objetivo *weighted sum, goal programming e goal attainment* aplicadas ao hybrid NSGA-II para resolver o *bi-objective LRP* no contexto de coleta de resíduos.

Ghezavati e Beigi, 2016, propuseram o *location-routing problem with time window (LRPTW) and homogeneous fleet type an designing a multi-echelon, and capacitated reverse logistics network*. Neste contexto, os autores compararam a matemática baseada no ε -restrito com o NSGA-II. Fu et al., 2017, apresentaram um modelo de localização multi-objetivo baseado no subsídio fornecido pelo governo para a reciclagem de *construction and demolition waste*. Este case de logística reversa buscou minimizar a proporção de descarte e os custos operacionais, por fim, os autores adaptaram um algoritmo PSO.

Um *design of a Forward/Reverse Logistics Network with Environmental Considerations* foi proposto por Rabbani et al., 2017. Os autores compararam dois procedimentos meta-heurísticos NSGA-II and MOPSO, sendo que o primeiro apresentou melhor desempenho. Zhu e Hu, 2017, propuseram um *sustainable logistics network modeling for enterprise supply chain*, onde buscaram atender ao tripé da sustentabilidade com a aplicação conjunta do ε -restrito ao *augment constraint algorithm (AUGMENCON)*. Wang et al., 2018b, apresentaram o *cooperation for Recycling Vehicle Routing Optimization in Two-Echelon Reverse Logistics Networks*, sendo que para a sua resolução, os autores utilizaram um algoritmo baseado no *Clarke and Wright (CW) savings method* em conjunto com o NSGA-II (CW_NSQA-II). Neste contexto de

logística reversa, aplicada a um case na China, foi possível minimizar os custos e o número de veículos. Em trabalhos futuros, os autores pretendem fazer uso de considerações estocásticas, avaliar o compartilhamento de veículos e as condições de tráfego real.

Para verificar o elo do VRPLR com o VRPFuel, Gong et al., 2018, trataram o *new closed-loop supply chain logistics network of vehicle routing problem with simultaneous pickups and deliveries (VRPSPD) dominated by remanufacturer*, onde apresentaram o *bee evolutionary algorithm guiding nondominated sorting genetic algorithm II (BEG-NSGA-II)* para solucioná-lo visando três objetivos: min consumo de combustível, min tempo de espera e min menor distância de entrega. O problema foi aplicado no contexto de distribuição logística e foram realizados testes genéricos. Foi verificada a eficácia do algoritmo proposto em relação ao tradicional NSGA-II.

A relação entre o VRPLR e o PRP foi verificada por Zohal e Soleimani, 2016, que apresentaram um estudo de caso sobre a indústria do ouro e utilizaram o *green closed-loop supply chain*. Além do procedimento exato, os autores utilizaram o ACO e para ajustar os parâmetros, o método Taguchi. Desta forma, o MILP foi implementado nos *softwares* LINGO e *Matlab*. Os objetivos foram maximizar a renda, minimizar custos e a emissão de gases poluentes. Yu e Solvang, 2018, apresentaram um caso de sustentabilidade na cadeia logística de suprimentos, onde propuseram maximizar os lucros e minimizar os impactos ambientais.

Por fim, atendendo as três variações dos VRP com considerações ambientais (VRPFuel, PRP e VRPLR), têm-se os trabalhos publicados por Gupta et al., 2017, Farrokhi-Asl et al., 2018 e Soleimani et al., 2018. Assim, Gupta et al., 2017, apresentaram um algoritmo evolucionário de caminho mais curto aplicado ao *green multi-objective multi-attribute VRP (G-MoMaVRP)*. Nele foram considerados *time-windows, pickup and delivery, heterogeneous fleet of vehicles* e congestionamento de tráfego. Foram realizados testes na literatura e alguns estudos de caso reais em Cingapura.

Farrokhi-Asl et al., 2018, propuseram um problema de aplicação geral para a logística reversa, onde realizaram a solução de coleta de resíduos de forma sustentável. Soleimani et al., 2018, abordaram a coleta e distribuição de produtos remanufaturados no contexto do VRP com *pickup and delivery*, com

considerações sustentáveis. O modelo de PNL foi resolvido com auxílio da técnica multiobjectivo *Linearizing process*. A principal contribuição dos autores está na proposta de distribuição de produtos novos e remanufaturados por meio da óptica sustentável.

3.3.4 Outros Trabalhos

Dentre os artigos de revisão selecionados, destaca-se o de Dekker et al., 2012, que propuseram uma contribuição à área de PO para a logística verde, concretizando a integração dos aspectos ambientais na logística; abordaram temas sobre Facilidades, Transporte e Inventário, considerando o processo de decisão por meio do design, planejamento e controle. De forma complementar, abordaram os impactos ambientais por meio de métricas e metodologias dos artigos por eles analisados. Quanto à emissão de CO₂ e ao consumo de combustível, os autores relatam as melhorias ocorridas na fórmula da gasolina, com a exclusão dos aditivos de chumbo a fim de melhorar a qualidade do ar e uso de biocombustíveis. Por fim, descrevem oportunidades aplicadas em diferentes modais.

Uma pesquisa sobre o transporte rodoviário de cargas verdes foi apresentado por Demir et al., 2014a. Neste estudo foi realizada a integração entre as áreas de PO, Engenharia Mecânica e Engenharia de Tráfego; os autores fizeram uso dos trabalhos mais recentes que propunham diferentes formas de mensurar a emissão de CO₂ e o consumo de combustível. Constataram a criticidade de fatores para explicar o consumo, tipo de veículo, carga, velocidade, gradiente de estrada, dentre outros. Sugerem como trabalhos futuros, o uso de abordagens multi-objetivo com considerações verdes, buscar alternativas para a minimização de emissões de CO₂, considerações sociais relacionadas às condições trabalhistas dos caminhoneiros.

Lin et al., 2014, apresentaram um *survey* sobre as considerações ambientais aplicadas ao VRP, onde relataram as principais variações do VRP, procedimentos de solução (algoritmos), uma proposta de taxonomia para o GVRP (VRPFuel, PRP e VRPRL) e contextualizações de aplicação. Como

direcionamento de pesquisas futuras, os autores incentivam a aplicação da sistemática em contextos interdisciplinares; considerar as incertezas para não negligenciar a demanda do cliente, o que acaba sendo muito usual; coleta de resíduos aplicado a logística reversa e sistemas de distribuição *multi-echelon*.

Das e Jharkharia, 2018, apresentaram uma revisão da literatura sobre o gerenciamento da cadeia de suprimento de baixo carbono e os principais problemas na tomada de decisão neste contexto. Esta é uma pesquisa importante para esta temática que, segundo os autores, está no estágio inicial. Engeland et al., 2018, propuseram uma revisão da literatura sobre modelos estratégicos de otimização de rede em cadeias reversas de suprimento de resíduos.

Malladi e Sowlati, 2018, apresentaram uma pesquisa sobre os aspectos da sustentabilidade aplicada no IRP. Os autores utilizaram as bases da *Web of Science* e *Google Scholar* e obtiveram uma amostra de 40 artigos, nos quais realizaram a análise do conteúdo. O trabalho passou por quatro fases: coleta do material, análise descritiva, seleção da categoria e avaliação do material. Assim como a presente pesquisa, poucos periódicos (10%) estavam relacionados a sustentabilidade; cerca de metade da amostra também estava relacionada a estudos de caso reais; 9 dos 40 artigos são de caráter multi-objetivo. Dentre as oportunidades de trabalhos futuros, os autores citam a oportunidade de explorar aspectos sociais, como criação de novos empregos e o aumento da carga de tráfego.

3.3.5 Resumo dos artigos relacionados ao MOOGVRP

Um resumo dos 76 artigos relacionados ao MOOGVRP, abordados nas seções 3.2.1, 3.2.2, 3.2.3 e 3.2.4 é apresentado no Quadro 3.1. Este Quadro está organizado por referências, apresentadas em ordem alfabética e cronológica. O tipo de pesquisa foi classificado como estudo de caso (c), aplicação geral (g) e revisão (r). A frota foi classificada como homogênea (ho), heterogênea (he) ou não informada (ni). O GVRP foi classificado pela taxonomia utilizada neste estudo: VRPFuel, PRP e VRPRL. Foi determinado se os procedimentos utilizados eram exatos, heurísticos ou, alternativamente,

ambas as abordagens. O número de objetivos foi organizado como bi-objetivo (bi), tri-objetivo (tri) ou multi-objetivo (multi). Na sequência foram especificados os objetivos do estudo, a aplicação proposta do trabalho, as técnicas de solução e o número de citações (coletado em maio de 2019 pela SCOPUS).

Como exemplo, pode-se ver Dekker et al. (2012) e Ehrgott et al. (2012). Assim, Dekker et al. (2012) é um artigo de revisão que aborda o PRP com o objetivo de integrar aspectos ambientais na logística, aplicado à logística verde e com 353 citações. Ehrgott et al. (2012), um estudo de caso, com frota homogênea, que também aborda o PRP, utilizou procedimento heurístico com modelagem matemática de bi-objetivo de minimização do tempo de viagem e máxima adaptação às rotas utilizadas; aplicado na rota de ciclismo, utilizou o *bi-objective shortest path problem* e obteve 36 citações.

Quadro 3.1 - Resumo dos 76 artigos relacionados ao MOOGVRP

Referência	Tipo	Frota	GVRP			Procedimento		Objective	Objetivos	Aplicações	Técnicas	Nº de citações
			VRPFuel	PRP	VRPRL	Exato	Heurístico					
Dekker et al. (2012)	r	-		x		-	-	-	Integração de aspectos ambientais na logística	Logística Verde	Revisão	353
Ehrgott et al. (2012)	c	ho		x			x	bi	Min tempo de viagem; Max adaptação às rotas utilizadas	Rota de ciclismo	<i>Bi-objective shortest path problem</i>	36
Liu et al. (2012)	g	ni			x		x	bi	Min custo; Min número de veículos	Logística Reversa	MOPSO	1
Chen et al. (2013)	c	he		x			x	bi	Min número de chegada de caminhões; Min tempo de espera	Fila da caminhões	PFGA	53
Demir et al. (2014a)	r	-	x	x		-	-	-	Pesquisa sobre o transporte rodoviário de cargas verdes	Cargas Green	Revisão	260
Demir et al. (2014b)	c	ho	x				x	bi	Min consumo de combustível; Min tempo de trajeto	Distribuição Logística	<i>ALNS; weighting method; ϵ-constraint method</i>	156
Govindan et al. (2014)	c	he		x			x	bi	Min custo; Min impactos ambientais	Distribuição de alimentos perecíveis	AMOVNS; MOPSO	201
Khoo e Teoh (2014)	c	he	x	x		x		bi	Max lucro operacional; Min índice de frota verde (combustível, poluição e ruído)	Avaliação comercial	Programação dinâmica	9
Lin et al. (2014)	r	-	x	x	x	-	-	-	Pesquisa sobre consideração ambiental aplicada ao VRP	Tendências passadas e futuras	Revisão	314
Long et al. (2014)	c	ni		x			x	bi	Min congestionamento de tráfego; Min poluição Ambiental	Redes rodoviárias urbanas	ABC Modificado	28
Ramos et al. (2014)	c	he			x	x		tri	Min custo; Min emissão de CO ₂ ; Max horas de trabalho	Sistema de coleta de lixo reciclável	<i>ϵ-constraint method</i>	73
Validi et al. (2014)	c	he		x			x	bi	Min custo; Min emissão de CO ₂	Distribuição de leite	<i>MOGA-II; NSGA-II; Sequential Quadratic Programming.</i>	92
Alexiou e Katsavounis (2015)	g	ni		x		x		tri	Min custo; Min poluição; Min risco	Distribuição logística	Procedimento DPH	5
Schaefer e Konur (2015)	g	ho		x		x		bi	Min custo; Min emissão de CO ₂	Distribuição logística	Aproximação por fronteira de Pareto	19
Yang et al. (2015)	g	he		x			x	tri	Min custos de distribuição; Max satisfação do cliente; Min poluição ambiental	Distribuição logística	MOGA Híbrido	14
Yu et al. (2015)	c	ni			x	x		bi	Min custo; Min poluição	Coleta de lixo	Programação dinâmica	8

Amer et al. (2016)	c	ni	x	x			x	tri	Min tempo de viagem; Min consumo de combustível; Min emissão de CO ₂	Engarrafamento	<i>Improved Simulated Annealing TOPSIS</i>	9
Baykasoglu e Subulan (2016)	c	ni	x	x		x		tri	Min custos totais; Min tempo de viagem; Min emissão de CO ₂	Distribuição logística	<i>Goal programming</i>	20
Entezaminia et al. (2016)	c	ho			x	x		bi	Min custos da cadeia de suprimentos; Max critérios ambientais	Logística reversa	<i>LP-metrics method</i>	35
Ghezavati e Beigi (2016)	g	ho			x	x	x	bi	Min custo; Min tempo de viagem	Logística reversa	NSGA-II	10
Govindan et al. (2016)	c	ni			x	x	x	multi	Min custo; Min impactos ambientais; Max responsabilidade social	Reciclagem de seringas médicas	<i>MOPSO; ϵ-constraint method</i>	50
Kumar et al. (2016)	c	ho	x	x			x	bi	Min custo; Min consumo de combustível e consequente emissão de CO ₂	Distribuição logística	SLPSO	36
Niknamfar e Niaki (2016)	g	he	x	x		x		bi	Max lucro de todas as transportadoras; Max lucro operacional	Distribuição logística	<i>Lexicographic</i>	10
Psychas et al. (2016)	g	ho	x				x	tri	Min rota; Min tempo de viagem; Min consumo de combustível	Distribuição logística	PMS-NSDEs	4
Rabbani et al. (2016)	g	ho			x		x	bi	Min custo; Max aspectos sociais	Coleta de resíduos	NSGA-II Híbrido	10
Rahimi et al. (2016)	c	he		x			x	tri	Max lucro; Min atraso; Min emissão de CO ₂	Produtos perecíveis	NSGA-II	16
Rao et al. (2016)	g	ho	x				x	bi	Min custo; Min consumo de combustível	Distribuição logística	MOLS	7
Yin et al. (2016)	c	he		x			x	bi	Min custo; Min <i>makespan</i>	<i>Scheduling</i>	Hiper-heurística AOC	14
Zeng et al. (2016)	c	ni		x		x		bi	Min emissão de CO ₂ ; Min tempo de viagem	Sistema de navegação	Programação Linear	18
Zohal e Soleimani (2016)	c	ho		x	x	x	x	tri	Max receita; Min custo; Min emissão de CO ₂	Indústria do ouro	MOACO	31
Al-e-hashem et al. (2017)	g	ho		x			x	bi	Min custo; Min emissão de GHG	Distribuição logística	<i>Hybrid L-shaped method</i>	3
Androutsopoulos e Zografos (2017)	g	ho	x				x	bi	Min tempo; Min consumo de combustível	Distribuição logística	MOACO	9
Coelho et al. (2017)	c	he	x				x	multi	Min distancia; Min tempo mínimo de número de drones (veículos); Max rapidez; Min uso da carga da bateria; Min tempo de coleta; Min tempo de entrega	Uso de Drone	<i>Black-box dynamic search algorithm; MOSPOOLS</i>	10
Fu et al. (2017)	c	ni			x		x	bi	Min proporção de resíduos descartados; Min custo	Logística reversa	MOPSO	3
Govindan et al. (2017)	c	ho		x		x		tri	Min custo; Max desempenho do fornecedor; Min emissão de CO ₂	Cadeia de suprimentos em circuito fechado	MIP Fuzzy	13
Guo et al. (2017)	g	ni		x			x	tri	Min emissão de CO ₂ ; Min tempo de espera; Min número de veículos	Distribuição logística	MOPSO	2
Gupta et al. (2017)	c	he	x	x	x		x	tri	Min custo da rota; Max qualidade de serviço; Min emissão veicular	Logística ecológica	MOSPEA	4
Hammad et al.	c	ho		x		x		bi	Min ruído; Min tempo de viagem	Poluição sonora	MILP	9

(2017)												
Hassanzadeh e Rasti-Barzoki (2017)	g	ni	x				x	bi	Min custo total de atraso; Min energia	Distribuição logística	VNSGA-II; NSGA-II	8
Heilig et al. (2017)	c	ni		x			x	tri	Min custo; Min tempo de viagem; Min emissão de CO ₂	Transporte Inter-terminal	AMOSa	6
Norouzi et al. (2017)	g	ni	x				x	bi	Min custo; Min consume de combustível	Distribuição logística	MOPSO	13
Ouhader e Kyal (2017)	c	ho		x		x		tri	Min custo; Min emissão de CO ₂ ; Max oportunidade de trabalho	Distribuição logística	ϵ -constraint method	6
Rabbani et al. (2017)	g	he			x		x	tri	Min custo; Max capacidade de resposta (satisfação); Min emissão de CO ₂	Logística reversa	NSGA-II; MOPSO	3
Rani e Reddy (2017)	g	ni	x				x	bi	Min "sharp values"; Min fuzzy	Distribuição logística	MOSPP	0
Toro et al. (2017a)	g	ho	x	x		x		bi	Min custo; Min emissão de GHG	Distribuição logística	ϵ -constraint method	15
Toro et al. (2017b)	g	he	x	x		x		bi	Min custo; Min consumo de combustível e emissão de CO ₂	Distribuição logística	ϵ -constraint method	5
Tricoire e Parragh (2017)	c	he		x		x	x	bi	Min custo; Min emissão de CO ₂	Distribuição logística	BIOBAB; 2-opt	6
Zhu e Hu (2017)	g	he			x		x	tri	Min custo; Min impactos ambientais; Max responsabilidade social	Logística reversa	AUGMENCON	1
Abad et al. (2018)	c	ho	x				x	bi	Min custo; Min consumo de combustível	Cross docking	NRGA; MOPSO	6
Asadi et al. (2018)	c	ni		x		x	x	bi	Min custo; Min emissão de CO ₂	Distribuição logística	NSGA-II; MOPSO	1
Chen et al. (2018)	c	ho		x			x	bi	Min custo; Min emissão de CO ₂	Frota de caminhões	NSGA-II-TS (com Tabu Search)	2
Costa et al. (2018)	g	ho		x			x	bi	Min emissão de CO ₂ ; Min custos salariais	Distribuição logística	MOLS	0
Das e Jharkharia (2018)	r	-		x		-	-	-	Revisão da literatura relevante sobre gerenciamento da cadeia de suprimento de baixo carbono	Cadeia de suprimentos de baixo carbono	Revisão	15
Ebrahimi (2018)	c	he		x		x		tri	Min custo; Min emissão de CO ₂ ; Max capacidade de resposta da rede integrada	Cadeia de suprimentos fechada (pneus)	ϵ -constraint method	4
Engeland et al. (2018)	r	-			x		-	-	Integração da cadeia de suprimentos reversa e literatura sobre gerenciamento de resíduos	Cadeias de fornecimento reverso de resíduos	Revisão	0
Farrokhi-Asl et al. (2018)	g	he	x	x	x		x	tri	Min custo geral, CO ₂ e combustível; Min risco de transporte; Min risco de viagem (local)	Logística reversa	CA; MOPSO; NSGA-II; SPAE-II; MOSA	0
Fathollahi-Fard et al. (2018)	c	he		x			x	bi	Min custo de transporte e distância; Min emissão de CO ₂	Assistência Médica Domiciliar	MOSSA; MOSA	10
Gong et al. (2018)	c	he	x		x		x	tri	Min consume de combustível; Min tempo de espera; Min distância para entrega	Distribuição logística	BEG-NSGA-II	0
Guo et al. (2018)	c	ho		x			x	bi	Min custo; Min emissão de CO ₂	Agendamento de transporte	ESMPO	7

Guo et al. (2018)	g	ni		x			x	tri	Min emissão de CO ₂ ; Min tempo de espera (janela de tempo); Min número de veículos	Distribuição logística	MOPSO	2
Liu et al. (2018)	g	ni		x			x	bi	Min custos; Min emissão de CO ₂	Distribuição logística	HQIA	4
Malladi e Sowlati (2018)	r	-	x	x	x	-	-	-	Aspectos de sustentabilidade aplicados ao IRP	Problema de roteamento de inventário	Revisão	2
Poonthalir e Nadarajan (2018)	g	ho	x			x	x	bi	Min custo; Min consumo de combustível	Distribuição logística	MOPSO	14
Rabbani et al. (2018)	c	he		x		x	x	multi	Min custo; Min emissão de CO ₂ ; Min insatisfação; Max confiabilidade do veículo	Distribuição logística	MOSA	4
Rad e Nahavandi (2018)	c	he	x	x		x		tri	Min custo; Min emissão de CO ₂ ; Max satisfação do cliente	Circuito fechado <i>green</i> da cadeia de suprimentos	LP-metrics	5
Rau et al. (2018)	c	ho	x				x	bi	Min custo; Min combustível, manuseio e energia	Gerenciamento logístico	MOPSO	1
Shui e Szeto (2018)	c	ni	x	x			x	bi	Min demanda não atendida; Min custo de emissão de CO ₂ e consumo de combustível	Substituição de bicicletas	EABC	10
Soleimani et al. (2018)	c	ni	x	x	x	x		bi	Min custo; Min energia consumida (combustível)	Distribuição logística	Programação linear	11
Sun et al. (2018)	c	ni		x		x		bi	Min custo; Min emissão de CO ₂	Logística multimodal	MNIP	6
Teoh et al. (2018)	g	ni		x			x	bi	Min emissão de CO ₂ ; Min risco	Distribuição logística	MODE	0
Validi et al. (2018)	c	he		x			x	bi	Min emissão de CO ₂ ; Min custo	Distribuição logística	MOGA-II	1
Wang et al. (2018a)	g	ho	x			x	x	bi	Min custo; Min número de veículos	Logística reversa	CW_NSGA-II	2
Wang et al. (2018b)	c	ni			x		x	bi	Min consume de energia; Min insatisfação	Distribuição logística	NSGA-II	0
Yu e Solvang (2018)	g	he		x	x	x		bi	Max lucro; Min impacto ambiental (emissão de CO ₂)	Logística reversa	<i>Weighting method; ε-constraint method</i>	1
Zapata-Cortes et al. (2018)	c	ni		x		x		tri	Min custo; Min inventário; Min emissão de CO ₂	Distribuição logística	Programação linear	0
Zhang et al. (2018)	c	ni		x			x	tri	Min tempo; Min custo; Min emissão de CO ₂	Emergências médias	MOGA	2

Fonte: O autor.

Legenda: ABC (*artificial bee colony*); ALNS (*adaptive large neighborhood search algorithm*); AMOSA (*achieved multi-objective simulated annealing*); AMOVNS (*adapted multi-objective variable neighborhood search*); AUGMENCON (*augment constraint algorithm*); BEG-NSGA-II (*bee evolutionary algorithm guiding nondominated sorting genetic algorithm II*); BIOBAB (*bi-objective branch-and-bound*); CA (*Cultural algorithm*); CW_NSGA-II (*Clarke and Wright savings method and the non-dominated sorting genetic algorithm-II*); EABC (*enhanced artificial bee colony*); ESMPO (*evolution-strategy-based memetic pareto optimization*); HQIA (*hybrid quantum immune algorithm*); MIP (*mixed integer programming*); MILP (*mixed integer linear programming*); MNIP (*mixed non-linear integer programming*); MOACO (*multi-objective ant colony optimization*); MODE (*multi-objective differential evolution*); MOGA (*multi-objective*

genetic algorithm); MOGA-II (*multi-objective genetic algorithm of kind II*); MOLS (*multi-objective Local Search*); MOPSO (*multi-objective particle swarm optimization*); MOSPEA (*metaheuristic optimization algorithm*); MOSPOOLS (*multi-objective smart pool search metaheuristic*); MOSPP (*multi objective shortest path problem*); MOSSA (*multi-objective salp swarm algorithm*); NRGGA (*non-dominated ranking genetic algorithm*); NSGA-II (*non-dominated sorting genetic algorithm II*); PFGA (*pareto front genetic algorithms*); PMS-NSDEs (*parallel multi-start non-dominated sorting differential evolution algorithms*); SLPSO (*hybrid self-learning particle swarm optimization*); TOPSIS (*technique for order preference by similarity to ideal solution*); VNSGA-II (*multi-objective variable neighborhood search with non-dominated sorting genetic algorithm II*).

Os trabalhos mais citados na amostra estão apresentados na Tabela 3.3. Essa tabela está estruturada por referências, periódicos, tipo de artigo e número de citações obtidas no SCOPUS. Os três trabalhos mais citados foram revisões de literatura, conduzidas por Dekker et al. (2012), Lin et al. (2014) e Demir et al. (2014a). Todos os trabalhos já foram apresentados nas seções anteriores.

Tabela 3.3 – Os 11 artigos mais citados da amostra MOOGVRP

Referência	Periódicos	Tipo	Nº de citação
Dekker et al. (2012)	<i>European Journal of Operational Research</i>	Revisão	353
Lin et al. (2014)	<i>Expert Systems with Applications</i>	Revisão	314
Demir et al. (2014a)	<i>European Journal of Operational Research</i>	Revisão	260
Govindan et al. (2014)	<i>International Journal of Production Economics</i>	Estudo de caso	201
Demir et al. (2014b)	<i>European Journal of Operational Research</i>	Estudo de caso	156
Validi et al. (2014)	<i>International Journal of Production Economics</i>	Estudo de caso	92
Ramos et al. (2014)	<i>Omega (United Kingdom)</i>	Estudo de caso	73
Chen et al. (2013)	<i>Transportation Research Part E</i>	Estudo de caso	53
Govindan et al. (2016)	<i>Ecological Indicators</i>	Estudo de caso	50
Ehrgott et al. (2012)	<i>Transportation Research Part A</i>	Estudo de caso	36
Kumar et al. (2016)	<i>Computers and Industrial Engineering</i>	Estudo de caso	36

Fonte: O autor.

*

A partir dos dados verificados até aqui, tem-se condições de responder as perguntas propostas para esta pesquisa, apresentadas na seção 3.2.1 de Procedimentos Metodológicos.

Para responder à primeira pergunta desta pesquisa (Quais são os estudos mais relevantes sobre o MOOGVRP?), os estudos mais relevantes durante o período analisado foram apresentados na Tabela 3.3, na qual os três artigos mais citados foram revisões. Dekker et al. (2012) e Demir et al. (2014a) abordaram aspectos relacionados à logística, enquanto Lin et al. (2014) procuraram demonstrar a evolução e a relação do GVRP. Os outros artigos citados com mais frequência procuraram aprimorar técnicas e aplicá-las a contextos reais.

Para responder à segunda pergunta (quais são as tendências do MOOGVRP que podem orientar futuras pesquisas?), as estratificações da seção 3.2.2 (dados bibliométricos) e 3.3 (trabalhos correlatos, esta seção) são de grande importância. Nesse contexto, o Quadro 3.1 resumiu a proposta dos 76 artigos focados em

revisões, aplicação geral e estudos de caso. Os autores da amostra estão associados a 96 instituições, centros de pesquisa e empresas, e as maiores contribuições, até agora, vieram do Irã, China, EUA e Reino Unido. A Figura 3.7 mostrou-se muito interessante, pois mostra a quantidade de trabalho desenvolvido considerando VRPFuel, PRP e VRPRL, bem como suas interações na amostra analisada.

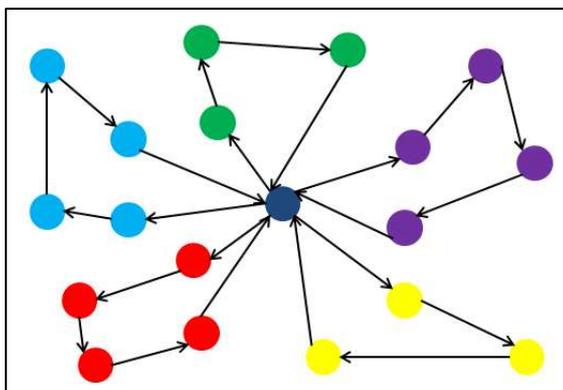
4 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentadas as técnicas a serem utilizadas para solucionar um problema, como os propostos no Capítulo 2. Inicialmente é abordado o Problema de Roteamento de Veículos (PRV) para a definição de um conjunto de rotas otimizadas e a abordagem da Otimização de Problemas Multi-objetivos, a fim de encontrar o equilíbrio entre objetivos conflitantes. Neste contexto, são apresentados procedimentos exatos, heurísticos e meta-heurísticos para as técnicas propostas. Além disso, é apresentado o método de Agregação Aditiva e Função Utilidade para auxiliar na escolha de uma solução pertencente à Fronteira de Pareto e algumas considerações ambientais para a quantificação da emissão de GHG.

4.1 PROBLEMA DE ROTEAMENTO DE VEÍCULOS (VRP)

Nesta seção será abordado o modelo matemático do VRP, as suas variações mais utilizadas na literatura e o caso do *Green VRP*. A Figura 4.1 apresenta um exemplo esquemático de um PRV, com cinco roteiros e um único depósito.

Figura 4.1 – Exemplo de um Problema de Roteamento de 5 roteiros e único depósito



Fonte: O autor.

4.1.1 Modelagem Matemática para o VRP

Na Literatura pode-se encontrar algumas abordagens matemáticas para resolver o VRP, como as propostas por Fisher e Jaikumar (1981) e Subramanian et al. (2013). De acordo com Goldbarb e Luna (2005), o VRP é um problema que possui aplicações muito abrangentes, nas áreas de gerenciamento de distribuição e

logística, como, transporte de jornais, transporte escolar, recolhimento de lixo, roteamento de linhas aéreas e entre inúmeras possibilidades de aplicação.

O PRVC (PRV Capacitado, ou simplesmente VRP) tem a finalidade de determinar um conjunto de rotas para os veículos que começa e termina no depósito, a demanda de todos os seus clientes deve ser obrigatoriamente atendida pelos veículos, cada cliente deve ser atendido por somente um veículo e a capacidade de cada veículo não poderá ser violada. Sendo assim, a soma dos custos das operações de transportes realizadas deverá ser minimizada.

Fisher e Jaikumar (1981) propuseram um modelo matemático para o VRP. Assim, como variáveis de decisão, tem-se: $x_{ij}^b = 1$, se o veículo b atende o cliente j após o cliente i e 0, caso contrário; $y_i^b = 1$, se a demanda do cliente i foi atendida pelo veículo b e 0, caso contrário; v representa o número de clientes a serem atendidos pela demanda D_i ($i = 1, \dots, v$); $i = 0$ se refere ao depósito; Cap_b trata da capacidade máxima de cada veículo b ($b = 1, \dots, B$); c_{ij} aborda o custo de viagem do cliente i ao cliente j .

Neste contexto, o problema pode ser representado pelo grafo completo $G(V,A)$, onde $V = \{0, 1, \dots, v\}$ representa o conjunto de nós e $A = \{(i, j) : i \neq j\}$ o conjunto de arcos que fazem a ligação entre i e j . O objetivo é percorrer todos os nós do grafo e retorne ao nó 0, ou seja, um trajeto de circuito fechado; a cada nó deverá estar associada uma demanda D_i do cliente i . Por fim, para cada arco (i, j) , tem-se um valor d_{ij} representando a distância entre i e j . Além disso, todos os roteiros deverão começar e terminar no nó 0; a quantidade de demanda deve respeitar a capacidade do veículo e cada nó i deverá ser visitado exatamente uma vez. A formulação matemática é apresentada de (4.1) a (4.9).

$$\min \sum_{i=1}^v \sum_{j=1}^v \sum_{b=1}^v d_{ij} x_{ij}^b \quad (4.1)$$

$$S. a.: \sum_{b=1}^B y_i^b = 1, \quad i = 1, \dots, v \quad (4.2)$$

$$\sum_{b=1}^B y_i^b = B, \quad i = 0 \quad (4.3)$$

$$\sum_{i=1}^v D_i y_i^b \leq Cap_b, \quad b = 1, \dots, B \quad (4.4)$$

$$\sum_{i=1}^v x_{ij}^b = y_j^b, \quad j = 0, \dots, v \quad b = 1, \dots, B \quad (4.5)$$

$$\sum_{j=1}^v x_{ij}^b = y_j^b, \quad i = 0, \dots, v \quad b = 1, \dots, B \quad (4.6)$$

$$\sum_{i \in S} x_{ij}^b = x_{ij}^b \leq |N| - 1, \quad N \subseteq \{1, \dots, v\} \quad b = 1, \dots, B \quad (4.7)$$

$$x_{ij} = 0 \text{ ou } 1, \quad i = 0, \dots, v \quad j = 0, \dots, v \quad b = 1, \dots, B \quad (4.8)$$

$$y_i^b = 0 \text{ ou } 1, \quad i = 0, \dots, v \quad b = 1, \dots, B \quad (4.9)$$

Onde: em (4.1), a função objetivo, impõe a minimização do custo total, sendo este proporcional à distância percorrida. As restrições em (4.2) garantem que cada cliente seja visitado por um único veículo. Em (4.3), todos os veículos saem do depósito ($i=0$). O limite de capacidade de carga do veículo é respeitado pela restrição (4.4). Em (4.5) e (4.6) estão as restrições que ligam as variáveis x e y , se $y = 1$, fazendo com que os veículos não interrompam suas viagens em um cliente. As restrições em (4.7) evitam a formação de sub-rotas. Por fim, em (4.8) e (4.9) têm-se as variáveis de decisão do problema (NÉIA et al., 2013).

A segunda modelagem, de acordo com Subramanian et al. (2013), a versão clássica do VRP, mais conhecida como PRVC, considera um único depósito, um único tipo de veículo (frota homogênea) b , demanda de somente coleta ou somente entrega para todos os seus clientes e a matriz de custos como sendo simétrica. A fim de simplificar a notação, o depósito será referenciado pelo índice 0 e c_{ij} o custo de transporte entre o depósito e os clientes, ou ainda, entre os clientes.

Assim, x_{ij} representam variáveis inteiras que armazenam o número de vezes que a aresta aparece em uma rota. Ela pode assumir o valor 2 no caso de a rota conter apenas um cliente. Por fim, considere V como sendo o conjunto complementar de V , onde foi incluído o depósito (com o rótulo correspondente a 0). A formulação matemática é apresentada de (4.10) a (4.15).

$$\min \sum_{i \in V} \sum_{j \in V, j > i} c_{ij} x_{ij} \quad (4.10)$$

$$S. a.: \sum_{i \in V, i < k} x_{ik} + \sum_{j \in V, j > k} x_{kj} = 2, \quad \forall k \in v \quad (4.11)$$

$$\sum_{j \in v} x_{0j} = 2b \quad (4.12)$$

$$\sum_{i \in V} \sum_{j \in V, i < j} x_{ij} + \sum_{i \in V} \sum_{j \in V, i < j} x_{ij} \geq 2e(V) \quad \forall V \subseteq v \quad (4.13)$$

$$x_{ij} \in \{0,1\} \quad \forall \{i,j\} \in E, i > 0 \quad (4.14)$$

$$x_{ij} \in \{0,1,2\} \quad \forall \{0,j\} \in E \quad (4.15)$$

Onde: Em (4.10), a função objetivo, minimiza o custo total de viagem. As restrições em (4.11) asseguram que cada cliente possui duas arestas incidentes. Em (4.12) se determina que o número de arestas incidentes no depósito deve ser o dobro da quantidade de veículos b . O impedimento da formação de sub-rotas é apresentado nas restrições em (4.13). Por último, em (4.14) e (4.15) tem-se a definição das variáveis.

4.1.2 Variações do VRP

O Quadro 4.1 apresenta as tradicionais variações do VRP propostas por Lin et al. (2014) seguido de uma breve descrição. Vale ressaltar que as técnicas presentes no quadro possuem variações (incrementos) na literatura.

Quadro 4.1 - Principais variações do VRP

Variação do VRP	Breve descrição
<i>Capacitated VRP</i>	Considere a capacidade do veículo.
<i>Dynamic VRP</i>	Este é um procedimento dinâmico em que os pedidos dos clientes são organizados durante o planejamento e são atribuídos ao veículo apropriado em tempo real.
<i>Fleet Size and Mix VRP</i>	Determina a combinação econômica de veículos na frota, considerando o <i>trade-off</i> entre os custos fixos do veículo e os custos variáveis proporcionais.
<i>Fuzzy VRP</i>	Fórmula os elementos subjetivos, incertos, vagos e ambíguos.
<i>Generalized VRP</i>	Cada cliente pula uma pontuação diferente (ou lucro) e é dividido em agrupamentos de unidades.
<i>Inventory Routing Problem</i>	Garante que não há estoques em cada cliente.
<i>Location Routing Problem</i>	Aborda um único ou um conjunto de depósitos e, subsequentemente, uma série de rotas para os respectivos depósitos abertos para minimizar o custo total.
<i>Multi-compartment MVRP</i>	Nesse caso, o problema envolve veículos heterogêneos e qualificados. A demanda de um cliente por um determinado produto não pode ser dividida.
<i>Multi-depot VRP</i>	Tem mais de um depósito. Cada roteiro começa e termina no mesmo depósito.
<i>Multi-echelon VRP</i>	Facilmente aplicado às em contextos reais, visa minimizar o custo total de transporte dos veículos envolvidos em todos os níveis, ou seja, a entrega do frete abrange toda a cadeia e é obrigada a ser realizada por meio de depósitos intermediários; portanto, vários estágios são realizados.
<i>Open VRP</i>	Cada rota é um caminho hamiltoniano em vez de um ciclo hamiltoniano. Os veículos não são obrigados a retornar ao depósito após a finalização de suas atividades.
<i>Periodic VRP</i>	Procura encontrar um roteamento viável para que o custo associado ao horizonte de tempo seja minimizado.
<i>Pickup and Delivery Problem</i>	Considera a coleta e / ou entrega de mercadorias. Grandes variações estão disponíveis na literatura
<i>Site-dependent VRP</i>	Há independência compatível entre clientes (sites) e tipos de veículos. Cada cliente pode ser visitado apenas por um grupo predefinido de tipos de veículos.
<i>Split-delivery VRP</i>	Cada cliente pode ser atendido por um ou mais veículos.
<i>Stochastic VRP</i>	Ocorre na não aleatoriedade de elementos como tempos de viagem, demanda do cliente ou também grupos de clientes.
<i>Time-dependent VRP</i>	O tempo de viagem entre qualquer par de depósitos e clientes depende da distância entre os pontos ou alternativamente da hora do dia.
<i>VRP with Loading Constraints</i>	Ele determina simultaneamente (como um conjunto) as rotas e os padrões de empacotamento (restrições de carregamento).
<i>VRP with Time Windows</i>	Esse problema pode ser de dois tipos: janelas de tempo rígido (<i>hard</i>) ou flexível (<i>soft</i>). Para o <i>Hard Time Windows</i> , o veículo não pode atrasar, deve chegar a tempo ou cedo. Para <i>Soft Time Windows</i> , pode haver uma violação se houver uma penalidade.

Fonte: Compilado do artigo de Lin *et al.* (2014).

Outras abordagens de taxonomia podem ser encontradas na literatura, como a proposta por Bodin e Golden (1981), Eksioglu *et al.* (2009) e a de Braekers *et al.* (2016).

4.2 PROCEDIMENTOS HEURÍSTICOS E META-HEURÍSTICOS

A seguir são apresentadas as heurísticas construtivas de Clarke e Wright e Inserção do mais próximo. Na sequência as meta-heurísticas Algoritmo Genético (AG) e Busca Tabu (BT) para solucionar o VRP.

4.2.1 Algoritmo dos *Savings* de Clarke e Wright (*Savings* de C&W)

O algoritmo de Clarke & Wright, proposto em 1964, também é conhecido como Heurística das Economias ou dos *Savings* de C&W. Este é um dos algoritmos heurísticos clássicos de construção de rotas (GONÇALVES et al., 2013). A Figura 4.2 apresenta os passos do algoritmo. Ele também pode ser utilizado no PRV.

Figura 4.2 – Passos do Algoritmo dos *Savings* de Clarke e Wright

Algoritmo dos <i>Savings</i> de Clarke e Wright	
INÍCIO	
1. Passo 1: Iniciar pelo vértice “1”.	
2. Passo 2: Calcular os <i>savings</i> :	
3.	$scw_{ij} = c_{1i} + c_{1j} - c_{ij}$
4. para todo $i, j = 2, 3, 4 \dots, n$. Considerar $scw_{ij}=0$, se $i=j, i=1$ e $j=1$;	
5. Passo 3: Ordenar os <i>savings</i> em ordem decrescente;	
6. Passo 4: Iniciando do topo da lista dos <i>savings</i> , ou seja, pelo maior valor, forme sub-rotas maiores até formar um único ciclo, fazendo a ligação dos nós i e j apropriados.	
FIM	

Fonte: Gonçalves et al. (2013).

4.2.2 Algoritmo da Inserção do mais próximo

Os procedimentos heurísticos do Algoritmo da Inserção do mais próximo envolvem a escolha de um vértice inicial, do vértice a ser inserido na solução, além da posição da inserção no vértice. Normalmente parte-se de uma sub-rota e, então, seleciona-se e insere-se os vértices ainda não inclusos até completar um ciclo hamiltoniano (GONÇALVES et al., 2013). A Figura 4.3 apresenta os passos do algoritmo.

Figura 4.3 - Passos do Algoritmo Inserção do mais próximo

Algoritmo da Inserção do mais próximo
INÍCIO
1. Passo 1: Inicie com um sub-grafo consistindo somente do nó i .
2. Passo 2: Encontre o nó k tal que c_{ik} seja mínimo e forneça a sub-rotas $i-k-i$.
3. Passo 3: (Seleção) Dada uma sub-rotas, ache o nó k que não se encontre na sub-rotas e que esteja o mais próximo de qualquer um dos nós da sub-rotas.
4. Passo 4: (Inserção) Busque o arco (i) da sub-rotas que minimize: $c_{ik}+c_{kj}-c_{ij}$. Inserir k entre i e j .
5. Passo 5: Retorne ao Passo 3 até obter um ciclo Hamiltoniano.
FIM

Fonte: Gonçalves et al. (2013).

4.2.3 Algoritmo Genético

Segundo Chaves et al. (2007), Bezerra (2008) e Pinho et al. (2013), o Algoritmo Genético (AG) é um método fundamentado no mecanismo da evolução das espécies, ou seja, natural e da genética, tendo o trabalho de Darwin e do Mendel como base. Tal algoritmo vem sendo utilizado com ampla aplicabilidade, devido a diversos fatores como a capacidade de lidar com funções discretas, contínuas e mistas, o método de busca não ser totalmente aleatório e a descontinuidade de uma função ou de sua derivada não o afetar.

O AG utiliza a mesma nomenclatura da teoria da evolução natural e da genética. Assim, um indivíduo de uma população pode ser formado por um ou mais cromossomos. Ambas as nomenclaturas são válidas se corresponderem a um único elemento. O cromossomo (*string*; solução), que normalmente se implementa como um vetor e cada componente deste vetor é denominado de gene. O alelo é o valor representado pelo gene e o locus é o local fixo deste gene. O conjunto de alelos e genes é representado pelo genótipo e suas características são chamadas de fenótipo. A comparação da terminologia utilizada na Biologia e no contexto de AGs é apresentada no Quadro 4.2.

Quadro 4.2 – Relação da terminologia do Algoritmo Genético com a Biologia

Biologia	Algoritmo Genético
Cromossomo	Indivíduo (<i>string</i>)
Gene	<i>Bit</i>
Alelo	Valor do <i>Bit</i>
Locus	Posição de um <i>Bit</i> específico no indivíduo
Genótipo	Indivíduo candidato a solução - x
Fenótipo	Valor da função para um dado indivíduo - $f(x)$

Fonte: Pinho et al. (2013)

O AG possui os seguintes componentes básicos: a sua representação genética (cromossomo), a população inicial, a função de avaliação (*fitness*), os métodos de seleção, de cruzamento e de mutação, os critérios de parada e a adoção de parâmetros. A Figura 4.4 apresenta um pseudocódigo geral do AG.

Figura 4.4 – Pseudocódigo de um Algoritmo Genético

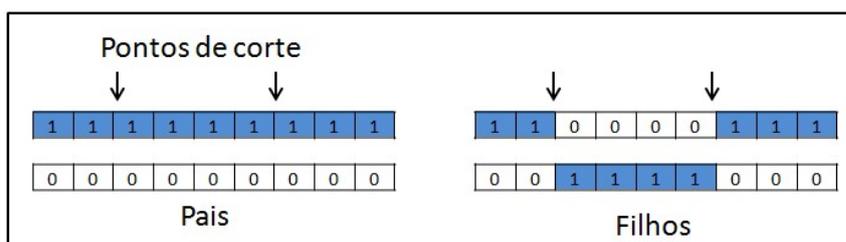
```
Algoritmo Genético  
  
INÍCIO  
1. Inicie a população;  
2. Avalie a população  
3. Enquanto (critério de parada não for atingido) faça  
4.     Selecione indivíduos para próxima geração;  
5.     Aplique cruzamento e mutação;  
6.     Avalie a população;  
7. Fim_Enquanto;  
Fim
```

Fonte: Adaptado de Bezerra (2008).

Inicialmente, a representação genética consiste em fazer com que o computador “compreenda” a base de dados do problema estudado. A geração da população pode ser realizada aleatoriamente ou por meio de uma heurística, que normalmente contribui para uma solução melhor num período de tempo menor. A função de avaliação determina a qualidade do indivíduo, como também a solução do problema em questão. O método de seleção para o cruzamento seleciona as melhores regiões no espaço de busca, ou melhor, seleciona os indivíduos que serão submetidos aos operadores genéticos. Pode-se utilizar para seleção, por exemplo, a roleta simples, seleção elitista ou seleção por torneio.

Os operadores genéticos mais comuns são os de Cruzamento (*Crossover*) e Mutação. No cruzamento, dois indivíduos são combinados para formar novos indivíduos. A diferença deste processo está na escolha do locus dos indivíduos pais a serem trocados para gerar os indivíduos filhos. A Figura 4.5 apresenta um exemplo de cruzamento de dois pontos.

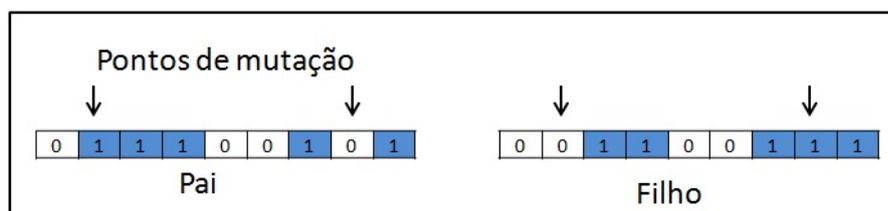
Figura 4.5 – Cruzamento de dois pontos



Fonte: Adaptado de Pinho et al. (2013).

Já a mutação se caracteriza por mudanças aleatórias em determinadas características dos indivíduos; mais especificamente, ela se aplica no nível do *bit* (gene). A Figura 4.6 apresenta um exemplo de mutação binária simples.

Figura 4.6 – Exemplo de uma mutação binária simples



Fonte: Adaptado de Pinho et al. (2013)

Os critérios de parada são critérios com a finalidade de delimitar o número de buscas após certo número de gerações (iterações) finalizadas em um AG. São implementados por meio de um número máximo de iterações, quando a população não apresenta melhora ou, ainda, em caso de diminuição da diversidade populacional. Por fim, o AG possui alta sensibilidade em relação a quatro parâmetros que são: tamanho da população, número de gerações, taxa de cruzamento e taxa de mutações.

4.2.4 Busca Tabu

De acordo com Gonçalves et al. (2013) e Alves (2015), considera-se que Glover (1986) é o pai da meta-heurística Busca Tabu (BT; ou *Tabu Search*; TB) devido aos inúmeros trabalhos publicados neste contexto. A BT explora soluções no espaço solução além do ótimo local. O método segue a premissa da busca local, onde gera movimentos a cada iteração através das soluções vizinhas. O movimento transforma uma solução em outra e a vizinhança é um conjunto de soluções que possibilita um conjunto de movimentos possíveis.

O algoritmo BT se norteia em três premissas: a primeira se refere ao uso de uma estrutura de dados (lista) para armazenar o histórico da evolução do processo de busca. A segunda, trata do uso de um mecanismo de controle para o aceite ou não da nova solução, com base nos registros da lista tabu referente as restrições e aspirações desejadas. A terceira e última, visa a incorporação de procedimentos que modificam as estratégias de diversificação e oscilação.

O primeiro passo do procedimento é a definição de uma solução inicial. Cada passo do algoritmo gera uma vizinhança da solução atual e posteriormente, se pesquisa o melhor vizinho, que fará parte da solução vigente.

A lista tabu tem a finalidade de não deixar que uma mesma solução passe pelo mesmo caminho dentro de um certo tempo em que o movimento deve permanecer na lista. Por haver movimentos proibidos (tabus), eles podem ser quebrados com o critério de aspiração, que autoriza o movimento, somente se a solução proibida for melhor do que a qualquer solução encontrada até aquele momento. O algoritmo finaliza ao alcançar o critério de parada que normalmente é um número pré-estabelecido ou de iterações após a última melhoria encontrada. A Figura 4.7 apresenta o pseudocódigo da meta-heurística BT.

Figura 4.7 - Pseudocódigo da meta-heurística Busca Tabu

<p>Procedimento Busca Tabu</p> <p>INÍCIO</p> <ol style="list-style-type: none"> 1. $s_0 \leftarrow$ Geração da solução inicial; 2. $s^* \leftarrow s_0$; * {Melhor solução obtida até então} 3. $s \leftarrow s_0$; 4. $IterT \leftarrow 0$; {Contador do número de iterações} 5. $MelhorIter \leftarrow 0$; {Iteração mais recente que forneceu s^*} 6. Seja $BTmax$ o número de iterações sem melhora em s^*; 7. $LT \leftarrow \emptyset$; {Lista Tabu} 8. Enquanto ($IterT - MelhorIter \leq BTmax$ e $IterT < IterMax$) faça 9. $IterT \leftarrow IterT + 1$; 10. Seja $S' \leftarrow S \oplus mov$ o melhor elemento de $V \subset N(s)$ tal que o movimento mov não seja tabu ($mov \notin LT$) ou se tabu, atenda ao critério de aspiração, isto é, $f(s') < f(s^*)$; 11. Atualize a LT; 12. $s \leftarrow s'$; 13. Se $f(s') < f(s^*)$ então 14. $s^* \leftarrow s'$; 15. $MelhorIter \leftarrow IterT$; 16. Fim Se; 17. Fim-Enquanto; 18. Retorne s^*; <p>FIM</p>
--

Fonte: Adaptado de Alves (2015).

4.3 OTIMIZAÇÃO MULTI-OBJETIVO

A otimização multi-objetivo (*Multi Objective Optimization* - MOO) refere-se ao processo de otimizar dois ou mais objetivos conflitantes de forma simultânea sujeitos a restrições (DEMIR et al., 2014a). Ao tratar do problema de minimização, o modelo matemático fica definido de (4.16) a (4.20) a seguir.

$$\text{Min } Z = f(x) = [f_1(x), f_2(x), \dots, f_k(x)]^T \quad (4.16)$$

$$\text{s. a.: } g(x) = [g_1(x), g_2(x), \dots, g_m(x)]^T \leq 0 \quad (4.17)$$

$$h(x) = [h_1(x), h_2(x), \dots, h_p(x)]^T = 0 \quad (4.18)$$

$$x = [x_1, x_2, \dots, x_n]^T \in X \quad (4.19)$$

$$z = [z_1, z_2, \dots, z_n]^T \in Z \quad (4.20)$$

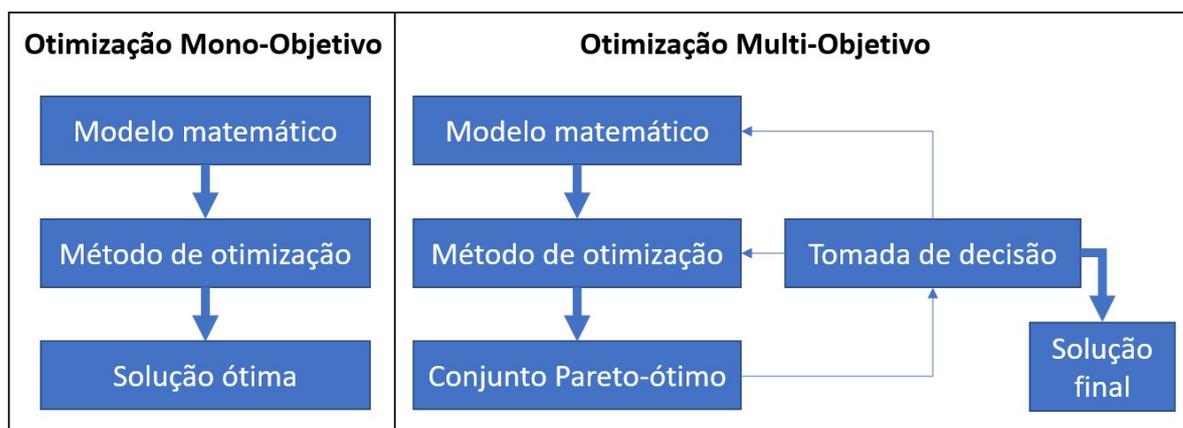
onde, x : vetor das variáveis de decisão de dimensão n ; Z e $f(x)$: correspondem ao vetor das funções objetivo de dimensão k ; $g(x)$: trata do conjunto de restrições de desigualdade de dimensão m ; $h(x)$, o conjunto de restrições de igualdade de dimensão p . Em (4.16), o espaço $Z = f(x)$ trata da imagem de X , assim denominado de região factível no espaço das funções objetivo. As restrições apresentadas em (4.17) e (4.18) definem o espaço das variáveis de decisão em R^n da região factível X e qualquer ponto $x \in X$ como uma solução factível. Em (4.19) tem-se o domínio das variáveis de decisão e, por fim, em (4.20), o domínio das funções objetivo (MACIEL, 2012).

Vale destacar que se não houver conflitos e for possível encontrar uma solução única (trivial), então não se justifica a utilização de MOO. Portanto, vamos considerar que este caso não ocorrerá e que existe algum conflito entre as funções objetivo. Além disso, ao procurar soluções, chega-se a um ponto em que, ao tentar melhorar um objetivo, os outros serão prejudicados. Portanto, uma solução será considerada Pareto eficiente (Pareto ótimo ou fronteira não dominada) se não puder ser eliminada da análise por conta de outra solução que melhore um dos objetivos sem piorar os demais. Por fim, o objetivo de um problema MOO é encontrar soluções não dominadas e quantificar os *trades-off* na satisfação dos diferentes objetivos estabelecidos (MIETTINEN, 1999 e DEMIR et al., 2014a).

Em contrapartida, o caso da otimização mono-objetivo caracteriza-se por uma única função objetivo que geralmente resulta em uma solução única, salvo casos

particulares (múltiplas soluções). A Figura 4.8 apresenta a estrutura básica ao tratar da otimização mono-objetivo e multi-objetivo.

Figura 4.8 – Estrutura básica da otimização mono e multi-objetivo



Fonte: Adaptado de Maciel (2012, pg.38).

Segundo Ehrgott et al. (2012), no caso de problemas de roteamento bi-objetivo, em vez de obter a rota mais curta considerando a relação origem-destino, o objetivo é gerar rotas eficientes, ou seja, um conjunto de soluções de compromisso. Assim, são denominadas de rotas eficientes aquelas que não apresentam melhoria quando tentamos aprimorar a solução geral alterando, por exemplo, um determinado ponto de demanda de uma rota para outra rota e/ou vice-versa.

Os métodos de MOO podem ser classificados em métodos geradores e métodos baseados em preferências. Os métodos geradores buscam gerar um ou mais pontos ótimos de Pareto não levando em consideração o uso de preferências. Os métodos baseados em preferência utilizam informações cedidas pelo tomador de decisão (*decision maker*), *a priori* ou de forma iterativa, como parte de seu processo de solução.

Os métodos clássicos comumente utilizados para a resolução de problemas MOO podem ser organizados em quatro categorias. A primeira aborda os métodos para não articular a informação de preferência dada como, por exemplo, o *Method of Global Criterion*. Na segunda têm-se os métodos *a priori* como, por exemplo, os *Methods for Cardinal Information Given (Utility Function e Bounded Objective)* e *Methods for Mixed Ordinal and Cardinal Information Given (Lexicographic Method e Goal Programming)*. Na terceira categoria têm-se os métodos para a articulação progressiva, dos quais se destacam os *Methods for Explicit Trade-Off Information*

Given (métodos iterativos) e os métodos implícitos. Por fim, a última, têm-se os métodos *a posteriori*, nos quais se enquadram o *Parametric Method*, *ϵ -constraint*, MOLP (*Multi-objective Linear Programming*) e *Adaptative Search* (HWANG e MASUD, 1979).

Em outras palavras, sintetizando, os métodos *a priori*, tem a característica da tomada de decisão ao ocorrer antes de proceder com o processo de busca das soluções. Já no caso dos métodos *a posteriori*, após a busca das soluções é que se toma a decisão. Por fim, nos métodos iterativos, o decisor intervém durante os resultados parciais (COELLO et al., 2007 e MACIEL, 2012).

A seguir, é apresentado o referencial a respeito de Dominância e Fronteira de Pareto; *Weight method*; algoritmo ϵ -restrito, algoritmo NSGA-II e o algoritmo MOPSO, sendo estes da 4ª Classe, ou seja, *a posteriori*.

4.3.1 Dominância e Fronteira de Pareto

Em MOO, a otimalidade foi introduzida por Francisco Ysidro Edgeworth (EDGEWORTH, 1881) e posteriormente aprimorada por Vilfredo Pareto (PARETO, 1896). Por conta disso se utiliza a nomenclatura de Edgeworth-Pareto, Pareto-otimalidade, Pareto-ótimo ou Fronteira de Pareto (PF, *Pareto Front*).

De acordo com Meza (2014) e Dasgupta et al. (1999), em MOO não existe uma solução única, pois, em geral, não se tem uma solução que seja a melhor para todos os objetivos. Então, define-se um conjunto de Pareto, onde cada solução no conjunto representa um vetor objetivo na PF. A solução PF é considerada um conjunto de soluções ótimas e não-dominadas. A seguir, cinco definições de Dominância e PF segundo Meza (2014) e Dasgupta et al. (1999).

Definição 1 – Otimalidade de Pareto: um vetor objetivo z_1 é Pareto ótimo se não houver outro vetor objetivo z_2 , tal que $z_{i2} \leq z_{i1}$ para todo $i = [1, \dots, m]$ e $z_{j2} < z_{j1}$ para todo $j, j = [1, \dots, m]$.

Definição 2 – Estrita Dominância: um vetor objetivo z_1 é dominado por outro vetor z_2 se $z_{i2} < z_{i1}$ para todo $i, i = [1, \dots, m]$.

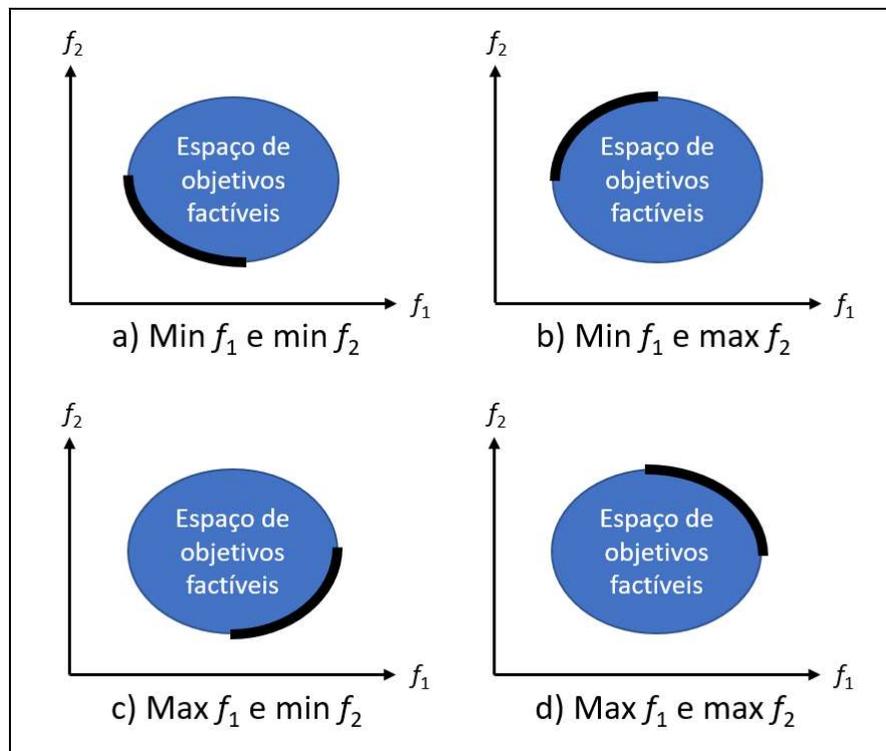
Definição 3 – Dominância: um vetor objetivo z_1 domina outro vetor z_2 se z_1 não for pior que z_2 em todos os objetivos e melhor em pelo menos um objetivo, ou seja, $z_1 < z_2$.

Definição 4 – Dominância Fraca: um vetor objetivo z_1 dominante fracamente outro vetor z_2 se z_1 não for pior que z_2 em todos os objetivos.

Definição 5 – s-Pareto Ótimo: Dado um problema Multi-objetivo e K conceitos de projetos, um vetor objetivo z_1 é s-Pareto Ótimo se não houver outro vetor objetivo z_2 no conceito de projeto k tal que $z_{2i} \leq z_{1i}$ para todo $i = [1, \dots, m]$ e todos os conceitos k , onde $k = [1, \dots, K]$; e $z_{2j} < z_{1j}$ pelo menos um $j, j = [1, \dots, m]$ para qualquer conceito k .

A Figura 4.9 apresenta o comportamento da PF ao tratar de diferentes combinações da abordagem de minimização e maximização em um problema de otimização bi-objetivo.

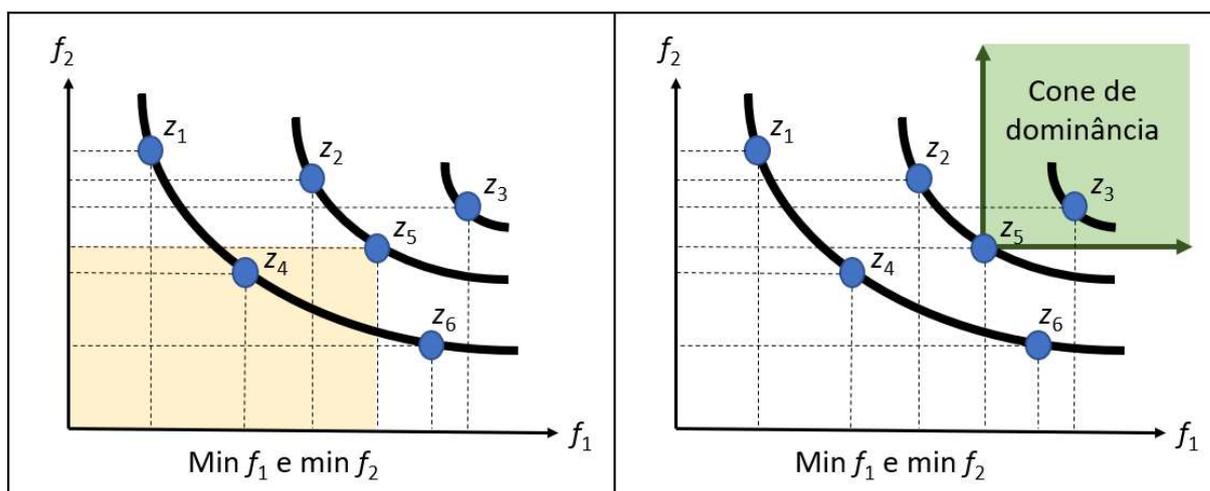
Figura 4.9 – Exemplo de fronteira de Pareto no espaço de objetivos factíveis



Fonte: O autor.

A Figura 4.10 (lado esquerdo) demonstra em amarelo a área que abrange o ponto z_4 , que por sua vez, domina o ponto z_5 . Em contrapartida, na Figura 4.10 (lado direito), apresenta o cone de dominância representado em verde, onde z_3 é dominado pelo ponto z_5 .

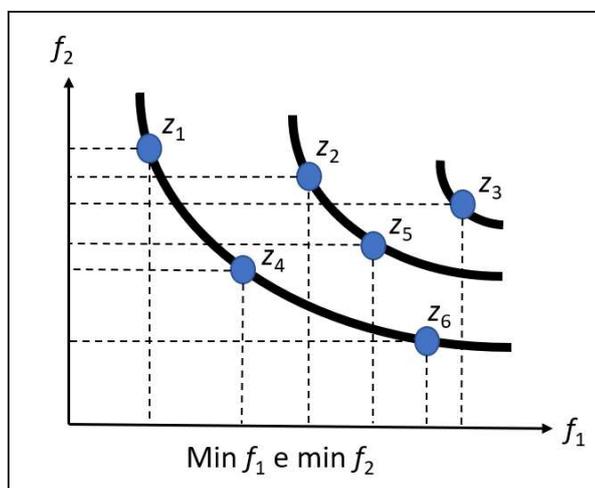
Figura 4.10 – Exemplo de dominância Pareto



Fonte: O autor.

Na Figura 4.11, z_4 domina z_2 , z_5 e z_3 . Observa-se que z_4 e z_6 são soluções não-dominadas, pois z_4 é pior do que z_6 em f_2 e z_6 é pior do que z_4 em f_1 . Neste contexto, as soluções z_1 , z_4 e z_6 são não-dominadas por qualquer outra solução da população de soluções apresentada. Assim, estes elementos (z_1 , z_4 e z_6) são pertencentes à fronteira de Pareto.

Figura 4.11 – Exemplo de fronteira de Pareto



Fonte: O autor.

4.3.2 Weighted Method

O *Weighted method* (método da ponderação, WM), também chamado de método dos pesos ou método da soma ponderada, associa cada função objetivo com um coeficiente de ponderação e minimiza a soma ponderada dos objetivos utilizados, assim transformando-a em uma única função objetivo. O procedimento adotado neste método também é chamado de escalarização, isto é, a transformação de um problema com vários objetivos em um outro com apenas um objetivo.

Segundo Deb (2001), dentre as técnicas multi-objetivo, esta é a abordagem mais simples. Além disso, a solução é garantida em um problema convexo.

Em (4.21) a (4.24) está a formulação matemática para o método das ponderações. Vale lembrar que a soma dos pesos deve estar normalizada.

$$\text{Min } Z = \sum_{k=1}^{N_{obj}} w_k f_k(x) \quad (4.21)$$

$$\text{s. a.: } g_j(x) \geq 0 \quad j = 1, \dots, NR_{des} \quad (4.22)$$

$$h_k(x) = 0 \quad k = 1, \dots, NR_{igu} \quad (4.23)$$

$$x_i^{(inf)} \leq x_i \leq x_i^{(sup)} \quad i = 1, \dots, N_{val} \quad (4.24)$$

onde, em (4.21) tem-se a função objetivo, w_k pertence ao intervalo $[0,1]$ e refere-se ao peso para cada função objetivo f_k . As restrições são apresentadas em (4.22) e (4.23). Por fim, o domínio das variáveis de decisão está em (4.24).

4.3.3 Método ε -restrito

O método ε -restrito foi proposto por Haimes et al., em 1971. Segundo Deb (2001), em seu mecanismo deve-se selecionar apenas uma das funções objetivo para otimização e as demais são incorporadas às restrições. Este método encontra soluções PF em casos convexo, não-convexo e discreto. Assim, tenta-se obter uma aproximação da fronteira eficiente a partir das soluções ótimas para os diferentes parâmetros de entrada " ε ". Em (4.25) a (4.29) está a respectiva formulação matemática.

$$\text{Min } Z = f_k(x) \quad (4.25)$$

$$\text{s. a.: } f_m(x) \leq \varepsilon_m \quad m = 1, \dots, N_{obj} \text{ e } m \neq k \quad (4.26)$$

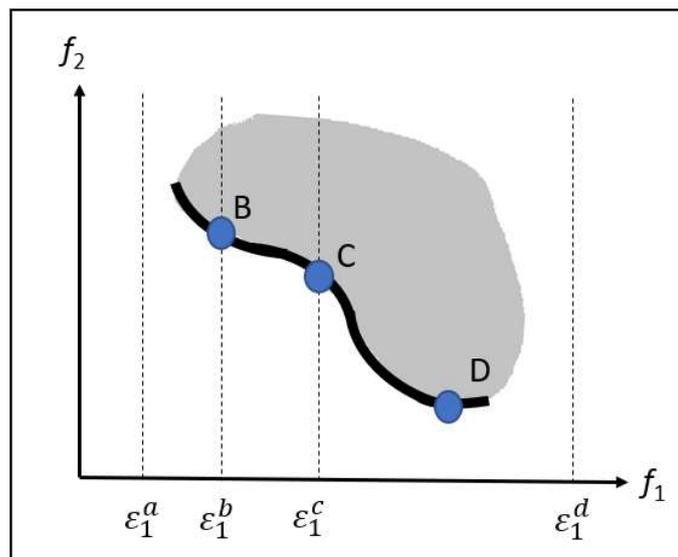
$$g_j(x) \geq 0 \quad j = 1, \dots, NR_{des} \quad (4.27)$$

$$h_k(x) = 0 \quad k = 1, \dots, NR_{igu} \quad (4.28)$$

$$x_i^{(inf)} \leq x_i \leq x_i^{(sup)} \quad i = 1, \dots, N_{val} \quad (4.29)$$

onde, em (4.25) consta a função objetivo selecionada. As demais funções objetivo estão representadas como restrições do problema em (4.26), junto das restrições (4.27) e (4.28). O domínio das variáveis de decisão, em (4.29). A Figura 4.12 apresenta o funcionamento do método, sendo que vale destacar que se deve fazer várias iterações para gerar a fronteira de Pareto.

Figura 4.12 – Exemplo de método ε -restrito



Fonte: O autor.

4.3.4 Algoritmo Genético Multi-objetivo

Holland (1975) desenvolveu o conceito do AG nas décadas de 1960 e 1970. O AG tem sido muito utilizado para aplicações multi-objetivo. Segundo Konak et al. (2006), em seu artigo “*Multi-objective optimization using genetic algorithms: A tutorial*”, as variações mais utilizadas do AG Multi-objetivo são apresentadas no Quadro 4.3, onde as mesmas estão organizadas por algoritmo, função *fitness*, mecanismo de diversidade da solução, elitismo, vantagens e desvantagens. Na sequência é apresentado um breve resumo de cada um deles.

Quadro 4.3 - Principais variações do Algoritmo Genético Multi-objetivo

Algoritmo	Função <i>fitness</i>	Mecanismo de diversidade	Elitismo	Vantagens	Desvantagens
VEGA, 1985	Cada subpopulação é avaliada em relação a um objetivo diferente.	Não	Não	Primeira implementação direta do MOGA.	Tende a convergir ao extremo de cada objetivo.
WBGA, 1992	Média ponderada dos objetivos normalizados.	<i>Niching</i> . Pesos predefinidos.	Não	Simple extensão do AG de mono-objetivo.	Dificuldades no espaço de função objetivo não-convexo.
MOGA, 1993	Classificação de Pareto.	<i>Fitness</i> compartilhado por nicho.	Não	Simple extensão do AG de mono-objetivo.	Geralmente tem a convergência lenta. Problemas relacionados ao parâmetro de tamanho de nicho.
NPGA, 1994	Sem atribuição de <i>fitness</i> , seleção de torneios.	contagem de nicho como desempate na seleção do torneio.	Não	Processo de seleção muito simples com seleção de torneios.	Problemas relacionados ao parâmetro de tamanho de nicho. Parâmetro extra para seleção de torneios.
NSGA, 1994	Classificado com base na classificação não dominada.	<i>Fitness</i> compartilhado por nicho.	Não	Rápida convergência.	Problemas relacionados ao parâmetro de tamanho de nicho.
RWGA, 1995	Média ponderada dos objetivos normalizados.	Pesos atribuídos aleatoriamente.	Sim	Implementação eficiente e fácil.	Dificuldades no espaço de função objetivo não-convexo.
PAES, 1996	O domínio de Pareto é usado para substituir um pai, se o filho dominar.	Densidade baseada em células como desempate entre os filhos e os pais.	Sim	Estratégia de escalada aleatória em mutações. Fácil de implementar.	Não é uma abordagem baseada na população. O desempenho depende dos tamanhos das células.
SPEA, 1999	Classificação baseado no arquivo externo de soluções não-dominadas.	<i>Cluster</i> para truncar a população externa.	Sim	Muito utilizado. Nenhum parâmetro para a clusterização.	Algoritmo de agrupamento complexo.
PESA, 2000	Nenhuma atribuição de condicionamento físico.	Densidade baseada em células.	Puro elitismo	Fácil de implementar. Computacionalmente	O desempenho depende dos tamanhos das células.

				eficiente.	Informações prévias necessárias sobre o espaço objetivo.
NSGA-II, 2000	Classificado com base na classificação não dominada.	<i>Crowding distance</i> .	Sim	Parâmetro único (N). Muito utilizado. Eficiente.	<i>Crowding distance</i> funciona apenas no espaço objetivo.
SPEA-II, 2001	Força dos dominadores.	Densidade baseada no k -ésimo vizinho mais próximo.	Sim	SPEA aprimorado.	Pontos externos são preservados.
RDGA, 2003	O problema foi reduzido para um problema bi-objetivo com classificação e densidade da solução como objetivos.	Densidade baseada em célula da região proibida.	Sim	Atualização dinâmica de célula. Robusto em relação ao número de objetivos.	Mais difícil de implementar do que outros.
DMOEA, 2003	Classificação baseada em células.	Densidade adaptativa baseada em células.	Sim (implícito)	Inclui técnicas eficientes para atualizar as densidades das células. Abordagens adaptativas para definir parâmetros do AG.	Mais difícil de implementar do que outros.

Fonte: Adaptado de Konak et al. (2006).

O algoritmo *Vector Evaluated Genetic Algorithm* (VEGA), proposto por Schaffer (1985), foi o primeiro AG que utilizou um conjunto de soluções para aproximar a fronteira de Pareto. Trata-se de uma extensão direta de um AG mono-objetivo e as trocas de objetivo fazem com que a população encontrada seja boa para um objetivo e nem tanto para os demais objetivos.

No *Weight-based Genetic Algorithm* (WPGA), proposto por Hajela e Lin (1992), um vetor de pesos é incorporado no cromossomo da solução que contribui para promover a diversidade, além disso, várias soluções podem ser pesquisadas simultaneamente. O algoritmo *Multiple Objective Genetic Algorithm* (MOGA), proposto por Fonseca e Fleming (1993), foi o primeiro a buscar verdadeiramente pela fronteira de Pareto com o uso de condicionamento físico (*sharing*) para manter a diversidade da população. Por fim, O WPGA e o MOGA são simples extensões do AG mono-objetivo.

O *Niched Pareto Genetic Algorithm* (NPGA), proposto por Horn et al (1994), possui um processo de seleção muito simples com seleção de torneios. Já o *Random Weighted Genetic Algorithm* (RWGA), proposto por Murata e Ishibuchi (1995), é uma variação do MOGA onde cada solução recebe um vetor de pesos gerado aleatoriamente durante a fase de seleção em cada geração.

Knowles e Corne (1999) apresentaram uma versão memética do *Pareto-Archived Evolution Strategy* (PAES), sendo que o PAES utiliza do conceito de dominância e da densidade como procedimento de busca local para manter a diversidade das soluções.

Pareto Envelope-based Selection Algorithm (PESA), proposto por Corne et al. (2000), neste algoritmo elitista é definido o número de soluções por célula e, entre duas soluções não dominadas e que tem a menor densidade é preferível. O algoritmo *Dynamic Multi-objective Evolutionary Algorithm* (DMOEA), proposto por Yen e Lu (2003), é um outro exemplo de procedimento elitista.

Nondominated Sorting Genetic Algorithm (NSGA), proposto por Srinivas e Deb (1994), classifica a população em fronteiras não dominadas. A sua evolução, *Fast Nondominated Sorting Genetic Algorithm* (NSGA-II), também proposto por Deb et al. (2000), trata de uma versão mais eficiente que o NSGA e que utiliza o *crowding distance* para ampliar a diversificação das soluções.

O *Strength Pareto Evolutionary Algorithm* (SPEA), proposto por Zitzler e Thiele (1999), é um algoritmo que utiliza a classificação de não-dominância por meio

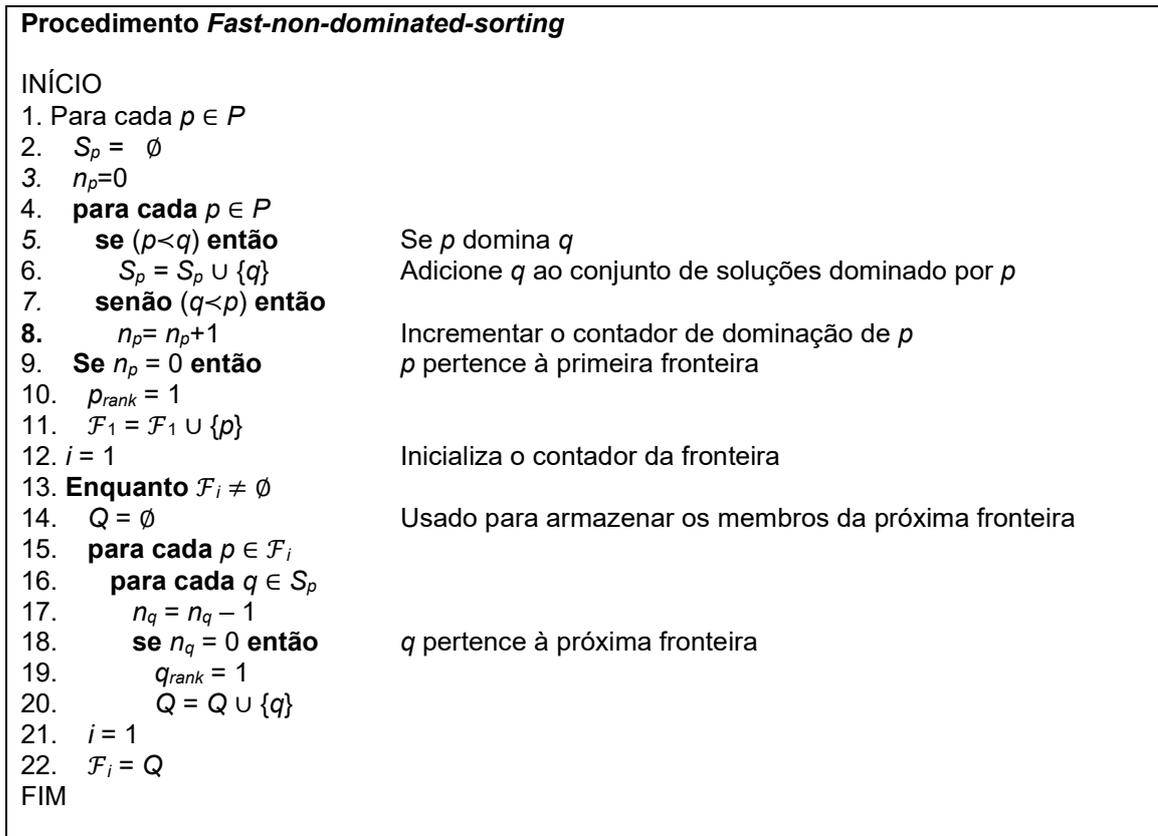
de um arquivo externo de tamanho fixo. Por outro lado, o seu sucessor *Region-based Selection in Evolutionary, Multiobjective Optimization* (SPEA-II), também proposto por Zitzler et al. (2001), evoluiu com o uso de uma medida de densidade para discriminar soluções de uma mesma classificação.

O algoritmo *Rank-Density Based Genetic Algorithm* (RDGA), proposto por Lu e Yen (2003), usa uma abordagem baseada em células que converte um problema de k objetivos em um problema bi-objetivo, com a finalidade de minimizar o valor da classificação individual e a densidade da população. Ainda se tem outras variações tais como o *Region-based Selection in Evolutionary Multiobjective Optimization* (PESA-II), *Multi-objective Evolutionary Algorithm* (MEA), dentre outras mais.

4.3.4.1 Algoritmo NSGA II

O *Non-dominated Sorting Genetic Algorithm II* (AG de ordenação não dominada II, NSGA-II), proposto por Deb et al. (2002) é um AG multi-objetivo que classifica as soluções através do conceito de dominância de Pareto.

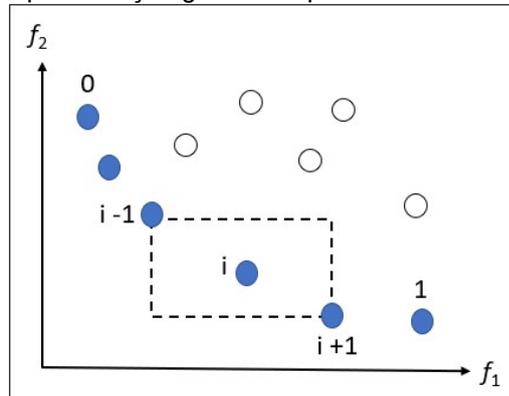
O diferencial deste algoritmo ocorre por meio do “Elitismo”, que garante a preservação de boas soluções no processo de busca; do procedimento “*Fast-non-dominated-sorting*” (ordenamento rápido não-dominado, FNS) onde ocorre a classificação da população em diferentes níveis através do uso da dominância de Pareto. A Figura 4.13 apresenta o procedimento *Fast-non-dominated-sorting*. Neste contexto, todas as soluções na primeira fronteira não-dominada terão a sua contagem de dominação como zero. Na sequência, para cada solução p com $np = 0$, visitamos cada membro (q) de seu conjunto Sp (conjunto de soluções dominado por p) e reduz-se a contagem de dominação em uma unidade. Com esse procedimento, se para qualquer membro q , a contagem de dominação for zero, será colocada em uma lista separada Q , sendo então pertencente à segunda frente não-dominada. Então, o procedimento acima é repetido com cada membro de Q e a terceira fronteira é identificada. O processo continua até a formação de todas as fronteiras.

Figura 4.13 – Procedimento *Fast-non-dominated-sorting*

Fonte: Adaptado de Deb et al. (2002).

O “*Crowding Distance Assignment*” (atribuição da distância de aglomeração, CD) tem a finalidade de garantir a diversidade da população elitista, por meio das melhores soluções. A Figura 4.14 mostra uma representação gráfica do procedimento de CD e a Figura 4.15 apresenta o procedimento do algoritmo do CD.

Figura 4.14 – Representação gráfica do procedimento Crowding Distance



Fonte: Adaptado de Deb et al. (2002).

Figura 4.15 – Procedimento *Crowding Distance*

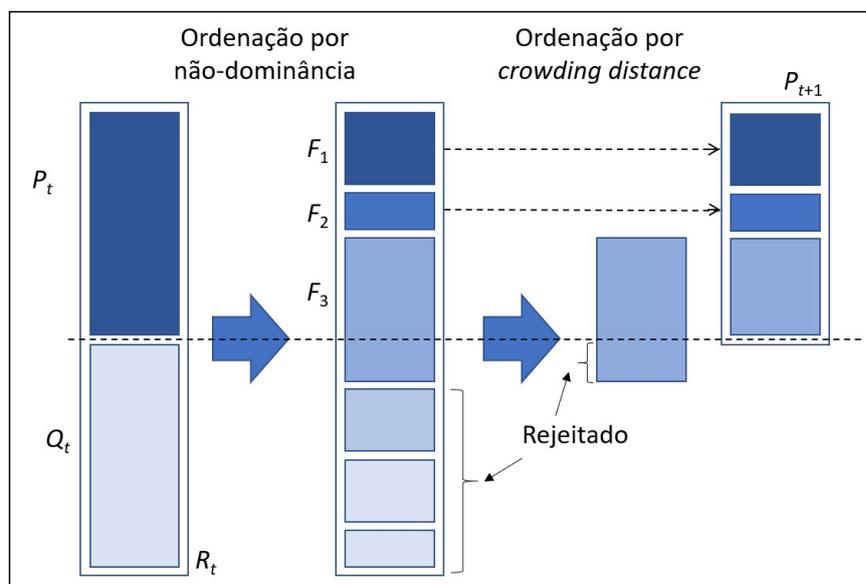
Procedimento <i>Crowding Distance</i>	
INÍCIO	
1. $I = \mathcal{F} $	Número de soluções em \mathcal{F}
2. Para cada i , o conjunto \mathcal{F} $[i]_{distance} = 0$	Inicializa a distância
3. Para cada objetivo m	
4. $\mathcal{F} = \text{ordenar}(\mathcal{F}, m)$	Classifique usando cada valor objetivo
5. $\mathcal{F} [1]_{distance} = \mathcal{F} [I]_{distance} = \infty$	Para a seleção dos pontos de contorno
6. para $i = 2$ até $(I - 1)$	Para todos os outros pontos
7. $\mathcal{F} [i]_{distance} = \mathcal{F} [i-1]_{distance} + (\mathcal{F} [i+1].m - \mathcal{F} [i-1].m) / (f_m^{max} - f_m^{min})$	
FIM	

Fonte: Deb et al. (2002).

O procedimento de cálculo do CD utiliza a classificação da população, de acordo com cada valor atribuído a função objetivo em ordem crescente de magnitude, visto que todas as funções objetivo devem ser normalizadas. Para cada função objetivo referente às soluções com o menor e maior valor, são atribuídos valor infinito de distância. As outras soluções intermediárias recebem um valor de distância igual à diferença normalizada absoluta.

A combinação do FNS e do CD resulta no *Crowded-Comparison Operator* (operador de comparação lotada), com a finalidade de comparar duas soluções priorizando o critério de dominância, sempre favorecendo a diversidade. Este possui fundamental importância como operador genético de seleção por torneio, pois possibilita a escolha de uma solução em um contexto de múltiplas funções objetivo. Este algoritmo tem como procedimento gerar uma população inicial aleatória P_t de dimensão N e uma população de descendentes Q_t , da mesma dimensão, com o uso de operadores genéticos. Então, combina-se estas populações e se obtém o conjunto R_t com $2 \times N$ indivíduos. Esta população é ranqueada pelos indivíduos não-dominados da primeira fronteira e assim por diante até completar o tamanho N . Assim, os indivíduos excedentes não são considerados por causa do critério de diversidade, que aceita os indivíduos com maior valor do índice *distance* para compor P_{t+1} . A Figura 4.16 sintetiza o procedimento do algoritmo NSGA-II de forma visual.

Figura 4.16 – Esquema do procedimento NSGA-II



Fonte: Adaptado de Deb et al. (2002).

Após a criação desta nova população, cria-se a população de descendentes Q_{t+1} , com o uso dos operadores genéticos de seleção, cruzamento (recombinação) e mutação. O algoritmo finaliza após atender ao critério de parada. A Figura 4.17 apresenta o procedimento NSGA-II na forma de algoritmo.

Figura 4.17 – Procedimentos do Algoritmo NSGA-II

Procedimento NSGA-II

R_t = Conjunto de pais e filhos.

P_t = Conjunto de pais.

Q_t = Conjunto de filhos (crossover e mutados).

\mathcal{F}_i = Fronteira i .

N = tamanho da população.

INÍCIO

1. Criar uma população de soluções aleatórias P_1 de N indivíduos

2. Ordenar P_1 por dominância

3. Aplicar operadores genéticos em P_1 para gerar uma nova população, Q_1 de tamanho N

4. $R_t = P_t \cup Q_t$

Combinar população de pais e filhos

5. $\mathcal{F} = \text{fast-non-dominated-sort}(R_t)$

$\mathcal{F} = (\mathcal{F}_1, \mathcal{F}_2, \dots)$, fronteiras não-dominadas de R_t

6. $P_{t+1} = \emptyset$ e $i = 1$

7. **Até que** $|P_{t+1}| + |\mathcal{F}_i| < N$

Até que a população parental seja preenchida

8. **Crowding-distance-assignment**(\mathcal{F}_i)

Calcule o *crowding-distance* na \mathcal{F}_i

9. $P_{t+1} = P_{t+1} \cup \mathcal{F}_i$

Incluir a fronteira não dominada na população pai

10. $i = i + 1$

Verifique a próxima fronteira para inclusão

11. Ordenar ($\mathcal{F}_i, <n$)

Classificar em ordem decrescente $<n$

12. $P_{t+1} = P_{t+1} \cup \mathcal{F}_i[1 : (N - |P_{t+1}|)]$

Escolha o primeiro $(N - |P_{t+1}|)$ elemento da \mathcal{F}_i

13. $Q_{t+1} = \text{make-new-pop}(P_{t+1})$

Crossover e mutação para criar nova pop. Q_{t+1}

14. $t = t + 1$

Incrementar o contador de geração

FIM

Fonte: Adaptado de Deb et al. (2002).

4.3.5 Algoritmo MOPSO

Segundo Abad et al. (2018) o *Multi-objective particle swarm optimization* (otimização de enxame de partículas multiobjetivo, MOPSO), proposto por Coello (2000), demonstra-se muito eficiente e tem sido amplamente utilizado na literatura a fim de resolver vários problemas de otimização. As três etapas deste algoritmo realizam a inicialização, *unloaded sorting* (classificação não-carregada) e *crowding distance*, apresentado na seção 4.3.4.1. Na sequência, a velocidade da partícula e sua atualização ocorre por meio das equações (4.30) e (4.31).

$$vel_{k+1,d}^i = w * vel_{k,d}^i + C_1 * r_1 (pbest_{k,d}^i - x_{k,d}^i) + C_2 * r_2 * (gbest_{k,d}^i - x_{k,d}^i) \quad (4.30)$$

$$x_{k+1,d}^i = x_{k,d}^i + vel_{k+1,d}^i \quad (4.31)$$

onde, r_1 e r_2 são números aleatórios uniformes; C_1 e C_2 são constantes que especificam a aceleração de partículas para *pbest* e *gbest*; w se refere ao peso inercial. Para o cálculo do peso inercial, pode-se fazer uso da distribuição linear proposta por Kennedy et al. (2001), conforme (4.32).

$$W = W_{max} - \frac{W_{max} - W_{min}}{Maxiteration} iteration \quad (4.32)$$

E assim, W_{max} e W_{min} tratam, respectivamente, da quantidade máxima e mínima de inércia. A Figura 4.18 apresenta o procedimento MOPSO na forma de algoritmo.

Figura 4.18 – Procedimento do Algoritmo MOPSO

Procedimento MOPSO

INÍCIO

1. Inicialização do enxame;
2. Inicialização do repositório;
3. Avaliação do repositório e seleção do líder;
4. **Enquanto** não for satisfeito o critério de parada **faça**
5. **Para cada partícula** \in *enxame* **faça**
6. Atualização da velocidade;
7. Atualização da posição;
8. Turbulência;
9. Avaliação do desempenho;
10. Atualização do componente individual;
11. **Fim**
12. Atualização do repositório e seleção do líder;
13. **Fim**
14. **Return** repositório.

FIM

Fonte: Adaptado de Coello (2000) e Lima (2017).

O algoritmo MOPSO apresentado na Figura 4.18 começa com a inicialização do enxame das partículas, do repositório e da avaliação do repositório, onde é definida a fronteira de Pareto inicial e o valor do *gbest* (líder). Em seguida começa um *loop* com a atualização de cada partícula quanto a velocidade e posição; um procedimento de turbulência; a avaliação do desempenho por meio das funções objetivo e a atualização das partículas individualmente. No final da iteração é atualizado o repositório e a seleção do líder. Então, quando atingido o critério de parada, o algoritmo retorna o repositório com o conjunto final de soluções (fronteira de Pareto).

Para a seleção do líder pode-se utilizar algum critério na escolha das partículas inseridas no repositório. Esta escolha pode ser aleatória ou, por exemplo, a partícula com o maior valor de CD.

4.3.6 Métodos de avaliação da solução

A literatura apresenta muitos métodos e técnicas para a avaliação de uma solução obtida por meio da abordagem multi-objetivo. Neste contexto, segundo Assis (2013), as principais características avaliadas são: (i) a cardinalidade, ou seja, o número de soluções obtidas; (ii) a proximidade quanto a fronteira de Pareto; (iii) a extensão, que trata do intervalo de valores coberto pela fronteira para cada objetivo e (iv) a distribuição, ou seja, se ao longo da fronteira, as soluções estão uniformemente distribuídas.

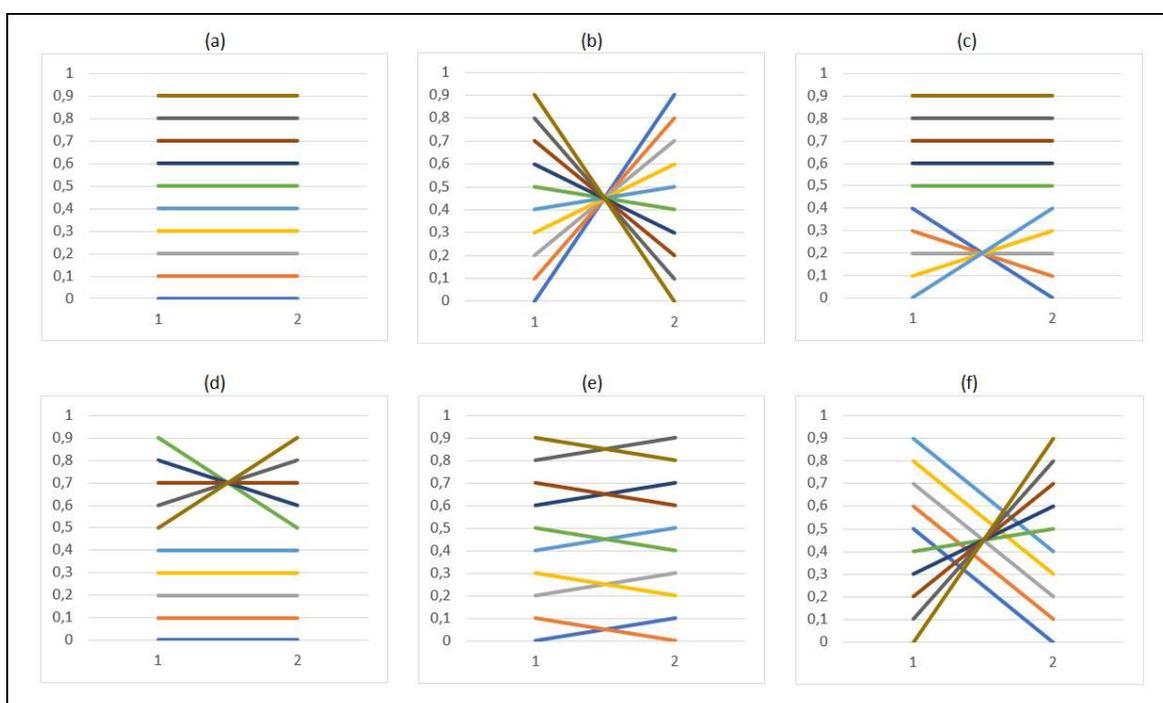
Dentre elas pode-se destacar algumas técnicas que utilizam ou não uma solução (normalmente o resultado exato) como referência. Como técnicas que utilizam uma solução como referência pode-se destacar o indicador de distância, indicador de espaçamento, indicador de diversidade, grau de dominância e porcentagem de soluções eficientes (DEB, 2001). Já algumas das técnicas que não utilizam uma solução como referência são o hipervolume (ZITZLER e THIELE, 1999), distância à origem (MATOS, 2012) e método da cobertura (ZITZLER, 1999).

Na próxima seção será abordada uma técnica de avaliação de conflito de uma função multi-objetivo e, também, as técnicas hipervolume, indicador de distância e porcentagem de soluções eficientes.

4.3.6.1 Avaliação de conflito de uma função multiobjectivo

Segundo Freitas et al. (2013), conforme os exemplos apresentados na Figura 4.19, pode-se realizar a avaliação de conflito das funções objetivo. Assim, em (4.19a) ocorre a harmonia total, (4.19b) conflito máximo global, (4.19c) conflito concentrado em valores baixos, (4.19d) conflito concentrado em valores altos, (4.19e) conflito médio global e (4.19f) conflito local concentrado em locais diferentes em cada objetivo. A sistemática se estende para o caso de ainda mais funções objetivo.

Figura 4.19 – Exemplos de tipos de conflitos em um problema multi-objetivo



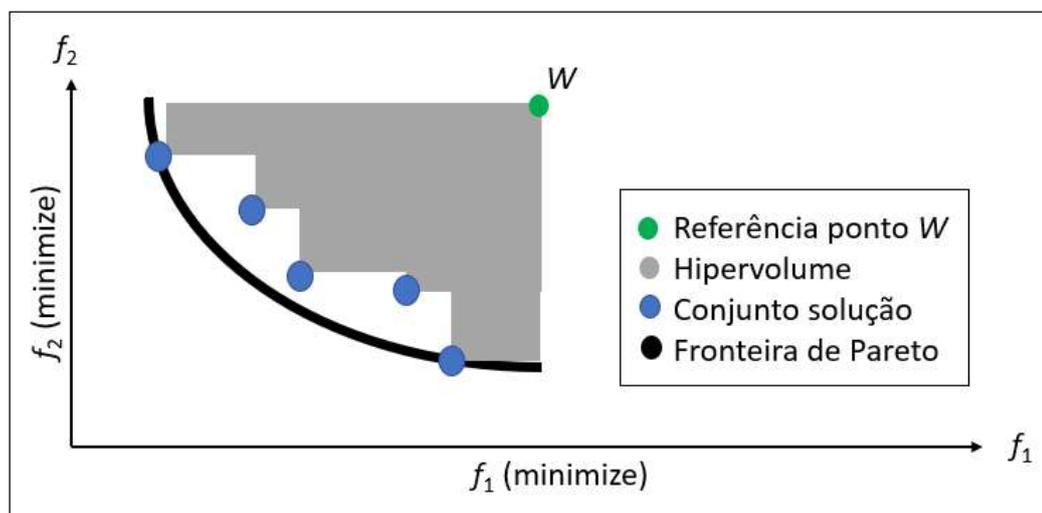
Fonte: Adaptado de Freitas et al. (2013).

4.3.6.2 Hipervolume

Segundo Deb (2001) com o cálculo do Hipervolume pode-se estimar a proximidade das soluções em relação a fronteira de Pareto ótimo. Como procedimento, calcula-se o volume da região coberta entre os pontos das soluções na fronteira de Pareto e um determinado ponto de referência, assim, ocorre a soma dos hipercubos formados pelas soluções não dominadas. Este procedimento é utilizado quando não se conhece a fronteira de Pareto ótimo. Auxilia a mensurar a qualidade de uma solução de forma comparativa com outras soluções e, desta forma, quanto maior o hipervolume melhor será a solução. A Figura 4.20 apresenta

um exemplo gráfico do hipervolume para o caso bi-objetivo de minimização e w como o ponto de referência.

Figura 4.20 – Exemplo de hipervolume



Fonte: O autor.

4.3.6.3 Indicador de distância (I_{GD})

Segundo Schardong (2011), o índice de indicador de distância (I_{GD}) apresenta a proximidade do conjunto de soluções testado com a frente de Pareto conhecida. Sendo n = número de soluções do conjunto testado; d_i = a distância entre a solução i do conjunto testado e a solução mais próxima da fronteira de Pareto, a equação (4.32) apresenta o procedimento de cálculo.

$$I_{GD} = \frac{\sqrt{\sum_{i=1}^n d_i^2}}{n} \quad (4.32)$$

4.3.6.4 Porcentagem de soluções eficientes (I_{PSE})

Proposto por Ulungu et al. (1999), o índice de porcentagem de soluções eficientes (I_{PSE}) representa o percentual da quantidade de soluções do conjunto de referência encontrada por uma heurística. Considerando P = conjunto de soluções x não-dominados; $Heurística$ = heurística utilizada; Ref = Conjunto de referência z (conjunto solução não-dominada entre todos os métodos avaliados), a equação (4.33) apresenta a porcentagem de soluções eficientes encontradas por $Heurística$.

$$I_{PSE}(Heurística) = 100. \frac{|\{z|\exists x \in P: f(x) \geq z\}|}{|Ref|} \quad (4.33)$$

4.4 ANÁLISE DE DECISÃO

Nesta seção são apresentadas duas abordagens para a Análise de Decisão, sendo elas: Modelo de Agregação Aditivo e a Teoria da Utilidade.

4.4.1 Modelo de Agregação Aditivo

Segundo Almeida (2013), num processo de decisão podemos utilizar o Modelo de Agregação Aditivo (MAA), também conhecido como “soma ponderada”, corresponde a um comum método de critério único de síntese. Com esse modelo, o decisor tem certeza ao obter o vetor de consequência x para cada alternativa a . Assim, utiliza-se a função valor $valor_j(a)$ em cada critério j na avaliação intracritério. A função de valor global é apresentada na equação (4.34).

$$valor(a) = \sum_{j=1}^n k_j valor_j(a) \quad (4.34)$$

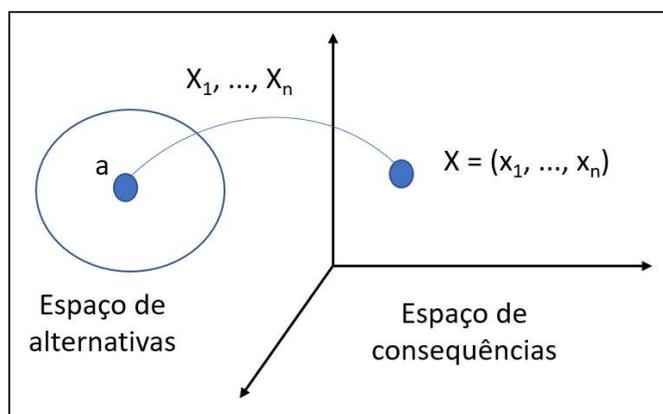
Desta forma, k_j se refere a constante de escala para o critério j , e que deve ser normalizado, de acordo com a equação (4.35).

$$\sum_{j=1}^n k_j = 1 \quad (4.35)$$

Por fim, se obtém a solução de um problema com a alternativa que obtiver o máximo valor global de $valor(a)$.

O espaço de consequência, em um problema de decisão é importante para avaliar o valor das alternativas. A partir da Figura 4.21, cada alternativa tem um vetor de consequências $x = (x_1, \dots, x_j, \dots, x_n)$, onde x_j representa a consequência do critério j em um total de n critérios.

Figura 4.21 – Espaço de consequências



Fonte: Adaptado de Almeida (2013).

Desta forma, os MAA, em cada alternativa se tem um vetor de consequência x , que representa a função valor definida sobre a respectiva consequência, conforme apresentado em (4.36).

$$valor(x) = \sum_{j=1}^n k_j valor_j(x_j) \quad (4.36)$$

4.4.2 Teoria da Utilidade

Segundo Belfiore e Fávero (2013), a propriedade fundamental da Teoria da Utilidade, relata que a Função Utilidade Monetária (FU) de um DM (*Decision Maker*, tomador de decisão) tem a propriedade de ser indiferente entre duas alternativas caso tenham a mesma utilidade esperada.

Assim, pode-se configurar $U(x) = 0$ para o menor valor da utilidade e $U(x) = 1$ para o maior valor de utilidade. As demais utilidades devem estar dentro deste intervalo. Este procedimento facilita ver a utilidade relativa de todos os resultados, do pior para o melhor. Por fim, ao fazer uso de uma FU em um processo de análise de decisão, ela deve se adequar as preferências e valores do DM.

4.5 CONSIDERAÇÕES AMBIENTAIS

Aqui são tratadas as considerações ambientais relacionadas às emissões de GHG. De acordo com o Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA, 2019), em seu Programa de controle de emissões

veiculares (Proconve), estabelece os limites máximos de emissão GHG para veículos automotores. A Tabela 4.1 apresenta os limites admissíveis de gases poluentes para motocicletas (veículos utilizados no estudo de caso) a partir de 1 de janeiro de 2016.

Tabela 4.1 - Limites admissíveis de gases poluentes para motocicletas

Poluentes	Limite de velocidade	
	< 130 km/h	≥ 130 km/h
Monóxido de carbono (CO em g/km)	2,00	2,00
Hidrocarbonetos (HC em g/km)	0,56	0,25
Óxidos de nitrogênio (NOx em g/km)	0,13	0,17
Dióxido de carbono (CO ₂ em g/km)	Não informado	Não informado

Fonte: Adaptado de IBAMA (2019)

Segundo Carvalho (2011), em seu relatório sobre “Emissões relativas de poluentes do transporte motorizado de passageiros nos grandes centros urbanos brasileiros”, pode-se observar as emissões médias relativas de CO₂ do transporte urbano por meio de diferentes modalidades, conforme a Tabela 4.2.

Tabela 4.2 - Emissões médias de CO₂ do transporte urbano

Modalidade	Emissões quilométricas (kg) de CO ₂ /km
Metrô	3,16
Ônibus	1,28
Automóvel	0,19
Motocicleta	0,07
Veículos pesados	1,28

Fonte: Adaptado de Carvalho (2011).

A partir dos valores apresentados nas Tabelas 4.1 e 4.2, têm-se os parâmetros (constantes) de entrada para mensurar a quantidade de emissão de gases poluentes proposta neste trabalho.

5 METODOLOGIA PROPOSTA

A metodologia proposta para a pesquisa ficou composta por 4 etapas, como pode-se observar no Quadro 5.1.

Quadro 5.1 – Metodologia para a resolução de MOOGVRP: estudos de caso

<p>Etapa 1 – “Tratamento” dos Dados</p> <ul style="list-style-type: none"> • Estudo de caso 1 (Distribuição de jornais) <ul style="list-style-type: none"> ○ Macro pontos ○ Coleta das distâncias e tempos • Estudo de caso 2 (Transporte de funcionários) <ul style="list-style-type: none"> ○ Coleta das distâncias e tempos ○ Limitação no tempo de trajeto <p>Etapa 2 – Modelagem Matemática para o MOOGVRP Apresentação do modelo matemático MOOGVRP, mais especificamente do “problema de roteamento de veículos multi-objetivo com considerações ambientais”.</p> <p>Etapa 3 – Abordagens meta-heurísticas para o MOOGVRP</p> <ul style="list-style-type: none"> • NSGA-II • MOPSO • Algoritmo híbrido proposto: CWNSGA-II • Algoritmo híbrido proposto: CWTSNSGA-II <p>Etapa 4 – Análise dos Resultados</p> <ul style="list-style-type: none"> • Análise da Fronteira de Pareto para os estudos de caso • Estratificação das oportunidades obtidas da solução dos estudos de caso • Seleção do melhor roteiro através da Função Utilidade para os estudos de caso • Análise das instâncias da literatura selecionadas • Avaliação dos estudos de caso e das instâncias da literatura
--

Fonte: O autor.

5.1 ETAPA 1: “TRATAMENTO” DOS DADOS

Esta seção apresenta o tratamento realizado para a obtenção dos dados na resolução dos estudos de caso propostos.

5.1.1 Estudo de Caso 1 – Distribuição de Jornal

Para o “tratamento” dos dados do primeiro estudo de caso, os 479 pontos de entregas (pontos de demanda) foram organizados de forma a considerar fragmentos dos logradouros (das ruas) como referência. Assim, a base de dados foi reduzida para “48 pontos macro” (ou “fragmentos de ruas”) de entrega, que contêm os 479

pontos originais. Estes 479 pontos foram “agrupados” para formarem os 48 pontos macros.

A gráfica forneceu a proposta de “fragmentação” dos logradouros, pois a mesma já faz uso dos mesmos como um apoio para o desenvolvimento dos seus itinerários de entrega dos jornais. Para melhor entendimento, a Figura 5.1 apresenta a fragmentação realizada em uma parte da Av. República Argentina na formação de três pontos macro. Assim, o primeiro endereço de entrega será tratado como “ponto macro” e os demais pontos de entrega do respectivo fragmento serão os pontos de entrega pertencentes ao ponto macro em questão.

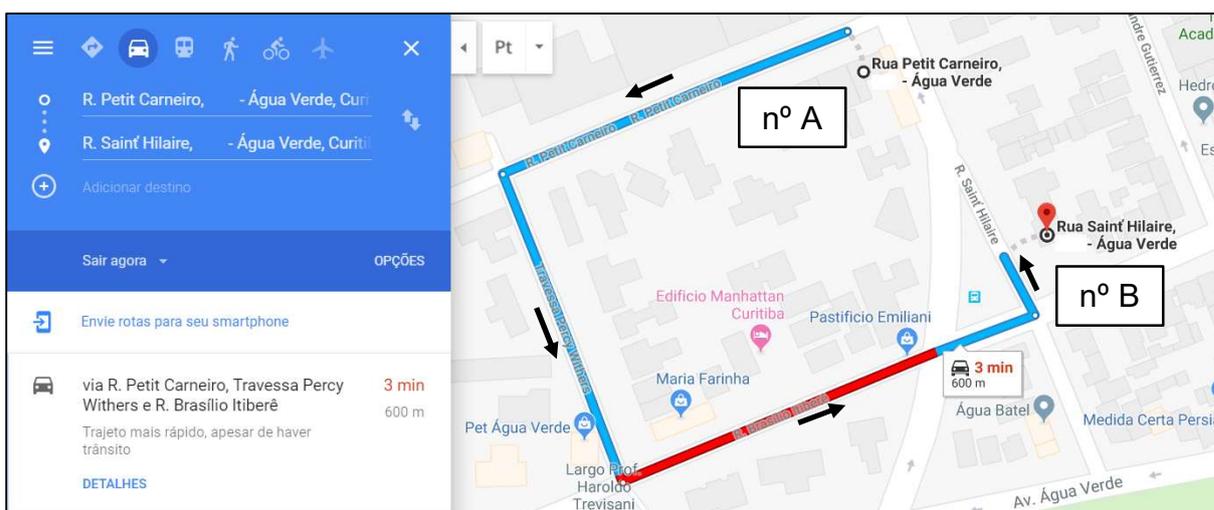
Figura 5.1 – Fragmentação da Av. República Argentina nos pontos macro 3, 4 e 5



Fonte: Adaptado de Google Maps.

O *software R* foi utilizado em conjunto com o *Google Maps* para realizar a coleta dos tempos e, também, das distâncias entre os 48 pontos macro. O site utilizado disponibiliza alguns meios de transporte como referência, sendo eles: carro, transporte público, a pé, bicicleta e avião. Foi selecionado o “carro” como referência para a coleta de dados no *software*, por melhor se aproximar da realidade da atividade, visto que o itinerário é percorrido por uma motocicleta (conforme já comentado no capítulo 2). A Figura 5.2 apresenta um exemplo simples da coleta da distância e do tempo (3 min e 600 metros) para percorrer o itinerário entre os pontos macro 34 e 43 (Tabela 2.1), correspondentes a Rua Petit Carneiro (A) e a Rua Saint’ Hilarie (B), respectivamente. A linha azul representa o trajeto e o fragmento em vermelho representam o trânsito intenso.

Figura 5.2 – Exemplo de coleta do tempo e distância entre pontos macro



Fonte: Adaptado de *Google Maps*.

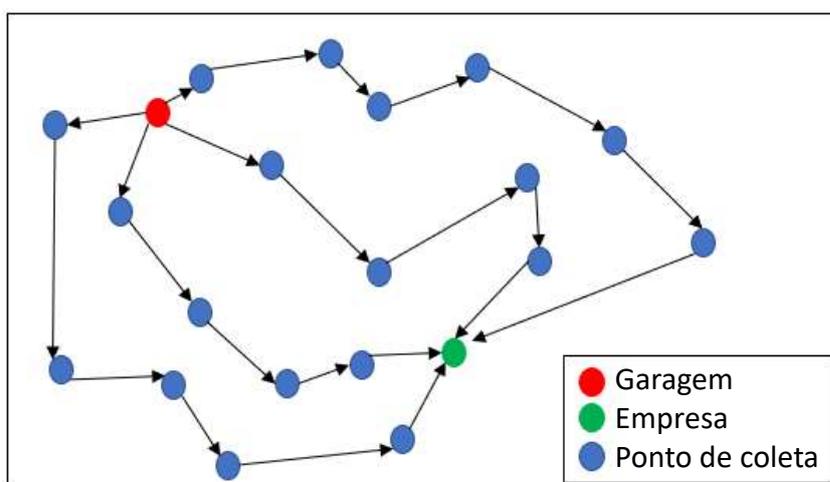
5.1.2 Estudo de Caso 2 – Transporte de Funcionários

Aqui, no “tratamento” dos dados do segundo estudo de caso, também foi realizada a coleta dos dados através do *software R* em conjunto com o *Google Maps* para obter os tempos e, também, das distâncias entre os pontos de demanda considerados. No total são 199 funcionários a serem coletados em 184 pontos de coleta. Este problema envolve oito roteiros.

Como o roteiro selecionado foi o do primeiro turno, então, o “depósito” do problema será a garagem dos ônibus no início da rota, os endereços dos funcionários serão os pontos a serem transpassados e a fábrica será o retorno ao “depósito”.

Aqui também foi selecionado o “carro” como referência para a coleta de dados no *software*, por melhor se aproximar da realidade da atividade, visto que o itinerário é percorrido por um ônibus. Para este estudo de caso de transporte de funcionários não foi utilizado os pontos macros por não haver necessidade. Com esta abordagem para o problema, a solução será factível no contexto de aplicação. A Figura 5.3 apresenta de forma esquemática a proposta de roteirização.

Figura 5.3 – Exemplo do tratamento dos dados para o transporte de funcionários com 4 ônibus



Fonte: o Autor.

A Tabela 5.1 apresenta um resumo da situação atual através dos dados obtidos através do *Google Maps*, considerando o respectivo roteiro (linha), a quantidade de passageiros, a taxa de ocupação do veículo, o tempo de percurso para a coleta dos funcionários (aqui não é considerado o tempo que leva da garagem até o primeiro ponto de coleta) e a distância total do percurso correspondente.

Tabela 5.1 - Situação atual das rotas

Referência	Passageiros	Ocupação (%)	Tempo de coleta (min)	Distância total (km)
Linha 1	26	83,8	93	108
Linha 2	31	100,0	127	93
Linha 3	32	103,2	112	77
Linha 4	20	64,5	102	56
Linha 5	27	87,1	106	77
Linha 6	18	58,0	93	79
Linha 7	30	96,7	112	94
Linha 8	18	58,1	117	82

Fonte: O autor.

Ainda na Tabela 5.1 pode-se observar uma diferença em mais de 40% na ocupação dos veículos. Além disso nota-se a discrepância quanto ao tempo e distância de percurso.

5.2 ETAPA 2: MODELAGEM MATEMÁTICA PARA O MOOGVRP

O MOOGVRP tem a finalidade de determinar um conjunto de rotas para os veículos que iniciam e terminam seu trajeto no depósito, sendo que a demanda de todos os seus clientes deve ser obrigatoriamente atendida pelos veículos; cada cliente deve ser atendido por somente um veículo e a capacidade de cada veículo não poderá ser violada.

O problema tem abordagem multi-objetivo para encontrar a melhor solução do conflito entre os objetivos de “minimização da emissão de CO₂” e “minimização absoluta das demandas de cada roteiro em relação a demanda média”.

Neste contexto, o problema pode ser representado pelo grafo completo $G = (V, A)$, onde $V = \{1, 2, \dots, v\}$ representa o conjunto de nós e $A = \{(i, j): i \neq j\}$, o conjunto de arcos que fazem a ligação entre i e j . O objetivo é percorrer todos os nós do grafo e retornar ao nó 1, ou seja, um trajeto de circuito fechado, sendo que a cada nó deverá estar associado uma demanda D_i do cliente i . Por fim, para cada arco (i, j) , tem-se um valor d_{ij} representando as distâncias entre i e j (ou t_{ij} , os tempos); a quantidade de demanda D_i deve respeitar a capacidade do veículo (Cap_b) e cada nó i deve ser visitado exatamente uma vez (ou seja, a demanda não poderá ser dividida entre dois ou mais veículos).

As variáveis de decisão são:

$$x_{ij}^b = \begin{cases} 1, & \text{se o veículo } b, \text{ que sai da origem } i, \text{ atende o cliente } j \\ 0, & \text{caso contrário} \end{cases}$$

Os parâmetros são:

v = número de clientes a serem atendidos;

k = variável auxiliar equivalente ao número do cliente;

U_k = entrega acumulada para o endereço k ;

D_i = demanda do cliente i ;

D_{med} = demanda média por roteiro;

Cap_b = capacidade do veículo b ;

B = quantidade de veículos b utilizados;

d_{ij} = distância percorrida do endereço i até o endereço j ;

t_{ij} = tempo de percorrida do endereço i até o endereço j ;

e_b = taxa de emissões quilométricas (kg) de CO₂/km do veículo b (0,07 para motocicleta e 1,28 para ônibus, valores obtidos da Tabela 4.2).

A formulação matemática das funções objetivo são apresentadas (4.1) a (4.12).

Minimizar $f: (f_1, f_2)$

$$\text{Onde: } f_1 = \sum_{i=1}^v \sum_{j=1}^v \sum_{b=1}^B d_{ij} x_{ij}^b e_b \quad (4.1)$$

$$f_2 = \sum_{b=1}^B \left| \sum_{i=1}^v D_i x_{ij}^b - D_{med} \right| \quad (4.2)$$

Sujeito a:

$$x_{kk} = 0, \quad k > 1 \quad (4.3)$$

$$\sum_{i=1}^v x_{ik}^b = 1, \quad i \neq k, i = 1 \text{ ou } D_i + D_k \leq Cap_b, k > 1 \quad (4.4)$$

$$\sum_{j=1}^v x_{kj}^b = 1, \quad j \neq k, j = 1 \text{ ou } D_j + D_k \leq Cap_b, k > 1 \quad (4.5)$$

$$U_k \geq U_i + D_k - Cap_b + Cap_b(x_{ki}^b + x_{ik}^b) - (D_k + D_i)x_{ki}^b, \quad i \neq k, i \neq 1 \quad (4.6)$$

$$U_k \leq Cap_b - (Cap_b - D_k)x_{1k}^b, \quad k > 1 \quad (4.7)$$

$$U_k \geq D_k + \sum_{i=1}^v D_i x_{ik}^b, \quad i > 1, k > 1 \quad (4.8)$$

$$B = \sum_{i=1}^v \frac{D_i}{Cap_b}, \quad i > 1 \quad (4.9)$$

$$\sum_{j=1}^v x_{ij}^b \geq B, \quad j > 1 \quad (4.10)$$

$$D_k \leq U_k \leq Cap_b, \quad k > 1, k = 1, \dots, v \quad (4.11)$$

$$x_{ij}^b = \{0, 1\}, \quad i = 1, \dots, v; j = 1, \dots, v; b = 1, \dots, B \quad (4.12)$$

Os objetivos são definidos pelas equações de (4.1) e (4.2), sendo que em (4.1) tem-se a definição o grau de poluição ambiental nos roteiros, medido pelas emissões de CO₂. Neste contexto, a poluição ambiental é determinada pela distância de transporte e o tipo de veículo utilizado. Esta função objetivo foi uma adaptação para o caso de frota homogênea da terceira função objetivo proposta na modelagem matemática de Yang et al. (2015). Em (4.2) tem-se a segunda função objetivo do modelo proposto com a minimização absoluta das demandas de cada roteiro em relação a demanda média, visando a homogeneização das demandas.

Quanto as restrições do problema, em (4.3) tem-se que a distância do cliente k até ele mesmo é zero. Em (4.4) cada endereço deve ser visitado por um veículo; já a equação (4.5) representa que deve sair um veículo de cada endereço. Em (4.6) se k segue i , verifica-se o quanto pode ser alocado em cada roteiro; por outro lado, em (4.7) se k é o primeiro endereço a ser visitado, então a entrega acumulada U_k é igual à quantidade desta demanda D_k . Se k não for o primeiro endereço a ser visitado, então são adicionados mais endereços a serem visitados em (4.8). Em (4.9) é estabelecido o número mínimo de veículos. O número suficiente de veículos encaminhado para fora do depósito é apresentado em (4.10). Em (4.11) tem-se que a entrega acumulada U_K , deve respeitar o seu limite inferior D_K e a capacidade do veículo Cap_b (limite superior). As variáveis de decisão x_{ij}^b apresentadas em (4.12) são binárias, onde se atribui o valor “1” se for selecionada e “0”, caso contrário. As equações (4.3) até (4.12) foram adaptadas de LINGO (2017).

Ainda para o segundo estudo de caso, será necessário adicionar a equação (4.13) que tem a função de limitar cada roteiro em até uma hora e trinta minutos (90min). Vale destacar que a contagem do tempo de percurso de cada “pétala” do MOOGVRP, especificamente para o segundo estudo de caso, ocorre a partir da primeira coleta de funcionário e não da saída do depósito.

$$\sum_{b=1}^B t_{ij} x_{ij}^b \leq 90, \quad b = 1, \dots, B; i \neq j \quad (4.13)$$

5.3 ETAPA 3: ABORDAGENS META-HEURÍSTICAS

As descrições dos procedimentos meta-heurísticos multiobjetivo são apresentadas nesta seção. Os parâmetros foram definidos em cada uma das

abordagens após testes preliminares realizados pelo autor. A Tabela 5.2 apresenta de forma simplificada algumas características marcantes dos algoritmos propostos no Estudo de Caso 1 (EC1) e Estudo de Caso 2 (EC2).

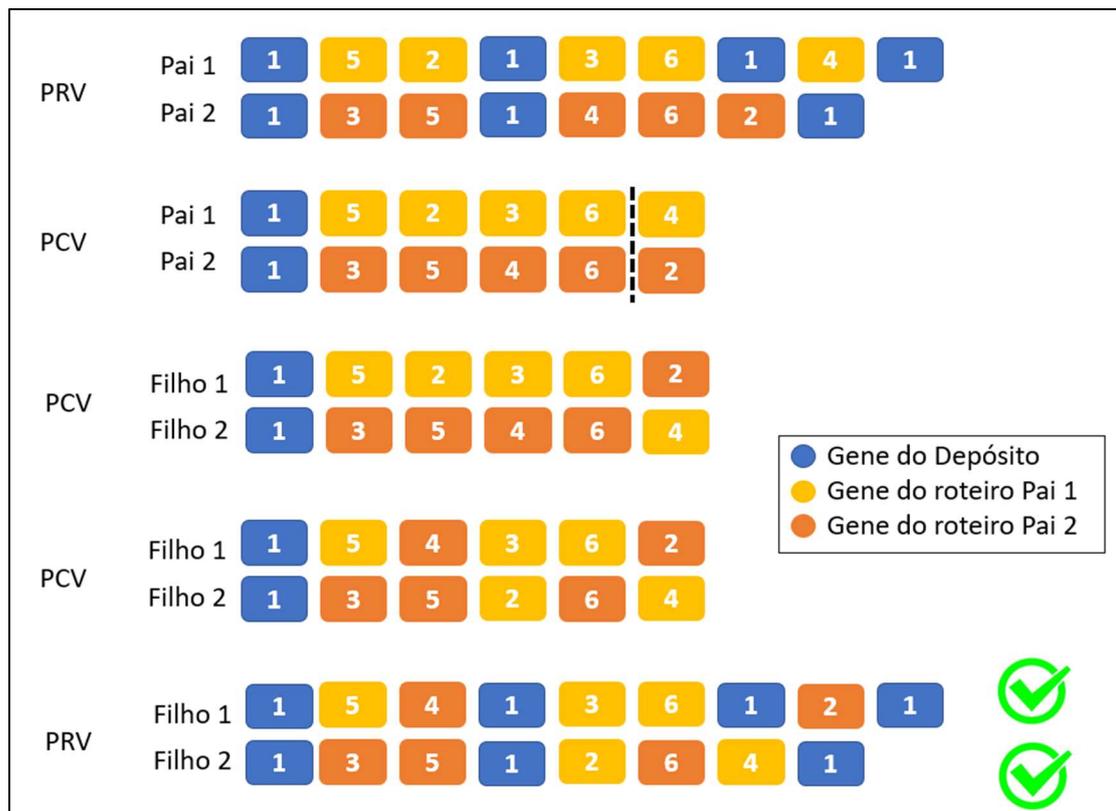
Tabela 5.2 – Características dos algoritmos (Estudo de Caso 1–EC1 e Estudo de Caso 2–EC2)

Característica	Abordagem			
	NSGA-II	MOPSO	CWNSGA-II	CWTSNSGA-II
Solução inicial randômica	EC1, EC2	EC1, EC2	-	-
Solução inicial CW+Swap	-	-	EC1, EC2	EC1, EC2
CW por pétala	-	-	EC1	EC1
Movimento TS	-	-	-	EC1, EC2
Base de dados de tempo	EC2	EC2	EC2	EC2
Base de dados da distância	EC1, EC2	EC1, EC2	EC1, EC2	EC1, EC2

Fonte: o Autor.

5.3.1 NSGA-II

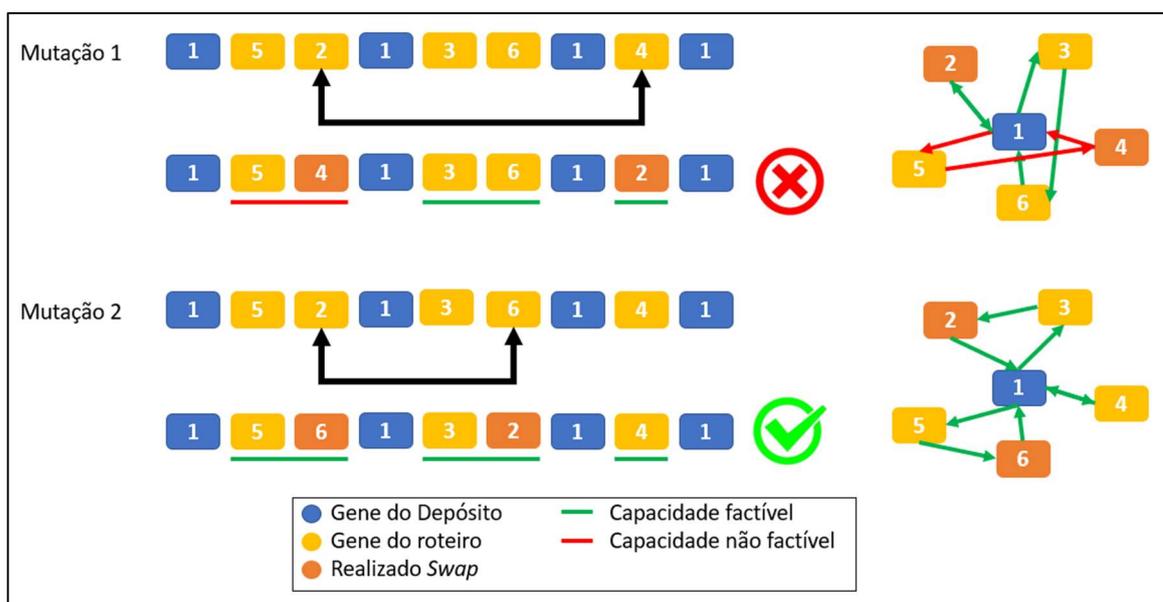
O algoritmo NSGA-II, apresentado na seção 4.3.4.1, será aplicado ao MOOGVRP, nos dois estudos de caso aqui tratados. No Estudo de caso 1, referente à entrega de jornais, os parâmetros utilizados, após vários experimentos preliminares, foram: população = 100; capacidade do veículo = 210 (volumes de jornal); número de iterações = 100; percentual de crossover = 0,5 e percentual de mutação = 0,1. A formação do roteiro na solução inicial é randômica. Para realizar o *crossover*, conforme mostrado na Figura 5.4, primeiramente o VRP foi “transformado” em um PCV e, depois, realizado o corte aleatório de um ponto entre o segundo e o penúltimo gene. Na sequência, é realizada a adequação do cromossomo, por meio da mutação, para que contenha todos os endereços do roteiro como PCV. Por fim, o PCV é “transformado” em um VRP fazendo-se a “repartição” do cromossomo de acordo com a capacidade do veículo. Assim, a criação de um novo roteiro (cromossomo) será factível.

Figura 5.4 – Exemplo de *crossover*

Fonte: o Autor.

O *swap* (troca) de dois genes selecionados aleatoriamente também foi utilizado. Vale destacar que pode ocorrer de alguns *swaps* serem ignorados pelo algoritmo, caso os roteiros (“pétalas”) formados não atendam a capacidade do veículo. A Figura 5.5 apresenta dois exemplos de *swap*.

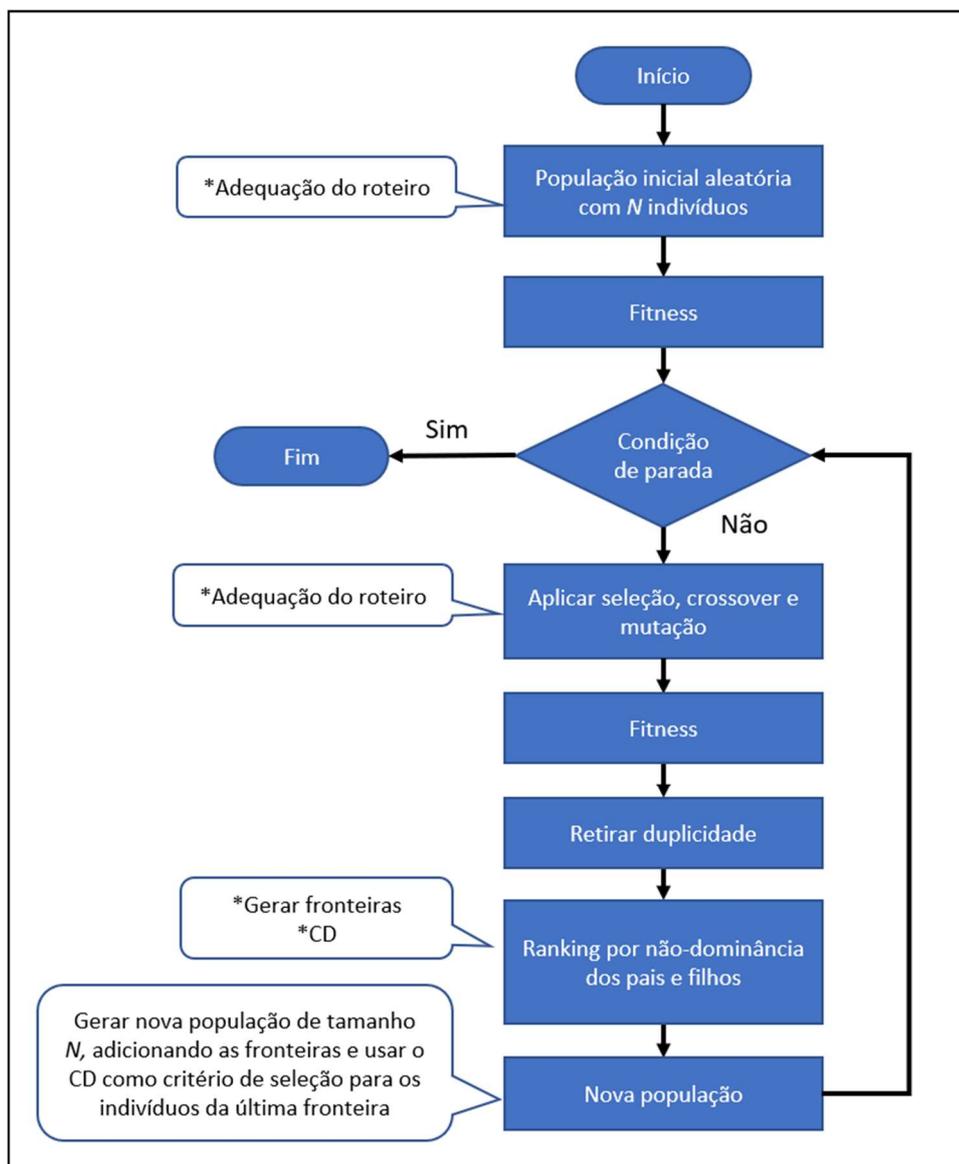
Figura 5.5 – Exemplo de Swap



Fonte: o Autor.

Já no Estudo de caso 2, transporte de funcionários, os parâmetros utilizados, após vários experimentos preliminares, foram: população = 100; capacidade do veículo = 31 (passageiros); número de iterações = 100; percentual de crossover = 0,5; percentual de mutação = 0,1 e tempo máximo de trajeto em 127 min. Aqui a formação inicial dos roteiros também ocorre de forma randômica. Quanto ao crossover e mutação, foi utilizado o mesmo procedimento do Estudo de caso 1 com o acréscimo do “tempo máximo de trajeto” junto da “capacidade do veículo” para a validação dos roteiros. A Figura 5.6 apresenta o fluxograma do algoritmo NSGA-II implementado.

Figura 5.6 – Fluxograma do algoritmo NSGA-II implementado



Fonte: o Autor.

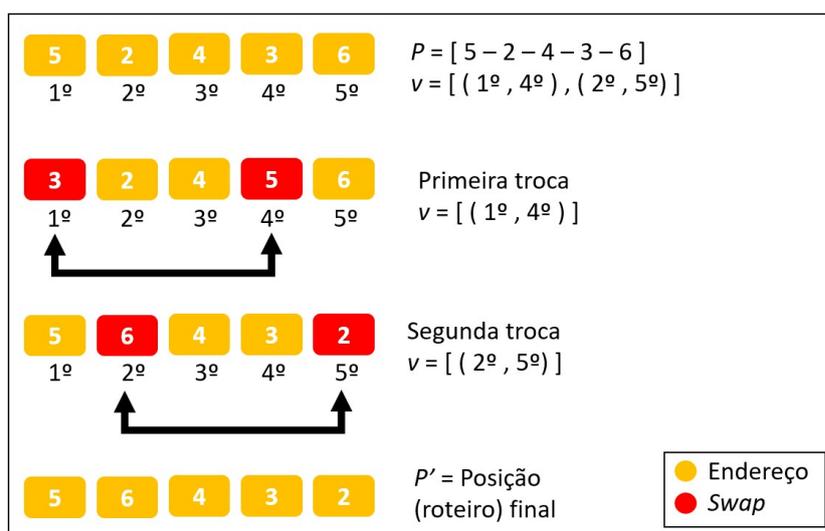
5.3.2 MOPSO

O algoritmo MOPSO, apresentado na seção 4.3.5, será aplicado ao MOOGVRP, nos dois estudos abordados. O Estudo de caso 1, referente à entrega de jornais, os parâmetros utilizados, após vários experimentos preliminares, foram: número de partículas = 100; capacidade do veículo = 210 (volumes de jornal); número de iterações = 100; como turbulência foi considerada a inversão de uma partícula (roteiro) a cada iteração. A formação do roteiro na solução inicial é randômica.

Para o cálculo da velocidade e posição, equações (4.48) e (4.49), foram atribuídas, conforme recomendações da literatura (ABAD et al., 2018): constante de aceleração ou taxa de cognição $C1$ e $C2 = 1$; o peso inercial W por meio da equação (4.50); $W_{max} = 1$ e $W_{min} = 0,2$. Além disso, por tratar-se de um problema discreto, foram adotadas algumas considerações para os cálculos das equações (4.48) e (4.49):

- a) Procedimento de cálculo para a nova posição através da soma entre a posição atual e a velocidade ($P' = P + v$): Para “somar” P e v deve-se transpor os valores da posição P (roteiro) em relação aos valores dispostos em v (pares para troca ou *swap*). A Figura 5.7 apresenta de forma esquemática este procedimento.

Figura 5.7 – Exemplo de cálculo da posição ($P' = P + v$)



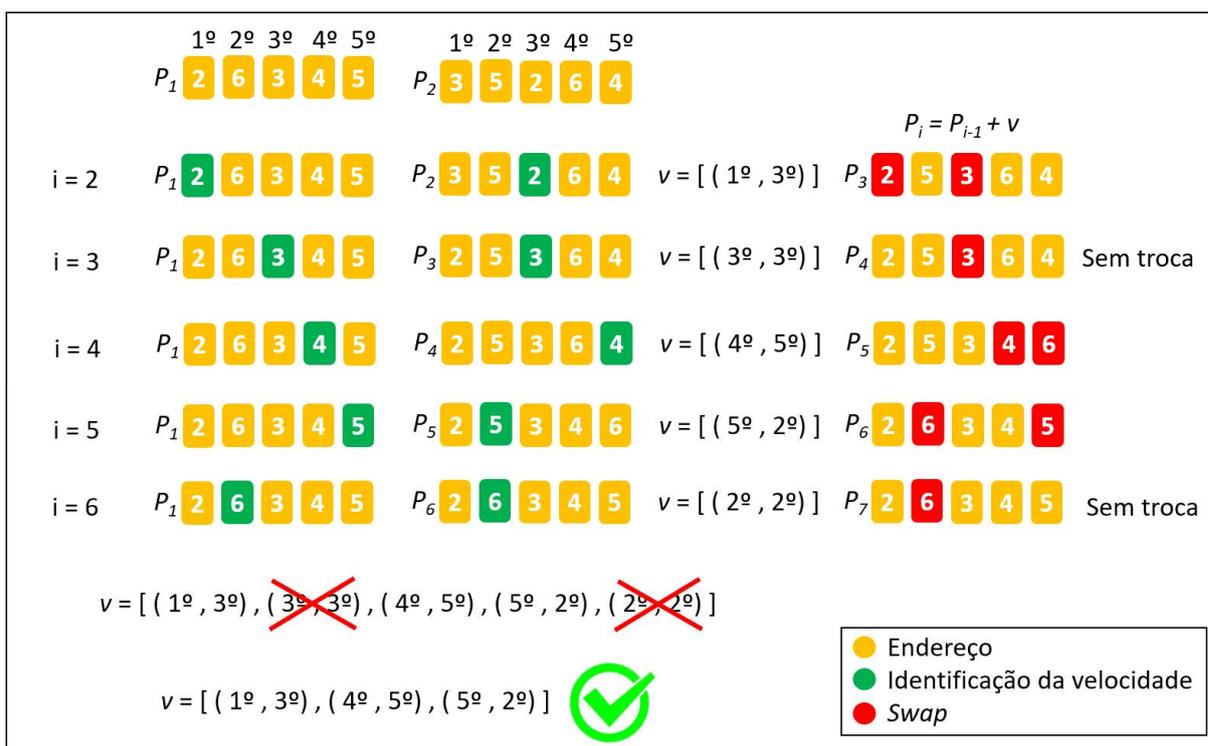
Fonte: o Autor.

- b) Procedimento para obter a velocidade (v) através da subtração de duas posições ($P_2 - P_1$): Se “ $v = P_2 - P_1$ ”, então “ $P_2 = P_1 + v$ ”, ou seja, a subtração de duas posições resulta na velocidade, conforme a equação (5.15).

$$P_i = P_{i-1} + v \quad (5.15)$$

A Figura 5.8 apresenta o procedimento de cálculo para a obtenção da velocidade por meio da diferença de duas posições (roteiros). Neste contexto, será verificada a identificação da velocidade de todos os elementos (em verde) nas posições das partículas para gerar o *swap*.

Figura 5.8 – Exemplo da velocidade através de duas posições



Fonte: o Autor.

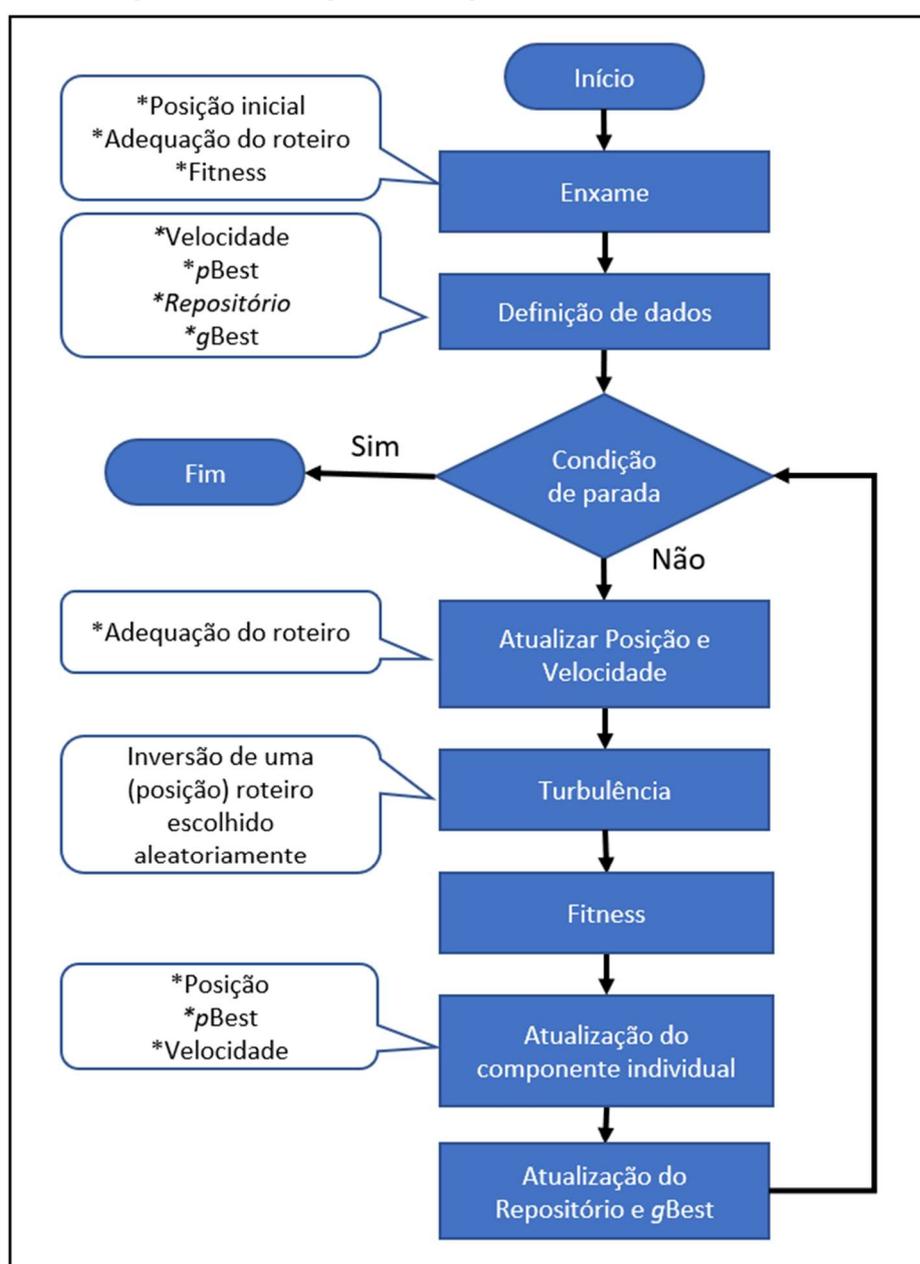
- c) Procedimento para obter a velocidade (v) através da soma de duas velocidades ($v_1 + v_2$): Ocorre por meio da concatenação destas velocidades. Exemplo: $v_1 = [(1^o, 4^o)]$ e $v_2 = [(2^o, 5^o)]$, então: $v = [(1^o, 4^o), (2^o, 5^o)]$.
- d) Procedimento para obter a velocidade (v) através da multiplicação entre um coeficiente real (c) e uma velocidade (v). São três casos:
- i. $c < 0$, onde $c * v$ não é determinado;
 - ii. $c = 0$, onde $c * v = \emptyset$, a velocidade é nula;
 - iii. $c > 0$, onde $c * |v|$. Aqui deve-se truncar o valor de v e $|v|$ é o comprimento do vetor de velocidade.

Observa-se que as posições (roteiros) foram simplificadas para o PCV e após os procedimentos de cálculo das equações (4.48) e (4.49) foram readequados para o PRV. Foi estabelecido que o vetor velocidade pode conter até N trocas, onde N é o número de endereços a serem percorridos, além do depósito.

Como partícula $pBest$ foi considerada a evolução da própria partícula. A partícula $gBest$ é a escolha aleatória de uma partícula do repositório. No repositório consta a fronteira de Pareto atualizada a cada iteração. Vale ressaltar que todos os roteiros foram validados pela capacidade do veículo (motocicleta).

Já no Estudo de caso 2, transporte de funcionários, os parâmetros utilizados, após experimentos preliminares, foram: número de partículas = 100; capacidade do veículo = 31 (passageiros); número de iterações = 100; tempo máximo de trajeto em 127 min. Aqui a formação inicial dos roteiros também ocorre de forma randômica. Todos as partículas (roteiros) atendem ao “tempo máximo de trajeto” junto da “capacidade do veículo”. A Figura 5.9 apresenta o fluxograma do algoritmo MOPSO implementado.

Figura 5.9 – Fluxograma do algoritmo MOPSO implementado



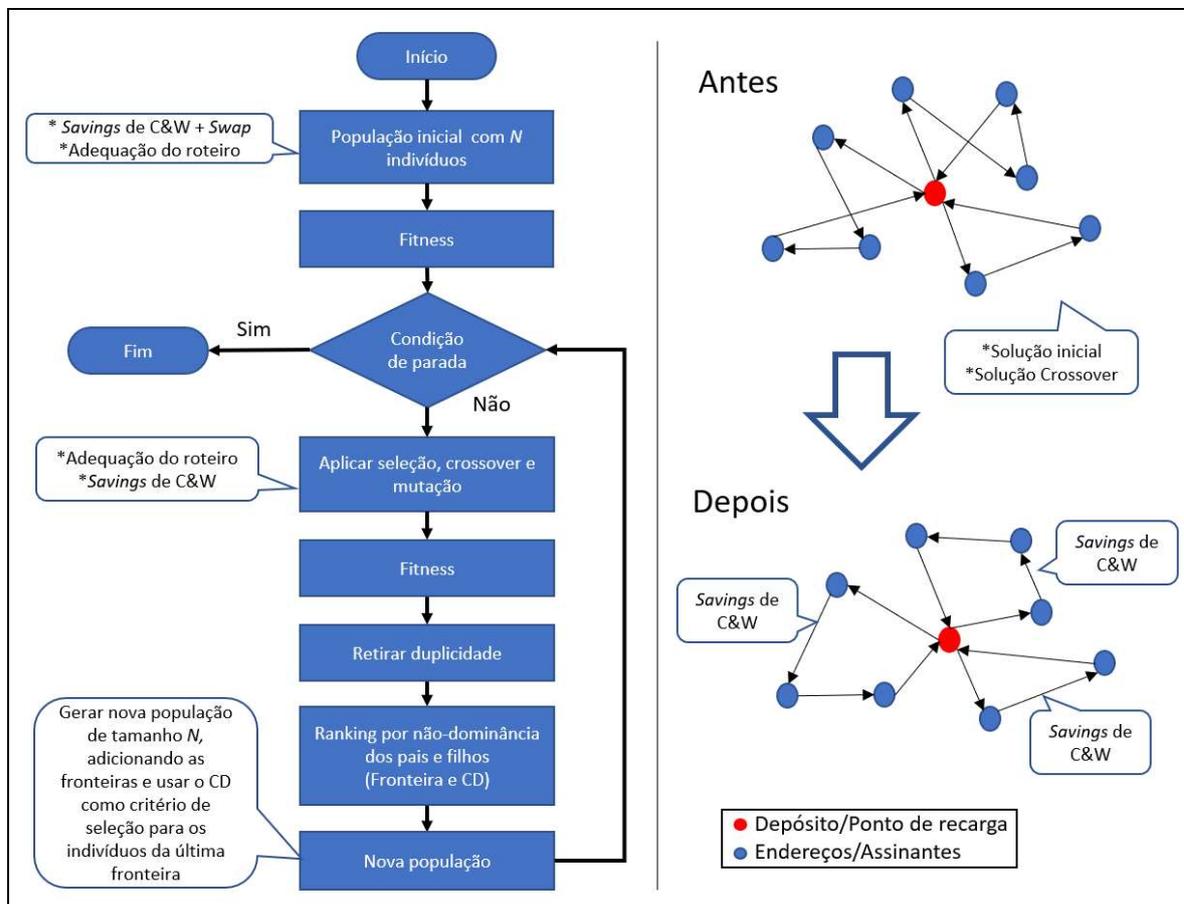
Fonte: o Autor.

5.3.3 Algoritmo Híbrido CWNSGA-II

Nesta seção apresenta-se a proposta do procedimento do Algoritmo Híbrido dos *Savings* de Clarke & Wright com o *Non-dominated Sorting Genetic Algorithm II* (CWNSGA-II). O algoritmo de C&W foi descrito na seção 4.2.1 e o algoritmo NSGA-II na seção 4.3.4.1. Na literatura pode-se encontrar trabalhos correlatos como o de Wang et al., (2018a), onde os autores utilizaram o C&W como procedimento na geração da população inicial. Aqui, foi aplicado o C&W e realizada a operação de *Swap* até a quantidade estabelecida da população para formar a População inicial.

Os parâmetros e procedimentos serão os mesmos dos já apresentados em 5.3.1 na solução dos dois estudos de caso propostos. O C&W será aplicado, somente no Estudo de Caso 1, como refinamento das soluções geradas após o *crossover*, mais especificamente, em cada “pétala” das soluções do VRP. A Figura 5.10 apresenta o fluxograma do algoritmo CWNSGA-II (lado esquerdo) e a influência do algoritmo de C&W no apromiramento das soluções.

Figura 5.10 – Fluxograma do algoritmo CWNSGA-II implementado (lado esquerdo) e aplicação do C&W na solução (lado direito)



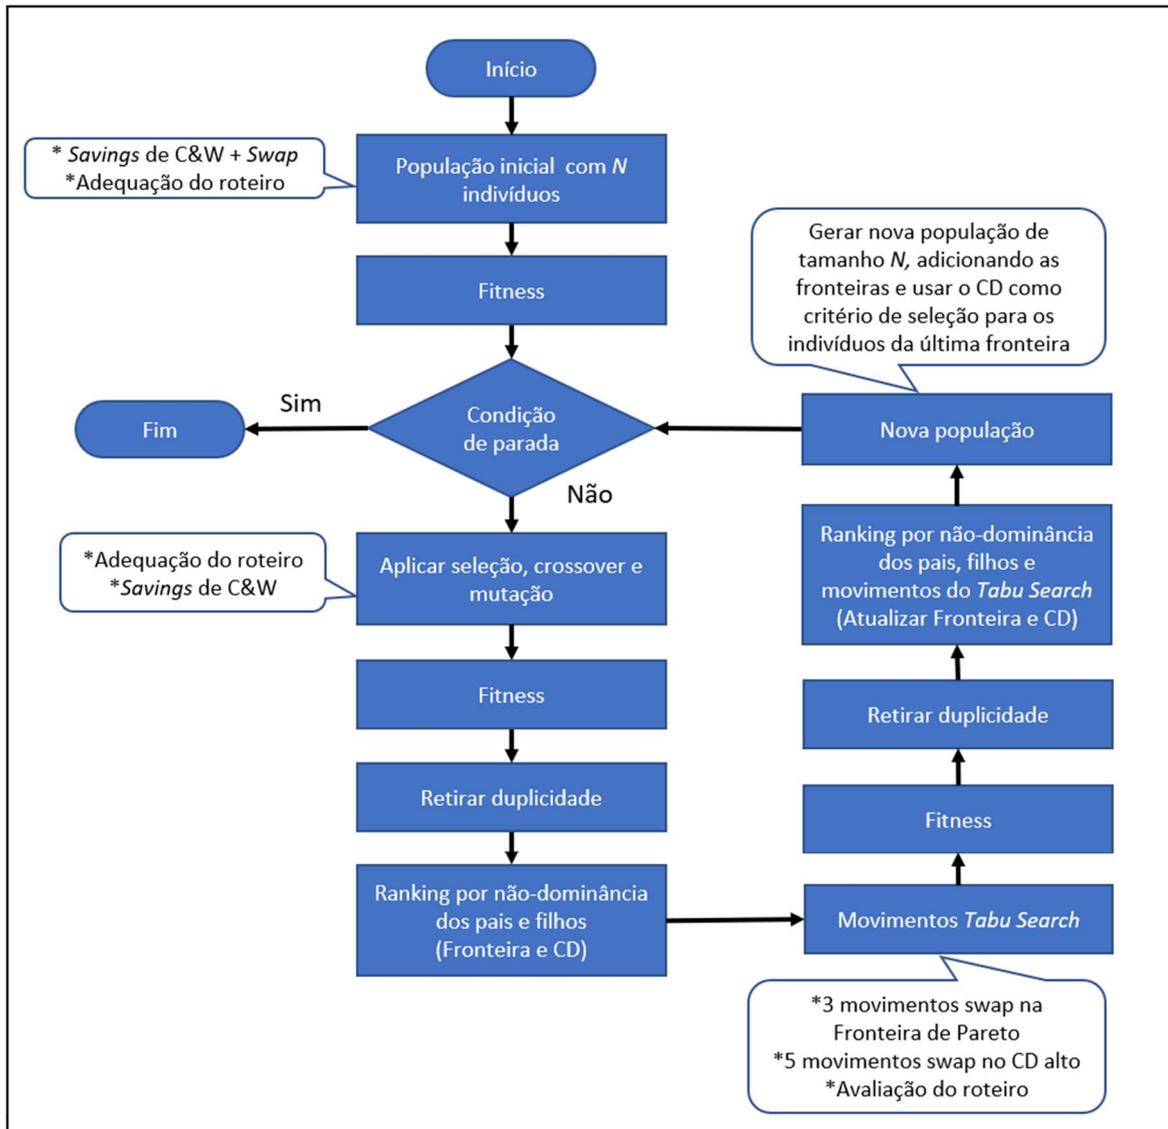
Fonte: o Autor.

5.3.4 Algoritmo Híbrido CWTSNSGA-II

Nesta seção são apresentadas as propostas dos procedimentos do Algoritmo Híbrido dos *Savings* de Clarke & Wright, *Tabu Search* and *Non-dominated Sorting Genetic Algorithm II* (CWTSNSGA-II). O algoritmo de C&W foi descrito na seção 4.2.1; o algoritmo TS na seção 4.2.4 e o algoritmo NSGA-II na seção 4.3.4.1. Os parâmetros e procedimentos serão os mesmos dos já apresentados em 5.3.3 na solução dos dois estudos de caso propostos.

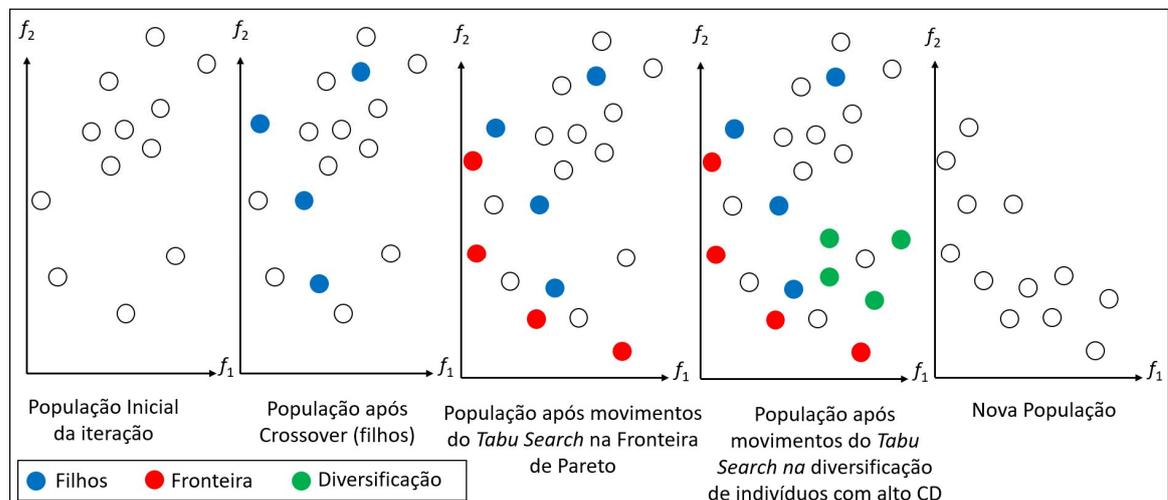
O diferencial do CWTSNSGA-II está no *loop* (Figura 5.11), pois realiza os mesmos procedimentos do NSGA-II, mais uma quantidade de movimentos do TS, calcula o *Fitness*, retira a duplicidade das soluções, atualiza a PF (*Pareto Front*), DC (*Crowding Distance*) e gera a nova população. Além disso, há o aperfeiçoamento das pétalas do VRP por meio do C&W. Os movimentos do TS são *Swaps* na PF e na solução com maior valor de CD, para ampliar a quantidade de soluções próximas da PF e para diversificar soluções isoladas. Desta forma o algoritmo melhora consideravelmente a sua população a cada iteração. A Figura 5.11 apresenta o fluxograma do algoritmo CWTSNSGA-II. A ilustração comentada das etapas nas iterações deste procedimento é apresentada na Figura 5.12.

Figura 5.11 – Fluxograma do algoritmo CWTSNSGA-II implementado



Fonte: o Autor.

Figura 5.12 – Etapas nas iterações do algoritmo CWTSNSGA-II implementado

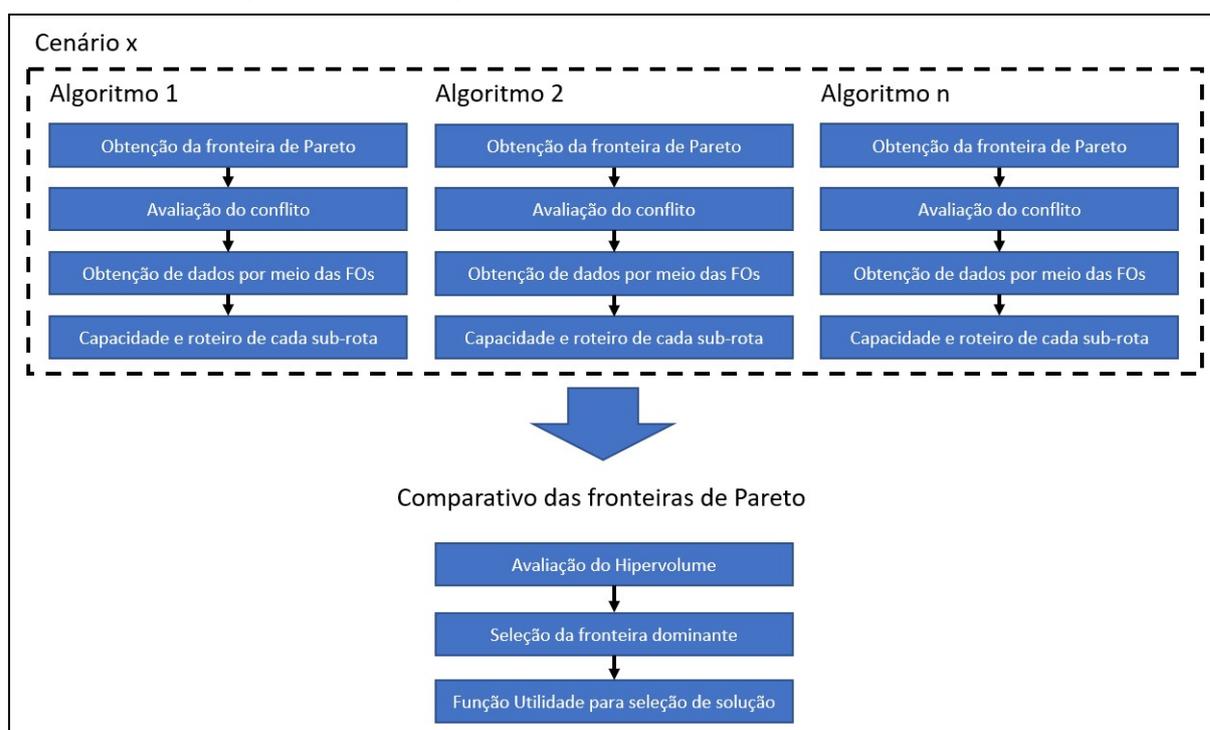


Fonte: o Autor.

5.4 ETAPA 4: ANÁLISE DOS RESULTADOS

Para realizar a análise dos resultados deve-se observar o procedimento adotado em cada cenário, conforme a Figura 5.13.

Figura 5.13 – Fluxograma procedimento adotado em cada cenário.



Fonte: o Autor.

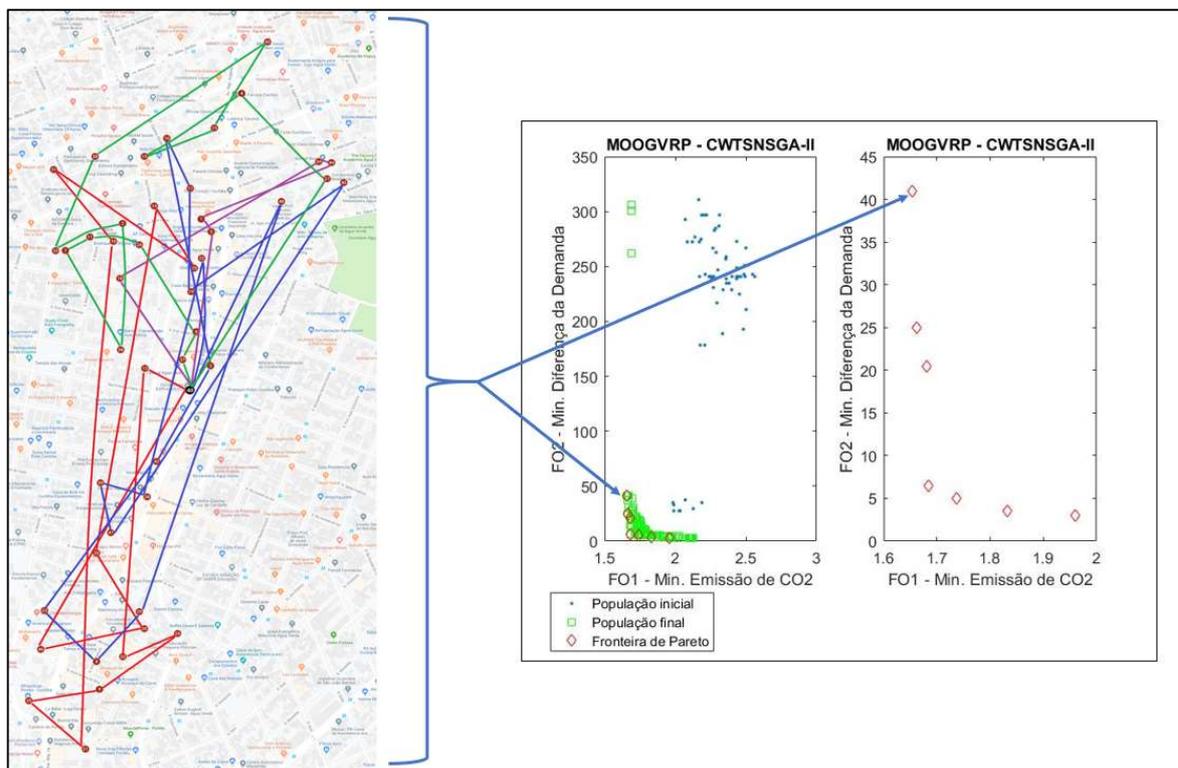
Desta forma, em um “cenário *x*” será realizado o comparativo entre técnicas multi-objetivo. Para cada técnica (algoritmo), será realizada a obtenção da fronteira de Pareto por meio de três rodadas e a avaliação do hipervolume (seção 4.3.6.2). Na sequência a avaliação do conflito; a obtenção de informações por meio das FOs (consumo de combustível, tempo de percurso, por exemplo); a solução de roteirização (com seus *tours*) e a capacidade atribuída (em cada *tour*) do PRV.

Então, ocorre o comparativo entre as fronteiras obtidas por meio de cada algoritmo, calculando-se o hipervolume e observando a dominância. Então uma solução é selecionada através da Função Utilidade, onde aqui foi utilizada de forma ponderada, pois foi solicitado pesos ao decisor para ponderar as utilidades e assim definir a melhor solução. Assim tem-se uma proposta de neutralidade em relação ao risco da decisão.

Para tais procedimentos, em cada estudo de caso, foi solicitado ao decisor a atribuição de pesos em cada uma das funções objetivo para a escolha da melhor solução. Então, de acordo com o DM de cada estudo de caso, foi atribuído 70% de importância para a primeira função objetivo e 30% para a segunda função objetivo. Não será aqui analisado o *trade-off* da PF e a análise de sensibilidade quanto aos pesos atribuídos pelos DMs. Por fim, uma discussão dos resultados e do comparativo da solução atual com a proposta é realizada.

Com a finalidade de melhor ilustrar a interpretação dos dados, a Figura 5.14 apresenta de forma gráfica a solução correspondente a um roteiro que representa o ponto (3,4; 21) da PF.

Figura 5.14 – Exemplo de interpretação da solução



Fonte: o Autor.

Exemplos didáticos para interpretação dos estudos de caso de distribuição de jornais e transporte de funcionários são apresentados no anexo A.

6 OBTENÇÃO, DISCUSSÃO E ANÁLISE DOS RESULTADOS

Neste capítulo são apresentados os resultados, assim como a sua análise e discussão, obtidos por meio das técnicas propostas no capítulo 5. Para os testes dos dois estudos de caso e, também, das instâncias da literatura, foi utilizado o *software* Matlab R2016b instalado em um notebook com processador Intel® Core™ i7-7500U CPU @ 2.7GHz 2.90GHZ, 16,00 GB de RAM, com sistema operacional de 64 bits.

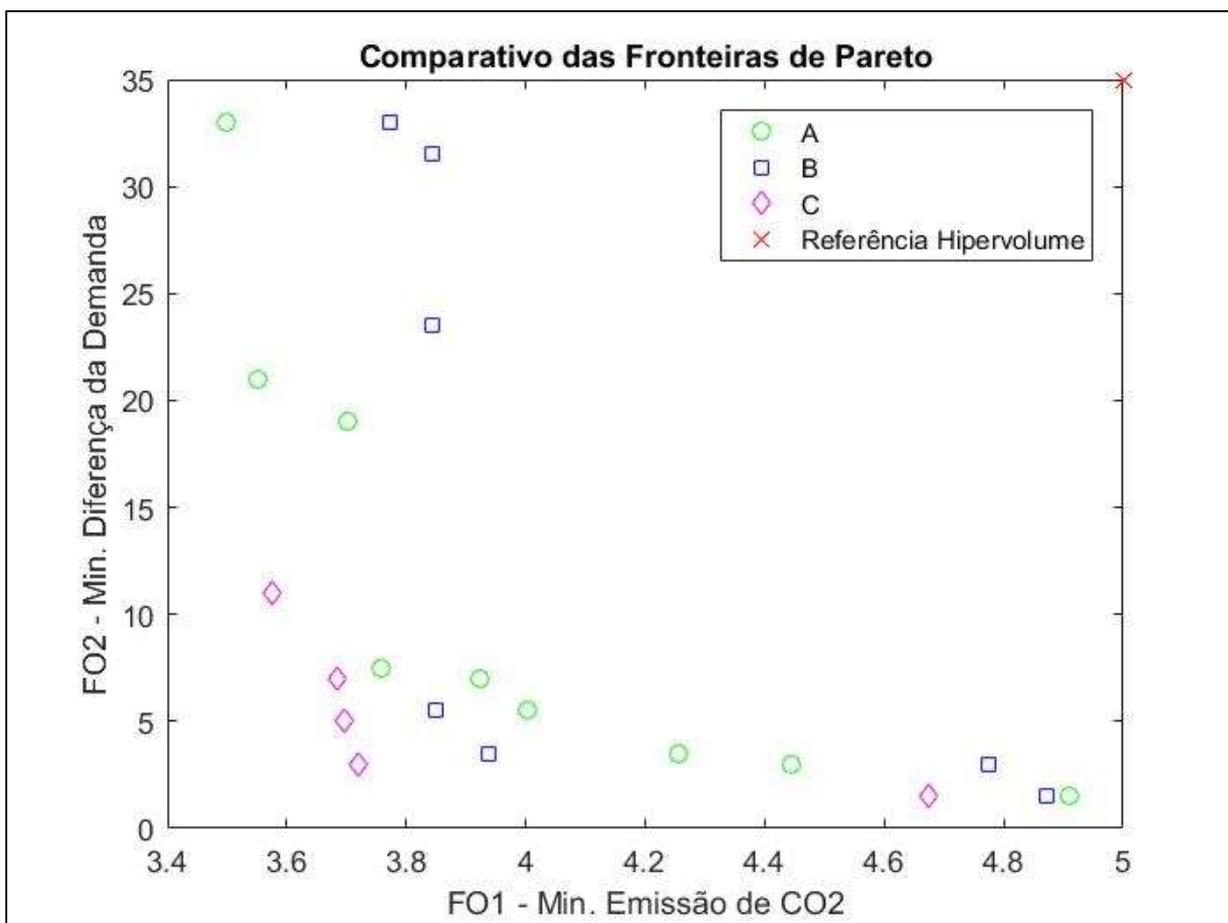
6.1 ESTUDO DE CASO 1: DISTRIBUIÇÃO DE JORNAIS

Aqui apresenta-se os resultados obtidos através de cada uma das técnicas utilizadas (NSGA-II; MOPSO; CWNSGA-II e CWTSNSGA-II) para o primeiro estudo de caso, distribuição de jornais.

6.1.1 NSGA-II

Inicialmente foram realizadas três rodadas (A, B e C) fazendo-se uso da técnica NSGA-II, variando as populações iniciais em cada uma das rodadas, sendo que as respectivas fronteiras são apresentadas na Figura 6.1. Os tempos computacionais foram de 4,6; 4,2 e 4,5 segundos, respectivamente. A Tabela 6.1 apresenta os hipervolumes em unidades de área (u.a.) da Figura 6.1 para auxiliar na decisão da fronteira mais dominante.

Figura 6.1 – Comparativo das rodadas iniciais do Estudo de Caso 1, algoritmo NSGA-II



Fonte: o Autor

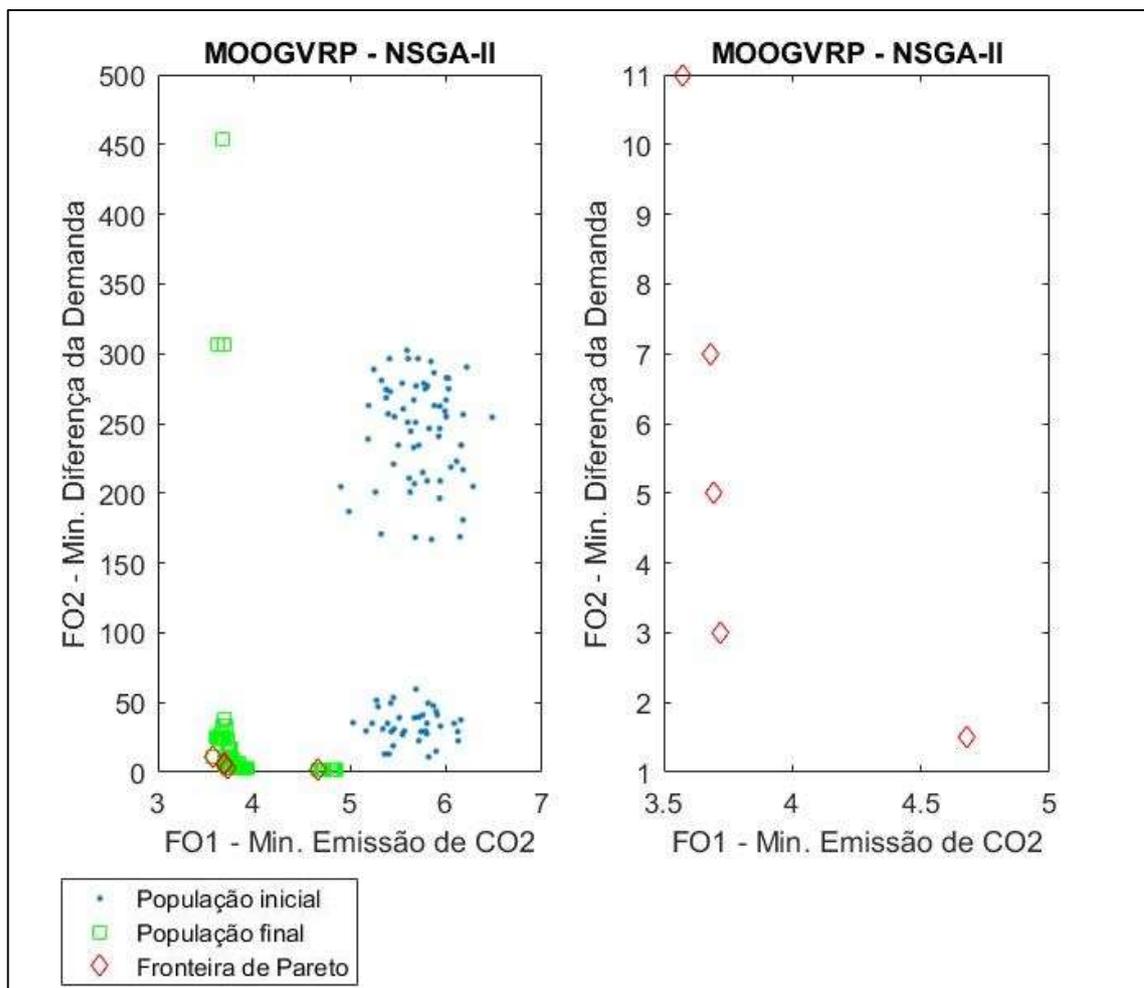
Tabela 6.1 – Avaliação das fronteiras de Pareto

Rodada/solução	Hipervolume (u.a.)
A	41,2
B	36,6
C	45,1

Fonte: o Autor.

Portanto, o conjunto de soluções C que apresenta o maior Hipervolume, com 45,1 u.a., será a solução analisada. A Figura 6.2 apresenta a população inicial, população final e a fronteira da solução C obtida por meio da técnica NSGA-II.

Figura 6.2 – Fronteira de Pareto com a poluição inicial e final (lado esquerdo) e fronteira de Pareto (lado direito), através da técnica NSGA-II

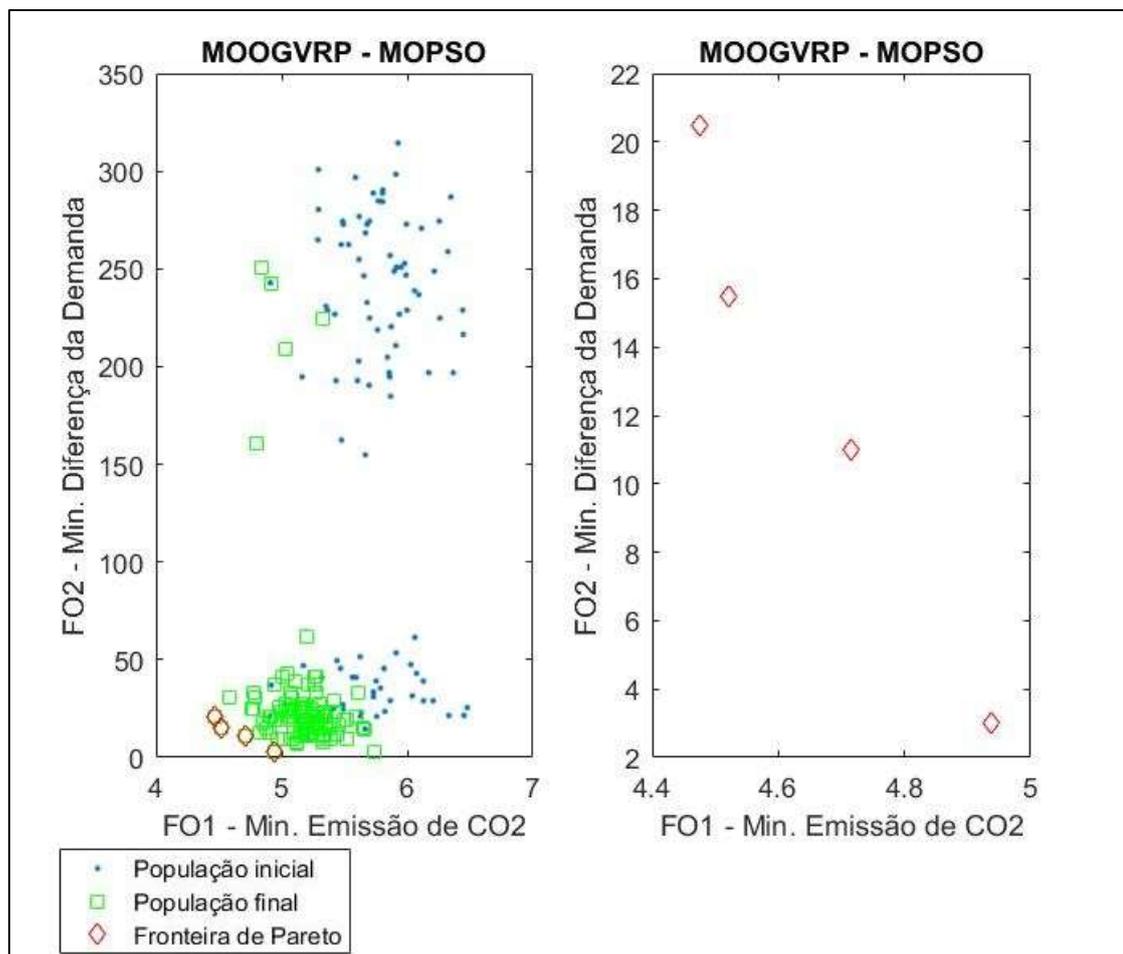


Fonte: o Autor.

6.1.2 MOPSO

Inicialmente foram realizadas três rodadas (A, B e C) fazendo-se uso da técnica MOPSO, variando as populações iniciais em cada uma das rodadas. Os tempos computacionais foram de 7,8; 8,1 e 8,4 segundos. Os hipervolumes obtidos foram de 42,9; 50,5 e 44,1 u.a., portanto, o conjunto de soluções B (fronteira) que apresentou o maior hipervolume será a solução analisada. A Figura 6.3 apresenta a população inicial, população final e a fronteira da rodada B, obtida por meio da técnica MOPSO.

Figura 6.3 – Fronteira de Pareto com a poluição inicial e final (lado esquerdo) e fronteira de Pareto (lado direito), através da técnica MOPSO

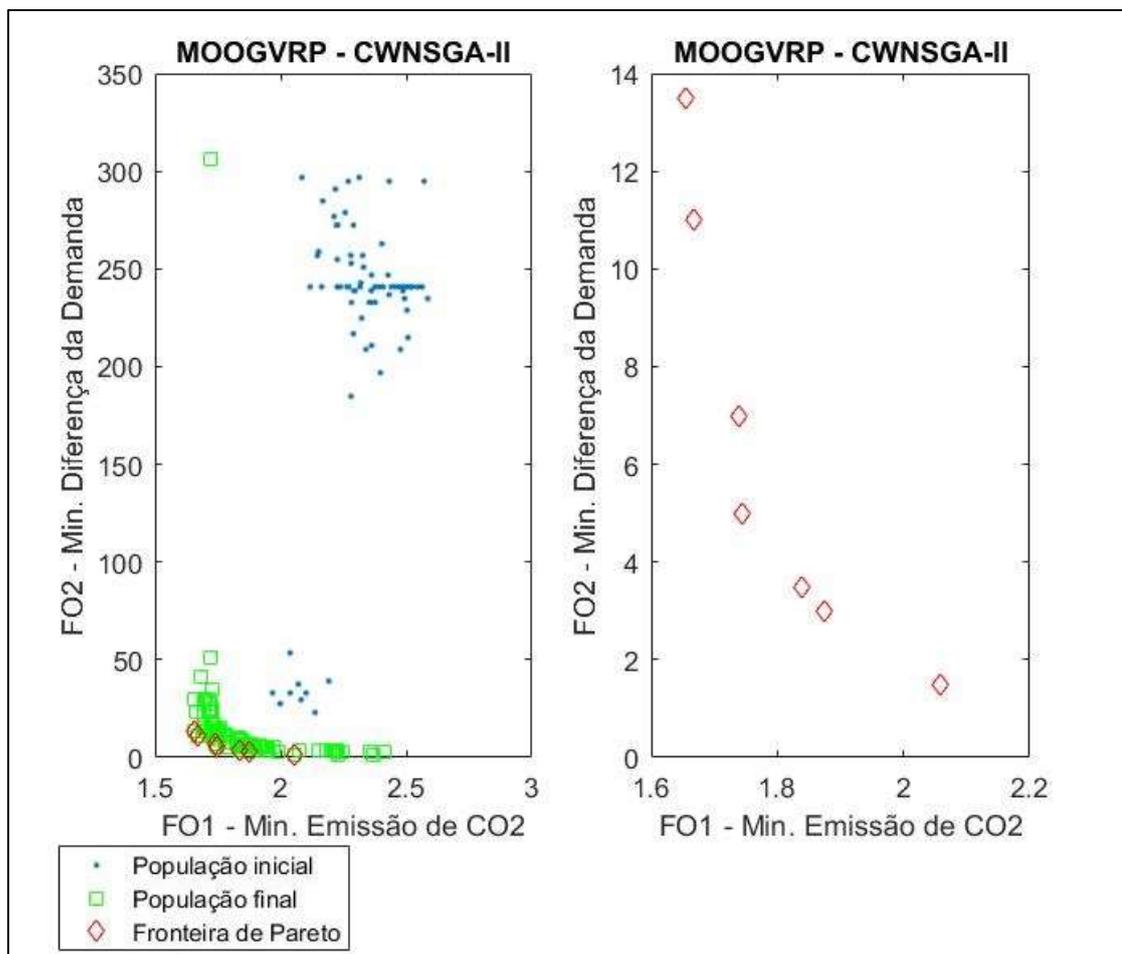


Fonte: o Autor.

6.1.3 CWNSGA-II

Inicialmente foram realizadas três rodadas (A, B e C), variando as populações iniciais em cada uma das rodadas, fazendo-se uso da técnica CWNSGA-II. Os tempos computacionais foram de 9,1; 7,2 e 7,6 segundos. Os hipervolumes obtidos foram de 15,2; 17,8 e 14,9 u.a., portanto, o conjunto de soluções B (fronteira) que apresentou o maior hipervolume será a solução analisada. A Figura 6.4 apresenta a população inicial, população final e a fronteira da rodada B obtida por meio da técnica CWNSGA-II.

Figura 6.4 – Fronteira de Pareto com a poluição inicial e final (lado esquerdo) e fronteira de Pareto (lado direito), através da técnica CWNSGA-II

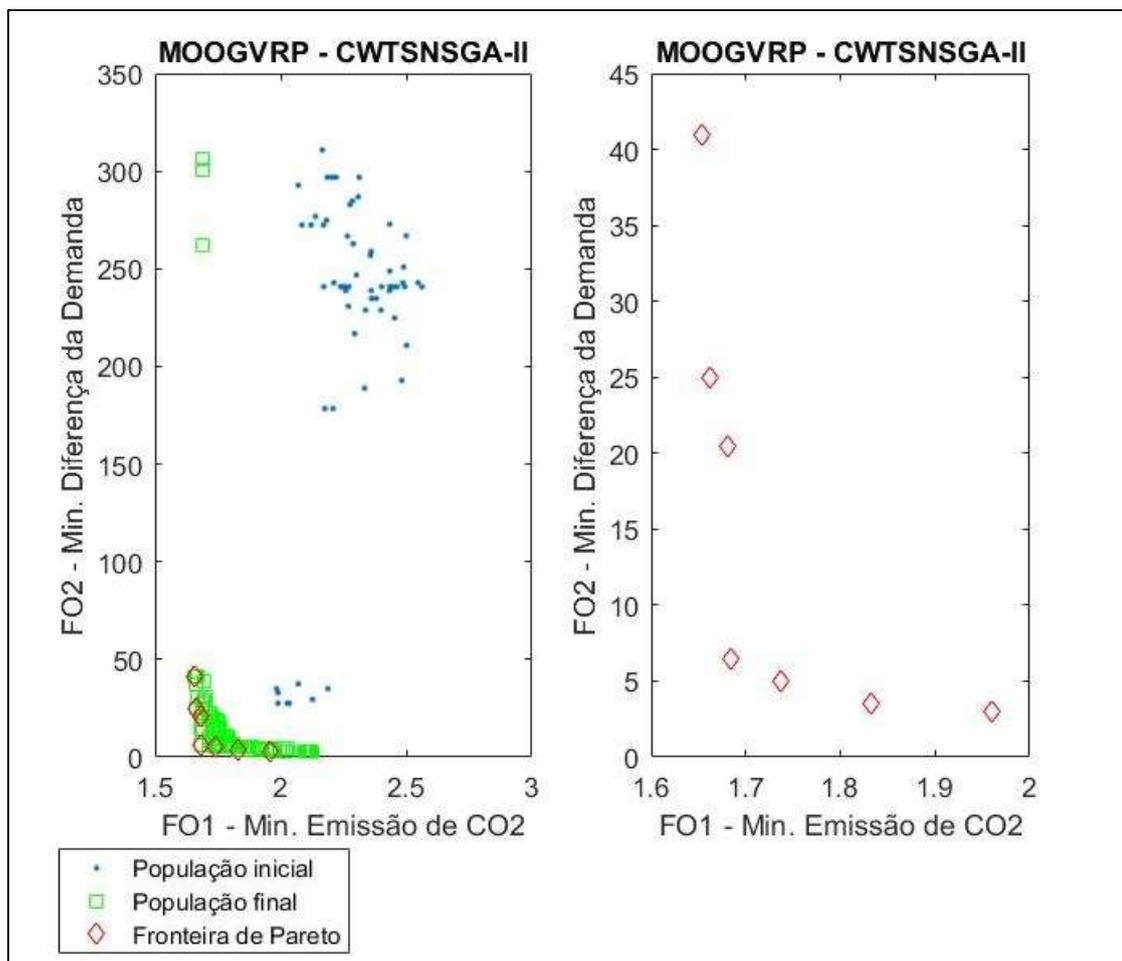


Fonte: o Autor.

6.1.4 CWTSNSGA-II

Inicialmente foram realizadas três rodadas (A, B e C) fazendo-se uso da técnica CWTSNSGA-II, variando as populações iniciais em cada uma das rodadas. Os tempos computacionais foram de 11,2; 11,1 e 11,7 segundos. Os hipervolumes obtidos foram de 29,1; 29,9 e 30,1 u.a., portanto, o conjunto de soluções C (fronteira) que apresentou o maior hipervolume será a solução analisada. A Figura 6.5 apresenta a população inicial, população final e a fronteira da rodada C obtida por meio da técnica CWTSNSGA-II.

Figura 6.5 – Fronteira de Pareto com a poluição inicial e final (lado esquerdo) e fronteira de Pareto (lado direito), através da técnica CWTSNSGA-II

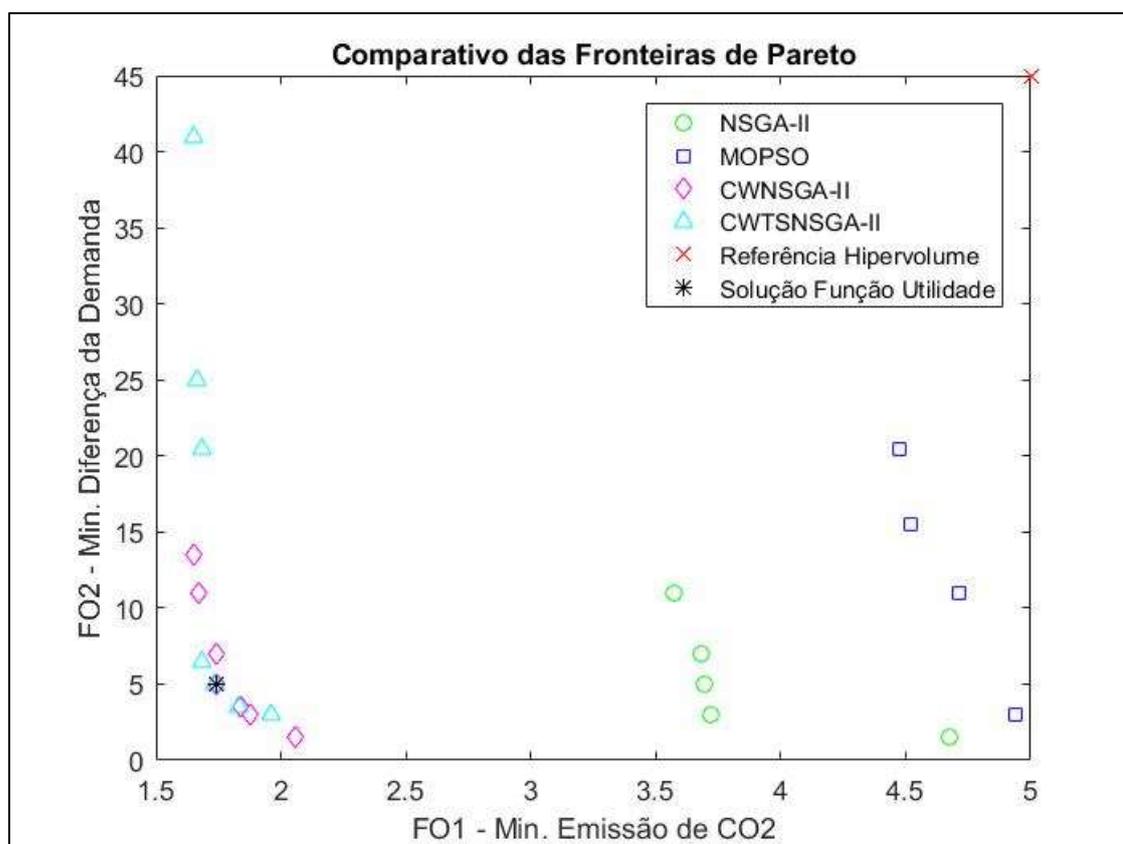


Fonte: o Autor.

6.1.5 Análise dos Resultados

A Figura 6.6 apresenta um gráfico com as fronteiras de Pareto obtidas das técnicas utilizadas para a resolução deste estudo de caso 1. Também é apresentado o ponto de referência, ponto = (5; 45), para o cálculo do hipervolume e a solução para a Função Utilidade, ponto = (1,7; 5), que será apresentada na sequência.

Figura 6.6 – Análise das fronteiras de Pareto entre as técnicas utilizadas no Cenário 1



Fonte: o Autor.

A Tabela 6.2 apresenta o resultado da avaliação das fronteiras de Pareto. Nota-se que quanto maior o valor do hipervolume, melhor será o conjunto de soluções. Portanto, o cálculo do hipervolume reforça a dominância da solução do algoritmo CWNSGA-II em relação ao CWTSNSGA-II, NSGA-II e MOPSO, respectivamente, neste problema proposto com 143,9 u.a. Nota-se que os valores de hipervolume apresentados na Tabela 6.2 são diferentes dos valores do melhor hipervolume de cada algoritmo. Isso porque a referência para o cálculo foi alterado, pois aqui trata-se do comparativo entre algoritmos.

Tabela 6.2 – Avaliação das fronteiras de Pareto

Algoritmo	Hipervolume
NSGA-II	59,3
MOPSO	17,0
CWNSGA-II	143,9
CWTSNSGA-II	139,2

Fonte: o Autor.

A Figura 6.7 apresenta os cálculos da aplicação da Função Utilidade aplicada na fronteira de Pareto dominante, resultante do algoritmo CWNSGA-II. Para tal procedimento, foi solicitado ao decisor a atribuição de pesos em cada uma das funções objetivo para a escolha da melhor solução. Então, de acordo com o DM foi atribuído 70% de importância para a primeira função objetivo e 30% para a segunda função objetivo. Por fim, a solução 4, com coordenadas (1,7; 5,0) apresentou a maior Função Utilidade, sendo esta a solução proposta para este Estudo de caso 1.

Figura 6.7 – Função Utilidade aplicada na fronteira de Pareto dominante do Estudo de caso 1

Solução	1	2	3	4	5	6	7
FO1	1,65	1,67	1,74	1,74	1,84	1,88	2,06
FO2	13,50	11,00	7,00	5,00	3,50	3,00	1,50

Menor é melhor!
Menor é melhor!

Solução	1	2	3	4	5	6	7
FO1	1,00	0,97	0,79	0,78	0,54	0,45	0,00
FO2	0,00	0,21	0,54	0,71	0,83	0,88	1,00
Função Utilidade	0,70	0,74	0,71	0,76	0,63	0,58	0,30

Pesos
0,70
0,30

Fonte: o Autor.

A Tabela 6.3 apresenta o comparativo entre a solução atual e a solução proposta pela gráfica. A solução otimizada utilizou a mesma quantidade de veículos (motocicletas) e foi melhor em relação a todos os requisitos. O destaque foi para a diferença da demanda, ou seja, melhor equilíbrio da quantidade de jornais atribuídos aos *bags* para a sua distribuição.

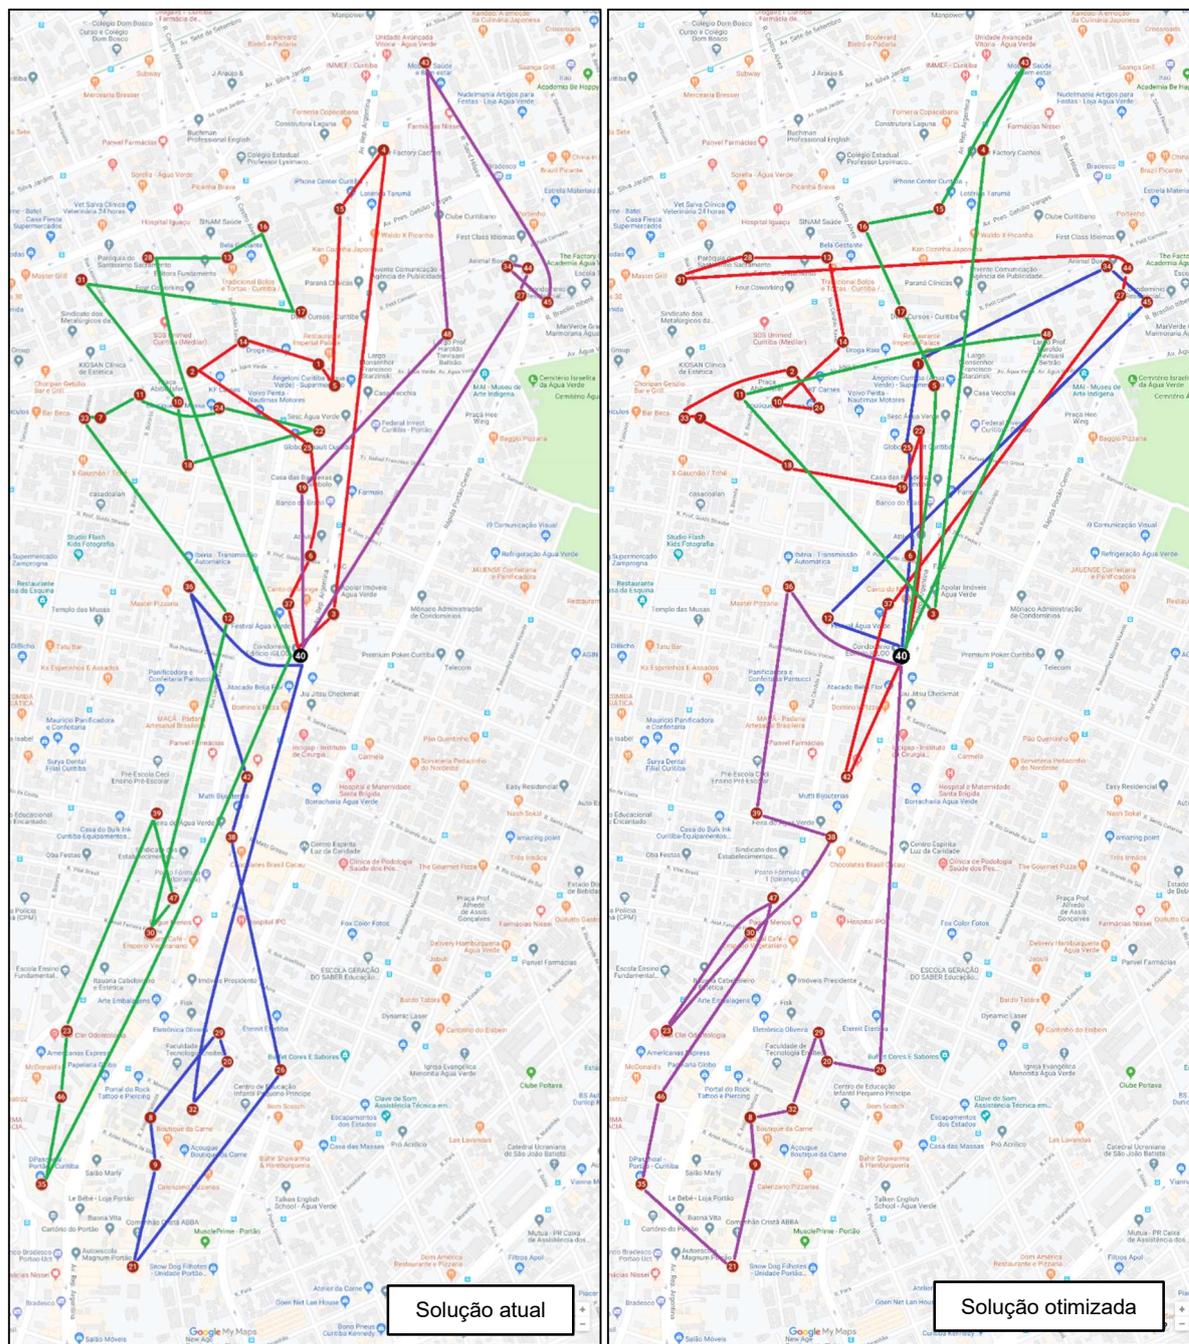
Tabela 6.3 – Comparativo entre a solução atual e a proposta

Solução (roteiro)	Emissões quilométricas (kg) de CO ₂ /km	Distância percorrida (km)	Consumo de combustível (l)	Tempo de percurso (min)	Nº de veículos	Diferença da Demanda
Atual	2,2	31,1	0,8	113,2	4	40
Otimizada	1,7	24,9	0,6	92,0	4	5
Redução (%)	19,9%	19,9%	19,9%	18,7%	-	87,5%

Fonte: o Autor.

A Figura 6.8 apresenta o comparativo da solução corrente (lado esquerdo) com a solução otimizada (lado direito) e a Tabela 6.4 a descrição dos roteiros da solução proposta para a distribuição de jornais deste Estudo de Caso 1.

Figura 6.8 – Comparação da solução corrente x otimizada para o Estudo de Caso 1



Fonte: o Autor.

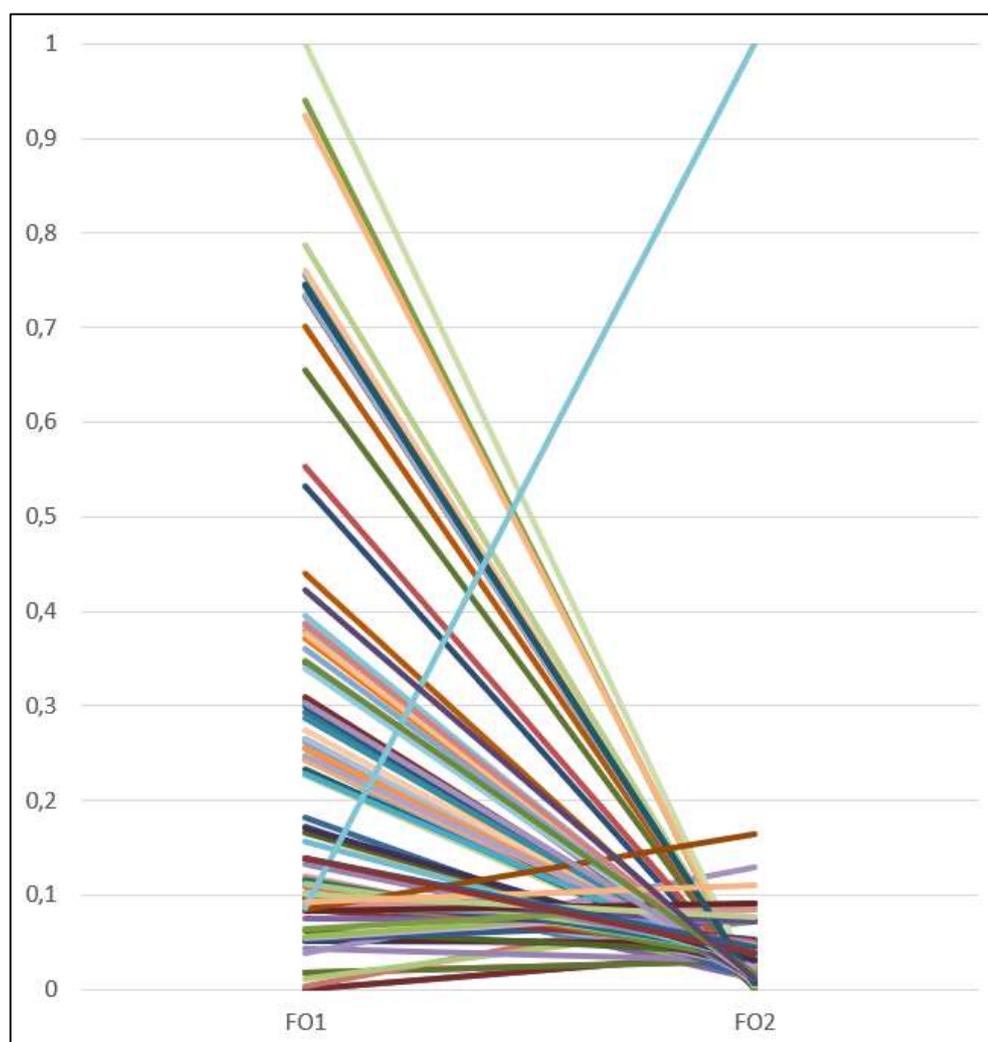
Tabela 6.4 – Descrição do roteiro proposto para o Estudo de Caso 1

PRV	Descrição do roteiro proposto	Capacidade atribuída
Tour 1	0-6-25-1-34-45-12-0	199
Tour 2	0-22-19-18-7-33-2-24-10-14-13-28-41-31-44-27-37-42-40-0	197
Tour 3	0-5-17-16-15-43-4-3-11-48-0	199
Tour 4	0-26-20-29-32-8-9-21-35-46-47-23-30-38-39-36-0	196

Fonte: o Autor.

Na Figura 6.9 pode-se observar a avaliação de conflito por meio dos valores normalizados resultantes das FOs.

Figura 6.9 – Avaliação de conflito entre as FOs do Estudo de caso 1, através do CWNSGA-II



Fonte: o Autor.

A Tabela 6.5 apresenta informações obtidas por meio das funções objetivo utilizadas, mais especificamente, os roteiros obtidos da fronteira de Pareto, emissão

de CO₂ (FO₁), distância percorrida, consumo de combustível, tempo de percurso, número de veículos utilizados e a diferença da demanda (FO₂).

Tabela 6.5 – Informações obtidas por meio das funções objetivo, através da técnica CWNSGA-II, do Estudo de Caso 1

Solução (roteiro)	Emissões quilométricas (kg) de CO ₂ /km	Distância percorrida (km)	Consumo de combustível (l)	Tempo de percurso (min)	Nº de veículos utilizados	Diferença da Demanda
VRP 1	1,7	23,6	0,6	87	4	13,5
VRP 2	1,7	23,8	0,6	89	4	11,0
VRP 3	1,7	24,9	0,6	88	4	7,0
VRP 4	1,7	24,9	0,6	92	4	5,0
VRP 5	1,8	26,3	0,7	95	4	3,5
VRP 6	1,9	26,8	0,7	95	4	3,0
VRP 7	2,1	29,4	0,7	101	4	1,5

Fonte: o Autor.

A Tabela 6.6 apresenta a estratificação da capacidade atribuída em cada roteiro (*tours* do VRP) obtido pela fronteira de Pareto.

Tabela 6.6 – Estratificação da capacidade atribuída em cada sub-*tour* das soluções, através da técnica CWNSGA-II, do Estudo de Caso 1

Solução (roteiro)	Capacidade atribuída em cada <i>tour</i> do VRP			
	<i>Tour 1</i>	<i>Tour 2</i>	<i>Tour 3</i>	<i>Tour 4</i>
VRP 1	199	191	202	199
VRP 2	197	193	202	199
VRP 3	197	200	195	199
VRP 4	199	197	199	196
VRP 5	199	198	198	196
VRP 6	197	197	198	199
VRP 7	197	198	198	198

Fonte: o Autor.

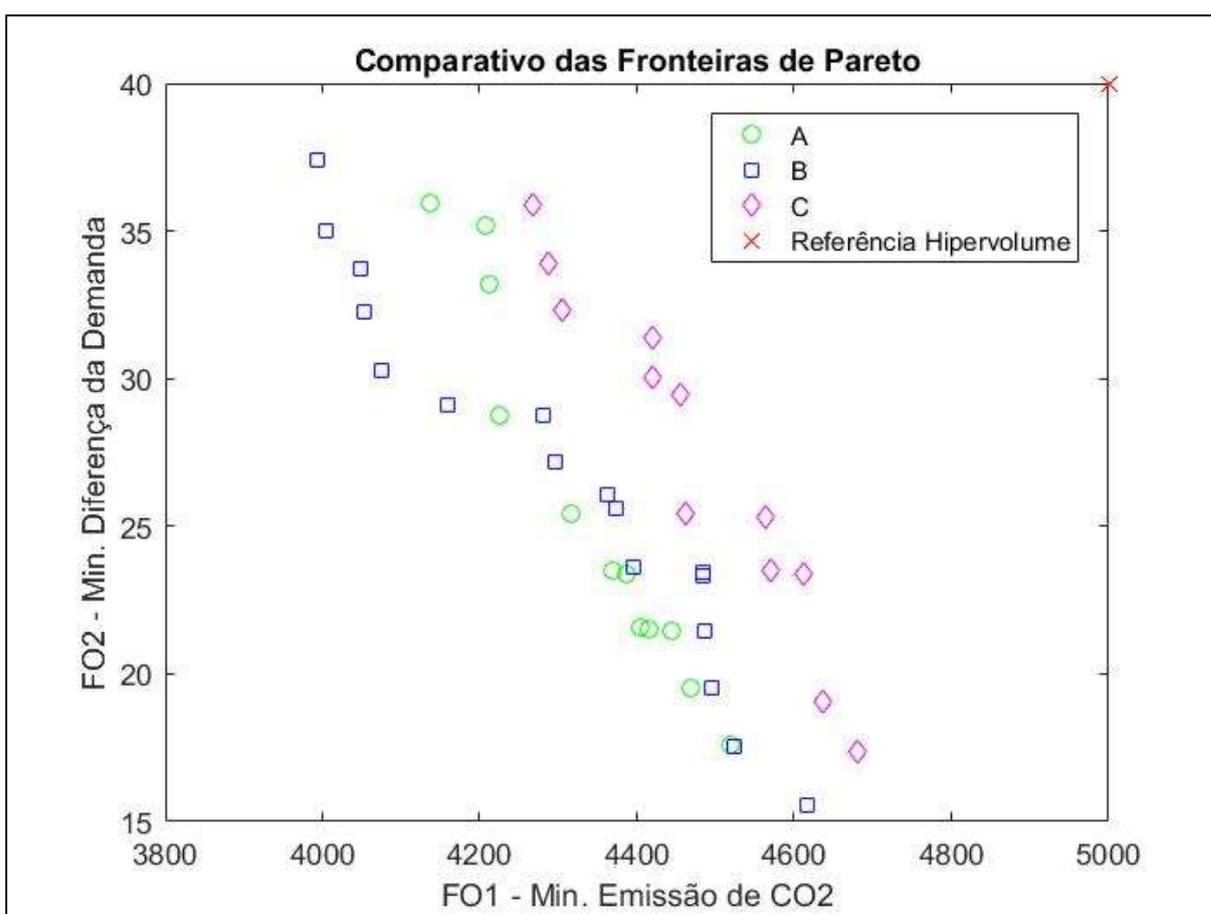
6.2 ESTUDO DE CASO 2: TRANSPORTE DE FUNCIONÁRIOS

Nesta seção são apresentados os resultados obtidos através de cada uma das técnicas utilizadas (NSGA-II; MOPSO; CWNSGA-II e CWTSNSGA-II) para o segundo estudo de caso, transporte de funcionários.

6.2.1 NSGA-II

Inicialmente foram realizadas três rodadas (A, B e C), variando as populações iniciais em cada uma das rodadas, fazendo-se uso da técnica NSGA-II, sendo que as respectivas fronteiras são apresentadas na Figura 6.10. Os tempos computacionais foram de 10,5; 10,1 e 11,8 segundos, respectivamente. A Tabela 6.7 apresenta os hipervolumes das fronteiras da Figura 6.10 para auxiliar na decisão da fronteira mais dominante.

Figura 6.10 – Comparativo das rodadas iniciais do Estudo de Caso 2, algoritmo NSGA-II



Fonte: o Autor

Tabela 6.7 – Avaliação das fronteiras de Pareto

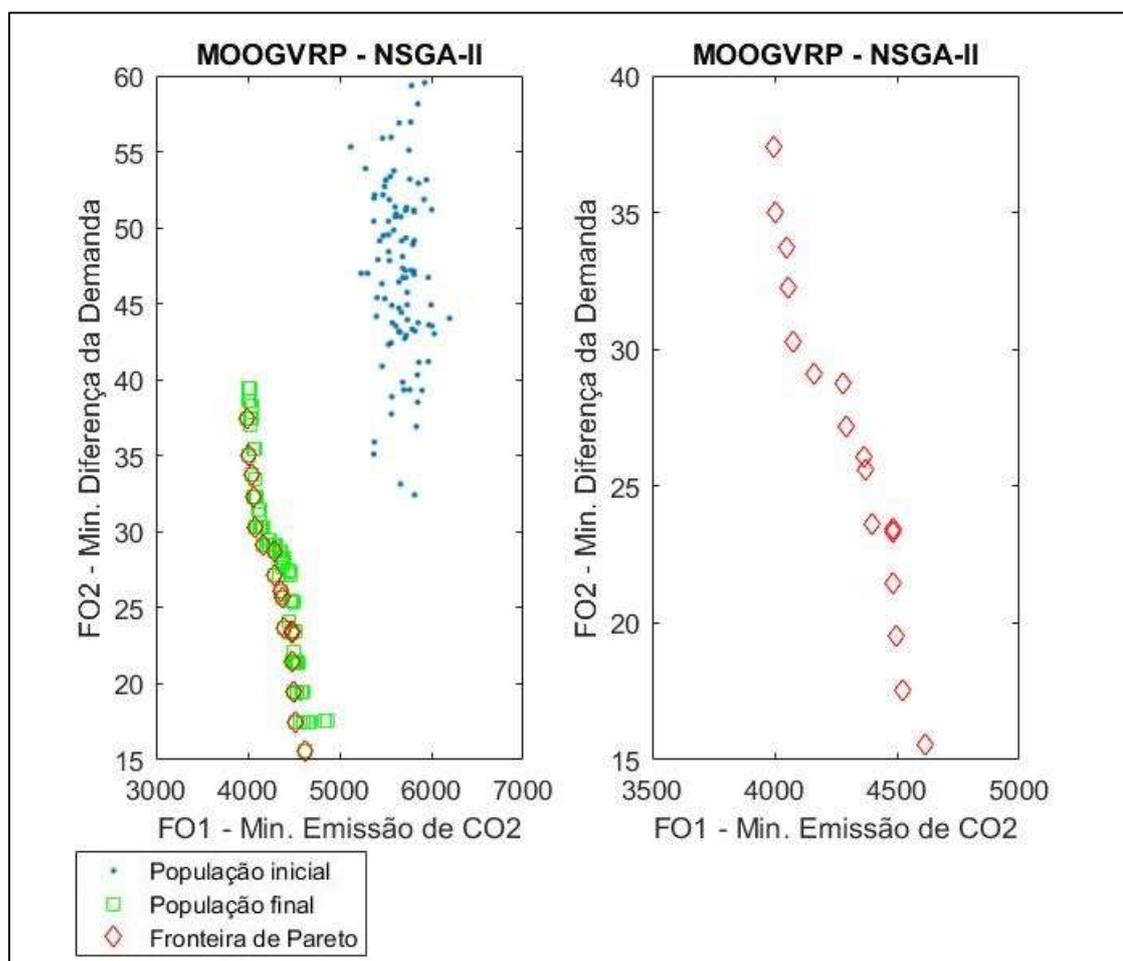
Rodada/solução	Hipervolume (u.a.)
A	157.730.000
B	177.710.000
C	123.230.000

Fonte: o Autor.

Vale ressaltar que os valores dos hipervolumes ficaram altos, pois as técnicas NSGA-II e MOPSO apresentaram soluções ruins em relação as demais, o que deixou distante a referência para o cálculo do hipervolume. Conseqüentemente o valor do hipervolume ficou maior; o estudo de caso 1 trata de uma base onde os endereços são relativamente próximos, dentro de um único bairro e, desta forma, o valor do hipervolume será proporcionalmente menor; no estudo caso 2, os endereços são bem mais distantes, pois contempla Curitiba e Região Metropolitana. Por esta razão os valores de hipervolume ficaram proporcionalmente mais altos.

Portanto, o conjunto de soluções B que apresenta o maior hipervolume, com 177.710.000 u.a., será a solução analisada. A Figura 6.11 apresenta a população inicial, população final e a fronteira da solução B obtida por meio da técnica NSGA-II.

Figura 6.11 – Fronteira de Pareto com a população inicial e final (lado esquerdo) e fronteira de Pareto (lado direito), através da técnica NSGA-II, no Estudo de Caso 2

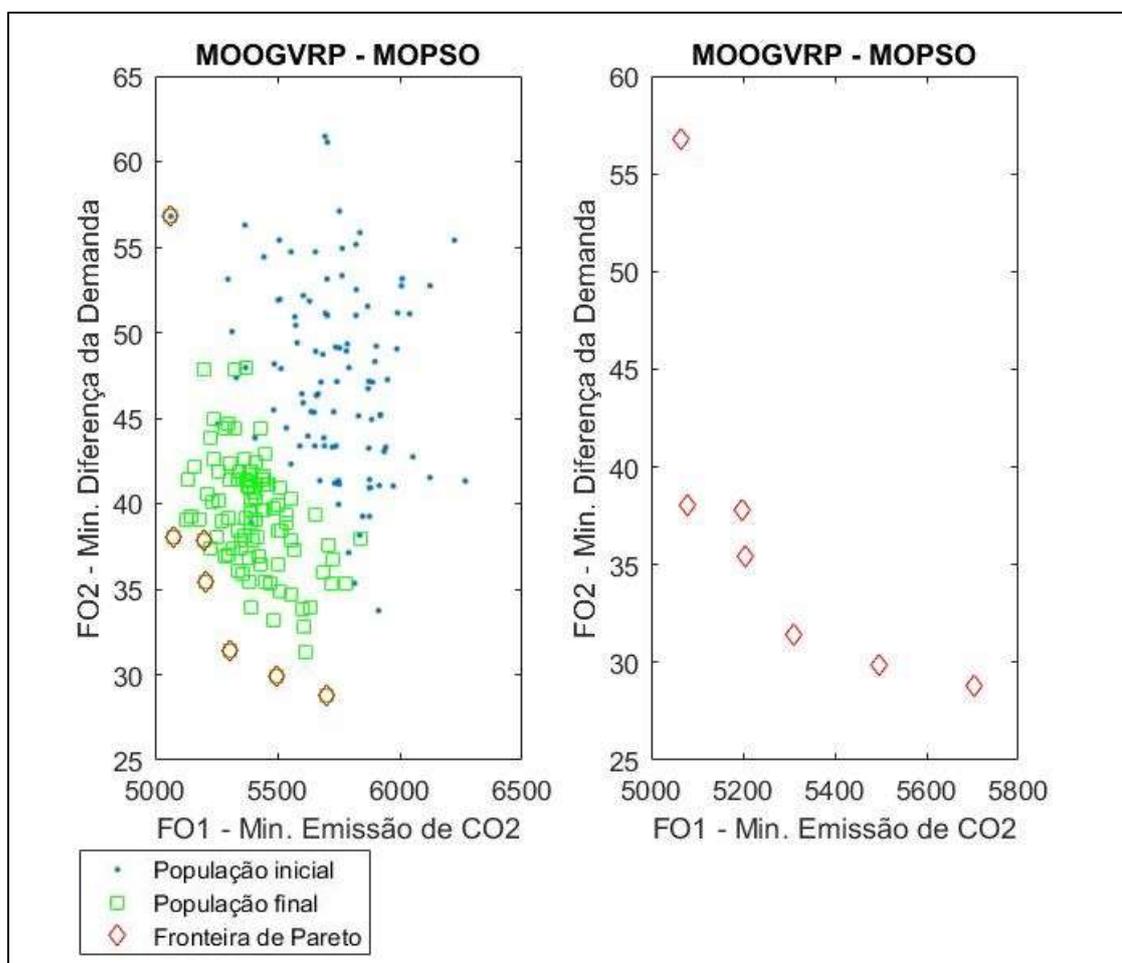


Fonte: o Autor.

6.2.2 MOPSO

Inicialmente foram realizadas três rodadas (A, B e C) fazendo-se uso da técnica MOPSO, variando as populações iniciais em cada uma das rodadas. Os tempos computacionais foram de 30,7; 30,4 e 31,5 segundos. Os hipervolumes obtidos foram de 223.970.000, 228.370.000 e 231.100.000 u.a., portanto, o conjunto de soluções C (fronteira) que apresentou o maior hipervolume será a solução analisada. A Figura 6.3 apresenta a população inicial, população final e a fronteira da solução (rodada) C, obtida por meio da técnica MOPSO.

Figura 6.12 – Fronteira de Pareto com a poluição inicial e final (lado esquerdo) e fronteira de Pareto (lado direito), através da técnica MOPSO, no Estudo de Caso 2

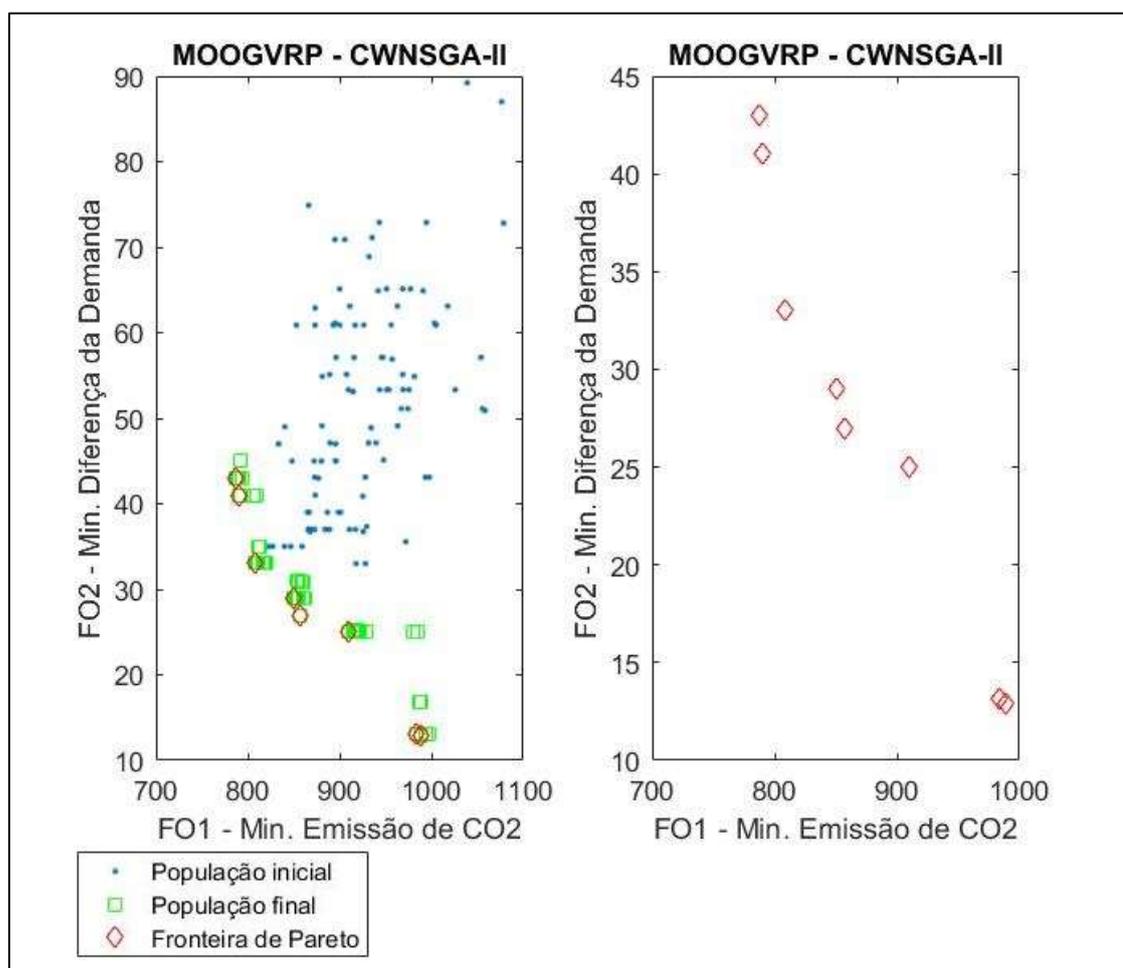


Fonte: o Autor.

6.2.3 CWNSGA-II

Inicialmente foram realizadas três rodadas (A, B e C) fazendo-se uso da técnica CWNSGA-II, variando as populações iniciais em cada uma das rodadas. Os tempos computacionais foram de 9,7; 9,8 e 13,8 segundos. Os hipervolumes obtidos foram de 56.624.000, 56.458.000 e 68.573.000 u.a., portanto, o conjunto de soluções C (fronteira) que apresentou o maior hipervolume será a solução analisada. A Figura 6.13 apresenta a população inicial, população final e a fronteira da solução C obtida por meio da técnica CWNSGA-II.

Figura 6.13 – Fronteira de Pareto com a população inicial e final (lado esquerdo) e fronteira de Pareto (lado direito), através da técnica CWNSGA-II, Estudo de Caso 2

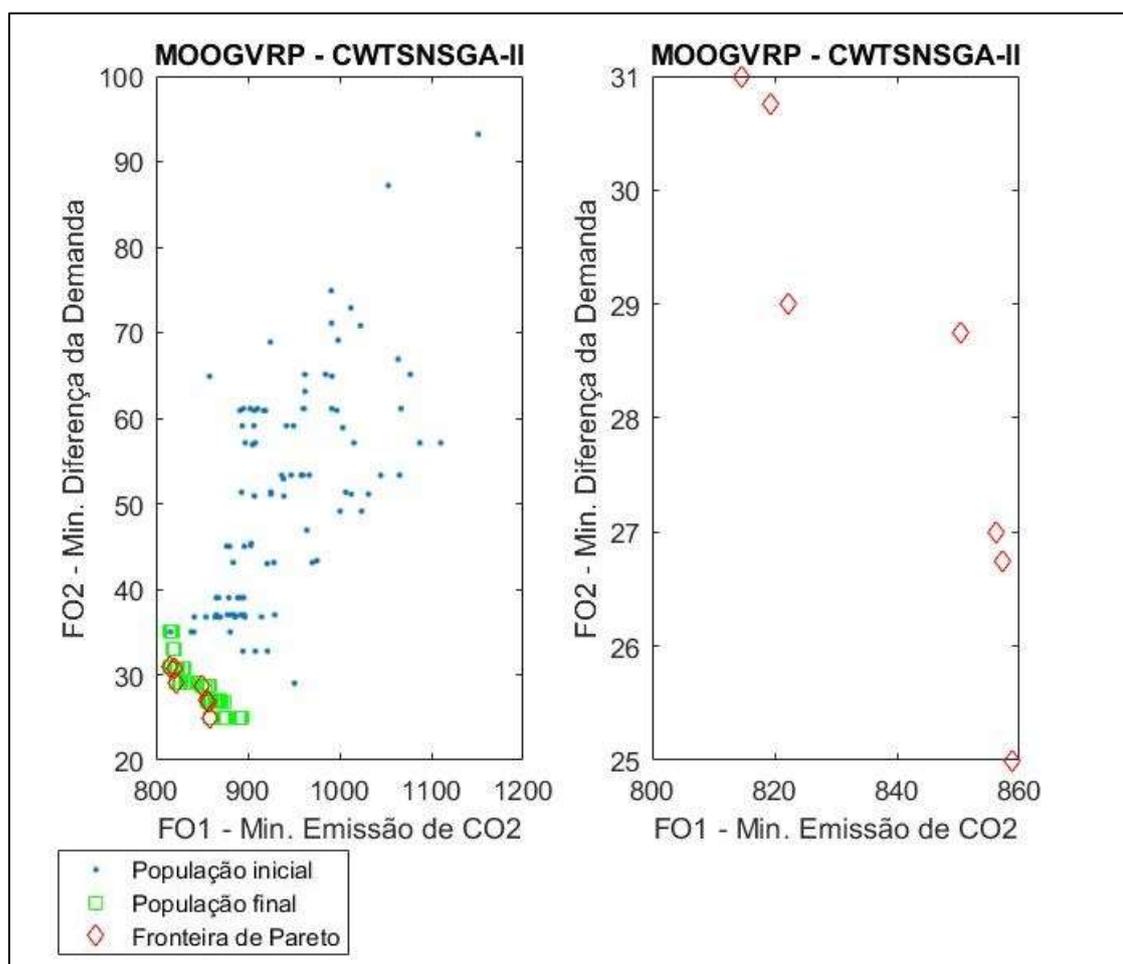


Fonte: o Autor.

6.2.4 CWTSNSGA-II

Inicialmente foram realizadas três rodadas (A, B e C), variando as populações iniciais em cada uma das rodadas, fazendo-se uso da técnica CWTSNSGA-II. Os tempos computacionais foram de 18,5; 17,1 e 15,3 segundos. Os hipervolumes obtidos foram de 20.718.000, 19.412.000 e 24.048.000 u.a., portanto, o conjunto de soluções C (fronteira) que apresentou o maior hipervolume será a solução analisada. A Figura 6.14 apresenta a população inicial, população final e a fronteira da solução C obtida por meio da técnica CWTSNSGA-II.

Figura 6.14 – Fronteira de Pareto com a população inicial e final (lado esquerdo) e fronteira de Pareto (lado direito), através da técnica CWTSNSGA-II

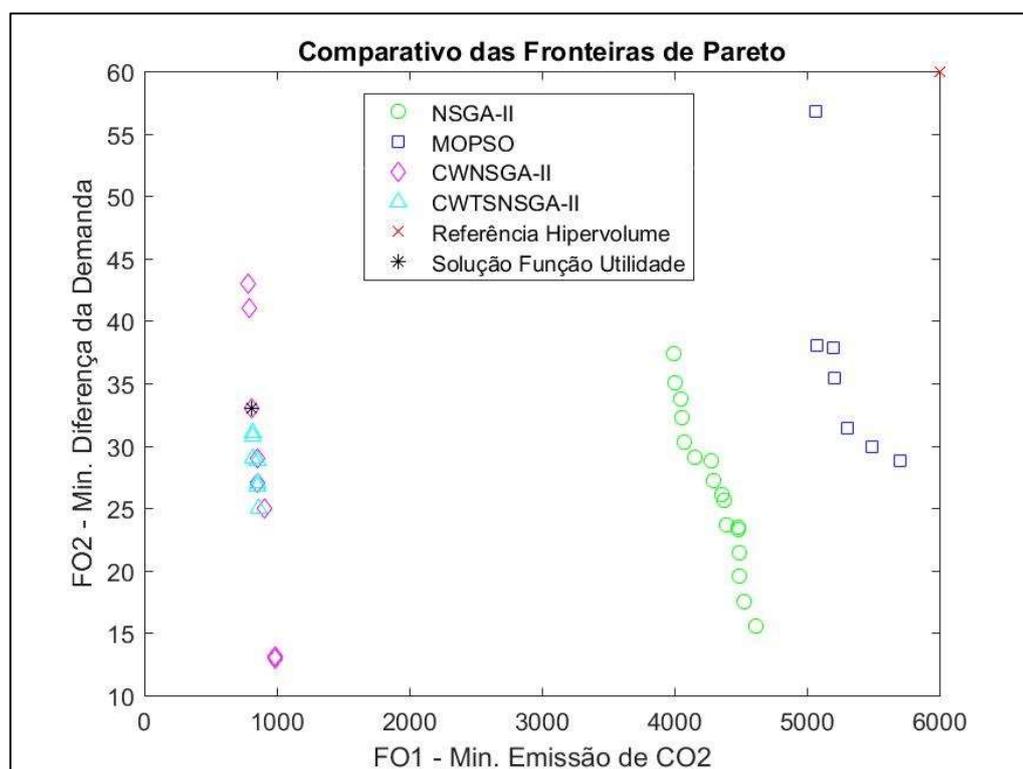


Fonte: o Autor.

6.2.5 Análise dos Resultados

A Figura 6.15 apresenta um gráfico com as fronteiras de Pareto obtidas das técnicas utilizadas para a resolução deste estudo de caso 2. Também aparece o ponto de referência, ponto = (6000; 60), para o cálculo do hipervolume e a solução para a Função Utilidade, ponto = (808,19; 33,0), que será apresentada na sequência.

Figura 6.15 – Análise das fronteiras de Pareto entre as técnicas utilizadas no Estudo de Caso 2



Fonte: o Autor.

A Tabela 6.8 apresenta o resultado da avaliação das fronteiras de Pareto. Nota-se que quanto maior o valor do hipervolume, melhor será o conjunto de soluções. Portanto, do mesmo modo que ocorreu no Estudo de Caso 1, o cálculo do hipervolume reforça a dominância da solução do algoritmo CWNSGA-II quanto ao CWTSNSGA-II, NSGA-II e MOPSO, respectivamente, neste problema proposto com 1.8 bilhões de u.a.. Nota-se que os valores de hipervolume apresentados na Tabela 6.8 são diferentes dos valores do melhor hipervolume de cada algoritmo. Isso porque a referência para o cálculo foi alterado, pois aqui trata-se do comparativo entre algoritmos.

Tabela 6.8 – Avaliação das fronteiras de Pareto

Algoritmo	Hipervolume
NSGA-II	823.170.000
MOPSO	262.310.000
CWNSGA-II	2.423.900.000
CWTSNSGA-II	1.813.000.000

Fonte: o Autor.

A Tabela 6.9 apresenta o comparativo entre a solução atual e as soluções propostas. Assim, verifica-se informações obtidas por meio das funções objetivo utilizadas, mais especificamente, os roteiros obtidos da fronteira de Pareto, emissão de CO₂ (FO₁), distância percorrida, consumo de combustível, tempo de percurso, número de veículos utilizados e a diferença da demanda (FO₂).

Tabela 6.9 – Comparativo entre a solução atual e as soluções propostas

Solução (roteiro)	Emissões em quilogramas (kg) de CO ₂ /km	Distância percorrida (km)	Consumo de combustível (l)	Tempo de percurso (min)	Nº de veículos	Diferença da Demanda
Atual	852,4	666	256,1	862	8	37,2
VRP 1	787,5	615,2	236,6	869	8	43,0
(%)	7,6%	7,6%	7,6%	-0,8%	0,0%	-15,4%
VRP 2	790,2	617,4	237,4	863	8	41,0
(%)	7,3%	7,3%	7,3%	-0,1%	0,0%	-10,1%
VRP 3	808,1	631,4	242,8	896	8	33,0
(%)	5,2%	5,2%	5,2%	-3,9%	0,0%	11,4%
VRP 4	850,4	664,4	255,5	925	8	29,0
(%)	0,2%	0,2%	0,2%	-7,3%	0,0%	22,1%
VRP 5	857,6	670	257,6	940	8	27,0
(%)	-0,6%	-0,6%	-0,6%	-9,0%	0,0%	27,5%
VRP 6	910,1	711	273,4	940	8	25,0
(%)	-6,8%	-6,8%	-6,8%	-9,0%	0,0%	32,9%
VRP 7	983,0	768	295,3	978	9	22,0
(%)	-15,3%	-15,3%	-15,3%	-13,5%	-12,5%	40,9%
VRP 8	988,1	772	296,9	984	9	22,0
(%)	-15,9%	-15,9%	-15,9%	-14,2%	-12,5%	40,9%

Fonte: o Autor.

A Figura 6.16 apresenta os cálculos da aplicação da Função Utilidade aplicada na fronteira de Pareto dominante, resultante do algoritmo CWNSGA-II. Para tal procedimento, foi solicitado ao decisor a atribuição de pesos em cada uma das funções objetivo. Então, o Decisor atribuiu 70% de importância para a primeira função objetivo e 30% para a segunda função objetivo. Por fim, a solução 3, com

coordenadas (808,19; 33,0) apresentou a maior Função Utilidade, sendo esta a solução proposta para este Estudo de Caso 2. A otimização foi de 5,2% para a FO₁ (min emissão de CO₂) e 11,4% para a FO₂ (min da diferença da demanda).

Figura 6.16 – Função Utilidade aplicada na fronteira de Pareto dominante do Estudo de caso 2

Solução	1	2	3	4	5	6	7	8
FO1	787,46	790,27	808,19	850,43	857,60	910,08	983,04	988,16
FO2	43,00	41,00	33,00	29,00	27,00	25,00	13,11	12,89

Menor é melhor!
Menor é melhor!

Solução	1	2	3	4	5	6	7	8
FO1	1,00	0,99	0,90	0,69	0,65	0,39	0,03	0,00
FO2	0,00	0,07	0,33	0,46	0,53	0,60	0,99	1,00
Função Utilidade	0,70	0,71	0,73	0,62	0,61	0,45	0,32	0,30

Pesos
0,70
0,30

Fonte: o Autor.

A solução otimizada faz uso da mesma quantidade de veículos (motocicletas) e foi melhor em relação as emissões, distância, consumo de combustível e diferença da demanda, ou seja, melhor equilíbrio da quantidade de jornais atribuídos aos *bags* para a sua distribuição. Foi pior quanto ao tempo de percurso. Por outro lado, os ônibus com ociosidade podem atender as flutuações de demanda com mais agilidade.

A Tabela 6.10 apresenta a estratificação da capacidade atribuída em cada roteiro (*tours* do VRP) e a Tabela 6.11, o tempo, todos obtidos pela solução atual e as soluções da fronteira de Pareto.

Tabela 6.10 – Estratificação da capacidade atribuída em cada sub-*tour* da solução atual e das soluções otimizadas, através da técnica CWNSGA-II, do Estudo de Caso 2, com limite de percurso em 127 min

Solução (roteiro)	Capacidade atribuída em cada <i>tour</i> do VRP								
	Tour 1	Tour 2	Tour 3	Tour 4	Tour 5	Tour 6	Tour 7	Tour 8	Tour 9
Atual	26	31	20	29	27	18	18	30	
VRP 1	31	14	19	31	29	30	23	22	-
VRP 2	31	14	20	31	28	30	23	22	-
VRP 3	31	16	22	27	28	30	23	22	-
VRP 4	31	16	24	28	25	30	23	22	-
VRP 5	31	17	24	27	25	30	23	22	-
VRP 6	31	17	24	25	26	30	24	22	-
VRP 7	24	19	20	24	21	23	24	22	22
VRP 8	24	19	20	24	21	23	23	23	22

Fonte: o Autor.

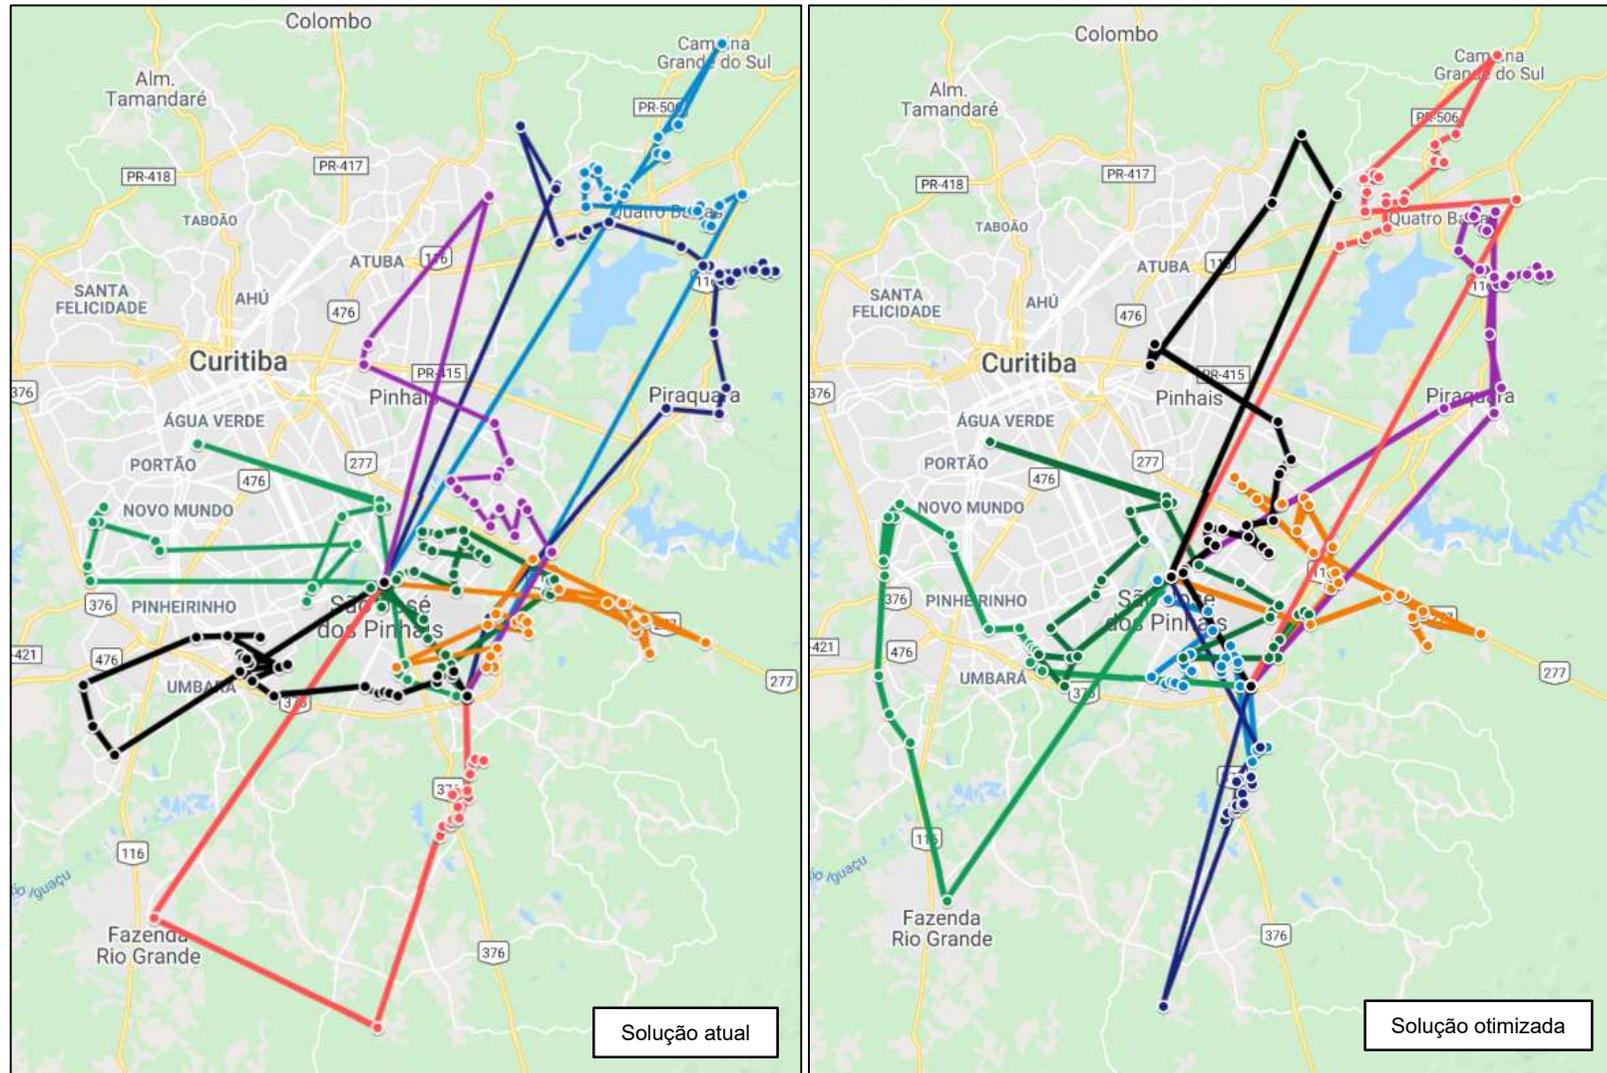
Tabela 6.11 – Estratificação do tempo atribuído em cada sub-*tour* da solução atual e das soluções otimizadas, através da técnica CWNSGA-II, do Estudo de Caso 2, com limite de percurso em 127 min

Solução (roteiro)	Tempo (min) atribuído em cada <i>tour</i> do VRP								
	<i>Tour 1</i>	<i>Tour 2</i>	<i>Tour 3</i>	<i>Tour 4</i>	<i>Tour 5</i>	<i>Tour 6</i>	<i>Tour 7</i>	<i>Tour 8</i>	<i>Tour 9</i>
Atual	93	127	112	102	106	93	112	117	-
VRP 1	88	90	121	122	112	100	113	123	-
VRP 2	88	90	126	113	110	100	113	123	-
VRP 3	88	119	126	109	118	100	113	123	-
VRP 4	117	120	126	112	114	100	113	123	-
VRP 5	113	124	126	115	121	105	113	123	-
VRP 6	113	124	126	119	115	100	120	123	-
VRP 7	123	95	126	118	95	113	70	115	123
VRP 8	123	95	126	118	99	113	68	118	124

Fonte: o Autor.

A Figura 6.17 apresenta o comparativo da solução corrente (lado esquerdo) com a solução otimizada (lado direito) e a Tabela 6.12 a descrição dos roteiros da solução proposta para a coleta e entrega no transporte de funcionários, do Estudo de Caso 2.

Figura 6.17 – Comparação da solução corrente (esquerda) x otimizada (direita) para o Estudo de Caso 2



Fonte: o Autor.

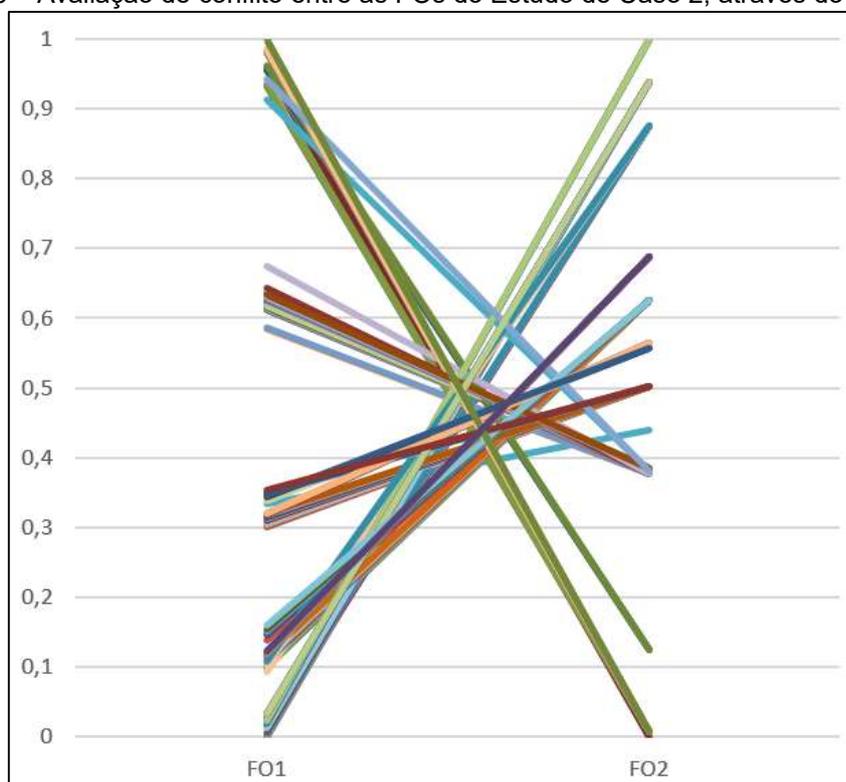
Tabela 6.12 – Descrição do roteiro proposto para o Estudo de Caso 2 (G=Garagem; F=Fábrica)

PRV	Descrição do roteiro proposto	Capacidade atribuída
Tour 1	G-96-95-97-98-177-178-179-180-181-73-72-71-100-182-183-99-75-184-185-74-161-160-158-F	31
Tour 2	G-159-156-151-153-152-154-157-155-150-148-149-147-146-145-144-162-F	16
Tour 3	G-163-164-56-58-57-60-59-61-62-165-167-169-170-172-175-173-176-171-168-174-166-F	22
Tour 4	G-64-65-63-66-67-68-69-70-92-91-90-139-55-120-121-125-124-123-126-122-115-114-117-118-116-119-F	27
Tour 5	G-101-105-110-111-108-107-102-106-103-109-112-113-134-135-138-136-141-140-142-143-79-80-78-76-77-104-F	28
Tour 6	G-54-52-51-50-37-39-41-48-45-46-47-44-43-42-49-38-40-36-34-35-33-18-19-20-21-22-23-24-53-F	30
Tour 7	G-29-30-31-32-10-11-9-8-7-5-6-4-2-3-13-12-14-15-16-17-25-F	23
Tour 8	G-26-27-28-127-129-128-130-131-132-133-137-81-87-86-88-89-82-83-84-85-93-94-F	22

Fonte: o Autor.

Na Figura 6.18 pode-se observar a avaliação de conflito por meio dos valores normalizados resultantes das FOs, da solução escolhida para este Estudo de Caso 2.

Figura 6.18 – Avaliação de conflito entre as FOs do Estudo de Caso 2, através do CWNSGA-II



Fonte: o Autor.

6.2.6 Atendendo aos requisitos do Estudo de Caso 2

Até o momento foi verificado o quanto a solução pode melhorar considerando os mesmos parâmetros utilizados atualmente pela empresa, que são até 127 min de percurso e 31 lugares no veículos. Já nesta seção foi considerado o requisito de tempo máximo de trajeto solicitado pela empresa, ou seja, até 90 min. A técnica utilizada será o algoritmo CWNSGA-II, visto que apresentou o melhor desempenho até então. A Tabela 6.13 apresenta os parâmetros da seção 5.3.3, onde foi realizada a atualização do tempo máximo de trajeto.

Tabela 6.13 – Parâmetros para avaliação realística do Estudo de Caso 2

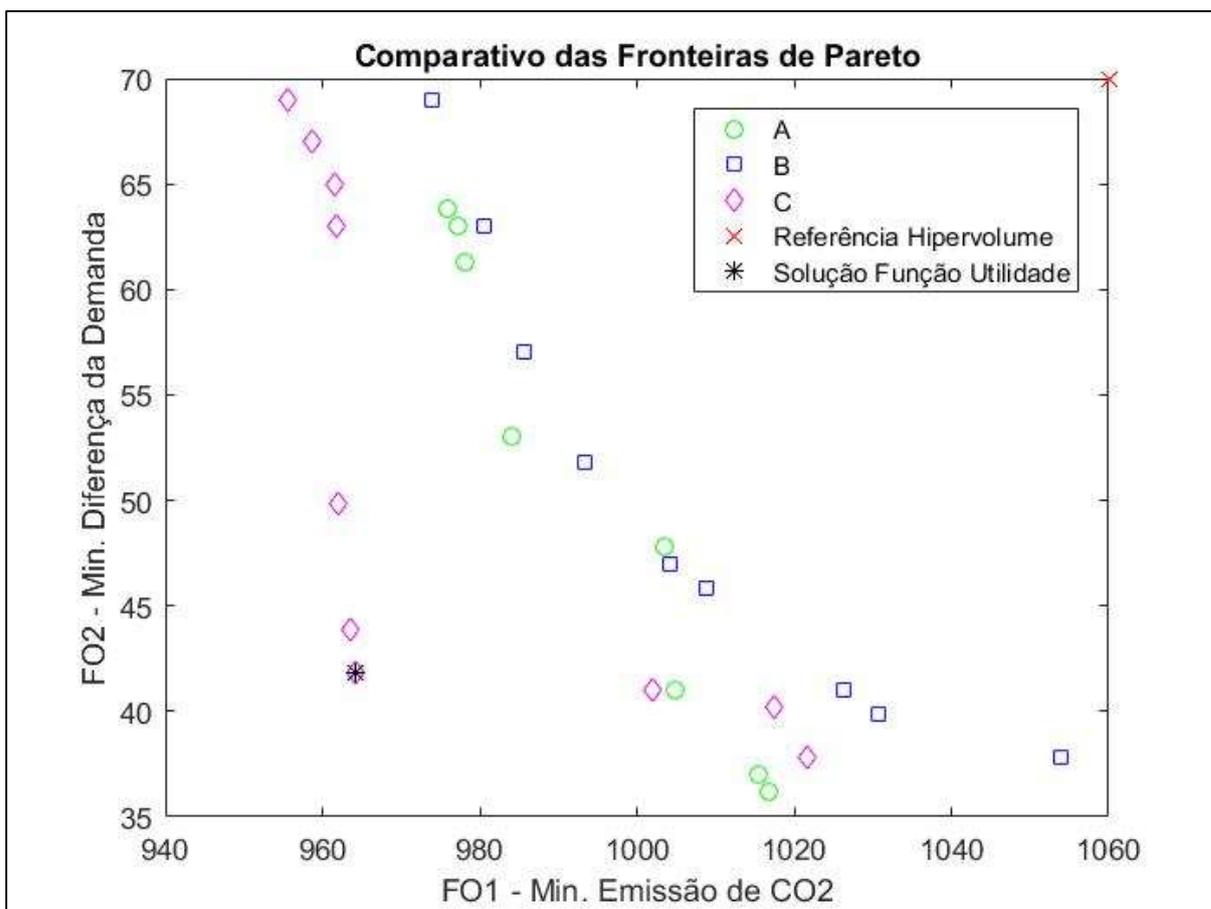
Algoritmo	Hipervolume
População	100
Capacidade do veículo	31
Número de iterações	100
Crossover	0,5
Mutação	0,1
Tempo máximo de trajeto em min	90
Vetor de decisão	(0,7; 0,3)

Fonte: o Autor.

Inicialmente foram realizadas três rodadas (A, B e C), variando as populações iniciais em cada uma das rodadas, fazendo-se uso da técnica CWNSGA-II. Os tempos computacionais foram de 8,9; 9,1 e 9,0 segundos. Os hipervolumes obtidos foram de 22.390.000, 18.918.000 e 29.347.000 u.a., portanto, o conjunto de soluções C (fronteira) que apresentou o maior hipervolume será a solução analisada.

A Figura 6.19 apresenta um gráfico com as fronteiras de Pareto obtidas da técnica CWNSGA-II utilizada para a resolução deste Estudo de Caso 2, na versão ideal. Também é apresentado o ponto de referência, ponto = (1060; 70), para o cálculo do hipervolume e a solução para a Função Utilidade, ponto = (964,1; 41,8), a sétima solução da rodada C, que será apresentada na sequência. Nota-se que o vetor de decisão, para a Função Utilidade, é diferente do apresentado no início deste estudo de caso; tal medida foi adotada para que a solução otimizada fosse melhor em relação a solução corrente. No caso atual, com mais veículos, tem-se uma situação diferente e mais espaço para a análise.

Figura 6.19 – Análise das fronteiras de Pareto obtidas por CWNSGA-II para o Cenário 2 - ideal



Fonte: o Autor.

A Tabela 6.14 apresenta informações obtidas por meio das funções objetivo utilizadas, mais especificamente, os roteiros da PF, emissão de CO₂ (FO₁), distância percorrida, consumo de combustível, tempo de percurso, número de veículos utilizados e a diferença da demanda (FO₂).

Tabela 6.14 – Informações obtidas por meio das funções objetivo, através da técnica CWNSGA-II, do Estudo de Caso 2 – ideal

Solução (roteiro)	Emissões quilométricas (kg) de CO ₂ /km	Distância percorrida (km)	Consumo de combustível (l)	Tempo de percurso (min)	Nº de veículos utilizados	Diferença da Demanda
Atual	852,4	666	256,1	862	8	37,2
VRP 1	955,5	746,5	287,1	931	12	69,0
VRP 2	958,7	749,0	288,1	930	12	67,0
VRP 3	961,5	751,2	288,9	934	12	65,0
VRP 4	961,7	751,3	289,0	936	12	63,0
VRP 5	962,1	751,6	289,1	947	12	49,8
VRP 6	963,5	752,7	289,5	956	12	43,8
VRP 7	964,1	753,2	289,7	962	12	41,8
VRP 8	1.002,0	782,8	301,1	988	12	41,0
VRP 9	1.017,5	794,9	305,7	1003	12	40,2
VRP 10	1.021,6	798,1	307,0	1005	12	37,8

Fonte: o Autor.

A Tabela 6.15 apresenta a estratificação da capacidade atribuída em cada roteiro (*tours* do VRP) e a Tabela 6.16, o tempo, todos obtidos pela solução atual e as soluções da fronteira de Pareto. Nota-se que respeitando o tempo de até 90 min de trajeto, será necessário o acréscimo de 4 ônibus. Assim será mais interessante o uso de microônibus ou van para evitar a ociosidade da capacidade. Embora aparentemente inviável, por conta da necessidade de mais veículos e motoristas, aqui fica a proposta e cabe a empresa tomar a decisão que julgue como sendo a mais adequada. A Figura 6.20 apresenta o comparativo da solução corrente de 8 veículos (lado esquerdo) com a solução otimizada de 12 veículos (lado direito).

Tabela 6.15 – Estratificação da capacidade atribuída em cada sub-*tour* da solução atual e das soluções otimizadas, através da técnica CWNSGA-II, do Estudo de Caso 2 – Ideal, com limite de percurso em 90 min

Solução (roteiro)	Capacidade atribuída em cada <i>tour</i> do VRP											
	Tour 1	Tour 2	Tour 3	Tour 4	Tour 5	Tour 6	Tour 7	Tour 8	Tour 9	Tour 10	Tour 11	Tour 12
Atual	26	31	20	29	27	18	18	30	-	-	-	-
VRP 1	26	18	5	16	19	23	19	29	14	11	13	6
VRP 2	26	18	5	16	20	21	19	29	14	11	13	7
VRP 3	25	18	6	16	20	21	19	29	14	11	13	7
VRP 4	24	18	6	16	20	21	19	29	14	11	14	7
VRP 5	25	18	6	16	20	21	18	22	17	14	8	14
VRP 6	25	18	5	16	19	23	18	18	14	14	12	17
VRP 7	25	18	6	16	20	21	18	18	14	14	12	17
VRP 8	28	17	8	16	23	15	17	18	14	14	12	17
VRP 9	28	17	8	16	23	16	16	18	14	14	12	17
VRP 10	28	17	8	16	20	17	18	18	14	14	12	17

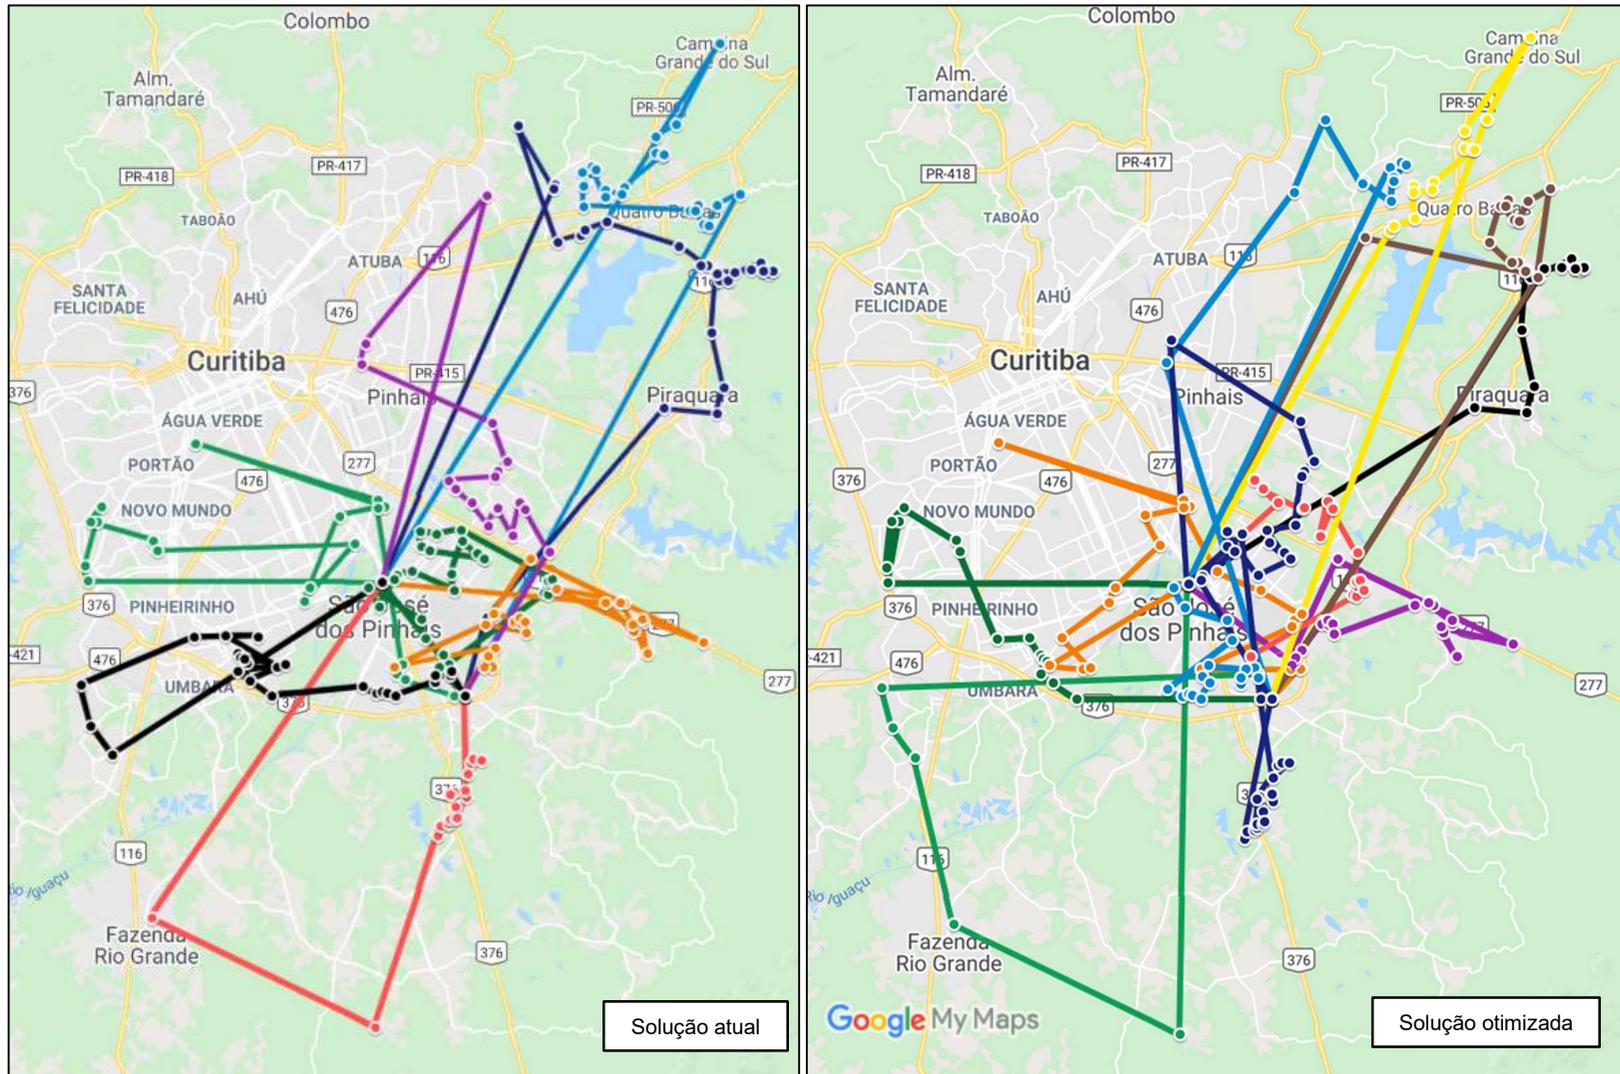
Fonte: o Autor.

Tabela 6.16 – Estratificação do tempo atribuído em cada sub-*tour* da solução atual e das soluções otimizadas, através da técnica CWNSGA-II, do Estudo de Caso 2 – Ideal, com limite de percurso em 90 min

Solução (roteiro)	Tempo (min) atribuído em cada <i>tour</i> do VRP											
	Tour 1	Tour 2	Tour 3	Tour 4	Tour 5	Tour 6	Tour 7	Tour 8	Tour 9	Tour 10	Tour 11	Tour 12
Atual	93	127	112	102	106	93	112	117	-	-	-	-
VRP 1	59	79	82	89	88	83	85	76	79	89	87	35
VRP 2	59	79	82	89	89	79	85	76	79	89	87	37
VRP 3	57	79	86	89	89	79	85	76	79	89	89	37
VRP 4	59	79	86	89	89	79	85	76	79	89	89	37
VRP 5	57	79	86	89	89	79	62	85	84	86	89	62
VRP 6	57	79	82	89	88	83	59	77	80	89	88	85
VRP 7	57	79	86	89	89	79	62	77	80	89	88	87
VRP 8	83	83	84	83	84	84	74	77	80	89	88	79
VRP 9	83	83	84	83	86	87	84	77	80	89	88	79
VRP 10	83	83	84	83	89	89	78	77	80	89	88	82

Fonte: o Autor.

Figura 6.20 – Comparação da solução corrente (esquerda) x otimizada (direita) para o Estudo de Caso 2 - Ideal



Fonte: o Autor.

6.3 INSTÂNCIAS DA LITERATURA

Os algoritmos apresentados neste trabalho (NSGA-II; MOPSO; CWNSGA-II e CWTSNSGA-II) foram aplicados a um conjunto de instâncias da literatura. Para o caso do MOOGVRP foi utilizado um conjunto de 27 instâncias do CVRP (mais especificamente o *Set A* de Augerat), com a dimensão variando de 32 até 80 cidades (considerando o depósito), entre 5 e 10 roteiros nas soluções, disponível em <http://neo.lcc.uma.es/vrp/vrp-instances/capacitated-vrp-instances/>.

No estudo de caso 1, distribuição de jornais, a base de dados foi composta pela distância entre os endereços. Já no estudo de caso 2, transporte de funcionários, a base de dados foi composta pela distância e pelo tempo entre os endereços. A função objetivo (4.1) fez uso das distâncias como referência para avaliar a emissão de CO₂. A restrição (4.13) utilizou o tempo de trajeto em sua métrica. Após testes preliminares realizados pelo autor para o estudo de caso 2, foi constatado que os códigos dos algoritmos CWNSGA-II, CWTSNSGA-II utilizados no estudo de caso 1 não poderiam ser fielmente aplicados no estudo de caso 2. O procedimento de C&W aplicado nas “pétalas” do roteiro cumpriu o seu papel de melhorar a rota quanto a quilometragem, entretanto, em alguns casos piorou o tempo de percorrida, assim violando a equação (4.13) de limitação do tempo. Nos testes das Instâncias da Literatura não se aplicou a equação (4.13), pois as bases fornecidas não contemplam os tempos de percurso.

Por esta razão, foi realizada a divisão dos algoritmos CWNSGA-II e CWTSNSGA-II em versão 1 e versão 2. Para a versão 1 tem-se a aplicação do algoritmo de C&W para aprimorar as “pétalas” do roteiro; esta versão 1 foi utilizada no estudo de caso 1. Já na versão 2, utilizada no estudo de caso 2, não foi aplicado o algoritmo de C&W nas “pétalas”, tornando-se assim uma simplificação da versão 1. Desta forma, aqui foi bordado os algoritmos NSGA-II, MOPSO, CWNSGA-II_v1, CWNSGA-II_v2, CWTSNSGA-II_v1 e CWTSNSGA-II_v2. A seguir a descrição das métricas avaliativas e a análise das instâncias da literatura.

6.3.1 Métricas Avaliativas

Para avaliar os algoritmos apresentados neste trabalho foram utilizados os mesmos parâmetros de Hassanzadeh e Barzoki (2017) quanto ao número de iterações, tamanho da população e/ou partícula, percentual de crossover e percentual de mutação; e Abad et al. (2018) para a taxa de cognição. A Tabela 6.17 apresenta os parâmetros atribuídos.

Tabela 6.17 – Valores atribuídos para os parâmetros do NSGA-II, MOPSO e CWNSGA-II

Parâmetro	Nível
Iterações	100
População/Partícula	60
Crossover	0,7
Mutação	0,3
C ₁ e C ₂	1

Fonte: o Autor.

Todas as instâncias apresentam capacidade do veículo em 100 unidades. As FOs utilizadas são as mesmas do estudo de caso 1, ou seja, as equações (4.1) e (4.2) que buscam minimizar a emissão de CO₂ e minimizar a diferença entre a maior e a menor capacidade utilizada do veículo.

Para avaliar as instâncias foram realizadas três simulações e selecionada a resposta com o maior hipervolume. As métricas utilizadas são as relacionadas à qualidade, ao tempo de processamento, ao número de soluções e a distância ideal média; tais métricas também foram utilizadas por Hassanzadeh e Barzoki (2017).

Métrica da Qualidade: Métrica da Qualidade ou percentual de soluções não dominadas. Aqui, as PFs resultantes de cada algoritmo são confrontadas e avaliadas em relação a dominância entre as soluções apresentadas. Por fim é apresentado o percentual de soluções não dominadas de cada algoritmo. Esta técnica difere da Porcentagem de Soluções Eficientes, apresentada em 4.3.6.4, pois neste caso precisa de um conjunto de referência;

Tempo de processamento: O tempo de processamento em segundos (s) de cada algoritmo;

Número de soluções: Número de soluções apresentadas na PF;

Distância Ideal Média: A distância ideal média (*Mean Ideal Distance* - MID) utiliza um ponto ideal imaginário como referência para calcular as distâncias euclidianas médias. Este ponto é obtido através do valor mínimo de cada função

objetivo entre todas as soluções da PF. Assim, o melhor algoritmo terá o menor valor de MID. O procedimento de cálculo é apresentado na equação (6.1).

$$MID = \frac{\sum_{i=1}^N C_i}{N}, C_i = \sqrt{f_{i1}^2 + f_{i2}^2} \quad (6.1)$$

onde N é o número de elementos do conjunto de soluções não dominadas de cada algoritmo; $f_{i1}^2 + f_{i2}^2$ é a distância euclidiana entre o ponto ideal e a solução não dominada. Esta técnica difere do Indicador de distância apresentado em 4.5.6.3, que precisa de um conjunto PF como referência de melhor solução;

Hipervolume: Apresentado em 4.3.6.2. O ponto de referência para cada instância é definido conforme os resultados obtidos pelos algoritmos;

Número de veículos: O modelo matemático proposto não fixou o número de veículos e, por esta razão, o número de veículos aceito varia de um até a densidade da instância, isto é, o número de “cidades” a serem percorridas. A instância proposta apresenta a quantidade de veículos utilizada em sua melhor resposta. Assim, aqui serão apresentadas a média e o desvio padrão da quantidade de veículos apresentados nas soluções da PF de cada algoritmo em cada instância.

6.3.2 Análise das Instâncias da literatura

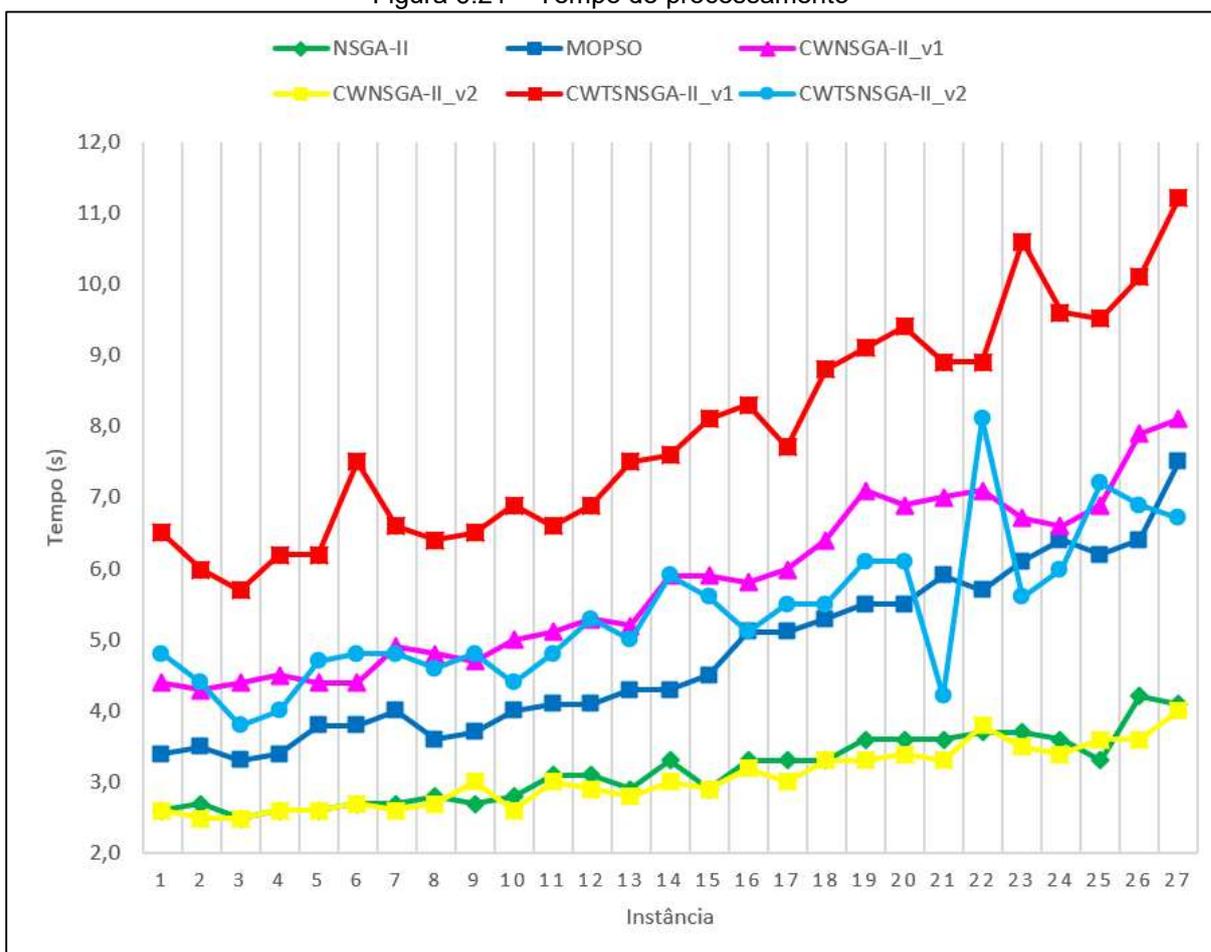
A Tabela 6.18 e a Figura 6.21 apresentam o tempo de processamento em segundos (s) do conjunto de instâncias testadas. Nota-se que os algoritmos da versão 1 precisaram de mais tempo em relação aos algoritmos da versão 2. Isso ocorre por causa da aplicação do algoritmo de C&W nas “pétalas” das soluções dos roteiros, após o *crossover*, com a finalidade de aprimorá-las. Além disso, o algoritmo CWTSNSGA-II_v1 foi o mais lento devido a complexidade da sua estrutura.

Tabela 6.18 – Tempo de processamento

Instância	Referência	NSGA-II	MOPSO	CWNSGA-II_v1	CWNSGA-II_v2	CWTSNSGA-II_v1	CWTSNSGA-II_v2
A-n32-k5	1	2,6	3,4	4,4	2,6	6,5	4,8
A-n33-k5	2	2,7	3,5	4,3	2,5	6,0	4,4
A-n33-k6	3	2,5	3,3	4,4	2,5	5,7	3,8
A-n34-k5	4	2,6	3,4	4,5	2,6	6,2	4,0
A-n36-k5	5	2,6	3,8	4,4	2,6	6,2	4,7
A-n37-k5	6	2,7	3,8	4,4	2,7	7,5	4,8
A-n37-k6	7	2,7	4,0	4,9	2,6	6,6	4,8
A-n38-k5	8	2,8	3,6	4,8	2,7	6,4	4,6
A-n39-k5	9	2,7	3,7	4,7	3,0	6,5	4,8
A-n39-k6	10	2,8	4,0	5,0	2,6	6,9	4,4
A-n44-k7	11	3,1	4,1	5,1	3,0	6,6	4,8
A-n45-k6	12	3,1	4,1	5,3	2,9	6,9	5,3
A-n45-k7	13	2,9	4,3	5,2	2,8	7,5	5,0
A-n46-k7	14	3,3	4,3	5,9	3,0	7,6	5,9
A-n48-k7	15	2,9	4,5	5,9	2,9	8,1	5,6
A-n53-k7	16	3,3	5,1	5,8	3,2	8,3	5,1
A-n54-k7	17	3,3	5,1	6,0	3,0	7,7	5,5
A-n55-k9	18	3,3	5,3	6,4	3,3	8,8	5,5
A-n60-k9	19	3,6	5,5	7,1	3,3	9,1	6,1
A-n61-k9	20	3,6	5,5	6,9	3,4	9,4	6,1
A-n62-k8	21	3,6	5,9	7,0	3,3	8,9	4,2
A-n63-k9	22	3,7	5,7	7,1	3,8	8,9	8,1
A-n63-k10	23	3,7	6,1	6,7	3,5	10,6	5,6
A-n64-k9	24	3,6	6,4	6,6	3,4	9,6	6,0
A-n65-k9	25	3,3	6,2	6,9	3,6	9,5	7,2
A-n69-k9	26	4,2	6,4	7,9	3,6	10,1	6,9
A-n80-k10	27	4,1	7,5	8,1	4,0	11,2	6,7

Fonte: o Autor.

Figura 6.21 – Tempo de processamento



Fonte: o Autor.

A Tabela 6.19 apresenta a média e o desvio padrão da quantidade de veículos apresentadas nas PF (Pareto *Front*) da solução dos algoritmos. Nota-se que a dimensão é o tamanho da matriz, ou seja, a quantidade de endereços (ou clientes) a serem percorridos considerando o depósito. Embora não foi fixada a quantidade de veículos, a maior parte dos resultados utilizou a mesma quantidade de veículos da solução de referência.

A Tabela 6.20 e a Figura 6.22 apresentam a quantidade de soluções resultantes da PF de cada algoritmo. Nota-se que os algoritmos CWNSGA-II_v1, CWTSNSGA-II_v1 e CWTSNSGA-II_v2 foram os que tiveram o maior número de soluções nas PF. As médias da quantidade de soluções para NSGA-II, MOPSO, CWNSGA-II_v1, CWNSGA-II_v2, CWTSNSGA-II_v1, CWTSNSGA-II_v2 foram de 8,0; 4,6; 11,3; 10,1; 11,1 e 11,2 respectivamente. Por fim, o CWNSGA-II_v1 apresentou a maior média de soluções nas PF.

Tabela 6.19 – Número de veículos

Instância				NSGA-II		MOPSO		CWNSGA-II_v1		CWNSGA-II_v2		CWTSNSGA-II_v1		CWTSNSGA-II_v2	
Nome	Ref.	Dimensão	Veic.	Média	D.P.	Média	D.P.	Média	D.P.	Média	D.P.	Média	D.P.	Média	D.P.
A-n32-k5	1	32	5,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0
A-n33-k5	2	33	5,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0
A-n33-k6	3	33	6,0	6,0	0,0	6,0	0,0	6,0	0,0	6,0	0,0	6,0	0,0	6,0	0,0
A-n34-k5	4	34	5,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0
A-n36-k5	5	36	5,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0
A-n37-k5	6	37	5,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0
A-n37-k6	7	37	6,0	6,0	0,0	6,0	0,0	6,0	0,0	6,0	0,0	6,0	0,0	6,0	0,0
A-n38-k5	8	38	5,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0
A-n39-k5	9	39	5,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0	5,0	0,0
A-n39-k6	10	39	6,0	6,0	0,0	6,0	0,0	6,0	0,0	6,0	0,0	6,0	0,0	6,0	0,0
A-n44-k7	11	44	7,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0
A-n45-k6	12	45	6,0	6,0	0,0	6,0	0,0	6,0	0,0	6,0	0,0	6,0	0,0	6,0	0,0
A-n45-k7	13	45	7,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0
A-n46-k7	14	46	7,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0
A-n48-k7	15	48	7,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0
A-n53-k7	16	53	7,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0
A-n54-k7	17	54	7,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0	7,0	0,0
A-n55-k9	18	55	9,0	9,0	0,0	9,0	0,0	9,0	0,0	9,0	0,0	9,0	0,0	9,5	0,5
A-n60-k9	19	60	9,0	9,0	0,0	9,0	0,0	9,0	0,0	9,0	0,0	9,0	0,0	9,0	0,0
A-n61-k9	20	61	9,0	9,0	0,0	9,0	0,0	9,0	0,0	9,0	0,0	9,0	0,0	9,0	0,0
A-n62-k8	21	62	8,0	8,0	0,0	8,0	0,0	8,0	0,0	8,0	0,0	8,0	0,0	8,0	0,0
A-n63-k9	22	63	9,0	9,0	0,0	9,0	0,0	9,0	0,0	9,0	0,0	9,0	0,0	9,0	0,0
A-n63-k10	23	63	10,0	10,0	0,0	10,0	0,0	10,0	0,0	10,0	0,0	10,0	0,0	10,0	0,0
A-n64-k9	24	64	9,0	9,0	0,0	9,0	0,0	9,0	0,0	9,0	0,0	9,0	0,0	9,0	0,0
A-n65-k9	25	65	9,0	9,9	0,4	9,3	0,5	9,7	0,5	9,0	0,0	9,0	0,0	9,9	0,3
A-n69-k9	26	69	9,0	9,0	0,0	9,0	0,0	9,0	0,0	9,0	0,0	9,0	0,0	9,3	0,5
A-n80-k10	27	80	10,0	10,0	0,0	10,0	0,0	10,0	0,0	10,0	0,0	10,0	0,0	10,0	0,0

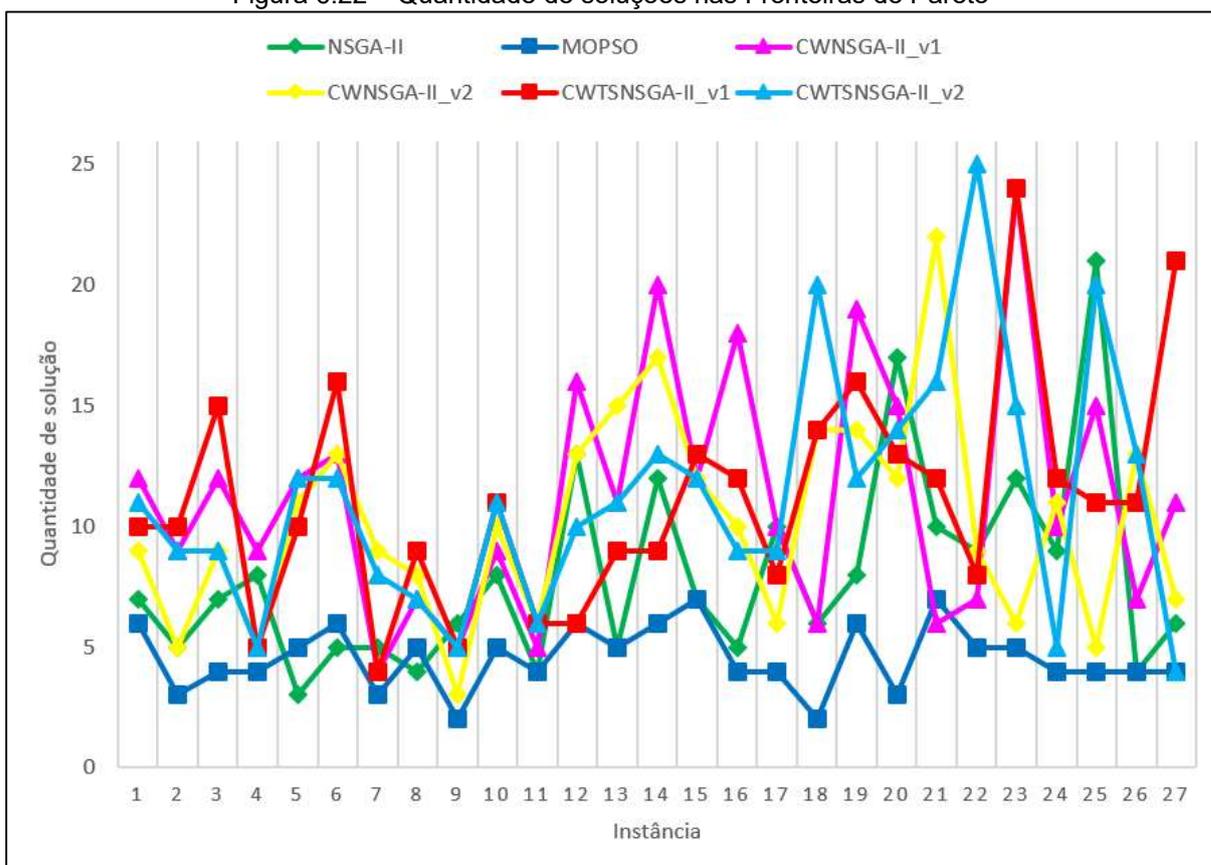
Fonte: o Autor.

Tabela 6.20 – Quantidade de soluções nas Fronteiras de Pareto

Instância	Referência	NSGA-II	MOPSO	CWNSGA-II_v1	CWNSGA-II_v2	CWTSNSGA-II_v1	CWTSNSGA-II_v2
A-n32-k5	1	7	6	12	9	10	11
A-n33-k5	2	5	3	9	5	10	9
A-n33-k6	3	7	4	12	9	15	9
A-n34-k5	4	8	4	9	5	5	5
A-n36-k5	5	3	5	12	11	10	12
A-n37-k5	6	5	6	13	13	16	12
A-n37-k6	7	5	3	4	9	4	8
A-n38-k5	8	4	5	7	8	9	7
A-n39-k5	9	6	2	5	3	5	5
A-n39-k6	10	8	5	9	10	11	11
A-n44-k7	11	4	4	5	6	6	6
A-n45-k6	12	13	6	16	13	6	10
A-n45-k7	13	5	5	11	15	9	11
A-n46-k7	14	12	6	20	17	9	13
A-n48-k7	15	7	7	12	12	13	12
A-n53-k7	16	5	4	18	10	12	9
A-n54-k7	17	10	4	10	6	8	9
A-n55-k9	18	6	2	6	14	14	20
A-n60-k9	19	8	6	19	14	16	12
A-n61-k9	20	17	3	15	12	13	14
A-n62-k8	21	10	7	6	22	12	16
A-n63-k9	22	9	5	7	9	8	25
A-n63-k10	23	12	5	24	6	24	15
A-n64-k9	24	9	4	10	11	12	5
A-n65-k9	25	21	4	15	5	11	20
A-n69-k9	26	4	4	7	13	11	13
A-n80-k10	27	6	4	11	7	21	4

Fonte: o Autor.

Figura 6.22 – Quantidade de soluções nas Fronteiras de Pareto



Fonte: o Autor.

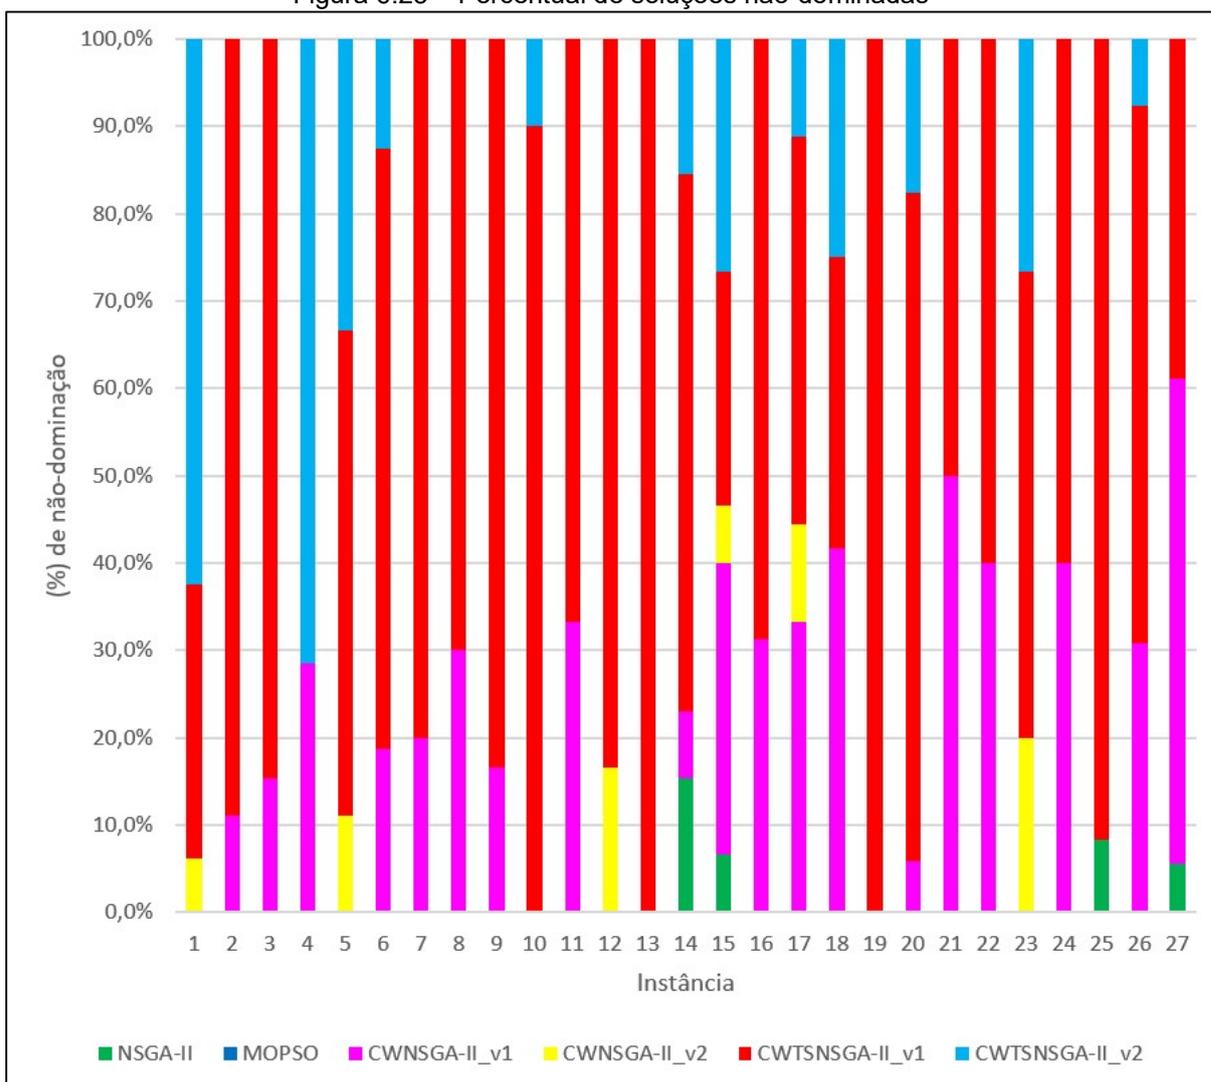
A Tabela 6.21 e a Figura 6.23 apresentam o percentual de dominância, ou de soluções não-dominadas, ao avaliar os algoritmos testados neste trabalho. Os algoritmos CWNSGA-II_v2 e CWTSNSGA-II_v1 foram predominantemente superiores na qualidade das soluções em relação aos demais algoritmos.

Tabela 6.21 – Percentual de dominância nas soluções

Instância	Referência	NSGA-II	MOPSO	CWNSGA-II_v1	CWNSGA-II_v2	CWTSNSGA-II_v1	CWTSNSGA-II_v2
A-n32-k5	1	0,0%	0,0%	0,0%	6,3%	31,3%	62,5%
A-n33-k5	2	0,0%	0,0%	11,1%	0,0%	88,9%	0,0%
A-n33-k6	3	0,0%	0,0%	15,4%	0,0%	84,6%	0,0%
A-n34-k5	4	0,0%	0,0%	28,6%	0,0%	0,0%	71,4%
A-n36-k5	5	0,0%	0,0%	0,0%	11,1%	55,6%	33,3%
A-n37-k5	6	0,0%	0,0%	18,8%	0,0%	68,8%	12,5%
A-n37-k6	7	0,0%	0,0%	20,0%	0,0%	80,0%	0,0%
A-n38-k5	8	0,0%	0,0%	30,0%	0,0%	70,0%	0,0%
A-n39-k5	9	0,0%	0,0%	16,7%	0,0%	83,3%	0,0%
A-n39-k6	10	0,0%	0,0%	0,0%	0,0%	90,0%	10,0%
A-n44-k7	11	0,0%	0,0%	33,3%	0,0%	66,7%	0,0%
A-n45-k6	12	0,0%	0,0%	0,0%	16,7%	83,3%	0,0%
A-n45-k7	13	0,0%	0,0%	0,0%	0,0%	100,0%	0,0%
A-n46-k7	14	15,4%	0,0%	7,7%	0,0%	61,5%	15,4%
A-n48-k7	15	6,7%	0,0%	33,3%	6,7%	26,7%	26,7%
A-n53-k7	16	0,0%	0,0%	31,3%	0,0%	68,8%	0,0%
A-n54-k7	17	0,0%	0,0%	33,3%	11,1%	44,4%	11,1%
A-n55-k9	18	0,0%	0,0%	41,7%	0,0%	33,3%	25,0%
A-n60-k9	19	0,0%	0,0%	0,0%	0,0%	100,0%	0,0%
A-n61-k9	20	0,0%	0,0%	5,9%	0,0%	76,5%	17,6%
A-n62-k8	21	0,0%	0,0%	50,0%	0,0%	50,0%	0,0%
A-n63-k9	22	0,0%	0,0%	40,0%	0,0%	60,0%	0,0%
A-n63-k10	23	0,0%	0,0%	0,0%	20,0%	53,3%	26,7%
A-n64-k9	24	0,0%	0,0%	40,0%	0,0%	60,0%	0,0%
A-n65-k9	25	8,3%	0,0%	0,0%	0,0%	91,7%	0,0%
A-n69-k9	26	0,0%	0,0%	30,8%	0,0%	61,5%	7,7%
A-n80-k10	27	5,6%	0,0%	55,6%	0,0%	38,9%	0,0%

Fonte: o Autor.

Figura 6.23 – Percentual de soluções não-dominadas



Fonte: o Autor.

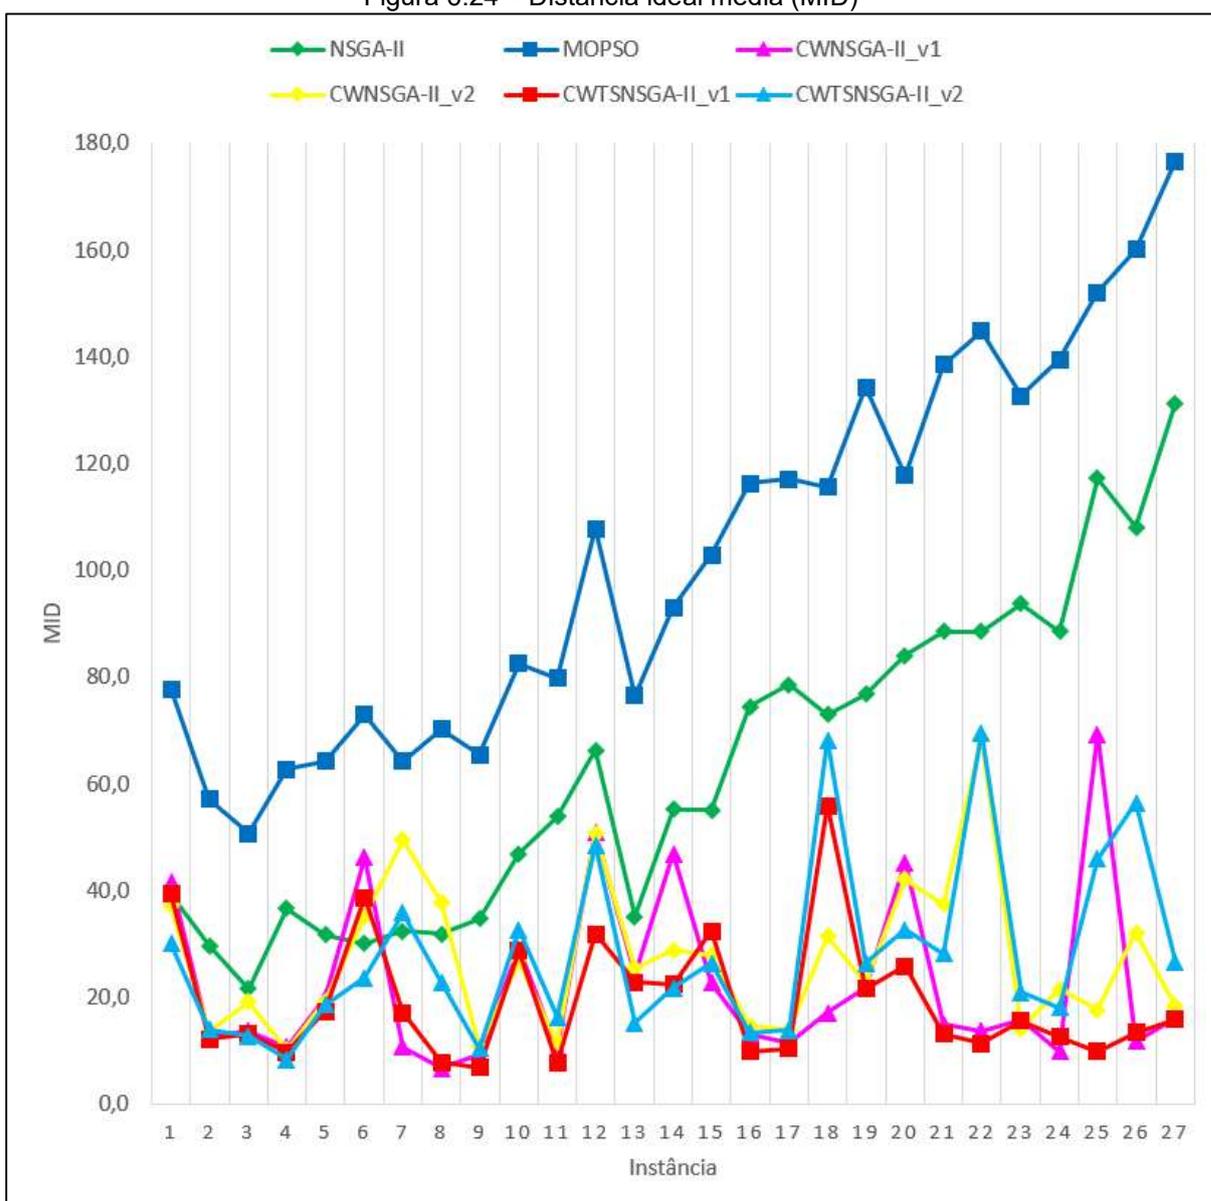
A Tabela 6.22 e a Figura 6.24 apresentam os valores encontrados para o MID. Aqui, quanto menor o valor para o MID, melhor. Observa-se a superioridade dos algoritmos CWNSGA-II_v1, CWNSGA-II_v2, CWTSNSGA-II_v1 e CWTSNSGA-II_v2 em relação aos algoritmos NSGA-II e MOPSO.

Tabela 6.22 – Distância ideal média (MID)

Instância	Referência	NSGA-II	MOPSO	CWNSGA-II_v1	CWNSGA-II_v2	CWTSNSGA-II_v1	CWTSNSGA-II_v2
A-n32-k5	1	39,3	77,8	41,7	37,2	39,3	30,1
A-n33-k5	2	29,6	57,1	12,8	13,5	12,2	14,0
A-n33-k6	3	21,6	50,6	13,5	19,1	13,1	12,7
A-n34-k5	4	36,6	62,7	10,7	10,0	9,7	8,4
A-n36-k5	5	31,7	64,2	20,0	19,2	17,3	18,5
A-n37-k5	6	30,1	72,9	46,2	35,2	38,7	23,6
A-n37-k6	7	32,4	64,1	10,6	49,3	17,1	35,8
A-n38-k5	8	32,0	70,2	6,7	37,8	7,8	22,8
A-n39-k5	9	34,6	65,4	9,2	10,6	6,8	10,3
A-n39-k6	10	47,0	82,5	29,1	26,8	28,7	32,6
A-n44-k7	11	53,8	79,6	10,2	11,5	7,5	16,2
A-n45-k6	12	66,3	107,7	51,0	50,7	31,9	48,5
A-n45-k7	13	35,2	76,4	24,3	25,3	22,8	15,2
A-n46-k7	14	55,2	93,1	46,9	29,0	22,4	21,7
A-n48-k7	15	55,0	102,8	22,6	27,9	32,4	26,5
A-n53-k7	16	74,4	116,2	13,0	14,7	9,9	13,3
A-n54-k7	17	78,5	117,1	11,3	13,9	10,4	13,8
A-n55-k9	18	72,9	115,4	17,2	31,3	55,8	68,2
A-n60-k9	19	76,8	134,2	21,8	22,7	21,6	26,5
A-n61-k9	20	84,0	117,7	45,2	42,1	26,0	32,7
A-n62-k8	21	88,5	138,5	14,9	37,4	13,1	28,1
A-n63-k9	22	88,5	144,7	13,5	68,4	11,3	69,5
A-n63-k10	23	93,7	132,6	15,7	14,2	15,5	20,9
A-n64-k9	24	88,4	139,4	9,9	21,4	12,6	18,1
A-n65-k9	25	117,2	152,1	69,3	17,7	9,9	45,8
A-n69-k9	26	108,1	160,1	11,8	32,1	13,4	56,5
A-n80-k10	27	131,4	176,6	16,0	18,3	15,8	26,6

Fonte: o Autor.

Figura 6.24 – Distância ideal média (MID)



Fonte: o Autor.

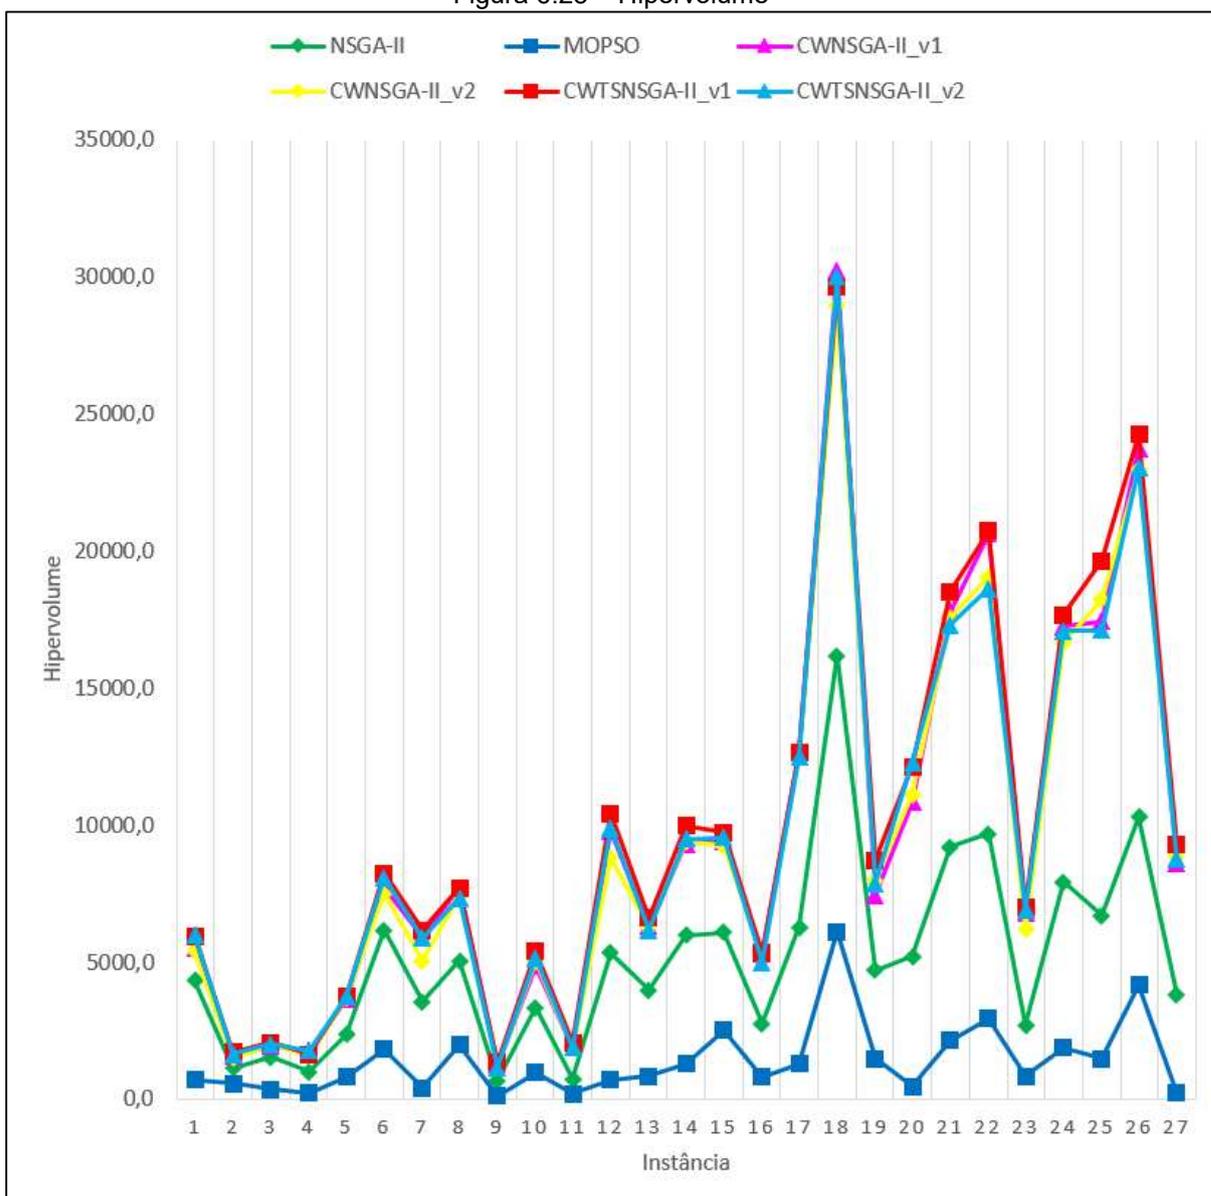
A Tabela 6.23 e a Figura 6.25 apresentam os valores encontrados para o hipervolume; quanto maior o valor do hipervolume, melhor será. Esses valores apenas confirmam os resultados apresentados pela análise do MID.

Tabela 6.23 – Hipervolume

Instância	Referência	NSGA-II	MOPSO	CWNSGA-II_v1	CWNSGA-II_v2	CWTSNSGA-II_v1	CWTSNSGA-II_v2
A-n32-k5	1	4.318,3	693,1	5.528,2	5.398,5	5.944,4	5.978,9
A-n33-k5	2	1.124,0	557,8	1.591,2	1.513,0	1.712,9	1.633,2
A-n33-k6	3	1.548,2	350,3	1.923,0	1.972,9	2.058,1	2.032,5
A-n34-k5	4	1.014,2	227,8	1.752,7	1.614,4	1.624,3	1.772,5
A-n36-k5	5	2.353,8	775,5	3.624,7	3.657,7	3.730,3	3.713,7
A-n37-k5	6	6.181,6	1.816,7	7.712,5	7.505,7	8.226,0	8.079,8
A-n37-k6	7	3.547,7	401,4	5.919,4	5.048,0	6.183,5	5.877,5
A-n38-k5	8	5.032,1	1.948,1	7.693,0	7.422,9	7.696,2	7.351,5
A-n39-k5	9	670,6	102,9	1.214,3	1.161,6	1.342,2	1.156,5
A-n39-k6	10	3.336,0	970,9	4.830,2	5.045,3	5.387,2	5.149,4
A-n44-k7	11	718,2	187,5	1.876,2	1.813,8	2.047,6	1.883,3
A-n45-k6	12	5.319,8	714,8	9.804,7	8.810,3	10.411,0	9.888,4
A-n45-k7	13	3.965,7	848,3	6.294,2	6.266,2	6.589,1	6.150,8
A-n46-k7	14	5.970,2	1.293,3	9.315,0	9.378,5	9.961,5	9.483,3
A-n48-k7	15	6.067,8	2.487,5	9.410,0	9.269,0	9.748,1	9.526,1
A-n53-k7	16	2.749,0	777,3	5.301,7	5.170,8	5.347,6	5.001,6
A-n54-k7	17	6.261,9	1.270,2	12.643,0	12.470,0	12.645,0	12.476,0
A-n55-k9	18	16.196,0	6.138,9	30.237,0	28.937,0	29.676,0	30.003,0
A-n60-k9	19	4.706,2	1.477,9	7.460,2	7.980,8	8.722,3	7.893,9
A-n61-k9	20	5.216,7	480,0	10.835,0	11.118,0	12.120,0	12.283,0
A-n62-k8	21	9.198,1	2.148,1	17.785,0	17.564,0	18.510,0	17.303,0
A-n63-k9	22	9.706,3	2.934,9	20.599,0	19.059,0	20.707,0	18.643,0
A-n63-k10	23	2.687,9	822,3	6.799,3	6.209,5	7.004,7	6.881,4
A-n64-k9	24	7.946,6	1.885,3	17.244,0	16.649,0	17.659,0	17.080,0
A-n65-k9	25	6.728,5	1.482,0	17.432,0	18.234,0	19.654,0	17.112,0
A-n69-k9	26	10.297,0	4.148,1	23.741,0	22.956,0	24.235,0	23.000,0
A-n80-k10	27	3.808,2	227,3	8.613,8	8.852,3	9.283,1	8.744,6

Fonte: o Autor.

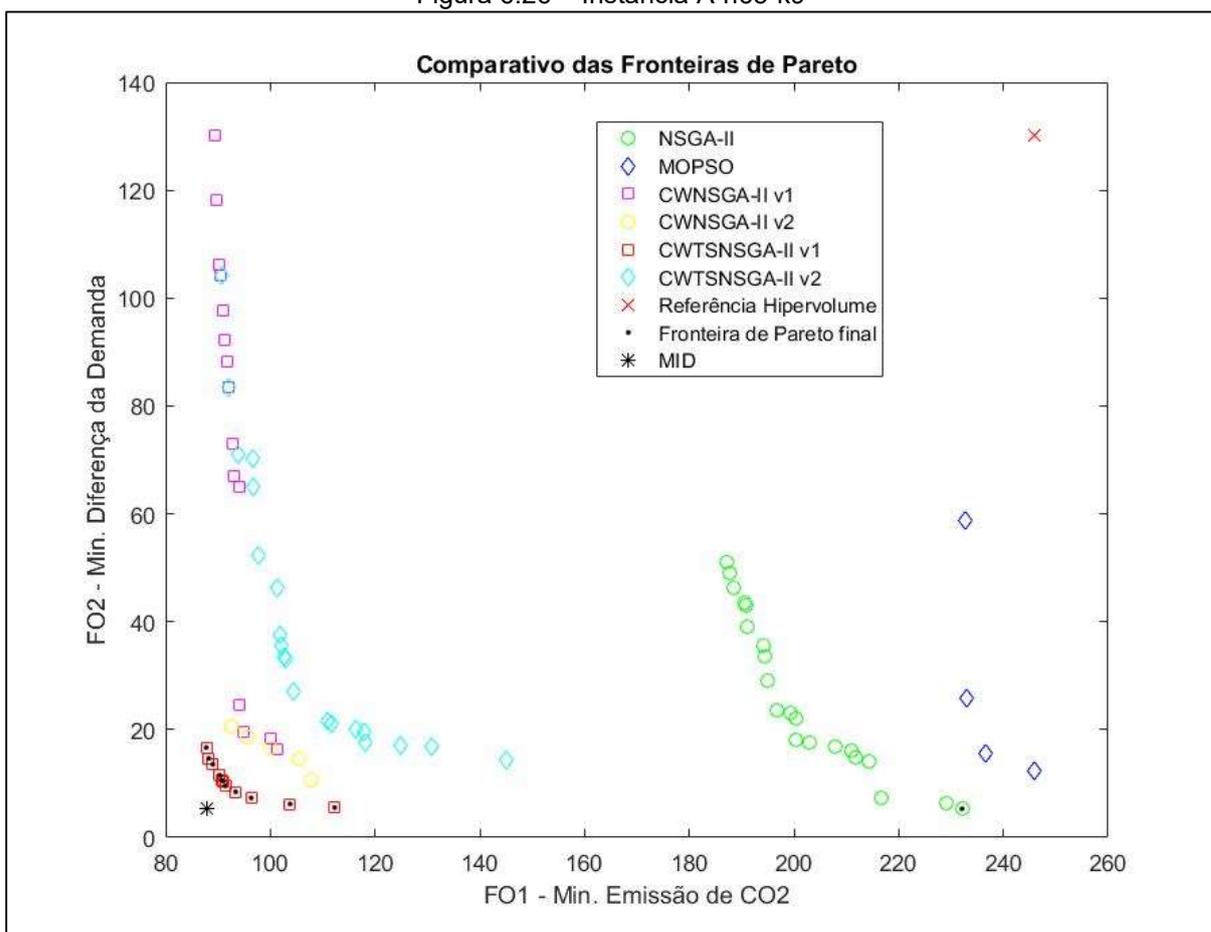
Figura 6.25 – Hipervolume



Fonte: o Autor.

A Figura 6.26 apresenta de forma sintetizada alguns dos resultados da instância A-n65-k9. Assim, pode-se observar as FP resultantes dos algoritmos NSGA-II, MOPSO, CWNSGA-II_v1, CWNSGA-II_v2, CWTSNSGA-II_v1 e CWTSNSGA-II_v2; a dominância do algoritmo CWTSNSGA-II_v1 quanto aos demais; a FP “final” composta por todas as soluções do CWTSNSGA-II_v1 e uma solução do NSGA-II, devidamente identificadas pelo ponto preto; a referência do hipervolume (representado pelo x vermelho) e do MID (representado pelo asterisco preto).

Figura 6.26 – Instância A-n65-k9



Fonte: o Autor.

Por fim, a Tabela 6.24 apresenta a média e o desvio padrão quanto aos algoritmos testados, com base nas métricas avaliativas para as instâncias da literatura. Podemos concluir que o algoritmo CWNSGA-II_v2 foi o melhor quanto ao tempo computacional. CWNSGA-II_v1 foi o melhor em relação à quantidade de soluções. CWTSNSGA-II_v1 foi o melhor quanto ao percentual de dominância, MID e hipervolume. De forma geral observa-se que as derivações do NSGA-II apresentaram resultados superiores quando ao próprio NSGA-II e MOPSO. Por fim, a aplicação do C&W no aprimoramento das pétadas do roteiro resultou em maior percentual de dominância para o CWNSGA-II_v1 e CWTSNSGA-II_v1, embora foi pior no tempo computacional.

Tabela 6.24 – Média e Desvio Padrão dos dados analisados

Algoritmo	Tempo de processamento		Quantidade de solução		Percentual de dominância		MID		Hipervolume	
	Média	D.P.	Média	D.P.	Média	D.P.	Média	D.P.	Média	D.P.
NSGA-II	3,2	0,5	8,0	4,2	0,0	0,0	63,1	30,2	5.061,9	3.481,9
MOPSO	4,8	1,2	4,6	1,3	0,0	0,0	102,7	35,8	1.376,6	1.344,1
CWNSGA-II_v1	5,8	1,2	11,3	5,0	0,2	0,2	22,8	16,3	9.525,2	7.331,7
CWNSGA-II_v2	3,1	0,4	10,1	4,3	0,0	0,1	27,3	14,2	9.299,2	7.088,6
CWTSNSGA-II_v1	7,9	1,5	11,1	4,6	0,6	0,2	19,4	11,9	9.934,3	7.402,9
CWTSNSGA-II_v2	5,4	1,0	11,2	5,0	0,1	0,2	28,0	16,6	9.485,1	7.098,9

Fonte: o Autor.

7 CONCLUSÃO

Este trabalho apresenta uma nova abordagem para o MOOGVRP possível de ser adotada em problemas de distribuição logística de uma forma geral. A utilização da referida metodologia é aqui ilustrada por meio de dois estudos de caso, onde o primeiro aborda uma aplicação relativamente simples de entregas de jornais e revistas junto a uma gráfica. Já o segundo estudo de caso trata do transporte fretado de funcionários. Como contribuição desta tese, tem-se a visão geral estruturada, análise de trabalhos recentes sobre o tema, diferentes abordagens de solução dada a este estudo e um planejamento minucioso voltado a facilitar a execução factível dos estudos de caso.

Os objetivos propostos foram atendidos, onde, mais especificamente trata-se da proposta inovadora MOOGVRP, a apresentação das principais técnicas relacionadas a temática, a documentação das principais abordagens ambientais de roteamento de veículos (GVRP, PRP, VRPRL), os procedimentos de solução meta-heurístico, a geração e análise de cenários.

Ainda como contribuição e objetivo proposto desta pesquisa, tem-se os algoritmos híbridos envolvendo NSGA-II com C&W, e também, NSGA-II com C&W e TS, ou seja, CWNSGA-II e CWTSNSGA-II, respectivamente. No algoritmo CWNSGA-II, a solução inicial foi realizada através da aplicação do C&W como um PCV, realizando *swaps* até gerar número de indivíduos da população inicial e, na sequência, adequado o PCV para o VRP. Em problemas que envolvem apenas a distância foi aplicada o C&W como refinamento das soluções geradas após o *crossover*, mais especificamente, em cada “pétala” das soluções do VRP.

A principal contribuição é o algoritmo CWTSNSGA-II. O diferencial está no *loop*, pois realiza os mesmos procedimentos do NSGA-II e, também, certo número de movimentos do TS, calcula o *Fitness*, exclui a duplicidade das soluções, atualiza a PF, DC e gera a nova população. Além disso, há o aperfeiçoamento das “pétalas” do VRP por meio do C&W, quando se utiliza apenas a distância. Os movimentos do TS são *Swaps* na PF e na solução com maior valor de CD, para ampliar a quantidade de soluções próximas da PF e para diversificar soluções isoladas. Desta forma o algoritmo melhora consideravelmente a sua população a cada iteração.

Em relação a literatura foi analisado e estratificado um total de 76 artigos resultantes da amostra de pesquisa. Os trabalhos mais relevantes foram publicados

por Dekker et al. (2012) e Demir et al. (2014a) que abordaram aspectos relacionados à logística e, Lin et al. (2014), que procuraram demonstrar a evolução e a relação do GVRP. Os outros artigos citados com mais frequência procuraram aprimorar técnicas e aplicá-las a contextos reais. Quanto as tendências do MOOGVRP, as estratificações da seção 3.2.2 (dados bibliométricos) e 3.3 (trabalhos correlatos) são de grande importância. Nesse contexto, o Quadro 3.1 resumiu a proposta dos 76 artigos focados em revisões, aplicação geral e estudos de caso. Os autores da amostra estão associados a 96 instituições, centros de pesquisa e empresas, e as maiores contribuições, até agora, vieram do Irã, China, EUA e Reino Unido. A Figura 3.7 mostrou-se muito interessante, pois mostra a quantidade de trabalhos desenvolvidos considerando VRPFuel, PRP e VRPRL, bem como suas interações na amostra analisada.

Para a coleta dos dados foi considerada a assimetria das distâncias de percorrida e conseqüentemente dos tempos de trajeto, ao invés das usuais distâncias Euclidianas (simétricas). Foram realizados testes comparativos entre algoritmos por meio do hipervolume (quanto maior, melhor), para depois utilizar a função utilidade na escolha da melhor solução, amparada através dos pesos atribuídos pelo Decisor.

Quanto ao estudo de caso 1, distribuição de jornais, na definição dos pontos macros foi considerada a “direção da rua”, ao invés do ponto médio usualmente adotada por pesquisadores. Por esta e as demais óticas abordadas, o entregador tem condições de realizar sua atividade visando a menor quantidade de adequações no momento da entrega. O algoritmo CWNSGA-II demonstrou superioridade quanto aos demais. A otimização alcançada foi de 19,9% para a FO₁ (minimização da emissão de CO₂), com conseqüente e mesmo percentual de minimização da distância total e 87,5% para a FO₂, (minimização da diferença da demanda).

O estudo de caso 2, transporte de funcionários, restringiu seus roteiros quanto a limitação de tempo, sendo este um dos principais problemas enfrentados. Vale ressaltar que a garagem foi considerada como a origem e a fábrica (empresa), como destino. Utilizando os mesmos parâmetros da solução corrente, obteve-se a otimização de 5,2% para a FO₁ e 11,4% quanto a FO₂. Aqui o algoritmo proposto CWNSGA-II também demonstrou superioridade quanto aos demais. Foi testado um cenário considerando a limitação de tempo em 90 min por veículo e, para a

adequada implementação prática seria necessário acrescentar mais 4 veículos a frota atual.

Neste contexto, a otimização multi-objetivo auxiliou no conflito existente entre a minimização da emissão de CO₂ e minimização da diferença da demanda. Assim, quanto a FO₁ foi possível estratificar a distância percorrida, o consumo de combustível e o tempo de percurso. A emissão de GHG concretiza as considerações ambientais que transformam este problema em um MOOGVRP. A FO₂, diferença da demanda, contribui para a homogeneização da capacidade utilizada pelo veículo. As considerações ambientais, de alto valor atualmente, são aqui tratadas como mecanismo para a consciente tomada de decisão. Dentre as FOs utilizadas, a FO₁ teve maior peso por ser a referência para tais estratificações. Vale ressaltar que caso o DM optasse por outros pesos, a solução poderia ser diferente. A FU utilizada foi neutra, caso o DM quisesse utilizar a FU com atitude perante o risco, teria que fazer uma reclassificação da FU.

Quanto às instâncias da literatura, foi necessário realizar a divisão dos algoritmos CWNSGA-II e CWTSNSGA-II em versão 1 e 2, por causa das adequações voltadas às particularidades dos estudos de caso. A versão 1, aplicada no estudo de caso 1, utiliza o algoritmo de C&W para aprimorar as “pétalas” do roteiro. A versão 2, aplicada no estudo de caso 2, não se aplica o algoritmo de C&W nas “pétalas”, tornando-se assim uma simplificação da versão 1. De forma complementar, o estudo de caso 2 avalia o tempo de percurso e, neste caso, ocorre de o C&W melhorar o roteiro e piorar o tempo de percurso. Desta forma, nas instâncias da literatura foram aplicados os algoritmos NSGA-II, MOPSO, CWNSGA-II_v1, CWNSGA-II_v2, CWTSNSGA-II_v1 e CWTSNSGA-II_v2.

Portanto, ao considerar as instâncias da literatura o algoritmo CWNSGA-II_v2 obteve o melhor no tempo computacional. O algoritmo CWNSGA-II_v1 obteve o melhor na quantidade de soluções das PF. O algoritmo CWTSNSGA-II_v1 obteve o melhor no percentual de dominância, MID e hipervolume. De forma geral observa-se que as derivações do NSGA-II (CWNSGA-II_v1, CWNSGA-II_v2, CWTSNSGA-II_v1 e CWTSNSGA-II_v2) apresentaram resultados superiores em relação ao próprio NSGA-II e o MOPSO. Por fim, a aplicação do C&W no aprimoramento das pétalas do roteiro resultou em maior percentual de dominância para o CWNSGA-II_v1 e CWTSNSGA-II_v1, embora precisaram de maior tempo computacional que os algoritmos CWNSGA-II_v2 e CWTSNSGA-II_v2.

Ainda são muitas as oportunidades visando explorar aplicações e técnicas aos trabalhos relacionados ao MOOGVRP. Neste contexto, pretende-se ainda:

- a) Desenvolver outros algoritmos meta-heurísticos multi-objetivos, além de versões híbridas, sempre visando o aprimoramento dos resultados e do avanço científico por meio do avanço das técnicas;
- b) Explorar configurações de motorização (incluindo ajustes) dos veículos, visto que as abordagens ambientais aqui tratadas estão limitadas a quilometragem de percorrida e não se aprofundam quanto às questões técnicas do veículo;
- c) Avaliar a sensibilidade dos pesos aplicados na FU para a definição da solução;
- d) Avaliar o *trade-off* das PF a fim de ampliar a discussão das soluções obtidas através das técnicas utilizadas;
- e) Realizar uma análise minuciosa (inclusive estatística) das técnicas meta-heurísticas e híbridas implementadas e, da sensibilidade dos parâmetros utilizados;
- f) Normalização dos valores atribuídos ao hipervolume, visto as significativas discrepâncias apresentadas nos estudos de caso;
- g) Utilizar a versão expandida da base de dados estudo de caso 1, distribuição de jornais, que contempla cerca de 8,5 mil pontos de entrega (assinantes do jornal);
- h) No estudo de caso 2, transporte de funcionários, avaliar o “balanceamento / homogeneização do tempo” como função objetivo, de forma alternativa a demanda média utilizada. Assim, todos os motoristas sairão no mesmo horário para realizar a coleta ou entrega de funcionários (passageiros);
- i) Abordar com profundidade os conceitos de Análise de Decisão e *Multi-Objective Optimisation Design*;
- j) Explorar aspectos sociais do tripé da sustentabilidade, os três pilares simultaneamente e os problemas VRPRL, que se constatou serem em número bastante reduzido.

No anexo B estão todos os trabalhos (periódicos e eventos) publicados no decorrer do curso de Doutorado.

REFERÊNCIAS

- ABAD, H.K.E.A.; VAHDANI, B.; SHARIFI, M.; ETEBARI, F. A bi-objective model for pickup and delivery pollution-routing problem with integration and consolidation shipments in cross-docking system. **J. Clean. Prod.**, vol. 193, p. 784–801, 2018.
- AL-E-HASHEM, S.M.J.; REKIK, Y.; HOSEINHAJLOU, E.M. A hybrid L-shaped method to solve a bi-objective stochastic transshipment-enabled inventory routing problem. **Int. J. Prod. Econ.**, p.1-18, 2017.
- ALEXIOU, D.; KATSAVOUNIS, S. A multi-objective transportation routing problem. **Operational Research**, vol.15, p.199–211, 2015.
- ALMEIDA, A.T. **Processo de decisão nas organizações: construindo modelos de decisão multicritério**. São Paulo: Atlas, 2013.
- ALVES, R. **Modelo matemático para seleção de rotas de patrulhamento escolar: o caso da patrulha escolar de ponta grossa**. 72 f. Dissertação (Mestrado em Engenharia de Produção), Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2015.
- AMER, H.; SALMAN, N.; HAWES, M.; CHAQFEH, M.; MIHAYLOVA, L.; MAYFIELD, M. An improved simulated annealing technique for enhanced mobility in smart cities. **Sensors** (Switzerland), vol. 16, p. 1-23, 2016.
- ANDROUTSOPOULOS, K.N.; ZOGRAFOS, K.C. An integrated modelling approach for the bicriterion vehicle routing and scheduling problem with environmental considerations. **Transportation Research Part C: Emerging Technologies**, vol. 82, p. 180–209, 2017.
- ASADI, E.; HABIBI, F.; NICKEL, S.; SAHEBI, H. A bi-objective stochastic location-inventory-routing model for microalgae-based biofuel supply chain. **Appl. Energy**, vol. 228, p. 2235–2261, 2018.
- ASSIS, L.P. **Investigação de metaheurísticas aplicadas ao problema de roteamento de veículos multiobjetivo com coleta opcional**. 202 f. Tese (Escola de Engenharia, Programa de Pós-Graduação em Engenharia Elétrica), Universidade Federal de Minas Gerais, Belo Horizonte, 2013.
- BALLOU, R. H. **Gerenciamento da Cadeia de Suprimentos: planejamento, organização e logística empresarial**. Bookman, 4ª. Edição, 2001.
- BAUZA, R.; GOZALVEZ, J.; SANCHEZ-SORIANO, J. Road traffic congestion detection through cooperative vehicle-to-vehicle communications. In: **Local Computer Networks (LCN)**, 2010 *IEEE* 35th Conference on, p 606–612, Oct 2010.

BAYKASOĞLU, A.; SUBULAN, K. A multi-objective sustainable load planning model for intermodal transportation networks with a real-life application. **Transp. Res. Part E Logist. Transp. Rev.**, vol. 95, p. 207–247, 2016.

BELFIORE, P.; FÁVERO, L. P. **Pesquisa Operacional: para cursos de Engenharia**. Rio de Janeiro: Elsevier, 2013.

BEZERRA, S. N. 135 f. **Algoritmos evolutivos paralelos aplicados ao problema das p-Medianas**. Dissertação (Mestrado em Modelagem Matemática e Computacional), Centro Federal de Educação Tecnológica de Minas Gerais, 2008.

BODIN, L.D.; GOLDEN, B. Classification in vehicle routing and scheduling. **Networks**, vol. 11, n. 2, p. 97-108, 1981.

BRAEKERS, K.; RAMAEKERS, K.; NIEUWENHUYSE, I.V. The vehicle routing problem: State of the art classification and review. **Computers & Industrial Engineering**, vol. 99, p. 300-313, 2016.

CARVALHO, C.H.R. 1606: Texto para discussão. Emissões relativas de poluentes do transporte motorizado de passageiros nos grandes centros urbanos brasileiros. **Instituto de Pesquisa Econômica Aplicada (IPEA)**, Brasília, abril de 2011.

CHAVES, A. A.; BIAJOLI, F. L.; MINE, O. M.; SOUZA, M. J. F. Meta-heurísticas híbridas para resolução do problema do caixeiro viajante com coleta de prêmios. **Produção**, vol. 17, p. 263-272, 2017.

CHEN, C.; QIU, R.; HU, X. The Location-Routing Problem with Full Truckloads in Low-Carbon Supply Chain Network Designing. **Math. Probl. Eng.** 2018.

CHEN, G.; GOVINDAN, K.; GOLIAS, M.M. Reducing truck emissions at container terminals in a low carbon economy: Proposal of a queueing-based bi-objective model for optimizing truck arrival pattern. **Transp. Res. Part E Logist. Transp. Rev.** vol. 55, p. 3–22, 2013.

CLARKE, G.; WRIGHT, J. W. Scheduling of vehicles from a central depot to a number of delivery points. **Operations Research**, vol. 12, n. 4, 568–582, 1964.

COELHO, B.N.; COELHO, V.N.; COELHO I.M.; OCHI, L.S.; HAGHNAZAR K, R.; ZUIDEMA, D.; LIMA, M.S.F.; COSTA, A.R. A multi-objective green UAV routing problem. **Computers and Operations Research**, vol. 88, p. 306-315, 2017.

COELLO, C. A. C.; LAMONT, G. B.; VELDHUIZEN, D. A. V. **Evolutionary algorithms for solving multi-objective problems**. New York: Springer, 2007.

COELLO, C.A. 2000. MOPSO: a proposal for multiple objective particle swarm optimization. In: **Proceedings of the 2002 Congress on Evolutionary Computation**, vol. 2, CEC 2002, p. 1051-1056, 2000.

CORNE DW, KNOWLES JD, OATES MJ. The Pareto envelope-based selection algorithm for multiobjective optimization. In: **Proceedings of sixth international conference on parallel problem solving from Nature**, p. 839-848, September, 2000. Paris, France: Springer; 2000.

COSTA, L.; LUST, T.; KRAMER, R.; SUBRAMANIAN, A. A two-phase Pareto local search heuristic for the bi-objective pollution-routing problem. **Networks**, vol. 2018, p.1-26, 2018.

COSTA, M. A. F.; COSTA, M. F. B. **Projeto de pesquisa: entenda e faça**. 2. ed. Petrópolis, RJ: Ed. Vozes, 2011.

DANTZIG, G.B.; RAMSER, J.H. The truck dispatching problem. **Management Science**, vol. 6, p. 80-91, 1959.

DAS, C.; JHARKHARIA, A. Low carbon supply chain: a state-of-the-art literature review. **Journal of Manufacturing Technology Management**, vol. 29, n. 2, pp. 398-428, 2018.

DASGUPTA, P.; CHAKRABARTI, P.P.; DESARKAR, S.C. **Multiobjective Heuristic Search: An introduction to intelligent Search Methods for Multicriteria Optimization**. Vieweg: Computational Intelligence, 1999.

DEB K, AGRAWAL S, PRATAP A, MEYARIVAN T. A fast elitist nondominated sorting genetic algorithm for multi-objective optimization: NSGA-II. In: **Proceedings of sixth international conference on parallel problem solving from nature**, p. 849-858, September, 2000. Paris, France: Springer; 2000.

DEB, K. PRATAP. A.; AGUARWAL, S. MEYARIVAN, T. A fast and elitist multiobjective genetic algorithm: NSGA-II. **IEEE transactions on evolutionary computation**, IEEE, vol. 6, n. 2, p. 182–197, 2002.

DEB, K. **Multi-objective optimization using evolutionary algorithms**. [S.I.]: John Wiley & Sons, Inc, 2001.

DEKKER, A.L.; BLOEMHOF, J.; MALLIDIS, I. Operations Research for green logistics - An overview of aspects, issues, contributions and challenges. **European Journal of Operational Research**, vol. 219, p. 671-679, 2012.

DEMIR, E.; BEKTAS, T.; LAPORTE, G. A review of recent research on green road freight transportation. **European Journal of Operational Research**, vol. 237, p. 775–793, 2014a.

DEMIR, E.; BEKTAS, T.; LAPORTE, G. The bi-objective Pollution-Routing Problem. **European Journal of Operational Research**, vol. 232, p. 464–478, 2014b.

DETRO, S. P. **Otimização na localização e na capacidade de armazenamento de soja e milho para o estado do Paraná**. 112 f. Dissertação (Mestrado em Engenharia de Produção e Sistemas). Pontifícia Universidade Católica do Paraná, 2013.

EBRAHIMI, S.B. A stochastic multi-objective location-allocation-routing problem for tire supply chain considering sustainability aspects and quantity discounts. **J. Clean. Prod.**, vol. 198, p. 704–720, 2018.

EDGEWORTH, F. Y. **Mathematical Psychics: An Essay on the Application of Mathematics to the Moral Sciences**. Lausanne, Switzerland: C. K. Paul, 1881.

EHRGOTT, M.; WANG, J.Y.T.; RAITH, A.; VAN HOUTTE, C. A bi-objective cyclist route choice model. **Transp. Res. Part A Policy Pract.**, vol. 46, p. 652–663, 2012.

EKSIUGLU, B.; VURAL, A.V.; REISMAN, A. The vehicle routing problem: a taxonomic review. **Computers & Industrial Engineering**, vol. 57, n. 4, p. 1472-1486, 2009.

ENGELAND, J.V.; BELIEM, J.; BOECK, L.D.; JAEGER, S.D. Literature Review: Strategic Network Optimization Models in Waste Reverse Supply Chains. **Omega**, vol. 91, 2018.

ENTEZAMINIA, A.; HEYDARI, M.; RAHMANI, D. A multi-objective model for multi-product multi-site aggregate production planning in a green supply chain: Considering collection and recycling centers. **J. Manuf. Syst.**, vol. 40, p. 63–75, 2016.

FARROKHI-ASL, H.; MAKUI, A.; JABBARZADEH, A.; BARZINPOUR, F. Solving a multi-objective sustainable waste collection problem considering a new collection network. **Operational Research**, p. 1-39, 2018.

FATHOLLAHI-FARD, A.M.; HAJIAGHAEI-KESHTELI, M.H.-K.; TAVAKKOLI-MOGHADDAM, R. A Bi-objective green home health care routing problem. **J. Clean. Prod.**, vol. 200, p. 423–443, 2018.

FISHER, M.L.; JAIKUMAS, R. A generalized assignment heuristic for vehicle routing. **Networks**, vol. 11, n. 2, p.109-124, 1981.

FONSECA, C.M.; FLEMING P.J. Multiobjective genetic algorithms. In: **IEE colloquium on 'Genetic Algorithms for Control Systems Engineering'** (Digest No. 1993/130), 28 May 1993. London, UK: IEE; 1993.

FREITAS, A.R.R.; FLEMING, P.J.; GUIMARAES, F.G. A Non-parametric Harmony-Based Objective Reduction Method for Many-Objective Optimization. **2013 IEEE International Conference on Systems, Man, and Cybernetics**. pp. 651-656, 2013. doi:10.1109/smc.2013.116

- FU, P.; LI, H.; WANG, X.; LUO, J.; ZHAN, S.L.; ZUO, C. Multiobjective Location Model Design Based on Government Subsidy in the Recycling of CDW. **Math. Probl. Eng.** 2017.
- GHEZAVATI, V.R.; BEIGI, M. Solving a bi-objective mathematical model for location-routing problem with time windows in multi-echelon reverse logistics using metaheuristic procedure. **Journal of Industrial Engineering International.**, vol. 12, p. 469–483, 2016.
- GLOVER, F. Future paths for integer programming and links to artificial intelligence. **Computers and Operational Research**, vol. 13, n. 5, p. 533-549, 1986.
- GOLDBARG, M. C.; LUNA, H. P. **Otimização combinatória e programação linear**. 2 ed. Rio de Janeiro: Elsevier, 2005.
- GONÇALVES, S. M.; STEINER, M. T. A.; SOUZA, L. V. Metodologia para o PRV: um Estudo de Caso para a Distribuição de Água Mineral. In: LOPES, H. S.; RODRIGUES, L. C. A.; STEINER, M. T. A. (eds.) **Meta-Heurísticas em Pesquisa Operacional**. Ed. Omnipax, Curitiba, PR, 2013.
- GONG, X.; DENG, Q.; GONG, X.; ZHANG, L.; WANG, H.; XIE, H. A Bee Evolutionary Algorithm for multiobjective Vehicle Routing Problem with Simultaneous Pickup and Delivery. **Math. Probl. Eng.**, p.1–21, 2018.
- GOVINDAN, K.; DARBARI, D.J.; AGARWAL, V.; JHA, P.C. Fuzzy multi-objective approach for optimal selection of suppliers and transportation decisions in an eco-efficient closed loop supply chain network. **Journal of Cleaner Production**, vol. 165, p.1598-1619, 2017.
- GOVINDAN, K.; JAFARIAN, A.; KHODAVERDI, R.; DEVIKA, K. Two-echelon multiple-vehicle location-routing problem with time windows for optimization of sustainable supply chain network of perishable food. **Int. J. Prod. Econ.**, n.152, p. 9–28, 2014.
- GOVINDAN, K.; PAAM, P.; ABTAHI, A.R. A fuzzy multi-objective optimization model for sustainable reverse logistics network design. **Ecol. Indic.**, n. 67, p. 753–768, 2016.
- GUO, Y.; CHENG, J.; LUO, S.; GONG, D. Robust Dynamic multi-objective vehicle routing optimization method. **IEEE/ACM Trans. Comput. Biol. Bioinforma.**, vol. 5963, 1–1, 2017.
- GUO, Z.; ZHANG, D.; LIU, H.; HE, Z.; SHI, L. Green transportation scheduling with pickup time and transport mode selections using a novel multi-objective memetic optimization approach. **Transp. Res. Part D Transp. Environ.**, vol. 60, p. 137–152, 2018.
- GUPTA, A.; HENG, C.K.; ONG, Y.S.; TAN, P.S.; ZHANG, A.N. A generic framework for multi-criteria decision support in eco-friendly urban logistics systems. **Expert Systems with Applications**, vol. 71, p. 288-300, 2017.

HAIMES, Y.; LASDON, L.; WISMER, D. On a bicriterion formulation of the problems of integrated system identification and system optimization. **IEEE Transaction on Systems, Man, and Cybernetics**, vol. 1, n. 3, p.296-a97, 1971.

HAJELA P, LIN C-Y. Genetic search strategies in multicriterion optimal design. **Struct Optimization**, n. 4, vol. 2, p. 99–107, 1992.

HAMMAD, A.W.A.; AKBARNEZHAD, A.; REY, D. Sustainable urban facility location: Minimising noise pollution and network congestion. **Transp. Res. Part E Logist. Transp. Rev.**, vol. 107, p. 38–59, 2017.

HASSANZADEH, A.; RASTI-BARZOKI, M. Minimizing total resource consumption and total tardiness penalty in a resource allocation supply chain scheduling and vehicle routing problem. **Applied Soft Computing**, vol. 58, p. 307–323, 2017.

HEILIG, L.; LALLA-RUIZ, E.; VOß, S. Multi-objective inter-terminal truck routing. **Transportation Research Part E: Logistics and Transportation Review**, vol. 106, p. 178–202, 2017.

HOLLAND, J.H. **Adaptation in natural and artificial systems**. Ann Arbor: University of Michigan Press, 1975.

HORN J, NAFPLIOTIS N, GOLDBERG DE. A niched Pareto genetic algorithm for multiobjective optimization. In: **Proceedings of the first IEEE conference on evolutionary computation**. IEEE world congress on computational intelligence, p. 27–29, June, 1994. Orlando, FL, USA: IEEE; 1994.

HWANG, C.L.; MASUD, A.S.M. **Multiple Objective Decision Making-Methods and Applications: A State-of-the-Art Survey**. Lecture Notes in Economics and Mathematical Systems, 1979.

IBAMA. Programa de controle de emissões veiculares (Proconve). Disponível em: < <http://www.ibama.gov.br/emissoes/veiculos-automotores/programa-de-controle-de-emissoes-veiculares-proconve> >. Acessado em: 4 de abr. 2019.

KENNEDY, J.; EBERHART, R.C.; SHI, Y. **Swarm Intelligence**, vol. 1. Kaufmann, San Francisco, p. 700-720, 2001.

KHOO, H.L.; TEOH, L.E. A bi-objective dynamic programming approach for airline green fleet planning. **Transp. Res. Part D Transp. Environ.**, vol. 33, p. 166–185, 2014.

KNOWLES J, CORNE D. The Pareto archived evolution strategy: a new baseline algorithm for Pareto multiobjective optimisation. In: **Proceedings of the 1999 congress on evolutionary computation-CEC99**, p. 6–9 July 1999. Washington, DC, USA: IEEE; 1999.

KONAK, A.; COIT, D.W.; SMITH, A.E. Multi-objective optimization using genetic algorithms: A tutorial. **Reliability Engineering & System Safety**, vol. 91, n. 9, p. 992–1007, 2006.

KUMAR, R.S.; KONDAPANENI, K.; DIXIT, V.; GOSWAMI, A.; THAKUR, L.S.; TIWARI, M.K. Multi-objective modeling of production and pollution routing problem with time window: A self-learning particle swarm optimization approach. **Computers and Industrial Engineering**, vol. 99, p. 29–40, 2016.

LINGO. **LINGO: The Modeling Language and Optimizer**. Lindo Systems Inc. 2017.

LIMA, R.H.R. **Um estudo sobre configuração automática do algoritmo de otimização por enxame de partículas multiobjetivo**. ix, 55 f. Dissertação (Programa de Pós-Graduação em Informática), Universidade Federal do Paraná, Setor de Ciências Exatas, 2017.

LIN, C.; CHOY, K.L.; HO, G.T.S.; CHUNG, S.H.; LAM, H.Y. Survey of Green Vehicle Routing Problem: Past and future trends. **Expert Systems with Applications**, vol. 41, p. 1118–1138, 2014.

LIU, H.; WANG, W.; ZHANG, Q. Multi-objective location-routing problem of reverse logistics based on GRA with entropy weight. **Grey Syst. Theory Appl.**, n. 2, p. 249–258, 2012.

LIU, X.-H.; SHAN, M.-Y.; ZHANG, R.-L.; ZHANG, L.-H. Green Vehicle Routing Optimization Based on Carbon Emission and Multiobjective Hybrid Quantum Immune Algorithm. **Math. Probl. Eng.**, p.1–9, 2018.

LONG, J.; SZETO, W.Y.; HUANG, H. A bi-objective turning restriction design problem in urban road networks. **European Journal of Operational Research**, vol. 237, p. 426–439, 2014.

LU H, YEN GG. Rank-density-based multiobjective genetic algorithm and benchmark test function study. **IEEE Trans. Evol. Comput.**, vol. 7, n. 4, p. 325–43, 2003.

MACIEL, R.S. **Otimização multiobjetivo na análise da Integração de Geração Distribuída às Redes de Distribuição**. 146 f. Tese (Doutorado em Engenharia Elétrica), Universidade Estadual Paulista Júlio de Mesquita Filho, 2012.

MALLADI, K.T.; SOWLATI, T. Sustainability aspects in Inventory Routing Problem: A review of new trends in the literature. **J. Clean. Prod.**, vol.197, p. 804–814, 2018.

MATOS, B.A.S.L. **Mapeamento ótimo de doenças através da minimização simultânea do viés e da variância**. 75f. Dissertação (Instituto de Ciências Exatas, Departamento de Estatística), Universidade de Brasília, Brasília, 2012.

MEZA, G.R. **Controller tuning by means of evolutionary multiobjective optimization: a holistic multiobjective optimization design procedure**. Editorial Universitat Politècnica de València, 2014.

MIETTINEN, K. **Nonlinear multiobjective optimization**. Norwell: Kluwer, 1999.

MURATA, T.; ISHIBUCHI, H. MOGA: multi-objective genetic algorithms. In: **Proceedings of the 1995 IEEE international conference on evolutionary computation**, 29 November–1 December, 1995. Perth, WA, Australia: IEEE; 1995.

NÉIA, S.S.; ARTERO, A.O.; CANTÃO, L.A.P.; CUNHA, C.B. Roteamento de Veículos Utilizando Otimização por Colônia de Formigas e Algoritmo Genético. In: LOPES, H. S.; RODRIGUES, L. C. A.; STEINER, M. T. A. (eds.) **Meta-Heurísticas em Pesquisa Operacional**. Ed. Omnipax, Curitiba, PR, 2013.

NEO. Networking and Emerging Optimization. Capacitated VRP Instances. Disponível em: < <http://neo.lcc.uma.es/vrp/vrp-instances/capacitated-vrp-instances/> >. Acessado em: 3 de jun. 2019.

NIKNAMFAR, A.H.; NIAKI, S.T.A. Fair profit contract for a carrier collaboration framework in a green hub network under soft time-windows: Dual lexicographic max-min approach. **Transportation Research Part E: Logistics and Transportation Review**, vol. 91, p. 129–151, 2016.

NOROUZI, N.; SADEGH-AMALNICK, M.; TAVAKKOLI-MOGHADDAM, R. Modified particle swarm optimization in a time-dependent vehicle routing problem: minimizing fuel consumption. **Optimization Letters**, vol. 11, p. 121–134, 2017.

OUHADER, H.; EL KYAL, M. Combining Facility Location and Routing Decisions in Sustainable Urban Freight Distribution under Horizontal Collaboration: How Can Shippers Be Benefited? **Math. Probl. Eng.**, 2017.

PARETO, V. **Cours d'économie politique**. Lausanne, Switzerland: F. Rouge, 1896.

PINHO, A. F.; MONTEVECHI, J. A. B.; MARINS, F. A. S.; MIRANDA, R. C. Algoritmos genéticos: fundamentos e aplicações. In: LOPES, H. S.; RODRIGUES, L. C. A.; STEINER, M. T. A. (eds.) **Meta-Heurísticas em Pesquisa Operacional**. Ed. Omnipax, Curitiba, PR, 2013.

POONTHALIR, G.; NADARAJAN, R. A Fuel Efficient Green Vehicle Routing Problem with varying speed constraint (F-GVRP). **Expert Systems with Applications**, vol. 100, p. 131–144, 2018.

PSYCHAS, I.D.; MARINAKI, M.; MARINAKIS, Y.; MIGDALAS, A. Non-dominated sorting differential evolution algorithm for the minimization of route based fuel consumption multiobjective vehicle routing problems. **Energy Syst.**, vol. 8, p. 785–814, 2016.

RABBANI, M.; BOSJIN, S.A.; YAZDANPARAST, R.; SARAVI, N.A. A stochastic time-dependent green capacitated vehicle routing and scheduling problem with time window, resiliency and reliability: A case study. **Decision Science Letters**, vol. 7, p. 381–394, 2018.

RABBANI, M.; FARROKHI-ASL, H.; ASGARIAN, B. Solving a bi-objective location routing problem by a NSGA-II combined with clustering approach: application in waste collection problem. **J. Ind. Eng. Int.**, vol. 13, p. 13–27, 2016.

RABBANI, M.; SARAVI, N.A.; FARROKHI-ASL, H. Design of a forward/reverse logistics network with environmental considerations. **Int. J. Supply Oper. Manag. IJSOM**, vol. 4, p. 115–132, 2017.

RAD, R.S.; NAHAVANDI, N. A novel multi-objective optimization model for integrated problem of green closed loop supply chain network design and quantity discount. **J. Clean. Prod.**, vol. 196, p. 1549–1565, 2018.

RAHIMI, M.; BABOLI, A.; REKIK, Y. Sustainable Inventory Routing Problem for Perishable Products by Considering Reverse Logistic. **IFAC-PapersOnLine**, vol. 49, n. 12, p. 949–954, 2016.

RAMOS, T.R.P.; GOMES, M.I.; BARBOSA-PÓVOA, A.P. Planning a sustainable reverse logistics system: Balancing costs with environmental and social concerns. **Omega** (United Kingdom), vol. 48, p. 60–74, 2014.

RANI, G.V.; REDDY, B. Multi-objective fuzzy shortest path selection for green routing and scheduling problems. **Int. J. Adv. Res. Comput. Sci.**, vol. 8, p. 470–475, 2017.

RAO, W.; LIU, F.; WANG, S. An Efficient Two-Objective Hybrid Local Search Algorithm for Solving the Fuel Consumption Vehicle Routing Problem. **Appl. Comput. Intell. Soft Comput.**, p. 1–16, 2016.

RAU, H.; BUDIMAN, S.D.; WIDYADANA, G.A. Optimization of the multi-objective green cyclical inventory routing problem using discrete multi-swarm PSO method. **Transportation Research Part E**, vol. 120, p.51–75, 2018.

SAWIK, B.; FAULIN, J.; PÉREZ-BERNABEU, E. A Multicriteria Analysis for the Green VRP: A Case Discussion for the Distribution Problem of a Spanish Retailer. **Transportation Research Procedia**, vol. 22, p. 305-313, 2017a.

SCHARDONG, A. **Aplicação de algoritmos evolucionários à gestão integrada de sistemas de recursos hídricos. 185f.** Tese (Doutorado em Engenharia Civil), Escola Politécnica da Universidade de São Paulo, 2011.

SCHAEFER, B.; KONUR, D. Economic and environmental considerations in a continuous review inventory control system with integrated transportation decisions. **Transportation Research Part E: Logistics and Transportation Review**, vol. 80, p. 142–165, 2015.

SCHAFFER, J.D. Multiple objective optimization with vector evaluated genetic algorithms. In: **Proceedings of the international conference on genetic algorithm and their applications**, 1985.

SHUI, C.S.; SZETO, W.Y. Dynamic green bike repositioning problem – A hybrid rolling horizon artificial bee colony algorithm approach. **Transportation Research Part D: Transport and Environment**, vol. 60, p.119-136, 2018.

SOLEIMANI, H.; CHAHARLANG, Y.; GHADERI, H. Collection and distribution of returned-remanufactured products in a vehicle routing problem with pickup and delivery considering sustainable and green criteria. **Journal of Cleaner Production**, vol. 172, p. 960-970, 2018.

SRINIVAS, N.; DEB K. Multiobjective optimization using nondominated sorting in genetic algorithms. **J. Evol. Comput.**, vol. 2, n. 3, p. 221–48, 1994.

STEINER NETO, P.J.; DATTA, D.; STEINER, M.T.A.; CANGIHLIERI JÚNIOR, O.; FIGUEIRA, J.R.; DETRO, S.P.; SCARPIN, C.T. A multi-objective genetic algorithm based approach for location of grain silos in Paraná State of Brazil. **Computers & Industrial Engineering**, vol. 111, p. 318-390, 2017.

STEINER, M.T.A.; DATTA, D.; STEINER NETO, P.J.; SCARPIN, C.T.; FIGUEIRA, J.R. Multi-objective optimization in partitioning the healthcare system of Parana State in Brazil. **Omega**, vol. 52, p. 53-64, 2015.

SUBRAMANIAN, A.; PENNA, P.H.V.; OCHI, L.S.; SOUZA, M.J.F. Um algoritmo heurístico baseado em iterated local search para problemas de roteamento de veículos. In: LOPES, H. S.; RODRIGUES, L. C. A.; STEINER, M. T. A. (eds.) **Meta-Heurísticas em Pesquisa Operacional**. Ed. Omnipax, Curitiba, PR, 2013.

SUN, Y.; HRUSOVSKY, M.; ZHANG, C.; LANG, M. A Time-Dependent Fuzzy Programming Approach for the Green Multimodal Routing Problem with Rail Service Capacity Uncertainty and Road Traffic Congestion. **Complexity**, vol. 2018, p. 1-22, 2018.

SZEJKA, A.L.; CANGIHLIERI JR., O.; PANETTO, H.; LOURES, E.R.; AUBRY, A. Semantic interoperability for an integrated product development process: a systematic literature review. **International Journal of Production Research**, vol. 55, n.22, p. 6691-6709, 2017.

TÁVORA, R. C. M. **Grupos de visitação na AMAN: um estudo de caso do problema do caixeiro viajante**. 107 f. Dissertação (Mestrado em Matemática), Universidade Estadual de Campinas, 2011.

TEOH, B.E.; PONNAMBALAM, S.G.; SUBRAMANIAN, N. Data driven safe vehicle routing analytics: a differential evolution algorithm to reduce CO₂ emissions and hazardous risks. **Annals of Operations Research**, vol. 270, pp. 515-538, 2018.

TORO, E.M.; FRANCO, J.F.; ECHEVERRI, M.G.; GUIMARÃES, F.G. A multi-objective model for the green capacitated location-routing problem considering environmental impact. **Computers and Industrial Engineering**, vol. 110, p. 114–125, 2017a.

TORO, E.M.; FRANCO, J.F.; ECHEVERRI, M.G.; GUIMARÃES, F.G.; RENDÓN, R.A.G. Green open location-routing problem considering economic and environmental costs. **International Journal of Industrial Engineering Computations**, vol. 8, p. 203–216, 2017b.

TRICOIRE, F.; PARRAGH, S.N. Investing in logistics facilities today to reduce routing emissions tomorrow. **Transportation Research Part B: Methodological**, vol. 103, p. 56–67, 2017.

ULUNGU, E.L.; TEGHEM, J.; FORTEMPS, PH.; TUYTTENS, D. MOSA method: a tool for solving multiobjective combinatorial optimization problems. **J. Multi-Crit. Decis. Anal.**, vol. 8, p. 221–236, 1999.

US EPA, 2018. **Inventory of U.S. Greenhouse Gas Emissions and Sinks: 1990-2016**. EPA 430-R-2018-003.

VALIDI, S.; BHATTACHARYA, A.; BYRNE, P.J. A case analysis of a sustainable food supply chain distribution system—A multi-objective approach. **International Journal of Production Economics**, vol. 152, p. 71–87, 2014.

VALIDI, S.; BHATTACHARYA, A.; BYRNE, P.J. A solution method for a two-layer sustainable supply chain distribution model. **Computers & Operations Research**, vol. 54, p. 204–217, 2015.

VALIDI, S.; BHATTACHARYA, A.; BYRNE, P.J. Sustainable distribution system design: a two-phase DoE-guided meta-heuristic solution approach for a three-echelon bi-objective AHP-integrated location-routing model. **Ann. Oper. Res.**, p. 1–32, 2018.

WANG, S.; WANG, X.; LIU, X.; YU, J. A Bi-Objective Vehicle-Routing Problem with Soft Time Windows and Multiple Depots to Minimize the Total Energy Consumption and Customer Dissatisfaction. **Sustainability**, vol. 10, n. 4257, p. 1-21, 2018a.

WANG, Y.; PENG, S.; ASSOGBA, K.; LIU, Y.; WANG, H.; XU, M.; WANG, Y. Implementation of cooperation for recycling vehicle routing optimization in two-echelon reverse logistics networks. **Sustain**, vol. 10, 2018b.

YANG, B.; HU, Z.; WEI, C.; LI, S.; ZHAO, L.; JIA, S. Routing with time-windows for multiple environmental vehicle types. **Computers and Industrial Engineering**, vol. 89, p. 150–161, 2015.

YEN GG, LU H. Dynamic multiobjective evolutionary algorithm: adaptive cell-based rank and density estimation. **IEEE Trans. Evol. Comput.**, vol. 7, n. 3, p. 253–74, 2003.

YIN, P.Y.; LYU, S.R.; CHUANG, Y.L. Cooperative coevolutionary approach for integrated vehicle routing and scheduling using cross-dock buffering. **Eng. Appl. Artif. Intell.**, vol. 52, p. 40–53, 2016.

YU, H.; SOLVANG, W.D.; LI, S. Optimization of long-term performance of municipal solid waste management system: A bi-objective mathematical model. **Int. J. Energy Environ**, vol. 6, p. 153–164, 2015.

YU, H.; SOLVANG, W.D. Incorporating Flexible Capacity in the Planning of a Multi-Product Multi-Echelon Sustainable Reverse Logistics Network under Uncertainty. **Journal of Cleaner Production**, vol. 198, p. 285-303, 2018.

ZAPATA-CORTES, J.A.; ARANGO-SERNA, M.D.; SERNA-URÁN, C.A. Comparison of three IRP-based models to reduce logistics costs and greenhouse gas emissions. **Dyna**, vol. 85, p. 199–204, 2018.

ZENG, W.; MIWA, T.; MORIKAWA, T. Prediction of vehicle CO₂ emission and its application to eco-routing navigation. **Transportation Research Part C: Emerging Technologies**, vol. 68, p. 194–214, 2016.

ZHANG, B.; LI, H.; PENG, J. Sustainable multi-depot emergency facilities location-routing problem with uncertain information. **Applied Mathematics and Computation**, vol. 333, p. 506–520, 2018.

ZHU, L.; HU, D. Sustainable Logistics Network Modeling for Enterprise Supply Chain. **Math. Probl. Eng.**, 2017.

ZITZLER, E. **Evolutionary algorithms for multiobjective optimization: Methods and applications**. PhD thesis, Swiss Federal Institute of Technology Zurich, 1999.

ZITZLER, E.; THIELE, L. Multiobjective evolutionary algorithms: a comparative case study and the strength Pareto approach. **IEEE Trans. Evol. Comput.**, vol. 3, n. 4, p. 257–71, 1999.

ZITZLER E, LAUMANNNS M, THIELE L. **SPEA2: improving the strength Pareto evolutionary algorithm**. Swiss Federal Institute Technonology: Zurich, Switzerland; 2001.

ZOHAL, M.; SOLEIMANI, H. Developing an ant colony approach for green closed-loop supply chain network design: a case study in gold industry. **J. Clean. Prod.**, vol. 133, p. 314–337, 2016.

ANEXO A EXEMPLO DIDÁTICO

A seguir, um exemplo didático para interpretação dos estudos de caso de distribuição de jornais e transporte de funcionários apresentados nesta tese.

Caso 1: Entrega de jornais

O Quadro 1 apresenta os dados para a Demanda e as Distâncias (km).

Quadro 1 – Dados do exemplo didático para a entrega de jornais.

Dem.	Dist.	1*	2	3	4	5	6
0	1*	0,0	1,2	0,9	0,8	1,8	1,8
12	2	2,3	0,0	1,0	1,0	0,6	0,6
15	3	1,1	0,5	0,0	0,3	0,9	0,8
9	4	1,0	0,7	0,2	0,0	1,0	1,1
10	5	2,0	0,6	2,1	2,0	0,0	0,9
11	6	2,0	0,8	2,1	2,0	1,1	0,0

Nota: O endereço "1" é o depósito.

Também foi considerado:

*Capacidade do veículo: até 40 unidades.

*FO₁: Minimizar a emissão de CO₂.

*FO₂: Minimizar o valor absoluto das demandas de cada roteiro em relação a demanda média, visando a homogeneização das demandas.

Solução 1: (1 – 4 – 6 – 1 – 5 – 3 – 2 – 1)

FO₁: $0,8+1,1+2+1,8+2,1+0,5+2,3 = 10,6 * 0,07$ (taxa de kg de CO₂ para motocicleta)
= 0,742 kg de CO₂/km

FO₂:

Número de veículos utilizados no roteiro = 2

Demanda média de veículos = $(12+15+9+10+11)/2 = 28,5$

Roteiro 1 (1 – 4 – 6 – 1) = $9+11 = 20$ unidades (jornais para entregar)

Roteiro 2 (1 – 5 – 3 – 2 – 1) = $10+15+12 = 37$ unidades

Portanto, FO₂: $|(20-28,5)|+|(37-28,5)| = 17$

Solução 2: (1 – 2 – 3 – 1 – 4 – 5 – 6 – 1)

FO₁: =1,2+1+1,1+0,8+1+0,9+2= 8 * 0,07 (taxa de kg de CO₂ para motocicleta) = 0,56 kg de CO₂/km

FO₂:

Número de veículos utilizados no roteiro = 2

Demanda média de veículos = (12+15+9+10+11)/2 = 28,5

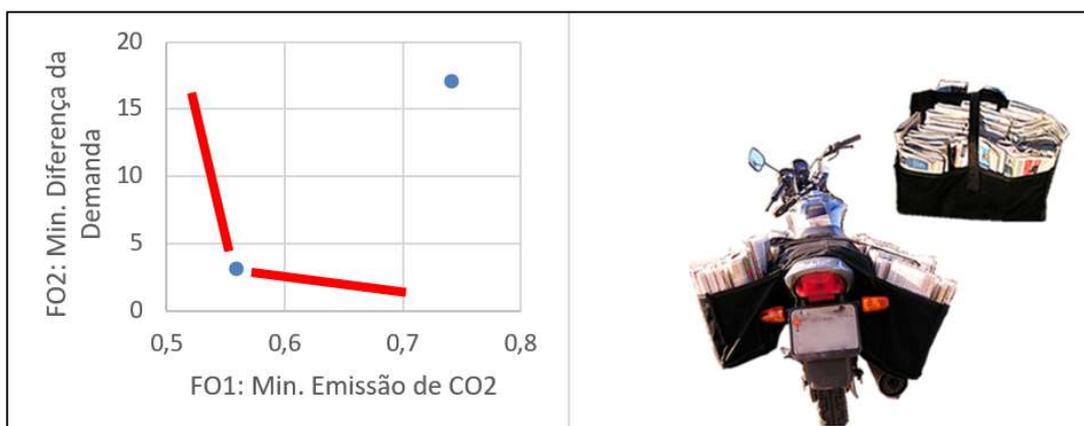
Roteiro 1 (1 – 2 – 3 – 1) = 12+15 = 27 unidades (jornais para entregar)

Roteiro 2 (1 – 4 – 5 – 6 – 1) = 9+10+11 = 30 unidades

Portanto, FO₂: |(27-28,5)|+|(30-28,5)| = 3

A Figura 1 apresenta o gráfico com as soluções e a fronteira de Pareto com a solução dominante. Além disso, também é mostrado um exemplo de veículo para a distribuição dos jornais.

Figura 1 – Resultado do Caso 1 (lado esquerdo) e exemplo de motocicleta utilizada no processo de distribuição de jornais (lado direito)



A Solução 2 (0,560; 3) domina a Solução 1 (0,742;17). Vale destacar que embora as duas soluções atendam ao requisito “capacidade do veículo”, na primeira solução a utilização da capacidade está desbalanceada, com 20 e 37 unidades de jornal nos roteiros. A segunda solução apresenta maior equilíbrio da carga (com 27 e 30 unidades) para a distribuição sem prejudicar a vida útil dos bags das motocicletas (sem encher exageradamente as motos).

Caso 2: Transportes de funcionários

O Quadro 2 apresenta os dados para a Demanda, as Distâncias (km) e os Tempos de trajeto (min).

Quadro 2 – Dados do exemplo didático para o transporte de funcionários

Dem.	Dist.	1*	2	3	4	5	6	Temp.	1*	2	3	4	5	6
0	1*	0,0	1,2	0,9	0,8	1,8	1,8	1*	0	4	2	3	5	5
12	2	2,3	0,0	1,0	1,0	0,6	0,6	2	6	0	3	3	2	2
15	3	1,1	0,5	0,0	0,3	0,9	0,8	3	4	2	0	1	3	3
9	4	1,0	0,7	0,2	0,0	1,0	1,1	4	3	2	1	0	2	2
10	5	2,0	0,6	2,1	2,0	0,0	0,9	5	6	3	5	5	0	4
11	6	2,0	0,8	2,1	2,0	1,1	0,0	6	6	3	5	5	4	0

Nota: O endereço "1" é o depósito.

Também foi considerado:

*Capacidade do veículo: até 40 passageiros.

*Tempo máximo de percurso para cada roteiro do PRV: 15 min.

*Não foi contabilizado no tempo de percurso o fragmento correspondente a saída do depósito (endereço 1) até o primeiro endereço de coleta.

*FO₁: Minimizar a emissão de CO₂.

*FO₂: Minimizar o valor absoluto das demandas de cada roteiro em relação a demanda média, visando a homogeneização das demandas.

Solução 1: (1 – 4 – 6 – 1 – 5 – 3 – 2 – 1)

FO₁: 0,742 kg de CO₂/km

FO₂: 17

Restrição de tempo:

Roteiro 1 (1 – 4 – 6 – 1) = $_ + 2 + 6 = 8$ min

Roteiro 2 (1 – 5 – 3 – 2 – 1) = $_ + 5 + 2 + 6 = 13$ min

Solução 2: (1 – 2 – 3 – 1 – 4 – 5 – 6 – 1)

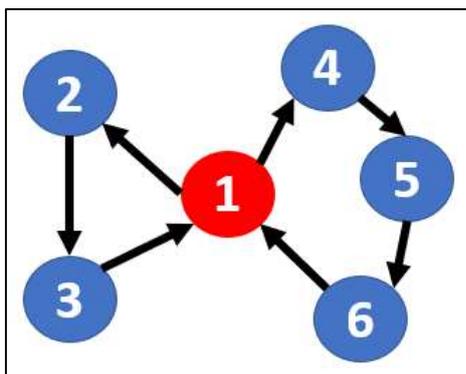
FO₁: 0,56 kg de CO₂/km

FO₂: 3

Roteiro 1 (1 – 2 – 3 – 1) = $_ + 3 + 4 = 7$ min

Roteiro 2 (1 – 4 – 5 – 6 – 1) = $_ + 2 + 4 + 6 = 12$ min

Figura 2 – Representação gráfica para o transporte de funcionários



Aqui para o Caso 2 foi utilizado a mesma solução do Caso 1, acrescentando a restrição de tempo. Observa-se que a restrição de tempo é um limitante no problema abordado.

ANEXO B PUBLICAÇÕES

Na sequência foi listada as publicações realizadas durante o curso do doutorado. Elas estão classificadas nas categorias de artigos de periódico (P), congresso nacional (CN), congresso internacional (CI) e capítulo de livro (CL). As quantidades publicadas foram de 5, 4, 14 e 1 respectivamente. Alguns outros trabalhos encontram-se em desenvolvimento ou em avaliação dos periódicos. A seguir, têm-se as referidas publicações de forma detalhada.

- [P] Ferreira, J. C.; Steiner, M. T. A.; Canciglieri Junior, O. Guide to multi-objective optimization for the green vehicle routing problem. **Revista Internacional de Métodos Numéricos para Cálculo y Diseño en Ingeniería**, v. 36, n. 1, p. 1-21, 2020.
- [P] Ferreira, J. C.; Steiner, M.T.A. Vehicle Routing Problem: A Case Study in Curitiba City, Brazil. **Proelium**, v. 8, n. 5, p. 219 – 234, 2020.
- [P] Chiarello, F.; Steiner, M.T.A.; Oliveira, E.B.; Arce, J.E.; Ferreira, J. C. Artificial Neural Networks Applied in Forest Biometrics and Modeling: State of the Art (January/2007 To July/2018). **Cerne**, v. 25, n. 2, p. 140-155, 2019.
- [P] Silva, A. L.; Ferreira, J. C.; Steiner, M.T.A. Abordagem de Roteamento de Veículos com Procedimentos Exatos e Heurísticos sob uma Óptica Ambiental: um Estudo de Caso. **Revista Eletrônica e-xacta**, v. 16, p. 1, 2018.
- [P] Ferreira, J. C.; Steiner, M.T.A.; Guersola, M. S. A Vehicle Routing Problem Solved Through Some Metaheuristics Procedures: A Case Study. **IEEE Latin America Transactions**, v. 15, p. 943-949, 2017.
- [CI] Ferreira, J. C.; Steiner, M. T. A. A new approach to the problem of multi-objective optimization for the green vehicle routing problem: a case study of the newspaper distribution problem. In: **CIE49**, 2019, Pequim – China, 2019.
- [CI] Scaburi, A.; Ferreira, J. C.; Steiner, M. T. A. Sustainable Logistics: a case study about Vehicles Routing with environmental considerations. In: **2nd World Symposium on Sustainability Science and Research**, 2019, Curitiba – Brasil, 2019.
- [CI] Ferreira, J. C.; Steiner, M. T. A.; Canciglieri Junior, O. Um Survey sobre Otimização Multi-Objetivo para Problemas de Roteamento Green. In: **7th International Workshop Advances in Cleaner Production**, 2018, Barranquilla – Colômbia, 2018.
- [CI] Ferreira, J. C.; Steiner, M. T. A. Vehicle routing problem: a case study in Curitiba city, Brazil. In: **XXIV IJCIEOM 2018**, 2018, Lisboa - Portugal. 2018 IJCIEOM, 2018.

- [CN] Blasques, J. G.; Ferreira, J. C.; Steiner, M. T. A. Otimização na logística de distribuição de mercadorias através do problema do caixeiro viajante: um estudo de caso para produtos de beleza. In: **XXVI SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO**, 2019, Bauru - SP, SIMPEP, 2019.
- [CN] Brito, L. R.; Ferreira, J. C.; Scaburi, A.; Steiner, M. T. A. Otimização no processo de rotas de uma empresa de jornais no município de Curitiba-Pr. In: **XXVI SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO**, 2019, Bauru - SP, SIMPEP, 2019.
- [CN] Cordeiro, A. F.; Ferreira, J. C.; Steiner, M. T. A. Otimização na roteirização de veículos: estudo de caso aplicado ao processo operacional de uma empresa de distribuição logística. In: **XXVI SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO**, 2019, Bauru - SP, SIMPEP, 2019.
- [CN] Giacomitti, G.; Ferreira, J. C.; Steiner, M. T. A. Otimização do processo de rotas em uma empresa de distribuição de produtos do setor alimentício. In: **XXVI SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO**, 2019, Bauru - SP, SIMPEP, 2019.
- [CN] Scaburi, A.; Ferreira, J. C.; Steiner, M. T. A. Estudo comparativo entre abordagens de resolução do problema de roteamento de veículos baseadas em modelos matemáticos. In: **XXVI SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO**, 2019, Bauru - SP, SIMPEP, 2019.
- [CN] Scaburi, A. ; Ferreira, J. C. ; Steiner, M. T. A. Problema de Localização de Facilidades (PLF) e Problema do Caixeiro Viajante (PCV) para a otimização do roteamento de veículos: uma revisão bibliométrica e sistemática da literatura. In: **IX CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO**, 2019, Ponta Grossa - PR. CONBREPRO, 2019.
- [CN] Ferreira, J. C.; Steiner, M. T. A.; Costa, S. E. G. Uma reflexão sobre a Gestão de Estratégia de Operações e o Problema de Roteamento de Veículos. In: **VIII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO**, 2018, Ponta Grossa - PR. CONBREPRO, 2018.
- [CN] Ferreira, J. C.; Steiner, M. T. A. An asymmetric vehicle routing problem solved through heuristic procedures. In: **XXXVIII ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO**, 2018, Maceió - AL. ENEGEP, 2018.
- [CN] Ferreira, J. C.; Rosa, C. R. M.; Steiner, M. T. A.; Gutierrez, T. PROBLEMA DE LOCALIZAÇÃO DE FACILIDADES: uma reflexão por meio das publicações realizadas no ENEGEP (2008-2017). In: **XXXVIII ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO**, 2018, Maceió - AL. ENEGEP, 2018.
- [CN] Scaburi, A. ; Ferreira, J. C. ; Steiner, M. T. A. Survey sobre o Problema de Roteamento: uma contribuição bibliométrica. In: **XXXVIII ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO**, 2018, Maceió - AL. ENEGEP, 2018.

- [CN] Ferreira, J. C.; Steiner, M. T. A. Problema de Roteamento de Veículos: um estudo de caso em uma empresa de transportes rápidos em Curitiba-PR. In: **VII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO**, 2017, Ponta Grossa - PR. CONBREPRO, 2017.
- [CN] Ferreira, J. C.; Steiner, M. T. A. . Problema de Roteamento de Veículos: um estudo de caso comparando duas abordagens que fazem uso de modelos matemáticos. In: **VII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO**, 2017, Ponta Grossa - PR. COMBREPRO, 2017.
- [CN] Silva, A. L.; Ferreira, J. C.; Steiner, M. T. A. Otimização do processo operacional do transporte fretado de funcionários de uma indústria química em Curitiba-PR. In: **XXXVII ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO**, 2017, Joinville - SC. ENEGEP, 2017.
- [CN] Silva, A. L.; Ferreira, J. C.; Steiner, M. T. A. Otimização do processo operacional do transporte fretado de funcionários de uma indústria química em Curitiba-PR. In: **XXIV SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO**, 2017, Bauru - SP, SIMPEP, 2017.
- [CL] Scaburi, A.; Ferreira, J. C.; Steiner, M.T.A. Sustainable Logistics: A Case Study of Vehicle Routing with Environmental Considerations. In: Leal Filho W., Borges de Brito P., Frankenberger F. (Org.). International Business, Trade and Institutional Sustainability. World Sustainability Series. 2ed.: Springer, 2019, p. 765-779.