



TÉCNICAS DE OTIMIZAÇÃO PARA A DESCARBONIZAÇÃO E EFICIÊNCIA OPERACIONAL NO TRANSPORTE DE CARGAS

Conrado Vidotte Plaza

Tese de Doutorado apresentada ao Programa de Pós-graduação em Engenharia de Transportes, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Engenharia de Transportes.

Orientadores: Glaydston Mattos Ribeiro
Laura Silvia Bahiense da Silva
Leite

Rio de Janeiro
Junho de 2024

TÉCNICAS DE OTIMIZAÇÃO PARA A DESCARBONIZAÇÃO E EFICIÊNCIA
OPERACIONAL NO TRANSPORTE DE CARGAS

Conrado Vidotte Plaza

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO
LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA
DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR
EM CIÊNCIAS EM ENGENHARIA DE TRANSPORTES.

Orientadores: Glaydston Mattos Ribeiro
Laura Silvia Bahiense da Silva Leite

Aprovada por: Prof. Glaydston Mattos Ribeiro
Profa. Laura Silvia Bahiense da Silva Leite
Prof. Francisco Glaubos Nunes Clímaco
Prof. Matheus Henrique de Sousa Oliveira
Prof. Orivalde Soares da Silva Junior
Profa. Vanessa de Almeida Guimarães

RIO DE JANEIRO, RJ – BRASIL
JUNHO DE 2024

Plaza, Conrado Vidotte

Técnicas de Otimização para a Descarbonização e Eficiência Operacional no Transporte de Cargas/Conrado Vidotte Plaza. – Rio de Janeiro: UFRJ/COPPE, 2024.

XVII, 222 p.: il.; 29, 7cm.

Orientadores: Glaydston Mattos Ribeiro

Laura Silvia Bahiense da Silva Leite

Tese (doutorado) – UFRJ/COPPE/Programa de Engenharia de Transportes, 2024.

Referências Bibliográficas: p. 140 – 155.

1. Otimização. 2. Localização de facilidades. 3. Centros de Integração Logística. 4. Veículos elétricos. 5. Localização de carregadores. I. Ribeiro, Glaydston Mattos *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia de Transportes. III. Título.

Agradecimentos

Aos meus orientadores, Professor Glaydston e Professora Laura, por compartilharem comigo tantos conhecimentos e experiências únicas durante essa longa jornada.

To Professor Okan, thank you for welcoming me with open arms and for generously sharing your unique and invaluable knowledge with me. Your kindness and support have truly made a difference in my journey.

À Vanessa e ao Glaubos, pelas contribuições ao longo desta pesquisa e aos trabalhos já desenvolvidos e que ainda serão desenvolvidos juntos.

À banca, pelo tempo disponibilizado e as contribuições que enriqueceram a pesquisa.

Aos meus familiares, pelo amor incondicional e por nunca deixarem de acreditar e incentivar meus sonhos, mesmo que fosse necessário me ausentar e estar mais distante. Obrigado por todo apoio, carinho, confiança e dedicação.

Ao Raonne, pelo amor, amizade, por ter me ajudado em cada segundo desta jornada, me garantindo suporte físico e emocional para estar sempre continuando.

Aos meus grandes amigos, por estarem presentes na minha vida, vocês me deram suporte e me reabasteceram de energia nessa longa jornada.

Ao Professor Antônio Nelson, pessoa chave na minha história acadêmica e profissional. Sou muito grato por ter encontrado a sua orientação, o que deu um norte à meu percurso de vida.

Aos amigos do laboratório GIS-OTM e do PET, pela companhia, troca de informações e por todas as vezes que reiniciaram o servidor e o acesso remoto.

Aos colegas da UFRJ-Macaé, em especial aos docentes do Programa de Engenharia Civil, que compreenderam as dificuldades de um doutorando.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

TÉCNICAS DE OTIMIZAÇÃO PARA A DESCARBONIZAÇÃO E EFICIÊNCIA OPERACIONAL NO TRANSPORTE DE CARGAS

Conrado Vidotte Plaza

Junho/2024

Orientadores: Glaydston Mattos Ribeiro

Laura Silvia Bahiense da Silva Leite

Programa: Engenharia de Transportes

Devido a dependência do sistema logístico brasileiro com o modo rodoviário, além de impactos econômicos negativos, tem-se que o setor foi responsável por 50% das emissões de CO_2 . Visando contornar este problema, esta tese tem por objetivo desenvolver técnicas de otimização para descarbonização e eficiência operacional no transporte de cargas. Para isto, foram apresentados dois problemas nesta tese. O Problema Multiperíodo de Localização de Centros de Integração Logística (PML-CIL) destina-se a promover a multimodalidade da rede de transportes a partir da localização de CILs considerando diversos períodos de investimentos. Proposto em Programação Linear Inteira Mista, o modelo matemático multiperíodo busca minimizar, simultaneamente, os custos logísticos (transporte, investimento e operação) e de emissões de CO_2 . O modelo foi avaliado a partir de instâncias reais do transporte de soja brasileira, utilizando-se tanto um *solver* comercial quanto duas abordagens heurísticas: uma baseada em algoritmo genético e outra em relaxação linear. Já o Problema de Localização de Carregadores para Caminhões Elétricos de Longa Distância Considerando Roteamento e a Regulamentação da Jornada de Trabalho dos Motoristas (PLCR-JTM) visa a localização de carregadores veiculares para eletrificação da frota de longa distância. Baseada em técnicas de transformação da rede, a modelagem proposta em Programação Linear Inteira Mista busca minimizar os custos logísticos e de investimentos ao sincronizar: o carregamento veicular, nível do carregador, legislação da jornada de trabalho dos motoristas e o roteamento dos veículos. Abordagens metodológicas foram propostas e validadas para reduzir os custos computacionais e permitir a obtenção de soluções para instâncias de grande porte.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

OPTIMIZATION TECHNIQUES FOR DECARBONIZATION AND OPERATIONAL EFFICIENCY IN FREIGHT TRANSPORT

Conrado Vidotte Plaza

June/2024

Advisors: Glaydston Mattos Ribeiro

Laura Silvia Bahiense da Silva Leite

Department: Transportation Engineering

Due to the dependency of the Brazilian logistics system on road transportation, in addition to negative economic impacts, the sector was responsible for 50% of CO_2 emissions. To address this issue, this thesis aims to develop optimization techniques for decarbonization and operational efficiency in freight transportation. To this end, two problems are presented in this thesis. The Multiperiod Logistics Integration Centers Location Problem (MLICLP) aims to promote the multimodality of the transportation network through the strategic location of LICs considering various periods of investment. Proposed in Mixed-Integer Linear Programming, the multiperiod mathematical model simultaneously minimizes logistical costs (transportation, investment, and operation) and CO_2 emissions costs. The model was evaluated using real instances of Brazilian soybean transportation, employing both a commercial solver and two heuristic approaches: one based on a genetic algorithm and the other on linear relaxation. The long-haul electric truck Charger Location Problem considering Routing and Driver's Working Hours regulation (CLPR-DWH) aims to locate vehicle chargers for the electrification of the long-haul fleet. Based on network transformation techniques, the proposed Mixed-Integer Linear Programming model minimizes logistical and investment costs by synchronizing vehicle charging, charger type, driver's working hours regulation, and vehicle routing. Methodological approaches were proposed and validated to reduce computational costs and to allow obtaining solutions for large-scale instances.

Sumário

Lista de Figuras	x
Lista de Tabelas	xv
1 Introdução	1
1.1 Localização de Centros de Integração Logística (CILs)	4
1.2 Localização de Carregadores para Veículos Elétricos	6
1.3 Objetivos e Contribuições	7
1.4 Organização da Tese	8
2 Problema Multiperíodo de Localização de Centros de Integração Logísticos (PMLCIL): modelagem e técnicas de otimização considerando critérios econômicos e ambientais	9
2.1 Revisão da Literatura	9
2.1.1 O Problema de Localização de CILs	12
2.2 Formulação Matemática	16
2.3 Técnicas de Otimização para o PMLCIL	20
2.3.1 Heurística baseada em Algoritmo Genético	21
2.3.2 Heurística Baseada em Relaxação	43
2.4 Experimentos Computacionais	43
2.4.1 Parâmetros do estudo de caso	44
2.4.2 Cenários de avaliação	54
2.4.3 Avaliação do modelo matemático	55
2.4.4 Análise de sensibilidade dos pesos	67
2.4.5 Avaliação das heurísticas propostas	71
2.5 Conclusões do Capítulo	82
3 Problema de Localização de Carregadores para Caminhões Elétricos de Longa Distância Considerando Roteamento e a Jornada de Trabalho dos Motoristas	85
3.1 Revisão da Literatura	85
3.2 Definição do Problema e Transformação das Redes	90

3.2.1	Premissas gerais	91
3.2.2	Definição da demanda	92
3.2.3	Estratégias de carregamento	92
3.2.4	Rede de Transporte	92
3.2.5	Rede de Comunicação	94
3.2.6	Rede de Comunicação Espaço-Temporal	95
3.2.7	Definição de <i>caminho direto</i>	97
3.3	Formulação Matemática e Estratégias Metodológicas	100
3.3.1	Estratégias para redução do tamanho do modelo	103
3.3.2	Condição inicial dos motoristas	110
3.4	Experimentos Computacionais	112
3.4.1	Análise computacional em rede artificial	112
3.4.2	Estudo de caso: distribuição estadual de soja	119
3.4.3	Estudo de caso: distribuição nacional da soja produzida em cada estado do Centro-Oeste	127
3.5	Conclusões do Capítulo	135
4	Conclusões Finais	138
4.1	Estágio Sanduíche e Publicações	138
	Referências Bibliográficas	140
A	Modelos Matemáticos de Problema de Localização de CILs	156
A.1	CILs como pontos concentradores de carga	156
A.2	Atendimento da demanda par-a-par	158
A.3	Incorporação de aspectos ambientais	160
A.4	Modelo Multiperíodo	162
B	Matrizes OD da soja em grãos consolidadas por região do IBGE	164
B.1	Soja em grãos	164
C	Microrregiões candidatas	167
D	Resultados Método Exato	170
D.1	Quantidade de CILs abertos	170
D.2	Volumes operacionais em cada CIL – Instância COSNESEN	175
E	Desempenho da abordagem gulosa para o cálculo de aptidão	194
F	Parâmetros do AG	197
F.1	Calibragem dos parâmetros do AG	197
F.2	Comparação entre as Máscaras de Viabilidade	201

F.3	Escolha do método para indivíduos relaxados	203
G	<i>Time-to-target plots</i>	207
G.1	Ttt-plots para E10%	208
G.1.1	pmut = 0,05	208
G.1.2	pmut = 0,15	209
G.1.3	pmut = 0,25	210
G.2	Ttt-plots para E20%	211
G.2.1	pmut = 0,05	211
G.2.2	pmut = 0,15	212
G.2.3	pmut = 0,25	213
H	Resultados para as instâncias de distribuição de soja	214
I	Análise de Sensibilidade Instâncias	220

Lista de Figuras

2.1	Estrutura simplificada da rede do problema de localização de CILs. . .	13
2.2	Estrutura conceitual do modelo matemático multiperíodo proposto. . .	17
2.3	Estrutura do Algoritmo Genético proposto para o PMLCIL.	23
2.4	Estrutura do vetor de codificação do cromossomo.	24
2.5	Exemplo de codificação do cromossomo.	24
2.6	Estrutura do algoritmo de cálculo do valor de aptidão do cromossomo.	27
2.7	Plano de reprodução.	33
2.8	Operador de cruzamento.	34
2.9	Operador de mutação.	35
2.10	Exemplo de aplicação de máscara de viabilidade.	36
2.11	Fluxograma de aplicação dos critérios de parada.	41
2.12	Zoneamento utilizado: microrregiões do PNLT.	45
2.13	Rede multimodal adaptada do PNLT para o horizonte de 2031.	47
2.14	Volume de soja em grãos, milho, açúcar e farelo de soja transportado em cada período de análise (em 10^6 toneladas) – adaptado de MT [1].	48
2.15	Microrregiões candidatas a construção de CIL	51
2.16	Custo total, dividido em custo logístico e de emissões, obtido para os cenários de avaliação aplicados à instância <i>COSNESEN</i>	59
2.17	Proporção do custo total em custos logísticos e de emissões para os cenários de avaliação aplicados à instância <i>COSNESEN</i>	59
2.18	Volume transportado diretamente entre o par OD (referência <i>ij</i>) e através de CILs (referência <i>ikj</i>) para cada cenário de avaliação (ins- tância <i>COSNESEN</i>).	62
2.19	Volume transportado diretamente entre o par OD (Total Direto) e através de CILs (Total CIL) para cada cenário de avaliação (instância <i>COSNESEN</i>).	62
2.20	Volumes operacionais totais dos CILs agregados de acordo com a região para cada cenário de avaliação.	64
2.21	Volume operacional dos CILs em cada período para o Cenário 0a e instância <i>COSNESEN</i> (volumes em 10^6 toneladas).	67

2.22	Análise de Pareto a partir dos valores de $\Delta Z(C_{logisticos})$ e $\Delta Z(C_{emissoes})$ – comparação com o cenário “Nada a Fazer” – para cada variação dos pesos α e β . Valores negativos indicam economias em relação ao cenário sem CILs.	69
2.23	Custos totais para cada variação dos pesos α e β . Os valores percentuais indicam a contribuição dos custos logísticos e dos custos de emissões no valor total.	71
2.24	Diagrama de caixas a partir dos valores de GAP e de tempos computacionais observados ao aplicar o AG proposto sem e com indivíduos relaxados na população inicial para as instâncias e cenários abordados no estudo.	79
2.25	Diagrama de caixas a partir dos valores de GAP e de tempos computacionais observados ao aplicar a Heurística Baseada em Relaxação para as instâncias e cenários abordados no estudo.	80
2.26	Tempos computacionais obtidos ao aplicar as heurísticas abordadas neste estudo e o Gurobi (em segundos).	81
3.1	Exemplo de rede de transporte para apresentação do problema em tela.	91
3.2	Exemplo de uma rede de comunicação a partir da rede de transporte da Figura 3.1.	95
3.3	Classificações dos <i>segmentos de caminho</i> que compõem a rede de comunicação espaço-temporal para a demanda 1 do exemplo, com $(o^1, d^1) = (1, 5)$	98
3.4	Soluções para os exemplos de apresentação do problema considerando $e^1 = e^2 = \underline{\Delta} = 0$ e $a^1 = a^2 = \overline{\Delta} = 12$	99
3.5	Redes operacionais para os exemplos de apresentação do problema.	110
3.6	Rede de 25 nós utilizada nos experimentos computacionais.	113
3.7	Resultado da localização geográfica dos carregadores.	126
3.8	Resultado da simplificação da rede viária considerando-se uma <i>cordon line</i> para cada estado.	128
3.9	Resultado da localização geográfica dos carregadores.	136
B.1	Produção da soja entre as regiões brasileiras para cada horizonte de análise (em 10^6 toneladas).	164
B.2	Consumo da soja entre as regiões brasileiras para cada horizonte de análise (em 10^6 toneladas).	165
D.1	Volume operacional dos CILs em cada horizonte para o Cenário 0a e instância <i>COSNESEN</i> (volumes em 10^6 toneladas).	178

D.2	Volume operacional dos CILs em cada horizonte para o Cenário 0b e instância <i>COSNESEN</i> (volumes em 10^6 toneladas).	181
D.3	Volume operacional dos CILs em cada horizonte para o Cenário 1a e instância <i>COSNESEN</i> (volumes em 10^6 toneladas).	184
D.4	Volume operacional dos CILs em cada horizonte para o Cenário 1b e instância <i>COSNESEN</i> (volumes em 10^6 toneladas).	187
D.5	Volume operacional dos CILs em cada horizonte para o Cenário 2a e instância <i>COSNESEN</i> (volumes em 10^6 toneladas).	190
D.6	Volume operacional dos CILs em cada horizonte para o Cenário 2b e instância <i>COSNESEN</i> (volumes em 10^6 toneladas).	193
E.1	Gráfico de dispersão dos valores de aptidão obtidos para uma amostra de 500 indivíduos aleatórios utilizando-se um <i>solver</i> comercial e a heurística gulosa proposta.	195
E.2	GAP ao comparar o valor de aptidão de cada indivíduo para cada cenário de avaliação para uma amostra de 500 indivíduos aleatórios. .	196
E.3	Tempos computacionais para cálculo do valor de aptidão de cada indivíduo para cada cenário de avaliação para uma amostra de 500 indivíduos aleatórios.	196
F.1	Tempos computacionais observados para atingir o alvo para conjunto elite com tamanho equivalente a 10% e 20% do tamanho da população.199	
F.2	Quantidade de gerações requeridas para atingir o alvo para conjunto elite com tamanho equivalente a 10% e 20% do tamanho da população.200	
F.3	Tempos computacionais para atingir o alvo em 80% das aplicações variando-se o tamanho da população e probabilidade de mutação. . .	201
F.4	Quantidade de gerações requeridas para atingir o alvo em 80% das aplicações variando-se o tamanho da população e probabilidade de mutação.	202
F.5	Tempos computacionais observados ao aplicar o AG sem e com máscara de viabilidade em populações com 80 e 60 indivíduos.	202
F.6	Gerações requeridas ao aplicar o AG sem e com máscara de viabilidade em populações com 80 e 60 indivíduos.	203
F.7	Quantidade de redefinições da população em função do número de gerações.	204
F.8	Valores de GAP observados ao aplicar o AG proposto sem e com indivíduos relaxados na população para os cenários 0a e 0b.	205
F.9	Tempos computacionais observados ao aplicar o AG proposto sem e com indivíduos relaxados na população para os cenários 0a e 0b. . . .	206

G.1	População com 40 indivíduos.	208
G.2	População com 60 indivíduos.	208
G.3	População com 80 indivíduos.	208
G.4	População com 120 indivíduos.	208
G.5	Ttt-plot para população com 40 indivíduos.	209
G.6	Ttt-plot para população com 60 indivíduos.	209
G.7	Ttt-plot para população com 80 indivíduos.	209
G.8	Ttt-plot para população com 120 indivíduos.	209
G.9	Ttt-plot para população com 40 indivíduos.	210
G.10	Ttt-plot para população com 60 indivíduos.	210
G.11	Ttt-plot para população com 80 indivíduos.	210
G.12	Ttt-plot para população com 120 indivíduos.	210
G.13	Ttt-plot para população com 40 indivíduos.	211
G.14	Ttt-plot para população com 60 indivíduos.	211
G.15	Ttt-plot para população com 80 indivíduos.	211
G.16	Ttt-plot para população com 40 indivíduos.	212
G.17	Ttt-plot para população com 60 indivíduos.	212
G.18	Ttt-plot para população com 80 indivíduos.	212
G.19	Ttt-plot para população com 120 indivíduos.	212
G.20	Ttt-plot para população com 40 indivíduos.	213
G.21	Ttt-plot para população com 60 indivíduos.	213
G.22	Ttt-plot para população com 80 indivíduos.	213
G.23	Ttt-plot para população com 120 indivíduos.	213
H.1	Valores de GAP obtidos ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância <i>CO</i>	214
H.2	Tempos computacionais observados ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância <i>CO</i>	215
H.3	Valores de GAP obtidos ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância <i>COS</i>	215
H.4	Tempos computacionais observados ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância <i>COS</i>	216
H.5	Valores de GAP obtidos ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância <i>COSNE</i>	216

H.6	Tempos computacionais observados ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância <i>COSNE</i>	217
H.7	Valores de GAP obtidos ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância <i>COSNESE</i>	217
H.8	Tempos computacionais observados ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância <i>COSNESE</i>	218
H.9	Valores de GAP obtidos ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância <i>COSNESEN</i>	218
H.10	Tempos computacionais observados ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância <i>COSNESEN</i>	219

Lista de Tabelas

2.1	Conjuntos e índices.	17
2.2	Variáveis de decisão.	18
2.3	Parâmetros.	18
2.4	Exemplo de atualização da quantidade de facilidades a serem fechadas nos quatro períodos.	38
2.5	Síntese dos critérios de parada implementados no Algoritmo Genético proposto.	42
2.6	Produção e consumo da soja entre as regiões do Brasil.	49
2.7	Distribuição das microrregiões candidatas a receberem as instalações de um CIL entre as regiões brasileiras.	50
2.8	Resumo das variações do custo operacional dos veículos em função da condição do pavimento.	53
2.9	Cenários de avaliação.	55
2.10	Instâncias elaboradas para avaliação.	55
2.11	Resultados ótimos para as diferentes instâncias de soja.	57
2.12	Quantidade de CILs abertos em cada horizonte para os diferentes cenários a partir da instância <i>COSNESEN</i>	60
2.13	Volumes mínimos e máximos transportado através dos CILs localizados nas regiões Norte, Nordeste e Sudeste.	65
2.14	Volumes mínimos e máximos transportado através dos CILs localizados nas regiões: Sul e Centro-Oeste.	66
2.15	Resultados do impacto dos pesos α e β nos cenários avaliados (valores em negrito indicam os menores custos totais do cenário avaliado).	70
2.16	Resultados das abordagens heurísticas propostas para as diferentes instâncias de soja.	74
2.17	Controle de igualdade entre a solução do AG proposto e os indivíduos relaxados na população inicial para as instâncias avaliadas.	83
3.1	Parâmetros simplificados da legislação de jornada de trabalho para Brasil, EUA e Canadá.	88
3.2	Variáveis de decisão.	100

3.3	Cálculo dos limitantes inferiores e superiores para classificação de nós não-supérfluos para o exemplo apresentado.	109
3.4	Estatísticas da rede artificial.	112
3.5	Estatísticas da demanda.	114
3.6	Estatísticas das Redes de Comunicação.	115
3.7	Estatísticas das Redes de Comunicação-Espaço-Temporal sem e com a estratégia de gerenciamento de nós supérfluos.	115
3.8	Resultados para as instâncias.	117
3.9	Quantidades de nós e arcos resultantes da flexibilização do tempo de chegada.	118
3.10	Resultados da análise de sensibilidade.	118
3.11	Valores de GAPs obtidos na análise de sensibilidade.	119
3.12	Informações das bases de demanda.	120
3.13	Estatísticas das redes de transportes.	121
3.14	Estatísticas das redes iniciais e transformadas para cada instância.	122
3.15	Resultados para as instâncias por estado.	125
3.16	Resultados da localização de carregadores para as instâncias por estado.	125
3.17	Informações das bases de demanda.	127
3.18	Estatísticas das redes de transportes \mathcal{G}	129
3.19	Estatísticas das redes iniciais e transformadas para cada instância.	129
3.20	Resultados para a instância de distribuição nacional da soja produzida em cada estado do Centro-Oeste.	130
3.21	Resultados para a instância de distribuição nacional da soja produzida em cada estado do Centro-Oeste com solução inicial viável.	134
3.22	Resultados da localização de carregadores para as instâncias por estado.	135
A.1	Conjuntos e índices do modelo matemático proposto por COSTA [2].	156
A.2	Parâmetros do modelo matemático proposto por COSTA [2].	157
A.3	Variáveis de decisão do modelo matemático proposto por COSTA [2].	158
A.4	Equivalência entre os parâmetros do modelo proposto por GUIMARÃES [3] e COSTA [2].	161
A.5	Parâmetros do modelo proposto por GUIMARÃES [3].	161
B.1	Matriz OD da soja (em toneladas)	166
C.1	Microrregiões candidatas para instalação de CIL.	167
D.1	CILs abertos em cada horizonte para as diferentes instâncias de soja.	170
D.2	Cenário 0a (Volumes em $\times 10^6$ ton.).	175
D.3	Cenário 0b (Volumes em $\times 10^6$ ton.).	178
D.4	Cenário 1a (Volumes em $\times 10^6$ ton.)	181

D.5	Cenário 1b (Volumes em $\times 10^6$ ton.)	184
D.6	Cenário 2a (Volumes em $\times 10^6$ ton.)	187
D.7	Cenário 2b (Volumes em $\times 10^6$ ton.)	190
F.1	Resultados da análise dos ttt-Plots para afinação dos parâmetros. . .	199
F.2	Resultados do AG proposto para a instância CO sem e com indivíduos relaxados na população inicial.	205
I.1	Instâncias avaliadas para a análise de sensibilidade.	220
I.2	Resultados para a instância DF+GO_BR sem e com solução primal inicial.	221
I.3	Resultados para a instância MT_BR sem e com solução primal inicial.	222

Capítulo 1

Introdução

Como resultado das crescentes pressões competitivas decorrentes da globalização, as empresas que antes atuavam principalmente em mercado doméstico tendem a buscar meios de se manterem competitivas, como, por exemplo, por meio da minimização dos custos na cadeia produtiva. Neste sentido, empresas nos Estados Unidos, Japão e outros países desenvolvidos estão estabelecendo instalações em países com menores custos de mão de obra para reduzir os custos de produção, mas mantendo ou até mesmo melhorando a qualidade dos produtos (CANEL e KHUMAWALA [4]).

A infraestrutura de transportes insere-se, neste contexto, de forma fundamental e estratégica, uma vez que é utilizada em todas as etapas das cadeias produtivas, desde a movimentação da matéria prima às fábricas até a distribuição dos bens de consumo aos clientes, além do transporte da mão de obra em todas as etapas do processo. Com isso, o desempenho dos sistemas de transportes reflete diretamente nos custos finais dos produtos e no acesso destes à população. Desta forma, a eficiência operacional e estratégica destes sistemas pode impactar diretamente no desenvolvimento das atividades econômicas e sociais das regiões.

Devido às suas dimensões continentais, somado à distribuição territorial das atividades produtivas, no Brasil, o setor de transportes se torna ainda mais importante para a integração geográfica, uma vez que os fluxos de pessoas e mercadorias percorrem longas distâncias e têm de alcançar áreas longínquas no interior do território. Portanto, é de suma importância haver um planejamento e um processo de investimentos continuados no setor de transporte de forma a garantir impactos positivos nas esferas econômicas, sociais e ambientais (ver, por exemplo, CNT [5], MONTEIRO HUERTAS [6], GUIMARÃES *et al.* [7]).

De acordo com GUIMARÃES [8], o planejamento estratégico deste setor é importante para o aumento da competitividade brasileira (em nível nacional e internacional) e para redução dos custos totais associados às atividades de movimentação de carga. Conforme apresentado por CNT [5] ao avaliar a composição e dispêndios dos custos logísticos totais (composto pelos custos de transporte, estoque, armazenagem

e administrativos), verificou-se que, em 2016, os custos de transporte corresponderam a 55% dos custos logísticos totais para as empresas. Além disso, os custos logísticos totais representaram, naquele ano, 12,3% do valor do PIB, enquanto nos Estados Unidos, por exemplo, este valor foi de 7,8%. Para 2020, o custo logístico no Brasil foi estimado em 11,6% do PIB (MINISTÉRIO DO DESENVOLVIMENTO, INDÚSTRIA, COMÉRCIO E SERVIÇOS [9]), valor próximo ao observado para 2016. Esta alta parcela do PIB destinada à apenas uma categoria de serviço pode impactar na distribuição de recursos públicos com outras atividades básicas de uma nação, além de indicar a necessidade de métodos eficientes para otimização da utilização dos recursos. Ao reduzir custos e distâncias, pode-se alcançar efeitos multiplicadores em toda a cadeia produtiva, proporcionando desenvolvimento econômico nos setores produtivos regionais e internacionais de um país (GUIMARÃES [8]).

É apontado por CNT [10] que a falta de investimentos em infraestrutura é o principal gargalo logístico no sistema brasileiro, mas não o único, uma vez que há, por exemplo, deficiência e número insuficiente de portos, aeroportos e ferrovias, além da falta de manutenção e má qualidade das rodovias. A ineficiência do sistema de transporte de cargas no Brasil também foi identificada e sinalizada por CNT E COPPEAD [11] e por LOPES *et al.* [12], que compararam a situação brasileira à indicadores internacionais e afirmaram haver espaço para melhoria da eficiência da atividade de transporte no país.

Como consequência destes entraves no setor, pode-se citar entraves à circulação de bens e pessoas, comprometimento da qualidade dos serviços prestados e desigualdade entre regiões, além de impactos no desenvolvimento econômico e social do país (CNT [5], WANKE e FLEURY [13]). Pode-se citar, ainda, desequilíbrios na matriz de transportes brasileira (com níveis desiguais de eficiência na operação dos modos), com predominância do uso do modo rodoviário. A movimentação de cargas no Brasil, por exemplo, é realizada majoritariamente pelo modo rodoviário (65%, CNT [14]). Essa distribuição modal transparece a dependência do sistema logístico de cargas com o modo rodoviário, ocasionando, dentre outros problemas, impactos econômicos e ambientais negativos.

Esse desequilíbrio na matriz modal, agravado pelo aumento significativo da distância percorrida na última década (ALAM e GUO [15]), tem contribuído significativamente para a emissão de gases de efeito estufa. De acordo com RITCHIE *et al.* [16], o transporte rodoviário foi responsável por aproximadamente 11,9% das emissões globais de gases de efeito estufa (emissões oriundas da queima de combustíveis fósseis, considerando carros, caminhões, motocicletas e ônibus). Deste percentual, 40% equivalem às emissões de veículos de carga (caminhões e caminhões pesados). Já no âmbito brasileiro, em 2021, o setor de transporte foi responsável por aproximadamente 50% da emissão de CO_2-eq (EPE [17]).

Portanto, a realização de investimentos visando a eficiência deste setor são essenciais, pois podem refletir no desenvolvimento regional sustentável, favorecendo a expansão da economia (com geração de empregos e renda), na redução de impactos ambientais e na melhoria das condições de vida da população e, principalmente, dos motoristas. Porém, a análise de sistemas de transportes é complexa, já que estes são constituídos por diversas partes que possuem comportamentos individuais mas que afetam o sistema como um todo. A Pesquisa Operacional (PO) insere-se, neste contexto, como uma importante ferramenta analítica para a avaliação dos sistemas logísticos, posicionando-se como recurso fundamental no planejamento estratégico e no suporte à decisão para agentes públicos e privados.

Visando a descarbonização e melhoria da eficiência operacional no transporte de cargas, esta tese apresenta dois problemas de otimização: o Problema Multiperíodo de Localização de Centros de Integração Logísticos (PMLCIL) e o Problema de Localização de Carregadores para Caminhões Elétricos de Longa Distância considerando a Regulamentação da Jornada de Trabalho dos Motoristas (PLCR-JTM).

O primeiro problema foi selecionado por abranger a localização de facilidades (os Centros de Integração Logísticos, ou CILs, neste caso) que favorecem a multimodalidade no sistema de transportes, impactando positivamente para a descarbonização (por meio da redução de emissões de CO_2) e para aspectos econômicos, por meio da redução dos custos logísticos. Além disso, apesar de não terem sido considerados no processo de otimização, a implementação de CILs pode, indiretamente, favorecer o desenvolvimento de aspectos sociais, como a geração de empregos, menor exposição da população à poluições e congestionamentos, além de aumento da segurança viária com a redução de veículos nas vias.

No entanto, a implantação de facilidades de grande porte, como os CILs, requer altos investimentos iniciais, além de longo prazo para a construção das infraestruturas necessárias para o início da operação, postergando os benefícios no sistema logístico. Visando contornar estas dificuldades, o segundo problema apresentado, o PLCR-JTM, envolve a localização estratégica de carregadores veiculares para a descarbonização do transporte rodoviário de cargas a partir da eletrificação dos veículos de longa distância. Este problema aborda avaliação dos custos de implantação dos carregadores e operação dos veículos, além de aspectos sociais, ao incorporar a legislação da jornada de trabalho dos motoristas.

1.1 Localização de Centros de Integração Logística (CILs)

Em decorrência das diferenças entre os modos de transportes, estudos que visam a melhoria na eficiência operacional e a modernização da rede de transporte como um todo demandam uma perspectiva sistêmica do setor, baseada no uso integrado e complementar dos diferentes modos (CNT [10]). Para isto, destaca-se a multimodalidade da rede como uma solução logística que viabiliza a melhor utilização dos modos de transportes disponíveis, visando aumentar a eficiência do serviço ao otimizar as atividades logísticas, tornando as operações mais eficientes e sustentáveis. No entanto, há de se considerar que, em determinadas regiões do país, não há estruturas que permitam a integração e transferência modal e/ou estas são ineficientes (GUIMARÃES [8]).

Estruturas de integração logística, como os Centros de Integração Logística (CILs), são essenciais para a coordenação da cadeia logística, uma vez que permitem a conexão entre os modos de transportes, além de oferecer espaço para operações, como de transbordo e armazenamento. Desta forma, essas estruturas constituem um vetor para a otimização de custos e dos níveis de serviço de transporte, sendo relevantes para o desenvolvimento sustentável do setor. No entanto, para que isso aconteça de maneira efetiva, é necessário um planejamento no setor de transportes, levando-se em consideração metodologias que possibilitem avaliar como, onde e de que forma as estruturas de integração modal devem ser consideradas no planejamento de transportes, fundamentando-se o Problema de Localização de CILs (PLCIL).

Os trabalhos de COSTA [2], GUIMARÃES [8], GUIMARÃES *et al.* [18] e GUIMARÃES [3] fazem contribuições ao PLCIL a partir de metodologias que visam otimizar o sistema considerando-se, no processo de otimização, aspectos econômicos e até ambientais (no caso exclusivo de GUIMARÃES [3]). Porém, os modelos matemáticos presentes nestes estudos são classificados como estáticos, uma vez que utilizam todas as informações de entrada (como demandas, distâncias e tempos de viagem) valores conhecidos e sem variação temporal, enquanto as saídas são variáveis de decisão especificadas para um determinado momento e ocasião. Embora os resultados destes modelos possam orientar tomadores de decisão, estes não são capazes de avaliar possíveis variações temporais nas informações, auxiliando a tomada de decisões em problemas reais de médio e longo prazo.

Por outro lado, as formulações multiperíodo buscam formalizar a complexidade temporal inerente às instâncias de problemas reais, transformando modelos instantâneos de decisões pontuais em modelos de horizontes estendidos (ou períodos), capturando os aspectos temporais das instâncias. Desta forma, podem envolver, para

cada período, decisões sobre quantas instalações abrir, onde localizá-las e como alocar a produção de cada instalação (ARABANI e FARAHANI [19], CANEL *et al.* [20], OWEN e DASKIN [21]). Neste contexto, destaca-se a abordagem mutiperíodo para o PLCIL proposta por MT [22], que considera apenas os aspectos econômicos na otimização. Porém, além de não considerar aspectos ambientais na otimização, o modelo não foi aplicado a um estudo de caso devido a sua alta complexidade.

Cabe salientar que, embora a otimização das cadeias logísticas a partir da implantação de CILs possa gerar valor monetário a longo prazo ao sistema, para a construção e implantação destas facilidades, faz-se necessário um dispendioso investimento inicial, que depende de suas características técnicas e operacionais. Assim, ao considerar apenas um horizonte para a análise de localização das facilidades, tem-se que os benefícios estimados no modelo serão atingidos apenas com a implantação de todos os investimentos previstos para a otimização do sistema e quando a utilização da rede atingir os valores críticos inseridos como dados de entrada do modelo. Como consequência, devido às variações temporais das demandas transportadas e elevados custos de investimentos para a abertura de facilidades deste porte, pode haver um planejamento estratégico com elevado aporte financeiro sem utilização completa da infraestrutura em determinados períodos, inviabilizando a implantação de projetos de acordo com a realidade econômica da região, principalmente no contexto de países em desenvolvimento.

Portanto, é de suma importância que o planejamento leve em consideração informações operacionais e de investimentos de diferentes períodos ao longo da operação do sistema logístico, permitindo avaliar o impacto das informações de cada período nos períodos subsequentes. Os modelos multiperíodos permitem avaliar cenários com projeções temporais tendenciais, otimistas e/ou pessimistas, permitindo incorporar efeitos de acontecimentos específicos em determinados períodos, como o impacto da pandemia da COVID-19 na demanda. Como resultado, pode-se obter planos estratégicos capazes de incorporar, de forma otimizada, a priorização de investimentos de acordo com as variações temporais dos dados de entrada.

Ante o exposto, emerge a seguinte problemática: como determinar a localização de centros de integração logística (CILs) considerando diferentes horizontes de planejamento, os pares de origem e destino das cargas (demanda par-a-par) e as emissões de CO_2 ?

1.2 Localização de Carregadores para Veículos Elétricos

Devido a seus benefícios potenciais na melhoria da eficiência energética e na redução de emissões ambientais, a eletrificação dos transportes tem ganhado o interesse de governos, indústria e da academia nos últimos anos (CHEN *et al.* [23], ZHONG *et al.* [24]). Neste contexto, diversos trabalhos tem investigado os impactos da adoção de veículos elétricos para o transporte de cargas. Porém, os caminhões elétricos ainda possuem algumas limitações que posicionam-se como obstáculos para sua ampla adoção, como baixa autonomia, escassa infraestrutura de carregamento e necessidade de maior tempo de recarga da bateria (ALAM e GUO [15], CHEN *et al.* [23], DAVATGARI *et al.* [25], KUCUKOGLU *et al.* [26], MAYERLE *et al.* [27], SMITH *et al.* [28]). Neste contexto, estudos de localização de infraestruturas de carregamento para veículos elétricos posicionam-se como importantes ferramentas para contornar as limitações desta tecnologia, especialmente ao incorporar tecnologias que permitam carregamentos rápidos ou estratégias de carregamento parcial, projetando-se infraestrutura logística eletrificada que permita atender os prazos de distribuição dos produtos.

Em países com vasta área territorial, como é o caso do Brasil, as distâncias percorridas pelos motoristas podem ser consideráveis e, frequentemente, requer a permanência na estrada por vários dias consecutivos, o que as caracteriza como viagens de longa distância. Estas são regulamentadas pela Lei nº 13.103 de 2015 (BRASIL [29]) e definidas como aquelas em que o motorista profissional empregado permanece fora da base da empresa, matriz ou filial e de sua residência por mais de 24 horas. Com o objetivo de evitar a exaustão dos motoristas comerciais e, conseqüentemente, acidentes no trânsito, a Lei nº 13.103 de 2015 regulamenta as condições de trabalho dos motoristas, estabelecendo, por exemplo, o número de horas consecutivas de direção, a necessidade de paradas rápidas para descanso, além de descansos mais longos, e, ainda, um período de folga após um número específico acumulado de dias consecutivos de trabalho.

No entanto, a necessidade de descansos para cumprimento da legislação de jornada de trabalho acrescida da necessidade de recarga dos caminhões elétricos pode impactar o planejamento operacional dos veículos e o tempo de entrega. Neste contexto, destaca-se a importância da análise conjunta destes dois elementos na programação dos veículos e rotas. No entanto, para que seja possível sincronizar a jornada de trabalho com a necessidade de recarga dos veículos, deve haver carregadores localizados em pontos estratégicos ao longo dos percursos. A importância da integração da legislação de jornada de trabalho com a programação dos veículos tem sido estudada na literatura (ver, por exemplo, KOUBÁA *et al.* [30] e PILZ *et al.*

[31]). Porém, não foram identificados trabalhos que analisam a legislação de jornada de trabalho no contexto da localização de carregadores para caminhões elétricos de longa distância.

Ante o exposto, emerge a seguinte problemática: como determinar a localização de carregadores para caminhões elétricos em viagens de longa distância de forma a sincronizar as paradas para carregamento e as paradas para descanso na rede de transporte?

1.3 Objetivos e Contribuições

Neste contexto, esta tese tem por objetivo principal desenvolver técnicas de otimização para a descarbonização e eficiência operacional no transporte de cargas a partir de dois problemas:

1. Problema Multiperíodo de Localização de Centros de Integração Logísticos (PMLCIL): Desenvolver e solucionar um modelo matemático abrangente para a localização e alocação de CILs em múltiplos períodos. Este modelo deve considerar, simultaneamente, critérios econômicos (custos de transporte, investimento e operação) e ambientais (emissões de CO_2) no processo de otimização, além de permitir a incorporação de variações temporais dos dados de entrada. Tem-se, como objetivos específicos:
 - i. Equacionamento e validação de um modelo multiperíodo para a Localização de CILs;
 - ii. Desenvolvimento e aplicação de abordagens heurísticas para solução do modelo matemático proposto; e
 - iii. Comparação dos resultados alcançados a partir das metodologias utilizadas, verificando as contribuições para as decisões estratégicas ao desenvolvimento do transporte multimodal de cargas.
2. Problema de Localização de Carregadores para Caminhões Elétricos de Longa Distância Considerando Roteamento e a Regulamentação da Jornada de Trabalho dos Motoristas (PLCR-JTM): Desenvolver e solucionar um modelo matemático abrangente para a localização de carregadores para caminhões de longa distância que considere a regulamentação da jornada de trabalho dos motoristas. O modelo também deve incorporar carregadores com diferentes níveis de carregamento, de forma a não gerar atrasos na programação logística, e rotas flexíveis. Tem-se, como objetivos específicos:
 - i. Equacionamento e validação do modelo matemático;

- ii. Desenvolvimento e aplicação de estratégias metodológicas para redução do esforço computacional e obtenção de soluções para redes reais; e
- iii. Comparação dos resultados alcançados a partir das metodologias utilizadas, verificando as contribuições para as decisões estratégicas à eletrificação do transporte de carga de longa distância.

Como contribuições à literatura acadêmica, esta tese busca apresentar: a) propostas de métodos que visam (direta e/ou indiretamente) a promoção de aspectos econômicos, ambientais e sociais no sistema logístico brasileiro; b) técnicas de otimização para problemas de localização de facilidades, apresentando-se tanto um planejamento logístico estratégico e integrado através da localização ótima de CILs quanto a eletrificação do modo rodoviário; c) abordagem heurística, contribuindo com métodos para solução de problemas matemáticos que envolvam instâncias reais de grande porte, com as quais os métodos exatos se tornam inviáveis; d) estratégia de redução de número de variáveis e de restrições em modelos baseados em rede espaço-temporal.

1.4 Organização da Tese

Esta tese está organizada em quatro capítulos, sendo esta introdução o primeiro. O Problema Multiperíodo de Localização de Centros de Integração Logísticos (PMLCIL) é apresentado e discutido no Capítulo 2 em cinco subdivisões: revisão da literatura, conjuntamente com a apresentação do Problema de Localização de CILs (Seção 2.1); descrição do modelo matemático proposto para o PMLCIL (Seção 2.2); apresentação da heurística baseada em Algoritmo Genético e da heurística baseada em Relaxação Linear (Seção 2.3); apresentação dos experimentos computacionais (Seção 2.4); e conclusões deste primeiro problema (Seção 2.5).

Já o Problema de Localização de Carregadores para caminhões elétricos de longa distância considerando Roteamento e a Jornada de Trabalho dos Motoristas (PLCRJTM) é apresentado e discutido no Capítulo 3 em cinco subdivisões: revisão da literatura (Seção 3.1); definição do problema e apresentação da metodologia de transformação da rede viária em rede de comunicação espaço-temporal (Seção 3.2); formulação matemática e estratégias metodológicas para a redução dos custos computacionais (Seção 3.3); experimentos computacionais (Seção 3.4); e conclusões deste segundo problema (Seção 3.5).

No Capítulo 4, apresenta-se as conclusões finais desta tese. Por fim, apresenta-se o referencial bibliográfico que fundamentou esta pesquisa e os apêndices com materiais complementares à leitura desta tese.

Capítulo 2

Problema Multiperíodo de Localização de Centros de Integração Logísticos (PMLCIL): modelagem e técnicas de otimização considerando critérios econômicos e ambientais

Neste capítulo, são apresentados e discutidos os fundamentos teóricos, a modelagem matemática e as técnicas de otimização para o Problema Multiperíodo de Localização de CILs (PMLCIL). O modelo proposto considera, simultaneamente, critérios econômicos e ambientais na otimização. Foram também propostas duas abordagens heurísticas para a solução do modelo matemático proposto, uma baseada em Algoritmo Genético e outra baseada em Relaxação Linear. Por fim, discute-se as instâncias do estudo de caso e os resultados dos experimentos computacionais.

2.1 Revisão da Literatura

Devido ao grande investimento de capital requerido para a implantação de uma nova facilidade ou modificação de uma já implementada, OWEN e DASKIN [21] destacam que se faz necessário que estas estruturas sejam rentáveis não somente no momento de sua abertura, mas também ao longo de sua vida útil operacional, mesmo que as tendências de mercado evoluam ou mudem os fatores ambientais e populacionais. Desta forma, torna-se interessante incorporar, nos Problemas de Localização de Facilidades (PLF), as incertezas e/ou variações futuras dos parâmetros dos modelos matemáticos, tornando-os aderentes à realidade e permitindo avaliar a dinâmica do problema e a evolução do sistema logístico em diferentes períodos de operação.

Desta forma, a formulação de modelos matemáticos multiperíodos para PLFs permitem cobrir decisões operacionais e estratégicas a partir da possibilidade de ajustes temporais dos parâmetros de entrada e até modelar problemas em que os resultados de um período impactam no comportamento dos períodos seguintes. As decisões destes modelos envolvem definir, para cada período de análise, a abertura e a alocação dos fluxos entre cada facilidade, além dos meios de transportes disponíveis.

A partir da literatura de PLFs, verificou-se que, de forma geral, os trabalhos abordam a incorporação de variações temporais dos parâmetros de oferta e demanda, bem como do sistema de transporte disponível nos modelos. Dependendo das especificidades do problema, podem ser observados, ainda: i) variação nos parâmetros de matéria prima, como disponibilidade e/ou sazonalidade (SANTIBAÑEZ-AGUILAR *et al.* [32], DOGAN e GOETSCHALCKX [33]); ii) incertezas nos dados de entrada (CORREIA *et al.* [34], MOHAMMED *et al.* [35], ZEBALLOS *et al.* [36], NICKEL *et al.* [37], BARON *et al.* [38]); iii) utilização do conceito de cadeia de Markov (SHEU e KUNDU [39]); iv) elasticidade da demanda em relação à características da oferta (CORREIA e MELO [40, 41], FATTAHI *et al.* [42], WANG *et al.* [43]) e; v) modelagem de produtos perecíveis (RAFIE-MAJD *et al.* [44]).

Complementarmente, observou-se abordagens matemáticas com decisões temporais pertinentes à: i) planejamento dos investimentos e origem de recursos (NICKEL *et al.* [37]); ii) possibilidade de abertura e fechamento das facilidades, podendo haver um custo ou não para isto (CANEL *et al.* [20], CORREIA e MELO [40, 41], WANG *et al.* [43], GHAREMANI-NAHR *et al.* [45], LU *et al.* [46], JENA *et al.* [47, 48], GELAREH *et al.* [49], THANH *et al.* [50], HINOJOSA *et al.* [51]); iii) dimensionamento e/ou modularidade da capacidade das facilidades (CORREIA *et al.* [34], CORREIA e MELO [40, 41], FATTAHI *et al.* [42], LU *et al.* [46], JENA *et al.* [47, 48], THANH *et al.* [50], MOGALE *et al.* [52], NEKOOGHADIRLI *et al.* [53], ALUMUR *et al.* [54], SHULMAN [55]; e iv) gestão de inventário (MOGALE *et al.* [52]).

A depender das características do estudo de caso e, conseqüentemente, das instâncias a qual deseja-se aplicar os PLFs, pode não haver dificuldade em lidar com os requisitos do sistema para obtenção de soluções ótimas, uma vez que os fatores e parâmetros muitas vezes são fixos e consistentes com o horizonte de planejamento. Assim, soluções ótimas podem ser obtidas por meio de *solvers* comerciais (ver, por exemplo, CORREIA *et al.* [34], NICKEL *et al.* [37], ALUMUR *et al.* [54]).

Sabe-se, no entanto, que os PLFs são classificados como NP-Difícil, ou seja, obter soluções ótimas em tempo polinomial pode não ser possível (OWEN e DASKIN [21], HINOJOSA *et al.* [51], KRARUP e PRUZAN [56]). Visando contornar as dificuldades enfrentadas pelos *solvers* matemáticos, principalmente na resolução de instâncias reais ou de grande porte, como é o caso de sistemas logísticos complexos, abordagens heurísticas têm sido cada vez mais utilizadas no contexto de localização

de facilidades. Cabe destacar que a decisão entre utilizar diretamente um *solver* comercial ou outras técnicas de otimização dependem, por exemplo, das características do modelo, do tamanho das instâncias do problema e da possibilidade de pré-processamentos.

Dentre as técnicas de otimização presentes na literatura de PLFs, tem-se abordagens heurísticas inspiradas em processos biológicos, como é o caso dos Algoritmos Genéticos (WANG *et al.* [43], MAURI *et al.* [57], SAEIDIAN *et al.* [58], AAR-DAL *et al.* [59], FERNANDES *et al.* [60], KAZAKOVTSEV e ANTAMOSHKIN [61], XIFENG *et al.* [62], ABOOLIAN *et al.* [63], WU *et al.* [64], ZHANG *et al.* [65], PIRKUL e JAYARAMAN [66]). Destes, apenas WANG *et al.* [43] abordaram um modelo multiperíodo. Neste, a codificação do cromossomo representa, para cada período e facilidade, a decisão de abertura ou fechamento (variável binária), a decisão de expansão ou não da capacidade (variável binária) e a quantidade de expansão modular. Para avaliação da aptidão dos indivíduos, os autores utilizaram um *solver* comercial.

Foram também observadas técnicas de relaxação lagrangiana ou linear para solução dos problemas multiperíodos de localização de facilidades (FATTAHI *et al.* [42], RAFIE-MAJD *et al.* [44], JENA *et al.* [47, 48], THANH *et al.* [50], HINO-JOSA *et al.* [51], SHULMAN [55], GHADERI [67], MELO *et al.* [68], THANH *et al.* [69], ALBAREDA-SAMBOLA *et al.* [70], CHARDAIRE *et al.* [71]). A utilização destas técnicas requerem uma etapa seguinte para tornar a solução relaxada em solução viável do problema em estudo ou aprimorar o resultado obtido. RAFIE-MAJD *et al.* [44], por exemplo, apresentaram uma abordagem baseada em relaxação lagrangiana e um algoritmo heurístico para tornar a solução relaxada em solução viável do problema. Já GHADERI [67] propuseram abordagens heurísticas baseadas em relaxação linear e um algoritmo híbrido baseado em busca de vizinhança variável para melhora da solução.

Observa-se que a literatura sobre PLFs é ampla e abrangente, abordando uma pluralidade de aplicações à problemas logísticos. No entanto, a literatura torna-se mais restrita acerca do tema de PLFs multiperíodo (WANG *et al.* [72]). Apesar de abranger uma variedade de parâmetros e ajustes metodológicos, as técnicas de otimização presentes na literatura são desenvolvidas para tornar os modelos aderentes à realidade de cada aplicação, tornando-os únicos e específicos para cada circunstâncias. Assim, embora existam estudos relevantes que exploram essa dimensão, a pesquisa sobre PLFs multiperíodos ainda oferece oportunidades significativas para inovação e desenvolvimento. Cabe destacar, ainda, que a literatura sobre o tema ainda carece de estudos voltados ao problema de localização-alocação multiperíodo de CILs. Tendo em vista este gargalo, propõe-se, neste estudo, investigar técnicas de otimização para o Problema Multiperíodo de localização de CILs.

2.1.1 O Problema de Localização de CILs

Diferentes planos e programas estaduais e federais de logística foram lançados ao longo das duas últimas décadas. Dentre eles, destaca-se o Plano Nacional de Logística e Transportes – PNLT, um plano plurianual, composto por matrizes de produção e atração para diversos produtos de consumo, bem como indicações sobre a atual infraestrutura e investimentos planejados para sua melhoria para o horizonte de 20 anos, ou seja, até 2031 após a última atualização (MT [1, 73, 74]). Estes planos já sinalizavam a necessidade de investimentos específicos na infraestrutura de transporte (ampliação ou implantação), além da necessidade de otimização das operações visando a multimodalidade e a intermodalidade em prol da eficiência econômica e operacional. Para que isto ocorra, faz-se necessária a implantação de estruturas de integração logística, como os CILs.

De acordo com COSTA [2], um CIL pode ser definido como uma estrutura de integração logística, ou plataforma terrestre, caracterizada pela oferta de serviços que buscam promover a otimização do transporte de mercadorias. Além disto, dependendo do nível de especialização e serviços ofertados, pode ser também definido como uma plataforma logística. Nestas estruturas, pode-se considerar as atividades de manipulação das cargas, armazenagem e despacho, tendo como principal função da instalação a concentração de pequenas cargas para a promoção do uso da intermodalidade ou redução de custo por ganho de escala de volume. Quando localizados próximos aos entroncamentos modais, os CILs podem ser dotados de infraestruturas capazes de permitir a integração entre os diferentes meios de transportes presentes na rede, incentivando a intermodalidade e a eficiência operacional, além da possibilidade de promover a utilização de meios de transportes com menores impactos ambientais. Neste contexto, visando a promoção da intermodalidade do transporte de cargas no Brasil, um importante projeto foi desenvolvido pelo Ministério da Infraestrutura (MT [22]) com o objetivo de propor uma metodologia para o Problema de Localização de CILs (PLCIL) de maneira a apoiar o desenvolvimento das políticas públicas voltadas para este setor.

A rede integrada de produção e distribuição do PLCIL possui três níveis, conforme esquematizado na Figura 2.1. O primeiro nível corresponde aos produtores das *commodities*. O segundo nível corresponde aos CILs que forem abertos e integrados à rede. Por fim, o terceiro nível corresponde aos consumidores. O transporte entre uma zona de produção e uma zona de consumo pode ser feito diretamente pelo modo rodoviário ou por meio de um CIL. No caso dos fluxos que passam pelo CIL, o transporte pode ser realizado de forma multimodal: o produto alcança a facilidade pelo modo rodoviário e, então, é distribuído até os consumidores por uma combinação intermodal (rodoviário, ferroviário, hidroviário e/ou cabotagem). Considera-se,

neste trabalho, o CIL como uma estrutura simplificada, onde se realiza apenas o transbordo dos produtos.

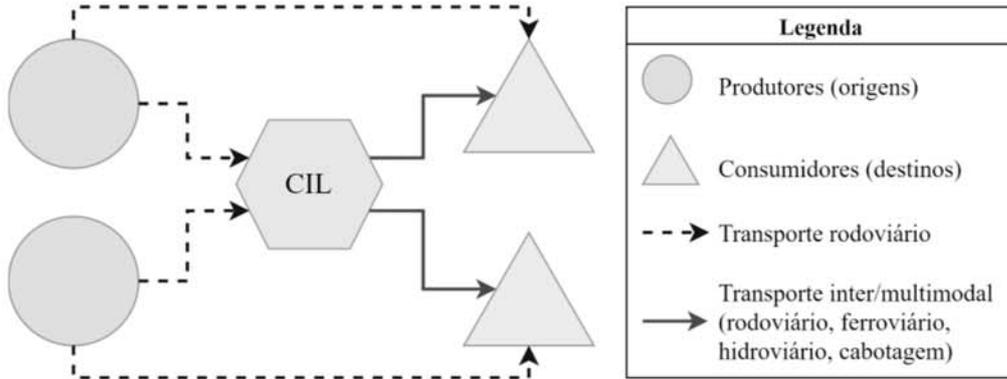


Figura 2.1: Estrutura simplificada da rede do problema de localização de CILs.

Discute-se a seguir os modelos matemáticos de localização-alocação de CILs presentes na literatura e que embasaram o desenvolvimento desta pesquisa. Embora estes modelos permitam fluxos diretos entre as origens e destinos, estas modelagens generalizam o problema de localização de facilidades capacitado multiproduto e multicamada. Os modelos matemáticos podem ser consultados no Apêndice A.

O primeiro modelo matemático aderente ao contexto da localização-alocação de CILs foi proposto por COSTA [2] (ver Apêndice A.1). Em Programação Linear Inteira Mista (PLIM), este modelo tem por objetivo identificar, quantificar e localizar os CILs de forma a minimizar os custos de transportes entre as zonas de produção e de consumo de diferentes produtos, considerando a integração modal e os investimentos necessários, levando-se em consideração as seguintes premissas:

- Os CILs a serem instalados são selecionados a partir de um conjunto de candidatos pré-definidos;
- Um candidato a CIL somente será aberto e utilizado por um produtor caso resulte em redução do custo total de transporte. Ou seja, se o candidato a CIL não beneficiar nenhum produtor, este não deverá ser aberto; e
- Há uma capacidade mínima e máxima para abertura do CIL, para que se garanta a viabilidade econômica da estrutura. Assim, um CIL só será aberto quando a soma dos volumes de carga que passarem por ele estiver compreendida entre estes limitantes.

O modelo proposto foi avaliado pela autora utilizando-se como instância o transporte da soja em grãos, farelo de soja, milho e açúcar produzidos no Brasil. Para estas instâncias, o modelo pôde ser resolvido por método exato, utilizando-se um *solver* comercial. No entanto, da forma que foi estruturado, este modelo considera os

CILs como pontos concentradores de cargas, isto é, recebendo produtos de diversos pontos produtores e enviando-os para outros pontos consumidores, sem considerar parâmetros contratuais de relação entre produtores e consumidores. Desta forma, o objetivo do modelo consiste no atendimento das demandas totais das zonas de consumo (destino), independente da origem das *commodities*. Segundo GUIMARÃES [8], tendo em vista o modelo econômico neoliberal, esta abordagem não representa a realidade econômica do país, em que há relações contratuais entre clientes e fornecedores que precisam ser consideradas para atendimento dos fluxos de *commodities*. Portanto, devido às exigências contratuais de comercialização destes produtos, tem-se a necessidade de reavaliar o atendimento da demanda par-a-par na modelagem matemática de localização-alocação de CILs.

De acordo com GUIMARÃES [3], entende-se por demanda par-a-par quando respeitada a relação comercial entre uma zona de consumo que demanda certo produto de uma zona de produção específica. Ou seja, a demanda não poderá ser atendida por outra zona de produção, ainda que os produtos sejam homogêneos e isso proporcione redução dos custos totais. Neste contexto, GUIMARÃES [8] apresentou adequações ao modelo matemático proposto por COSTA [2] visando garantir o atendimento das demandas par-a-par, resultando no modelo matemático apresentado no Apêndice A.2.

GUIMARÃES [8] propõe, ainda, duas restrições que podem ser adicionadas ao modelo: a primeira permite limitar os investimentos financeiros em abertura de CILs, devido à restrições orçamentárias; já a segunda permite limitar a quantidade de CILs abertos, não por questões orçamentárias, mas por definições prévias de número máximo de estruturas que se deseja instalar. A validação deste modelo ocorreu utilizando-se as mesmas instâncias e parâmetros aplicados por COSTA [2], também sendo resolvido por método exato (*solver* comercial).

Os modelos matemáticos até então apresentados na literatura para o PLCIL são classificadas como estáticos ou determinísticos (OWEN e DASKIN [21], BALLOU [75]), nos quais todas as informações de entrada (como demandas, distâncias e tempos de viagem) são valores conhecidos e fixados, enquanto as saídas são variáveis de decisão especificadas para um determinado momento e ocasião. Embora os resultados destes modelos possam orientar tomadores de decisão, estes não são capazes de avaliar variações temporais nas informações inerentes à tomada de decisões em problemas reais. Por outro lado, os problemas multiperíodos transformam modelos instantâneos de decisões pontuais em modelos que capturam os aspectos temporais das instâncias. Ou seja, permitem o planejamento de localização abordando, conjuntamente, dados de diversos períodos. CANEL *et al.* [20] aponta a importância dos modelos multiperíodos para estudos da expansão de capacidade dos sistemas e para empresas que enfrentam mudanças nas condições de mercado ou esperam que

custos relevantes mudem ao longo do tempo. Desta forma, uma vez que o horizonte de planejamento é estendido para mais de um período, podem envolver decisões sobre quantas instalações abrir, onde localizá-las e como alocar a produção de cada instalação em cada período (localização-alocação).

Neste contexto, também a partir do modelo de GUIMARÃES [8] e de suas características previamente estabelecidas, MT [22] apresentou um modelo matemático multiperíodo para a localização de CILs, capaz de prever o momento em que um CIL será aberto em uma escala temporal minimizando-se os custos logísticos totais (conforme apresentado no Apêndice A.4). Para isto, foi inserido um novo índice no modelo, de forma a discretizar temporalmente cada uma das variáveis, coeficientes e constantes do modelo. Além disso, as restrições do modelo garantem que cada candidato a CIL seja aberto apenas em um período, mantendo-se aberto nos períodos subsequentes. No entanto, apesar de ter sido proposto, este modelo não foi aplicado e avaliado a um estudo de caso devido a sua alta complexidade.

Os modelos matemáticos anteriormente apresentados consideram, como objetivo, a minimização apenas dos custos logísticos através da intermodalidade promovida a partir da instalação de CILs, como os custos de transporte (direto e através de um CIL), de transbordo, de abertura e operação das facilidades. No entanto, sabe-se que, além dos custos logísticos, a promoção da intermodalidade em um sistema de transportes pode resultar ainda em benefícios socioambientais, como na redução de emissões de poluentes atmosféricos, de ruídos sonoro e até mesmo de acidentes.

Neste contexto, visando contribuir na produção científica de modelos mais sustentáveis, ainda que por meio de impactos ambientais isolados, GUIMARÃES [3] propôs um novo modelo matemático que considera, no processo de otimização, tanto os custos logísticos (transporte, transbordo, abertura e operação de CILs), quanto os custos associados à emissão de CO_2 relacionados ao transporte do produto (modo rodoviário, se direto; ou multimodal, quando através de CILs). As emissões ambientais são expressas em valores monetários, uma vez que as emissões podem ser taxadas (como, por exemplo, através de políticas de *carbon tax*). De acordo com a autora, a opção de abordar a emissão de CO_2 decorreu da identificação de que este impacto é o mais recorrente nos estudos sobre o tema, além de ser o foco de acordo e tratados internacionais destinados à proteção do meio ambiente, como o Acordo de Paris, e devido ao fato do transporte ser uma das principais fontes de emissão antrópica deste gás. Cabe destacar que o modelo respeita a demanda par-a-par imposta pela matriz OD e não considera as emissões provenientes da abertura e operação das estruturas de integração, tendo em vista que a única atividade nela desenvolvida é o transbordo. A função objetivo possui, ainda, pesos associados aos custos logísticos e ambientais, que podem ser utilizados para definir o grau de importância de cada termo no processo de planejamento do setor. Este modelo é composto, ainda, por

restrições que limitam as emissões de CO_2 , permitindo avaliar políticas de *carbon cap* mesmo considerando o preço de emissão igual a zero.

Portanto, evidencia-se a necessidade de contribuição ao estado da arte dos Problemas de Localização de CILs a partir do desenvolvimento e avaliação de um modelo matemático multiperíodo que considere, na otimização, tanto aspectos econômicos quanto ambientais. O modelo deve abordar as complexidades operacionais resultantes da abertura de facilidades em diferentes períodos de análise, respeitando-se as restrições já impostas pelos modelos presentes na literatura, como o atendimento demanda par-a-par. Visando contornar as dificuldades decorrentes da complexidade do modelo multiperíodo na busca por soluções para instâncias reais e de grande porte, faz-se também importante contribuições relacionadas às técnicas de otimização para o problema em questão.

2.2 Formulação Matemática

A estrutura conceitual do modelo matemático capacitado, mono-objetivo e multiperíodo para localização de CILs é apresentada na Figura 2.2. O modelo proposto é de localização-alocação, pois não vislumbra apenas a localização ótima para a abertura das facilidades, mas também busca otimizar a alocação dos fluxos OD nos CILs para os diferentes períodos de tempo analisados. Na alocação dos fluxos, a demanda par a par imposta por uma matriz origem-destino (OD) é respeitada.

A característica de multiperíodo do modelo permite considerar a variação temporal dos parâmetros de entrada, como a demanda, custos, distâncias e, até mesmo, a disponibilidade de modos de transporte no sistema logístico. Como consequência, introduz ao modelo a possibilidade de adaptação temporais das decisões (localização e alocação dos fluxos) em consonância com as variações desses parâmetros.

Em suma, para utilização do modelo, assume-se que os seguintes parâmetros são conhecidos para cada período e fornecidos como dados de entrada: a matriz de demanda e consumo dos produtos a serem distribuídos; a quantidade de zonas candidatas a CIL e suas capacidades; os custos operacionais e os fatores de emissão dos diferentes tipos de transportes presentes na rede logística; os custos de abertura (fixos) e de operação (variáveis) dos candidatos a CIL; os custos de transbordo das cargas nos CILs; e a precificação da emissão de CO_2 .

O modelo matemático proposto é expresso por (2.1) a (2.11). Os conjuntos e índices utilizados no modelo matemático são apresentados na Tabela 2.1, enquanto que as variáveis de decisão e os parâmetros são apresentados, respectivamente, nas Tabelas 2.2 e 2.3. Neste modelo, proposto em Programação Linear Inteira Mista, os custos logísticos (transporte, investimento e operação) e os custos de emissões de CO_2 são simultaneamente minimizados.

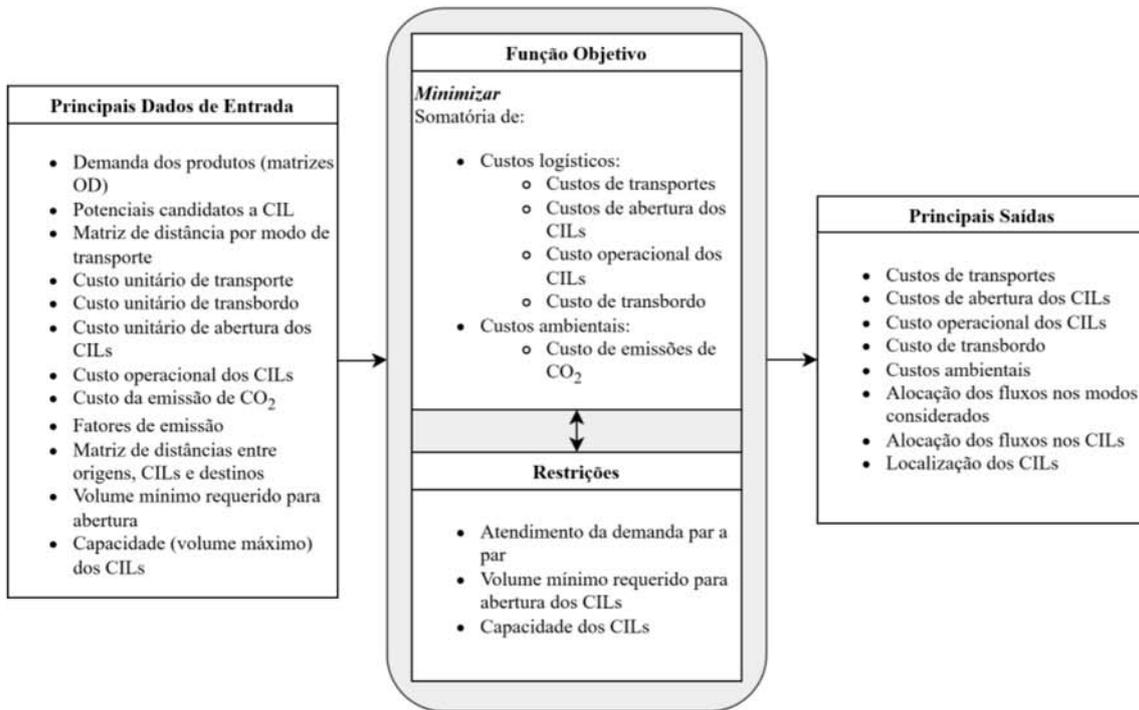


Figura 2.2: Estrutura conceitual do modelo matemático multiperíodo proposto.

Tabela 2.1: Conjuntos e índices.

Notação	Descrição
T	Conjunto de períodos (ou horizontes) de análise, onde $t \in T$
P	Conjunto de produtos, onde $p \in P$
I	Conjunto de zonas de produção, onde $i \in I$
J	Conjunto de zonas de demanda, onde $j \in J$
K	Conjunto de zonas candidatas a CILs, onde $k \in K$
M_{tpij}^{dir}	Conjunto de modos de transportes m disponíveis no período $t \in T$ para o transporte do produto $p \in P$ diretamente de uma zona de produção $i \in I$ para uma zona de consumo $j \in J$
M_{tpik}^{ent}	Conjunto de modos de transportes m disponíveis no período $t \in T$ para o transporte do produto $p \in P$ de uma zona de produção $i \in I$ para um CIL $k \in K$
M_{tpkj}^{sai}	Conjunto de modos de transportes m disponíveis no período $t \in T$ para o transporte do produto $p \in P$ de um CIL $k \in K$ para uma zona de consumo $j \in J$

Tabela 2.2: Variáveis de decisão.

Notação	Descrição
x_{tpijm}^{dir}	Volume do produto $p \in P$ transportado diretamente entre $i \in I$ e $j \in J$ por um modo $m \in M_{tij}^{dir}$ (sem passar por um CIL) no período $t \in T$
x_{tpikm}^{ent}	Volume do produto $p \in P$ transportado entre $i \in I$ e o candidato a CIL $k \in K$ por um modo de transporte $m \in M_{tik}^{ent}$ (volume de entrada no CIL) no período $t \in T$
x_{tpkjm}^{sai}	Volume do produto $p \in P$ transportado entre o candidato a CIL $k \in K$ e $j \in J$ por um modo de transporte $m \in M_{tkj}^{sai}$ (volume de saída do CIL) no período $t \in T$
z_{tk}	Variável que indica a abertura (1) ou não (0) do CIL $k \in K$ no período $t \in T$
y_{tpikj}	Volume total do produto $p \in P$ transportado de $i \in I$ para $j \in J$ que utiliza o candidato a CIL $k \in K$ no período $t \in T$ (esta variável garante que as matrizes OD serão respeitadas, isto é, as demandas par-a-par serão atendidas)

Tabela 2.3: Parâmetros.

Notação	Descrição
C_{tpijm}^{dir}	Custo unitário de transporte do produto $p \in P$ a partir de uma zona de produção $i \in I$ diretamente para uma zona de consumo $j \in J$, por um modo de transporte $m \in M_{tpij}^{dir}$ (sem passar por um CIL) no período $t \in T$
C_{tpikm}^{ent}	Custo unitário de transporte do produto $p \in P$ a partir de uma zona de produção $i \in I$ para um CIL $k \in K$, por um modo de transporte $m \in M_{tpik}^{ent}$ no período $t \in T$
C_{tpkjm}^{sai}	Custo unitário de transporte do produto $p \in P$ a partir de um CIL $k \in K$ para uma zona de demanda $j \in J$, por um modo de transporte $m \in M_{tpkj}^{sai}$ no período $t \in T$
CT_{tpkjm}^{sai}	Custo de transbordo do produto $p \in P$ em um CIL $k \in K$ com destino a uma zona de demanda $j \in J$, por um modo de transporte $m \in M_{tpkj}^{sai}$ no período $t \in T$
C_{CO_2}	Custo associado às emissões de CO_2
g_{tk}	Custo de abertura de um candidato a CIL $k \in K$ no período $t \in T$
δ_{tpk}	Custo operacional de utilização do candidato a CIL $k \in K$ no período $t \in T$ para o produto $p \in P$
v_{tk}^{min}	Volume mínimo requerido para abertura do candidato a CIL $k \in K$ no período $t \in T$
v_{tk}^{max}	Capacidade máxima do candidato a CIL $k \in K$ no período $t \in T$
d_{tpij}	Volume do produto $p \in P$ produzido na zona $i \in I$ para atender a demanda na zona $j \in J$ (matriz O/D) no período $t \in T$
$f e_m$	Fator de emissão do combustível usado pelo modo de transporte $m \in M_{tpij}^{dir}$, $m \in M_{tpik}^{ent}$ e $m \in M_{tpkj}^{sai}$
dt_{tijm}	Distância percorrida pelo modo de transporte $m \in M_{tpij}^{dir}$ entre as zonas de produção $i \in I$ e consumo $j \in J$ no período $t \in T$
dt_{ikm}	Distância percorrida pelo modo de transporte $m \in M_{tpik}^{ent}$ para o transporte da soja entre a zona de produção $i \in I$ e o candidato a CIL $k \in K$ no período $t \in T$
dt_{kjm}	Distância percorrida pelo modo de transporte $m \in M_{tpkj}^{sai}$ para o transporte da soja entre o candidato a CIL $k \in K$ e a zona de consumo $j \in J$
α	Peso associado aos custos logísticos
β	Peso associado aos custos de emissões de CO_2

$$\begin{aligned}
\text{Minimize } \alpha \left[\mathcal{Z}(C_{\log.}) = & \sum_{t \in T} \sum_{p \in P} \sum_{i \in I} \sum_{j \in J} \sum_{m \in M_{tpij}^{dir}} C_{tpijm}^{dir} x_{tpijm}^{dir} \right. \\
& + \sum_{t \in T} \sum_{p \in P} \sum_{i \in I} \sum_{k \in K} \sum_{m \in M_{tpik}^{ent}} C_{tpikm}^{ent} x_{tpikm}^{ent} \\
& + \sum_{t \in T} \sum_{p \in P} \sum_{k \in K} \sum_{j \in J} \sum_{m \in M_{tpkj}^{sai}} C_{tpkjm}^{sai} x_{tpkjm}^{sai} \\
& + \sum_{t \in T} \sum_{k \in K} g_{tk} z_{tk} \\
& \left. + \sum_{t \in T} \sum_{p \in P} \sum_{k \in K} \sum_{j \in J} \sum_{m \in M_{tpkj}^{sai}} x_{tpkjm}^{sai} (\delta_{tpk} + CT_{tpkjm}^{sai}) \right] \\
+ \beta C_{CO_2} \left[\mathcal{Z}(\text{emiss.}) = & \sum_{t \in T} \sum_{p \in P} \sum_{i \in I} \sum_{j \in J} \sum_{m \in M_{tpij}^{dir}} f e_m dt_{tpijm} x_{tpijm}^{dir} \right. \\
& + \sum_{t \in T} \sum_{p \in P} \sum_{i \in I} \sum_{k \in K} \sum_{m \in M_{tpik}^{ent}} f e_m dt_{tpikm} x_{tpikm}^{ent} \\
& \left. + \sum_{t \in T} \sum_{p \in P} \sum_{k \in K} \sum_{j \in J} \sum_{m \in M_{tpkj}^{sai}} f e_m dt_{tpkjm} x_{tpkjm}^{sai} \right] \quad (2.1)
\end{aligned}$$

Sujeito a:

$$\sum_{m \in M_{tpij}^{dir}} x_{tpijm}^{dir} + \sum_{k \in K} y_{tpikj} = d_{tpij} \quad \forall t \in T, p \in P, i \in I, j \in J \quad (2.2)$$

$$\sum_{i \in I} y_{tpikj} = \sum_{m \in M_{tpkj}^{sai}} x_{tpkjm}^{sai} \quad \forall t \in T, p \in P, k \in K, j \in J \quad (2.3)$$

$$\sum_{j \in J} y_{tpikj} = \sum_{m \in M_{tpik}^{ent}} x_{tpikm}^{ent} \quad \forall t \in T, p \in P, i \in I, k \in K \quad (2.4)$$

$$\sum_{t \in T} z_{tk} \leq 1 \quad \forall k \in K \quad (2.5)$$

$$v_{tk}^{\min} \sum_{\theta=1}^t z_{\theta k} \leq \sum_{p \in P} \sum_{i \in I} \sum_{m \in M_{tpik}^{ent}} x_{tpikm}^{ent} \leq v_{tk}^{\max} \sum_{\theta=1}^t z_{\theta k} \quad \forall t \in T, k \in K \quad (2.6)$$

$$x_{tpijm}^{dir} \geq 0 \quad \forall t \in T, p \in P, i \in I, j \in J, m \in M_{tpij}^{dir} \quad (2.7)$$

$$x_{tpikm}^{ent} \geq 0 \quad \forall t \in T, p \in P, i \in I, k \in K, m \in M_{tpik}^{ent} \quad (2.8)$$

$$x_{tpkjm}^{sai} \geq 0 \quad \forall t \in T, p \in P, k \in K, j \in J, m \in M_{tpkj}^{sai} \quad (2.9)$$

$$y_{tpikj} \geq 0 \quad \forall t \in T, p \in P, i \in I, k \in K, j \in J \quad (2.10)$$

$$z_{tk} \in \{0, 1\} \quad \forall t \in T, k \in K \quad (2.11)$$

O primeiro termo da Função Objetivo (2.1) ($\mathcal{Z}(C_{\logisticos})$) busca minimizar o custo logístico da rede (transporte e operação) por meio da alocação dos fluxos di-

retamente entre as zonas de produção e consumo ou passando pelos CILs que forem abertos. Para os CILs abertos, são considerados os custos de abertura, operacionais, transporte e de transbordo. Já o segundo termo ($C_{CO_2}Z(\text{emissoes})$) busca minimizar os custos de emissão de CO_2 relacionados ao transporte do produto (modo rodoviário, se direto; ou multimodal, quando utilizando os CILs). As emissões ambientais são expressas em valores monetários, uma vez que as emissões podem ser taxadas (como, por exemplo, por políticas de *carbon taxes*). O modelo não considera as emissões provenientes da abertura e operação das estruturas de integração, tendo em vista que a única atividade nela desenvolvida é o transbordo. A Função Objetivo possui os pesos α e β associados, respectivamente, aos custos logísticos e ambientais. Estes pesos podem ser utilizados para definir o grau de importância de cada termo no processo de planejamento do setor de transporte. O peso β pode ser também modelado como complemento de α , por exemplo, a partir da expressão $\beta = 1 - \alpha$, como utilizado na análise de Pareto apresentada na Seção 2.4.4.

As Restrições (2.2) garantem que, para cada recorte temporal, a demanda total entre cada par O/D será atendida. As Restrições (2.3) e (2.4) impõem que, para cada recorte temporal, todo o volume de um produto que deixa uma zona de produção e destina-se a uma zona de consumo passando por um CIL deve ser exatamente igual ao volume total deste produto entrando e saindo do CIL. As Restrições (2.2), (2.3) e (2.4) garantem, juntas, que as demandas par-a-par sejam respeitadas em cada período. As Restrições (2.5) impõem que um candidato a CIL só pode ser aberto uma única vez (em um único período). As Restrições (2.6) impõem um volume mínimo para abertura de um candidato a CIL e uma capacidade máxima quando aberto. Estas restrições estabelecem que, após aberto, o candidato a CIL permanece com operações nos períodos subsequentes. Assume-se que as regiões candidatas a implantação de CILs selecionadas para abertura iniciam a operação de imediato no início do período. As Restrições (2.7)-(2.11) estão relacionadas ao domínio das variáveis de decisão.

2.3 Técnicas de Otimização para o PMLCIL

Visando contornar as dificuldades enfrentadas pelos *solvers* matemáticos na resolução de instâncias de grande porte, apresenta-se, nesta seção, duas abordagens heurísticas para o PMLCIL. Estas estratégias são baseadas nos conceitos dos algoritmos genéticos, heurística gulosa e relaxação linear.

2.3.1 Heurística baseada em Algoritmo Genético

Um Algoritmo Genético (AG) é uma heurística de busca utilizada em otimização para encontrar soluções aproximadas em um tempo computacional razoável. Inspirado na teoria da evolução de Darwin, foi proposto inicialmente por HOLLAND [76] e transporta os conceitos de genética para a exploração do espaço de soluções. Buscam combinar a sobrevivência dos indivíduos mais aptos com uma troca de informações estruturada, porém aleatória, das informações genéticas.

Destaca-se as seguintes vantagens dos AGs em relação aos demais processos de otimização e busca (GOLDBERG [77], WIRSANSKY [78]): capacidade de lidar com problemas com representação matemática complexa; capacidade de otimização global, ao realizar a busca a partir de uma base diversificada de pontos (indivíduos) de forma simultânea, convergindo aos locais mais adaptados, reduzindo a probabilidade de convergência para mínimos locais em comparação aos métodos que realizam buscas a partir de um único ponto; suporte para processamento paralelo e distribuído e; possibilidade de aprendizado contínuo.

Por outro lado, dentre as limitações dos AGs, pode-se destacar a necessidade de calibragem dos hiperparâmetros, como o tamanho da população e taxas de probabilidade de mutação; operações computacionalmente intensivas, principalmente ao trabalhar com populações potencialmente grandes, além da natureza repetitiva dos AGs, e; se a aptidão de um indivíduo for muito maior do que o resto da população, pode ocorrer convergência da população para esta solução, levando o algoritmo genético a ficar prematuramente preso em um máximo ou mínimo local, ao invés de encontrar o global.

Neste contexto, foi desenvolvida uma metaheurística evolutiva para o PMLCIL, estruturada a partir dos conceitos dos AGs e complementada por uma abordagem heurística gulosa e construtiva para a avaliação da aptidão dos indivíduos. A estrutura do AG proposto para o PMLCIL é apresentado no Algoritmo 1 e na Figura 2.3.

Descreve-se, nesta seção, as definições especiais do AG para o problema proposto, conforme segue (em parênteses, identifica-se as etapas a partir do Algoritmo 1):

- Codificação do cromossomo (anterior à implementação do Algoritmo 1);
- Avaliação da aptidão – *fitness* (linhas 7 e 24);
- Criação da população inicial (linhas 2 a 6);
- Elitismo e redefinição do conjunto Não Elite \mathcal{NE} (linhas 9 a 13);
- Plano de reprodução: operadores de seleção, recombinação (*crossover*), mutação e máscaras de viabilidade (linhas 14 a 23); e
- Próxima geração (linhas 25 a 27) e critérios de parada (linha 8).

Algoritmo 1: Algoritmo Genético proposto para o PMLCIL.

Entrada: Parâmetros dos cenários, tamanho da população ($PopSize$)

```
1 início
2   {Criação da População Inicial  $pop_0$ }
3   Cria vetor com indivíduos relaxados ( $relaxInd$ )
4    $pop_0 \leftarrow relaxInd$ 
5   enquanto  $pop_0 < popSize$  faça
6     | Adiciona indivíduo aleatório na população  $pop_0$ 
7   Avalia a aptidão dos indivíduos presentes na  $pop_0$ 
8   enquanto Critérios de Parada faça
9     | {Elitismo}
10    | Cria os conjuntos Elite ( $\mathcal{E}$ ) e Não Elite ( $\mathcal{NE}$ )
11    | {Redefinição da população}
12    | se  $\mathcal{NE} < 15\% \times PopSize$  então
13      | | Redefinição da população
14    | {Cruzamento}
15    | enquanto Descendentes ( $\mathcal{D}$ )  $< PopSize$  faça
16      | |  $ind_E \leftarrow Seleção(\mathcal{E})$ 
17      | |  $ind_{NE} \leftarrow Seleção(\mathcal{NE})$ 
18      | | {Recombinação (crossover)}
19      | |  $[descendente_1, descendente_2] \leftarrow Recombinação(ind_E, ind_{NE})$ 
20      | | para cada  $descendente \in [descendente_1, descendente_2]$  faça
21        | | | se Probabilidade de mutação é satisfeita então
22          | | | | Mutação(descendente)
23      | |  $\mathcal{D} \leftarrow [descendente_1, descendente_2]$ 
24    | Avalia a aptidão de todos descendentes  $\in \mathcal{D}$ 
25    | {Próxima geração}
26    |  $pop_{g+1} \leftarrow \mathcal{E}$  enquanto  $pop_{g+1} < PopSize$  faça
27      | |  $pop_{g+1} \leftarrow Seleção(\mathcal{D} \cup \mathcal{NE})$ 
28  retorna Melhor cromossomo (menor valor de aptidão)
```

a. Codificação do cromossomo

A codificação do problema através da configuração do cromossomo é um ponto importante para a implementação dos AGs e visa representar, no formato de cromossomo, as soluções candidatas para um problema de otimização. De forma sintética, as decisões do PMLCIL consistem em, para cada período analisado, definir a localização de CILs e realizar a alocação dos fluxos de produtos transportados diretamente entre cada par OD ou passando por um CIL. Ao serem definidas as variáveis que indicam a localização das facilidades, o problema pode ser reduzido à um problema de alocação de fluxos por minimização de custos (logísticos e de emissões de CO_2). Neste contexto, a codificação do cromossomo deve representar as variáveis de localização z_{tk} , restando a alocação dos fluxos para a etapa de avaliação da aptidão.

Embora a variável escolhida para ser representada pelo cromossomo seja binária, em concordância com as definições tradicionais dos AGs, esta possui dois índices de referência, que indicam os conjuntos de períodos de análise ($t \in T$) e de zonas candidatas a CIL ($k \in K$). Dessa forma, a variável z_{tk} pode ser representada por

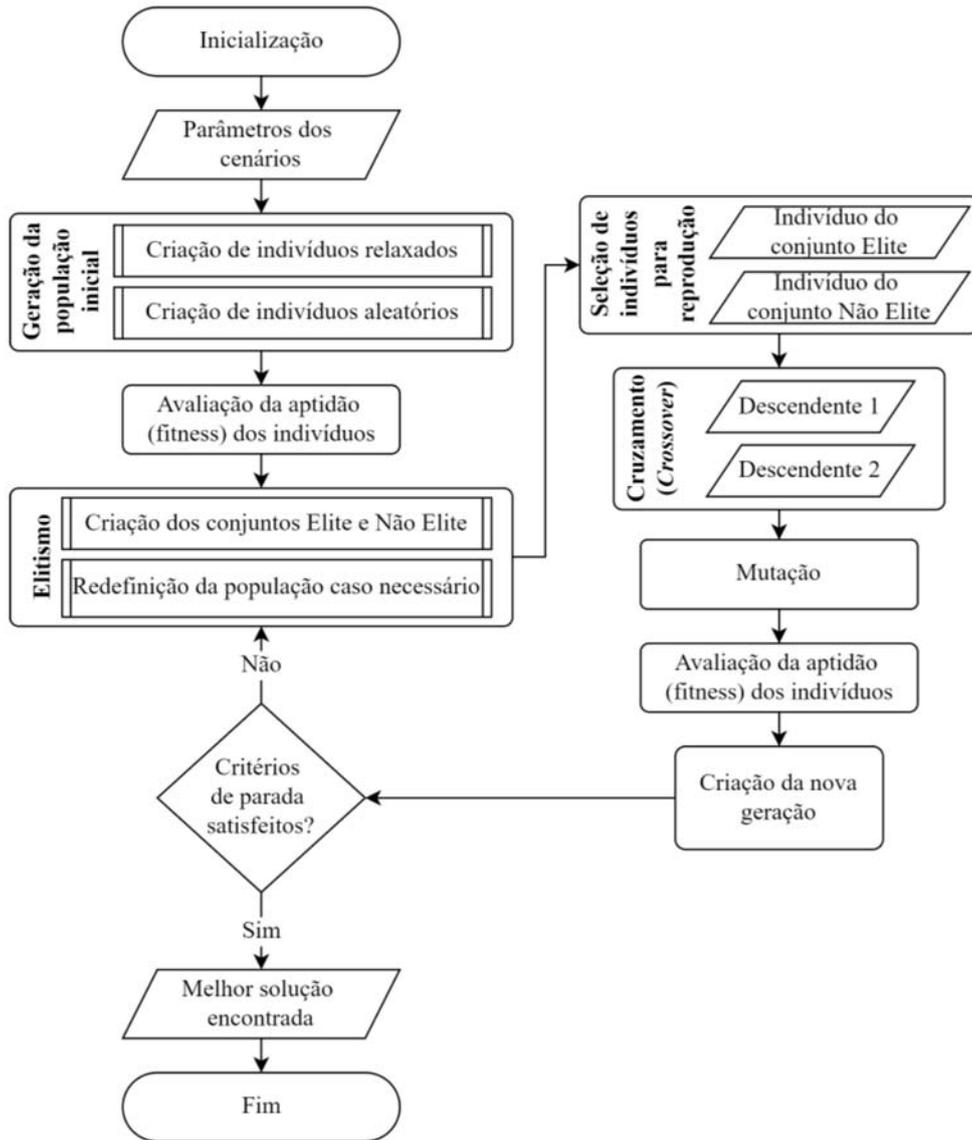


Figura 2.3: Estrutura do Algoritmo Genético proposto para o PMLCIL.

uma matriz de tamanho $T \times K$, o que pode dificultar a aplicação dos procedimentos genéticos ou até mesmo exigir maiores custos computacionais para a manipulação e armazenamento de grandes populações, uma vez que cada indivíduo de uma população é representado por um cromossomo.

Com o objetivo de reduzir o tamanho do cromossomo, considerou-se um genótipo em formato de vetor, onde cada gene (posição no cromossomo) representa um candidato a CIL ($k \in K$), conforme ilustrado na Figura 2.4. Neste caso, os alelos h_k são representados por números inteiros $h_k \in \mathbb{Z} : 0 \leq h_k \leq |T|$, onde o valor zero indica que o candidato não é selecionado para localização e os demais números positivos inteiros designam o período de análise a partir do qual aquele CIL deve ser considerado em operação ($1 \leq h_k \leq |T|$). Cabe destacar que a operação tem início no começo do período e assim se mantém, ou seja, não é permitido que as facilidades sejam fechadas após terem suas operações iniciadas.

Cromossomo:	h_1	h_2	h_3	h_4	\dots	$h_{ K -2}$	$h_{ K -1}$	$h_{ K }$
Candidato a CIL ($k \in K$):	1	2	3	4	\dots	$ K -2$	$ K -1$	$ K $

Figura 2.4: Estrutura do vetor de codificação do cromossomo.

A Figura 2.5 ilustra parte da codificação de um cromossomo para um problema composto por um conjunto de 80 candidatos a CILs e quatro períodos de análise. Cada gene representa um candidato a CIL ($k \in \{1, 80\}$), enquanto o alelo indica se o CIL foi considerado ou não para operação ($h_k = t \in \{0, 4\}$). Nesse exemplo, os candidatos a CIL $k = 3$ e $k = 79$ possuem início de operação no primeiro período ($h_k = 1$). Os candidatos $k = 1$ e $k = 4$ seriam abertos, respectivamente, no segundo ($h_1 = 2$) e quarto períodos ($h_4 = 4$). Já os candidatos $k = 2$, $k = 78$ e $k = 80$ não são considerados para abertura em nenhum período ($h_k = 0$).

Cromossomo:	2	0	1	4	\dots	0	1	0
Candidato a CIL ($k \in K$):	1	2	3	4	\dots	78	79	80

Figura 2.5: Exemplo de codificação do cromossomo.

b. Aptidão do cromossomo (*Fitness*)

A função de aptidão, ou *fitness*, tem por objetivo aferir o desempenho do cromossomo de acordo com o problema avaliado, ou seja, aponta para o valor da Função Objetivo. Diz-se que um indivíduo está adaptado ou apto quando seu valor de aptidão se aproxima da solução ótima do problema ou apresenta a melhor solução em comparação às presentes na população. Além disso, como na dinâmica da evolução natural darwinista, a aptidão pode ser associada à habilidade de um indivíduo em competir com os outros indivíduos da população e sobreviver. Assim, este resultado é de grande importância para os algoritmos genéticos e todos os indivíduos (desde a população inicial até os resultantes da aplicação dos operadores genéticos) devem ter sua aptidão avaliada.

Considerando a Função Objetivo (2.1) e dado o cromossomo com a solução das variáveis de localização z_{tk} , tem-se que o problema inicial de localização-alocação pode ser reduzido à um problema de alocação de fluxos por minimização de custos, restando solucionar as variáveis de decisão x_{tjkm}^{dir} , x_{tikm}^{ent} , x_{tkjm}^{sai} e y_{tikj} .

Como todos os indivíduos de todas as gerações do AG devem ter sua aptidão avaliada, o tempo requerido para aplicação de *solvers* comerciais impacta diretamente no tempo computacional do AG. Visando reduzir este impacto, propõem-se, neste trabalho, uma heurística construtiva com estratégia gulosa e determinística

para a alocação dos fluxos dos produtos na rede em cada período de análise, visando a redução dos custos totais e respeitando as restrições impostas pelo modelo. O procedimento heurístico proposto é apresentado no Algoritmo 2 e na Figura 2.6.

O primeiro passo consiste em avaliar a viabilidade do cromossomo quanto à restrição de volume mínimo para a abertura do candidato a CIL (Restrição (2.6)). As viabilidade das soluções são derivadas dos parâmetros de entrada do modelo (ver Tabela 2.3). A razão entre os parâmetros volume de produtos a ser transportado em cada período (d_{tij}) e do volume mínimo requerido para a abertura de um candidato a CIL em cada período (v_{tk}^{min}) limita a quantidade total de CILs que podem estar abertos em cada período. O vetor contendo a quantidade máxima de CILs que podem ser abertos em cada período respeitando-se o volume mínimo é representado por $MaxCILs_T$.

Caso o cromossomo represente, em qualquer período, quantidade de CILs superior ao valor indicado em $MaxCILs_T$, a solução é considerada inviável. Para este caso, duas abordagens podem ser aplicadas: utilizar máscaras de viabilidade para tornar a solução viável (como será discutido adiante) ou, por se tratar de um problema de minimização, atribuir o valor infinito para o *fitness*. Por outro lado, caso o cromossomo represente uma solução viável, parte-se para a etapa de alocação dos fluxos.

Visando respeitar as restrições de demanda par-a-par, a alocação dos fluxos é realizada individualmente para cada par Origem-Destino (i, j). Uma vez calculados os custos logísticos e de emissões para cada arco da rede, todo o fluxo de cada par OD é alocado na ligação de menor custo (abordagem gulosa), seja ela por arco direto (x_{tijn}^{dir}) ou através de um CIL (x_{tikm}^{ent} e x_{tkjm}^{sai}).

Posteriormente, verifica-se o atendimento à restrição de capacidade das facilidades (v_{tk}^{max}): caso alguma facilidade tenha sua capacidade extrapolada, até que a restrição seja respeitada, os fluxos excedentes são realocados para os arcos que acrescentam menor valor de custo à solução. Por fim, verifica-se o atendimento ao volume mínimo nos CILs (v_{tk}^{min}): caso algum CIL não tenha recebido o volume mínimo requerido para abertura, até que a restrição seja respeitada, os fluxos não passantes por esta facilidade são realocados para os arcos que passam por este CIL, respeitando-se os menores acréscimos no custo total. Neste processo, foram incluídos controles para evitar que este manejo de fluxos entre arcos pudesse extrapolar novamente a capacidade de cada facilidade (condição anteriormente avaliada). A validação do desempenho da abordagem gulosa proposta para o cálculo de aptidão dos indivíduos é apresentado no Apêndice E.

Algoritmo 2: Avaliação da aptidão de um cromossomo (*fitness*)

Entrada: cromossomo, matriz OD, matriz de custos

```
1 início
2   {Calcula vetor com limites máximos de candidatos abertos em cada período}
3   para cada  $t \in T$  faça
4      $MaxCILs_t \leftarrow (\sum_{i \in I} \sum_{j \in J} d_{tij}) / v_t^{min}$ 
5     {Verificação da viabilidade do cromossomo}
6     Calcula vetor com CILs abertos em cada período  $CILsAbertos_t, \forall t \in T$ 
7     para cada  $t \in T$  faça
8       se  $CILsAbertos_t \leq MaxCILs_t$  então
9         {Solução viável, aplicar a Abordagem Gulosa}
10        para cada  $(i, j), i \in I, j \in J$  faça
11          {Cria lista com o arco direto e os arcos passando pelos CILs abertos}
12          Ordenar lista de arcos em ordem crescente de custo
13          se Arco com menor custo utiliza um CIL? então
14             $x_{tikm}^{ent} \leftarrow +d_{tij}, x_{tkjm}^{sai} \leftarrow +d_{tij}$ 
15          senão
16             $x_{tijm}^{dir} \leftarrow +d_{tij}$ 
17          {Verificação das restrições de capacidade e volume mínimo}
18          para cada  $k \in K$  faça
19            enquanto Restrição de capacidade ( $v_{tk}^{max}$ ) não é satisfeita faça
20              Realocar as demandas passantes no CIL k visando menor acréscimo
21              no custo
22            enquanto Restrição de volume mínimo ( $v_{tk}^{min}$ ) não é satisfeita faça
23              Realocar as demandas para o CIL k visando menor acréscimo no
24              custo
25            retorna fitness
26          senão
27            {Solução inviável}
28            se Utilizar máscara de viabilidade? então
29              Aplicar o algoritmo de máscara de viabilidade no cromossomo
30              Reavaliar o cromossomo viável (volta para início)
31            senão
32              retorna  $\infty$ 
```

c. População inicial e tamanho da população

Uma das principais vantagens de se utilizar algoritmos populacionais em comparação aos métodos que utilizam apenas um único ponto de busca é a possibilidade de explorar o espaço de soluções a partir de diversos pontos de busca, aumentando-se as chances de escapar de mínimos locais.

Para iniciar o processo evolutivo do AG, uma população inicial deve ser gerada para, a partir desta, novas gerações serem construídas e, então, convergir aos pontos

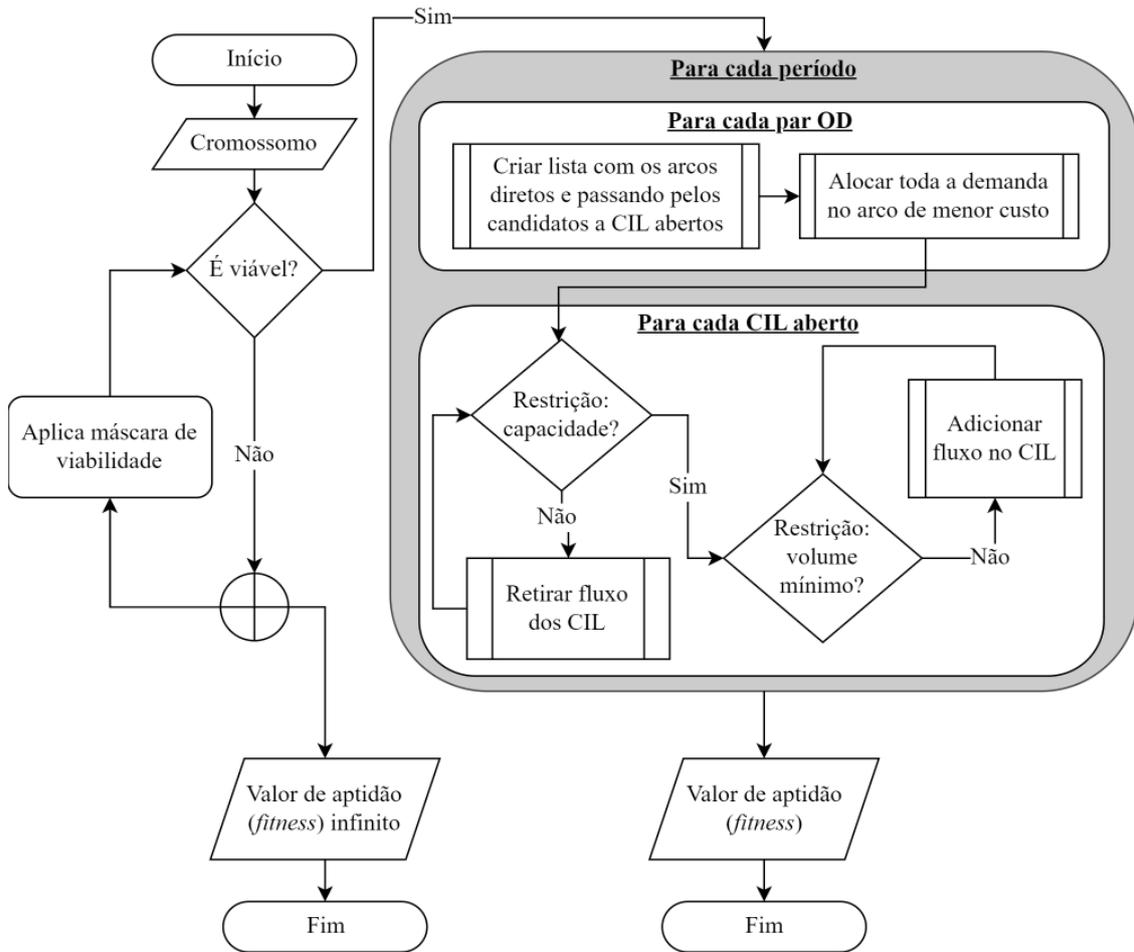


Figura 2.6: Estrutura do algoritmo de cálculo do valor de aptidão do cromossomo.

de mínimo ou máximo. Recomenda-se que, na população inicial, possua cromossomos gerados de forma aleatória, visando alcançar arbitrariamente diferentes soluções iniciais. Esta diversificação de cromossomos na população reflete no espreadimento dos pontos para exploração simultânea de diversos locais na área de busca.

A geração de um cromossomo aleatório no AG proposto ocorre por meio de um processo iterativo de sorteio para cada alelo do cromossomo (vetor) de tamanho $|K|$, definindo-se um valor aleatório entre 0 (não abertura/localização) e $|T|$ (instante inicial de operação da facilidade). Lembrando que, uma vez aberto, a operação deve permanecer até o último período. Por exemplo, em uma análise com quatro períodos, caso seja sorteado o valor 2, o candidato terá operações nos períodos 2, 3 e 4 e deve ser contabilizado para verificação da viabilidade nesses três períodos. Este procedimento é apresentado no Algoritmo 3.

Visando gerar apenas soluções iniciais viáveis, considerou-se que os valores compreendidos no intervalo entre $[0, |T|]$ possuem igual probabilidade de serem sorteados até que os limitantes superiores apresentados no vetor $MaxCILs_T$ sejam atingidos, expressa pelo valor $1/(|T| + 1)$. Quando o limitante superior de um período é atingido, as probabilidades de sorteio deste período e dos que o precedem são zeradas,

deixando de serem sorteados.

Observa-se que, no início do procedimento, a probabilidade de ser sorteado o valor 0 é de $1/(|T| + 1)$, enquanto a de serem sorteados valores maiores que zero é de $|T|/(|T| + 1)$. Ou seja, dependendo da quantidade de períodos na análise, há maior probabilidade dos primeiros candidatos a CIL serem abertos (alelo com valor maior que zero) e, conseqüentemente, dos últimos genes receberem valor zero, pois a quantidade máxima de CILs em operação é atingida. Para contornar este viés, ao fim da construção do cromossomo, os alelos são misturados, mantendo-se a aleatoriedade e a viabilidade do cromossomo.

Algoritmo 3: Geração de indivíduos aleatórios.

```

1 início
2   {Calcula vetor com limites máximos de candidatos abertos em cada período}
3   para cada  $t \in T$  faça
4      $MaxCILs_t \leftarrow (\sum_{i \in I} \sum_{j \in J} d_{tij})/v_t^{min}$ 
5   {Calcula vetor de probabilidade de cada período ser sorteado}
6   para cada  $t \in \{0, T\}$  faça
7      $prob_t \leftarrow [1/(T + 1)]$ 
8   enquanto  $k < K$  faça
9      $cromossomo_k \leftarrow alelo, alelo \in \{0, T\}, prob_t$ 
10    Atualiza vetor de probabilidade após sorteio de acordo com períodos que ainda
11    podem ter CILs abertos
12  Embaralha genes do cromossomo
13  retorna  $cromossomo$ 

```

Além dos cromossomos aleatórios, podem também ser incorporados na população inicial indivíduos gerados a partir da solução da relaxação linear do problema (ver, por exemplo, HINOJOSA *et al.* [51] e FATTAHI *et al.* [42]), denominados, nesta tese, de indivíduos relaxados. Este processo tem por objetivo inserir alelos bem adaptados, ou seja, com valores que possuem chances de compor a solução ótima do problema, auxiliando na convergência da população.

O passo inicial consiste na relaxação linear do modelo matemático, transformando as variáveis binárias z_{tk} em variáveis do conjunto dos números reais positivos. Ou seja, as Restrições (2.11) são substituídas pelas Restrições (2.12). A solução do problema relaxado é então obtida utilizando-se um *solver* comercial e as variáveis reais z_{tk} são ordenadas de forma decrescente de valor.

$$0 \leq z_{tk} \leq 1 \quad \forall t \in T, k \in K \quad (2.12)$$

Três estratégias foram implementadas para a transformação das soluções relaxadas em cromossomos: Método 1 – melhora da solução, Método 2 – abertura precoce e Método 3 – um indivíduo para cada período, conforme apresentado a seguir.

O Método 1, denominado "melhora da solução", tem por objetivo avaliar se

cada variável da solução relaxada gera uma melhora na aptidão do indivíduo. Esse procedimento tem início com a criação de um cromossomo com todos os candidatos a CIL ainda fechados, ou seja, um vetor nulo de tamanho $|K|$. Em seguida, para cada variável z_{tk} com valor maior que zero presente na solução relaxada (ordenada de forma decrescente de valor), verifica-se o impacto no valor de aptidão do cromossomo ao atribuir o valor t para o alelo k . Caso haja melhora no valor de aptidão, mantém-se o valor do alelo. Caso contrário, o valor anterior do alelo é recuperado. O Algoritmo 4 descreve este procedimento iterativo.

Algoritmo 4: Indivíduo relaxado: Método 1 - Melhora da solução.

Entrada: z^r : Vetor com as soluções relaxadas, de tamanho $T \times K$ em ordem decrescente

```

1 início
2   Inicia um cromossomo com todas as facilidades fechadas (cromossomo)
3   Avalia a aptidão do cromossomo
4   para cada  $z_{tk}^r \in z^r$  faça
5     se  $z_{tk}^r > 0$  então
6        $cromossomo[k] \leftarrow t$ 
7       Avalia aptidão do novo cromossomo
8       se houve melhora na solução? então
9         Mantém o cromossomo modificado
10      senão
11        Retorna o alelo  $k$  para o valor anterior
12   retorna cromossomo

```

O Método 2, denominado "abertura precoce", tem por objetivo criar um cromossomo atribuindo-se, para cada alelo, o menor período presente na solução relaxada com valor acima de zero. Ou seja, caso a solução relaxada aponte valor acima de zero para os períodos 2, 3 e 4, o candidato será selecionado para iniciar a operação no período 2. Os candidatos com valor zero na solução relaxada em todos os períodos permanecem fechados. O Algoritmo 5 apresenta este procedimento.

Algoritmo 5: Indivíduo relaxado: Método 2 - Abertura precoce.

Entrada: z^r : Vetor com as soluções relaxadas, de tamanho $T \times K$ em ordem decrescente

```

início
  Inicia um cromossomo com todas as facilidades fechadas (cromossomo)
  para cada  $z_{tk}^r \in z^r$  faça
    se  $z_{tk}^r > 0$  então
      se ( $cromossomo[k] = 0$ ) ou ( $cromossomo[k] > t$ ) então
         $cromossomo[k] \leftarrow t$ 
  Avalia a aptidão do cromossomo
  retorna cromossomo

```

Buscando manter a diversidade genética na população, o Método 3 visa construir $|T|$ indivíduos, de forma que cada indivíduo represente cada período, incorporando-se todas as variáveis z_{tk} que tiveram valor maior que zero na solução relaxada. Este

procedimento tem início com um cromossomo nulo para cada período de análise. Em seguida, para cada $t \in T$, verifica-se quais candidatos a CIL tiveram valor maior que zero na solução relaxada. Por exemplo, se um candidato a CIL k possuir solução relaxada maior que zero nos períodos $t = 2$ e $t = 3$, o k -ésimo alelo dos cromossomos referentes a esses períodos devem receber o respectivo valor de t . Já nos demais cromossomos, o k -ésimo alelo deverá ter o valor zero atribuído. O Algoritmo 6 descreve este procedimento.

Algoritmo 6: Indivíduo relaxado: Método 3 - Um indivíduo para cada período.

Entrada: z_{tk} : Vetor com as soluções relaxadas

```

1 início
2   para cada  $t \in T$  faça
3     Inicia um cromossomo para o período  $t$  com todas as facilidades fechadas
4     ( $cromossomo_t$ )
5     para cada  $z_{tk}^r \in z^r$  faça
6       se  $z_{tk}^r > 0$  então
7          $cromossomo_t[k] \leftarrow t$ 
8     para cada  $t \in T$  faça
9       Avalia a aptidão do  $cromossomo_t$ 
10    retorna Lista com um cromossomo para cada período

```

Observa-se que, dependendo da solução do modelo matemático relaxado, estes métodos podem resultar em cromossomos que representam soluções inviáveis. Para contornar este problema, podem ser aplicadas máscaras de viabilidade, como será discutido adiante. Cabe destacar que estes métodos podem ser aplicados individualmente ou em conjunto, o que permitiria adicionar diversos indivíduos relaxados na população. Para aplicação neste estudo, optou-se pela inclusão de indivíduos relaxados obtidos a partir dos três métodos simultaneamente, aumentando-se a probabilidade de inserção de informações bem adaptadas (ver Apêndice F).

Um importante hiperparâmetro para o desempenho do AG é o tamanho da população, pois afeta o tempo de execução e a diversidade de exploração do espaço de busca (HOLLAND [76], GOLDBERG [77], WIRSANSKY [78], FALCONE [79]). Populações pequenas, por exemplo, podem possuir pouca diversidade de soluções e, com isso, reduzir o espaço de busca, aumentando-se as possibilidades de convergência à pontos de mínimos ou máximos locais. Por outro lado, populações grandes exigem maior esforço computacional. ALANDER [80] propõe que o tamanho da população deve estar dentro do intervalo que varia do tamanho do cromossomo ao seu dobro. Assim, esse parâmetro deve ser calibrado de acordo com as características do problema, de forma a encontrar um melhor equilíbrio entre a solução encontrada e o tempo computacional.

A calibragem deste parâmetro é abordado no Apêndice F. Optou-se por utilizar

população com 80 indivíduos para as instâncias com apenas indivíduos aleatórios na população inicial e com 60 indivíduos para as instâncias com indivíduos relaxados na população inicial, uma vez que, neste último caso, são adicionados cromossomos bem adaptados desde a primeira geração.

d. Elitismo e redefinição do conjunto Não Elite

Enquanto o valor de aptidão médio tende a melhorar a cada geração do AG, é possível que, em um determinado momento, o melhor indivíduo seja perdido em decorrência da aplicação dos operadores de seleção, recombinação e mutação. WIRSANSKY [78] afirma que, em muitos casos, esta perda é temporária, uma vez que estes indivíduos serão reinseridos em futuras gerações. No entanto, para garantir que o(s) melhor(es) indivíduo(s) sempre participem da próxima geração, pode-se aplicar a estratégia de elitismo, que consiste em um tratamento diferenciado aos indivíduos com melhores valores de aptidão de forma a garantir que estes sempre estejam presentes nas futuras gerações (ver, por exemplo, WIRSANSKY [78], DE JONG [81]. Além disso, como consequência da utilização de estratégias de elitismo, pode haver significativo impacto positivo na performance dos algoritmos, pois evita-se o gasto potencial de tempo necessário para redescobrir boas soluções perdidas.

No AG proposto, a população é dividida em dois conjuntos: Elite (\mathcal{E}) e Não Elite (\mathcal{NE}). Adotou-se tamanho do conjunto \mathcal{E} equivalente a 10% do tamanho da população, sendo constante para todas as gerações e proporcional ao tamanho da população, o que permite adaptação para diferentes aplicações. A escolha do tamanho deste conjunto é apresentada no Apêndice F. Neste conjunto, são atribuídos os indivíduos que possuem os melhores valores de aptidão, sem permitir a repetição de cromossomos (soluções idênticas às presentes neste conjunto são excluídos da população visando aumentar a diversidade). Os indivíduos presentes no \mathcal{E} são sempre considerados na geração subsequente, intensificando o desempenho de busca no processo evolutivo.

Os indivíduos restantes na população (diferentes daqueles presentes no conjunto Elite) são atribuídos ao \mathcal{NE} . Diferentemente do conjunto \mathcal{E} , no qual não é permitido indivíduos com cromossomos iguais, no \mathcal{NE} pode conter cromossomos idênticos.

A construção de uma população com indivíduos aleatórios é fundamental para manter a diversidade de exploração. Porém, ao longo das gerações, como resultado dos operadores de cruzamento e mutação, é esperado que os cromossomos presentes na população tendem a convergir para as melhores soluções da geração (já presentes no conjunto \mathcal{E}). WIRSANSKY [78] destaca que se a aptidão de um indivíduo for muito maior do que o resto da população, pode ocorrer a convergência dos cromossomos para esta solução, levando o AG a ficar prematuramente preso em um máximo ou mínimo local, ao invés de encontrar o global.

Somado à isto, em consequência da exclusão de indivíduos com cromossomos idênticos aos contidos no \mathcal{E} , ocorre uma redução do tamanho da população e, conseqüentemente, do tamanho do conjunto \mathcal{NE} . Como resultado, agrava-se ainda mais a diversidade de soluções presentes na análise, levando-se à uma convergência precoce para um mínimo local.

Visando contornar esse viés do processo evolutivo, implementou-se um mecanismo de redefinição aleatória do \mathcal{NE} , criando-se novos indivíduos aleatórios para este conjunto (utiliza-se o procedimento para a criação de indivíduos aleatórios apresentado no Algoritmo 3). Assim, adiciona-se diversidade na população, mas conserva-se a intensificação de busca gerada pelos indivíduos elite. A redefinição do conjunto \mathcal{NE} é aplicada sempre que o tamanho do conjunto atinge valor inferior a 15% do parâmetro de tamanho da população inicial.

e. Plano de reprodução

O AG é uma metaheurística evolutiva que baseia-se em mecânicas de cópia dos cromossomos ou troca de alelos durante o procedimento de reprodução dos indivíduos. Esta etapa do AG tem por objetivo definir um plano de reprodução para gerar descendentes dos indivíduos da população atual a partir da aplicação de operadores de seleção, cruzamento e mutação. O plano de reprodução proposto é representado pelo Algoritmo 7 e ilustrado na Figura 2.7.

Algoritmo 7: Plano de Reprodução: aplicação dos operadores genéticos.

Entrada: Conjuntos Elite (\mathcal{E}) e Não Elite (\mathcal{NE}), probabilidade de mutação (p_{mut})

```

1 início
2   {Operador de seleção}
3    $indA \leftarrow Torneio(\mathcal{E})$ 
4    $indB \leftarrow Torneio(\mathcal{NE})$ 
5   {Operador de recombinação (crossover)}
6   Sorteia número entre  $[1, |K| - 1]$ 
7    $[descendenteA, descendenteB] \leftarrow crossover(indA, indB)$ 
8   {Operador de mutação}
9   para cada  $descendente \in [descendenteA, descendenteB]$  faça
10     $p \leftarrow$  número aleatório entre  $[0,1]$ 
11    se  $p \leq p_{mut}$  então
12      Sorteia um número  $k$  entre  $[1, |K|]$ 
13      Altera valor do alelo  $descendente[k]$ 
14  retorna ( $DescendenteA, DescendenteB$ )

```

O operador de seleção é responsável por escolher indivíduos da população para reprodução e pode ser implementado de diversas formas no AG. Dentre os métodos de seleção presentes na literatura, tem-se roleta enviesada, amostragem universal estocástica (*stochastic universal sampling - SUS*, sorteio, classificação (*rank-based*) e torneio (ver, por exemplo, HOLLAND [76], GOLDBERG [77], WIRSANSKY [78],

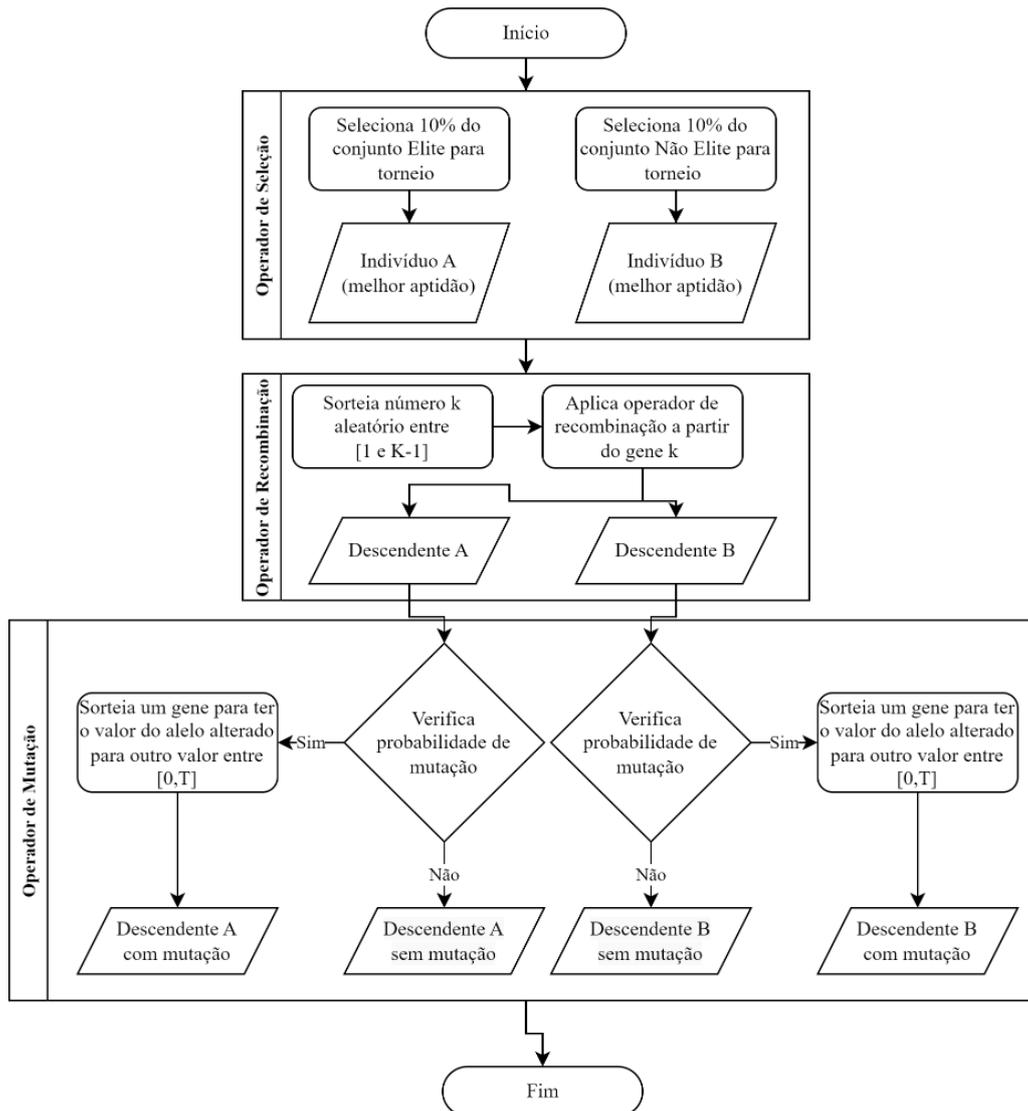


Figura 2.7: Plano de reprodução.

DE JONG [81]). Utilizar indivíduos mais adaptados para o processo de reprodução de acordo com seu valor de aptidão significa maior probabilidade deste contribuir com um ou mais herdeiros adaptados na próxima geração.

Para o algoritmo proposto, utilizou-se o método de seleção por Torneio. De forma geral, este método consiste em selecionar aleatoriamente dois ou mais indivíduos da população para participarem de um torneio. O indivíduo que possuir maior valor de aptidão é considerado vencedor e, então, destacado para a reprodução.

O número de indivíduos participantes em cada rodada é denominado de tamanho do torneio. WIRSANSKY [78] destaca que, quanto maior for o tamanho do torneio, maiores as chances do melhor indivíduo da população em participar e, consequentemente, menores a chance de um indivíduo com menor valor de aptidão vencer e participar da reprodução. Caso isto ocorra, pode ocorrer convergência precoce da população e perda de diversidade genética. O tamanho do torneio definido no

método proposto é de 10% do tamanho da população ou do conjunto de indivíduos desejado (\mathcal{E} ou \mathcal{NE}). Assim, para conjuntos pequenos, menos candidatos são selecionados, reduzindo-se a probabilidade de se destacar aquele com maior valor de aptidão. Cabe ressaltar que, caso a multiplicação do percentual pelo tamanho da população não retorne um número inteiro, seleciona-se o próximo maior valor inteiro e que sempre são selecionados ao menos dois indivíduos para o torneio.

O operador de recombinação (ou *crossover*) é responsável por gerar descendentes a partir da troca de partes genéticas entre dois indivíduos selecionado (GOLDBERG [77], WIRSANSKY [78]). Desta forma, a escolha dos indivíduos é de grande importância para a diversificação das gerações posteriores e ampliação da busca local. Pensando nisso, para a geração de novos indivíduos, optou-se por aplicar os operadores de reprodução a partir de um indivíduo do \mathcal{E} e outro do \mathcal{NE} . O procedimento de recombinação, em que cada par de cromossomos passa por um cruzamento de informações, é realizado em duas etapas principais (ilustrado na Figura 2.8):

1. Define-se o ponto de recombinação, que estabelece a parte dos cromossomos que trocarão informações genéticas entre si, elencando-se aleatoriamente um valor inteiro l entre o segundo e penúltimo alelo ($l \in \{2, |K| - 1\}$);
2. Todos os alelos compreendidos entre o valor sorteado l e o comprimento total do cromossomo são trocados entre si, gerando dois novos indivíduos.

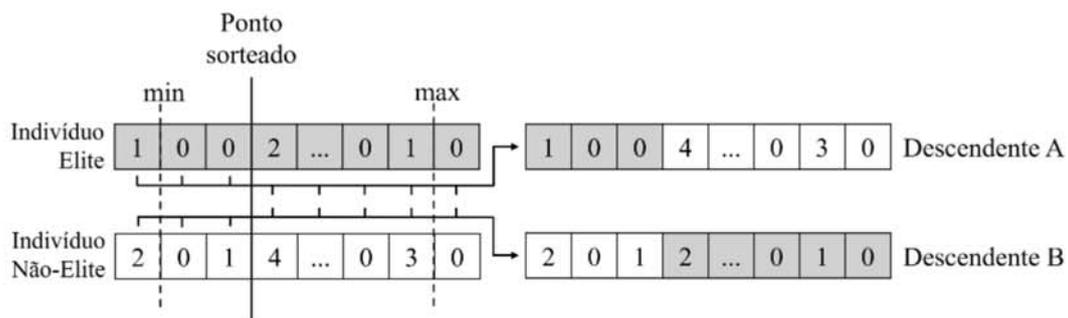


Figura 2.8: Operador de cruzamento.

Como na biologia, há uma pequena probabilidade dos indivíduos sofrerem mutação nos AG, o que permite alterar aleatoriamente o valor de um alelo dos novos cromossomos gerados. Mesmo que a reprodução e o cruzamento busquem e recombinem de forma efetiva, parte do material genético útil para a solução pode ser perdida. GOLDBERG [77] enfatiza a necessidade da aplicação do operador de mutação para proteger contra essa perda irrecuperável. Além disso, este operador auxilia escapar de mínimos ou máximos locais.

O operador de mutação é o último a ser aplicado no processo de geração de descendentes. Para cada novo indivíduo gerado a partir da aplicação do operador de

recombinação, é avaliado se o cromossomo sofrerá mutação com uma probabilidade de ocorrência P_{mut} . Caso positivo, o operador de mutação consiste em selecionar arbitrariamente um gene e alterar o valor de seu alelo, como ilustrado na Figura 2.9. Desta forma, pode-se alterar o período de abertura de um CIL ou até mesmo em sua não abertura. Esses operadores podem gerar indivíduos inviáveis, mas que serão identificados no cálculo da aptidão.

WIRSANSKY [78] menciona que a mutação deve ocorrer com uma probabilidade baixa, pois traz o risco de prejudicar o desempenho de qualquer indivíduo a quem for aplicada. Além disso, se a taxa de mutação for excessivamente alta, o AG pode se comportar como um algoritmo de busca aleatória. Nesta tese, adotou-se o valor de 0,1 para P_{mut} (conforme detalhado no Apêndice F).

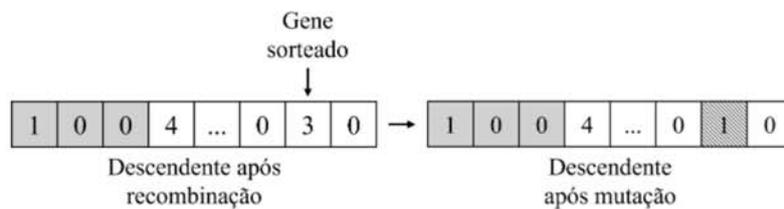


Figura 2.9: Operador de mutação.

f. Máscaras de viabilidade

Devido às restrições do modelo, as aplicações dos operadores genéticos podem resultar em cromossomos que representam soluções inviáveis. Uma importante restrição, por exemplo, é a quantidade de facilidades abertas, como discutido anteriormente no cálculo do valor de aptidão. Caso deseja-se manter o cromossomo inviável na população, por se tratar de um problema de alocação por minimização de custos, este receberá um valor de aptidão que tenda ao infinito. Assim, ao serem selecionados para torneio em conjunto com indivíduos viáveis, seja para o processo de reprodução ou para a construção da geração seguinte, os indivíduos inviáveis tendem a ser descartados e deixam de contribuir geneticamente (similar à seleção natural).

No entanto, armazenar e manipular estes indivíduos inviáveis, que não contribuem efetivamente com a busca no espaço viável, podem consumir recursos computacionais de forma desnecessária, o que precisa ser controlado para aplicações em instâncias de grande porte. Além disso, o descarte completo desses cromossomos não é totalmente interessante, uma vez que pode levar à perda de alelos importantes para a construção da solução do problema.

Para contornar essa perda, elaborou-se máscaras de viabilidade, que tem por objetivo tornar cromossomos inviáveis em soluções viáveis. A ideia principal consiste em construir um vetor binário de tamanho $|K|$, similar ao tamanho do cromossomo,

que indique as alterações necessárias em cada alelo para tornar o cromossomo viável. Como o intuito é reduzir a quantidade de facilidades abertas, quando a célula da máscara tiver valor 1, o candidato a CIL com o gene correspondente permanecerá com o mesmo valor. Porém, quando a máscara indicar valor zero para o alelo, a facilidade deverá ser fechada. Vale ressaltar que não é permitido um CIL ser aberto e depois fechado.

Exemplifica-se o procedimento na Figura 2.10. Observa-se que, para o cromossomo inviável do exemplo, o segundo e o antepenúltimo candidatos deveriam ser abertos, respectivamente, nos períodos 4 e 1. Porém, para tornar a solução viável, a máscara de viabilidade indicou que estes dois candidatos devem ser fechados (indicado por zero), tornando-os inoperantes em todos os períodos. As demais facilidades permanecem com os mesmos valores que o cromossomo inicial por terem valor 1 atribuído às respectivas células da máscara.

Dado o cromossomo inviável e o vetor com a quantidade máxima de CILs que podem ser abertos em cada período (vetor $MaxCILs_T$), duas abordagens aleatórias foram propostas para a escolha dos locais candidatos a serem fechados: Máscara de viabilidade por período crescente (Máscara 1) e Máscara de viabilidade por período decrescente (Máscara 2).

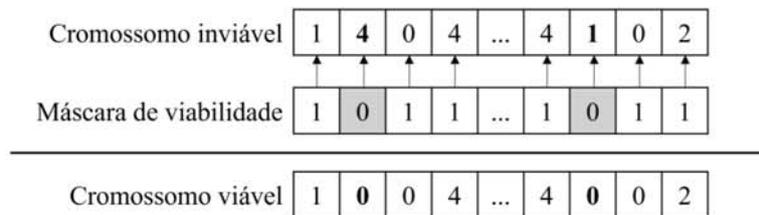


Figura 2.10: Exemplo de aplicação de máscara de viabilidade.

O primeiro método, denominado de Máscara de viabilidade por período crescente (Máscara 1), busca identificar, individualmente para cada período $t \in T$ e em ordem crescente, as facilidades que devem ser fechadas para tornar a solução viável. Identificado que o período t possui mais CILs em operação do que o valor limitante, lista-se todas as posições do cromossomo que representam os candidatos que podem ser fechados para tornar o período viável. Ou seja, identifica-se os alelos com valor compreendido no intervalo entre 1 e t . Em seguida, sorteia-se, aleatoriamente, quantos candidatos forem necessários para serem fechados (valor zero na máscara de viabilidade) até que o período t seja viável. Por fim, deve-se atualizar o vetor com as quantidades de facilidades a serem fechadas em cada período. O Algoritmo 8 apresenta esse procedimento.

Para exemplificar, toma-se um cromossomo inviável fictício que, para ser viável, precisa ter três, quatro, cinco e cinco facilidades fechadas, respectivamente, no primeiro, segundo, terceiro e quarto períodos, representado pelo vetor $[3,4,5,5]$. Na

Algoritmo 8: Construção de máscara de viabilidade por procedimento de período crescente.

Entrada: cromossomo inviável

- 1 **início**
- 2 Calcular a quantidade de CILs abertos em cada período
- 3 Calcular a quantidade de CILs que devem ser fechados em cada período
- 4 **para** $t \in T$ *em ordem crescente* **faça**
- 5 Listar os genes do cromossomo com alelo no intervalo $[1,t]$
- 6 **enquanto** t *é inviável* **faça**
- 7 Sortear genes da lista para serem fechados
- 8 Atribuir valor 0 ao gene correspondente da máscara de viabilidade
- 9 Atualizar a quantidade de CILs que devem ser fechados nos períodos $[t,T]$
- 10 **retorna** *Máscara de viabilidade*

primeira iteração, para $t = 1$, são listados todos os alelos do cromossomo que possuem valor igual a 1. Destes, são sorteados aleatoriamente três alelos para serem fechados. Ao fim desta iteração, atualiza-se o vetor com a quantidade de CILs a serem fechados para $[0,1,2,2]$, já que estes CILs que foram fechados teriam também operação nos períodos subsequentes. A segunda iteração, para $t = 2$, irá selecionar alelos com valor 1 e 2. Logo, poderá fechar mais facilidades do primeiro período. Sorteados os alelos e fechadas as facilidades, atualiza-se o vetor referência para $[0,0,1,1]$. Na terceira iteração, para $t = 3$, busca-se apenas um alelo com valor 1, 2 ou 3 para ser fechado, podendo serem escolhidas novamente facilidades que iniciavam as operações nos dois primeiros períodos. Após esta iteração, atualiza-se o vetor de referência para $[0,0,0,0]$, indicando que já foram fechadas as quantidades necessárias para tornar o cromossomo em solução viável.

No entanto, observa-se que, por ser realizada a análise em ordem crescente de período, este procedimento aumenta a probabilidade de serem eliminados da população os alelos que referenciam aos primeiros períodos de análise. Como os CILs visam reduzir também os custos operacionais da rede logística, pode ser interessante para a solução ótima manter informações que indiquem abertura nos primeiros períodos de operação. Portanto, esta tendência comportamental seguida da perda desse material genético pode ser prejudicial para o processo de construção da solução ótima. Visando contornar este problema, propõe-se também o procedimento de construção de máscara de viabilidade descrito a seguir.

Neste contexto, foi proposto o segundo método de elaboração de máscara de viabilidade, denominado de Máscara de viabilidade por período decrescente (Máscara 2). Este procedimento tem por objetivo tornar a solução viável avaliando-se os períodos $t \in T$ de forma decrescente, reduzindo-se a perda de alelos que referenciam aos primeiros períodos de análise. Assim, embora as etapas sejam similares ao procedimento anterior, desta vez, a análise tem início no último período $t = |T|$ em

direção a $t = 1$. O procedimento é descrito no Algoritmo 9.

Algoritmo 9: Construção de máscara de viabilidade por procedimento de período decrescente.

Entrada: cromossomo inviável

```

1 início
2   Calcular a quantidade de CILs abertos em cada período
3   Calcular a quantidade de CILs que devem ser fechados em cada período
4   para  $t \in T$  em ordem decrescente faça
5     Listar os genes do cromossomo com alelo no intervalo [1,t]
6     enquanto  $t$  é inviável faça
7       Sortear genes da lista para serem fechados
8       Atribuir valor 0 ao gene correspondente da máscara de viabilidade
9       Atualizar a quantidade de CILs que devem ser fechados nos período [t,T]
```

Para exemplificar este procedimento, toma-se o mesmo cenário anterior, com a quantidade de CILs a serem fechados por período igual a [3,4,5,5]. Na primeira iteração, para $t = 4$, busca-se sortear e fechar cinco facilidades para tornar o último período viável. Para isso, estes alelos podem conter os valores 1, 2, 3 ou 4. Ao fim desta primeira iteração, supondo-se que foram sorteados os alelos com valor 2, 1, 3, 2 e 4, tem-se que o vetor com a quantidade de facilidades a serem fechadas é atualizado conforme apresentado na Tabela 2.4. Observa-se que, desta forma, ao buscar a viabilidade do último período, abre-se a possibilidade de já ajustar a inviabilidade dos períodos que o precedem. O processo iterativo assim segue para as próximas iterações.

Tabela 2.4: Exemplo de atualização da quantidade de facilidades a serem fechadas nos quatro períodos.

Iteração	Alelo sorteado	Quantidade de facilidades a serem fechadas
Início	-	[3,4,5,5]
1	2	[3,3,4,4]
	1	[2,2,3,3]
	3	[2,2,2,2]
	2	[2,1,1,1]
	4	[2,1,1,0]

A partir da calibração dos parâmetros do AG proposto apresentado no Apêndice F, observou-se que a utilização da Máscara 2 resultou em menores valores de tempo computacional para populações com 80 indivíduos. Por este motivo, esta foi adotada para aplicação.

g. Geração Subsequente e Critérios de Parada

Por ser uma heurística evolutiva, uma nova geração populacional deve ser constituída a partir dos indivíduos da geração atual e de seus descendentes, gerados por meio dos procedimentos de reprodução. No AG proposto para o PMLCIL, considera-se, inicialmente, que todos os indivíduos presentes no conjunto \mathcal{E} sobrevivem para a próxima geração. Para complementar esta nova geração, indivíduos do conjunto \mathcal{NE} e de descendentes (\mathcal{D}) são selecionados pelo método do torneio até que seja atingido o tamanho predefinido para as populações. Esta etapa é apresentada nas linhas 23 e 24 do Algoritmo 1. Cabe destacar que o conjunto de descendentes possui tamanho idêntico ao estabelecido para a população (linha 13 do Algoritmo 1).

O AG proposto possui seis critérios de parada implementados, como descrito a seguir e resumidos na Tabela 2.5, juntamente com os valores adotados para cada item (para mais detalhes, consultar o Apêndice F).

- **Critério 1 - Tempo máximo decorrido do início do processo:** Este critério de parada possui a principal função de interromper o algoritmo caso seja excedido um limite de tempo decorrido inserido como parâmetro pelo usuário. Da forma que está implementado no algoritmo, este critério não é instantâneo para interrupção do código, mas sim, ao final de cada iteração, após o processo de criação de uma geração, é verificado se o tempo do processo até ali excedeu ou não o teto predefinido. Caso positivo, apresenta-se os resultados. Ou seja, pode ocorrer tempos superiores ao limite. A contagem do tempo decorrido tem início com a criação da população inicial, após a leitura dos dados de entrada e parâmetros do modelo. Desta forma, este tempo representa o gasto temporal do processo evolutivo. Caso deseja-se desativar este critério, basta ser inserido o valor de infinito. Foi adotado o valor de 3.600s.
- **Critério 2 - Número máximo de gerações:** Há também a possibilidade do algoritmo ser interrompido caso seja atingido um número máximo de iterações, ou seja, após uma determinada quantidade de gerações de indivíduos ser criada. Assim, ao final da avaliação de cada população, é verificado se foi atingido o valor máximo definido pelo usuário através do parâmetro de entrada. Caso positivo, apresenta-se os resultados. Como mencionado anteriormente, este critério também serve para limitar o tempo de execução e os recursos computacionais consumidos pelo algoritmo. Caso deseja-se desativá-lo, basta ser inserido o valor de infinito para o parâmetro de entrada. Foi adotado o valor de 200 gerações.
- **Critério 3 - Número máximo de gerações consecutivas sem melhora da solução:** Em consequência do procedimento de reprodução, a cada nova

geração, os indivíduos tendem a convergir para a melhor solução até então encontrada. Como resultado, pode ser que o algoritmo não encontre soluções melhores a cada geração, estagnando-se em um mínimo local, por exemplo. Como discutido anteriormente, faz-se importante a diversificação da população para controlar esse problema. Implementou-se, então, um critério de parada capaz de interromper o algoritmo caso seja atingido um número máximo de gerações consecutivas sem melhora da solução. Caso deseja-se desativá-lo, basta ser inserido o valor de infinito para o parâmetro de entrada. Destaca-se a importância deste parâmetro limitante não possuir valor baixo, para não interromper a busca precocemente, permitindo o algoritmo explorar outras soluções através do plano de reprodução. Foi adotado o valor de 20 gerações (equivalente a 10% do número máximo de gerações).

- **Critério 4 - Melhora significativa da solução aceitável entre gerações:** Em contraste ao anterior, há ainda a possibilidade de avaliar como critério de parada a taxa de melhora da melhor solução encontrada entre a penúltima e última geração. Este critério diferencia-se do anterior pois, enquanto este permite avaliar mesmo que uma pequena melhora na solução, aquele analisa se as soluções são exatamente iguais. Ao fim de cada geração, calcula-se a razão entre a melhor solução encontrada na última geração e a melhor solução encontrada na geração anterior à ela. O resultado é então comparado à um valor mínimo definido como parâmetro de entrada do algoritmo. Caso deseja-se desativá-lo, basta ser inserido o valor de infinito para o parâmetro de entrada. Foi adotado o valor de 0,1%.
- **Critério 5 - Razão entre as médias das duas últimas gerações:** Como característica do processo evolutivo, tem-se que, a cada iteração, a nova população resultante é constituída por indivíduos com melhores valores de aptidão quando comparados às populações anteriores. Assim, o valor médio de aptidão da população tende a revelar a direção e intensidade de convergência dos cromossomos à minimização do problema. Em um determinado momento, recursos computacionais podem ser dispendidos para não serem observadas melhorias significativas na convergência da população. Neste conceito, implementou-se um critério de parada capaz de avaliar se a razão entre o valor médio de aptidão da geração atual e o valor médio da população anterior à ela é menor do que um piso definido pelo parâmetro de entrada. Caso deseja-se desativá-lo, basta ser inserido o valor de infinito para o parâmetro de entrada. Ressalta-se que, em consequência do processo de redefinição do conjunto $\mathcal{N}\mathcal{E}$, no qual novos indivíduos aleatórios são inseridos na população, há momentos em que o valor médio de aptidão da população pode aumentar de uma geração

para outra. Foi adotado o valor de 1%.

- Critério 6 - Quantidade mínima de redefinição da população:** Com o objetivo de evitar a interrupção precoce do algoritmo através da convergência de um mínimo local, a última estratégia inserida avalia a quantidade de redefinições do conjunto \mathcal{NE} foram realizadas e, então, a compara com uma quantidade mínima exigida, definida como parâmetro de entrada no modelo. Desta forma, garante-se que o algoritmo apenas será cessado após ter completado um número mínimo de possibilidades de diversificação da população. Caso os critérios 4 e 5 sejam atingidos, mas a quantidade de redefinições ainda não tenha atingido o valor mínimo, força-se a aplicação da redefinição da população, diversificando-se a busca. Caso deseja-se desativá-lo, basta ser inserido o valor zero. Foi adotado o valor de 10 redefinições para quando houver indivíduo relaxado e, quando não houver, maior valor entre 10 redefinições e 40% multiplicado pelo número da geração em execução.

Na estrutura lógica de avaliação dos critérios de parada, os três primeiros critérios são analisados sequencialmente e de forma individual. Caso algum deles é atingido, o algoritmo é interrompido. Por outro lado, para conseguir interromper o algoritmo, os três últimos devem ser atingidos de forma simultânea. Vale ressaltar que, caso deseja-se inutilizar um critério, basta inserir o parâmetro adequado. O fluxograma apresentado na Figura 2.11 ilustra esse processo.

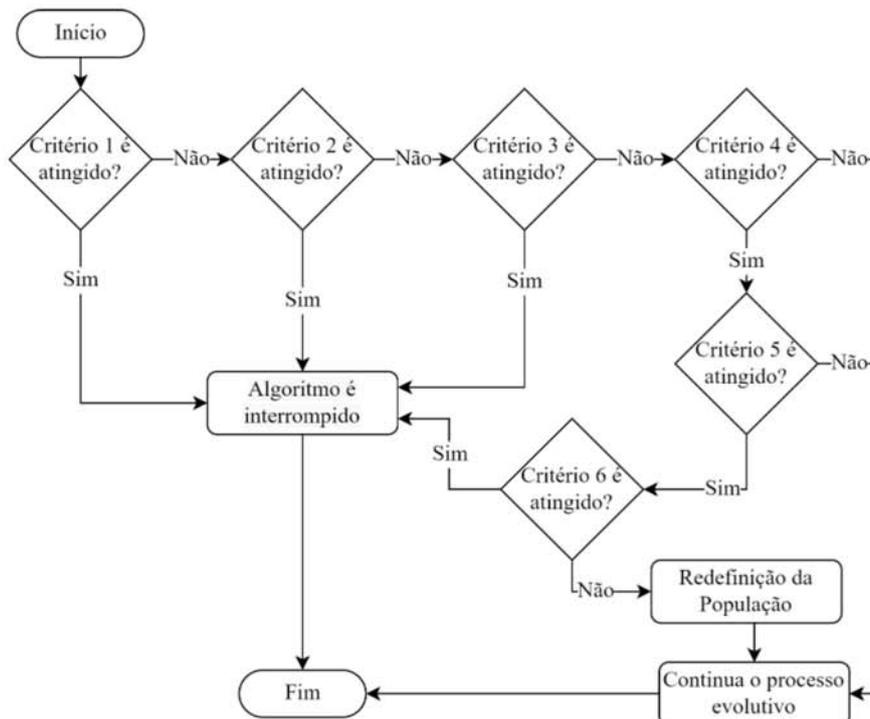


Figura 2.11: Fluxograma de aplicação dos critérios de parada.

Tabela 2.5: Síntese dos critérios de parada implementados no Algoritmo Genético proposto.

Critério de parada	Definição	Métrica da geração	Parâmetro de entrada para comparação	Critério de parada implementado	Estrutura lógica de avaliação	Valor adotado
Critério 1	Tempo máximo decorrido do início do processo	Tempo decorrido desde o início do processo evolutivo	Tempo máximo (em segundos)	Métrica \geq Parâmetro	Individual	3.600s
Critério 2	Número máximo de gerações	Quantidade de gerações já criadas	Número máximo de gerações	Métrica \geq Parâmetro	Individual	200 gerações
Critério 3	Número máximo de gerações consecutivas sem melhorar a solução	Número de gerações consecutivas sem melhorar a solução	Número máximo de gerações consecutivas sem melhorar a solução	Métrica \geq Parâmetro	Individual	20 gerações
Critério 4	Melhora significativa da solução aceitável entre gerações	Razão entre a melhor solução presente na última geração e a melhor solução presente na geração anterior	Valor mínimo de melhoria (em porcentagem)	Métrica \leq Parâmetro	Em conjunto (4, 5 e 6)	0,1%
Critério 5	Razão entre as melhores das duas últimas gerações	Razão entre o valor médio de aptidão da última geração atual e o valor médio de aptidão da geração anterior	Valor mínimo de melhoria (em porcentagem)	Métrica \leq Parâmetro	Em conjunto (4, 5 e 6)	1%
Critério 6	Quantidade mínima de redefinição da população	Quantidade de redefinições do conjunto \mathcal{NE} realizadas no processo todo	Valor mínimo de redefinições esperado	Métrica \geq Parâmetro	Em conjunto (4, 5 e 6)	10 ou mais

2.3.2 Heurística Baseada em Relaxação

Em alternativa ao AG apresentado, foi também proposta uma heurística construtiva baseada em relaxação linear, concebida baseando-se no “Método 1 – Melhora da Solução” e no “Método 2 – Abertura precoce” de geração dos indivíduos relaxados. A ideia principal desta heurística consiste em, a partir da solução relaxada do problema, incorporar a abertura do CIL e avaliar, conforme vetor da solução, se a abertura do CIL em um horizonte menor é capaz de gerar uma solução com menor valor.

A Heurística Baseada em Relaxação (HBR), apresentada pelo Algoritmo 10, tem como dado de entrada o vetor com a solução relaxada do problema de localização, com as variáveis ordenadas de forma decrescente de valor. A primeira etapa consiste na criação do vetor solução nulo, isto é, com todas as facilidades fechadas (linha 3), e a avaliação da FO desta solução (linha 4). O valor da FO para cada solução foi obtido utilizando-se o algoritmo guloso apresentado para a avaliação de aptidão dos indivíduos (Algoritmo 2). Então, para cada variável z_{ik}^t presente na solução relaxada ordenada, três possibilidades são avaliadas:

1. Caso o CIL k ainda não tenha sido aberto (linha 7), atribui-se o período t indicado no índice da variável relaxada como horizonte de abertura (linha 8);
2. Caso o CIL k já esteja aberto mas a variável em análise indica um horizonte de abertura anterior (linha 7), atribui-se t como o novo período de abertura do candidato (linha 8); e
3. Caso o CIL k já esteja aberto, mas a variável em análise indica um período de abertura posterior, nada é feito.

Sempre que um novo valor de abertura é atribuído ao vetor solução (caso 1 e 2), resolve-se o problema de alocação de fluxos para cálculo da FO utilizando-se a heurística gulosa (linha 9). A solução é mantida caso seja observada redução (melhora) no valor da solução. Caso contrário, a solução anterior é recuperada (linhas 10 e 11).

2.4 Experimentos Computacionais

Com o objetivo de avaliar o desempenho do modelo matemático proposto para o PMLCIL e das abordagens heurísticas propostas, optou-se por selecionar, como parâmetros de estudo de caso, informações do sistema logístico brasileiro de distribuição de *commodities* nacionais. A escolha do contexto brasileiro se sustenta, inicialmente, pela ineficiência logística estrutural, que impacta negativamente diversos setores da

Algoritmo 10: Heurística Baseada em Relaxação - Abertura precoce com avaliação.

Entrada: Vetor com a solução relaxada $z_{tk}^r, t \in T, k \in K$

```
1 início
2   {Inicia-se um vetor com todas as facilidades fechadas}
3    $z_k \leftarrow [0]$ 
4   Avalia a solução  $z_k$ 
5   para cada  $t \in T, k \in K$  faça
6      $vetorAux_K \leftarrow z_K$ 
7     se  $vetorAux_K[k] = 0$  OU  $vetorAux_K[k] < t$  então
8        $vetorAux_K[k] \leftarrow t$ 
9     Avalia a solução de  $vetorAux_k$ 
10    se  $Fitness(vetorAux_K) < Fitness(z_K)$  então
11       $z_K \leftarrow vetorAux_K$ 
12 retorna  $z_K$ 
```

economia, e o fato dos planos logísticos reconhecerem a necessidade de implantação de estruturas de integração como um objetivo estratégico. Além disso, por se tratar de um país com vasta dimensão territorial, permite avaliar as técnicas propostas a partir de instâncias reais e de grande porte.

Os testes computacionais foram realizados utilizando-se um computador com processador AMD Threadripper 3960X 24c/48t, com clock estático de 4.0 GHz, memória RAM de 128 GB DDR4 e sistema operacional Ubuntu 20.04 x64.

2.4.1 Parâmetros do estudo de caso

Como discutido anteriormente, o PNLT é um plano de caráter indicativo de médio e longo prazos, associados ao processo de desenvolvimento socioeconômico do país (MT [1, 73, 74]). Na última atualização deste plano, realizada em 2011, as matrizes de demanda e investimentos foram estendidas até o ano horizonte de 2031.

Após o PNLT, foi publicado o Plano Nacional de Logística - PNL 2025 (EPL [82]), contendo indicações de quais são os empreendimentos e investimentos necessários para otimizar a infraestrutura até o ano de 2025, além de informações georreferenciadas importantes para o desenvolvimento de futuros estudos na área. O PNL foi então revisado para o horizonte de 2035 (EPL [83], publicado no final de 2021). No entanto, como esta pesquisa teve início em 2019, optou-se por utilizar as informações contidas no PNLT que, naquele momento, era o plano que continha informações para um período de análise mais longínquo (2031). Além disso, o PNLT também foi a fonte de dados utilizada pelos modelos anteriores de localização de CILs presentes na literatura e na metodologia apresentada pelo governo federal (MT [84]).

Descreve-se, nesta seção, as informações dos parâmetros de entrada do modelo matemático do PMLCIL no qual realizou-se os testes computacionais. Considerou-se, para o índice T , quatro períodos espaçados igualmente entre si, definidos pelos anos de 2019 (ano de início desta pesquisa), 2023, 2027 e 2031 (horizonte máximo do PNLT).

a. Zoneamento e Redes de Transporte

O nível de desagregação do zoneamento selecionado para a obtenção de dados é um ponto relevante para o estudo de planejamento de transporte, pois é o que definirá o detalhamento espacial das informações. A base geográfica de zonas adotada neste estudo foi extraída do PNLT (MT [1]), considerando-se o nível de microrregiões. A base é composta por 559 zonas, sendo 558 microrregiões dentro do território nacional e uma zona internacional, com o objetivo de simular os fluxos de produtos destinados à exportação. A Figura 2.12 ilustra a divisão do Brasil nas 558 microrregiões nacionais.



Figura 2.12: Zoneamento utilizado: microrregiões do PNLT.

Outra base de suma importância para o desenvolvimento deste estudo é a rede de transporte contendo as informações de oferta. Foi utilizada a rede multimodal georreferenciada também fornecida pelo PNLT, contendo informações das infraestr-

turas rodoviárias, ferroviárias e hidroviárias já existente e, ainda, das infraestrutura previstas para os diferentes períodos. As bases contém dados relevantes como extensão, velocidade, capacidade, qualidade do pavimento, estado de conservação, dentre outras.

A rede georreferenciada publicada pelo plano é a prevista para o horizonte de 2031 (último período de análise), ou seja, com todos os projetos previstos já implementados. No entanto, a característica de multimodalidade do modelo matemático permite obter soluções intermediárias, que precedem a implantação de certas infraestruturas. Assim, buscou-se identificar quando cada investimentos de infraestrutura deveria ocorrer. No PNLT, os projetos foram apresentados em grupos temporais como segue: “até 2011”, “2012-2015”, “2016-2019”, “2020-2023” e “pós 2023”. Para compor as instâncias deste estudo, foram feitas as seguintes considerações:

- Rede Multimodal 2019: investimentos previstos nos grupos “até 2011”, “2012-2015” e “2016-2019”;
- Rede Multimodal 2023: incorporou-se, à Rede Multimodal de 2019, os investimentos do grupo “2020-2023”;
- Rede Multimodal 2027: incorporou-se, à Rede Multimodal de 2023, os investimentos do grupo “pós 2023”, coincidindo com a rede fornecida pelo PNLT; e
- Rede Multimodal 2031: idêntica à Rede Multimodal de 2027.

Cabe destacar que, no caso de vias rodoviárias que ainda seriam construídas ou pavimentadas, as ligações não foram removidas da rede, tomando-se cuidado para sempre haver ligações entre as zonas produtoras e consumidoras. Para estes casos, considerou-se infraestruturas de qualidade inferior, como, por exemplo, estradas em superfície natural (de terra). Para efeito disto na aplicação do modelo matemático, estas alterações foram sinalizadas para ajuste dos custos operacionais, uma vez que a ausência de infraestrutura adequada pode aumentar os custos variáveis e até fixos da operação. A Figura 2.13 ilustra a rede multimodal utilizada já para o horizonte de 2031.

b. Matriz de Demanda

Prever a demanda futura é crucial para estudos de planejamento de transportes. Somado à isto, prever a utilização das facilidades nos diferentes períodos de análise é essencial para o planejamento estratégico da localização destas infraestruturas, principalmente por envolverem altos custos iniciais de implantação. Assim, o estudo

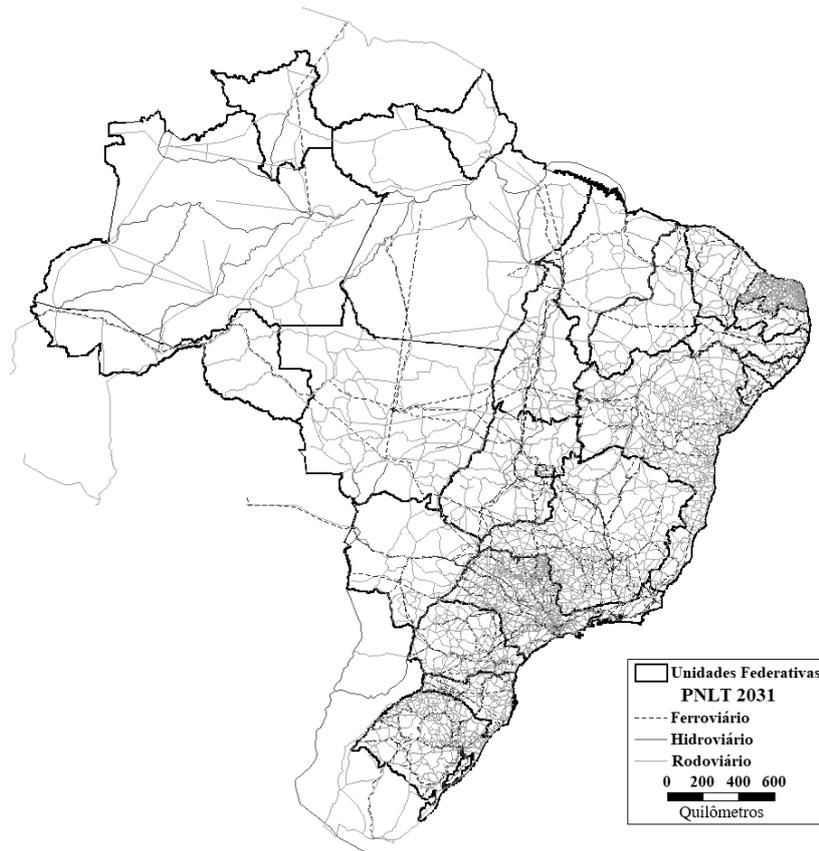


Figura 2.13: Rede multimodal adaptada do PNL T para o horizonte de 2031.

da previsão de demanda ao longo da vida útil do projeto pode nortear importantes tomadas de decisão para diferentes períodos de análise.

O PNL T, fundamentado em estudos de demanda, considerou os produtos dispostos em diferentes grupos de acordo com as características físicas e de manuseio (ver MT [1]). Dentre eles, destaca-se o Grupo 1, constituídos por produtos elencados por valor bruto de produção e que possuem características e particularidades como:

- São geradores de grandes volumes de transportes;
- Tem produção e/ou consumo concentrados em locais ou regiões identificadas;
- Permitem a utilização de transporte multimodal para sua movimentação; e
- Permitem a utilização total da capacidade de transporte.

Ao avaliar as bases de informações que compõem o PNL T, principalmente quanto ao Grupo 1, COSTA [2] concluiu que os produtos com maior relevância para a matriz de cargas nacional (excluindo-se a carga geral e minério de ferro), essencialmente decorrentes das atividades agrícolas e agroindustriais, são soja em grãos, farelo de soja, milho e açúcar. Destacou, ainda, que são produtos com maior possibilidade de

transferência entre os modos duto-ferro-hidroviários em busca de menores custos de transportes.

A partir das bases do PNLT, obteve-se as matrizes de produção e consumo (matriz OD) destes produtos para os anos de 2015, 2023 e 2031, georreferenciadas a partir da base de microrregiões. As matrizes OD para os períodos não disponíveis (2019 e 2027) foram obtidas através de regressão linear das matrizes conhecidas, aplicadas à cada par OD, mantendo-se as expectativas de crescimento dos mercados interno e externo e no aumento de produtividade. Embora o horizonte de 2015 não tenha sido utilizado na aplicação do modelo matemático, as informações desse ano orientaram o cálculo das matrizes de 2019. A Figura 2.14 apresenta os totais obtidos para cada produto e período de análise.

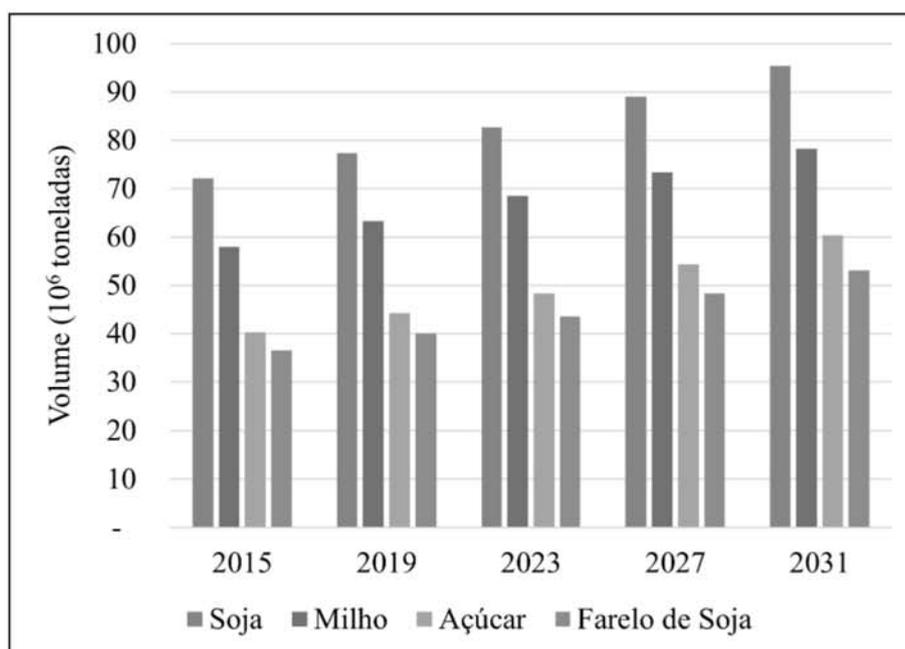


Figura 2.14: Volume de soja em grãos, milho, açúcar e farelo de soja transportado em cada período de análise (em 10^6 toneladas) – adaptado de MT [1].

Dentre estes produtos, elencou-se a soja em grãos para ser abordada neste trabalho. Essa escolha se justifica uma vez que foi o produto que apresentou matriz com maior volume transportado entre os produtos avaliados (soja em grãos, farelo de soja, milho e açúcar), como apresentado na Figura 2.14; e por possuir relevância na matriz nacional, uma vez que representou 48% da produção total de grãos no Brasil na safra de 2022/23 e estima-se que este produto represente 51% da safra 2023/24 (CONAB [85]). As matrizes de cada período para o produto destacado são apresentadas no Apêndice B.

A Tabela 2.6 apresenta, para cada período abordado, a distribuição percentual de produção e consumo da soja em grão em cada região brasileira. Observa-se que a região Centro-Oeste concentra a maior produção (45% a 47%), seguido pelo Sul

(30% a 34%), Nordeste (10% a 16%), Sudeste (5% a 6%) e Norte (3% a 5%). Quanto ao consumo da soja em grãos, destaca-se a exportação (44% a 48%), seguido pelo consumo interno na região Sul (22% a 24%), Centro-Oeste (19% a 21%), Nordeste (5%), Sudeste (4% a 5%) e Norte (1%).

Tabela 2.6: Produção e consumo da soja entre as regiões do Brasil.

período	2015		2019		2023		2027		2031	
Região	O	D	O	D	O	D	O	D	O	D
Centro-Oeste	47%	19%	47%	20%	46%	20%	46%	21%	45%	21%
Nordeste	10%	5%	11%	5%	13%	5%	14%	5%	16%	5%
Norte	3%	1%	4%	1%	4%	1%	5%	1%	5%	1%
Sudeste	6%	4%	6%	4%	5%	5%	5%	5%	5%	5%
Sul	34%	22%	33%	23%	32%	23%	31%	24%	30%	24%
Exterior	0%	48%	0%	46%	0%	45%	0%	44%	0%	44%

c. Candidatos a CIL

As microrregiões candidatas a receberem um CIL foram elencadas no estudo realizado pelo Ministério dos Transportes (MT [22, 84]). Trata-se de zonas próximas à entrocamento modais (locais onde se possa efetivamente realizar o transbordo e a multimodalidade), que possuem estruturas logísticas de integração preestabelecidas ou projetadas, próximas às zonas de produção e afastadas de áreas de proteção ambiental. O estudo apontou conjuntos de microrregiões candidatas para cada grupo de carga do PNLT (granéis vegetais, neogranéis, graneis líquidos, granéis sólidos e carga geral). Para granéis vegetais, tipo do produto abordado nesta tese, foram apontadas 208 microrregiões candidatas para a instalação de CILs.

Entretanto, o modelo de localização proposto apresenta um grau de complexidade crescente tanto com o aumento do número de locais candidatos quanto com o número de produtos considerados. Como deseja-se avaliar apenas o produto soja em grãos, foram pré-selecionadas 80 microrregiões candidatas a receber as instalações de um CIL para aplicação neste estudo, conforme proposto por COSTA [2] e apresentado na Figura 2.15 (listagem no Apêndice C).

A Tabela 2.7 apresenta a distribuição das microrregiões candidatas no território nacional. Verifica-se expressiva presença na região Centro-Oeste (31%), seguida pela Sul (28%) e Sudeste (25%). Por fim, tem-se as regiões norte e nordeste (8% cada).

Embora haja diferentes possibilidades de infraestruturas para os CILs, variando-se, por exemplo, tamanho, capacidades operacionais, tipos de operação, custos e outros, na aplicação proposta nesta tese, considerou-se todas as facilidades apenas com operação de transbordo, com mesmos custos operacionais e de investimento e com mesmo volume mínimo e máximo (capacidade) de operação.

O volume mínimo e máximo para operação dos CILs foram definidos conforme sugerido por COSTA [2] e podem variar de acordo com os cenários de avaliação

Tabela 2.7: Distribuição das microrregiões candidatas a receberem as instalações de um CIL entre as regiões brasileiras.

Região	Microrregiões			
	Total	%	Candidatas	%
Norte	64	11	6	8
Nordeste	188	34	6	8
Sudeste	160	29	20	25
Sul	94	17	23	28
Centro-Oeste	52	9	25	31
Total	558	100	80	100

(apresentados na Seção 2.4.2). Considerou-se tanto o volume mínimo igualado à apenas uma tonelada, o que pode resultar em um número maior de facilidades abertas, quanto igualadas a um milhão de toneladas, visto que, em uma situação real, a implantação de uma estrutura do tipo CIL precisa ser justificada por um volume mínimo de movimentação compatível com a de uma carga ferroviária ou hidroviária. Como capacidade das facilidades, adotou-se o valor de 100 milhões de toneladas, equivalente à produção total de soja em 2031. Desta forma, é permitido à facilidades acomodar toda a carga necessária e, assim, obter a capacidade requerida para cada período. No entanto, o modelo permite utilizar valores mais restritivos.

d. Parâmetros de custos logísticos e de implantação dos CILs

Os parâmetros de custo foram também baseados nos valores utilizados por COSTA [2]. Para o custo operacional de utilização do CIL, foi considerado o valor de R\$ 8 por tonelada. Neste valor são considerados os custos de recepção e expedição de cargas granéis, de operações de transbordo ferroviárias ou hidroviárias, de armazenagem e conservação quinzenal para granéis, além de taxas associadas.

O custo de abertura de um candidato a CIL depende, como explanado anteriormente, de suas características físicas e operacionais. No entanto, para este estudo, considerou todos os candidatos a CIL com mesmas características e, conseqüentemente, com mesmo valor de investimento. Este custo é definido de acordo com os cenários de avaliação (apresentados na Seção 2.4.2). Inicialmente, avaliou-se a partir de um valor simbólico de R\$ 1, devido a sua importância estratégica na concepção da malha de transportes do país. Posteriormente, avaliou-se os custos de abertura de R\$ 30 milhões e R\$ 100 milhões, com o objetivo de verificar o impacto da variação do custo fixo no resultado do modelo.

Os custos de transporte dos produtos dependem do modo que está sendo utilizado: quando é feito diretamente entre a origem e o destino, sem a passagem por um CIL, o produto utiliza apenas o modo rodoviário; por outro lado, caso passe por um CIL, o custo será de um transporte multimodal, incorporando-se, além do custo do

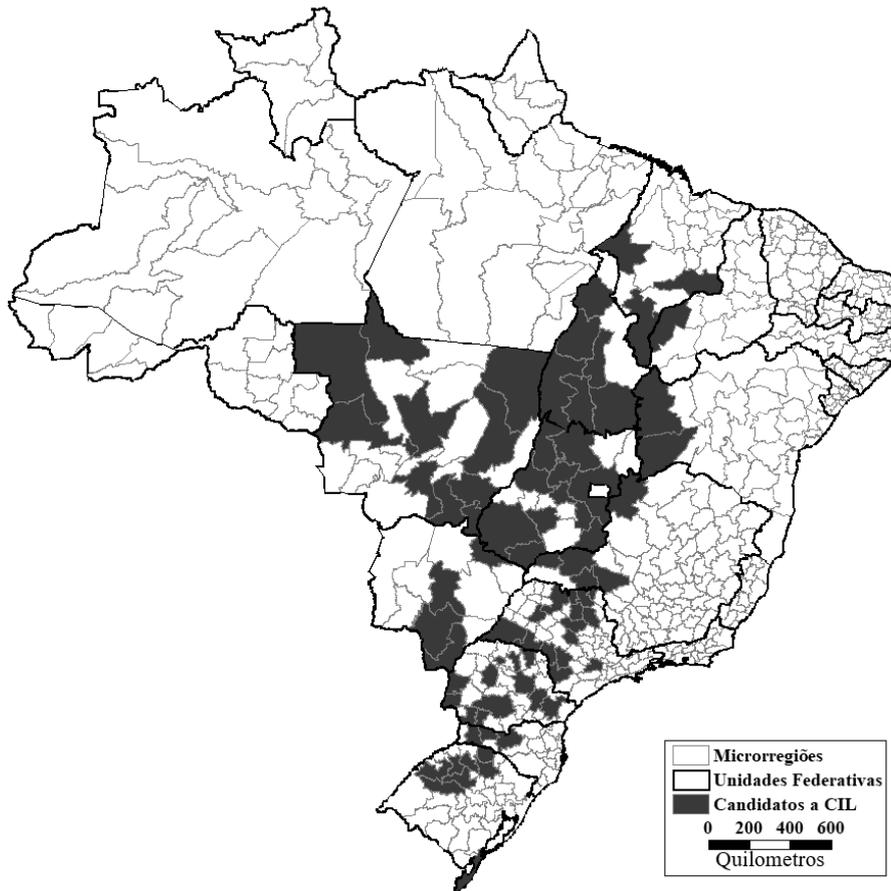


Figura 2.15: Microrregiões candidatas a construção de CIL

modo rodoviário, também o hidroviário, ferroviário e/ou de cabotagem (caso sejam utilizados).

As estimativas de custos de transportes utilizadas são provenientes das bases georreferenciadas do PNLT, que considera os projetos previstos no plano já implantados, ou seja, reproduz a rede para o horizonte de 2031. Então, foram criadas as redes para os períodos anteriores à 2031 retirando-se as melhorias previstas, evitando-se eliminar as ligações entre os pares OD.

Sabe-se que as condições da superfície de rolamento afetam o custo operacional dos veículos (COV), uma vez que pode haver, por exemplo, aumento no consumo de combustíveis, redução da vida útil dos pneus e aumento nos custos de manutenção do veículo. Desta forma, buscou-se, na literatura, referências para definir fatores de correção dos custos operacionais para os períodos intermediários que antecedem a implantação dos projetos previstos.

O relatório da Pesquisa CNT de Rodovias 2019 (CNT [86]) apontou que o estado péssimo do pavimento pode elevar os custos operacionais do transporte rodoviário de cargas em até 91,5%, enquanto que os estados ruim, regular e bom podem acrescer de, respectivamente, 65,6%, 41% e 18,8%. Ponderando-se estes valores à condição

da malha viária do Brasil, o relatório indica que o país gasta, em média, 28,5% a mais do que se as rodovias possuísem perfeito estado. A atualização para 2021 deste relatório (CNT [87]) aponta um aumento deste valor já para 30,9%. GEIPOP [88] apresentou que os custos operacionais obtidos para vias pavimentadas e não pavimentadas retornou um aumento de 61% para caminhões utilitários a diesel e 49% para caminhões médios.

Há, ainda na literatura, estudos que buscam correlacionar os custos operacionais dos veículos com a qualidade da via expressa a partir de indicadores, como o Índice de Irregularidade Superficial (IRI – *International Roughness Index*, proposto por PATERSON [89, 90]). O IRI descreve a escala de irregularidade longitudinal dos pavimentos, variando de 0 (superfície perfeitamente plana) a 20 (superfícies não pavimentadas extremamente avariadas). O IRI para vias não pavimentadas pode variar de 3 (quando o leito é natural e possui boas condições) a 20 (valor máximo do índice, para trechos em leito natural e péssimas condições).

BARNES e LANGWORTHY [91] indicaram um aumento de aproximadamente 13% no custo por milha de caminhão comercial quando o valor do IRI altera de 1,2 m/km para 2,7 m/km. No entanto, os valores de IRI abordados ainda estão abaixo da referência apontada para vias em leito natural (equivalente a 3 m/km), o que indica que o aumento percentual do custo pode ser ainda maior. ZAABAR e CHATTI [92], utilizando-se a ferramenta HDM-4, avaliaram o efeito da irregularidade superficial e da textura da via tanto nos diferentes elementos que constituem o custo operacional dos veículos (combustível, pneus, manutenção) quanto no valor total. Para os cenários de avaliação, variaram o tipo de veículo, valor do IRI (1 a 6) e a velocidade (56, 88 e 112 km/h). Como resultado, para a velocidade de 56 km/h, obtiveram que a variação do IRI de 1 para 6 pode resultar em um aumento de 21% para caminhões leves e médios e de 19% para caminhões pesados. Já para 88km/h, a mesma variação do IRI pode resultar em, respectivamente, aumento de 20%, 17% e 15% para caminhões leve, médio e pesados. Em uma abordagem similar, SUWARTO *et al.* [93] apresentaram uma investigação quanto à sensibilidade do IRI como indicador de performance de pavimentos e custo ao usuário, também baseado no HDM-4. Como resultado, apresentou os custos ao usuário (\$ por veículo-km) para diferentes tipos de veículo. Ao variar o valor do IRI de 2,1 m/km para 6,9 m/km, o estudo indicou um aumento de aproximadamente 13% nos custos ao usuário da via. As variações aqui apresentadas são sintetizadas na Tabela 2.8.

Observa-se que cada estudo apresenta uma abordagem metodológica específica e que resulta em uma variação particular ao caso avaliado. No entanto, estes orientaram a escolha dos fatores adotados neste estudo para o ajuste das matrizes nos períodos sem os projetos previstos no PNLT.

Os projetos de infraestrutura rodoviária previstos no PNLT estão subdivididos

Tabela 2.8: Resumo das variações do custo operacional dos veículos em função da condição do pavimento.

Referência	Variação
CNT [86]	18,8% a 91,5%, em função da qualidade da via ou 28,8% para a média ponderada da situação das rodovias brasileiras
GEIPOT [88]	61% para caminhões utilitários a diesel e 49% para caminhões médios
BARNES e LANGWORTHY [91]	13% para variação do IRI de 1,2 m/km para 2,7 m/km
ZAABAR e CHATTI [92]	15% a 21% dependendo da superfície e velocidade
SUWARTO <i>et al.</i> [93]	13% para variação do IRI de 2,1 m/km para 6,9 m/km

nas seguintes categorias: construção, adequação de capacidade, pavimentação e recuperação. Assim, para a correção das matrizes de custos operacionais do transporte rodoviário de carga para os períodos que precederam a implantação destes projetos, adotou-se os seguintes fatores de correção do custo operacional:

- Construção: a retirada do *link* na base georreferenciada resultou em problemas com a conectividade da rede entre as zonas OD, uma vez que a base georreferenciada é simplificada. Por tanto, considerou-se nas ligações antes da construção a existência de uma ligação não pavimentada (rodovia em leito natural), resultando no aumento de 49% dos custos;
- Adequação de capacidade: acréscimo de 13%;
- Pavimentação: acréscimo de 17%; e
- Recuperação: acréscimo de 28,5%.

Ajustadas as informações de custos para os diferentes períodos de análise na base georreferenciada da rede de transporte, executou-se um primeiro programa, desenvolvido em linguagem GISDK e integrado ao TransCAD, capaz de calcular as matrizes de caminhos mínimos para cada período entre todas as microrregiões, considerando-se o custo operacional na minimização. Como resultado desta aplicação, obteve-se matrizes de custo (em R\$ por tonelada) para o transporte direto entre as microrregiões (C_{ijm}^{dir}), entre as zonas de produção e candidatas à instalação de CILs (C_{tikm}^{ent}) e das zonas candidatas às zonas de consumo (C_{tkjm}^{sai}).

e. Emissões Ambientais

A introdução de uma abordagem ambiental no processo de localização de CILs foi proposta inicialmente por GUIMARÃES [3], ao considerar os custos da emissão de

CO_2 no modelo matemático. A autora considerou, a partir de diferentes referências presentes na literatura, fatores de emissão mínimos, médios e máximos de CO_2 para os diferentes modos de transportes presentes na rede do PNLT. Como o modelo proposto nesta tese também considera os custos de emissões de CO_2 ($Z(\text{emissões})$), utilizou-se os valores médios para os fatores de emissão, conforme segue: 77,6 g/t.km para o rodoviário, 21,625 g/t.km para o ferroviário, 9,3 g/t.km para o marítimo; e 30,6 g/t.km para a navegação de interior.

Para que as emissões fossem monetizadas, levantou-se a variação do preço do crédito de carbono (INVESTING.COM [94]) para o período de três meses (compreendido entre os dias 01/04/2020 e 01/07/2020), verificando-se o valor médio de £ 21,31, equivalente a R\$ 138,55 (utilizando-se o valor cambial médio do mês de junho/2020, R\$6,50/£, segundo INVESTING.COM [95]).

Com o objetivo de validar a precificação das emissões de CO_2 adotada a partir de informações do comércio de carbono, elencou-se quatro mercados de carbono localizados no continente americano, sendo dois nos Estados Unidos (*Californian Cap and Trade Program* e *Regional Greenhouse Gas Initiative*) e dois no Canadá (*Québec Cap and Trade Program* e *Nova Scotia Cap-and-Trade Program*). A partir da base disponibilizada pelo INTERNATIONAL CARBON ACTION PARTNERSHIP - ICAP [96], obteve-se o valor médio de US\$27,21 para o período compreendido entre 01/07/2023 a 31/12/2023, ou R\$134,41 (convertido para o real utilizando-se o valor de R\$4,94 para o câmbio do dólar, média para o período compreendido entre 04/10/2023 a 04/03/2024 – INVESTING.COM [97]). Observa-se que o valor encontrado é próximo ao já adotado para aplicação.

2.4.2 Cenários de avaliação

Visando avaliar a economia obtida com a abertura de CILs através do PMLCIL, elaborou-se, inicialmente, o cenário base de comparação sem instalações de facilidades, denominado *Nada a Fazer*. Seis cenários foram então estabelecidos ampliando-se as restrições impostas para abertura dos CILs, conforme apresentado na Tabela 2.9:

- Cenário 0: os CILs possuem custo simbólico de abertura de R\$1,00, devido a sua importância estratégica na concepção da malha de transportes do país, sendo o cenário 0a com volume mínimo de 1 tonelada e 0b de 1 milhão de toneladas a ser respeitado para abertura de um CIL;
- Cenário 1: o custo para abertura de um CIL é 30 milhões de reais, sendo o cenário 1a e 1b com volume mínimo de 1 tonelada e 1 milhão de toneladas a ser respeitado para abertura de um CIL; e

- Cenário 2: similar aos Cenários 1a e 1b, mas agora com custo de abertura de 100 milhões de reais.

Tabela 2.9: Cenários de avaliação.

Cenários	Custo Fixo (R\$ - g_k)	Volume mínimo (toneladas - v_{tk}^{min})
<i>Nada a Fazer</i>	Sem abertura de CILs	
0a	1	1
0b	1	1×10^6
1a	30×10^6	1
1b	30×10^6	1×10^6
2a	100×10^6	1
2b	100×10^6	1×10^6

Cabe destacar que o Cenário 0a possui menores restrições (valor simbólico de abertura e sem volume mínimo significativo), e pode não representar apropriadamente a realidade. No entanto, a avaliação deste é importante para verificar o impacto deste tipo de estrutura na rede logística.

Com o objetivo de avaliar o modelo proposto primeiro em instâncias menores para, então aumentar o desafio da aplicação, reduziu-se as matrizes OD da soja, criando-se um escalonamento de aplicação seguindo a ordem decrescente de volume produzido. Ou seja, a primeira avaliação considerou apenas a matriz de soja com origens no Centro-Oests (CO). Em seguida, realizou-se as análises da soja produzida nas regiões Centro-Oeste (CO) e Sul (S). Posteriormente, foram sucessivamente adicionadas as regiões Nordeste (NE), Sudeste (SE) e Norte (N), conforme apresentado na Tabela 2.10. Desta forma, a última instância, denominada de *COSNESEN*, abrange a matriz OD de produção para todo o país. Este escalonamento das instâncias será principalmente explorado na etapa de avaliação das abordagens heurísticas propostas.

Tabela 2.10: Instâncias elaboradas para avaliação.

Instância	Regiões de origem da soja	Tamanho da matriz
<i>CO</i>	CO	52 x 559
<i>COS</i>	CO + S	146 x 559
<i>COSNE</i>	CO + S + NE	334 x 559
<i>COSNESE</i>	CO + S + NE + SE	494 x 559
<i>COSNESEN</i>	CO + S + NE + SE + N	558 x 559

2.4.3 Avaliação do modelo matemático

Em uma análise inicial, o modelo matemático multiperíodo proposto ao PMLCIL foi aplicado aos seis cenários de avaliação (Tabela 2.9) para cada uma das cinco instâncias de soja criadas (Tabela 2.10). Nesta avaliação, tanto o termo econômico

quanto ambiental da função objetivo foram considerados para a localização ótima das facilidades, ou seja, adotou-se $\alpha = 1$ e $\beta = 1$. Os resultados foram obtidos utilizando-se o programa computacional Gurobi 9.0 e são apresentados na Tabela 2.11.

Verificou-se que, somando-se os quatro períodos, o custo total para o cenário *Nada a Fazer* varia de R\$ 14,796 bi (instância *CO*) a R\$ 28,648 bi (instância *COSNESEN*). Tem-se, ainda, que o custo logístico representou a maior parcela de dispendios, aproximadamente 88% do total, ante 12% dos custos de emissões de CO_2 .

Ao comparar os resultados da localização ótima de facilidades com o cenário base, observou-se que a implantação de CILs pode reduzir os custos totais de 41% (para os cenários 2a e 2b da instância *COSNESEN*) a 56% (para o cenário 0a da instância *COS*). Quanto aos custos logísticos, observou-se reduções de 40% (para os cenários 2a e 2b da instância *COSNESEN*) a 55% (para o cenário 0a da instância *COS*). Já para os custos de emissões de CO_2 , verificou-se reduções de 53% (para os cenários 2a e 2b das instâncias *COSNESE* e *COSNESEN*) a 58% (para os cenários 0a e 0b da instância *COS*). Portanto, mesmo para os cenários mais restritivos quanto à abertura de CILs (Cenário 2b), obteve-se redução de 40% nos custos logísticos e de 53% nos custos de emissões de CO_2 para o sistema logístico brasileiro.

De forma geral, os maiores ganhos percentuais foram observados para a instância *COS*, enquanto os menores ganhos percentuais para a instância *COSNESE*. Além disso, os Cenários 2a e 2b apresentaram maiores custos logísticos e, conseqüentemente, menores ganhos, devido ao custo fixo de abertura das facilidades.

Cabe destacar que os totais analisados são resultados da soma dos quatro períodos considerados. Ou seja, não são calculados os custos logísticos e de emissões para os anos intermediários (entre períodos). No entanto, o modelo apresentado não está limitado à apenas esta quantidade de horizontes, podendo realizar análises com mais períodos ou para a vida útil das infraestruturas. Desta forma, as avaliações financeira e econômica considerando-se a vida útil ou tempo de contrato destas facilidades podem resultar em valores positivos para a viabilidades destes projetos. Estes são ganhos expressivos e que podem refletir positivamente até mesmo no preço final de venda da soja. No entanto, atenta-se que, ao adicionar mais períodos de avaliação, será necessário maior custo computacional para obter soluções.

Apesar de terem sido abordadas diversas instâncias que incorporam as regiões produtoras de soja, escalonando-se as dimensões das matrizes OD, discute-se, a seguir, os resultados para a distribuição de soja produzida em nível nacional (todo o Brasil), ou seja, a instância *COSNESEN*. Os demais resultados são posteriormente utilizados para comparação com os obtidos pela metaheurística evolutiva proposta.

Tabela 2.11: Resultados ótimos para as diferentes instâncias de soja.

Instância	Cenários		Nada a fazer		0a	0b	1a	1b	2a	2b
	Custo Fixo (g_k , R\$)	Volume mínimo (v_{tk}^{min} , ton.)	1	1	1	1×10^6	30×10^6	30×10^6	100×10^6	100×10^6
CO	Tempo Computacional (s)	-	124	1,774	709	568	632	1,597		
	Custo Total ($\times 10^9$ R\$)	14,796	6,904	7,150	7,483	7,530	8,146	8,146		
	Comparação ao Nada a Fazer	-	-53%	-52%	-49%	-49%	-45%	-45%		
	Custos logísticos ($\times 10^9$ R\$)	13,048	6,152	6,380	6,723	6,759	7,343	7,343		
	Comparação ao Nada a Fazer	-	-53%	-51%	-48%	-48%	-44%	-44%		
	Custos Emissões CO2 ($\times 10^9$ R\$)	1,748	0,752	0,770	0,760	0,771	0,803	0,803		
	Comparação ao Nada a Fazer	-	-57%	-56%	-56%	-56%	-54%	-54%		
COS	Tempo Computacional (s)	-	349	3,163	1,541	1,122	4,388	8,424		
	Custo Total ($\times 10^9$ R\$)	20,397	9,069	9,356	10,138	10,163	11,354	11,354		
	Comparação ao Nada a Fazer	-	-56%	-54%	-50%	-50%	-44%	-44%		
	Custos logísticos ($\times 10^9$ R\$)	18,107	8,115	8,382	9,163	9,182	10,305	10,305		
	Comparação ao Nada a Fazer	-	-55%	-54%	-49%	-49%	-43%	-43%		
	Custos Emissões CO2 ($\times 10^9$ R\$)	2,290	0,954	0,973	0,975	0,981	1,049	1,049		
	Comparação ao Nada a Fazer	-	-58%	-58%	-57%	-57%	-54%	-54%		
COSNE	Tempo Computacional (s)	-	803	2,739	2,344	2,903	5,009	5,507		
	Custo Total ($\times 10^9$ R\$)	25,452	11,981	12,345	13,221	13,281	14,676	14,676		
	Comparação ao Nada a Fazer	-	-53%	-51%	-48%	-48%	-42%	-42%		
	Custos logísticos ($\times 10^9$ R\$)	22,511	10,724	11,064	11,938	11,991	13,316	13,316		
	Comparação ao Nada a Fazer	-	-52%	-51%	-47%	-47%	-41%	-41%		
	Custos Emissões CO2 ($\times 10^9$ R\$)	2,941	1,257	1,281	1,283	1,290	1,360	1,360		
	Comparação ao Nada a Fazer	-	-57%	-56%	-56%	-56%	-54%	-54%		

Continua na próxima página.

Tabela 2.11 - Resultados ótimos para as diferentes instâncias de soja (continuação).

Instância	Cenários		<i>Nada a fazer</i>					
	g_k , R\$	v_{tk}^{min} , ton.)	0a	0b	1a	1b	2a	2b
GOSNESE	Custo Fixo	-	1	1	30×10^6	30×10^6	100×10^6	100×10^6
	Volume mínimo	-	1	1×10^6	1	1×10^6	1	1×10^6
	Tempo Computacional (s)	-	1.458	16.566	3.681	3.444	27.400	19.848
	Custo Total ($\times 10^9$ R\$)	26,379	12,347	12,787	13,703	13,751	15,236	15,236
	Comparação ao <i>Nada a Fazer</i>	-	-53%	-52%	-48%	-48%	-42%	-42%
	Custos logísticos ($\times 10^9$ R\$)	23,351	11,044	11,459	12,371	12,413	13,822	13,822
	Comparação ao <i>Nada a Fazer</i>	-	-53%	-51%	-47%	-47%	-41%	-41%
	Custos Emissões CO2 ($\times 10^9$ R\$)	3,028	1,303	1,328	1,332	1,338	1,414	1,414
	Comparação ao <i>Nada a Fazer</i>	-	-57%	-56%	-56%	-56%	-53%	-53%
	GOSNESEN	Tempo Computacional (s)	-	1.664	25.652	2.842	5.334	20.751
Custo Total ($\times 10^9$ R\$)		28,648	13,815	14,298	15,266	15,301	16,839	16,840
Comparação ao <i>Nada a Fazer</i>		-	-52%	-50%	-47%	-47%	-41%	-41%
Custos logísticos ($\times 10^9$ R\$)		25,331	12,372	12,826	13,778	13,808	15,269	15,270
Comparação ao <i>Nada a Fazer</i>		-	-51%	-49%	-46%	-45%	-40%	-40%
Custos Emissões CO2 ($\times 10^9$ R\$)		3,317	1,443	1,472	1,488	1,493	1,570	1,570
Comparação ao <i>Nada a Fazer</i>		-	-56%	-56%	-55%	-55%	-53%	-53%

A Figura 2.16 ilustra, para a instância *COSNESEN*, os custos totais obtidos para cada cenário de avaliação. Nota-se que o custo tende a aumentar do cenário 0a ao cenário 2b, em consequência do aumento do custo fixo considerado para abertura das facilidades. A partir da Figura 2.17, observa-se que os custos logísticos são as principais parcelas dos custos totais, representando, em média, aproximadamente 90% do total, enquanto a parcela de emissões de CO_2 varia entre 9% e 12%.

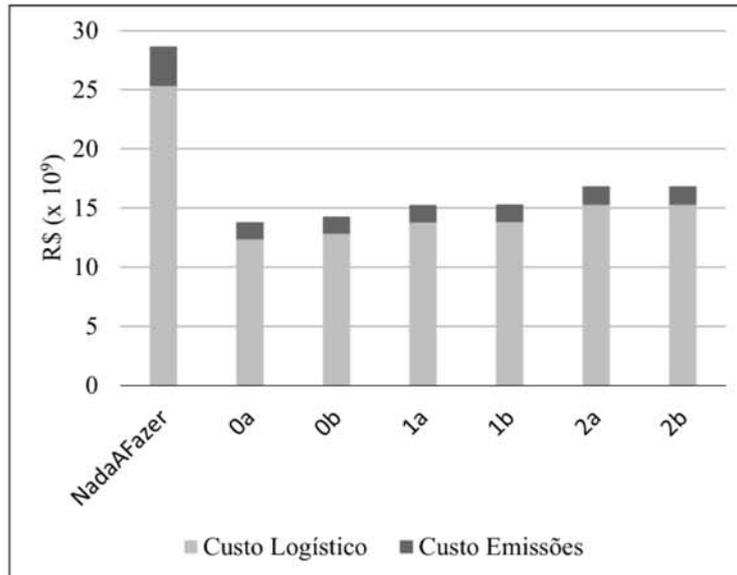


Figura 2.16: Custo total, dividido em custo logístico e de emissões, obtido para os cenários de avaliação aplicados à instância *COSNESEN*.

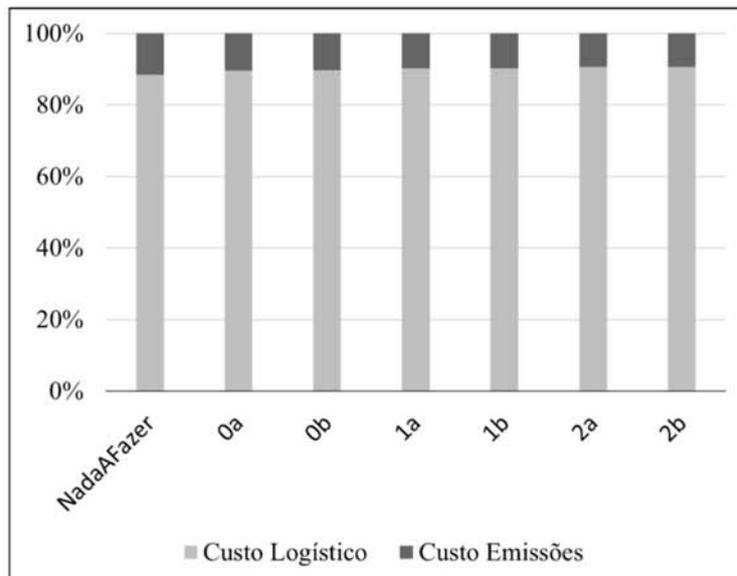


Figura 2.17: Proporção do custo total em custos logísticos e de emissões para os cenários de avaliação aplicados à instância *COSNESEN*.

As quantidades de candidatos a CIL abertos em cada região brasileira para cada cenário são apresentadas na Tabela 2.12. O cenário avaliado é indicado na primeira

coluna. Na coluna seguinte apresenta-se a região brasileira que possui microrregiões candidatas a instalação de CILs. Nas colunas seguintes apresenta-se, agregados por região, a quantidade total de facilidades disponível para localização (terceira coluna) e que foram selecionadas para abertura nos períodos de 2019, 2023, 2027 e 2031 (quarta a sétima colunas respectivamente). Na última coluna, apresenta-se o somatório das facilidades abertas. Uma tabela similar à esta, porém contendo os resultados para as demais instâncias criadas, é apresentada no Apêndice D.

Como esperado, o Cenário 0a foi o que apresentou maior quantidade de CILs abertos, em consequência do baixo custo inicial e volume mínimo não significativo para abertura. No entanto, a expressiva localização de facilidades logo no primeiro período reforça a importância econômica e estratégica dos CILs. Ao impor a quantidade mínima de 10^6 toneladas (Cenário 0b), a quantidade de facilidades abertas foi reduzida a 41, sendo 35 em 2019 e 2 em cada um dos períodos subsequentes. Este resultado destaca a relevância da utilização de abordagens multiperíodo como suporte à decisões de planejamento estratégico dos transportes.

Ao considerar o custo fixo de abertura de cada CIL igual a R\$ 30 mi, observou-se abertura de 31 facilidades para o Cenário 1a e 30 para o Cenário 1b. Porém, ao incrementar ainda mais este custo, alterando-se o valor para R\$ 100 mi, a quantidade de facilidades abertas reduziu para quase a metade, obtendo-se apenas 16 CILs abertos tanto para o cenário 2a quanto para o 2b. Nestes dois últimos cenários, dos mesmos 16 candidatos foram selecionados para abertura.

Para analisar o efeito de se considerar volume mínimos para abertura de CILs, nota-se resultados próximos ao comparar os cenários 1a com 1b e 2a com 2b. Já para o cenário 0, devido ao custo simbólico de abertura que permite a localização de uma maior quantidade de CILs sem impactar no custo geral, observa-se que a restrição de volume mínimo reduziu a quantidade de CILs abertos de 79 (Cenário 0a) para 35 (Cenário 0b).

Tabela 2.12: Quantidade de CILs abertos em cada horizonte para os diferentes cenários a partir da instância *COSNESEN*.

Cenário	Região	#CILS Dispon.	#CILs Selecionados				Total
			2019	2023	2027	2031	
0a	N	6	6	0	0	0	6
	NE	6	6	0	0	0	6
	SE	20	20	0	0	0	20
	S	23	23	0	0	0	23
	CO	25	24	0	0	0	24
	Total	80	79	0	0	0	79

Continua na próxima página.

Tabela 2.12 - Quantidade de CILs abertos em cada período para os diferentes cenários a partir da instância *COSNESEN*. (continuação).

Cenário	Região	#CILs Dispon.	#CILs Selecionados				Total
			2019	2023	2027	2031	
0b	N	6	0	2	0	1	3
	NE	6	4	0	1	0	5
	SE	20	5	0	0	0	5
	S	23	15	0	0	0	15
	CO	25	11	0	1	1	13
	Total	80	35	2	2	2	41
1a	N	6	1	0	0	0	1
	NE	6	5	0	0	0	5
	SE	20	4	0	0	0	4
	S	23	12	0	0	0	12
	CO	25	9	0	0	0	9
	Total	80	31	0	0	0	31
1b	N	6	0	1	0	0	1
	NE	6	4	0	0	0	4
	SE	20	4	0	0	0	4
	S	23	12	0	0	0	12
	CO	25	9	0	0	0	9
	Total	80	29	1	0	0	30
2a	N	6	0	0	0	0	0
	NE	6	2	0	0	0	2
	SE	20	3	0	0	0	3
	S	23	5	0	0	0	5
	CO	25	6	0	0	0	6
	Total	80	16	0	0	0	16
2b	N	6	0	0	0	0	0
	NE	6	2	0	0	0	2
	SE	20	3	0	0	0	3
	S	23	5	0	0	0	5
	CO	25	6	0	0	0	6
	Total	80	16	0	0	0	16

A Figura 2.18 apresenta a divisão dos volumes transportados diretamente entre os pares OD (fluxo ij) e passando por um CIL (fluxo ikj) em cada período para os cenários avaliados. Verifica-se, para todos os períodos e cenários, que a maior parte do volume de soja é transportado através da rede multimodal proporcionada pela localização das facilidades. Destaca-se, ainda, a capacidade do modelo em alocar os fluxos crescentes da demanda, expresso pelo crescimento do volume transportado diretamente e pelos CILs período a período.

A importância operacional e estratégica dos CILs no sistema logístico brasileiro fica mais evidente ao avaliar o gráfico apresentado na Figura 2.19, que apresenta

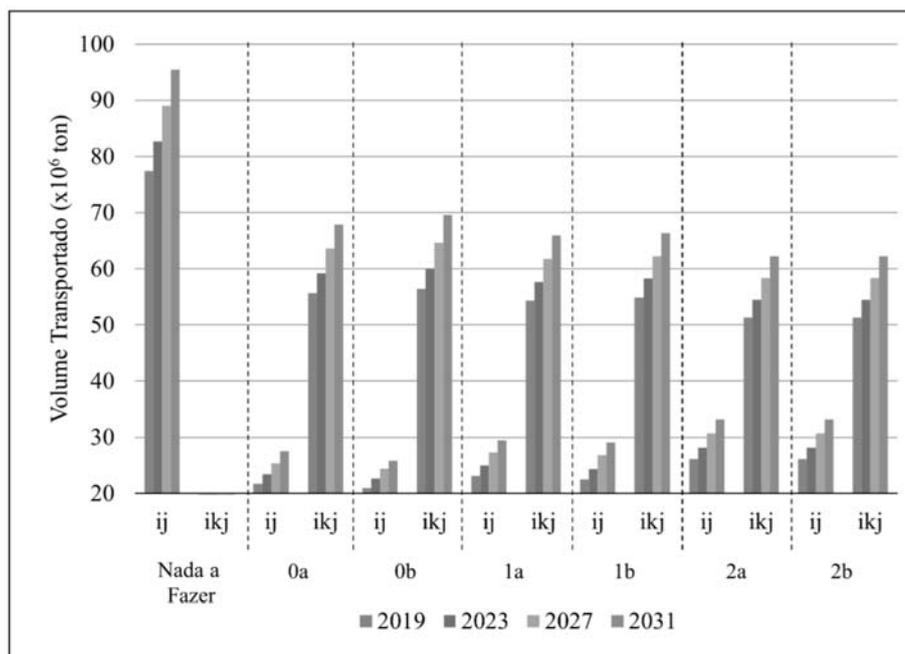


Figura 2.18: Volume transportado diretamente entre o par OD (referência ij) e através de CILs (referência ikj) para cada cenário de avaliação (instância *COSNESEN*).

a porcentagem do volume total que é transportado diretamente entre os pares OD (Total Direto) e passando por um CIL (Total CIL). Observa-se que nos cenários 2a e 2b, que tiveram menor quantidade de CILs selecionados para abertura (16 candidatos), 66% do volume de soja foi transportado através destas facilidades. Já para os cenários com menor custo fixo, essa porcentagem chegou a 73% (cenário 0b, que teve 41 facilidades abertas).

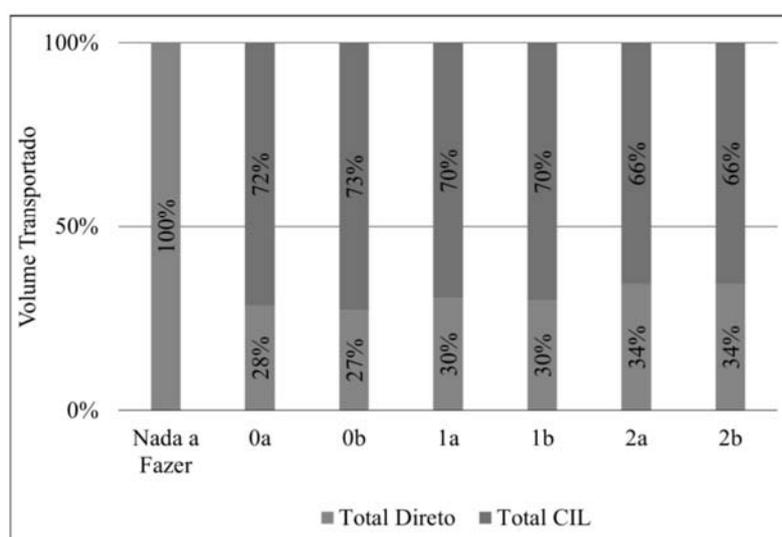


Figura 2.19: Volume transportado diretamente entre o par OD (Total Direto) e através de CILs (Total CIL) para cada cenário de avaliação (instância *COSNESEN*).

Na Figura 2.20 são ilustrados, para cada cenário de avaliação, os volumes opera-

dos pelos CILs agregados segundo a localização destes. A Tabela 2.13 e a Tabela 2.14 apresentam, para cada cenário, o menor e o maior volumes operacionais dos CILs de cada região. O detalhamento dos volumes em cada CIL resultantes da aplicação do modelo pode ser consultado no Apêndice D.

Verifica-se que as facilidades localizadas nas regiões CO e S tiveram maiores fluxos de soja. Esse resultado pode ser justificado por estas regiões serem as maiores produtoras da *commodity* em estudo, conforme apresentado na Tabela 2.6, e serem as localidades com maior quantitativo de facilidades abertas, como pode ser observado na Tabela 2.12. Consequentemente, observa-se que as infraestruturas com maior fluxo passante (máximos) estão localizadas principalmente nas regiões Centro-Oeste e Sudeste, apontando eixos que podem requerer infraestruturas de maiores dimensões comparadas às demais regiões. Destaca-se, ainda, que a região Norte possui as estruturas com os menores fluxos máximos e que deixam de ser localizadas nos cenários com maior custo fixo para abertura dos CILs (Cenários 2a e 2b).

Os volumes operacionais de cada facilidade aberta para cada período podem ser também expressos em mapas temáticos, como ilustrado na Figura 2.21. Nesta, são apresentados os fluxos dos quatro períodos de análise para o Cenário 0a, onde menores fluxos são indicados por cinza claro e os maiores fluxos operacionais em vermelho escuro. Destaca-se, com um círculo roxo, dois exemplos de candidatos a CIL em que a demanda aumenta ao passar do tempo (a coloração tende ao vermelho). Já com um círculo verde, destaca-se um CIL em que a demanda reduz com o passar do tempo. No entanto, cabe destacar que o modelo não permite redução à volumes abaixo do mínimo estabelecido para abertura do CIL. Os diagramas para os demais cenários de avaliação estão localizados no Apêndice D.

Esta informação pode servir para orientar a elaboração de planos estratégicos que englobam diferentes períodos, como, por exemplo, projetos que visam a implantação de CILs com características operacionais que atendam o fluxo inicial mas que já consideram ampliação ou limitações de suas funcionalidades para atendimento das demandas futuras.

A comparação entre os resultados obtidos indicou comportamento correto do modelo de otimização, uma vez que houve reduções nos custos logísticos e nos custos de emissões a partir da localização de facilidades em diferentes períodos. Além disso, as economias obtidas tanto nos custos logísticos quanto nos custos em emissões ressaltam a importância econômica e ambiental da abertura de CILs.

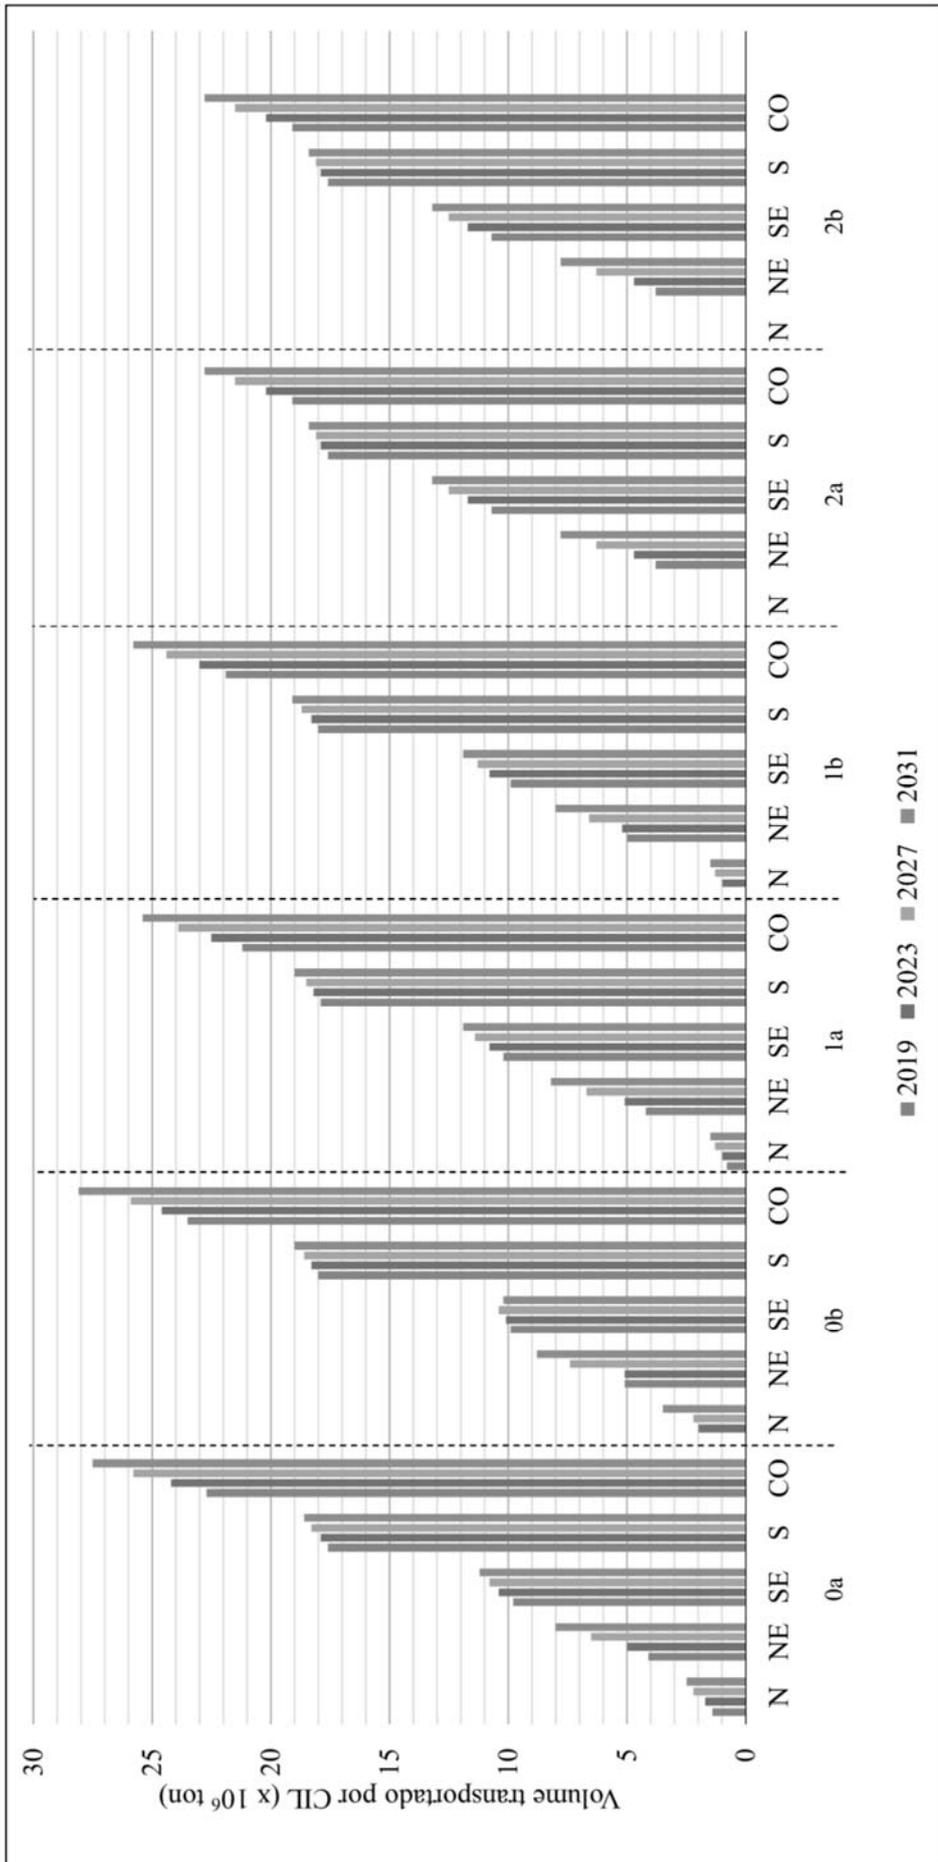


Figura 2.20: Volumes operacionais totais dos CILs agregados de acordo com a região para cada cenário de avaliação.

Tabela 2.13: Volumes mínimos e máximos transportado através dos CILs localizados nas regiões Norte, Nordeste e Sudeste.

Cenário	Período	Norte		Nordeste		Sudeste	
		Vol. min. (x10 ³ ton.)	Vol. max. (x10 ³ ton.)	Vol. min. (x10 ³ ton.)	Vol. max. (x10 ³ ton.)	Vol. min. (x10 ³ ton.)	Vol. max. (x10 ³ ton.)
0a	2019	27	576	112	1.741	4	3.641
	2023	25	718	152	1.990	5	4.320
	2027	26	936	226	2.451	5	4.956
	2031	27	1.074	282	2.914	4	5.417
0b	2019	-	-	1.000	2.056	1.000	3.857
	2023	1.000	1.000	1.000	2.070	1.000	4.239
	2027	1.000	1.211	1.000	2.754	1.000	4.767
	2031	1.000	1.494	1.000	3.276	1.000	4.780
1a	2019	817	817	187	1.939	1.062	4.110
	2023	1.018	1.018	252	2.254	1.010	4.934
	2027	1.260	1.260	335	2.774	1.078	5.614
	2031	1.502	1.502	405	3.295	1.063	6.380
1b	2019	-	-	1.000	2.029	1.058	3.897
	2023	1.000	1.000	1.000	2.157	1.065	4.831
	2027	1.268	1.268	1.000	2.807	1.089	5.569
	2031	1.547	1.547	1.114	3.339	1.119	6.276
2a	2019	-	-	695	3.126	1.675	5.162
	2023	-	-	955	3.747	1.739	6.194
	2027	-	-	1.164	5.108	1.744	7.106
	2031	-	-	1.373	6.469	1.748	8.018
2b	2019	-	-	1.000	2.822	1.675	5.162
	2023	-	-	1.000	3.703	1.737	6.184
	2027	-	-	1.164	5.108	1.742	7.061
	2031	-	-	1.373	6.469	1.746	7.973

Tabela 2.14: Volumes mínimos e máximos transportado através dos CILs localizados nas regiões: Sul e Centro-Oeste.

Cenário	Período	Sul		Centro-Oeste	
		Vol. min. (x10 ³ ton.)	Vol. max. (x10 ³ ton.)	Vol. min. (x10 ³ ton.)	Vol. max. (x10 ³ ton.)
0a	2019	97	2.446	1	7.013
	2023	95	2.520	1	7.203
	2027	92	2.728	1	7.663
	2031	89	2.443	1	8.123
0b	2019	1.000	2.235	1.000	7.069
	2023	1.000	2.222	1.000	7.258
	2027	1.000	2.205	1.000	7.703
	2031	0	2.202	1.000	8.113
1a	2019	827	2.395	450	7.078
	2023	438	2.924	547	7.266
	2027	827	2.713	598	7.729
	2031	825	2.892	643	8.190
1b	2019	1.000	2.241	1.000	7.076
	2023	1.000	2.363	1.000	7.266
	2027	1.000	2.530	1.000	7.729
	2031	1.000	2.718	1.000	8.190
2a	2019	1.768	5.700	1.142	7.108
	2023	1.782	5.620	1.529	7.299
	2027	1.827	5.466	1.639	7.770
	2031	1.872	5.368	1.750	8.241
2b	2019	1.758	5.711	1.142	7.113
	2023	1.771	5.631	1.529	7.304
	2027	1.815	5.478	1.639	7.778
	2031	1.860	5.381	1.750	8.251

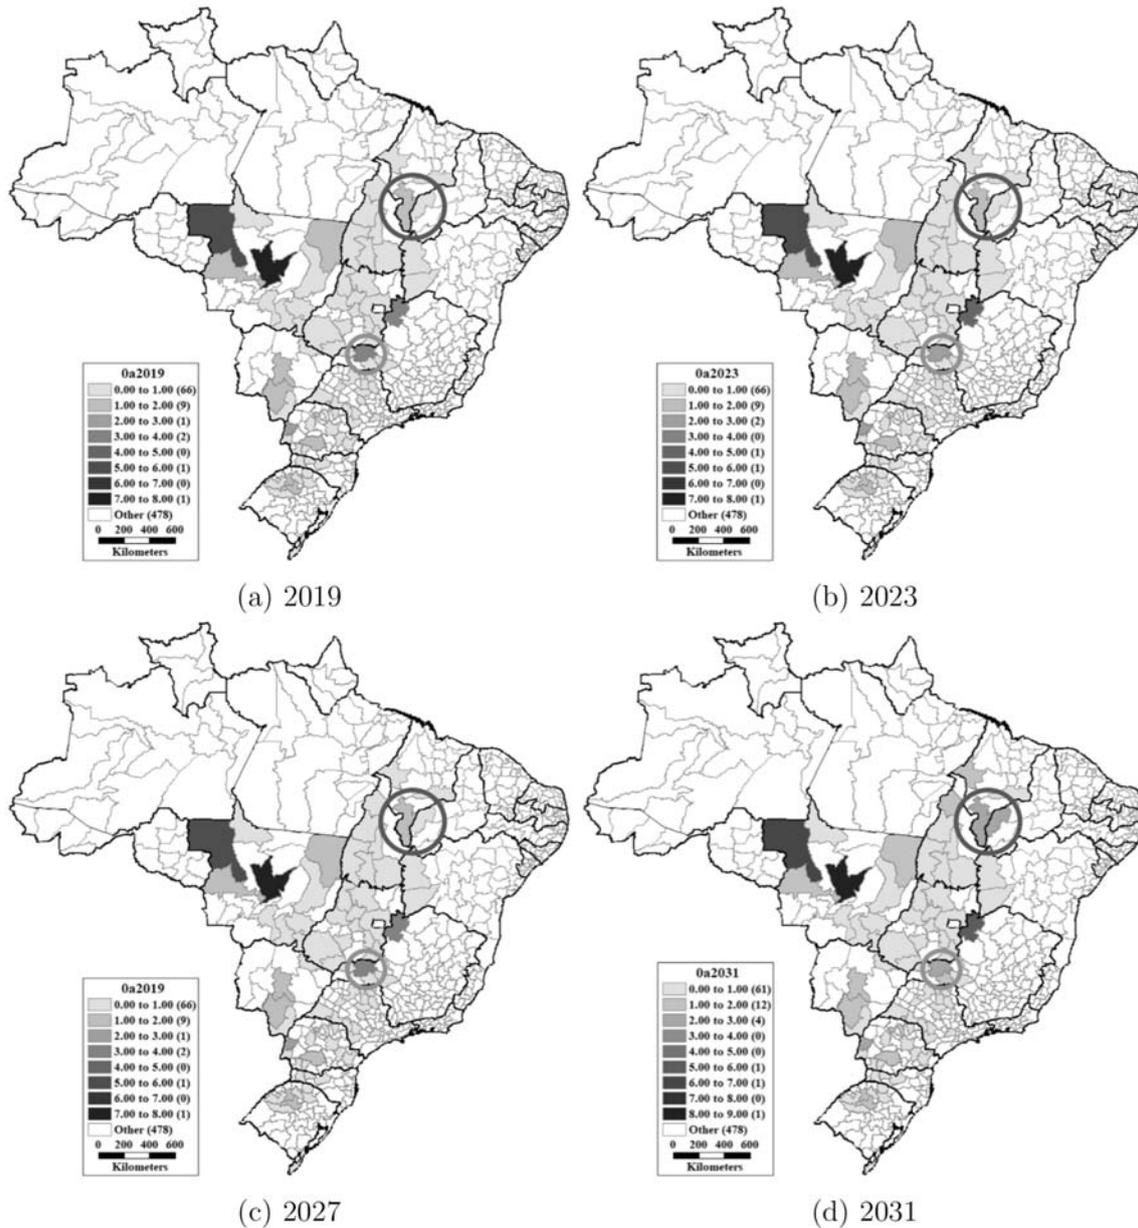


Figura 2.21: Volume operacional dos CILs em cada período para o Cenário 0a e instância *COSNESEN* (volumes em 10^6 toneladas).

2.4.4 Análise de sensibilidade dos pesos α e β

A função mono-objetivo (3.1) possui os pesos α e β associados, respectivamente, aos custos logísticos e de emissões de CO_2 . Na avaliação apresentada na seção anterior, foi avaliado o comportamento do modelo considerando-se estes dois critérios com mesmo valor de peso no processo de minimização, isto é, com $\alpha = 1$ e $\beta = 1$.

Visando avaliar o efeito de α e β em (3.1), esta seção apresenta uma análise baseada no conceito de Eficiência de Pareto. Para isto, iniciando de um modelo puramente ambiental (considerando somente os custos de emissões de CO_2 , isto é, $\alpha = 0$ e $\beta = 1$), o valor de α é progressivamente incrementado em 0,1, enquanto

o valor de β reduz em 0,1 até ser atingido o modelo puramente econômico (considerando apenas os custos logísticos, $\alpha = 1$ e $\beta = 0$). O primeiro e o último passo permitem avaliar a influência de cada peso na função mono-objetiva.

Este procedimento foi aplicado aos cenários com custo fixo, isto é, Cenários 1a, 1b, 2a e 2b, por serem mais aderentes à realidade. Além disso, utilizou-se apenas a instância com a matriz OD de soja nacional completa (COSNESEN). Novamente, os cenários foram comparados ao cenário *Nada a Fazer*, no qual nenhum CIL é disponível, para verificação dos ganhos econômicos e ambientais. Embora os custos logísticos totais ($\mathcal{Z}(C_{\log.})$) e os custos totais de emissão de CO_2 ($\mathcal{Z}(C_{\text{emiss.}})$) não sejam integralmente contabilizados na Função Objetivo (3.1) quando ponderados por pesos (α e β) diferentes de 1, ambos foram calculados após a otimização visando a comparação de economias ou despesas, conforme apresentado na Tabela 2.15.

O cenário e os valores de α e β avaliados são apresentados, respectivamente, na primeira, segunda e terceira colunas. A quantidade de CILs abertos em cada período avaliado – 2019, 2023, 2027 e 2031 – e o valor total de CILs localizados são apresentados, respectivamente, na quarta, quinta, sexta, sétima e oitava colunas. Na nona e décima primeira coluna, apresenta-se, respectivamente, os custos logísticos ($\mathcal{Z}(C_{\log.})$) e de emissões de CO_2 ($\mathcal{Z}(C_{\text{emiss.}})$). Já na décima terceira coluna, apresenta-se os custos totais, resultante da soma das duas parcelas avaliadas: $\mathcal{Z}(C_{\text{total}}) = \mathcal{Z}(C_{\log.}) + \mathcal{Z}(C_{\text{emiss.}})$. Por fim, as economias avaliadas em consequência da abertura dos CILs, quando comparados com o cenário *Nada a Fazer*, para os custos logísticos ($\Delta\mathcal{Z}(C_{\log.})$), custos de emissões de CO_2 ($\Delta\mathcal{Z}(C_{\text{emiss.}})$) e dos custos totais ($\Delta\mathcal{Z}(C_{\text{total}})$) são apresentados na décima, décima segunda e décima quarta colunas respectivamente.

Nos cenários em que uma capacidade mínima para abrir um CIL não é significativa (Cenários 1a e 2a), todas as 80 microrregiões candidatas são abertas na avaliação puramente ambiental ($\alpha = 0$ e $\beta = 1$). Esse resultado é esperado uma vez que os custos logísticos não são considerados na otimização e reforça o conceito dos CILs como importantes infraestruturas para a redução de emissões de CO_2 no sistema de transportes brasileiro. As emissões são reduzidas devido à multimodalidade relacionada aos CILs abertos. Cabe destacar que, mesmo com a abertura de todas as facilidades, tem-se uma redução dos custos logísticos de 39% para o Cenário 1a e de 17% para o Cenário 2a. Ou seja, obteve-se economias nos custos logísticos mesmo sem considerá-los no processo de otimização.

Observa-se que o número de CILs abertos reduz conforme o valor de α aumenta e o valor de β diminui gradualmente. Por fim, as economias aumentam para os custos logísticos e diminuem para os custos ambientais em todas as avaliações.

Os valores de $\Delta\mathcal{Z}(C_{\log.})$ e $\Delta\mathcal{Z}(C_{\text{emiss.}})$ apresentados Tabela 2.15 foram plotados, para cada cenário, a fim de mostrar as fronteiras de Pareto, conforme ilustrado na

Figura 2.23. É importante destacar que esses valores são uma variação percentual em relação ao cenário *Nada a Fazer*. Para todos os cenários, à medida que o valor de α aumenta (o que indica que o peso da emissão é reduzido), os gráficos mostram que a redução dos custos logísticos em relação ao cenário base tende a estabilizar em um patamar. Por outro lado, os custos relacionados às emissões de CO₂ tendem a aumentar, reduzindo os ganhos ambientais. Isso indica que, após um certo valor de α e β , os ganhos nos custos logísticos e de emissões de CO₂ não são significativos. Assim, um ponto de equilíbrio entre $\Delta Z(C_{log.})$ e $\Delta Z(C_{emiss.})$ pode ser determinado para cada cenário. Ao avaliar os custos totais $Z(C_{total})$ apresentados na Tabela 2.15, verifica-se que o menor valor foi obtido para o Cenário 1a quando utilizado os valores de $\alpha = 0,6$ e $\beta = 0,4$; para o Cenário 1b quando utilizado valores variando de $\alpha = 0,4$ e $\beta = 0,6$ a $\alpha = 0,8$ e $\beta = 0,2$; para o Cenário 2a com $\alpha = 0,4$ e $\beta = 0,6$ e $\alpha = 0,8$ e $\beta = 0,2$; e para o Cenário 2b com $\alpha = 0,4$ e $\beta = 0,6$. Portanto, os melhores valores de α e β devem ser definidos caso a caso. Os custos totais são também apresentados graficamente na Figura 2.23.

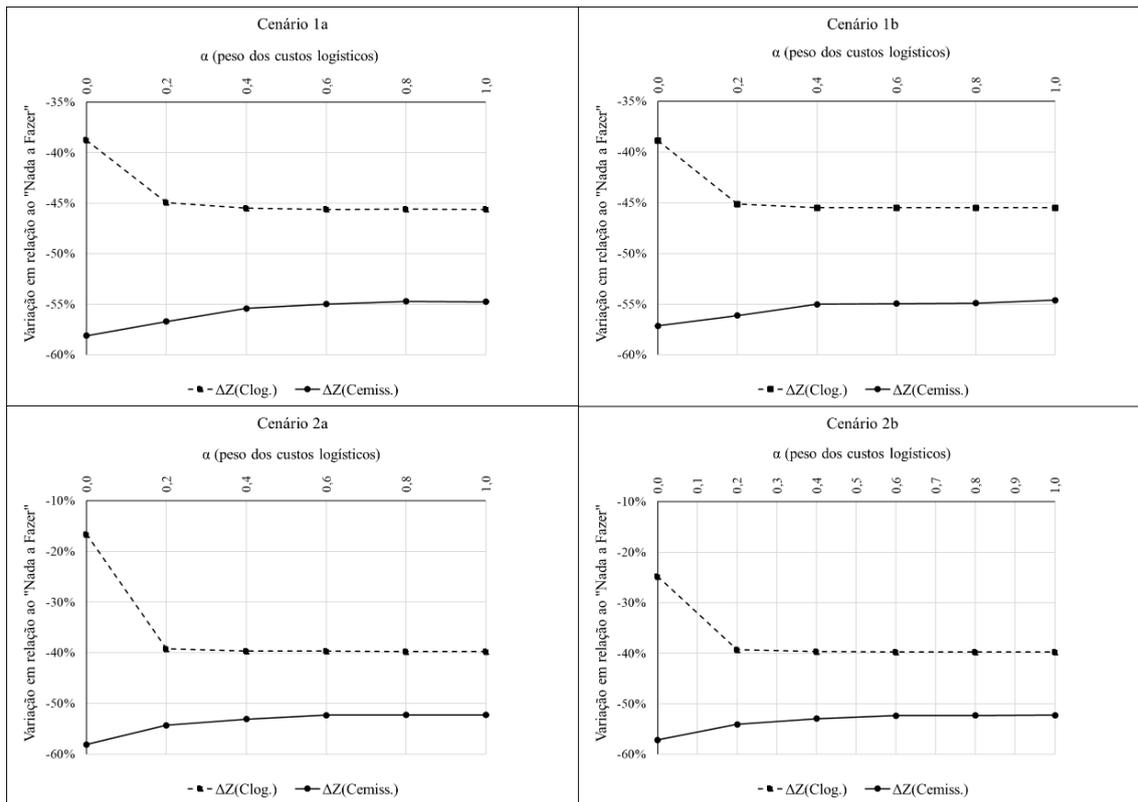


Figura 2.22: Análise de Pareto a partir dos valores de $\Delta Z(C_{logisticos})$ e $\Delta Z(C_{emissoes})$ – comparação com o cenário “Nada a Fazer” – para cada variação dos pesos α e β . Valores negativos indicam economias em relação ao cenário sem CILs.

Tabela 2.15: Resultados do impacto dos pesos α e β nos cenários avaliados (valores em negrito indicam os menores custos totais do cenário avaliado).

Cenário	α	β	#CILs Abertos					$Z(C_{log.})$ 10 ⁹ R\$	$\Delta Z(C_{log.})$ %	$Z(C_{emiss.})$ 10 ⁹ R\$	$\Delta Z(C_{emiss.})$ %	$Z(C_{total})$ 10 ⁹ R\$	$\Delta Z(C_{total})$ %
			2019	2023	2027	2031	Total						
<i>Nada A Fazer</i>	-	-	0	0	0	0	0	25,331	-	3,317	-	28,648	-
1a	0,0	1,0	80	0	0	0	80	15,510	-39	1,390	-58	16,900	-41
	0,2	0,8	39	0	0	0	39	13,953	-45	1,436	-57	15,389	-46
	0,4	0,6	34	0	0	0	34	13,810	-45	1,479	-55	15,289	-47
	0,6	0,4	30	0	0	0	30	13,778	-46	1,493	-55	15,271	-47
	0,8	0,2	30	0	0	0	30	13,785	-46	1,502	-55	15,287	-47
1b	1,0	0,0	31	0	0	0	31	13,777	-46	1,500	-55	15,277	-47
	0,0	1,0	43	5	2	1	51	15,479	-39	1,421	-57	16,900	-41
	0,2	0,8	29	1	0	0	30	13,900	-45	1,455	-56	15,355	-46
	0,4	0,6	29	1	0	0	30	13,810	-45	1,492	-55	15,302	-47
	0,6	0,4	29	1	0	0	30	13,807	-45	1,495	-55	15,302	-47
2a	0,8	0,2	29	1	0	0	30	13,807	-45	1,495	-55	15,302	-47
	1,0	0,0	28	1	0	0	29	13,806	-45	1,505	-55	15,311	-47
	0,0	1,0	80	0	0	0	80	21,110	-17	1,390	-58	22,500	-21
	0,2	0,8	19	0	0	0	19	15,394	-39	1,516	-54	16,910	-41
	0,4	0,6	17	0	0	0	17	15,284	-40	1,557	-53	16,841	-41
2b	0,6	0,4	14	0	0	0	14	15,275	-40	1,582	-52	16,857	-41
	0,8	0,2	15	0	0	0	15	15,258	-40	1,583	-52	16,841	-41
	1,0	0,0	15	0	0	0	15	15,258	-40	1,584	-52	16,842	-41
	0,0	1,0	43	5	2	1	51	19,049	-25	1,421	-57	20,470	-29
	0,2	0,8	19	0	0	0	19	15,370	-39	1,523	-54	16,893	-41
2b	0,4	0,6	16	0	0	0	16	15,280	-40	1,561	-53	16,841	-41
	0,6	0,4	15	0	0	0	15	15,261	-40	1,581	-52	16,842	-41
	0,8	0,2	15	0	0	0	15	15,260	-40	1,583	-52	16,843	-41
	1,0	0,0	15	0	0	0	15	15,260	-40	1,583	-52	16,843	-41

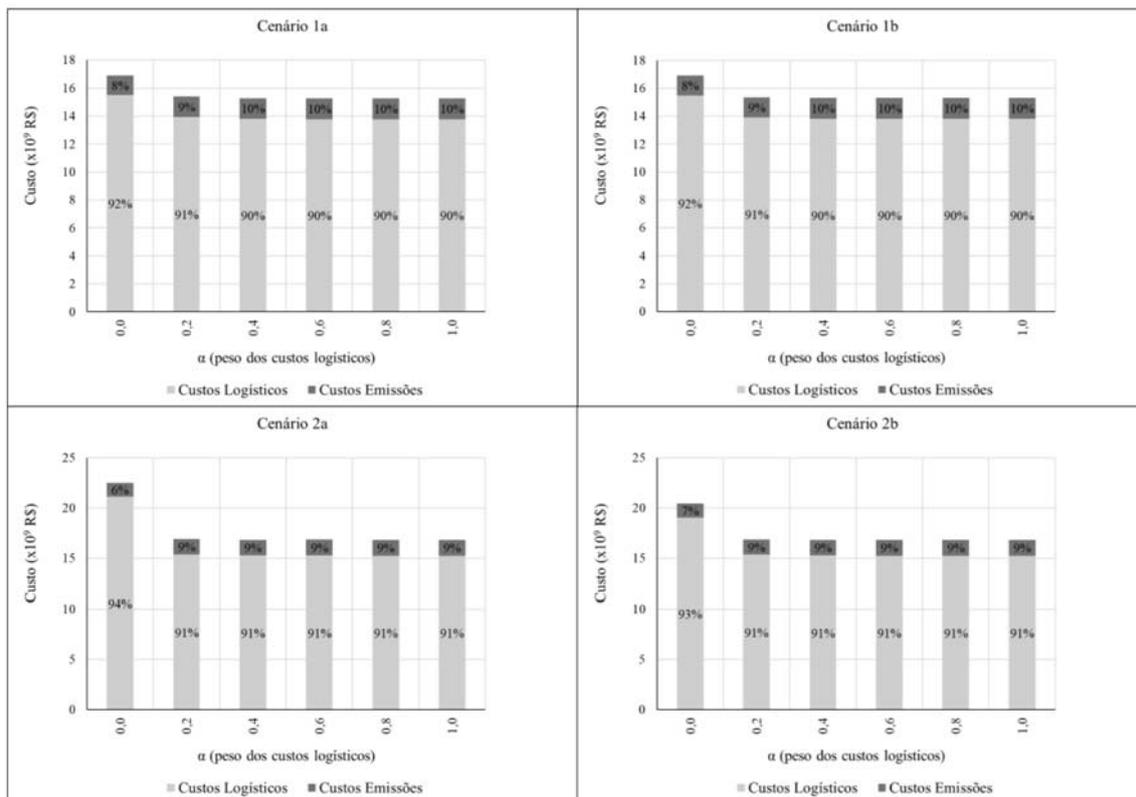


Figura 2.23: Custos totais para cada variação dos pesos α e β . Os valores percentuais indicam a contribuição dos custos logísticos e dos custos de emissões no valor total.

2.4.5 Avaliação das heurísticas propostas

Apresenta-se, nesta seção, os resultados da aplicação das abordagens heurísticas propostas neste trabalho para o PMLCIL. Tanto o AG quanto a HBR foram aplicados à todas as cinco instâncias de matriz de soja (Tabela 2.10) seguindo as definições dos seis cenários de avaliação propostos e apresentados na Tabela 2.9. Realizou-se a aplicação do AG sem e com a presença de indivíduos relaxados na população inicial. Devido ao comportamento estocástico dos AGs, a avaliação de cada instância e cenário foi repetida cinco vezes. Já para a HBR, foram efetuados trinta repetições. Cabe destacar que os parâmetros para a aplicação do AG proposto foram definidos a partir de testes computacionais, conforme apresentado no Apêndice F.

Os resultados são apresentados na Tabela 2.16. As três primeiras colunas caracterizam a instância avaliada, indicando, respectivamente, a região de produção da soja, o método heurístico utilizado e o cenário de avaliação. A quarta e a quinta coluna apresentam, respectivamente, a média e o desvio padrão dos valores de GAP obtidos para o conjunto de repetições. Este valor sinaliza o desvio em relação a solução ótima (obtida pelo Gurobi e apresentada na Seção 2.4.3) e é calculado por meio da Equação (2.13)). A sexta e sétima colunas apresentam, respectivamente, a média e o desvio padrão do tempo computacional do procedi-

mento heurístico. A oitava coluna apresenta a diferença, em porcentagem, entre os tempos computacionais demandados pelo método heurístico em relação ao *solver* ($\Delta T_{Heur/solver} = (T_{Heur} - T_{Solver})/T_{Solver}$). Por fim, a nona coluna apresenta a diferença, também em porcentagem, quando comparados os tempos computacionais das duas abordagens heurísticas propostas, isto é da HBR em relação ao AG ($\Delta T_{HBR/AG} = (T_{HBR} - T_{AG})/T_{AG}$).

Os resultados estão apresentado também por meio de diagramas de caixa na Figura 2.24 e na Figura 2.25 (estes são apresentados individualmente no Apêndice H para melhor visualização). Por fim, a Figura 2.26 ilustra, através de gráfico de barras, os tempos computacionais obtidos nesta análise computacional.

$$GAP = (SH - SE)/(SH) \quad (2.13)$$

Inicialmente, ao avaliar os resultados obtidos da aplicação do HBR, observa-se que o desvio padrão calculado para o GAP foi de 0% para todos os casos, indicando um comportamento determinístico deste algoritmo, o que era esperado uma vez que trata-se de uma heurística construtiva que parte do mesmo vetor inicial (solução da relaxação linear) e iterativamente constrói a solução heurística. A HBR foi capaz de gerar a solução ótima para os Cenários 2a e 2b da instância CO e para o Cenário 0a de todas as instâncias. Para as demais soluções, a heurística retornou boas soluções, com GAP inferiores a 0,6%. Em comparação à aplicação do solver, o uso da HBR permitiu obter soluções válidas para o problema em menor tempo computacional para quase todos os cenários e instâncias, com redução de tempo variando entre 16% e 95%, com exceção apenas do Cenário 0a das instâncias CO, COS e COSNE, nos quais o *solver* encontrou solução em menor tempo, porém com pouca diferença (até 7%).

A partir do valor médio dos resultados obtidos para as aplicações dos AGs propostos, nota-se que, para todos os casos avaliados, a aplicação do AG utilizando indivíduos relaxados na população apresentou melhores (menores) resultados de GAP quando comparado aos obtidos sem estes. Ao analisar a Figura 2.24, observa-se que, a partir da utilização de indivíduos relaxados, foram obtidos valores de GAP inferiores a 5% para quase todos os casos, sendo o Cenário 0b da instância *COSNE* a única exceção, que apresentou valor médio de GAP igual a 6,2%. Já para as aplicações sem indivíduos relaxados, foram obtidos valores de GAP variando entre 1,8% e 16,7%. Essa diferença entre as duas aplicações reforça a importância de se utilizar o método que incorpora os indivíduos relaxados na população inicial.

Quanto ao tempo computacional, observou-se que, em grande parte, a aplicação do AG com indivíduos relaxados apresentou menores valores, seguido pelo AG sem os indivíduos relaxados e, por fim, utilizando-se o *solver*. Estes resultados são também

apresentados em diagrama de barras na Figura 2.26. Observou-se, ainda, que os cenários em que há exigência de volume mínimo para abertura de CILs (0b, 1b e 2b), foi necessário maior tempo computacional para obtenção de soluções quando comparado com os respectivos cenários sem esta restrição.

Quando comparados os tempos computacionais das aplicações dos AGs em relação à HBR, foi observado melhor desempenho da HBR, que demandou menor tempo computacional para quase todos os cenários e instâncias, com reduções de tempo variando entre 5% e 96%. Apenas para os Cenários 0a e 1a da instância COSNESEN a aplicação do AG sem indivíduo relaxado apresentou melhor tempo computacional. No entanto, cabe ressaltar que os valores de GAP encontrados para estes dois cenários utilizando o AG foram de 3,5% e 5,4% respectivamente, superiores aos valores encontrados pelo HBR (0,0% e 0,1%).

Portanto, cabe destacar que estes resultados não devem ser avaliados de forma isolada. Por exemplo, para a instância COSNESEN, os menores tempos computacionais foram observados para a aplicação do AG sem indivíduos relaxados. Porém, estes apresentaram piores valores de GAP. Assim, a escolha da técnica de otimização a ser aplicada deve ser regida de acordo com as necessidades da aplicação. Isto é, se a importância está em obter soluções em menor tempo computacional, mesmo que estas não sejam de boa qualidade, ou se há tempo disponível para a obtenção de soluções melhores. Desta forma, destaca-se que a HBR apresentou melhor comportamento computacional dentre as abordagens heurísticas propostas, uma vez que retornou menores valores de GAP (inferiores a 0,6%) em melhores tempos computacionais do que as aplicações do AG sem indivíduos relaxados (1,8% a 16,7%) e do AG com indivíduos relaxados (0% a 6,2%).

Outro ponto relevante a ser destacado destes resultados é a pequena variação entre os resultados obtidos durante as repetições ao utilizar indivíduos relaxados na população (expressos pela distância entre o primeiro e terceiro quartis do diagrama de caixas (Figura 2.24) e pelos valores dos desvio padrão apresentados na Tabela 2.16). Este efeito é resultado da convergência precoce à solução representada pelos indivíduos relaxados, independente das sementes aleatórias de buscas iniciais (expressos pelos indivíduos aleatórios).

Tabela 2.16: Resultados das abordagens heurísticas propostas para as diferentes instâncias de soja.

Instân.	Método	Cenário	GAP (%)		Tempo (s)		$\Delta T_{Heur/solver}$ (%)	$\Delta T_{HBR/AG}$ (%)
			Méd.	Des. Pad.	Méd.	Des. Pad.		
CO	<i>Solver</i> Gurobi	0a	0,0	0,0	124	–	–	–
		0b	0,0	0,0	1.774	–	–	–
		1a	0,0	0,0	709	–	–	–
		1b	0,0	0,0	568	–	–	–
		2a	0,0	0,0	632	–	–	–
		2b	0,0	0,0	1.597	–	–	–
	Heurística Baseada em Relaxação	0a	0,0	0,0	129	0	4	–
		0b	0,2	0,0	137	0	-92	–
		1a	0,1	0,0	134	0	-81	–
		1b	0,1	0,0	135	0	-76	–
		2a	0,0	0,0	135	0	-79	–
		2b	0,0	0,0	135	0	-92	–
	AG sem Indivíduos Relaxados	0a	1,8	0,7	572	29	360	-77
		0b	3,7	3,7	2.225	813	25	-94
		1a	12,0	1,5	690	84	-3	-81
		1b	5,2	3,1	1.737	814	206	-92
		2a	7,1	3,2	3.073	399	386	-96
		2b	6,3	2,7	1.806	452	13	-93
	AG com Indivíduos Relaxados	0a	0,0	0,0	551	3	343	-77
		0b	3,1	0,0	630	19	-65	-78
		1a	4,0	0,0	594	12	-16	-77
		1b	1,2	0,0	611	17	8	-78
		2a	0,8	0,0	581	15	-8	-77
		2b	0,0	0,0	609	15	-62	-78

Continua na próxima página.

Tabela 2.16 - Resultados das abordagens heurísticas propostas para as diferentes instâncias de soja. (continuação).

Instân.	Método	Cenário	GAP (%)		Tempo (s)		$\Delta T_{Heur/solver}$ (%)	$\Delta T_{HBR/AG}$ (%)
			Méd.	Des. Pad.	Méd.	Des. Pad.		
COS	<i>Solver</i> Gurobi	0a	0,0	0,0	349	–	–	–
		0b	0,0	0,0	3.163	–	–	–
		1a	0,0	0,0	1.541	–	–	–
		1b	0,0	0,0	1.122	–	–	–
		2a	0,0	0,0	4.388	–	–	–
		2b	0,0	0,0	8.424	–	–	–
	Heurística Baseada em Relaxação	0a	0,0	0,0	372	0	7	–
		0b	0,2	0,0	416	0	-87	–
		1a	0,1	0,0	404	0	-74	–
		1b	0,1	0,0	405	0	-64	–
		2a	0,1	0,0	404	0	-91	–
		2b	0,1	0,0	400	0	-95	–
	AG sem Indivíduos Relaxados	0a	2,8	0,6	1.149	161	229	-68
		0b	7,5	1,7	3.652	24	15	-89
		1a	9,0	1,3	1.063	109	-31	-62
		1b	8,2	1,3	3.628	14	223	-89
		2a	16,7	6,0	1.855	1.199	-58	-78
		2b	12,3	2,2	3.634	21	-57	-89
	AG com Indivíduos Relaxados	0a	0,0	0,0	1.191	3	241	-69
		0b	1,7	0,0	1.823	41	-42	-77
		1a	2,6	0,0	1.388	15	-10	-71
		1b	3,5	0,0	1.801	27	61	-78
		2a	0,5	0,0	1.359	32	-69	-70
		2b	1,3	0,0	1.729	58	-79	-77

Continua na próxima página.

Tabela 2.16 - Resultados das abordagens heurísticas propostas para as diferentes instâncias de soja. (continuação).

Instân.	Método	Cenário	GAP (%)		Tempo (s)		$\Delta T_{Heur/solver}$ (%)	$\Delta T_{HBR/AG}$ (%)
			Méd.	Des. Pad.	Méd.	Des. Pad.		
COSNE	Solver Gurobi	0a	0,0	0,0	803	–	–	–
		0b	0,0	0,0	2.739	–	–	–
		1a	0,0	0,0	2.344	–	–	–
		1b	0,0	0,0	2.903	–	–	–
		2a	0,0	0,0	5.009	–	–	–
		2b	0,0	0,0	5.507	–	–	–
	Heurística Baseada em Relaxação	0a	0,0	0,0	827	0	3	–
		0b	0,3	0,0	887	0	-68	–
		1a	0,1	0,0	845	0	-64	–
		1b	0,1	0,0	875	0	-70	–
		2a	0,1	0,0	873	0	-83	–
		2b	0,1	0,0	863	0	-84	–
	AG sem Indivíduos Relaxados	0a	3,3	0,7	1.011	67	26	-18
		0b	6,5	0,8	3.635	29	33	-76
		1a	7,3	0,7	1.136	222	-52	-26
		1b	7,5	1,5	3.509	292	21	-75
		2a	12,0	4,3	2.112	1.020	-58	-59
		2b	11,8	1,3	3.648	31	-34	-76
	AG com Indivíduos Relaxados	0a	0,0	0,0	1.665	15	107	-50
		0b	6,2	0,0	2.489	65	-9	-64
		1a	1,8	0,0	1.882	11	-20	-55
		1b	3,2	0,0	2.465	43	-15	-65
		2a	0,4	0,0	1.859	18	-63	-53
		2b	0,1	0,0	2.382	88	-57	-64

Continua na próxima página.

Tabela 2.16 - Resultados das abordagens heurísticas propostas para as diferentes instâncias de soja. (continuação).

Instân.	Método	Cenário	GAP (%)		Tempo (s)		$\Delta T_{Heur/solver}$ (%)	$\Delta T_{HBR/AG}$ (%)
			Méd.	Des. Pad.	Méd.	Des. Pad.		
COSNESE	Solver Gurobi	0a	0,0	0,0	1.458	–	–	–
		0b	0,0	0,0	16.566	–	–	–
		1a	0,0	0,0	3.681	–	–	–
		1b	0,0	0,0	3.444	–	–	–
		2a	0,0	0,0	27.400	–	–	–
		2b	0,0	0,0	19.848	–	–	–
	Heurística Baseada em Relaxação	0a	0,0	0,0	1.231	0	-16	–
		0b	0,5	0,0	1.309	0	-92	–
		1a	0,1	0,0	1.287	0	-65	–
		1b	0,3	0,0	1.302	0	-62	–
		2a	0,1	0,0	1.309	1	-95	–
		2b	0,1	0,0	1.345	3	-93	–
	AG sem Indivíduos Relaxados	0a	3,2	1,0	1.386	190	-5	-11
		0b	6,4	0,7	3.650	43	-78	-64
		1a	6,6	0,4	1.357	221	-63	-5
		1b	9,0	2,2	3.307	777	-4	-61
		2a	14,6	1,1	1.622	398	-94	-19
		2b	12,6	1,7	3.632	33	-82	-63
	AG com Indivíduos Relaxados	0a	0,0	0,0	2.283	37	57	-46
		0b	2,2	0,0	3.304	29	-80	-60
		1a	2,5	0,0	2.530	41	-31	-49
		1b	1,8	0,0	3.198	41	-7	-59
		2a	1,0	0,0	2.490	23	-91	-47
		2b	0,3	0,0	3.416	56	-83	-61

Continua na próxima página.

Tabela 2.16 - Resultados das abordagens heurísticas propostas para as diferentes instâncias de soja. (continuação).

Instân.	Método	Cenário	GAP (%)		Tempo (s)		$\Delta T_{Heur/solver}$ (%)	$\Delta T_{HBR/AG}$ (%)
			Méd.	Des. Pad.	Méd.	Des. Pad.		
COSNESEN	Solver Gurobi	0a	0,0	0,0	1.664	–	–	–
		0b	0,0	0,0	25.652	–	–	–
		1a	0,0	0,0	2.842	–	–	–
		1b	0,0	0,0	5.334	–	–	–
		2a	0,0	0,0	20.751	–	–	–
		2b	0,0	0,0	21.760	–	–	–
	Heurística Baseada em Relaxação	0a	0,0	0,0	1.378	1	-17	–
		0b	0,5	0,0	1.542	2	-94	–
		1a	0,1	0,0	1.725	1	-39	–
		1b	0,2	0,0	1.480	2	-72	–
		2a	0,1	0,0	1.463	1	-93	–
		2b	0,2	0,0	1.434	2	-93	–
	AG sem Indivíduos Relaxados	0a	3,5	0,8	1.372	189	-18	0
		0b	5,9	1,2	3.105	654	-88	-50
		1a	5,4	0,5	1.301	142	-54	33
		1b	9,9	3,2	2.752	885	-48	-46
		2a	12,7	3,5	1.834	1.063	-91	-20
		2b	12,4	3,2	3.445	524	-84	-58
	AG com Indivíduos Relaxados	0a	0,0	0,0	2.367	21	42	-42
		0b	2,5	0,0	3.701	60	-86	-58
		1a	3,4	0,0	2.947	49	4	-41
		1b	2,8	0,0	3.537	50	-34	-58
		2a	0,3	0,0	2.627	22	-87	-44
		2b	1,0	0,0	3.480	83	-84	-59

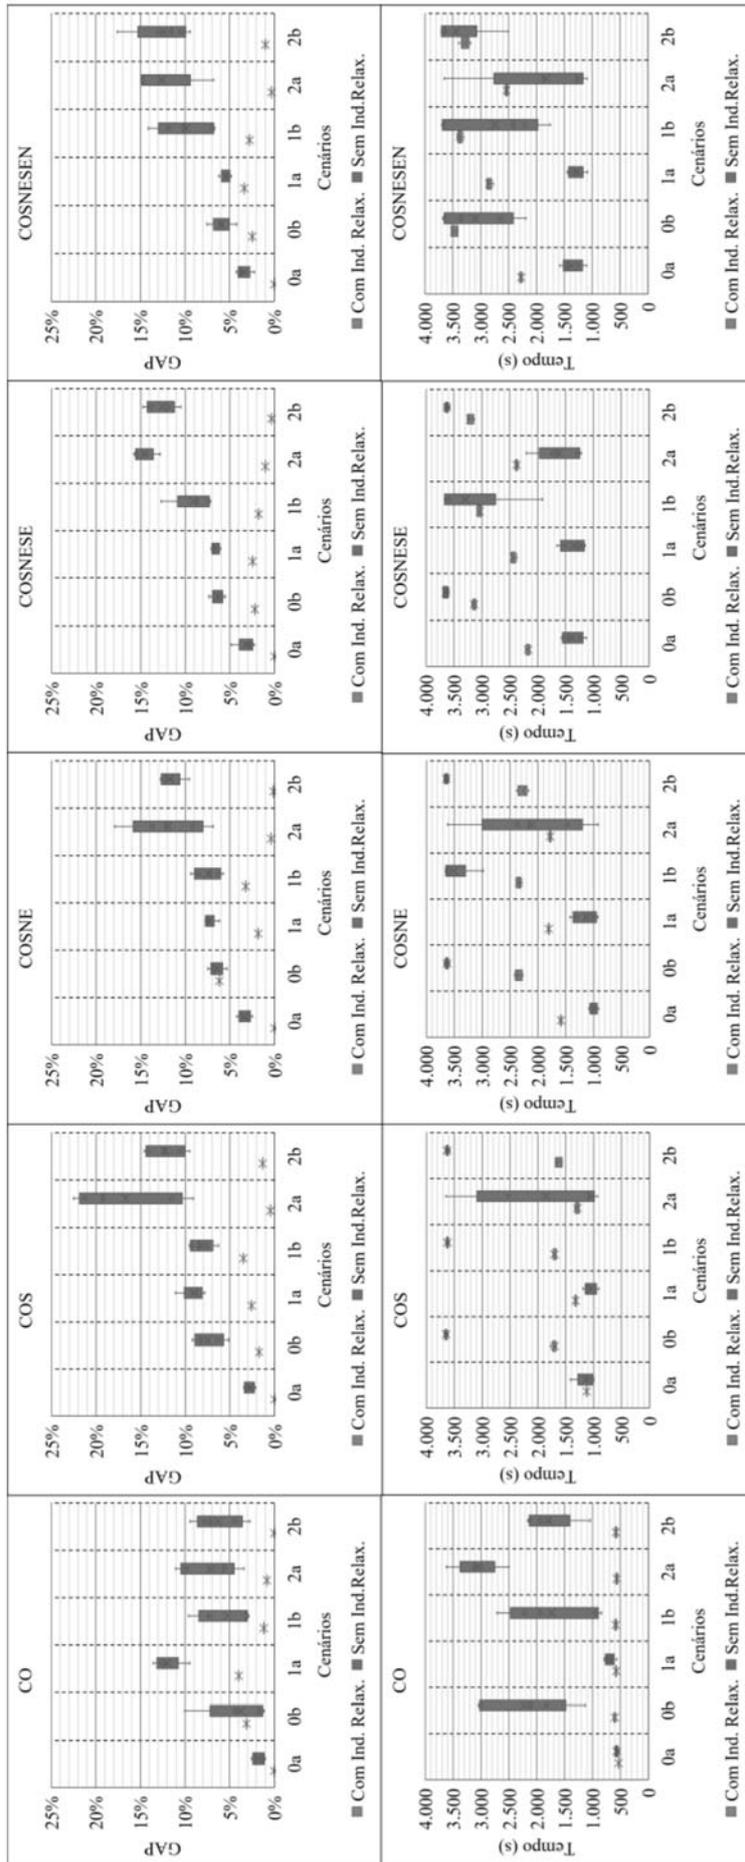


Figura 2.24: Diagrama de caixas a partir dos valores de GAP e de tempos computacionais observados ao aplicar o AG proposto sem e com indivíduos relaxados na população inicial para as instâncias e cenários abordados no estudo.

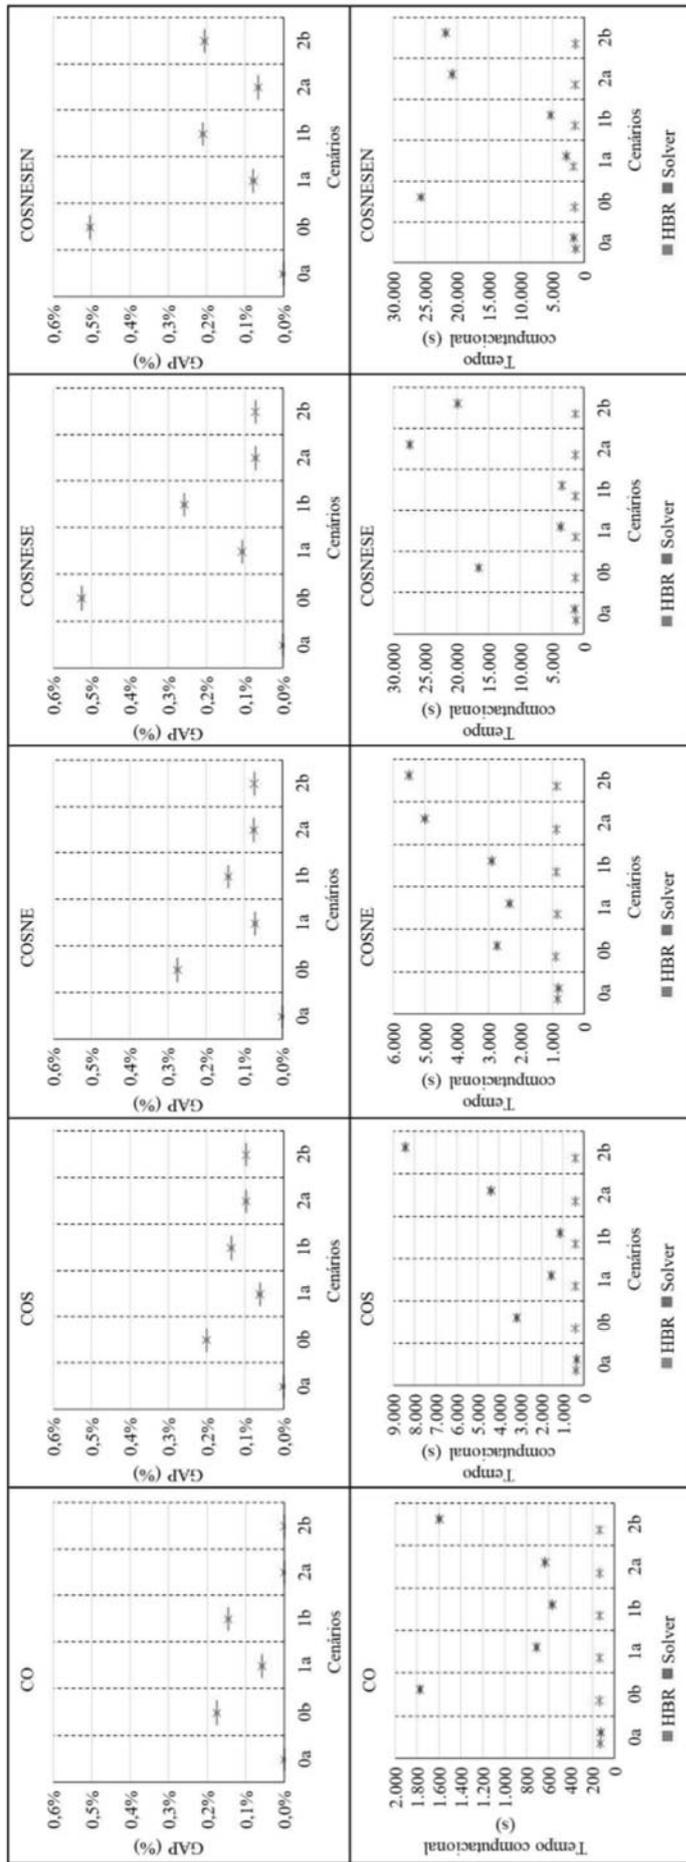


Figura 2.25: Diagrama de caixas a partir dos valores de GAP e de tempos computacionais observados ao aplicar a Heurística Baseada em Relaxação para as instâncias e cenários abordados no estudo.

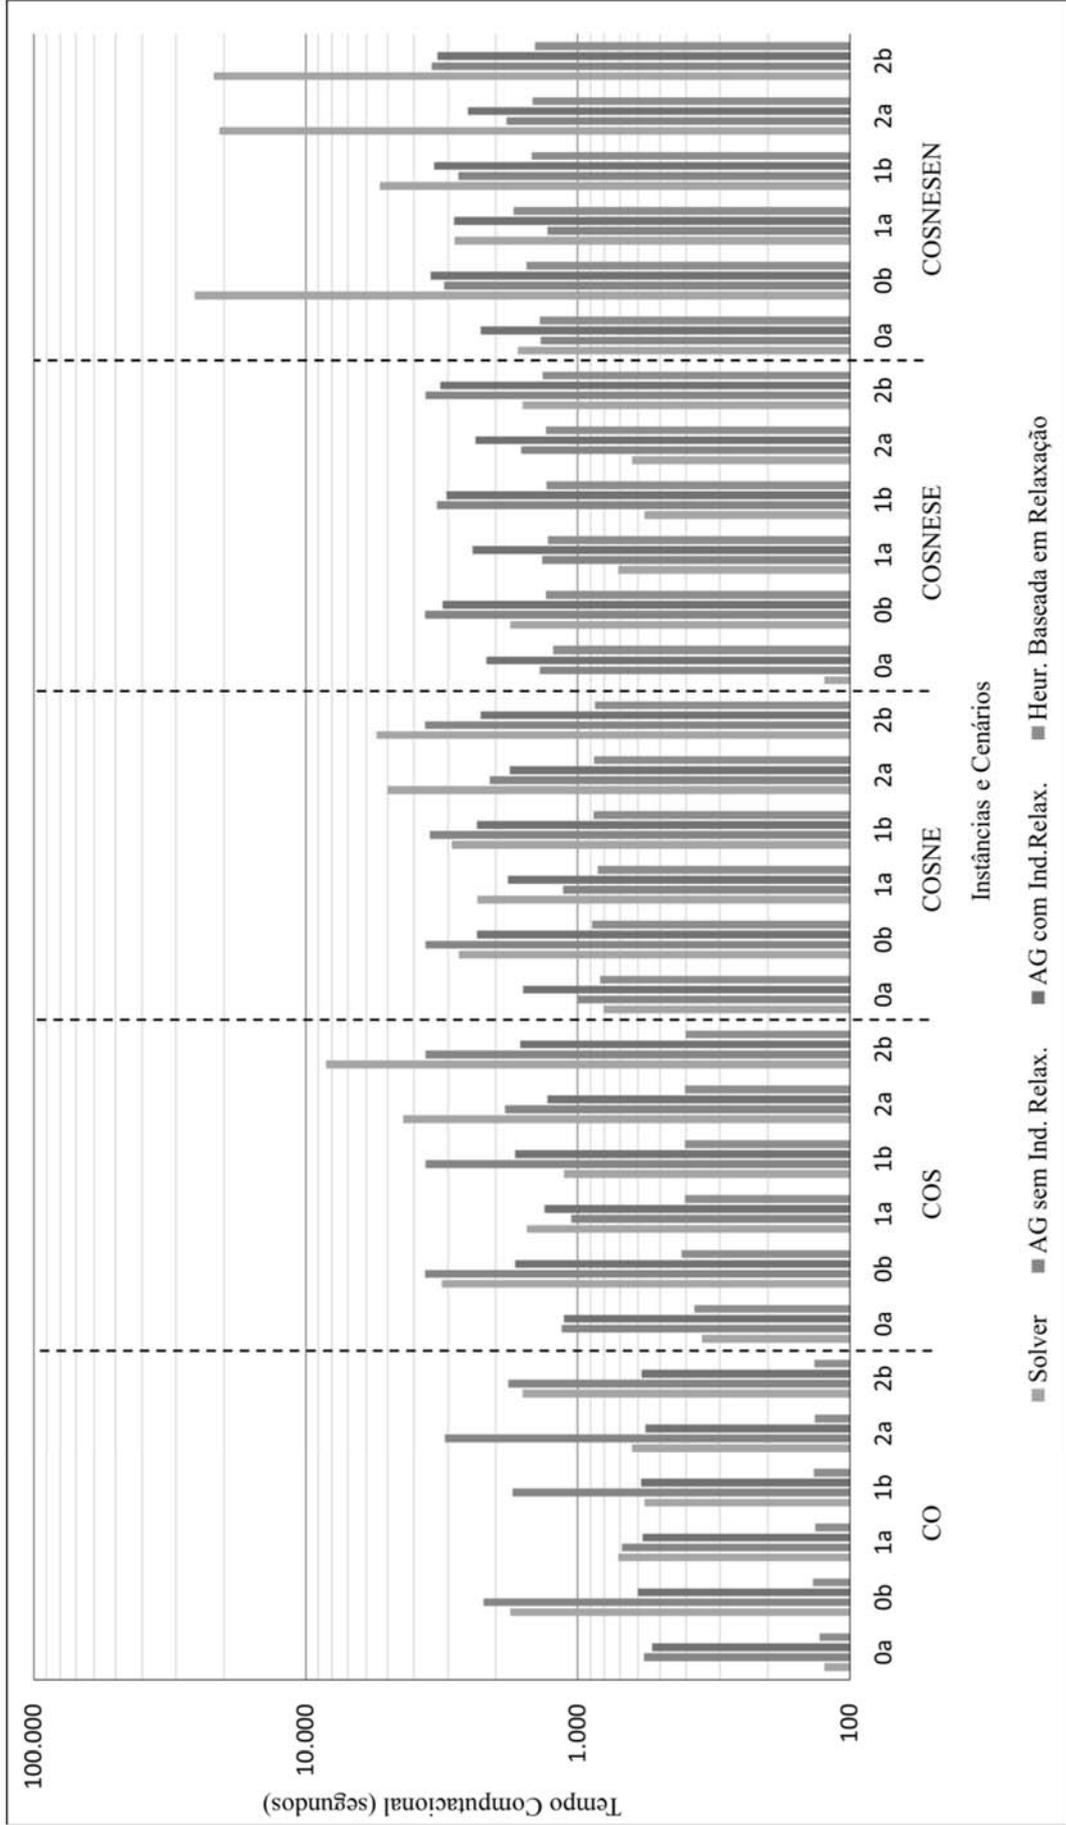


Figura 2.26: Tempos computacionais obtidos ao aplicar as heurísticas abordadas neste estudo e o Gurobi (em segundos).

Ao avaliar os resultados da aplicação do AG com indivíduos relaxados na população inicial, observou-se que a solução retornada era igual a solução relaxada inserida na população inicial. Isto é observado mesmo com a utilização de um sistema de critérios de parada complexo, que visa dificultar a parada precoce do algoritmo em prol da exploração do espaço de busca. A Tabela 2.17 apresenta, para cada instância, qual o método de geração do indivíduo relaxado que apresentou melhor adaptação e, conseqüentemente, orientou a convergência das gerações subsequentes. O valor de 100% indica que o AG retornou o indivíduo relaxado como solução nas cinco avaliações do cenário.

Observa-se que o algoritmo proposto para o “Método 1 - Melhora da solução” (Algoritmo 4) gerou as soluções para os cenários 0b, 1a, 1b, 2a e 2b para todas as instâncias, enquanto o “Método 2 - Abertura precoce” atendeu somente ao cenário 0a de todas as instâncias. Portanto, para este caso, o processo evolutivo característico dos AGs não é capaz de encontrar uma solução melhor do que o indivíduo relaxado inserido na população inicial.

2.5 Conclusões do Capítulo

Considerando-se a relevância para o planejamento estratégico sustentável dos sistemas logísticos, foi apresentado, neste capítulo, um modelo matemático para o Problema Multiperíodo de Localização de CILs. Neste, os custos logísticos (transporte, investimento e operação) e os custos de emissões de CO_2 são simultaneamente minimizados. Destaca-se que os CILs, quando localizados em pontos estratégicos, pode permitir a multimodalidade da rede, promovendo a melhor utilização dos modos de transportes disponíveis e a eficiência do serviço ao otimizar as atividades logísticas, tornando as operações mais eficientes e sustentáveis.

Tendo em vista que os problemas de localização de facilidades são classificados como NP-Difícil, duas abordagens heurísticas foram propostas, uma baseada em Algoritmos Genéticos (AG) e outra Baseada em Relaxação Linear (HBR). Para a alocação dos fluxos e cálculo da FO nas abordagens heurísticas, foi proposta uma abordagem heurística construtiva e gulosa que, a partir da solução de localização das facilidades (expressa pelo vetor cromossomo), realiza a alocação dos fluxos e retorna o valor da aptidão (custo total, composto pelo custo logístico e ambiental). O AG proposto possui, ainda, as seguintes particularidades: i) na população inicial, podem ser inseridos apenas indivíduos aleatórios ou, também, indivíduos criados a partir da solução da relaxação linear do problema; ii) é considerado um conjunto elite, mantendo-se as melhores soluções encontradas entre gerações, direcionando-se a convergência da operação de busca; iii) foi proposta a utilização de máscaras de viabilidade, que visam transformar os cromossomos inviáveis em soluções viáveis

Tabela 2.17: Controle de igualdade entre a solução do AG proposto e os indivíduos relaxados na população inicial para as instâncias avaliadas.

Instância	Cenário	Método de geração do indivíduo relaxado ¹		
		[1] (%)	[2] (%)	[3] (%)
CO	0a	0	100	0
	0b	100	0	0
	1a	100	0	0
	1b	100	0	0
	2a	100	0	0
	2b	100	0	0
COS	0a	0	100	0
	0b	100	0	0
	1a	100	0	0
	1b	100	0	0
	2a	100	0	0
	2b	100	0	0
COSNE	0a	0	100	0
	0b	100	0	0
	1a	100	0	0
	1b	100	0	0
	2a	100	0	0
	2b	100	0	0
COSNESE	0a	0	100	0
	0b	100	0	0
	1a	100	0	0
	1b	100	0	0
	2a	100	0	0
	2b	100	0	0
COSNESEN	0a	0	100	0
	0b	100	0	0
	1a	100	0	0
	1b	100	0	0
	2a	100	0	0
	2b	100	0	0

¹ Método [1] - Melhora da solução;
Método [2] - Abertura precoce;
Método [3] - Um indivíduo para cada período.

para o problema.

O modelo multiperíodo proposto foi aplicado ao contexto do transporte de soja em grãos produzida no Brasil. As soluções foram obtidas utilizando-se tanto um *solver* comercial quanto por meio das abordagens heurísticas propostas. Em todas as análises, o modelo matemático apresentou resultados satisfatórios e comportamento correto de otimização, uma vez que houve reduções nos custos logísticos e nos custos de emissões de CO_2 a partir da indicação das microrregiões candidatas e do período para a abertura de CILs. Para alguns cenários, obteve-se a abertura da infraestrutura em diferentes períodos, verificando-se a importância da característica de multiperíodo para um plano de implantação estratégico. Além disso, as economias obtidas tanto para os custos logísticos quanto para as emissões de CO_2 ressaltam a importância de investimentos em infraestruturas que visam a otimiza-

ção sustentável do sistema logístico. Dentre as abordagens heurísticas avaliadas, concluiu-se que a HBR apresentou melhor desempenho computacional na busca por soluções das instâncias avaliadas.

Embora tenha sido possível resolver as instâncias avaliadas utilizando-se o *solver* comercial, destaca-se que, dependendo das configurações do computador, não é garantido que soluções ótimas sejam encontradas. Neste contexto, a utilização de métodos heurísticos pode favorecer estes casos, posicionando-se como importante ferramenta no planejamento estratégico. Cabe destacar que a seleção da técnica de otimização a ser empregada deve ser determinada conforme as necessidades da aplicação.

Por fim, as contribuições apresentadas para o Problema Multiperíodo de Localização de CILs que, aplicado à cenários, pode apoiar o planejamento de sistema logísticos e na tomada de decisão. Como limitação do estudo, esclarece-se que os resultados são dependentes dos parâmetros de entrada, que precisam ser atualizados, caso seja necessário um estudo para direcionar investimentos públicos. Como sugestões para trabalhos futuros, recomenda-se: a aplicação do modelo com mais produtos além da soja (multiproduto); avaliação da contribuição de cada região para a elaboração de políticas e planejamentos estratégicos regionais; a incorporação de parâmetros econômicos nos dados de entrada, como taxas de juros e/ou inflacionárias para correção dos custos nos períodos a valor presente; modelagem de custos fixos em cada horizonte; a incorporação de outros parâmetros ambientais e sociais no modelo; e a elaboração de metodologias que visam a incorporação de incertezas nos parâmetros de entrada, como impactos na sazonalidade dos produtos causadas por secas, inundações ou outras eventualidades. Quanto às técnicas de otimização, podem também ser abordados em trabalhos futuros a investigação de outras heurísticas, como, por exemplo, de busca local, além de aprimoramentos nos parâmetros do AG, como utilização de probabilidade de mutação dinâmicas.

Capítulo 3

Problema de Localização de Carregadores para Caminhões Elétricos de Longa Distância Considerando Roteamento e a Jornada de Trabalho dos Motoristas

Tendo em vista os altos investimentos e o tempo necessário para planejamento, construção e início da operação dos CILs, uma alternativa para a redução de emissões de CO_2 no sistema de transporte de cargas consiste na eletrificação da frota. Neste contexto, são apresentados e discutidos, neste capítulo, os fundamentos teóricos, a modelagem matemática e estratégias de otimização para o Problema de Localização de Carregadores para caminhões elétricos de longa distância considerando Roteamento e a legislação da Jornada de Trabalho dos Motoristas (PLCR-JTM). Apresenta-se, ainda, os experimentos computacionais a partir da aplicação da modelagem propostas para uma rede fictícia e para estudos de casos utilizando a rede viária brasileira e distribuição de soja em grãos.

3.1 Revisão da Literatura

Em países com vasta área territorial, como, por exemplo, Brasil, Canadá, Estados Unidos e Austrália, as distâncias percorridas pelos motoristas para o transporte de cargas podem ser consideráveis. Visando a eletrificação da frota para viagens de longa distância, verifica-se que pode ocorrer da distância a ser percorrida exceder a autonomia das baterias dos caminhões, sendo necessárias paradas para carregamento ao longo do trajeto. No entanto, como estes deslocamentos comumente envolvem

atravessar áreas remotas e distantes dos principais centros urbanos, essas paradas podem ocorrer em locais onde a presença de carregadores veiculares é escassa como consequência de uma infraestrutura com poucos carregadores espalhados geograficamente ao longo dos caminhos. Este efeito pode ocorrer mesmo em países que possuem alta densidade de carregadores localizados próximos à centros urbanos.

Apesar de os problemas de localização de carregadores, localização de estações de recarga e de programação de recargas serem amplamente estudados para o contexto de veículos elétricos de passageiros ou de fretes de curta distância (DAVATGARI *et al.* [25], KUCUKOGLU *et al.* [26]), estes não podem ser diretamente aplicados ao contexto dos transportes de carga de longa distância, já que possuem características diferentes entre si, como de deslocamento, de necessidades de recarga, além de janelas de tempo de entrega restritas e que precisam ser cumpridas. Portanto, o estudo da seleção de tecnologia, da localização, da concepção e do dimensionamento destas infraestruturas devem ser efetuados com cautela, não só pelas implicações econômicas e práticas que afetam tanto os utilizadores como a sociedade em geral, mas também pelas exigências impostas à rede elétrica para carregamento de veículos pesados (BISCHOFF *et al.* [98], MAREEV *et al.* [99]). Dadas estas diferenças, o problema de localização de carregadores para caminhões de longa distância é uma área de conhecimento que ainda pouco explorada na literatura (DANESE *et al.* [100]) e este estudo visa contribuir com esta temática.

De um ponto de vista metodológico, há duas abordagens principais para a localização de infraestrutura de recargas (DAVATGARI *et al.* [25], SPETH *et al.* [101]): orientada para a cobertura geográfica e orientada para a demanda. A primeira tem por objetivo maximizar a cobertura geográfica dos serviços de recargas a partir da distribuição espacial uniforme de carregadores. Já a segunda abordagem visa a maior utilização dos sistemas de recargas pela demanda a partir de objetivos como a minimização de custos estratégicos (por exemplo, infraestrutura e carregadores) e custos operacionais (como tempo e energia), e estão sujeitas às restrições de conservação de demanda que garantem um certo nível de serviço com base na decisão de localização. Diferentes modelos matemáticos para a localização de veículos elétricos podem ser encontrados na literatura (ver, por exemplo, KUCUKOGLU *et al.* [26], XIAO *et al.* [102], ERDELIC *et al.* [103], KCHAOU BOUJELBEN *et al.* [104]).

No contexto da eletrificação de caminhões para deslocamentos de longa distância, SPETH *et al.* [101] propõem um modelo para a localização de carregadores visando projetar uma rede de carregamento rápido de alta potência para caminhões elétricos ao longo do território da Alemanha. No entanto, devido à disponibilidade limitada de dados de fluxos de caminhões, os autores utilizaram a abordagem orientada para a cobertura geográfica. Assim, o modelo teve por objetivo minimizar o número de carregadores e maximizar a cobertura geográfica.

Já DAVATGARI *et al.* [25] abordaram o Problema de Localização de Equipamentos de Abastecimento de Veículos Elétricos com Alocação de Capacidade, que tem por objetivo definir a localização, quantidade e tipos de carregadores minimizando-se os custos de investimentos estratégicos. Para isto, os autores apresentaram um modelo em Programação Linear Inteira Mista que visa encontrar a solução ótima para o problema (decisões de localização e alocação), como a quantidade e tipos de carregadores para cada localidade satisfazendo as restrições operacionais. Neste problema, os autores consideraram as rotas dos veículos fixas. Embora o modelo considere variáveis relacionadas à tomadas de decisão estratégicas, também são consideradas variáveis para o acompanhamento do nível da bateria e realização de recargas parciais, que caracterizam um nível de decisão tático.

Devido as longas distâncias frequentemente percorridas, os motoristas são obrigados a permanecer na estrada por vários dias consecutivos. Como consequência, estes estão submetidos a ambientes de trabalho altamente exigentes e com baixos níveis de controle, o que contribui para a maioria destes profissionais serem afetados pela fadiga (WISE *et al.* [105]). A fadiga crônica afeta negativamente a qualidade de vida dos motoristas e eleva o risco de erros humanos, aumentando, assim, o risco de acidentes e gerando impactos sociais relevantes. Visando o aumento da segurança viária e melhorias nas condições de trabalho dos motoristas comerciais, diversos países implementaram legislações específicas para a regularização da jornada de trabalho dos motoristas (JTM). No entanto, as condições estabelecidas nestas leis são complexas e dependem de considerações específicas para cada localidade. GOEL e VIDAL [106], por exemplo, descrevem e discutem a regulamentação dos Estados Unidos, Canadá, União Europeia e Austrália. No âmbito brasileiro, até pouco tempo atrás, as regulamentações que visam proporcionar descanso adequado aos motoristas para o transporte rodoviário eram consideradas insuficientes e sua fiscalização quase inexistente (MAYERLE *et al.* [27]). No entanto, a JTM foi regulamentada no Brasil a partir da Lei nº 13.103 de 2015 (BRASIL [29]), que define:

- A jornada diária de trabalho é limitada em 8 horas, admitindo-se a sua prorrogação por até 2 horas extraordinárias ou, mediante previsão em convenção ou acordo coletivo, por até 4 horas extraordinárias;
- Será considerado como trabalho efetivo o tempo em que o motorista estiver à disposição do empregador, excluindo-se os intervalos para refeição, repouso, descanso e o tempo de espera;
- Garante 11 horas de descanso no período de 24 horas, sendo, no mínimo, 8 horas ininterruptas no primeiro período (antes do início da viagem) e as remanescentes cumpridas nas 16 horas seguintes ao final do primeiro período de

descanso, que podem ser particionadas e coincidir com as paradas de descanso obrigatórias;

- O repouso diário pode ser feito no veículo, em alojamentos ou em local que ofereça condições adequadas;
- Estabelece um intervalo de 30 minutos a cada 6 horas de condução, podendo ser fracionado desde que as horas de condução não excedam 5,5 horas consecutivas;
- Será assegurado ao motorista profissional intervalo mínimo de 1 hora para refeição, podendo esse período coincidir com os tempos de parada obrigatória;
- No turno noturno (das 22h às 5h), o salário do motorista aumenta em 20% e a medida de jornada de trabalho é reduzida de 60 min para 52,5 min; e
- Caso o percurso exceda sete dias, o motorista tem direito a mais 24 horas de descanso por cada semana trabalhada (ou sua fração), usufruído no retorno do motorista à base ou domicílio (origem).

A Tabela 3.1 apresenta uma comparação síntese (devido a complexidade das legislações) dos valores praticados no Brasil (BRASIL [29]), Estados Unidos (FMCSA [107]) e Canadá (OF CANADA [108]).

Tabela 3.1: Parâmetros simplificados da legislação de jornada de trabalho para Brasil, EUA e Canadá.

Descrição	Notação	Valor (horas)		
		BRA	EUA	CAN
Número máximo de horas de direção acumuladas entre dois períodos de descanso.	h^{daily}	8	11	13
Número máximo de horas de direção acumuladas desde o final do último período de descanso ou pausa (horas de direção consecutivas).	$h^{driving}$	5,5	8	-
Duração mínima de um período de pausa para recuperar o tempo de direção.	h^{break}	0,5	0,5	0,5
Duração mínima de um período de descanso antes de iniciar o tempo de direção.	h^{rest}	8	10	8
Duração total de descanso em um dia (entre dois períodos longos de descanso).	$h^{totalrest}$	11	-	10

Neste contexto, CHEN *et al.* [23] destaca que, do ponto de vista da modelagem de veículos elétricos para longa distância, o comportamento de recarga, que geralmente está sincronizado com o descanso dos motoristas, pode contribuir para a mitigação da fadiga dos motoristas, especialmente após um período prolongado de direção. Portanto, considerar a fadiga pode resultar em planos de roteamento e carregamento distintos para os motoristas em viagens de longa distância e, conseqüentemente, na distribuição de fluxo e demanda de carregamento em toda a rede.

Dada a importância da legislação de JTM para contornar o problema crônico de fadiga enfrentado pelos motoristas, MAYERLE *et al.* [27] propuseram um modelo matemático que visa determinar, através da minimização dos custos, a rota ótima e a programação completa de paradas entre duas localidades (origem e destino). Foram consideradas a regulamentação de jornada de trabalho e as opções disponíveis para os locais de paradas para abastecimento, alimentação e descansos (rápidos e per noite) ao longo do caminho. Já RANCOURT *et al.* [109] abordaram o problema de roteamento e programação para veículos de longa distância considerando a regulamentação da jornada de trabalho dos motoristas dos Estados Unidos. O problema teve por objetivo identificar a sequência de clientes a serem visitados por cada veículo e a programação de descansos dada as janelas de tempo.

No entanto, MAYERLE *et al.* [27] e RANCOURT *et al.* [109] abordaram apenas veículos com motor à combustão. Por outro lado, considerando simultaneamente veículos elétricos e as restrições de descanso, CHEN *et al.* [23] propuseram um modelo matemático para o problema tático de roteamento e programação das recargas e das paradas para descanso em uma rede na qual já existem os pontos de recarga e de parada. Os autores avaliaram, ainda, diferentes níveis de recarga através da análise de sensibilidade.

Na literatura, é possível encontrar, ainda, outras abordagens que envolvem as restrições e complexidades de serem abordadas, simultaneamente, veículos elétricos e jornadas de trabalho, como estudos que apresentam abordagens de otimização para a sincronização de carregamento e formação de comboios ALAM e GUO [15], BAI *et al.* [110], ALBIŃSKI *et al.* [111]. Porém, de forma geral, estes trabalhos realizam abordagens táticas dos problemas.

Adicionalmente às estratégias de operações de carregamento, tem-se diferentes tecnologias de carregadores que podem ser empregados. Os carregadores podem ser divididos em três níveis de acordo com a potência de carregamento (KUCUKOGLU *et al.* [26], SCHOLL *et al.* [112]): Nível I e II são carregadores com modo de recarga lentos ou normais, enquanto Nível III possuem modo rápido de recarga. Uma vez que os veículos de longa distância necessitam de bateria com maior autonomia, quando comparado à veículos elétricos comerciais urbanos, e de maior número de recargas ao longo do percurso, estratégias de utilização de carregadores rápidos são relevantes para incentivar a implantação e difusão dos veículos elétricos neste tipo de viagem.

Em suma, conforme apresentado, poucos trabalhos presentes na literatura abordam juntamente o problema os veículos elétricos e da legislação de jornada de jornada de trabalho para viagens de longa distância, sendo, a maioria, abordagens que envolvem o problema tático de programação da atividade dos motoristas e carregamento dos veículos, com sincronização para formação de pelotão e com rotas fixas. Não foram identificados estudos que abordam o problema estratégico de localização

de carregadores para veículos de longa distância com possibilidade de roteamento e considerando a jornada de trabalho dos motoristas no processo de otimização. Neste contexto, este estudo tem por objetivo cobrir essa lacuna da literatura, que, juntamente com a distribuição esparsa da localização de produção e consumo de mercadorias no território brasileiro, destacam a importância do desenvolvimento de pesquisas que contribuam para uma rede de transporte eficiente e melhoria na segurança rodoviária.

3.2 Definição do Problema e Transformação das Redes

Nesta seção, apresenta-se o desenvolvimento e a modelagem do PLCR-JTM. Visando a minimização dos custos fixos e variáveis, este problema envolve, simultaneamente: a decisão da localização de carregadores, o roteamento de veículos, a legislação de jornada de trabalho dos motoristas de longa distância, os desafios do uso de veículos elétricos para viagens de longa distância e estratégias elétricas baseada em tecnologias de nível de carregamento dos carregadores. Neste modelo, o roteamento considerado é uma variante do Problema de Roteamento Aberto de Veículos (*open vehicle routing problem*), no qual os veículos não necessitam retornar ao mesmo nó de origem. Assim, cada demanda possui nó de origem diferente do nó de destino, com nós intermediários para atendimento da necessidade de carregamento dos veículos.

Para melhor entender a construção do problema abordado e como os elementos que o compõem interagem entre si, apresenta-se, a seguir, um exemplo hipotético, no qual almeja-se a localização de carregadores visando o menor custo. Para isto, considera-se a rede fictícia apresentada na Figura 3.1, onde há duas demandas a serem atendidas com pares OD sendo $(o^1, d^1) = (1, 5)$ e $(o^2, d^2) = (6, 9)$. Inicialmente, pode-se observar que a primeira demanda possui apenas uma opção de caminho viável, constituído pelos nós [1,2,3,4 e 5], enquanto a segunda demanda possui duas opções de caminhos viáveis com mesma distância: [6,7,8,9] ou [6,2,3,4,9].

Para este exemplo, considera-se um caminhão elétrico fictício com autonomia de 240 km. Neste caso, visando menores custos, há necessidade de localização de carregadores apenas no nó 3, com distâncias iguais entre si que representam o alcance do veículo, suficiente para atendimento das duas demandas.

No entanto, caso sejam inseridas restrições de jornada de trabalho dos motoristas, essa solução pode se tornar inviável. Por exemplo, ao considerar que os motoristas não podem dirigir mais do que 2h consecutivas e não mais do que 4h diárias, estes devem fazer ao menos uma parada rápida para descanso no nó 2 e uma parada para dormir no nó 4. Desta forma, o carregamento do veículo pode ser sincronizado com

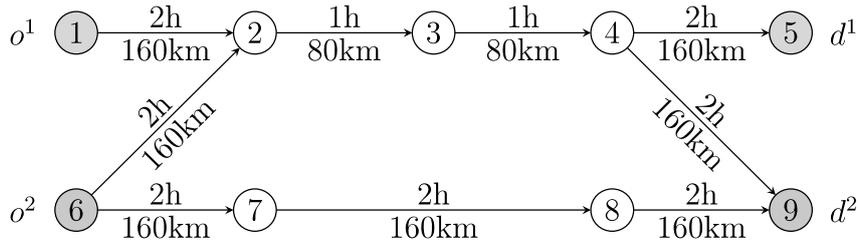


Figura 3.1: Exemplo de rede de transporte para apresentação do problema em tela.

as paradas obrigatórias do motorista, com localização de carregadores nestes nós.

Além disso, estratégias envolvendo diferentes tecnologias de carregadores podem ser elaboradas com base no tempo de disponibilidade do veículo em um determinado nó. Por exemplo, carregadores de alto desempenho podem ser localizados nas paradas rápidas (menos tempo disponível para carregamento), enquanto carregadores com menores performance podem ser implementados nos locais de parada para dormir (maior tempo disponível para carregamento).

O exemplo apresentado ilustra como a sincronização da ação de carregamento dos veículos com o tempo de pausa ou descanso do motorista pode afetar o problema de localização de carregadores para veículos de longa distância. Apresenta-se, nas sessões seguintes, a descrição formal do PLCR-JTM.

3.2.1 Premissas gerais

Segundo a literatura sobre veículos elétricos (ver KUCUKOGLU *et al.* [26]), considera-se que os caminhões elétricos iniciam a rota com carga total. Considera-se também que os condutores iniciam as suas viagens após um longo período de descanso, ou seja, a partida ocorre após o final de um período de descanso longo, o que permite aos condutores dirigirem o valor total das horas diárias permitidas. Além disso, uma vez que o problema é colocado em um nível estratégico, não são consideradas recargas parciais da bateria, apesar de ser permitido o carregamento antes do completo descarregamento da bateria, e considera-se que os veículos são totalmente carregados ao acessarem os carregadores.

De forma geral, a legislação sobre jornada de trabalho dos motoristas especifica duas categorias de função do motorista: horas de serviço e horas de condução. Horas de serviços referem-se ao tempo que o caminhoneiro está trabalhando, não necessariamente dirigindo. Já as horas de condução referem-se ao tempo específico em que o motorista está controlando o veículo. No problema abordado, assumiu-se que, ao longo da viagem, a única atribuição do motorista é conduzir o caminhão, uma vez que o problema é abordado a partir de um enfoque estratégico. Portanto, as horas de serviço coincidem com as horas de condução.

3.2.2 Definição da demanda

As viagens com mesmas características são combinadas em um único grupo denominado de demanda. A demanda $q \in \mathcal{Q}$ é definida por um vetor constituído de sete elementos $\langle o^q, d^q, f^q, e^q, a^q, \bar{r}^q, \underline{r}^q \rangle$, como descrito a seguir.

A demanda de uma *commodity* parte de um nó de produção ($o^q \in \mathcal{N}$) com destino à um nó de consumo ($d^q \in \mathcal{N}$) transportada por um fluxo de caminhões elétricos. O número necessário de veículos em um fluxo (f^q) é definido em função de sua capacidade e do volume de *commodities* a serem transportadas. O período em que a carga fica disponível para transporte e o prazo máximo para sua entrega são representados, respectivamente, por e^q e a^q . A autonomia operacional da bateria, expressa em medidas de distância, é definida por um valor mínimo de segurança (\underline{r}^q , que pode ser igual a zero) e um valor máximo que representa o alcance total quando a bateria está completamente carregada (máxima capacidade da bateria, \bar{r}^q).

3.2.3 Estratégias de carregamento

As decisões ótimas de localização e roteamento dos veículos podem variar de acordo com as tecnologias de carregamento disponibilizadas para implantação. Para a modelagem do problema proposto, considerou-se a disponibilidade de dois tipos de carregadores, rápido e lento, com custos fixos de instalação diferenciados no modelo. Essas tecnologias foram associadas às exigências da legislação de jornada de trabalho para compor as estratégias de carregamento, conforme descrito a seguir:

- Carregadores rápidos são disponibilizados aos motoristas em paradas rápidas (menor tempo disponível no local para carregamento); e
- Carregadores lentos são disponibilizados aos motoristas em paradas para descansos longos (maior tempo disponível para carregamento).

Desta forma, considera-se que os veículos são completamente carregados nos tempos em que estão cumprindo as exigências impostas pela legislação de jornada de trabalho.

3.2.4 Rede de Transporte

A rede de transporte é representada por um grafo direcionado e ponderado $\mathcal{G} = (\mathcal{N}, \mathcal{A})$, onde $\mathcal{N} = \{1, \dots, n\}$ é o conjunto de nós e $\mathcal{A} = \{(i, j) : i, j \in \mathcal{N}\}$ o conjunto de arcos. Associado a cada arco, há um comprimento $l_{ij} \geq 0$ e um tempo de viagem $\tau_{ij} \geq 0$. A Figura 3.1 ilustra um exemplo de uma rede de transporte para o problema em tela.

O custo variável para atravessar um arco $(i, j) \in \mathcal{A}$ é expresso pela soma de dois termos: custo de consumo energético e custo do motorista. O primeiro termo expressa, em valores monetários, a quantidade de bateria utilizada para ir de i até j . Portanto, depende do comprimento do arco e é expresso por $l_{ij}p^{cc}$, onde p^{cc} é o custo unitário de carregamento (em $\$/km$). Já o segundo termo representa os custos com o salário dos motoristas, expresso por $\tau_{ij}p^{hd}$, onde p^{hd} é o custo horário dos motoristas.

Um caminho é considerado viável para uma demanda na rede de transporte se são satisfeitos as seguintes condições:

- O caminho tem início no nó de origem (o^q) e termina no nó de destino (d^q) da demanda;
- Há carregadores suficientes ao longo do caminho de forma que seja viável trafegá-lo sem que o nível da bateria seja inferior à \underline{r}^q ; e
- A jornada de trabalho dos motoristas respeita a legislação.

As decisões do problema proposto envolvem a localização de carregadores, a programação horária dos motoristas e o roteamento da demanda levando-se em consideração a legislação de jornada de trabalho e as restrições de carregamento dos veículos. Portanto, o problema requer a sincronização espaço-temporal da demanda através da rede de transporte. A sincronização espacial é necessária para acompanhar o nível da bateria e sincronizar as recargas ao longo do trajeto, resultando na localização dos carregadores e o tipo (de carregamento rápido ou lento). Já a sincronização temporal é necessária não somente para verificar o atendimento à janela de tempo compreendida entre o tempo em que a demanda fica disponível para iniciar a viagem e o maior tempo permitido para entrega, mas, também, para certificar que a jornada de trabalho dos motoristas está em consonância com a legislação vigente. Portanto, ao saber onde e quando cada demanda localiza-se na rede de transporte, é possível obter as decisões esperadas do problema.

Neste contexto, apresenta-se, a seguir, as transformações propostas para a construção de uma rede espaço-temporal para o problema em estudo e que embasou a modelagem matemática. Para isto, apresenta-se, inicialmente, o processo de transformação da rede de transporte em uma rede de comunicação (MIRHASSANI e EBRAZI [113]) e nos conceitos de *segmentos de caminhos* (YILDIZ e KARAŞAN [114], ARSLAN *et al.* [115], YILDIZ *et al.* [116]). Por fim, apresenta-se a abordagem utilizada para a transformação desta rede em uma rede de comunicação espaço-temporal, conforme conceitos aplicados por DYK e KOENEMANN [117].

3.2.5 Rede de Comunicação

A decisão de roteamento do PLCR-JTM consiste em identificar, para cada demanda, a melhor combinação válida de nós a serem visitados, ou seja, consiste na construção de um caminho viável. Como discutido anteriormente, um caminho é considerado viável para uma demanda se há quantidade suficiente de carregadores ao longo de sua rota de forma que a autonomia da bateria seja respeitada e que a jornada de trabalho não exceda as restrições legais. Neste contexto, esta seção descreve a primeira etapa de transformação proposta, que consiste na expansão da rede de transporte \mathcal{G} em uma rede de comunicação $\hat{\mathcal{G}}^q$.

Esta abordagem visa construir uma rede constituída apenas por arcos viáveis, na qual carregadores são localizados em todos os nós visitados por uma demanda. Ou seja, cada arco no grafo de comunicação, denominado por “*segmento de caminho*”, é equivalente a trafegar entre dois nós da rede de transporte pelo caminho mínimo sem violar as condições de viabilidade.

Na rede de comunicação, \hat{l}_{ij} e $\hat{\tau}_{ij}$ representam, respectivamente, a distância e o tempo do menor caminho entre dois nós $i, j \in \mathcal{N}$. Um *segmento de caminho* somente é considerado na rede de comunicação se o tempo para trafegá-lo não excede a quantidade legal de horas consecutivas de direção ($\hat{\tau}_{ij} \leq h^{driving}$) e seu comprimento não excede a autonomia do veículo ($\hat{l}_{ij} \leq \bar{r}^q - \underline{r}^q$).

Embora a primeira condição seja definida pela legislação local (como apresentado na Tabela 3.1), a segunda é um dado de entrada da demanda. Portanto, deve ser gerada uma rede de comunicação para cada demanda $q \in \mathcal{Q}$, representada por $\hat{\mathcal{G}}^q = (\hat{\mathcal{N}}^q, \hat{\mathcal{A}}^q)$. Portanto, quando um nó interno $\{i : i \in \hat{\mathcal{N}}^q \setminus \{o^q, d^q\}\}$ é visitado pela demanda, significa que um carregador deve ser localizado neste nó, visando tornar a solução viável.

Duas estratégias são aplicadas a partir do pré-processamento das informações provenientes da rede de transporte \mathcal{G} para redução da quantidade de nós e segmentos de caminho na rede de comunicação. A primeira estratégia tem por objetivo identificar, para cada demanda, apenas os nós que conectam os nós de origem e destino. Desta forma, um nó $i \in \mathcal{N}$ somente é inserido na rede de comunicação $\hat{\mathcal{G}}^q$ se houver um caminho conectando este nó ao par OD da demanda avaliada (o^q, d^q) , ou seja, há um caminho conectando os nós (o^q, i) e (i, d^q) . Já a segunda estratégia visa identificar e desconsiderar os *segmentos de caminho* que chegam no nó de origem o^q ou que partem do nó de destino d^q da demanda.

Como conclusão, o conjunto de nós da rede de comunicação pode ser representado por $\hat{\mathcal{N}}^q = \{i : i \in \mathcal{N} \iff (\text{caminho de } o^q \text{ a } i) \cap (\text{caminho de } i \text{ a } d^q)\}$ e o conjunto de segmentos de caminho por $\hat{\mathcal{A}}^q = \{(i, j) : \hat{l}_{ij} \leq \bar{r}^q - \underline{r}^q \cap \hat{\tau}_{ij} \leq h^{driving}, i, j \in \hat{\mathcal{N}}^q, i \neq j, i \neq d^q, j \neq o^q\}$. O custo para atravessar um *segmento de caminho* é

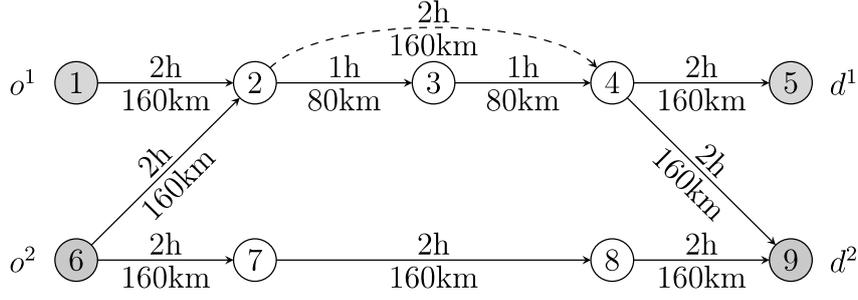


Figura 3.2: Exemplo de uma rede de comunicação a partir da rede de transporte da Figura 3.1.

resultado da soma do consumo de bateria e dos salários dos motoristas, expresso por $\hat{l}_{ij} p^{cc}$ e $\hat{\tau}_{ij} p^{hd}$, respectivamente.

A Figura 3.2 apresenta a expansão da rede de transporte apresentada na Figura 3.1 ao considerar o exemplo em que a autonomia dos veículos é igual a 240km e que os motoristas não podem dirigir mais do que duas horas consecutivas. Neste caso, o fator limitante para definição dos *segmentos de caminho* foi a regulamentação da jornada de trabalho, o que resultou em um conjunto com nove arcos, apenas um a mais do que os presentes na rede de transporte (no caso, o arco conectando os nós 2 e 4).

3.2.6 Rede de Comunicação Espaço-Temporal

O último passo para o processo de transformação das redes proposto consiste na aplicação de uma abordagem de expansão temporal para discretização da rede de comunicação $\hat{\mathcal{G}}^q$ em uma rede de comunicação espaço-temporal $\hat{\mathcal{G}}_{\mathcal{T}}^q$.

Recorda-se que cada demanda $q \in \mathcal{Q}$ tem um tempo de saída e^q e um tempo máximo de entrega a^q . Assim, o horizonte de planejamento de uma demanda é definido pelo intervalo $[e^q, a^q]$. O objetivo do processo de discretização é dividir o horizonte de planejamento em intervalos menores de tempo e de iguais comprimento δ , i.e., $\mathcal{T}^q = \{\underline{\Delta}^q, \underline{\Delta}^q + 1, \dots, \overline{\Delta}^q - 1, \overline{\Delta}^q\}$, onde $\underline{\Delta}^q = \lceil e^q/\delta \rceil$ e $\overline{\Delta}^q = \lceil a^q/\delta \rceil$. Já o horizonte de planejamento completo é descrito por $\mathcal{T} = \cup_{q \in \mathcal{Q}} \mathcal{T}^q$ e compreende o intervalo $[\min_{q \in \mathcal{Q}} \{\underline{\Delta}^q\}, \max_{q \in \mathcal{Q}} \{\overline{\Delta}^q\}]$, isto é, limitado inferiormente pelo menor tempo de saída e superiormente pelo maior tempo de chegada dentre as demandas

A rede de comunicação espaço-temporal $\hat{\mathcal{G}}_{\mathcal{T}}^q$ é uma expansão da rede de comunicação $\hat{\mathcal{G}}^q$, obtida discretizando-se por \mathcal{T}^q . O processo de expansão tem início pela construção do conjunto de nós $\hat{\mathcal{N}}_{\mathcal{T}}^q$, copiando-se cada nó $i \in \hat{\mathcal{N}}^q$ para cada $t \in \mathcal{T}^q$, resultando em nós no formato (i, t) .

Os arcos nesta rede expandida pertencem a cinco conjuntos: $\hat{\mathcal{A}}_{\mathcal{T}}^q \cup \hat{\mathcal{B}}_{\mathcal{T}}^q \cup \hat{\mathcal{R}}_{\mathcal{T}}^q \cup \hat{\mathcal{W}}_{\mathcal{T}}^q \cup \hat{\mathcal{D}}_{\mathcal{T}}^q$. O conjunto $\hat{\mathcal{A}}_{\mathcal{T}}^q$ contém os arcos que representam os segmentos de caminho da rede de comunicação, com movimentos no tempo e no espaço, ou seja, conectam

nós com diferentes posições geográficas: $((i, t), (j, t + u_{ij}^a))$, onde $u_{ij}^a = \lceil \hat{\tau}_{ij} / \delta \rceil$, desde que $t + u_{ij}^a \leq \bar{\Delta}^q$.

Os três conjuntos seguintes, $\hat{\mathcal{B}}_{\mathcal{T}}^q \cup \hat{\mathcal{R}}_{\mathcal{T}}^q \cup \hat{\mathcal{W}}_{\mathcal{T}}^q$, contém arcos de retenção, que denotam movimentos apenas no tempo. Estes representam quando o veículo está parado em uma mesma posição geográfica (em um nó) para atender as exigências impostas pelo problema. Assim, um arco de um desses conjuntos conecta dois nós $((i, t), (i, t + u^s))$, onde u^s é o tempo de serviço conforme segue:

- $\hat{\mathcal{B}}_{\mathcal{T}}^q$ contém arcos que representam paradas para descanso de curta duração enquanto o veículo é recarregado utilizando-se carregadores de carregamento rápido (Nível III): $u^b = \lceil h^{break} / \delta \rceil$;
- $\hat{\mathcal{R}}_{\mathcal{T}}^q$ contém arcos que representam paradas para descansos de longa duração (dormir) enquanto os veículos são carregados utilizando-se carregadores de carregamento lento (Nível I ou II): $u^r = \lceil h^{rest} / \delta \rceil$; e
- $\hat{\mathcal{W}}_{\mathcal{T}}^q$ contém arcos que representam tempos de espera em um nó, sem carregamento de veículo, com duração de tempo equivalente ao intervalo de discretização: δ .

Se há um caminho viável, a demanda pode alcançar o nó de destino d^q em qualquer tempo t desde que este seja menor do que o tempo máximo $\bar{\Delta}^q$, ou seja, a demanda é considerada entregue ao atingir um nó (d^q, t) com $t \in \mathcal{T}^q$, $t \leq \bar{\Delta}^q$. No entanto, o nó $(d^q, \bar{\Delta}^q)$ é considerado como destino final no problema matemático proposto. Visando manter o fluxo da *commoditie* do nó temporal de destino alcançado ao nó final, foram criados arcos temporais sem custos, conectando todos os nós temporais de destino ao nó de escoamento da demanda, ou seja, $((d^q, t), (d^q, \bar{\Delta}^q)), \forall t \in \mathcal{T}^q$. Estes arcos compõem o conjunto $\hat{\mathcal{D}}_{\mathcal{T}}^q$.

É importante salientar que, uma vez que os veículos iniciam o trajeto com as baterias carregadas e os motoristas descansados, não foram considerados arcos de descanso com carregamento nos nós temporais de origem. Além disso, quando a demanda atinge o destino, é considerado fim do trajeto. Logo, não são considerados arcos de descanso ou de espera conectando os nós temporais de destino. Ao mesmo tempo, não foi considerada localização de carregadores nas origens e destinos das demandas.

A Figura 3.3 ilustra os conjuntos de arcos da rede de comunicação espaço-temporal da demanda 1 do exemplo de apresentação do problema (Figura 3.2), i.e., $(o^1, d^1) = (1, 5)$, e considerando $e^1 = 0$, $a^1 = 12$ e $\delta = 1$. A Figura 3.4 apresenta uma solução viável e ótima para as duas demandas do exemplo. Na solução apresentada, observa-se que os motoristas fazem uma parada para descanso rápido no nó 2 (entre os tempos 2 e 4) e uma parada para dormir no nó 6 (entre os tempos 6 e 10). Assim,

a solução do problema aponta para a localização de carregadores de rápido e lento carregamento nos nós 2 e 6, respectivamente. No entanto, como as duas demandas necessitam utilizar simultaneamente a mesma infraestrutura, deve ser considerada a quantidade suficiente de carregadores para atendimento. Desta forma, verifica-se que a flexibilização do tempo máximo de entrega de ao menos uma das demandas permitiria, por exemplo, a utilização de arcos de espera, de forma que as duas demandas compartilhem a mesma estrutura de carregamento, reduzindo a quantidade de carregadores localizados na rede.

Como consequência da aplicação desta abordagem de discretização temporal, apenas há consumo de bateria quando os caminhões deslocam-se geograficamente, i.e., ao serem utilizados os *segmentos de caminho* contidos no conjunto $\hat{\mathcal{A}}_{\mathcal{T}}^q$. Desta forma, o custo para atravessar um arco espaço-temporal $((i, t), (j, t + u_{ij}^a)) \in \hat{\mathcal{A}}_{\mathcal{T}}^q$, dado por c_{ij}^{var} , é equivalente ao custo de ir do nó i ao nó j através da rede de comunicação ($\hat{l}_{ij} p^{cc} + \hat{\tau}_{ij} p^{hd}$). Por outro lado, ao utilizar um arco temporal $((i, t), (i, t + u^s)) \in \hat{\mathcal{B}}_{\mathcal{T}}^q \cup \hat{\mathcal{R}}_{\mathcal{T}}^q \cup \hat{\mathcal{W}}_{\mathcal{T}}^q$ pode ser considerado apenas o custos do salário do motorista ($u^s p^{hd}$), apenas o custo do serviço (c_{ij}^b para $\hat{\mathcal{B}}_{\mathcal{T}}^q$, c_{ij}^r para $\hat{\mathcal{R}}_{\mathcal{T}}^q$ e c_{ij}^w para $\hat{\mathcal{W}}_{\mathcal{T}}^q$) ou ambos os custos em conjunto, a depender das regras tarifárias impostas.

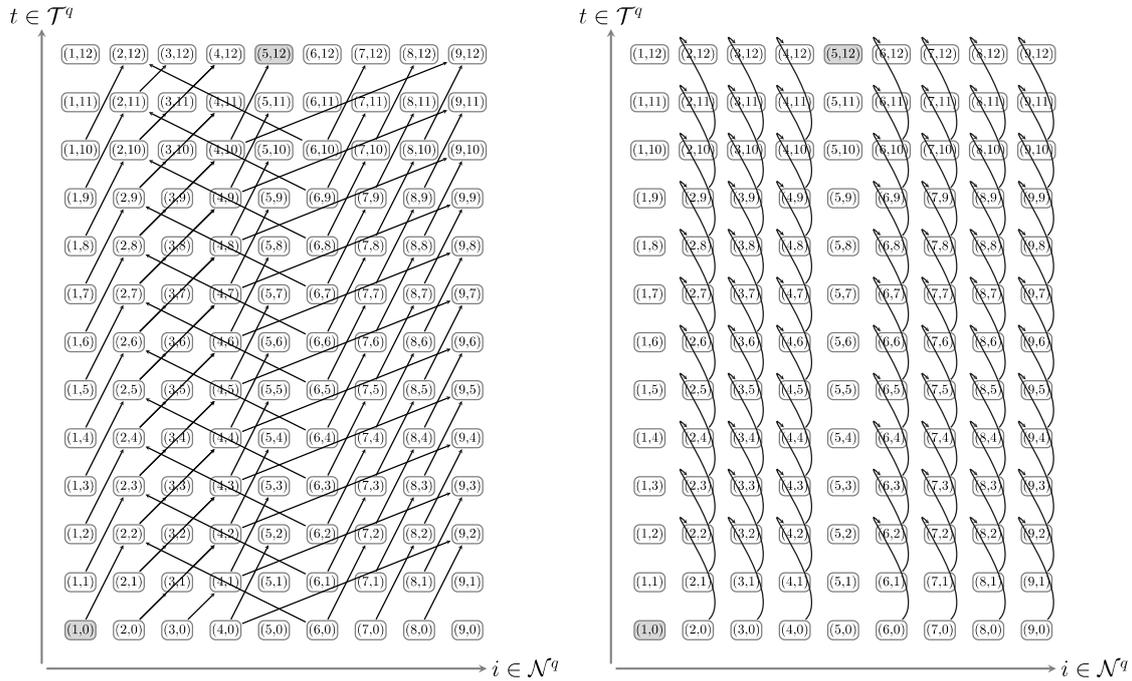
Como apresentado nesta seção, é necessário ajustar os parâmetros de tempo para coincidirem com o intervalo de discretização. Assim, em complemento aos parâmetros já discutidos, destaca-se a necessidade de ajuste dos seguintes parâmetros das regras de jornada de trabalho, conforme apresentado na Tabela 3.1:

- $\hat{h}^{daily} = \lceil h^{daily} / \delta \rceil$;
- $\hat{h}^{driving} = \lceil h^{driving} / \delta \rceil$; e
- $\hat{h}^{totalrest} = \lceil h^{totalrest} / \delta \rceil$.

3.2.7 Definição de *caminho direto*

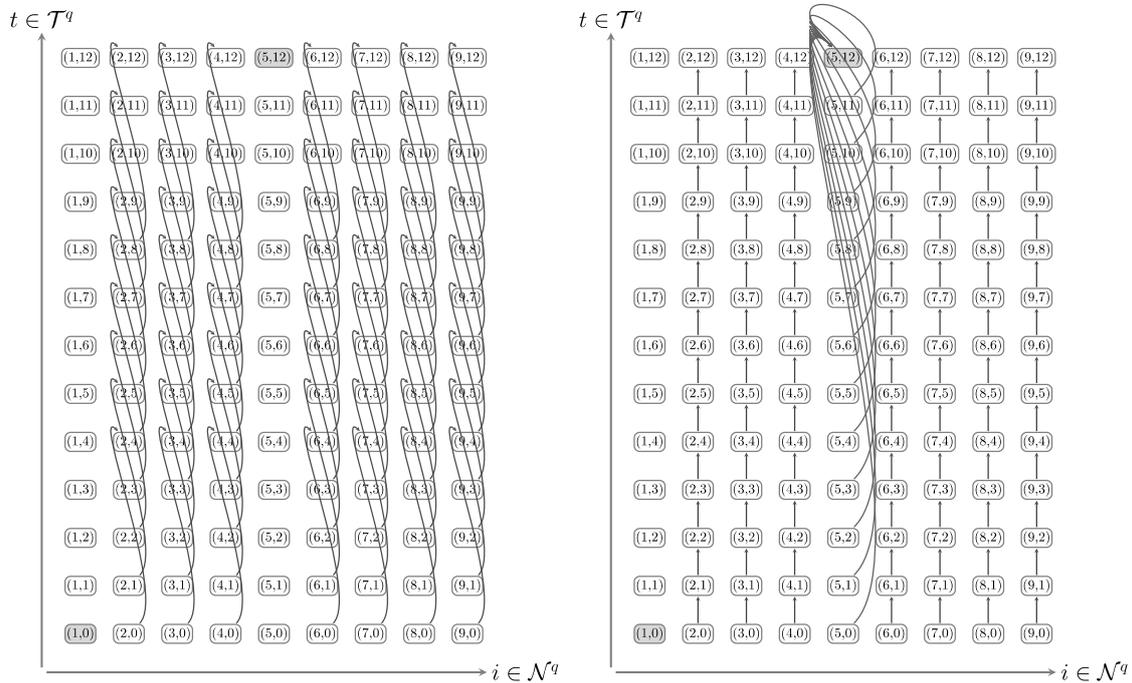
De acordo com YILDIZ e KARAŞAN [114], um *caminho direto* em uma rede composta por *segmentos de caminho*, como a rede de comunicação $\hat{\mathcal{G}}^q$ aqui desenvolvida, é uma sequência alternada de nós e arcos $(n_0, a_1, n_2, a_2, \dots, a_k, n_k)$ com $n_i \in \hat{\mathcal{N}}^q, \forall i = 0, \dots, k$ e $a_i = (n_{i-1}, n_i) \in \hat{\mathcal{A}}^q, \forall i = 1, \dots, k$. Um *caminho direto* é denominado de *não-simples* se possuir repetição de nós. Caso contrário, é denominado de *simples*.

Para aplicação ao PLCR-JTM, este conceito foi adaptado para a rede de comunicação espaço-temporal. Assim, um *caminho direto* pode ser definido por uma sequência alternada de nós temporais, segmentos de caminho e arcos temporais, em que $n_i \in \hat{\mathcal{N}}_{\mathcal{T}}^q$ e $a_i \in \hat{\mathcal{A}}_{\mathcal{T}}^q \cup \hat{\mathcal{B}}_{\mathcal{T}}^q \cup \hat{\mathcal{R}}_{\mathcal{T}}^q \cup \hat{\mathcal{W}}_{\mathcal{T}}^q \cup \hat{\mathcal{D}}_{\mathcal{T}}^q$. Portanto a decisão de roteamento do



(a) Conjunto $\hat{\mathcal{A}}_T^q$

(b) Conjunto $\hat{\mathcal{B}}_T^q$



(c) Conjunto $\hat{\mathcal{R}}_T^q$

(d) Conjuntos $\hat{\mathcal{W}}_T^q$ e $\hat{\mathcal{D}}_T^q$

Figura 3.3: Classificações dos *segmentos de caminho* que compõem a rede de comunicação espaço-temporal para a demanda 1 do exemplo, com $(o^1, d^1) = (1, 5)$

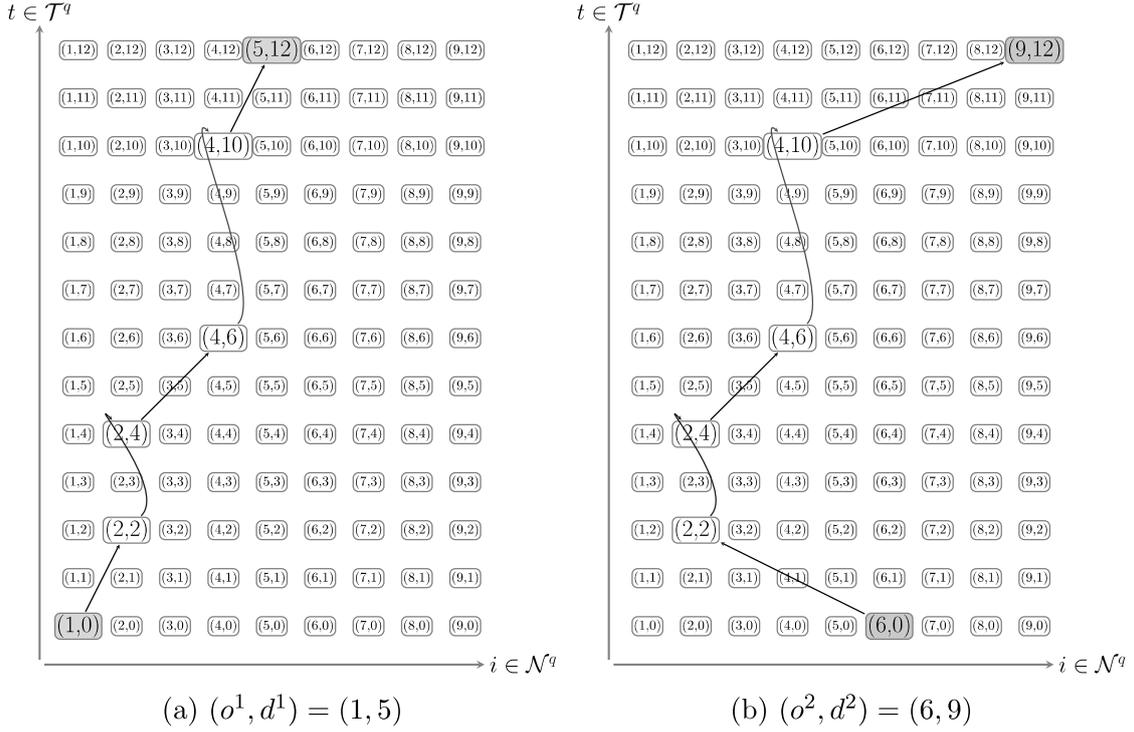


Figura 3.4: Soluções para os exemplos de apresentação do problema considerando $e^1 = e^2 = \underline{\Delta} = 0$ e $a^1 = a^2 = \overline{\Delta} = 12$.

PLCR-JTM é obtida para cada demanda $q \in \mathcal{Q}$ para encontrar um *caminho direto* em $\hat{\mathcal{G}}_T^q$ que conecta o nó temporal de origem $(o^q, \underline{\Delta}^q)$ e o nó temporal de destino $(d^q, \overline{\Delta}^q)$ por meio da junção de *segmentos de caminho* e arcos temporais.

Denota-se por $\mathcal{P}^q \subseteq \hat{\mathcal{A}}_T^q \cup \hat{\mathcal{B}}_T^q \cup \hat{\mathcal{R}}_T^q \cup \hat{\mathcal{W}}_T^q \cup \hat{\mathcal{D}}_T^q$ o conjunto de todos os *segmentos de caminho* e arcos temporais para uma demanda $q \in \mathcal{Q}$ e por \mathcal{P} o conjunto contendo todos os *segmentos de caminho* e arcos temporais para todas as demandas, i.e., $\mathcal{P} = \cup_{q \in \mathcal{Q}} \mathcal{P}^q$.

Para satisfazer uma determinada demanda, deve haver um caminho viável em $\hat{\mathcal{G}}_T^q$ que atenda as seguintes condições:

- Inicia em $(o^q, \underline{\Delta}^q)$ e termina em $(d^q, \overline{\Delta}^q)$, com a localização de carregadores em todos os nós intermediários visitados;
- A quantidade de horas dirigindo entre dois períodos longos de descanso não deve exceder o valor legal máximo h^{daily} ;
- A quantidade de horas consecutivas dirigindo não deve exceder o valor máximo legal $h^{driving}$;
- A duração do período descanso longo não deve ser menor do que o valor mínimo legal h^{rest} ;

- A duração do período curto de descanso não deve ser menor do que o valor mínimo legal h^{break} ;
- O período total de descanso em um dia não deve ser menor do que o valor mínimo legal $h^{totalrest}$, e
- Após percorrer um *segmento de caminho* (com consumo de bateria), a demanda deve percorrer um arco temporal com carregamento veicular.

3.3 Formulação Matemática e Estratégias Metodológicas

Nesta seção, descreve-se o modelo matemático baseado em uma rede de comunicação espaço-temporal proposto para o PLCR-JTM, no qual busca-se atender as restrições impostas pelo problema, discutidas na seção anterior. As variáveis de decisão são apresentadas na Tabela 3.2.

Tabela 3.2: Variáveis de decisão.

Notação	Descrição
x_{ij}^{qt}	Variável binária que indica (1), se a demanda $q \in \mathcal{Q}$ utiliza o <i>segmento de caminho</i> $((i, t), (j, t + u_{ij})) \in \mathcal{P}$ no tempo $t \in \mathcal{T}$, ou (0), caso contrário.
y_i^s	Quantidade de carregadores lentos localizados no nó $i \in \hat{N}$
y_i^f	Quantidade de carregadores rápidos localizados no nó $i \in \hat{N}$
θ	Porcentagem utilizada do orçamento para instalação de carregadores

Visando simplificar a notação da função objetivo, assumiu-se os custos e tempos nos arcos que compõem a rede de comunicação espaço-temporal representados, respectivamente, por c_{ij} e u_{ij} , conforme descrito a seguir:

$$c_{ij} = \begin{cases} f^q c_{ij}^{var}, & \text{se } ((i, t), (j, t + u_{ij}^a)) \in \hat{\mathcal{A}}_T^q \\ c_{ij}^b, & \text{se } ((i, t), (j, t + u^b)) \in \hat{\mathcal{B}}_T^q \\ c_{ij}^r, & \text{se } ((i, t), (j, t + u^r)) \in \hat{\mathcal{R}}_T^q \\ c_{ij}^w, & \text{se } ((i, t), (j, t + \delta)) \in \hat{\mathcal{W}}_T^q \\ 0, & \text{se } ((d^q, t), (d^q, \bar{\Delta}^q)) \in \hat{\mathcal{D}}_T^q \end{cases} \quad u_{ij} = \begin{cases} u_{ij}^a, & \text{se } ((i, t), (j, t + u_{ij}^a)) \in \hat{\mathcal{A}}_T^q \\ u^b, & \text{se } ((i, t), (j, t + u^b)) \in \hat{\mathcal{B}}_T^q \\ u^r, & \text{se } ((i, t), (j, t + u^r)) \in \hat{\mathcal{R}}_T^q \\ \delta, & \text{se } ((i, t), (j, t + \delta)) \in \hat{\mathcal{W}}_T^q \\ \bar{\Delta}^q - t, & \text{se } ((d^q, t), (d^q, \bar{\Delta}^q)) \in \hat{\mathcal{D}}_T^q \end{cases}$$

$$\text{minimize} \sum_{\substack{(i,t),(j,t+u_{ij}) \in \mathcal{P}^q \\ i \in \mathcal{T} \\ q \in \mathcal{Q}}} c_{ij} x_{ij}^{qt} + \theta \quad (3.1)$$

$$x_{ji}^{qt} - \sum_{\substack{j: \\ ((i,t),(j,t+u_{ij})) \in \mathcal{P}^q}} x_{ji}^{q,t-u_{ji}} = \begin{cases} 1, & \text{se } (i,t) = (o^q, \underline{\Delta}^q), \\ -1, & \text{se } (i,t) = (d^q, \overline{\Delta}^q), \\ 0, & \text{caso contrário.} \end{cases} \quad q \in \mathcal{Q}, t \in \mathcal{T}^q, (i,t) \in \hat{\mathcal{N}}_T^q \quad (3.2)$$

$$x_{ji}^{q,t-u_{ji}} \leq \sum_{t_1=t}^{\overline{\Delta}^q} \left(\sum_{\substack{j: \\ ((i,t_1),(j,t_1+u^b)) \in \hat{\mathcal{B}}_T^q}} x_{ij}^{qt_1} + \sum_{\substack{j: \\ ((i,t_1),(j,t_1+u^r)) \in \hat{\mathcal{R}}_T^q}} x_{ij}^{qt_1} \right) \quad q \in \mathcal{Q}, t \in \mathcal{T}^q, (i,t) \in \hat{\mathcal{N}}_T^q \setminus \{(o^q, \underline{\Delta}^q), (d^q, \overline{\Delta}^q)\} \quad (3.3)$$

$$\sum_{q \in \mathcal{Q}} \sum_{t_1=t+1}^{t+u^b} \sum_{((i,t_1-u^b),(i,t_1)) \in \hat{\mathcal{B}}_T^q} f^q x_{ij}^{q,t_1-u^b} \leq y_i^f \quad t \in \mathcal{T}, i \in \mathcal{N} \quad (3.4)$$

$$\sum_{q \in \mathcal{Q}} \sum_{t_1=t+1}^{t+u^r} \sum_{((i,t_1-u^r),(i,t_1)) \in \hat{\mathcal{R}}_T^q} f^q x_{ij}^{q,t_1-u^r} \leq y_i^s \quad t \in \mathcal{T}, i \in \mathcal{N} \quad (3.5)$$

$$\sum_{t=t_1}^{t_2} \sum_{((i,t),(j,t+u_{ij}^q)) \in \hat{\mathcal{A}}_T^q} x_{ij}^{qt} u_{ij} \leq \hat{h}^{daily} \left(1 + \sum_{t=t_1}^{t_2} \sum_{((i,t),(j,t+u^r)) \in \hat{\mathcal{R}}_T^q} x_{ij}^{qt} \right) \quad q \in \mathcal{Q}, t_1, t_2 \in \mathcal{T}^q : t_1 < t_2 \quad (3.6)$$

sujeito a:

$$\begin{aligned}
& \sum_{t=t_1}^{t_2} \left(\sum_{((i,t),(j,t+u^w)) \in \hat{\mathcal{N}}_T^q} x_{ij}^{qt} u^{w^q} + \sum_{((i,t),(j,t+u^b)) \in \hat{\mathcal{B}}_T^q} x_{ij}^{qt} u^{b^q} \right) \\
& \geq \begin{cases} (\hat{h}^{\text{totalrest}} - u^r) \left(\sum_{i \in \hat{\mathcal{N}}^q} \sum_{((i,t_2),(i,t_2+u^r)) \in \hat{\mathcal{R}}_T^q} x_{ij}^{qt_2} \right), & \text{if } t_1 = \underline{\Delta}^q \\
(\hat{h}^{\text{totalrest}} - u^r) \left(\sum_{i \in \hat{\mathcal{N}}^q} \sum_{((i,t_1-u^r),(i,t_1)) \in \hat{\mathcal{R}}_T^q} x_{ij}^{q,t_1-u^r} + \sum_{i \in \hat{\mathcal{N}}^q} \sum_{((i,t_2),(i,t_2+u^r)) \in \hat{\mathcal{R}}_T^q} x_{ij}^{qt_2} - 1 \right), & \text{if } t_1 > \underline{\Delta}^q \end{cases} \\
& \qquad \qquad \qquad q \in \mathcal{Q}, t_1, t_2 \in \mathcal{T}^q : t_1 < t_2 \tag{3.7}
\end{aligned}$$

$$\sum_{i \in \mathcal{N}} (p^{\text{sc}} y_i^s + p^{\text{fc}} y_i^f) \leq \theta K \tag{3.8}$$

$$x_{ij}^{qt} \in \{0, 1\} \qquad q \in \mathcal{Q}, t \in \mathcal{T}, ((i,t), (j,t+u_{ij})) \in \mathcal{P}^q \tag{3.9}$$

$$y_i^s, y_i^f \in \mathbb{Z}_+ \qquad i \in \mathcal{N} \tag{3.10}$$

$$\theta \in [0, 1] \tag{3.11}$$

A Função Objetivo (3.1) busca minimizar os custos variáveis de transporte (como consumo de energia e salário dos motoristas) juntamente com o percentual utilizado do orçamento para instalação dos carregadores (referência aos custos fixos através da variável θ). As Restrições (3.2) referem-se à conservação dos fluxos, garantindo que há um *caminho direto* viável para cada demanda, conectando o nó de origem ($o^q, \underline{\Delta}^q$) ao nó de destino ($d^q, \overline{\Delta}^q$). As Restrições (3.3) assegura que os caminhões devem ter suas baterias recarregadas, atravessando um arco temporal com carregamento, i.e., arcos do conjunto $\hat{\mathcal{B}}_{\mathcal{T}}^q \cup \hat{\mathcal{R}}_{\mathcal{T}}^q$, depois de trafegar por um *segmento de caminho* do conjunto $\hat{\mathcal{A}}_{\mathcal{T}}^q$. As Restrições (3.4) e (3.5) garantem que há quantidade suficiente de carregadores de rápido e lento carregamento, respectivamente, para atendimento da demanda. Portanto, estas restrições, juntamente com as Restrições (3.3), garantem a localização de carregadores (rápidos e/ou lentos) nos nós intermediários dos *caminhos diretos* de cada demanda. As Restrições (3.6) impõem que a quantidade total de horas que foram dirigidas entre dois períodos de descanso longo não exceda o limite diário estabelecido por lei. As Restrições (3.7) garantem aos motoristas que a quantidade de folgas entre dois períodos longos de descanso seja respeitada ($h^{totalrest}$ na Tabela 3.1). A Restrição (3.8) impõe um orçamento máximo para custos fixos como estratégias orçamentárias, onde p^{sc} e p^{fc} representam, respectivamente, o custo fixo unitário dos carregadores lentos e rápidos. Por fim, as Restrições (3.9)–(3.11) definem o domínio das variáveis de decisão.

3.3.1 Estratégias para redução do tamanho do modelo

Por ser baseado em uma rede discretizada temporalmente, o modelo matemático proposto tende a ser proibitivamente grande quando aplicado a instâncias de tamanho real. Visando contornar este problema, esta seção tem como objetivo descrever duas estratégias propostas que visam reduzir o tamanho do modelo matemático: i) redução da quantidade de restrições e ii) gerenciamento de nós e arcos supérfluos.

a. Redução da quantidade de restrições

Embora a legislação da jornada de trabalho do motorista dependa de especificidades locais, um entendimento comum e importante entre as leis é quanto à necessidade do período de descanso longo e como isso afeta a jornada diária. Este conceito é transcrito para o modelo através das Restrições (3.6)–(3.7). No entanto, estas foram modeladas com base em uma estrutura que considera a inserção de uma restrição para cada t_1 e $t_2 \in \mathcal{T}^q, t_1 < t_2$. Esta abordagem pode resultar em uma quantidade exponencial de restrições no modelo, surtindo na necessidade de um custo computacional excessivo dependendo do tamanho do conjunto \mathcal{T} . Neste contexto, discute-se a primeira estratégia proposta para redução do tamanho do

modelo, que consiste em estabelecer limites inferiores e superiores para o índice t_2 , impactando na quantidade de restrições no modelo.

As Restrições (3.6) impõem que a quantidade total de horas dirigidas entre dois períodos de tempo $t_1, t_2 \in \mathcal{T}^q$, $t_1 > t_2$ não exceda os limites legais diários, a não ser que haja um período de descanso longo entre eles. Ao assumir que não haja a necessidade de descanso rápidos ao longo do trajeto e que o motorista iniciou a viagem após um período de descanso longo, a primeira hipótese é que um motorista pode iniciar a viagem em t_1 e dirigir continuamente todas as horas diárias, ou seja, sem ter descansos rápidos ao longo do trajeto. Embora isso seja inviável devido à legislação de jornada de trabalho, esta hipótese permite elaborar um limite inferior relaxado para t_2 , dado por $t_1 + \hat{h}^{daily}$.

Por outro lado, t_2 deve estar longe o suficiente de t_1 para cobrir pelo menos uma jornada de trabalho, um período de descanso longo e mais uma jornada diária considerando todas as pausas necessárias. Desta forma, a formulação visa garantir uma nova jornada diária de trabalho apenas se o condutor tiver tido um descanso prolongado. Sem prejuízos, pode-se dizer que dois dias corridos (48h) menos o período de descanso longo engloba o necessário para limitar t_2 . Seguindo esta ideia, t_2 pode ser limitado superiormente por $t_1 + \lceil 48/\delta \rceil - u^r$. Assim, as Restrições (3.6) podem ser substituídas pelas Restrições (3.12).

Já as Restrições (3.7) visam garantir aos condutores o descanso diário total estabelecido na lei. Para isso, se um descanso longo terminar em t_1 e outro começa em t_2 (indicando fim de uma jornada diária), estas garantem que o tempo total de pausa e espera entre esses dois períodos de tempo seja igual ou maior que o valor mínimo legal. Para este caso, o único limitante inferior para t_2 é t_1 , de forma a sempre garantir o descanso entre os dois tempos. Por outro lado, t_2 deve estar longe o suficiente de t_1 para cobrir ao menos o final e o início de um período de descanso longo. Portanto, t_2 pode ser limitado superiormente por $t_1 + \lceil 24/\delta \rceil$, isto é, 24 horas de diferença. Assim, as Restrições (3.7) podem ser substituídas pelas Restrições (3.13).

b. Gerenciamento de nós e arcos supérfluos

Após a etapa de discretização, a rede de comunicação espaço-temporal $\hat{\mathcal{G}}_{\mathcal{T}}^q$ pode conter nós e arcos que não constituem soluções viáveis ao problema. Assim, um nó temporal $(i, t) \in \hat{\mathcal{N}}_{\mathcal{T}}^q$ é dito supérfluo caso seja impossível de ser visitados devido ao tempo necessário para chegar a este nó a partir da origem $(o^q, \underline{\Delta}^q)$ ou porque, ao visitá-lo, a demanda é impedida de atingir o nó de destino antes do tempo máximo estabelecido, isto é, nó $(d^q, \overline{\Delta}^q)$. Neste contexto, esta segunda estratégia para redução do tamanho do modelo é baseada nas proposições de BOLAND *et al.* [118], porém com ajustes para o problema atual.

$$\sum_{t=t_1}^{t_2} \sum_{((i,t),(j,t+u_{ij}^a)) \in \hat{\mathcal{A}}_7^q} x_{ij}^{qt} u_{ij} \leq \hat{h}^{daily} \left(1 + \sum_{t=t_1}^{t_2} \sum_{((i,t),(j,t+u^r)) \in \hat{\mathcal{R}}_7^q} x_{ij}^{qt} \right) \quad q \in \mathcal{Q}, t_1, t_2 \in \mathcal{T}^q : t_1 + \hat{h}^{daily} < t_2 \leq t_1 + \lceil 48/\delta \rceil - u^r \quad (3.12)$$

$$\sum_{t=t_1}^{t_2} \left(\sum_{((i,t),(j,t+u^w)) \in \hat{\mathcal{W}}_7^q} x_{ij}^{qt} u^w + \sum_{((i,t),(j,t+u^b)) \in \hat{\mathcal{B}}_7^q} x_{ij}^{qt} u^b \right) \geq \begin{cases} (\hat{h}^{totalrest} - u^r) \left(\sum_{i \in \hat{\mathcal{N}}^q} \sum_{((i,t_2),(i,t_2+u^r)) \in \hat{\mathcal{R}}_7^q} x_{ij}^{qt_2} \right), & \text{if } t_1 = \underline{\Delta}^q \\ (\hat{h}^{totalrest} - u^r) \left(\sum_{i \in \hat{\mathcal{N}}^q} \sum_{((i,t_1-u^r),(i,t_1)) \in \hat{\mathcal{R}}_7^q} x_{ij}^{q,t_1-u^r} + \sum_{i \in \hat{\mathcal{N}}^q} \sum_{((i,t_2),(i,t_2+u^r)) \in \hat{\mathcal{R}}_7^q} x_{ij}^{q,t_2} - 1 \right), & \text{if } t_1 > \underline{\Delta}^q \end{cases} \quad q \in \mathcal{Q}, t_1, t_2 \in \mathcal{T}^q : t_1 < t_2 \leq t_1 + \lceil 24/\delta \rceil - u^r \quad (3.13)$$

Esta estratégia tem como objetivo criar uma rede de comunicação espaço-temporal operacional $ON(\hat{\mathcal{G}}_T^q)$ a partir de uma seleção de nós e arcos não supérfluos provenientes de $\hat{\mathcal{G}}_T^q$, de modo que esta rede operacional seja capaz de produzir a solução ótima para $\hat{\mathcal{G}}_T^q$. Portanto, a rede de comunicação espaço-temporal operacional é derivada de $\hat{\mathcal{G}}_T^q$ e constituída pelo conjunto de nós $ON(\hat{\mathcal{N}}_T^q) \subset \hat{\mathcal{N}}_T^q$ e pelo conjunto de arcos $ON(\hat{\mathcal{A}}_T^q \cup \hat{\mathcal{B}}_T^q \cup \hat{\mathcal{R}}_T^q \cup \hat{\mathcal{W}}_T^q \cup \hat{\mathcal{D}}_T^q) \subset \hat{\mathcal{A}}_T^q \cup \hat{\mathcal{B}}_T^q \cup \hat{\mathcal{R}}_T^q \cup \hat{\mathcal{W}}_T^q \cup \hat{\mathcal{D}}_T^q$.

Sabe-se que, quando a demanda visita um nó interno na rede de comunicação, o caminhão deve ter a bateria recarregada e o motorista deve realizar ao menos um descanso rápido. Visando garantir que uma solução ótima de $ON(\hat{\mathcal{G}}_T^q)$ seja também uma solução ótima de $\hat{\mathcal{G}}_T^q$, é suficiente incluir, na rede operacional, apenas os nós temporais viáveis (i, t) determinados pelo tempo de viagem do *caminho direto* entre o nó temporal de origem $(o^q, \underline{\Delta}^q)$, o nó (i, t) e o nó de destino $(d^q, \overline{\Delta}^q)$ relaxando-se as necessidades de descanso impostas pelas restrições de jornada de trabalho.

Visando identificar os nós supérfluos da rede de comunicação espaço-temporal, são definidos, para cada nó $i \in \hat{\mathcal{N}}^q$, os recortes temporais que limitam inferior e superiormente a viabilidade da solução relaxada. Para isto, é aplicado um processo composto por três etapas, conforme descrito a seguir.

A primeira etapa do processo tem por objetivo identificar, na rede de comunicação $\hat{\mathcal{G}}^q$, o menor caminho que conecte o par OD através do nó avaliado i . Para isto, inicialmente identifica-se o caminho mínimo entre o nó de origem e o nó i (primeiro trecho) e, então, o caminho mínimo entre o nó i e o destino (último trecho). Desta análise, obtém-se os tempos mínimos de viagem para cada trecho do percurso, isto é, $\hat{\tau}_{o^q, i}$ e $\hat{\tau}_{i, d^q}$, respectivamente.

Os tempos mínimos de viagem supracitados se referem apenas ao tempo em direção e não considera os descansos necessários. Desta forma, estes valores podem destoar da realidade uma vez que não consideram os tempos adicionais consequentes da necessidade de cumprimento das restrições de jornada de trabalho. Visando realizar esta correção no tempo de viagem, as seguintes proposições foram estabelecidas.

Proposição 1. Seja $\hat{\tau}_{ij}$ um tempo de viagem entre os nós i e j , com duração superior à quantidade máxima de horas diárias permitida (h^{daily}) pela legislação de jornada de trabalho, o número necessário de descansos longos pode ser obtido através da Equação (3.14), onde ϵ é uma constante com valor pequeno (por exemplo, 0,001).

Prova. Define-se por $\hat{\tau}_{st}$ o tempo de viagem entre dois nós s e t . Conhecendo-se a quantidade máxima de horas diárias h^{daily} , definida na legislação local, três hipóteses podem ser assumidas: i) $\hat{\tau}_{st} < h^{daily}$; ii) $\hat{\tau}_{st} = h^{daily}$; iii) $\hat{\tau}_{st} > h^{daily}$. No primeiro caso, não há necessidade de parada para descanso longo, uma vez que a quantidade de horas dirigidas é inferior à máxima legal. No segundo caso,

a quantidade acumulada de horas trabalhadas em um dia atinge o valor máximo no instante em que o motorista chega no nó de destino. Por tanto, considera-se que o motorista realiza o descanso após a conclusão da viagem, não interferindo nas decisões do modelo. Para esta situação, considera-se, na equação proposta, um valor pequeno, denominado de ϵ , visando tornar o tempo de viagem ligeiramente inferior a valores múltiplos de h^{daily} . Já a ultima situação requer uma ou mais paradas para descanso ao longo da rota, impactando nas decisões do modelo.

$$n_{ij}^r = \lfloor (\hat{\tau}_{ij} - \epsilon) / h^{daily} \rfloor \quad (3.14)$$

Proposição 2. Seja $\hat{\tau}_{ij}$ um tempo de viagem entre os nós i e j com duração superior ao valor máximo de horas consecutivas dirigindo ($h^{driving}$) definido pela legislação de jornada de trabalho. O número necessário de paradas para descanso rápido pode ser obtido através da Equação (3.15), onde ϵ é uma constante com valor pequeno (por exemplo, 0,001).

Prova. Define-se por $\hat{\tau}_{st}$ o tempo de viagem entre dois nós s e t . Conhecendo-se a quantidade máxima legal de horas consecutivas dirigindo $h^{driving}$, quatro hipóteses podem ser assumidas: i) $\hat{\tau}_{st} < h^{driving}$; ii) $\hat{\tau}_{st} = h^{driving}$; iii) $\hat{\tau}_{st} > h^{driving}$ e $\hat{\tau}_{st} < h^{daily}$; e iv) $\hat{\tau}_{st} > h^{driving}$ e $\hat{\tau}_{st} > h^{daily}$. No primeiro caso, não há necessidade de parada para descanso rápido, uma vez que a quantidade de horas consecutivas dirigindo é inferior à máxima legal. No segundo caso, a quantidade de horas dirigindo sem descanso atinge o valor máximo permitido no instante em que o motorista chega no nó de destino. Por tanto, considera-se que o motorista realiza o descanso após a conclusão da viagem, não interferindo nas decisões do modelo. Para esta situação, considera-se, na equação proposta, um valor pequeno, denominado de ϵ , visando tornar o tempo de viagem ligeiramente inferior a valores múltiplos de $h^{driving}$. No terceiro caso, é necessário ao motorista realizar ao menos uma parada para descanso rápido ao longo da rota, mas não é necessário parada para descansos longos. Já para o último caso, observa-se que é necessária a realização de paradas para descanso rápido e longo. Neste caso, a parada para descanso rápido pode ser substituída pela parada de descanso longo.

$$n_{ij}^b = \lfloor (\hat{\tau}_{ij} - \epsilon) / h^{driving} \rfloor - n_{ij}^r \quad (3.15)$$

Visando exemplificar as proposições apresentadas, vamos considerar a demanda $q = 1$ apresentada na Figura 3.2, com $\hat{\tau}_{1,5} = 6$ horas, e adotando-se a quantidade máxima de horas diárias $h^{daily} = 3$ horas e a quantidade máxima legal de horas consecutivas dirigindo $h^{driving} = 4$ horas. Ao aplicar este exemplo numérico na Equação (3.14), obtém-se a necessidade de uma parada para descanso longo, que deve ser realizada, no máximo, até o nó 4. Por outro lado, observa-se que o motorista

pode dirigir consecutivamente apenas até o nó 3. Porém, como já há a necessidade de uma parada para descanso longo, uma possível solução é apenas a realização de uma parada para descanso longo no nó 3, eliminando-se a necessidade de parada para descanso rápido. Esse comportamento pode ser observado ao aplicar o exemplo numérico na Equação (3.15), obtendo-se $n_{1,5}^b = 0$.

Conhecendo-se o tempo de viagem mínimo de uma rota, incluindo-se os tempos adicionais necessários para descansos rápidos e longos, a segunda etapa consiste em avaliar se um nó $i \in \hat{\mathcal{N}}^q$ compõe uma rota viável para a demanda. Uma rota é considerada viável se $\underline{\Delta}^q + \lceil (\hat{\tau}_{o^q d^q}) / \delta \rceil + n_{o^q d^q}^r u^r + n_{o^q d^q}^b u^b \leq \overline{\Delta}^q$, onde $\hat{\tau}_{o^q d^q}$ é o tempo total de viagem obtido somando-se o primeiro e último segmento da rota, isto é, $\hat{\tau}_{o^q d^q} = \hat{\tau}_{o^q i} + \hat{\tau}_{i d^q}$. Caso o nó não permita um caminho viável para a demanda, este não é incluído na rede operacional (para nenhum ponto temporal).

Recorda-se que os nós temporais possuem o formato (i, t) , com $i \in \hat{\mathcal{N}}^q$ e $t \in \mathcal{T}$. A terceira etapa deste pré-processamento consiste em definir, para cada nó $i \in \hat{\mathcal{N}}^q$, limites inferiores e superiores de pontos temporais t que definem a viabilidade de um nó temporal. Os nós temporais não viáveis são denominados de supérfluos e removidos da rede operacional. Para isso, elabora-se as seguintes proposições.

Proposição 3. Visando garantir que qualquer solução ótima de $ON(\hat{\mathcal{G}}_{\mathcal{T}}^q)$ é uma solução ótima do PLCR-JTM, é suficiente incluir, para cada nó $i \in \hat{\mathcal{N}}^q$, apenas valores de $t \in \mathcal{T}^q$ superiores ao menor ponto temporal em que a demanda fica disponível no nó i . O limitante inferior é determinado pelo caminho mínimo direto entre o nó de origem da demanda o^q e o nó em análise, incluindo-se os descansos necessários. Define-se, como limitante inferior para classificação de nós não-supérfluos, $\underline{t}_i^q = \underline{\Delta}^q + \lceil \hat{\tau}_{o^q i} / \delta \rceil + n_{o^q i}^r u^r + n_{o^q i}^b u^b$.

Prova. Considere uma demanda $q \in \mathcal{Q}$ disponível a partir do tempo $\underline{\Delta}^q$ no nó de origem o^q , i.e., com partida no nó temporal $(o^q, \underline{\Delta}^q)$. O menor valor de $t \in \mathcal{T}^q$ em que esta demanda ficará disponível no nó $i \in \hat{\mathcal{N}}^q$ é definido pelo tempo mínimo necessário de deslocamento entre o nó de origem e o nó avaliado, definido por $\hat{\tau}_{o^q i}$, acrescido dos tempos necessários de descanso de modo que as condições legais da jornada de trabalho sejam respeitadas. Ou seja, para o nó $i \in \hat{\mathcal{N}}^q$, é suficiente adicionar apenas pontos temporais $t \geq \underline{\Delta}^q + \lceil \hat{\tau}_{o^q i} / \delta \rceil + n_{o^q i}^r u^r + n_{o^q i}^b u^b = \underline{t}_i^q$. Assim, todos os nós temporais (i, t) com $t < \underline{t}_i^q$ são considerados supérfluos e removidos da rede $ON(\hat{\mathcal{G}}_{\mathcal{T}}^q)$.

Proposição 4. Visando garantir que qualquer solução ótima de $ON(\hat{\mathcal{G}}_{\mathcal{T}}^q)$ é uma solução ótima do PLCR-JTM, é suficiente incluir, para cada nó $i \in \hat{\mathcal{N}}^q$, apenas valores de $t \in \mathcal{T}^q$ inferiores ao maior ponto temporal em que a demanda pode deixar o nó i sem que exceda o prazo máximo de entrega a^q . O limitante superior é definido pelo caminho mínimo direto entre o nó em análise i e o nó de destino da demanda d^q , incluindo-se os descansos necessários. Define-se, como limitante superior para

classificação de nós não-supérfluos, $\bar{t}_i^q = \bar{\Delta}^q - \lfloor \hat{\tau}_{id^q} / \delta \rfloor - n_{id^q}^r u^r - n_{id^q}^b u^b$.

Prova. Considere uma demanda $q \in \mathcal{Q}$ com destino ao nó d^q com prazo máximo de chegada igual a a^q , i.e., com chegada no nó temporal $(d^q, \bar{\Delta}^q)$. O maior valor de $t \in \mathcal{T}^q$ em que esta demanda poderá deixar o nó $i \in \hat{\mathcal{N}}^q$ com destino ao nó final do percurso é definido pelo tempo mínimo necessário de deslocamento entre o nó avaliado e o nó de destino, denominado por $\hat{\tau}_{id^q}$, acrescido dos tempos necessários de descanso de modo que as condições legais da jornada de trabalho sejam respeitadas. Ou seja, para o nó $i \in \hat{\mathcal{N}}^q$, é suficiente adicionar apenas pontos temporais $t \leq \bar{\Delta}^q - \lfloor \hat{\tau}_{id^q} / \delta \rfloor - n_{id^q}^r u^r - n_{id^q}^b u^b = \bar{t}_i^q$. Assim, todos os nós temporais (i, t) com $t > \bar{t}_i^q$ são considerados superfluos e removidos da rede $ON(\hat{\mathcal{G}}_{\mathcal{T}}^q)$.

Como resultado deste processo, obtém-se a rede operacional $ON(\hat{\mathcal{G}}_{\mathcal{T}}^q)$ construída sem os nós superfluos, reduzindo-se o tamanho do problema e, conseqüentemente, os custos computacionais associados a isto.

Com o objetivo de ilustrar este processo, considerou-se os parâmetros e as demandas apresentadas anteriormente e ilustradas na Figura 3.2. Para cada demanda, foram obtidos os valores dos limitantes temporais inferiores e superiores para cada nó, conforme apresentado na Tabela 3.3. A partir destes valores, foram identificados e removidos os nós superfluos, gerando-se a rede operacional apenas com os nós temporais não-supérfluos, suficientes para construir solução viável ao PLCR-JTM. As redes operacionais para cada demanda são ilustradas na Figura 3.5, que pode ser comparada com a versão inicial e completa da rede ilustrada na Figura 3.4.

Tabela 3.3: Cálculo dos limitantes inferiores e superiores para classificação de nós não-supérfluos para o exemplo apresentado.

Demanda	Nó	$\hat{\tau}_{o^q i}$	$n_{o^q i}^r$	$n_{o^q i}^b$	\bar{t}_i^q	$\hat{\tau}_{id^q}$	$n_{id^q}^r$	$n_{id^q}^b$	\bar{t}_i^q
$(o^1, \underline{\Delta}^1) = (1, 0)$ $(d^1, \bar{\Delta}^1) = (5, 12)$	1	0	0	0	0	6	1	1	0
	2	2	0	0	2	4	0	1	6
	3	3	0	1	5	3	0	1	7
	4	4	0	1	6	2	0	0	10
	5	6	1	1	12	0	0	0	12
	6	–	–	–	–	–	–	–	–
	7	–	–	–	–	–	–	–	–
	8	–	–	–	–	–	–	–	–
	9	–	–	–	–	–	–	–	–
$(o^2, \underline{\Delta}^2) = (6, 0)$ $(d^2, \bar{\Delta}^2) = (9, 12)$	1	–	–	–	–	–	–	–	–
	2	2	0	0	2	4	0	1	6
	3	3	0	1	5	3	0	1	7
	4	4	0	1	6	2	0	0	10
	5	–	–	–	–	–	–	–	–
	6	0	0	0	0	6	1	1	0
	7	2	0	0	2	4	0	1	6
	8	4	0	1	6	2	0	0	10
	9	6	1	1	12	0	0	0	12

(–) indica que o nó não possui ligação com a origem e/ou destino

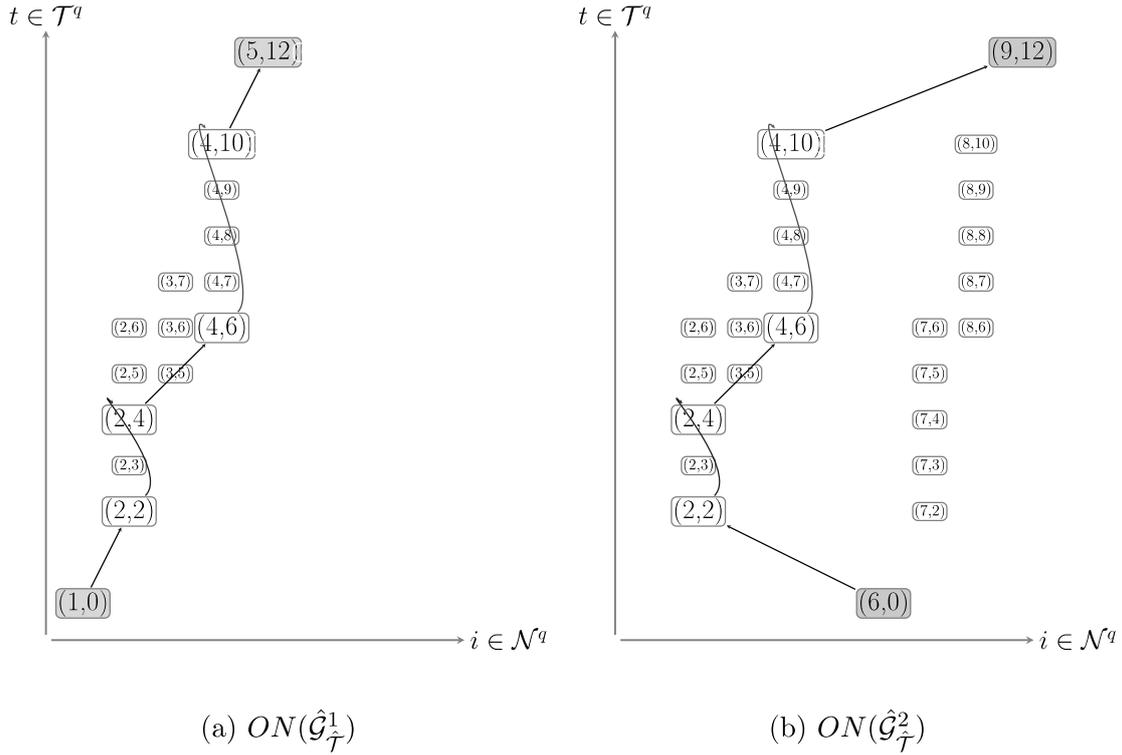


Figura 3.5: Redes operacionais para os exemplos de apresentação do problema.

3.3.2 Condição inicial dos motoristas

O modelo descrito foi estruturado a partir de uma abordagem estratégica para o PLCR-JTM, no qual foi considerado que os motoristas possuem apenas a função de dirigir e iniciam a jornada de trabalho após um longo período de descanso. Desta forma, os motoristas estão aptos à cumprir os períodos máximos de jornada de trabalho estabelecidos na legislação. No entanto, é possível adaptar o modelo para uma abordagem tática, incorporando-se o parâmetro de entrada z^q para indicar uma redução da primeira jornada de trabalho. Esta redução pode ocorrer, por exemplo, devido à horas trabalhadas antes de iniciar o percurso. Para isto, as Restrições (3.6) podem ser substituídas pelas Restrições (3.16), ou as Restrições (3.12) pelas Restrições (3.17).

Ao considerar a condição inicial do motorista, a Equação (3.14) deve ser substituída pela Equação (3.18). Neste caso, considera-se a redução apenas da jornada de trabalho que precede o primeiro período de descanso longo. Posteriormente, calcula-se, para o trecho após o descanso (expresso por $\hat{\tau}_{i,j} - h^{daily}(1 - z^q)$), a quantidade adicional de descansos necessária considerando-se o valor completo da jornada diária de trabalho (dado por h^{daily}).

$$\begin{aligned}
& \sum_{t=t_1}^{t_2} \sum_{((i,t),(j,t+u_{ij})) \in \hat{A}_7^q} x_{ij}^{qt} u_{ij} \leq \\
& \left\{ \begin{array}{l} \hat{h}^{daily} \left(1 - z^q + \sum_{t=t_1}^{t_2} \sum_{((i,t),(j,t+u^r)) \in \hat{\mathcal{R}}_7^q} x_{ij}^{qt} \right), \text{ se } t_1 = \underline{\Delta}^q \\ \hat{h}^{daily} \left(1 + \sum_{t=t_1}^{t_2} \sum_{((i,t),(j,t+u^r)) \in \hat{\mathcal{R}}_7^q} x_{ij}^{qt} \right), \text{ caso contrário} \end{array} \right. \\
& q \in \mathcal{Q}, t_1, t_2 \in \mathcal{T}^q : t_1 < t_2
\end{aligned} \tag{3.16}$$

$$\begin{aligned}
& \sum_{t=t_1}^{t_2} \sum_{((i,t),(j,t+u_{ij})) \in \hat{A}_7^q} x_{ij}^{qt} u_{ij} \leq \\
& \left\{ \begin{array}{l} \hat{h}^{daily} \left(1 - z^q + \sum_{t=t_1}^{t_2} \sum_{((i,t),(j,t+u^r)) \in \hat{\mathcal{R}}_7^q} x_{ij}^{qt} \right) \\ \hat{h}^{daily} \left(1 + \sum_{t=t_1}^{t_2} \sum_{((i,t),(j,t+u^r)) \in \hat{\mathcal{R}}_7^q} x_{ij}^{qt} \right) \end{array} \right. \\
& q \in \mathcal{Q}, t_1, t_2 \in \mathcal{T}^q : t_1 + \hat{h}^{daily}(1 - z^q) < t_2 \leq t_1 + \lceil 48/\delta \rceil - u^r, \text{ se } t_1 = \underline{\Delta}^q \\
& q \in \mathcal{Q}, t_1, t_2 \in \mathcal{T}^q : t_1 + \hat{h}^{daily} < t_2 \leq t_1 + \lceil 48/\delta \rceil - u^r, \text{ caso contrário} \\
& n_{ij}^r = 1 + \lceil (\hat{\tau}_{i,j} - h^{daily}(1 - z^q) - \epsilon) / h^{daily} \rceil
\end{aligned} \tag{3.17}$$

$$\tag{3.18}$$

3.4 Experimentos Computacionais

Foram realizados experimentos computacionais para avaliar a performance do modelo matemático e das estratégias propostas. O algoritmo foi implementado utilizando-se Python 3.11, NetworkX 3.1 e Gurobi 10. Todos os experimentos foram realizados em um *cluster* com processador Intel Xeon, 2.10GHz (utilizando apenas 1 núcleo), 20GB de RAM e tempo máximo de otimização de 6 horas. Inicialmente, avaliou-se o desempenho do modelo e das metodologias propostas a partir de uma rede artificial com 25 nós. Posteriormente, utilizando-se as melhores estratégias computacionais, realizou-se dois estudos de casos para a localização de carregadores visando a eletrificação da frota para: i) distribuição da soja por estado e; ii) distribuição nacional da soja produzida na região Centro-Oeste.

3.4.1 Análise computacional em rede artificial

As instâncias foram baseadas na rede artificial de 25 nós (Figura 3.6) introduzida por SIMCHI-LEVI e BERMAN [119] e amplamente utilizada como rede de referência para problemas de localização de estações de recarga ou abastecimento (ver, por exemplo, YILDIZ *et al.* [116], WANG e ZHOU [120], LIU *et al.* [121]). Os valores apresentados próximos aos nós indicam seu número de identificação, enquanto os valores próximos aos arcos indicam seu peso. Para esta avaliação, os valores apresentados nos arcos foram adotados tanto como distância (em quilômetros) quanto tempo (em horas). As estatísticas da rede são apresentadas na Tabela 3.4.

Tabela 3.4: Estatísticas da rede artificial.

#Nós	#Arcos	Comprimento		
		Min.	Max.	Média
25	55	2	9	4,36

Como descrito anteriormente, a demanda $q \in \mathcal{Q}$ é definida por um vetor constituído de sete elementos $\langle o^q, d^q, f^q, e^q, a^q, \bar{r}^q, \underline{r}^q \rangle$. Para os dados de demanda, foram gerados 300 pares OD conectando unidirecionalmente todos os nós da rede de forma crescente, isto é, partindo de $(o^1, d^1) = (1, 2)$ até $(o^{300}, d^{300}) = (24, 25)$. Foram atribuídos valores aleatórios entre 4h e 12h para o período em que a carga fica disponível para transporte e^q . Para todos os pares OD, adotou-se o mesmo número de veículos em um fluxo ($f^q = 10$ veículos) e mesma autonomia operacional da bateria, equivalente a 9 km ($\underline{r}^q = 0$ km e $\bar{r}^q = 9$ km), equivalente ao comprimento máximo observado na rede (ver Tabela 3.4).

Sabe-se que os veículos a diesel possuem a flexibilidade para transitar no caminho com menor distância e/ou menor tempo de viagem. Além disso, o aumento da distância percorrida ou do tempo de viagem podem desmotivar a adoção de

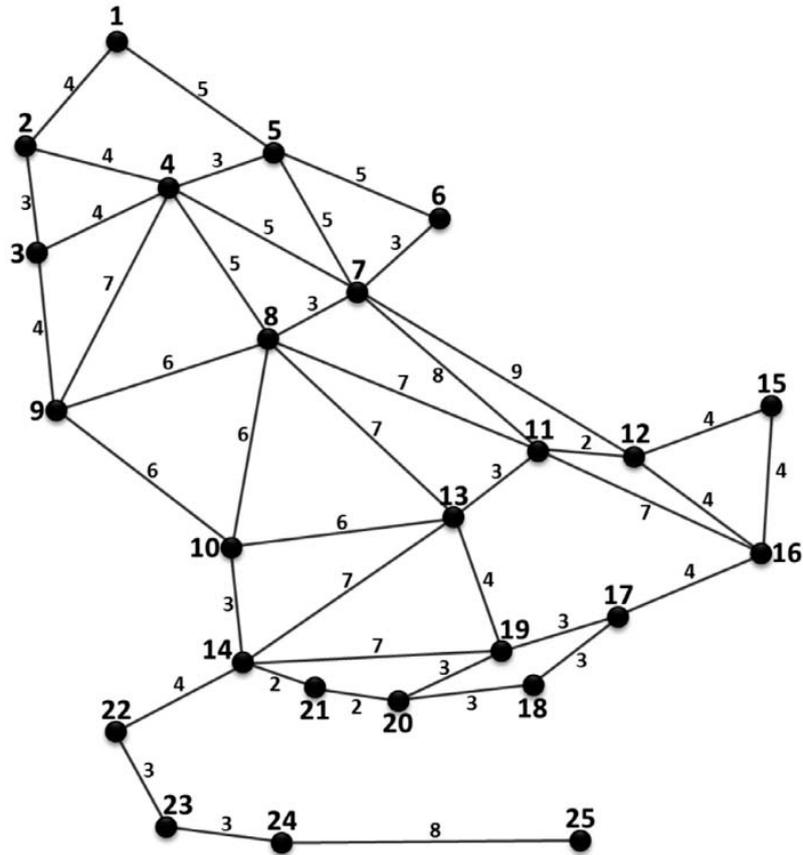


Figura 3.6: Rede de 25 nós utilizada nos experimentos computacionais.

veículos elétricos em substituição aos veículos à diesel. Portanto, para estimar o prazo máximo de entrega a^q , considerou-se que os veículos elétricos devem respeitar os menores tempos já praticados pelos caminhões a combustão, evitando-se, assim, o aumento da rota. Para isso, inicialmente identificou-se o caminho mínimo com menos quantidade de nós intermediários entre cada par OD a partir da rede de comunicação utilizando-se o NetworkX, uma biblioteca em Python para manipulação de redes. Como cada nó intermediário nesta rede indica a necessidade de paradas para descanso (longo ou rápido) e recarga, estimou-se, para cada demanda, o tempo mínimo necessário entre o par OD respeitando-se os limites impostos pela legislação de jornada de trabalho. Este valor, somado ao horário de partida, resultou no limite temporal de chegada da demanda no destino (a^q).

A Tabela 3.5 apresenta as estatísticas para os dados de entrada da demanda, onde as informações de distância de viagem refere-se à distância pelo caminho mínimo na rede de comunicação e o tempo de viagem é resultado do tempo de viagem no caminho mínimo acrescido dos tempos para atendimento da legislação de jornada de trabalho.

Visando permitir viabilidade entre todos os pares OD, adotou-se como número máximo de horas consecutivas de direção ($h^{driving}$) igual à 8 h, tornando possível

Tabela 3.5: Estatísticas da demanda.

#Pares OD	Distância de viagem			Tempo de viagem			Discretização		
	Min.	Max.	Média	Min.	Max.	Média	Min.	Max.	Média
300	2	38	14,27	2	59	19,70	4	118	39,39

incluir o nó 25 na análise. Para o número máximo de horas de direção acumuladas entre dois períodos de descanso longos (h^{daily}), adotou-se o valor de 14 h. As durações assumidas para a pausa curta (h^{break}) e para o descanso longo (h^{rest}) foram de 1 h e 8 h respectivamente. Por fim, admitiu-se que a duração total de descanso em um dia (entre dois períodos longos de descanso, $h^{totalrest}$) é de 10 h, sendo 8 h equivalente ao descanso inicial h^{rest} e as 2 h restantes a serem respeitadas ao longo do dia por meio da utilização de arcos de parada curta (conjunto $\hat{\mathcal{B}}_T^q$) ou de espera (conjunto $\hat{\mathcal{W}}_T^q$).

Para os custos fixos unitários de implantação dos carregadores, adotou-se os valores simbólicos de R\$ 5 e R\$ 8 para os carregadores de recarga lenta (p^{sc}) e rápida (p^{fc}) respectivamente. Já para os custos variáveis, adotou-se os seguintes valores simbólicos: R\$ 1 para o custo unitário de consumo da bateria (p^{cc}); R\$ 1 para o custo horário dos motoristas em operação (p^{hd}); R\$ 3 para o custo horário associado ao serviço de descanso rápido (c_{ij}^b); R\$ 6 para o custo horário associado ao serviço de descanso longo (c_{ij}^r) e; R\$ 1 para o custo horário associado ao serviço de espera (c_{ij}^w).

De acordo com a Lei nº 13.103 de 2015 (BRASIL [29]), ao trabalhar no turno noturno (das 22h às 5h), o salário do motorista aumenta em 20%. Portanto, os arcos da rede de comunicação espaço-temporal posicionados em horário compreendido neste intervalo tiveram o custo de mão de obra (p^{hd}) incrementado em 20%. Cabe destacar que, caso um arco possua operação em turno noturno e diurno, o custo é proporcionalmente ponderado. Como exemplo, vamos supor que um motorista inicie às 4 h a travessia de um arco de 2 h de extensão. Desta forma, o custo total de motorista para este arco será a soma de uma hora com aumento de 20% e uma hora com o valor regular, isto é, será equivalente à $1.2p^{hd} + p^{hd}$.

Conforme apresentado na Tabela 3.4, a rede de transporte \mathcal{G} adotada para esta etapa é constituída por 25 nós e 55 arcos. Posteriormente, foram construídas as Redes de Comunicação para cada demanda ($\hat{\mathcal{G}}^a$). Neste processo, buscou-se identificar e remover todos os arcos e nós que não constituíam soluções viáveis para o problema, o que resultou em redes com número de nós variando entre 2 e 16. A soma das informações das redes de comunicação para todas as demandas resultou em 1.570 nós e 2.775 arcos. As estatísticas para esta rede são apresentadas na Tabela 3.6.

Para cada demanda, realizou-se a discretização temporal das Redes de Comunicação a partir de dois processos. No primeiro, obteve-se a Redes de Comunicação-

Espaço-Temporal ($\hat{\mathcal{G}}_T^q$) completa. Já no segundo, obteve-se a Redes de Comunicação-Espaço-Temporal ($\hat{\mathcal{G}}_T^q$) reduzida a partir da aplicação da estratégia de gerenciamento de nós e arcos supérfluos. As estatísticas para estas duas redes são apresentadas na Tabela 3.7. Observa-se que a utilização da estratégia proposta para remover os nós supérfluos permitiu reduzir a quantidade de nós e arcos em aproximadamente 85% e 89% respectivamente. Essa redução impacta na quantidade de variáveis no modelo e, conseqüentemente, no custo computacional para resolver o problema.

Tabela 3.6: Estatísticas das Redes de Comunicação.

Estatística	Nós	Arcos
Mínimo	2	1
Máximo	16	59
Média	5,2	9,3
Total (300 demandas)	1.570	2.775

Tabela 3.7: Estatísticas das Redes de Comunicação-Espaço-Temporal sem e com a estratégia de gerenciamento de nós supérfluos.

Estatística	Sem estratégia		Com estratégia	
	Nós	Arcos	Nós	Arcos
Mínimo	6	5	2	1
Máximo	1.658	10.141	302	1.271
Média	262,8	992,3	38,1	110,3
Total (300 demandas)	78.840	297.683	11.430	33.088

Visando avaliar os impactos das estratégias de gerenciamento de nós e arcos supérfluos e da redução da quantidade de restrições no modelo, neste primeiro ciclo de resultados buscou-se solucionar o problema proposto com e sem estas estratégias. Cinco métodos de solução foram utilizados. O primeiro, denominado de “S”, consiste em solucionar o modelo utilizando-se o *solver* do Gurobi. O próximo método, denominado de “C”, considera as restrições (3.6)–(3.7) ou (3.12)–(3.13) como *lazy constraints*, inseridas manualmente no modelo através de *callbacks* quando violadas. Nos três métodos seguintes, estas restrições são também tratadas como *lazy constraints*, porém, inseridas através de estratégias internas do Gurobi. A diferença entre estes métodos está no processo de inserção das restrições no modelo: No método “G1”, a restrição pode ser usada para eliminar uma solução viável, mas não necessariamente que é incorporada caso outra restrição também elimina a solução; No método “G2”, todas as restrições que são violadas por uma solução viável são incorporadas no modelo; Por fim, no método “G3”, as restrições que eliminam a solução de relaxação no nó raiz também são incorporadas no modelo.

São apresentados, na Tabela 3.8, os resultados deste primeiro ciclo de análises. A primeira coluna apresenta o número de identificação de cada instância avaliada.

A segunda e terceira coluna indicam se foi utilizada (1) ou não (0) as estratégias de gerenciamento de nós e arcos supérfluos e de redução da quantidade de restrições respectivamente. Na quarta coluna é identificado o método utilizado para solucionar a instância. Nas quatro colunas seguintes, apresenta-se, respectivamente, os tempos dispendidos para a etapa de pré-processamento (desde a leitura das informações de entrada até a construções das redes de Comunicação–Espaço–Temporal), para a etapa de geração do modelo no Gurobi, o tempo de otimização (limitado em 21.600 s) e tempo total do processo. Como resultado, apresenta-se a solução encontrada, o valor de GAP e número de nós investigados nas colunas nove a onze respectivamente. Por fim, apresenta-se o motivo da interrupção do processo, que pode ser: “*Out of Memory*”, que indica ausência de memória suficiente para solucionar o modelo; “*Time Out*”, que sinaliza que o processo de otimização atingiu o tempo limite estabelecido, podendo ter uma solução ótima encontrada ou não, e; “*Optimality*”, quando uma solução ótima é encontrada.

Observa-se que não foi possível solucionar o modelo matemático quando nenhuma estratégia é aplicada (instâncias 0 a 4), sendo o principal motivo de interrupção o erro *Out of Memory*, resultante do elevado custo computacional para a construção e solução do modelo matemático. Apenas a instância 1 não resultou no erro de falta de memória por ter as restrições (3.6)–(3.7) tratadas como *lazy constraints*. Quando apenas a estratégia de redução da quantidade de restrições no modelo é considerada (instâncias 5 a 9), observou-se que houve exploração do espaço de busca. Porém, devido ao número exponencial de restrições, o tempo máximo de otimização foi atingido sem que uma solução fosse encontrada. Ao avaliar os resultados das instâncias 10 a 14, que consideram apenas a estratégia de gerenciamento de nós e arcos supérfluos, observou-se que a utilização desta estratégia permitiu encontrar a solução ótima para três das cinco instâncias avaliadas em tempo computacional variando entre 10.574s e 21.465s. Por fim, a análise dos resultados obtidos para as instâncias 15 a 19 indicou que a utilização conjunta das duas estratégias permitiu obter a solução ótima para as cinco instâncias em tempo computacional entre 6.177s e 11.847s, destacando-se a relevância do método apresentado.

Na sequência, avaliou-se o comportamento do modelo diante a flexibilização do tempo de chegada, considerando-se aumento no caminho mínimo (em 2%, 4%, 6%, 8%, 10%, 12% e 14%) e no orçamento disponível para a implantação dos carregadores elétricos (em 5%, 10%, 15%, 20%). Para todas as instâncias foram utilizadas as duas estratégias propostas na metodologia: gerenciamento de nós e arcos supérfluos e de redução da quantidade de restrições do modelo. Ao permitir maior tempo de entrega, novos arcos e nós são considerados na rede, exigindo maior custo computacional para a obtenção de soluções. A Tabela 3.9 apresenta a quantidade de nós e arcos na Rede de Comunicação e Rede de Comunicação–Espaço–Temporal.

Tabela 3.8: Resultados para as instâncias.

#	Instância		Tempo					Resultados				Motivo da interrupção	
	Ger. de nós e arcos superfluos	Redução da quantidade de restrições	Mét.	Pré-proc. (s)	Modelo (s)	Otimiz. (s)	Total (s)	Solução (R\$)	GAP	#Nós	#cuts		
0	0	0	S	9	9.203	-	9.212	-	-	-	-	-	Out of Memory
1	0	0	C	10	6.517	21.600	28.127	-	-	-	59.243	49.123	Time Out
2	0	0	G1	10	10.196	-	10.206	-	-	-	-	-	Out of Memory
3	0	0	G2	10	10.136	-	10.146	-	-	-	-	-	Out of Memory
4	0	0	G3	10	10.231	-	10.241	-	-	-	-	-	Out of Memory
5	0	1	S	10	6.063	21.601	27.674	-	-	-	2.868	-	Time Out
6	0	1	C	10	5.983	21.600	27.593	-	-	-	18.599	40.819	Time Out
7	0	1	G1	10	6.051	21.600	27.661	-	-	-	8.358	-	Time Out
8	0	1	G2	10	6.050	21.600	27.660	-	-	-	8.948	-	Time Out
9	0	1	G3	10	6.058	21.600	27.668	-	-	-	7.280	-	Time Out
10	1	0	S	7	625	9.942	10.574	10.716.80	1E-04	14.414	-	-	Optimality
11	1	0	C	7	588	11.867	12.462	10.716.80	1E-04	92.838	25.284	-	Optimality
12	1	0	G1	7	619	21.600	22.226	-	-	47.659	-	-	Time Out
13	1	0	G2	7	608	21.600	22.215	-	-	67.309	-	-	Time Out
14	1	0	G3	7	504	20.954	21.465	10.716.80	1E-04	48.459	-	-	Optimality
15	1	1	S	7	275	9.037	9.319	10.716.80	1E-04	23.337	-	-	Optimality
16	1	1	C	7	289	11.551	11.847	10.716.80	1E-04	137.883	27.181	-	Optimality
17	1	1	G1	7	309	8.047	8.363	10.716.80	1E-04	55.180	-	-	Optimality
18	1	1	G2	5	305	10.278	10.588	10.716.80	1E-04	115.868	-	-	Optimality
19	1	1	G3	7	307	5.863	6.177	10.716.80	1E-04	38.183	-	-	Optimality

- Significa que não foram obtidos valores.

Tabela 3.9: Quantidades de nós e arcos resultantes da flexibilização do tempo de chegada.

a^q	Rede de Comunicação		Rede de Comunicação-Espaço-Temporal	
	Nós	Arcos	Nós	Arcos
0%	1.570	2.775	11.430	33.088
2%	1.572	2.781	12.784	37.796
4%	1.680	3.251	15.093	47.238
6%	1.784	3.663	18.148	59.886
8%	1.815	3.813	19.976	67.656
10%	1.887	4.131	22.229	78.021
12%	1.932	4.361	24.346	87.487
14%	2.004	4.682	26.781	98.426

Para todas as instâncias, foram aplicados os cinco métodos de solução previamente apresentados (S, C, G1, G2, G3). No entanto, para a maioria das instâncias, foi possível obter a solução apenas utilizando-se as configurações padrões do *solver* (método “S”). A Tabela 3.10 e Tabela 3.11 apresentam, respectivamente, os resultados da função objetivo e de GAP obtidos para a análise de sensibilidade. Observa-se que o *solver* encontrou a solução ótima apenas para a linha de flexibilização do tempo de chegada igual a 0% (GAP de otimalidade usado pelo Gurobi é igual a 0,01%). Ao passo que o tamanho da rede expande, os valores de GAP obtidos também aumenta como consequência do maior tempo computacional necessário para resolver as instâncias. Cabe destacar que o tempo de otimização foi limitado em 21.600s.

Observou-se que o aumento do orçamento disponível permitiu redução nos custos operacionais. Este efeito é mais claro ao avaliar a linha sem considerar flexibilização do tempo de chegada (0%), para a qual foram obtidas soluções ótimas. Para os outros casos, deve-se ter em mente que foram obtidas soluções sub-ótimas, o que pode interferir nas análises já que os valores utilizados para solução do modelo são pouco relevantes.

Tabela 3.10: Resultados da análise de sensibilidade.

		Flexibilização do orçamento disponível (K)				
		0%	5%	10%	15%	20%
Flexibilização do tempo de chegada (a^q)	0%	10.716,80	10.711,89	10.709,89	10.709,40	10.708,99
	2%	10.714,60	10.712,79	10.710,69	10.709,40	10.708,99
	4%	-	10.715,50	10.713,10	10.710,39	10.713,69
	6%	10.731,40	10.720,19	10.714,30	10.712,79	10.713,29
	8%	10.777,60	10.720,29	10.724,20	10.728,10	10.716,49
	10%	-	10.738,50	10.740,50	-	10.726,59
	12%	-	-	10.725,80	10.783,49	10.755,70
	14%	-	-	-	-	-

Tabela 3.11: Valores de GAPs obtidos na análise de sensibilidade.

		Flexibilização do orçamento disponível (K)				
		0%	5%	10%	15%	20%
Flexibilização do tempo de chegada (a^t)	0%	0,01%	0,01%	0,01%	0,01%	0,01%
	2%	0,26%	0,26%	0,35%	0,15%	0,16%
	4%	-	0,31%	0,29%	0,24%	0,31%
	6%	0,62%	0,50%	0,45%	0,46%	0,43%
	8%	1,11%	0,55%	0,58%	0,63%	0,49%
	10%	-	0,75%	0,81%	-	0,63%
	12%	-	-	0,70%	1,26%	0,99%
	14%	-	-	-	-	-

3.4.2 Estudo de caso: distribuição estadual de soja

Neste estudo de caso, o modelo proposto ao PLCR-JTM foi aplicado visando avaliar, para cada estado brasileiro, a localização de carregadores para a eletrificação da frota de distribuição estadual da soja. Além da avaliação logística, este estudo de caso permite também avaliar o comportamento do modelo quando aplicado à instâncias reais compostas tanto por diferentes conjuntos de demanda quanto redes com variadas quantidades de nós e arcos.

Para isto, a partir da base georreferenciadas de soja para o ano de 2031 do PNLT (MT [1]), foram geradas as matrizes de produção e consumo de soja, o que permitiu elencar treze estados brasileiros com produção e consumo internos desta *commodity*: Bahia (BA), Goiás acrescido do Distrito Federal (GO+DF), Maranhão (MA), Minas Gerais (MG), Mato Grosso do Sul (MS), Mato Grosso (MT), Piauí (PI), Paraná (PR), Rondônia (RO), Rio Grande do Sul (RS), Santa Catarina (SC), São Paulo (SP) e Tocantins (TO). As informações de demanda são apresentadas na Tabela 3.12. Na primeira e segunda colunas, apresenta-se as informações do estado a qual a instância faz referência. Já as quantidades totais de pares OD e o volume de soja transportado estão dispostos, respectivamente, na terceira e quarta colunas. No entanto, dentre estes pares OD selecionados, necessita-se elencar apenas os deslocamentos que necessitam de descanso e recarga da bateria.

Os valores adotados para os parâmetros referentes à regulação de jornada de trabalho dos motoristas basearam-se na legislação brasileira, conforme apresentado na Tabela 3.1, sendo h^{break} o único diferente, uma vez que foi adotada a duração mínima de 1 hora, já que a discretização temporal adotada foi de 30 minutos ($\delta = 0,5$). Já para a capacidade de transporte dos caminhões e autonomia da bateria, adotou-se, respectivamente, os valores de 30 toneladas e 350 km (valor de autonomia reportado por AL-HANAHI *et al.* [122]).

A partir destas informações, executou-se um programa, desenvolvido em linguagem GISDK e integrado ao TransCAD, capaz de calcular as matrizes de caminhos

mínimos para cada demanda, considerando-se o tempo de viagem na minimização. Obteve-se, assim, o tempo e a distância de deslocamento entre cada par OD. Os deslocamentos com tempo de viagem superior a 5,5 h ou com distância superior a 350 km, isto é, que requerem descanso e/ou carregamento, foram selecionados como demanda para aplicação. A quantidade de pares OD que constituem o conjunto de demanda \mathcal{Q} para avaliação, o volume total de soja e a frota são apresentados na quinta, sexta e sétima colunas da Tabela 3.12. Observa-se que a instância RO possui apenas um único par OD que não foi selecionado para a avaliação. Como consequência, esta instância foi excluída da análise, restando doze instâncias para as próximas etapas.

Tabela 3.12: Informações das bases de demanda.

Sigla	Unidade Federativa	Demanda Total		Demanda Longa Distância		
		#Pares OD	Volume 10^3 ton.	#Pares OD	Volume 10^3 ton.	Frota
BA	Bahia	2	8,7	2	–	–
DF+GO	Distrito Federal e Goiás	126	857,2	72	184,2	6.163
MA	Maranhão	7	138,3	4	80,0	2.667
MG	Minas Gerais	25	367,7	18	83,5	2.787
MS	Mato Grosso do Sul	34	489,3	18	180,6	6.026
MT	Mato Grosso	102	4.988,9	81	4.014,5	133.840
PI	Piauí	3	2,3	1	0,3	12
PR	Paraná	433	4.130,5	187	1.139,9	38.055
RO	Rondônia	1	8,6	0	–	–
RS	Rio Grande do Sul	310	3.798,2	108	1.528,6	50.992
SC	Santa Catarina	31	164,7	7	19,4	650
SP	São Paulo	123	223,5	34	30,2	1.021
TO	Tocantins	14	63,2	8	18,7	1.368

A rede de transporte teve origem na rede multimodal do PNLT (apresentada na Figura 2.13), porém selecionando-se apenas as vias destinadas ao modo rodoviário. As informações estatísticas de cada rede são dispostas na Tabela 3.13. Na primeira coluna, apresenta-se a sigla da instância. Na segunda e terceira colunas estão descritas, respectivamente, as quantidades de nós e arcos presentes em cada rede de transporte. Na sequência, tem-se as estatísticas de distância (quarta a sexta colunas) e tempo (sétima a nona colunas) dos arcos.

Para os custos fixos unitários de implantação dos carregadores de recarga lenta (p^{sc}) e rápida (p^{fc}), adotou-se, respectivamente, os valores de R\$ 361.000 e R\$ 1.126.000. Estes valores foram adaptados de DAVATGARI *et al.* [25], que apresentou os custos de \$73.000 e \$228.000, respectivamente, e que foram convertidos para o real utilizando-se o valor de R\$4,94 para o câmbio do dólar (média para o

Tabela 3.13: Estatísticas das redes de transportes.

UF	#Nós	#Arcos	Distância (km)			Tempo (minutos)		
			min.	max.	média	min.	max.	média
BA	736	2.348	1	168	27	1	221	22
DF+GO	115	306	3	237	60	2	153	39
MA	59	132	4	241	80	3	163	51
MG	633	1.896	1	254	30	1	191	19
MS	71	184	3	226	71	2	170	46
MT	106	289	6	285	100	4	296	73
PI	63	148	3	207	75	2	150	54
PR	246	716	1	137	28	1	91	17
RS	425	1.278	1	163	24	1	103	16
SC	157	436	2	98	27	1	127	21
SP	1.095	3.485	1	82	14	1	52	8
TO	65	178	3	197	63	2	123	41

período compreendido entre 04/10/2023 a 04/03/2024 – INVESTING.COM [97]).

Para o custo horário dos motoristas em operação (p^{hd}), adotou-se o valor de R\$ 15 por hora trabalhada (adaptado de MAYERLE *et al.* [27]). Já para os custos associados ao serviço de espera (c_{ij}^w), descanso rápido (c_{ij}^b) e descanso longo (c_{ij}^r), adotou-se, respectivamente, os valores de R\$ 15, R\$ 30 e R\$ 60 por serviço utilizado. Já para o custo unitário de consumo de bateria (p^{cc}), adotou-se o valor de R\$ 1 por quilômetro rodado. Cabe destacar que os parâmetros de entrada aqui adotados são apenas para fins de pesquisa e avaliação do modelo. Para aplicações visando a real implantação da rede de carregamento, os valores devem ser reavaliados conforme necessidade.

A partir da rede de transporte \mathcal{G} de cada estado (Tabela 3.13), foram construídas as Redes de Comunicação ($\hat{\mathcal{G}}^q$) e Redes de Comunicação–Espaço–Temporal ($\hat{\mathcal{G}}_{\mathcal{T}}^q$) para cada par OD. Neste último processo de transformação, aplicou-se também a estratégia de pré-processamento para gerenciamento de nós e arcos supérfluos, uma vez que foi constatado que a aplicação destes métodos favorecem a solução do modelo matemático proposto, conforme discutido na seção anterior.

São apresentados, na Tabela 3.14, as estatísticas de nós e arcos da rede inicial (\mathcal{G}) e das redes transformadas ($\hat{\mathcal{G}}^q$ e $\hat{\mathcal{G}}_{\mathcal{T}}^q$) para cada instância. Adicionalmente, são também apresentadas a quantidade total de pontos temporais presentes na discretização (sexta coluna) e as reduções, em valor percentual, das quantidades de nós (décima coluna) e arcos (décima segunda coluna) decorrentes da aplicação da estratégia de gerenciamento de nós supérfluos.

Tabela 3.14: Estatísticas das redes iniciais e transformadas para cada instância.

UF	#Pares OD	Rede de Transportes \mathcal{G}		Rede de Comunicação $\hat{\mathcal{G}}^q$		Pontos de Discretização temporal		Rede de Comunicação-Espaço-Temporal $\hat{\mathcal{G}}_T^q$				
		#Nós	#Arcos	#Nós	#Arcos	#Nós	#Arcos	Redução (%)	#Arcos	Redução (%)		
BA	2	736	2.348	-	-	-	-	-	-	-		
DF+GO	126	115	306	2.217	49.283	2.468	72.724	1.918.613	21.358	-71	423.462	-78
MA	7	59	132	103	1.474	177	5.133	96.052	1.464	-71	19.479	-80
MG	25	633	1.896	-	-	-	-	-	-	-	-	-
MS	34	71	184	396	4.315	592	9.728	138.108	2.919	-70	37.197	-73
MT	102	106	289	2.257	32.520	3.517	126.033	2.216.176	35.046	-72	459.933	-79
PI	3	63	148	20	96	55	536	4.027	223	-58	1.581	-61
PR	433	246	716	-	-	-	-	-	-	-	-	-
RS	310	425	1.278	-	-	-	-	-	-	-	-	-
SC	31	157	436	789	36.770	534	26.205	1.358.854	7.386	-72	255.141	-81
SP	123	1.095	3.485	-	-	-	-	-	-	-	-	-
TO	14	65	178	243	4.756	324	9.950	245.173	3.048	-69	55.329	-77

- indica que não foi possível construir a rede.

Devido a limitação de *hardware* imposta para solução do problema, não foi possível construir as redes de comunicação para as instâncias BA, MG, PR, RS e SP. Cabe ressaltar que a quantidade de arcos presentes nas redes transformadas dependem não só da quantidade de arcos iniciais da rede de transportes \mathcal{G} , mas também da quantidade de pares OD presentes em \mathcal{Q} e o comprimento das viagens.

Observa-se que as redes de Comunicação–Espaço–Temporal poderiam possuir de 4.027 a 2.216.176 arcos. Contudo, a partir da aplicação da estratégia de gerenciamento de nós supérfluos, foi possível obter redes com até 72% menos nós e até 81% menos arcos, impactando significativamente no tamanho do modelo matemático e, conseqüentemente, no consumo computacional. Como resultado, obteve-se redes com quantidades de arcos variando entre 1.581 (instância PI) a 459.933 (instância MT) para aplicação e avaliação do desempenho do modelo.

Apesar de ter sido possível a construção das redes discretizadas para a instância MT, esta retornou o erro de falta de memória ("out of memory") durante a construção do modelo no Gurobi. Destaca-se que estas limitações decorrem, principalmente, das restrições computacionais impostas, principalmente quanto ao limite da memória RAM. Essa instância, juntamente com as instâncias que não puderam ter as redes transformadas obtidas (BA, MG, PR, RS e SP), foram retiradas das análises, restando-se as seguintes instâncias: DF+GO, MA, MS, PI, SC, TO.

Para a aplicação do modelo para estas instâncias, utilizou-se, como valor de orçamento disponível para a implantação dos carregadores (K), o mínimo montante necessário para a viabilização da operação, sendo: R\$ 3.675.795.000 para DF+GO; R\$ 2.883.110.000 para MA; R\$ 5.161.370.000 para MS; R\$ 4.332.000 para PI; R\$ 257.696.000 para SC; e R\$ 701.100.000 para TO.

Todas as análises foram executadas utilizando-se as estratégias de redução do tamanho do modelo (redução da quantidade de restrições e gerenciamento de nós e arcos supérfluos), uma vez que foi comprovada a importância do método a partir da análise dos resultados para a rede fictícia de 25 nós. Além disso, resolveu-se cada instância utilizando-se os cinco métodos de otimização anteriormente apresentados: utilizando-se o modelo completo e o solver do Gurobi (método "S") e considerando-se as restrições (3.12)–(3.13) como *lazy constraints*, inseridas manualmente através de *callbacks* quando violadas (método "C") ou inseridas através de estratégias internas do Gurobi (métodos "G1", "G2" e "G3").

Os resultados são apresentados na Tabela 3.15. A instância é apresentada na primeira coluna. Na segunda coluna é identificado o método utilizado para solucionar a instância. Nas quatro colunas seguintes, detalha-se, respectivamente, os tempos dispendidos para a etapa de pré-processamento (desde a leitura das informações de entrada até a construções das redes de Comunicação–Espaço–Temporal), para a etapa de construção do modelo no Gurobi, o tempo de otimização do *solver*

(limitado em 21.600 s) e o tempo total do processo. Como resultado, apresenta-se, respectivamente nas duas últimas colunas, a solução encontrada para a Função Objetivo e o motivo da interrupção do processo, que pode ser: “*Out of Memory*”, que indica ausência de memória suficiente para solucionar o modelo; “*Time Out*”, que sinaliza que o processo de otimização atingiu o tempo limite estabelecido, podendo ter uma solução ótima encontrada ou não, e; “*Optimality*”, quando uma solução ótima é encontrada.

A solução ótima foi obtida para quase todas as instâncias, sendo a instância DF+GO a única exceção. Nesta, o tempo limite de otimização (21.600 s) foi atingido sem ser obtida nenhuma solução viável ao problema. Para cada instância, destacou-se em negrito o tempo da sexta coluna do método que foi capaz de retornar uma solução ótima em menor tempo computacional. Observou-se, ainda, que não houve um padrão de desempenho suficiente para destacar um único método, sendo a performance de cada método dependente da instância.

Foram calculadas as estatísticas da quantidade necessária de carregadores rápidos e lentos em cada instância, conforme apresentado na Tabela 3.16. Na primeira coluna, é apresentada a instância em referência ao estado analisado. Na sequência, apresenta-se as informações de localização dos carregadores rápidos, que coincidem com as paradas para descanso curto: na segunda coluna, apresenta-se a quantidade de nós da rede que foram selecionados para a localização destes carregadores; na terceira e quarta colunas são exibidas as estatísticas de quantidade mínima e máxima observadas; na quinta coluna, é apresentado o total de carregadores rápidos localizados na rede. Similarmente ao apresentado para os carregadores rápidos, detalha-se, nas colunas sexta a nona, as mesmas informações para os carregadores lentos, que coincidem com as paradas para descanso longo.

A análise da eletrificação da rede logística de longa distância para as instâncias avaliadas indicou a necessidade de quantidade total de carregadores variando de 12 (instância PI) a 5.270 (instância MS). A quantidade de carregadores com rápido carregamento variou de 91 (instância SC) a 4.260 (instância MS), enquanto os de lento carregamento variou de 12 (instância PI) a 1.010 (instância MS). Observa-se que não foram selecionados carregadores rápidos para a instância PI. Para todas as instâncias, o valor disponibilizado para orçamento foi utilizado em 100%.

É apresentado, na Figura 3.7, os mapas de cada estado avaliado com o resultado da localização ótima dos carregadores de rápido e lento carregamento a partir dos valores estudados. A partir das informações dos nós selecionados para a localização dos carregadores e sabendo-se que o tipo de carregador está associado à necessidade do motorista naquele nó, os resultados do modelo podem, ainda, orientar o planejamento de infraestruturas de carregamento e descanso de acordo com as necessidades dos motoristas.

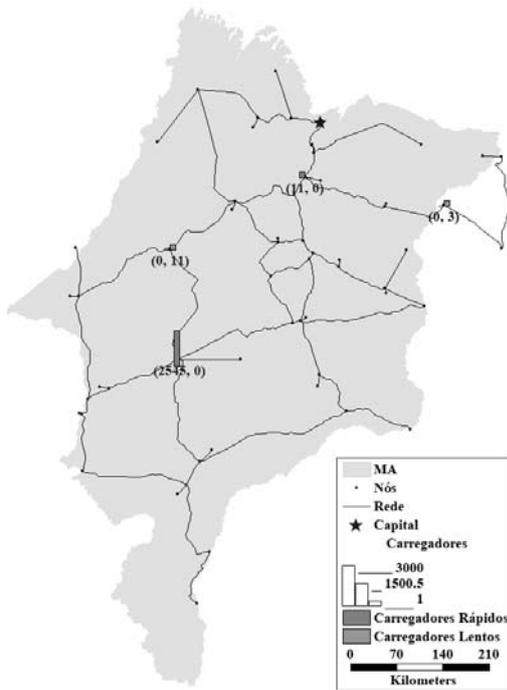
Tabela 3.15: Resultados para as instâncias por estado.

Inst.	Método	Tempo (s)				Resultados	
		Pré-proc	Modelo	Otimiz.	Total	FO	Motivo Interrupção
DF+GO	S	543	717	21.600	22.860	–	Time Out
	C	702	915	21.600	23.217	–	Time Out
	G1	702	1.014	21.600	23.316	–	Time Out
	G2	704	1.025	21.600	23.329	–	Time Out
	G3	702	1.029	21.600	23.331	–	Time Out
MA	S	5	38	4.216	4.259	4.463,00	Optimality
	C	4	60	18.167	18.231	4.463,00	Optimality
	G1	4	38	7.377	7.419	4.463,00	Optimality
	G2	4	42	2.486	2.532	4.463,00	Optimality
	G3	5	47	5.975	6.027	4.463,00	Optimality
MS	S	31	26	1.517	1.574	14.673,00	Optimality
	C	31	21	6.997	7.049	14.673,00	Optimality
	G1	29	23	6.092	6.144	14.673,00	Optimality
	G2	29	22	3.956	4.007	14.673,00	Optimality
	G3	29	22	2.144	2.195	14.673,00	Optimality
PI	S	2	1	0	3	1.014,00	Optimality
	C	3	1	3	7	1.014,00	Optimality
	G1	1	1	0	2	1.014,00	Optimality
	G2	1	1	0	2	1.014,00	Optimality
	G3	3	1	0	4	1.014,00	Optimality
SC	S	655	203	2.010	2.868	6.538,00	Optimality
	C	654	165	11.939	12.758	6.538,00	Optimality
	G1	768	232	1.690	2.690	6.538,00	Optimality
	G2	748	249	2.017	3.014	6.538,00	Optimality
	G3	748	250	2.147	3.145	6.538,00	Optimality
TO	S	16	98	1.641	1.755	7.224,00	Optimality
	C	16	74	9.867	9.957	7.224,00	Optimality
	G1	16	95	2.688	2.799	7.224,00	Optimality
	G2	19	120	3.535	3.674	7.224,00	Optimality
	G3	16	102	2.832	2.950	7.224,00	Optimality

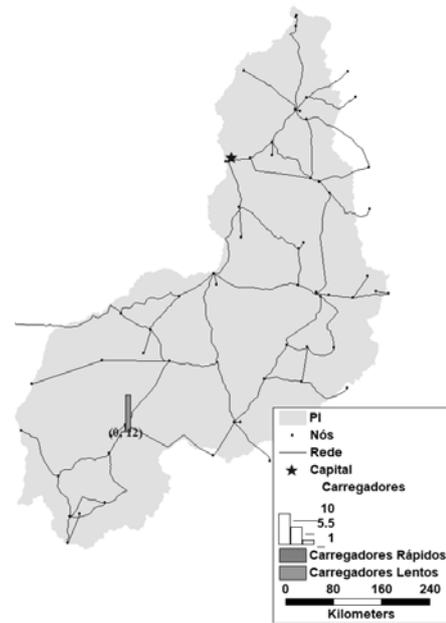
– Indica que nenhuma solução foi encontrada.

Tabela 3.16: Resultados da localização de carregadores para as instâncias por estado.

Instância	Carregador Rápido				Carregador Lento				Total geral
	#Nós	Min.	Max.	Total	#Nós	Min.	Max.	Total	
MA	2	11	2.545	2.556	2	3	11	14	2.570
MS	5	3	2.803	4.260	2	407	603	1.010	5.270
PI	0	0	0	0	1	12	12	12	12
SC	1	91	91	91	1	430	430	430	521
TO	3	171	171	513	2	171	171	342	855



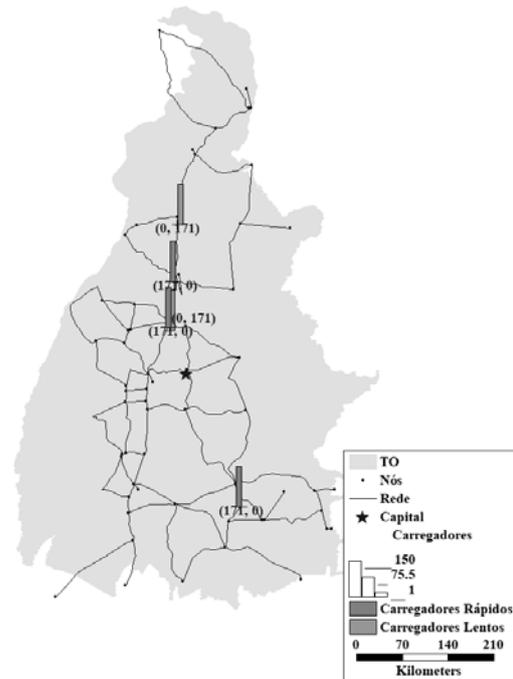
(a) Instância MA



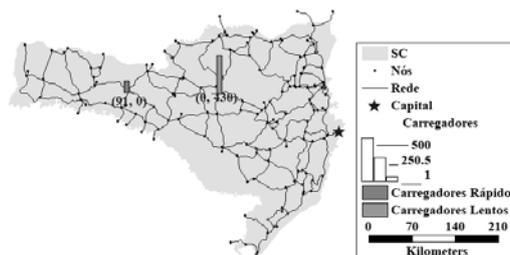
(b) Instância PI



(c) Instância MS



(d) Instância TO



(e) Instância SC

Figura 3.7: Resultado da localização geográfica dos carregadores.

3.4.3 Estudo de caso: distribuição nacional da soja produzida em cada estado do Centro-Oeste

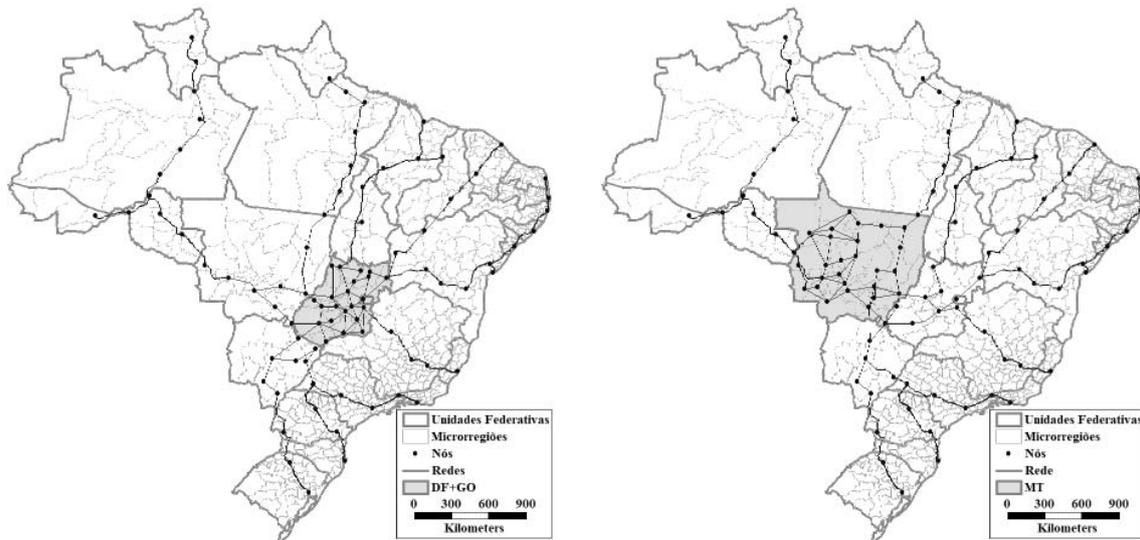
Tendo em vista que o Centro-Oeste é a região brasileira com maior produção de soja (ver Tabela 2.6), neste estudo de caso, objetiva-se avaliar a infraestrutura necessária para a eletrificação dos veículos que atuam no escoamento nacional da soja produzida nesta região, mantendo-se as restrições impostas no modelo proposto. Devido às limitações de hardware, que resultam na necessidade de redução das dimensões das instâncias avaliadas, foram elaboradas três instâncias para avaliação, sendo uma para cada estado do CO: Mato Grosso (MT_BR), Mato Grosso do Sul (MS_BR) e Goiás acrescido do Distrito Federal (DF+GO_BR).

A partir da base georreferenciada de soja para o ano de 2031 do PNLT (MT [1]), elaborou-se, para cada um dos três estados selecionados, a matriz de soja com produção no estado e destino para todo o país (incluindo o estado de origem). No entanto, as matrizes foram geradas considerando-se uma *cordon line* para cada estado. Desta forma, a unidade federativa em análise possui pontos de produção e consumo de acordo com as microrregiões do PNLT, enquanto as demais UFs possuem apenas um centroide coincidente com sua Capital. Além disso, adotou-se os pares de demanda com frota de tamanho igual ou superior a 10 veículo. As informações de demanda são apresentadas na Tabela 3.17. Na primeira e segunda colunas, apresenta-se as informações do estado a qual a instância faz referência. Já as quantidades totais de pares OD e o volume de soja transportado estão dispostos, respectivamente, na terceira e quarta colunas. Como realizado no estudo de caso anterior, elencou-se apenas os deslocamentos que necessitam de descanso e recarga da bateria.

Utilizou-se, aqui, os mesmos parâmetros de custos, jornada de trabalho dos motoristas e de autonomia dos veículos. Os deslocamentos com tempo de viagem superior a 5,5 h ou com distância superior a 350 km, isto é, que requerem descanso e/ou carregamento, foram selecionados como demanda para aplicação. A quantidade de pares OD que constituem o conjunto de demanda \mathcal{Q} para avaliação, o volume total de soja e a frota são apresentados na quinta, sexta e sétima colunas da Tabela 3.17.

Tabela 3.17: Informações das bases de demanda.

Sigla	Unidade Federativa	Demanda Total		Demanda Longa Distância		
		#Pares OD	Volume 10 ³ ton.	#Pares OD	Volume 10 ³ ton.	Frota
DF+GO_BR	Distrito Federal e Goiás	250	3.144,7	150	2.452,0	81.778
MT_BR	Mato Grosso	274	11.801,6	226	10.908,6	363.692
MS_BR	Matop Grosso do Sul	94	2.589,2	69	2.278,3	75.964



(a) Instância DF+GO_BR

(b) Instância MT_BR



(c) Instância MS_BR

Figura 3.8: Resultado da simplificação da rede viária considerando-se uma *cordon line* para cada estado.

A rede de transporte teve origem na rede multimodal do PNLT (apresentada na Figura 2.13), selecionando-se apenas as vias destinadas ao modo rodoviário. Visando reduzir a quantidade de arcos e nós na rede, foi gerada, para cada instância, uma rede simplificada unindo-se as vias com pequenas dimensões e mantendo-se apenas as principais ligações com as capitais das demais Unidades Federativas (considerando-se uma *cordon line* para cada estado, conforme apresentado para a demanda). As redes viárias resultantes deste processo são apresentadas na Figura 3.8.

As informações estatísticas de cada rede são dispostas na Tabela 3.18. Na primeira coluna, apresenta-se a sigla da instância. Na segunda e terceira colunas estão descritas, respectivamente, as quantidades de nós e arcos presentes em cada rede de transporte. Na sequência, tem-se as estatísticas de distância (quarta a sexta

colunas) e tempo (sétima a nona colunas) dos arcos.

Tabela 3.18: Estatísticas das redes de transportes \mathcal{G} .

Inst.	#Nós	#Arcos	Distância (km)			Tempo (minutos)		
			min.	max.	média	min.	max.	média
DF+GO_BR	92	220	6	350	227	4	210	136
MT_BR	96	234	75	350	237	45	210	142
MS_BR	85	190	88	350	251	53	210	151

A partir da rede de transporte \mathcal{G} de cada instância, apresentadas na Tabela 3.18, foram construídas as Redes de Comunicação ($\hat{\mathcal{G}}^q$) e Redes de Comunicação–Espaço–Temporal ($\hat{\mathcal{G}}_{\mathcal{T}}^q$) para cada par OD, conforme apresentado na Tabela 3.19. Adicionalmente, apresenta-se a quantidade total de pontos temporais presentes na discretização (quarta coluna). Os valores para a rede de Comunicação–Espaço–Temporal considera a aplicação da estratégia de gerenciamento de nós supérfluos.

Tabela 3.19: Estatísticas das redes iniciais e transformadas para cada instância.

Inst.	Rede de Comunicação $\hat{\mathcal{G}}^q$		Pontos de Discretização temporal	Rede de Comunicação–Espaço–Temporal $\hat{\mathcal{G}}_{\mathcal{T}}^q$	
	#Nós	#Arcos		#Nós	#Arcos
	DF+GO_BR	2.424	12.990	9.511	40.052
MT_BR	3.435	11.473	16.137	59.380	263.707
MS_BR	596	1.344	3.514	6.903	22.735

Para a aplicação do modelo, utilizou-se, como orçamento disponível para a implantação dos carregadores (K), os seguintes valores obtidos a partir de uma estimativa relaxada do problema (pelo método que embasou o Algoritmo 11): R\$ 150 bi para as instâncias DF+GO_BR e MS_BR e de R\$ 550 bi para a instância MT_BR.

Os resultados são apresentados na Tabela 3.20. A instância é apresentada na primeira coluna. Na segunda coluna é identificado o método utilizado para solucionar a instância. Nas quatro colunas seguintes, detalha-se, respectivamente, os tempos dispendidos para a etapa de pré-processamento (desde a leitura das informações de entrada até a construções das redes de Comunicação–Espaço–Temporal), para a etapa de construção do modelo no Gurobi, o tempo de otimização do solver (limitado em 21.600 s) e o tempo total do processo. Como resultado, apresenta-se, respectivamente nas três últimas colunas, a solução encontrada para a Função Objetivo, o valor de GAP retornado pelo Gurobi e o motivo da interrupção do processo, que pode ser: “*Out of Memory*”, que indica ausência de memória suficiente para solucionar o modelo; “*Time Out*”, que sinaliza que o processo de otimização atingiu o tempo limite estabelecido, podendo ter uma solução ótima encontrada ou não, e; “*Optimality*”, quando uma solução ótima é encontrada.

Observa-se que não foi possível obter soluções para as instâncias DF+GO_BR e MT_BR. No caso da primeira instância, verifica-se que único método que permitiu o modelo de ser construído foi o método “C”. Isto ocorre pois, nesse método, as restrições que utiliza *Callback* para adicionar as restrições (3.12)–(3.13) não são inseridas diretamente no modelo, pois são tratadas como *lazy constraints* e são adicionadas através de *callbacks* apenas quando violadas, liberando memória durante a construção do modelo. Por outro lado, foi possível obter boas soluções para a instância MS_BR por meio dos métodos “S” (valor de GAP de 0,04%) e “G2” e “G3” (GAP de aproximadamente 0,2%). Cabe destacar que o Gurobi é configurado com o valor de 0,01% para o limite de otimalidade.

Tabela 3.20: Resultados para a instância de distribuição nacional da soja produzida em cada estado do Centro-Oeste.

Instan.	Método	Tempo (s)				Resultados		
		Pre-Proces.	Mod.	Otimiz.	Total	Solução	GAP (%)	Motivo da Interrupção
DF+GO_BR	S	471	4.889	–	5.360	–	–	Out of Memory
	C	552	3.998	21.600	26.150	–	–	Time Out
	G1	551	4.201	–	4.752	–	–	Out of Memory
	G2	477	5.407	–	5.884	–	–	Out of Memory
	G3	550	4.433	–	4.983	–	–	Out of Memory
MT_BR	S	878	7.626	–	8.504	–	–	Out of Memory
	C	886	7.627	–	8.513	–	–	Out of Memory
	G1	833	7.431	–	8.264	–	–	Out of Memory
	G2	835	7.592	–	8.427	–	–	Out of Memory
	G3	852	7.766	–	8.618	–	–	Out of Memory
MS_BR	S	153	100	21.602	21.855	121.259,71	0,04	Time Out
	C	152	91	21.600	21.843	–	–	Time Out
	G1	147	95	21.600	21.842	–	–	Time Out
	G2	148	96	21.600	21.844	121.259,71	0,18	Time Out
	G3	148	99	21.600	21.847	121.259,71	0,21	Time Out

– Indica que nenhuma solução foi encontrada.

Ao avaliar os registros de saída do processo de otimização exportados pelo Gurobi, observou-se que, para estas instâncias, o erro “*Out of Memory*” ocorria após a construção do modelo, no início do processo de otimização. Visando contornar este problema, buscou-se gerar uma solução inicial viável através de um procedimento heurístico construtivo para ser inserida no Gurobi como solução inicial do processo de otimização. O algoritmo construtivo proposto é apresentado no Algoritmo 11 e descrito a seguir.

A partir do conjunto de vetores de demanda e os parâmetros da JTM, o algoritmo tem início com a geração dos dicionários das variáveis do problema (x_{ij}^{qt} , y_{it}^s e y_{it}^f). Neste momento, as informações de carregadores são armazenadas para cada tempo, pois ao final, necessita-se saber a quantidade de carregadores necessárias

para recarga simultânea dos veículos. Na sequência, parte para o processo iterativo e construtivo, no qual é gerada uma solução para cada demanda $q \in \mathcal{Q}$ até a construção da solução inicial completa. De forma geral, o processo iterativo aplicado a cada demanda busca verificar, dado um arco (i, j) a ser visitado, se a frota deve efetuar parada para descanso longo ou rápido ou se não há necessidade de parada antes de trafegar pelo arco de forma que não sejam violadas as restrições de autonomia do veículo e das diretrizes de JTM.

Para cada demanda a ser avaliada, inicia-se os seguintes parâmetros com valor zero: t , que indica o tempo acumulado de viagem, em intervalos de discretização, para definição do índice $t \in \mathcal{T}$; $distBeforeBreak$, indica a distância acumulada percorrida pelo veículo sem recarregar a bateria (controle das restrições de autonomia veicular); $timeBeforeBreak$, que indica a quantidade de horas dirigidas desde o último descanso rápido ou longo (controle das restrições de horas consecutivas em direção, $\hat{h}^{driving}$); $timeBeforeRest$, que indica a quantidade de horas dirigidas desde o último descanso longo (controle das restrições de horas diárias em direção, \hat{h}^{daily}); $nBreak$, $nRest$ e $nWait$, que indicam, respectivamente, a quantidade de descansos rápidos, de descansos longos e em espera realizados. Inicia-se, ainda, a variável $extraBreak$ para monitorar se todos os descansos diários que o motorista tem direito estão sendo cumpridos. Portanto, esta última é iniciada com o valor de $\hat{h}^{totalrest} - u^r$, que simboliza o tempo de descanso extra que o motoristas deve efetuar ao longo do dia reduzindo-se o primeiro descanso longo.

A próxima etapa consiste em, por meio da biblioteca do NetworkX, elencar o menor caminho (ponderando-se o tempo) conectando o par OD (o^q, d^q) a partir da rede de Comunicação $\hat{\mathcal{G}}^q$ (linha 7). Uma vez que cada nó visitado nesta rede significa obrigatoriamente uma parada, caso exista mais de um caminho com o mesmo valor de tempo mínimo, seleciona-se aquele com menor quantidade de nós visitado, isto é, menor quantidade de paradas (linha 8). Este processo não garante o caminho com menor tempo total de viagem, uma vez que o tempo dispendido nos nós depende do tipo de descanso a ser executado. No entanto, como explicado anteriormente, este algoritmo avalia se o veículo de fato necessita realizar uma parada.

A partir da lista de nós a serem visitados ($path$), do horário de partida (e^q) e volume da frota (f^q), inicia-se o processo construtivo da solução para a demanda em análise. Para cada arco (i, j) presente em $path$ (linha 9), é verificado se, ao atravessar este arco, a restrição de horas dirigidas no dia é violada (linha 10 e 11). Caso positivo, significa que o motorista deve realizar um descanso longo em i , reiniciando os parâmetros $timeBeforeRest$, $timeBeforeBreak$ e $distBeforeBreak$. Então, ao avançar para j , estes parâmetros de controle recebem as informações de distância e tempo do arco (i, j) (linhas 12, 13 e 14) e um descanso longo é adicionado ao contador $nRest$ (linha 15). Além disso, antes do descanso longo,

caso o motorista tenha saldo temporal remanescente de descansos que devem ser tirados ao longo do dia, são alocados arcos de espera $((i, t), (i, t + 1)) \in \hat{\mathcal{W}}_{\mathcal{T}}^q$ para complementar e tornar a solução viável, para então recomeçar um novo ciclo (linhas 16 a 20). Na sequência, atualiza-se as variáveis x_{ij}^{qt} para o arco de descanso longo $((i, t), (i, t + u^r)) \in \hat{\mathcal{R}}_{\mathcal{T}}^q$ utilizado e para a o arco de deslocamento de i para j $((i, t + u^r), (j, t + u^r + time(i, j))) \in \hat{\mathcal{A}}_{\mathcal{T}}^q$, de localização de carregadores lentos (em função do fluxo) e tempo de viagem acumulado t (linhas 21 a 24).

Caso não seja violada a restrição de descanso longo, é verificado se, ao atravessar o arco (i, j) , a restrição de horas consecutivas de direção é violada (linha 27). Caso positivo, é considerado que o veículo realiza uma parada rápida em i antes de partir para j . Os parâmetros $timeBeforeBreak$ e $distBeforeBreak$ são reiniciados e um descanso rápido é acrescido ao contador $nBreak$ (linhas 28 a 30). Uma vez que os descansos rápidos contabilizam como descansos que os motoristas tem direito ao longo do dia, reduz-se o tempo deste descanso do parâmetro $extraBreak$ (linha 31). Na sequência, atualiza-se as variáveis x_{ij}^{qt} para o arco de descanso rápido $((i, t), (i, t + u^b)) \in \hat{\mathcal{B}}_{\mathcal{T}}^q$ utilizado e para a o arco de deslocamento $((i, t + u^b), (j, t + u^b + time(i, j))) \in \hat{\mathcal{A}}_{\mathcal{T}}^q$, de localização de carregadores rápidos (em função do fluxo) e tempo de viagem acumulado t (linhas 32 a 35).

Por outro lado, se as condições acima descritas não forem violadas, o veículo pode continuar o deslocamento sem a necessidade de parada. Neste caso, são utilizados somente os arcos $((i, t + u^b), (j, t + u^b + time(i, j))) \in \hat{\mathcal{A}}_{\mathcal{T}}^q$ e atualizados os parâmetros $timeBeforeBreak$, $distBeforeBreak$ e t (linhas 36 a 40).

Por fim, após realizar o procedimento iterativo acima descrito para todas as demandas, seleciona-se, para cada nó, a maior quantidade de carregadores necessários dentre os valores registrados para cada variável y_{it}^s e y_{it}^f (linhas 41 e 43). Deste procedimento, obtém-se uma solução inicial viável para as variáveis de decisão x_{ij}^{qt} , y_i^s e y_i^f . Cabe destacar que, por ser um procedimento heurístico para construção de uma solução inicial, não foram avaliados os limites de orçamento durante o processo. Desta forma, a solução encontrada pode ser inviável quando utilizado valor de orçamento muito restritivo.

Os resultados da aplicação desta abordagem metodológica estão apresentados na Tabela 3.21. Observa-se que, para a instância DFGOS_BR e MTS_BR, o uso da heurística em conjunto com a estratégia de *lazy constraints* por meio de *callback* (método “C”) auxiliou na obtenção de solução ao problema: com valor de GAP de 4,22% e 5,13% respectivamente. Esta estratégia foi também benéfica para a instância MS_BR, uma vez que permitiu encontrar a solução ótima em menor tempo computacional quando comparado ao resultado sem uso da solução inicial viável. A análise de sensibilidade apresentada no Apêndice I reforça o desempenho positivo deste método para a obtenção de soluções.

Algoritmo 11: Heurística construtiva para solução inicial viável.

Entrada: \mathcal{Q} , parâmetros de JTM

1 **início**

2 {Inicia os vetores de soluções x_{ij}^{qt}, y_{it}^s e y_{it}^f }

3 **para cada** $q \in \mathcal{Q}$ **faça**

4 $t, distBeforeBreak, timeBeforeBreak, timeBeforeRest = 0$

5 $nBreak, nRest, nWait = 0$

6 $extraBreak = \hat{h}^{totalrest} - u^r$

7 Encontra-se todos os menores caminhos entre o^q e d^q por meio do NetworkX

8 $path \leftarrow$ caminho com menor número de nós

9 **para cada** $(i, j) \in path$ **faça**

10 {Verifica se há necessidade de descanso longo:}

11 **se** $timeBeforeRest + time(i, j) > (h^{daily})$ **então**

12 $timeBeforeRest = time(i, j)$

13 $timeBeforeBreak = time(i, j)$

14 $distBeforeBreak = dist(i, j)$

15 $nRest+ = 1$

16 **enquanto** $extraBreak > 0$ **faça**

17 Utiliza arcos de espera $((i, t), (i, t + 1)) \in \hat{\mathcal{W}}_{\mathcal{T}}^q$: $x_{ii}^{qt} = 1$

18 $t+ = 1$

19 $extraBreak- = 1$

20 $extraBreak = \hat{h}^{daily}$

21 Utiliza arco de descanso longo $((i, t), (i, t + u^r)) \in \hat{\mathcal{R}}_{\mathcal{T}}^q$: $x_{ii}^{qt} = 1$

22 Utiliza arco espaço-temporal $((i, t + u^r), (j, t + u^r + time(i, j))) \in \hat{\mathcal{A}}_{\mathcal{T}}^q$:

$x_{ij}^{qt} = 1$

23 Atualiza a variável de localização de carregadores rápidos: $y_{it}^s+ = f^q$

24 Atualiza o tempo total de viagem: $t+ = u^r + time(i, j)$

25 **senão**

26 $timeBeforeRest+ = time(i, j)$

27 **se** $timeBeforeBreak > h^{driving}$ **então**

28 $timeBeforeBreak = time(i, j)$

29 $distBeforeBreak = dist(i, j)$

30 $nBreak+ = 1$

31 $extraBreak- = u^b$

32 Utiliza arco de descanso curto $((i, t), (i, t + u^b)) \in \hat{\mathcal{B}}_{\mathcal{T}}^q$: $x_{ii}^{qt} = 1$

33 $y_i^f t+ = f^q$

34 Utiliza o arco espaço-temporal

$((i, t + u^b), (j, t + u^b + time(i, j))) \in \hat{\mathcal{A}}_{\mathcal{T}}^q$ $x_{ij}^{qt} = 1$

35 Atualiza tempo total de viagem: $t+ = u^b + time(i, j)$

36 **senão**

37 $timeBeforeBreak+ = time(i, j)$

38 Utiliza o arco espaço-temporal $((i, t), (j, t + time(i, j))) \in \hat{\mathcal{A}}_{\mathcal{T}}^q$:

$x_{ij}^{qt} = 1$

39 Atualiza o tempo total de viagem: $t+ = time(i, j)$

40 Atualiza a distância percorrida sem parada:

$distBeforeBreak+ = dist(i, j)$

41 {Retorna a maior quantidade de carregadores a ser localizado:}

42 $y_i^s = \max(y_{it}^s)$

43 $y_i^f = \max(y_{it}^f)$

44 **retorna** Vetores de soluções x_{ij}^{qt}, y_i^s e y_i^f

Tabela 3.21: Resultados para a instância de distribuição nacional da soja produzida em cada estado do Centro-Oeste com solução inicial viável.

Instan.	Método	Tempo (s)				Resultados		
		Pre-Proces.	Mod.	Otimiz.	Total	Solução	GAP (%)	Motivo da Interrupção
DF+GO_BR	S	626	7.225	0	7.851	–	–	Out of Memory
	C	464	3.470	21.600	25.534	303.321,61	4,22	Time Out
	G1	459	3.071	0	3.530	–	–	Out of Memory
	G2	467	3.657	0	4.124	–	–	Out of Memory
	G3	557	4.452	0	5.009	–	–	Out of Memory
MT_BR	S	860	7.742	0	8.602	–	–	Out of Memory
	C	819	8.541	21.600	30.960	519.565,69	5,13	Time Out
	G1	848	7.876	0	8.724	–	–	Out of Memory
	G2	848	7.864	0	8.712	–	–	Out of Memory
	G3	895	10.058	0	10.953	–	–	Out of Memory
MS_BR	S	147	97	14.502	14.746	121.259,71	0,01	Optimality
	C	148	89	21.600	21.837	121.448,71	0,39	Time Out
	G1	151	98	15.196	15.445	121.259,71	0,01	Optimality
	G2	150	98	21.600	21.848	121.468,76	1,70	Time Out
	G3	151	98	21.600	21.849	121.259,71	0,13	Time Out

– Indica que nenhuma solução foi encontrada.

Foram calculadas as estatísticas da quantidade necessária de carregadores rápidos e lentos em cada instância, conforme apresentado na Tabela 3.22. Na primeira coluna, é apresentada a instância. Na sequência, apresenta-se as informações de localização dos carregadores rápidos, que coincidem com as paradas para descanso curto: na segunda coluna, apresenta-se a quantidade de nós da rede que foram selecionados para a localização destes carregadores; na terceira e quarta colunas são exibidas as estatísticas de quantidade mínima e máxima observadas; na quinta coluna, é apresentado o total de carregadores rápidos localizados na rede. Similarmente ao apresentado para estes carregadores, detalha-se, nas colunas sexta a nona, as informações para os carregadores lentos, que coincidem com as paradas para descanso longo.

A análise da eletrificação da rede logística de longa distância para as instâncias avaliadas indicou a necessidade de quantidade total de carregadores variando de 111.831 (instância DF+GO_BR) a 458.007 (instância MT_BR). A quantidade total de carregadores com rápido carregamento variou de 67.596 (instância DF+GO_BR) a 281.015 (instância MT_BR), enquanto os de lento carregamento variou de 41.174 (instância MS_BR) a 176.992 (instância MT_BR). O resultado da variável θ para as três instâncias avaliadas indicou que a solução obtida utilizou valores inferiores ao orçamento disponibilizado para a localização dos carregadores (K). Foram observados consumos de, aproximadamente, 61%, 69% e 71% dos orçamentos disponibilizados para as instâncias DF+GO_BR, MT_BR e MS_BR respectivamente.

É apresentado, na Figura 3.9, os mapas com os resultados da localização ótima dos carregadores de rápido e lento carregamento a partir dos valores estudados para cada instância. Observa-se que a maior quantidade de carregadores são localizados, para todos os casos, na região CO e no eixo de ligação entre as regiões CO e Sul.

Tabela 3.22: Resultados da localização de carregadores para as instâncias por estado.

Instância	Carregador Rápido				Carregador Lento				Total geral
	#Nós	Min.	Max.	Total	#Nós	Min.	Max.	Total	
DF+GO_BR	34	5	6.128	67.596	25	5	7.049	44.235	111.831
MT_BR	43	8	25.839	281.015	32	298	25.891	176.992	458.007
MS_BR	24	1	12.467	81.294	19	4	12.467	41.174	122.468

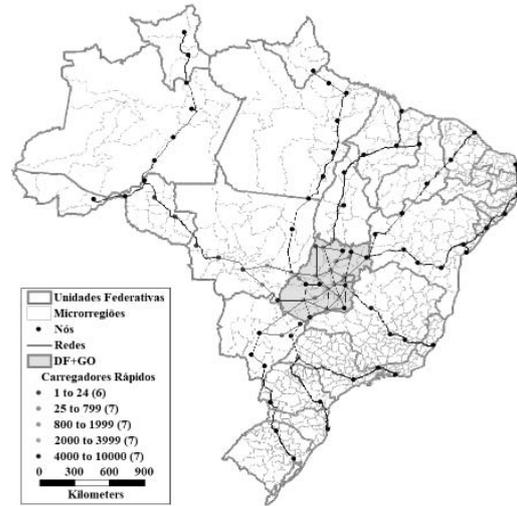
3.5 Conclusões do Capítulo

Tendo em vista a importância de se considerar a localização de carregadores de forma estratégica para permitir a eletrificação da frota da cadeia logística, apresentou-se, neste capítulo, um modelo matemático abrangente para a localização de carregadores para caminhões de longa distância que considere a regulamentação da jornada de trabalho dos motoristas. Os deslocamentos de longa distância realizados por caminhões são frequentes em sistemas logísticos de países com vasta extensão territorial, como é o caso do Brasil. Ao considerar a jornada de trabalho dos motoristas na modelagem do problema, além de incentivar a segurança viária, permite avaliar a localização estratégica de carregadores a fim de sincronizar o carregamento dos veículos com as paradas obrigatórias para descanso, evitando-se, assim, atrasos na entrega dos produtos. Para ser possível o carregamento do veículo nas paradas obrigatórias, dois níveis de carregadores foram considerados na formulação do problema: de lento carregamento, para as paradas longas, e; de rápido carregamento, para as paradas curtas.

A metodologia de construção do modelo baseou-se, inicialmente, na transformação da rede de transporte \mathcal{G} em uma rede de comunicação $\hat{\mathcal{G}}^q$, constituída apenas por arcos viáveis. Nesta, quando um nó intermediário é visitado, um descanso deve ocorrer e o veículo deve ser recarregado. Posteriormente, a rede $\hat{\mathcal{G}}^q$ passa por um processo de discretização temporal, resultando na rede de comunicação espaço-temporal $\hat{\mathcal{G}}_T^q$, na qual os nós da rede são replicados para um intervalo de tempo \mathcal{T}^q caracterizado pela demanda. Como resultado deste processo, são obtidas redes com grandes quantidades de nós e arcos, o que requer maior custo computacional para serem solucionadas. Visando contornar este problema, duas estratégias metodológicas foram aplicadas: estratégia para a redução da quantidade de restrições e estratégia de gerenciamento de nós e arcos supérfluos.



(a) DF+GO_BR: Carregadores Lentos.



(b) DF+GO_BR: Carregadores Rápidos.



(c) MT_BR Carregadores Lentos.



(d) MT_BR Carregadores Rápidos.



(e) MS_BR Carregadores Lentos.



(f) MS_BR: Carregadores Rápidos.

Figura 3.9: Resultado da localização geográfica dos carregadores.

A metodologia foi inicialmente aplicada em uma rede artificial contendo 25 nós. Para as configurações impostas, observou-se que foram obtidas soluções apenas quando utilizadas a estratégia de gerenciamento de nós e arcos supérfluos, preferencialmente em conjunto com a utilização da estratégia de redução da quantidade de restrições. Buscou-se, ainda, avaliar estratégias de obtenção de soluções a partir do uso padrão de um *solver* comercial e considerando algumas restrições como *lazy constraints*, inserindo-as tanto manualmente através de *callbacks* quanto por configurações de parâmetros do *solver*. Observou-se que a utilização da estratégia de *lazy constraints* não favoreceu no processo de busca de soluções.

Posteriormente, aplicou-se a modelagem matemática proposta para um estudo de caso de distribuição estadual de soja. Nesta, foi possível avaliar o comportamento do modelo em instâncias de tamanho real diversas. A partir de um conjunto de treze estados brasileiros com produção e consumo de soja, foi possível obter a solução ótima para cinco destes (MA, MS, PI, SC e TO). Assim, foi discutida a localização ótima de carregadores de rápido e lento carregamento para estas instâncias.

Por fim, o modelo proposto foi aplicado em um último estudo de caso, voltado à distribuição nacional da soja produzida nos estados do CO. Para isto, foram geradas três redes simplificadas baseadas em uma *cordon line* para cada estado da região CO: DF+GO_BR, MT_BR e MS_BR. Esta etapa permitiu avaliar a possibilidade de aplicação do modelo em escala nacional. No entanto, obteve-se soluções apenas para a instância referente ao estado MS. Visando contornar esse problema, foi proposto um procedimento heurístico para construção de uma solução primal inicial para ser inserida no *Solver*, auxiliando no processo de otimização. A técnica proposta apresentou-se satisfatória e foram discutidos os resultados acerca da localização ótima de carregadores de rápido e lento carregamento para estas instâncias.

O modelo elaborado foi baseado no Problema de Roteamento Aberto de Veículos. Porém, na logística de cargas brasileira, o caminhão tende a voltar para a base após o descarregamento. Esta pode ser apontada como uma limitação do modelo. Além disso, não foram diretamente considerados congestionamentos e outros atrasos na modelagem. Apesar destas impedâncias puderem ser empregadas a partir da redução da velocidade média, que impacta no aumento do tempo do arco, sugere-se, como trabalho futuro, a incorporação destas condições, principalmente na etapa de discretização temporal, o que permitirá avaliar o roteamento com base na variação horária de congestionamentos. Ainda como sugestões para trabalhos futuros, sugere-se: aprofundamento em procedimentos heurísticos para a solução do modelo; integração com os problemas de localização de CILs; associação da metodologia proposta para formulação com teoria de filas; e incorporação, na modelagem, a capacidade de veículos nos nós e limite de carregadores associado à disponibilidade de infraestrutura física ou elétrica.

Capítulo 4

Conclusões Finais

Ao longo do presente documento, foram desenvolvidas e discutidas técnicas de otimização para dois problemas que visam a descarbonização e eficiência operacional no transporte de cargas. A primeira proposta consistiu no Problema Multiperíodo de Localização de CILs (PMLCIL), no qual foi apresentado um modelo matemático abrangente para a localização e alocação de CILs em múltiplos períodos. Este modelo considerou, simultaneamente, critérios econômicos e de emissões de CO_2 no processo de otimização e permitiu incorporar variações temporais dos dados de entrada. Para solucionar o modelo, foram apresentados métodos heurísticos baseados em Algoritmo Genético, heurísticas gulosas e relaxação linear. O modelo foi aplicado para instâncias de distribuição de soja brasileira.

A segunda proposta abordou a eletrificação da frota de caminhões de longa distância, a partir do Problema de Localização de Carregadores para Caminhões Elétricos de Longa Distância considerando a Regulamentação da Jornada de Trabalho dos Motoristas (PLCR-JTM). Para este problema, foi desenvolvido e solucionado um modelo matemático abrangente, que incorpora carregadores com diferentes tecnologias, de forma a não gerar atrasos na programação logística, e rotas flexíveis, além da legislação da JTM. A modelagem baseou-se na discretização temporal da rede de comunicação e foram propostas estratégias metodológicas que visam reduzir a quantidade de variáveis e restrições no modelo. A metodologia proposta foi aplicada à uma rede de transportes artificial e à dois estudos de caso para a distribuição de soja, permitindo avaliar o desempenho do modelo em instâncias reais. Por fim, apresentou-se, ainda, uma heurística construtiva para geração de uma solução primal a ser utilizada como ponto de partida no processo de otimização do *solver*.

4.1 Estágio Sanduíche e Publicações

Foi realizado, entre 01/01/2023 e 31/06/2023, um período de estágio sanduíche, com bolsa CAPES PrInt (Processo 88887.717496/2022-00) na instituição HEC Montréal

- Universidade de Montreal, sob orientação do Professor Okan Arslan. Durante esse período, foi proposto e desenvolvido o PLCR-JTM. A pesquisa foi apresentada na conferência da Canadian Operational Research Society – “64th CORS Annual Conference”.

Os resultados científicos alcançados ao longo desta tese foram publicados em congressos e revistas científicas, a saber:

- Plaza, Guimarães, Skroder, Ribeiro, e Bahiense [123];
- Plaza, Guimarães, Ribeiro, e Bahiense [124];
- Plaza, Ribeiro, e Bahiense [125];
- Plaza, Ribeiro, Bahiense, e Climaco [126].

Cabe salientar que as publicações supracitadas não envolvem todas as contribuições científicas apresentadas nesta Tese. Desta forma, visando contribuir com a expansão do conhecimento na área, estão planejadas as publicações de três novos artigos. O primeiro abordará a relevância econômica e ambiental dos CILs por meio da aplicação do Problema Multiperíodo de Localização de CILs para a distribuição de soja brasileira, além das técnicas de otimização propostas, conforme discutido no Capítulo 2. Além disso, serão incorporados cenários com políticas de *carbon cap* e de limitação da quantidade de abertura de CILs em cada período. Já o segundo e o terceiro artigos abordarão o Problema de Localização de Carregadores para Caminhões Elétricos de Longa Distância Considerando Roteamento e a Jornada de Trabalho dos Motoristas. Inicialmente, serão publicadas as contribuições metodológicas, abordando-se as técnicas de transformação de rede e a modelagem proposta, juntamente com o estudo de caso estadual de distribuição de soja. Posteriormente, será publicado o estudo de caso para a distribuição nacional de soja e a relevância do problema para a descarbonização do sistema logístico brasileiro.

Referências Bibliográficas

- [1] MT. “Plano Nacional de Logística e Transportes: Relatório Executivo 2011. Ministério dos Transportes e Ministério da Defesa.” 2011. Disponível em: <<https://www.infraestrutura.gov.br/conteudo/2818-pnlt-relatorio-executivo-2011.html>>.
- [2] COSTA, M. B. B. D. *Utilização de Modelo de Localização-Alocação para Identificação de Zoneamento Logístico Integrado ao Planejamento Estratégico de Transportes*. Tese de Doutorado, Programa de Engenharia de Transportes, Universidade Federal do Rio de Janeiro - COPPE/UFRJ, Rio de Janeiro, Brasil, 2014.
- [3] GUIMARÃES, V. D. A. *Localização-Alocação de Centros de Integração Logística Considerando Critérios Econômicos e Ambientais*. Tese de Doutorado, Programa de Engenharia de Transportes, Universidade Federal do Rio de Janeiro - COPPE/UFRJ, Rio de Janeiro, Brasil, 2019.
- [4] CANEL, C., KHUMAWALA, B. M. “Multi-period international facilities location: An algorithm and application”, *International Journal of Production Research*, v. 35, n. 7, pp. 1891–1910, 1997. ISSN: 1366588X. doi: 10.1080/002075497194976.
- [5] CNT. *Plano CNT de transporte e logística 2018*. Relatório Técnico CDU 656.1/.7(81)(047), Confederação Nacional dos Transportes - CNT, Brasília, 2018.
- [6] MONTEIRO HUERTAS, D. “Breve análise espacial dos fluxos origem-destino do transporte rodoviário de carga”, *Revista Transporte y Territorio*, v. 20, pp. 110, apr 2019. ISSN: 1852-7175. doi: 10.34096/rtt.i20.6386. Disponível em: <<http://revistascientificas.filo.uba.ar/index.php/rtt/article/view/6386>>.
- [7] GUIMARÃES, V. D. A., SKRODER, G. C., RIBEIRO, G. M., et al. “Strategic planning of freight transportation to support smart cities design: The Brazilian soybean case”, *Revista Facultad de Ingeniería Universidad de*

Antioquia, v. 98, pp. 104–116, jun 2020. ISSN: 2422-2844. doi: 10.17533/udea.redin.20200583. Disponível em: <<https://revistas.udea.edu.co/index.php/ingenieria/article/view/340696>>.

- [8] GUIMARÃES, V. D. A. *Modelagem matemática para localização-alocação de centros de integração logística considerando as demandas par-a-par*. Tese de Mestrado, Programa de Engenharia de Transportes, Universidade Federal do Rio de Janeiro - COPPE/UFRJ, Rio de Janeiro, Brasil, 2015.
- [9] MINISTÉRIO DO DESENVOLVIMENTO, INDÚSTRIA, COMÉRCIO E SERVIÇOS. *Resultados da Consulta Pública do Custo-Brasil*. Relatório técnico, 2023. Disponível em: <https://www.gov.br/mdic/pt-br/assuntos/noticias/2023/setembro/mdic-define-oito-eixos-de-atuacao-para-reduzir-custo-brasil/resultados_cp_custo-brasil.pdf>.
- [10] CNT. *O transporte move o Brasil: o resumo das propostas da CNT ao país*. Relatório Técnico CDU 656.1/.7(81), Confederação Nacional dos Transportes - CNT, Brasília, 2019. Disponível em: <<https://cnt.org.br/propostas-cnt-transporte>>.
- [11] CNT E COPPEAD. *Transporte de Cargas no Brasil: ameaças e oportunidades para o desenvolvimento do país - diagnóstico e plano de ação*. Relatório técnico, Confederação Nacional dos Transportes - CNT e Centros de Estudos em Logística - COPPEAD, Rio de Janeiro, 2002.
- [12] LOPES, S. S., CARDOSO, M. P., PICCININI, M. S. “O transporte Rodoviário de Carga e o Papel do BNDES”, *Revista do BNDES*, v. 14, n. 29, pp. 35–60, 2008.
- [13] WANKE, P., FLEURY, P. F. “Transporte de cargas no Brasil: estudo exploratório das principais variáveis relacionadas aos diferentes modais e às suas estruturas de custos”, *Estrutura e dinâmica do setor de serviços no Brasil*. Brasília: Ipea, pp. 409–464, 2006. Disponível em: <https://www.ipea.gov.br/portal/images/stories/PDFs/livros/capitulo_12_transportes.pdf>.
- [14] CNT. *Boletins Técnicos CNT: Janeiro de 2022*. Relatório técnico, Confederação Nacional dos Transportes - CNT, Brasília, 2022.
- [15] ALAM, M. R., GUO, Z. “Co-optimization of charging scheduling and platooning for long-haul electric freight vehicles”, *Transportation Research Part C: Emerging Technologies*, v. 147, pp. 104009, 2 2023. ISSN: 0968090X.

doi: 10.1016/j.trc.2022.104009. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0968090X22004223>>.

- [16] RITCHIE, H., ROSER, M., ROSADO, P. “CO₂ and Greenhouse Gas Emissions”, *Our World in Data*, 2020. <https://ourworldindata.org/co2-and-greenhouse-gas-emissions>.
- [17] EPE. *Balço Energético Nacional 2023: Relatório Síntese - ano base 2021*. Relatório técnico, Empresa de Pesquisa Energética - EPE, 2023. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-748/topico-681/BEN_SÃntese_2023_PT.pdf>.
- [18] GUIMARÃES, V. D. A., RIBEIRO, G. M., DO FORTE, V. L., et al. “A location-allocation model for Logistics Integration Centers”, *International journal of transport economics*, v. XLIV, n. 2, pp. 273–292, 2017. doi: 10.19272/201706702006.
- [19] ARABANI, A. B., FARAHANI, R. Z. “Facility location dynamics: An overview of classifications and applications”, *Computers and Industrial Engineering*, v. 62, n. 1, pp. 408–420, 2012. ISSN: 03608352. doi: 10.1016/j.cie.2011.09.018. Disponível em: <<http://dx.doi.org/10.1016/j.cie.2011.09.018>>.
- [20] CANEL, C., KHUMAWALA, B. M., LAW, J., et al. “An algorithm for the capacitated, multi-commodity multi-period facility location problem”, *Computers and Operations Research*, v. 28, n. 5, pp. 411–427, 2001. ISSN: 03050548. doi: 10.1016/S0305-0548(99)00126-4.
- [21] OWEN, S. H., DASKIN, M. S. “Strategic facility location: A review”, *European Journal of Operational Research*, v. 111, n. 3, pp. 423–447, 1998. ISSN: 03772217. doi: 10.1016/S0377-2217(98)00186-6.
- [22] MT. *Estudos e Pesquisas para Desenvolvimento de Metodologia para Implementação de Centros de Integração Logística com Vistas a Subsidiar Políticas Públicas Voltadas à Promoção da Intermodalidade no Transporte de Cargas. Etapa 5 - Desenvolvimento da Metodologia de Localização de CILs. Tomo I*. Relatório técnico, Ministério dos Transportes e Fundação COPPETEC, 2016. Disponível em: <<https://www.gov.br/infraestrutura/pt-br/assuntos/politica-e-planejamento/politica-e-planejamento/centros-de-integracao-logistica>>.

- [23] CHEN, Z., DENG, Y., XIE, C., et al. “Network Equilibrium of Battery Electric Vehicles Considering Drivers’ Resting Behavior”, *SSRN Electronic Journal*, 2021. ISSN: 1556-5068. doi: 10.2139/ssrn.4104904. Disponível em: <<https://www.ssrn.com/abstract=4104904>>.
- [24] ZHONG, R., XU, R., SUMALEE, A., et al. “Pricing Environmental Externality in Traffic Networks Mixed With Fuel Vehicles and Electric Vehicles”, *IEEE Transactions on Intelligent Transportation Systems*, v. 22, n. 9, pp. 5535–5554, 2021. doi: 10.1109/TITS.2020.2987832.
- [25] DAVATGARI, A., COKYASAR, T., SUBRAMANYAM, A., et al. “Electric Vehicle Supply Equipment Location and Capacity Allocation for Fixed-Route Networks”. 2024.
- [26] KUCUKOGLU, I., DEWIL, R., CATTRYSSE, D. “The electric vehicle routing problem and its variations: A literature review”, *Computers and Industrial Engineering*, v. 161, pp. 107650, 2021. ISSN: 03608352. doi: 10.1016/j.cie.2021.107650. Disponível em: <<https://doi.org/10.1016/j.cie.2021.107650>>.
- [27] MAYERLE, S. F., CHIROLI, D. M. D. G., DE FIGUEIREDO, J. N., et al. “The long-haul full-load vehicle routing and truck driver scheduling problem with intermediate stops: An economic impact evaluation of Brazilian policy”, *Transportation Research Part A: Policy and Practice*, v. 140, pp. 36–51, 10 2020. ISSN: 09658564. doi: 10.1016/j.tra.2020.07.021. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0965856420306765>>.
- [28] SMITH, D., OZPINECI, B., GRAVES, R. L., et al. “Medium- and Heavy-Duty Vehicle Electrification: An Assessment of Technology and Knowledge Gaps”. 2 2020. Disponível em: <<https://www.osti.gov/biblio/1615213>>.
- [29] BRASIL. “Lei nº 13.103, de 2 de março de 2015”, *Diário Oficial [da] República Federativa do Brasil*, 2015. ISSN: 1677-7042. Disponível em: <https://www.planalto.gov.br/ccivil_03/_ato2015-2018/2015/lei/l13103.htm>.
- [30] KOUBÂA, M., DHOUIB, S., DHOUIB, D., et al. “Truck Driver Scheduling Problem: Literature Review”, *IFAC-PapersOnLine*, v. 49, n. 12, pp. 1950–1955, 2016. doi: 10.1016/j.ifacol.2016.07.916. Disponível em: <<https://doi.org/10.1016/j.ifacol.2016.07.916>>.

- [31] PILZ, D., SCHWERDFEGER, S., BOYSEN, N. “Make or break: Coordinated assignment of parking space for breaks and rest periods in long-haul trucking”, *Transportation Research Part B: Methodological*, v. 164, pp. 45–64, out. 2022. doi: 10.1016/j.trb.2022.08.002. Disponível em: <<https://doi.org/10.1016/j.trb.2022.08.002>>.
- [32] SANTIBAÑEZ-AGUILAR, J. E., GONZÁLEZ-CAMPOS, J. B., PONCE-ORTEGA, J. M., et al. “Optimal planning and site selection for distributed multiproduct biorefineries involving economic, environmental and social objectives”, *Journal of Cleaner Production*, v. 65, pp. 270–294, 2014. ISSN: 09596526. doi: 10.1016/j.jclepro.2013.08.004. Disponível em: <<http://dx.doi.org/10.1016/j.jclepro.2013.08.004>>.
- [33] DOGAN, K., GOETSCHALCKX, M. “A primal decomposition method for the integrated design of multi-period production-distribution systems A primal decomposition method for the integrate : d design of multi-period productiondistribution systems”, *IIE Transactions*, v. 31, n. 11, pp. 1027–1036, 1999.
- [34] CORREIA, I., NICKEL, S., SALDANHA-DA GAMA, F. “A stochastic multi-period capacitated multiple allocation hub location problem: Formulation and inequalities”, *Omega (United Kingdom)*, v. 74, pp. 122–134, 2018. ISSN: 03050483. doi: 10.1016/j.omega.2017.01.011. Disponível em: <<https://doi.org/10.1016/j.omega.2017.01.011>>.
- [35] MOHAMMED, F., SELIM, S. Z., HASSAN, A., et al. “Multi-period planning of closed-loop supply chain with carbon policies under uncertainty”, *Transportation Research Part D: Transport and Environment*, v. 51, pp. 146–172, 2017. ISSN: 13619209. doi: 10.1016/j.trd.2016.10.033. Disponível em: <<http://dx.doi.org/10.1016/j.trd.2016.10.033>>.
- [36] ZEBALLOS, L. J., MÉNDEZ, C. A., BARBOSA-POVOA, A. P., et al. “Multi-period design and planning of closed-loop supply chains with uncertain supply and demand”, *Computers and Chemical Engineering*, v. 66, pp. 151–164, 2014. ISSN: 00981354. doi: 10.1016/j.compchemeng.2014.02.027. Disponível em: <<http://dx.doi.org/10.1016/j.compchemeng.2014.02.027>>.
- [37] NICKEL, S., SALDANHA-DA GAMA, F., ZIEGLER, H. P. “A multi-stage stochastic supply network design problem with financial decisions and risk management”, *Omega*, v. 40, n. 5, pp. 511–524, 2012. ISSN: 03050483. doi:

10.1016/j.omega.2011.09.006. Disponível em: <<http://dx.doi.org/10.1016/j.omega.2011.09.006>>.

- [38] BARON, O., MILNER, J., NASERALDIN, H. “Facility location: A robust optimization approach”, *Production and Operations Management*, v. 20, n. 5, pp. 772–785, 2011. ISSN: 10591478. doi: 10.1111/j.1937-5956.2010.01194.x.
- [39] SHEU, J. B., KUNDU, T. “Forecasting time-varying logistics distribution flows in the One Belt-One Road strategic context”, *Transportation Research Part E: Logistics and Transportation Review*, v. 117, n. 2018, pp. 5–22, 2018. ISSN: 13665545. doi: 10.1016/j.tre.2017.03.003. Disponível em: <<https://doi.org/10.1016/j.tre.2017.03.003>>.
- [40] CORREIA, I., MELO, T. “A multi-period facility location problem with modular capacity adjustments and flexible demand fulfillment”, *Computers & Industrial Engineering*, v. 110, pp. 307–321, aug 2017. ISSN: 03608352. doi: 10.1016/j.cie.2017.06.003.
- [41] CORREIA, I., MELO, T. “Multi-period capacitated facility location under delayed demand satisfaction”, *European Journal of Operational Research*, v. 255, n. 3, pp. 729–746, 2016. ISSN: 0377-2217. doi: <https://doi.org/10.1016/j.ejor.2016.06.039>.
- [42] FATTAHI, M., MAHOOTCHI, M., GOVINDAN, K., et al. “Dynamic supply chain network design with capacity planning and multi-period pricing”, *Transportation Research Part E: Logistics and Transportation Review*, v. 81, pp. 169–202, 2015. ISSN: 13665545. doi: 10.1016/j.tre.2015.06.007. Disponível em: <<http://dx.doi.org/10.1016/j.tre.2015.06.007>>.
- [43] WANG, X. F., SUN, X. M., FANG, Y. “Genetic algorithm solution for multi-period two-echelon integrated competitive/uncompetitive facility location problem”, *Asia-Pacific Journal of Operational Research*, v. 25, n. 1, pp. 33–56, 2008. ISSN: 02175959. doi: 10.1142/S0217595908001626.
- [44] RAFIE-MAJD, Z., PASANDIDEH, S. H. R., NADERI, B. “Modelling and solving the integrated inventory-location-routing problem in a multi-period and multi-perishable product supply chain with uncertainty: Lagrangian relaxation algorithm”, *Computers and Chemical Engineering*, v. 109, pp. 9–22, 2018. ISSN: 00981354. doi: 10.1016/j.compchemeng.2017.10.013. Disponível em: <<http://dx.doi.org/10.1016/j.compchemeng.2017.10.013>>.

- [45] GHAHREMANI-NAHR, J., KIAN, R., SABET, E. “A robust fuzzy mathematical programming model for the closed-loop supply chain network design and a whale optimization solution algorithm”, *Expert Systems with Applications*, v. 116, pp. 454–471, 2019. ISSN: 09574174. doi: 10.1016/j.eswa.2018.09.027.
- [46] LU, H., LI, L., ZHAO, X., et al. “A model of integrated regional logistics hub in supply chain”, *Enterprise Information Systems*, v. 12, n. 10, pp. 1308–1335, 2018. ISSN: 17517583. doi: 10.1080/17517575.2018.1533588. Disponível em: <<https://doi.org/10.1080/17517575.2018.1533588>>.
- [47] JENA, S. D., CORDEAU, J. F., GENDRON, B. “Lagrangian heuristics for large-scale dynamic facility location with generalized modular capacities”, *INFORMS Journal on Computing*, v. 29, n. 3, pp. 388–404, 2017. ISSN: 15265528. doi: 10.1287/ijoc.2016.0738.
- [48] JENA, S. D., CORDEAU, J. F., GENDRON, B. “Solving a dynamic facility location problem with partial closing and reopening”, *Computers and Operations Research*, v. 67, pp. 143–154, 2016. ISSN: 03050548. doi: 10.1016/j.cor.2015.10.011. Disponível em: <<http://dx.doi.org/10.1016/j.cor.2015.10.011>>.
- [49] GELAREH, S., NEAMATIAN MONEMI, R., NICKEL, S. “Multi-period hub location problems in transportation”, *Transportation Research Part E: Logistics and Transportation Review*, v. 75, pp. 67–94, 2015. ISSN: 13665545. doi: 10.1016/j.tre.2014.12.016. Disponível em: <<http://dx.doi.org/10.1016/j.tre.2014.12.016>>.
- [50] THANH, P. N., PÉTON, O., BOSTEL, N. “A linear relaxation-based heuristic approach for logistics network design”, *Computers and Industrial Engineering*, v. 59, n. 4, pp. 964–975, 2010. ISSN: 03608352. doi: 10.1016/j.cie.2010.09.007. Disponível em: <<http://dx.doi.org/10.1016/j.cie.2010.09.007>>.
- [51] HINOJOSA, Y., PUERTO, J., FERNÁNDEZ, F. R. “A multiperiod two-echelon multicommodity capacitated plant location problem”, *European Journal of Operational Research*, v. 123, n. 2, pp. 271–291, 2000. ISSN: 03772217. doi: 10.1016/S0377-2217(99)00256-8.
- [52] MOGALE, D. G., KUMAR, M., KUMAR, S. K., et al. “Grain silo location-allocation problem with dwell time for optimization of food grain supply chain network”, *Transportation Research Part E: Logistics and Transportation Review*, v. 111, n. January, pp. 40–69, 2018. ISSN: 13665545. doi:

10.1016/j.tre.2018.01.004. Disponível em: <<https://doi.org/10.1016/j.tre.2018.01.004>>.

- [53] NEKOOGHADIRLI, N., TAVAKKOLI-MOGHADDAM, R., GHEZAVATI, V. R., et al. “Solving a new bi-objective location-routing-inventory problem in a distribution network by meta-heuristics”, *Computers and Industrial Engineering*, v. 76, n. 1, pp. 204–221, 2014. ISSN: 03608352. doi: 10.1016/j.cie.2014.08.004. Disponível em: <<http://dx.doi.org/10.1016/j.cie.2014.08.004>>.
- [54] ALUMUR, S. A., NICKEL, S., SALDANHA-DA-GAMA, F., et al. “Multi-period reverse logistics network design”, *European Journal of Operational Research*, v. 220, n. 1, pp. 67–78, 2012. ISSN: 03772217. doi: 10.1016/j.ejor.2011.12.045. Disponível em: <<http://dx.doi.org/10.1016/j.ejor.2011.12.045>>.
- [55] SHULMAN, A. “An Algorithm for Solving Dynamic Capacitated Plant Location Problems with Discrete Expansion Sizes”, *Operations Research*, v. 39, n. 3, pp. 423–436, 1991. ISSN: 0030-364X. doi: 10.1287/opre.39.3.423.
- [56] KRARUP, J., PRUZAN, P. M. “The simple plant location problem: Survey and synthesis”, *European Journal of Operational Research*, v. 12, n. 1, 1983. ISSN: 03772217. doi: 10.1016/0377-2217(83)90181-9.
- [57] MAURI, G. R., BIAJOLI, F. L., RABELLO, R. L., et al. “Hybrid metaheuristics to solve a multiproduct two-stage capacitated facility location problem”, *International Transactions in Operational Research*, v. 28, n. 6, pp. 3069–3093, 2021. ISSN: 14753995. doi: 10.1111/itor.12930.
- [58] SAEIDIAN, B., MESGARI, M. S., GHODOUSI, M. “Evaluation and comparison of Genetic Algorithm and Bees Algorithm for location-allocation of earthquake relief centers”, *International Journal of Disaster Risk Reduction*, v. 15, pp. 94–107, 2016. ISSN: 22124209. doi: 10.1016/j.ijdrr.2016.01.002. Disponível em: <<http://dx.doi.org/10.1016/j.ijdrr.2016.01.002>>.
- [59] AARDAL, K., VAN DEN BERG, P. L., GIJSWIJT, D., et al. “Approximation algorithms for hard capacitated k-facility location problems”, *European Journal of Operational Research*, v. 242, n. 2, pp. 358–368, 2015. ISSN: 03772217. doi: 10.1016/j.ejor.2014.10.011. Disponível em: <<http://dx.doi.org/10.1016/j.ejor.2014.10.011>>.

- [60] FERNANDES, D. R., ROCHA, C., ALOISE, D., et al. “A simple and effective genetic algorithm for the two-stage capacitated facility location problem”, *Computers and Industrial Engineering*, v. 75, n. 1, pp. 200–208, 2014. ISSN: 03608352. doi: 10.1016/j.cie.2014.05.023. Disponível em: <<http://dx.doi.org/10.1016/j.cie.2014.05.023>>.
- [61] KAZAKOVITSEV, L. A., ANTAMOSHKIN, A. N. “Genetic algorithm with fast greedy heuristic for clustering and location problems”, *Informatika (Slovenia)*, v. 38, n. 3, pp. 229–240, 2014. ISSN: 03505596.
- [62] XIFENG, T., JI, Z., PENG, X. “A multi-objective optimization model for sustainable logistics facility location”, *Transportation Research Part D: Transport and Environment*, v. 22, pp. 45–48, 2013. ISSN: 13619209. doi: 10.1016/j.trd.2013.03.003. Disponível em: <<http://dx.doi.org/10.1016/j.trd.2013.03.003>>.
- [63] ABOOLIAN, R., BERMAN, O., KRASS, D. “Competitive facility location and design problem”, *European Journal of Operational Research*, v. 182, n. 1, pp. 40–62, 2007. ISSN: 03772217. doi: 10.1016/j.ejor.2006.07.021.
- [64] WU, L. Y., ZHANG, X. S., ZHANG, J. L. “Capacitated facility location problem with general setup cost”, *Computers and Operations Research*, v. 33, n. 5, pp. 1226–1241, 2006. ISSN: 03050548. doi: 10.1016/j.cor.2004.09.012.
- [65] ZHANG, J., CHEN, B., YE, Y. “A multiexchange local search algorithm for the capacitated facility location problem”, *Mathematics of Operations Research*, v. 30, n. 2, pp. 389–403, 2005. ISSN: 0364765X. doi: 10.1287/moor.1040.0125.
- [66] PIRKUL, H., JAYARAMAN, V. “A multi-commodity, multi-plant, capacitated facility location problem: formulation and efficient heuristic solution”, *Computers & Operations Research*, v. 25, n. 10, pp. 869–878, oct 1998. ISSN: 03050548. doi: 10.1016/S0305-0548(97)00096-8. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0305054897000968>>.
- [67] GHADERI, A. “Heuristic Algorithms for Solving an Integrated Dynamic Center Facility Location - Network Design Model”, *Networks and Spatial Economics*, v. 15, n. 1, pp. 43–69, 2015. ISSN: 15729427. doi: 10.1007/s11067-014-9269-z.
- [68] MELO, M. T., NICKEL, S., SALDANHA-DA GAMA, F. “An efficient heuristic approach for a multi-period logistics network redesign problem”,

Top, v. 22, n. 1, pp. 80–108, 2014. ISSN: 18638279. doi: 10.1007/s11750-011-0235-3.

- [69] THANH, P. N., BOSTEL, N., PÉTON, O. “A DC programming heuristic applied to the logistics network design problem”, *International Journal of Production Economics*, v. 135, n. 1, pp. 94–105, 2012. ISSN: 09255273. doi: 10.1016/j.ijpe.2010.09.025.
- [70] ALBAREDA-SAMBOLA, M., FERNÁNDEZ, E., HINOJOSA, Y., et al. “The multi-period incremental service facility location problem”, *Computers and Operations Research*, v. 36, n. 5, pp. 1356–1375, 2009. ISSN: 03050548. doi: 10.1016/j.cor.2008.02.010.
- [71] CHARDAIRE, P., SUTTER, A., COSTA, M. C. “Solving the dynamic facility location problem”, *Networks*, v. 28, n. 2, pp. 117–124, 1996. ISSN: 00283045. doi: 10.1002/(SICI)1097-0037(199609)28:2<117::AID-NET5>3.0.CO;2-H.
- [72] WANG, W., WU, S., WANG, S., et al. “Emergency facility location problems in logistics: Status and perspectives”, *Transportation Research Part E: Logistics and Transportation Review*, v. 154, pp. 102465, 2021. ISSN: 13665545. doi: 10.1016/j.tre.2021.102465. Disponível em: <<https://doi.org/10.1016/j.tre.2021.102465>>.
- [73] MT. “Plano Nacional de Logística e Transportes: Relatório Executivo 2007. Ministério dos Transportes e Ministério da Defesa.” 2007. Disponível em: <https://www.gov.br/infraestrutura/pt-br/assuntos/transporte-terrestre_antigo/pnlt-relatorio-executivo-2007>.
- [74] MT. “Plano Nacional de Logística e Transportes: Relatório Executivo 2009. Ministério dos Transportes e Ministério da Defesa.” 2009. Disponível em: <https://www.gov.br/infraestrutura/pt-br/assuntos/transporte-terrestre_antigo/pnlt-relatorio-executivo-2009>.
- [75] BALLOU, R. H. *Gerenciamento da cadeia de suprimentos/logística empresarial*. 5 ed. Porto Alegre, Bookman, 2006.
- [76] HOLLAND, J. H. *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. Ann Arbor, MI, MIT press, 1992.
- [77] GOLDBERG, D. E. *Genetic Algorithms in Search, Optimization and Machine Learning*. 1st ed. USA, Addison-Wesley Longman Publishing Co., Inc., 1989. ISBN: 0201157675.

- [78] WIRSANSKY, E. *Hands-On Genetic Algorithms with Python: Applying genetic algorithms to solve real-world deep learning and artificial intelligence problems*. Birmingham,UK, Packt Publishing Ltd., 2020. ISBN: 9781838559182. Disponível em: <<https://books.google.com.br/books?id=A0vODwAAQBAJ>>.
- [79] FALCONE, M. A. G. *Estudo Comparativo Entre Algoritmos Genéticos e Evolução Diferencial para Otimização de um Modelo de Cadeia de Suprimento Simplificada*. Tese de Mestrado, Pontifícia Universidade Católica do Paraná. Programa de Pós-Graduação em Engenharia de Produção e Sistemas., Curitiba, 2004. Disponível em: <<http://www.produtronica.pucpr.br/publico/ppgeps/conteudo/dissertacoes/pdf/MarcoFalcone.pdf>>.
- [80] ALANDER, J. “On optimal population size of genetic algorithms”. In: *CompEuro 1992 Proceedings Computer Systems and Software Engineering*, pp. 65–70, 1992. doi: 10.1109/CMPEUR.1992.218485.
- [81] DE JONG, K. A. *An analysis of the behavior of a class of genetic adaptive systems*. Tese de Doutorado, University of Michigan, Michigan, Estados Unidos, 1975.
- [82] EPL. *Plano Nacional de Logística PNL - 2025. Relatório Executivo*. Brasília, Empresa de Planejamento e Logística, 2018. Disponível em: <<https://www.epl.gov.br/plano-nacional-de-logistica-2025>>.
- [83] EPL. *Plano Nacional de Logística PNL - 2035. Relatório Executivo*. Brasília, Empresa de Planejamento e Logística, 2021. Disponível em: <<https://www.epl.gov.br/plano-nacional-de-logistica-2035>>.
- [84] MT. *Estudos e Pesquisas para Desenvolvimento de Metodologia para Implementação de Centros de Integração Logística com Vistas a Subsidiar Políticas Públicas Voltadas à Promoção da Intermodalidade no Transporte de Cargas. Etapa 7 - Relatório Final. Tomo I*. Relatório técnico, Ministério dos Transportes e Fundação COPPETEC, 2016. Disponível em: <<https://www.gov.br/infraestrutura/pt-br/assuntos/politica-e-planejamento/politica-e-planejamento/centros-de-integracao-logistica>>.
- [85] CONAB. *Acompanhamento da Safra Brasileira de Grãos, v.11 - SAFRA 2023/24 - n. 1*. Relatório técnico, Companhia Nacional de Abastecimento - CONAB, Outubro 2023. Disponível em: <<https://www.conab.gov.br/info-agro/safras/graos>>.

- [86] CNT. *Pesquisa CNT de Rodovias 2019*. Relatório Técnico CDU 656.11(81)(047), Confederação Nacional dos Transportes - CNT: SEST SENAT, Brasília, 2019.
- [87] CNT. *Pesquisa CNT de Rodovias 2021*. Relatório Técnico CDU 656.11(81)(047), Confederação Nacional dos Transportes - CNT: SEST SENAT, Brasília, 2021.
- [88] GEIPOT. *Research on the Interrelationships Between Costs of Highway Construction, Maintenance and Utilization. Final Report. Vol. 5 - Study of Road User Costs*. Relatório técnico, Ministério dos Transportes, Brasília, DF, 1981.
- [89] PATERSON, W. D. “International Roughness Index: Relationship To Other Measures of Roughness and Riding Quality.” *Transportation Research Record*, v. 1084, pp. 49–59, 1986. ISSN: 0361-1981.
- [90] PATERSON, W. D. O. *Road Deterioration and Maintenance Effects: Models for planning and management*. Washington, D.C, USA, The International Bank for Reconstruction and Development / The World Bank, 1987. ISBN: 0801835909.
- [91] BARNES, G., LANGWORTHY, P. “Per Mile costs of operating automobiles and trucks”, *Transportation Research Record: Journal of the Transportation Research Board*, v. 1864, n. 1, pp. 71–77, 2004. ISSN: 03611981. doi: 10.3141/1864-10.
- [92] ZAABAR, I., CHATTI, K. “Calibration of HDM-4 models for estimating the effect of pavement roughness on fuel consumption for U. S. conditions”, *Transportation Research Record: Journal of the Transportation Research Board*, v. 2155, n. 1, pp. 105–116, 2010. ISSN: 03611981. doi: 10.3141/2155-12.
- [93] SUWARTO, F., NUGROHO, A., SUSANTI, R., et al. “Sensitivity analysis of road roughness on transportation costs”, *Journal of Physics: Conference Series*, v. 1444, n. 1, 2020. ISSN: 17426596. doi: 10.1088/1742-6596/1444/1/012048.
- [94] INVESTING.COM. “Crédito Carbono Futuros - Dez 20 (CFI2z0)”. <https://br.investing.com/commodities/carbon-emissions>, 2020.
- [95] INVESTING.COM. “GBP/BRL - Libra Esterlina Real Brasileiro”. <https://br.investing.com/currencies/gbp-brl>, 2020.

- [96] INTERNATIONAL CARBON ACTION PARTNERSHIP - ICAP. “ETS Prices”. <https://icapcarbonaction.com/en/ets-prices>, 2024.
- [97] INVESTING.COM. “USD/BRL - US Dollar Brazil Real”. <https://www.investing.com/currencies/usd-brl>, 2024.
- [98] BISCHOFF, J., MÁRQUEZ-FERNÁNDEZ, F. J., DOMINGUES-OLAVARRÍA, G., et al. “Impacts of vehicle fleet electrification in Sweden – a simulation-based assessment of long-distance trips”. In: *2019 6th International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS)*, pp. 1–7, 2019. doi: 10.1109/MTITS.2019.8883384.
- [99] MAREEV, I., BECKER, J., SAUER, D. U. “Battery Dimensioning and Life Cycle Costs Analysis for a Heavy-Duty Truck Considering the Requirements of Long-Haul Transportation”, *Energies*, v. 11, n. 1, 2018. ISSN: 1996-1073. doi: 10.3390/en11010055. Disponível em: <<https://www.mdpi.com/1996-1073/11/1/55>>.
- [100] DANESE, A., TORSÆTER, B. N., SUMPER, A., et al. “Planning of High-Power Charging Stations for Electric Vehicles: A Review”. 4 2022. ISSN: 20763417.
- [101] SPETH, D., PLÖTZ, P., FUNKE, S., et al. “Public fast charging infrastructure for battery electric trucks—a model-based network for Germany”, *Environmental Research: Infrastructure and Sustainability*, v. 2, pp. 025004, 6 2022. ISSN: 2634-4505. doi: 10.1088/2634-4505/ac6442. Disponível em: <<https://iopscience.iop.org/article/10.1088/2634-4505/ac6442>>.
- [102] XIAO, Y., ZHANG, Y., KAKU, I., et al. “Electric vehicle routing problem: A systematic review and a new comprehensive model with nonlinear energy recharging and consumption”, *Renewable and Sustainable Energy Reviews*, v. 151, pp. 111567, 2021. ISSN: 18790690. doi: 10.1016/j.rser.2021.111567. Disponível em: <<https://doi.org/10.1016/j.rser.2021.111567>>.
- [103] ERDELIC, T., CARIC, T., LALLA-RUIZ, E. “A Survey on the Electric Vehicle Routing Problem: Variants and Solution Approaches”, *Journal of Advanced Transportation*, v. 2019, 2019. ISSN: 20423195. doi: 10.1155/2019/5075671.
- [104] KCHAOU BOUJELBEN, M., GICQUEL, C., MINOUX, M. “A MILP model and heuristic approach for facility location under multiple operational

- constraints”, *Computers and Industrial Engineering*, v. 98, pp. 446–461, 2016. ISSN: 03608352. doi: 10.1016/j.cie.2016.06.022. Disponível em: <<http://dx.doi.org/10.1016/j.cie.2016.06.022>>.
- [105] WISE, J. M., HEATON, K., PATRICIAN, P. “Fatigue in Long-Haul Truck Drivers: A Concept Analysis”, *Workplace Health & Safety*, v. 67, n. 2, pp. 68–77, 2019. doi: 10.1177/2165079918800509.
- [106] GOEL, A., VIDAL, T. “Hours of Service Regulations in Road Freight Transport: An Optimization-Based International Assessment”, *Transportation Science*, v. 48, n. 3, pp. 391–412, ago. 2014. doi: 10.1287/trsc.2013.0477. Disponível em: <<https://doi.org/10.1287/trsc.2013.0477>>.
- [107] FMCSA, F. M. C. S. A. “Regulations and Interpretations - Part 395: Hours of Service of Drivers”. 2021.
- [108] OF CANADA, G. “Commercial Vehicle Drivers Hours of Service Regulations (SOR/2005-313)”. 2021.
- [109] RANCOURT, M.-E., CORDEAU, J.-F., LAPORTE, G. “Long-Haul Vehicle Routing and Scheduling with Working Hour Rules”, *Transportation Science*, v. 47, pp. 81–107, 2 2013. ISSN: 0041-1655. doi: 10.1287/trsc.1120.0417. Disponível em: <<http://pubsonline.informs.org/doi/10.1287/trsc.1120.0417>>.
- [110] BAI, T., LI, Y., JOHANSSON, K. H., et al. “Rollout-Based Charging Strategy for Electric Trucks with Hours-of-Service Regulations”, *IEEE Control Systems Letters*, 2023. ISSN: 24751456. doi: 10.1109/LCSYS.2023.3285137.
- [111] ALBIŃSKI, S., CRAINIC, T. G., MINNER, S. “The Day-before Truck Platooning Planning Problem and the Value of Autonomous Driving”, *CIRRELT*, pp. 1–37, 2020. Disponível em: <www.log.wi.tum.de>.
- [112] SCHOLL, J., BOYSEN, N., SCHOLL, A. “E-platooning: Optimizing platoon formation for long-haul transportation with electric commercial vehicles”, *European Journal of Operational Research*, v. 304, pp. 525–542, 1 2023. ISSN: 03772217. doi: 10.1016/j.ejor.2022.04.013. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0377221722003113>>.
- [113] MIRHASSANI, S. A., EBRAZI, R. “A Flexible Reformulation of the Refueling Station Location Problem”, *Transportation Science*, v. 47, pp. 617–628, 11 2013. ISSN: 0041-1655. doi: 10.1287/trsc.1120.0430. Disponível em: <<http://pubsonline.informs.org/doi/10.1287/trsc.1120.0430>>.

- [114] YILDIZ, B., KARAŞAN, O. E. “Regenerator Location Problem in Flexible Optical Networks”, *Operations Research*, v. 65, pp. 595–620, 6 2017. ISSN: 0030-364X. doi: 10.1287/opre.2016.1587. Disponível em: <<http://pubsonline.informs.org/doi/10.1287/opre.2016.1587>>.
- [115] ARSLAN, O., KARAŞAN, O. E., MAHJOUR, A. R., et al. “A Branch-and-Cut Algorithm for the Alternative Fuel Refueling Station Location Problem with Routing”, *Transportation Science*, v. 53, pp. 1107–1125, 7 2019. ISSN: 0041-1655. doi: 10.1287/trsc.2018.0869.
- [116] YILDIZ, B., ARSLAN, O., KARAŞAN, O. E. “A branch and price approach for routing and refueling station location model”, *European Journal of Operational Research*, v. 248, pp. 815–826, 2 2016. ISSN: 03772217. doi: 10.1016/j.ejor.2015.05.021.
- [117] DYK, M. V., KOENEMANN, J. “Dynamic discretization discovery under hard node storage constraints”. 3 2023. Disponível em: <<http://arxiv.org/abs/2303.01419>>.
- [118] BOLAND, N., HEWITT, M., MARSHALL, L., et al. “The continuous-time service network design problem”, *Operations Research*, v. 65, pp. 1303–1321, 9 2017. ISSN: 15265463. doi: 10.1287/opre.2017.1624.
- [119] SIMCHI-LEVI, D., BERMAN, O. “A Heuristic Algorithm for the Traveling Salesman Location Problem on Networks”, *Operations Research*, v. 36, pp. 478–484, 6 1988. ISSN: 0030-364X. doi: 10.1287/opre.36.3.478. Disponível em: <<https://pubsonline.informs.org/doi/10.1287/opre.36.3.478>>.
- [120] WANG, L., ZHOU, B. “Optimal Planning of Electric Vehicle Fast-Charging Stations Considering Uncertain Charging Demands via Dantzig-Wolfe Decomposition”, *Sustainability*, v. 15, n. 8, 2023. ISSN: 2071-1050. doi: 10.3390/su15086588. Disponível em: <<https://www.mdpi.com/2071-1050/15/8/6588>>.
- [121] LIU, H., LI, Y., ZHANG, C., et al. “Electric Vehicle Charging Station Location Model considering Charging Choice Behavior and Range Anxiety”, *Sustainability*, v. 14, n. 7, 2022. ISSN: 2071-1050. doi: 10.3390/su14074213. Disponível em: <<https://www.mdpi.com/2071-1050/14/7/4213>>.
- [122] AL-HANAHI, B., AHMAD, I., HABIBI, D., et al. “Charging Infrastructure for Commercial Electric Vehicles: Challenges and Future Works”, *IEEE Access*, v. 9, pp. 121476–121492, 2021. doi: 10.1109/ACCESS.2021.3108817.

- [123] PLAZA, C. V., GUIMARÃES, V. D. A., SKRODER, G. C., et al. “Localização de Centro de Integração Logística Considerando Critérios Econômicos e Ambientais: aplicação ao transporte de soja no Brasil”. In: *33^o Congresso de Pesquisa e Ensino em Transporte da ANPET*, pp. 2406–2417, Balneário Camboriú - SC, 2019. ANPET.
- [124] PLAZA, C. V., GUIMARÃES, V. D. A., RIBEIRO, G., et al. “Economic and environmental location of logistics integration centers: the Brazilian soybean transportation case”, *Top*, v. 28, n. 3, pp. 749–771, 2020. ISSN: 18638279. doi: 10.1007/s11750-020-00566-x.
- [125] PLAZA, C. V., RIBEIRO, G. M., BAHIENSE, L. “Localização de Centros de Integração Logística (CIL): aplicação de uma abordagem multiperíodo considerando critérios econômicos e ambientais”, *Anais do 34^o Congresso de Pesquisa e Ensino em Transportes*, pp. 1724–1735, 2020. ANPET, 100% Digital.
- [126] PLAZA, C. V., RIBEIRO, G. M., BAHIENSE, L., et al. “Localização de Centros de Integração Logística (CIL): método heurístico para a resolução do modelo multiperíodo”. In: *35^o Congresso de Pesquisa e Ensino em Transporte da ANPET*, pp. 1379–1390, 100
- [127] AIEX, R. M., RESENDE, M. G., RIBEIRO, C. C. “TTT plots: A perl program to create time-to-target plots”, *Optimization Letters*, v. 1, n. 4, pp. 355–366, 2007. ISSN: 18624472. doi: 10.1007/s11590-006-0031-4.
- [128] REYES, A., RIBEIRO, C. C. “Extending time-to-target plots to multiple instances”, *International Transactions in Operational Research*, v. 25, n. 5, pp. 1515–1536, 2018. ISSN: 14753995. doi: 10.1111/itor.12507.

Apêndice A

Modelos Matemáticos de Problema de Localização de CILs

Apresenta-se, neste Apêndice, os modelos matemáticos de localização-alocação de CILs presentes na literatura e que embasaram o desenvolvimento desta tese, conforme descrito na Seção 2.1.1.

A.1 CILs como pontos concentradores de carga

O primeiro modelo matemático aderente ao contexto da localização-alocação de CILs foi proposto por COSTA [2]. O modelo de Programação Linear Inteira Mista (PLIM) proposto é expresso por (A.1)–(A.9). Este modelo tem como objetivo identificar, quantificar e localizar os CILs de forma a minimizar os custos de transportes entre as zonas de produção e de consumo de diferentes produtos, considerando a integração modal e os investimentos necessários. Os conjuntos e índices deste modelo estão apresentados na Tabela A.1. Já os parâmetros do modelo e as variáveis de decisão estão apresentadas, respectivamente, na Tabela A.2 e Tabela A.3.

Tabela A.1: Conjuntos e índices do modelo matemático proposto por COSTA [2].

Notação	Descrição
P	Conjunto de produtos (<i>commodities</i>), onde $p \in P$
I	Conjunto de pontos de produção, onde $i \in I$
J	Conjunto de pontos de consumo, onde $j \in J$
K	Conjunto de pontos concentradores de carga (CILs), onde $k \in K$
M_{pi}^{dir}	Conjunto dos possíveis modos utilizados para transportar diretamente o produto p a partir do ponto de produção i para qualquer ponto consumidor j
M_{pi}^{ent}	Conjunto dos possíveis modos utilizados para transportar o produto p a partir do ponto de produção i para qualquer ponto concentrador k
M_{pk}^{sai}	Conjunto dos possíveis modos utilizados para transportar o produto p a partir do ponto concentrador k para qualquer ponto de demanda j

Tabela A.2: Parâmetros do modelo matemático proposto por COSTA [2].

Notação	Descrição
C_{pijm}^{dir}	Custo unitário de transporte do produto $p \in P$, demandado por $j \in J$, atendido por $i \in I$ de maneira direta
C_{pikm}^{ent}	Custo unitário para transportar o produto $p \in P$ embarcado na zona de produção $i \in I$ até o CIL $k \in K$ pelo modo de transporte $m \in M_{pi}^{ent}$
C_{pkjm}^{sai}	Custo unitário para transportar o produto $p \in P$ embarcado no CIL $k \in K$ até a zona de consumo $j \in J$, pelo modo de transporte $m \in M_{pk}^{sai}$
CT_{pkjm}^{sai}	Custo do(s) transbordo(s) do produto $p \in P$ entre o CIL $k \in K$ e a zona de consumo $j \in J$, para o modo $m \in M_{pk}^{sai}$ no período $t \in T$
g_{pk}	Custo fixo (aluguel) de utilização do CIL $k \in K$ pelo produto $p \in P$
v_{pk}	Custo variável de utilização do CIL $k \in K$ pelo produto $p \in P$
V_k^{min}	Volume mínimo para abertura do CIL
V_k^{max}	Volume máximo para abertura do CIL
P_{pi}	Capacidade de produção do produto $p \in P$ no ponto de produção $i \in I$
D_{pj}	Demanda pelo produto $p \in P$ no ponto de consumo $j \in J$

$$\begin{aligned}
\text{Minimize } (v_{CILs} - \text{Costa}) = & \sum_{p \in P} \sum_{i \in I} \sum_{j \in J} \sum_{m \in M_{pi}^{dir}} C_{pijm}^{dir} x_{pijm}^{dir} \\
& + \sum_{p \in P} \sum_{i \in I} \sum_{k \in K} \sum_{m \in M_{pi}^{ent}} C_{pikm}^{ent} x_{pikm}^{ent} \\
& + \sum_{p \in P} \sum_{k \in K} \left(g_{pk} z_k + v_{pk} \sum_{i \in I} \sum_{m \in M_{pi}^{ent}} x_{pikm}^{ent} \right) \\
& + \sum_{p \in P} \sum_{k \in K} \sum_{j \in J} \sum_{m \in M_{pk}^{sai}} (C_{pkjm}^{sai} + CT_{pkjm}^{sai}) x_{pkjm}^{sai}
\end{aligned} \tag{A.1}$$

Sujeito a:

$$\sum_{k \in K} \sum_{m \in M_{pi}^{ent}} x_{pikm}^{ent} + \sum_{j \in J} \sum_{m \in M_{pi}^{dir}} x_{pijm}^{dir} \leq P_{pi} \quad \forall p \in P, i \in I \tag{A.2}$$

$$V_k^{min} z_k \leq \sum_{p \in P} \sum_{i \in I} \sum_{m \in M_{pi}^{ent}} x_{pikm}^{ent} \leq V_k^{max} z_k \quad \forall k \in K \tag{A.3}$$

$$\sum_{i \in I} \sum_{m \in M_{pi}^{ent}} x_{pikm}^{ent} = \sum_{j \in J} \sum_{m \in M_{pk}^{sai}} x_{pkjm}^{sai} \quad \forall k \in K, p \in P \tag{A.4}$$

$$\sum_{k \in K} \sum_{m \in M_{pk}^{sai}} x_{pkjm}^{sai} + \sum_{i \in I} \sum_{m \in M_{pi}^{dir}} x_{pijm}^{dir} = D_{pj} \quad \forall p \in P, j \in J \tag{A.5}$$

$$x_{pijm}^{dir} \geq 0 \quad \forall p \in P, i \in I, j \in J, m \in M_{pi}^{dir} \tag{A.6}$$

$$x_{pikm}^{ent} \geq 0 \quad \forall p \in P, i \in I, k \in K, m \in M_{pi}^{ent} \tag{A.7}$$

$$x_{pkjm}^{sai} \geq 0 \quad \forall p \in P, k \in K, j \in J, m \in M_{pk}^{sai} \tag{A.8}$$

$$z_k \in \{0, 1\} \quad \forall k \in K \tag{A.9}$$

Tabela A.3: Variáveis de decisão do modelo matemático proposto por COSTA [2].

Notação	Descrição
x_{pijm}^{dir}	Volume do produto $p \in P$ transportado diretamente do ponto de produção $i \in I$ até o ponto de consumo $j \in J$ pelo modo $m \in M_{pi}^{dir}$
x_{pikm}^{ent}	Volume de produto $p \in P$ transportado do ponto de produção $i \in I$ até o ponto concentrador (candidato a CIL) $k \in K$ pelo modo $m \in M_{pi}^{ent}$ (fluxo de entrada no ponto concentrador)
x_{pkjm}^{sai}	Volume de produto $p \in P$ transportado do ponto concentrador (candidato a CIL) $k \in K$ até o ponto de consumo $j \in J$ pelo modo $m \in M_{pk}^{sai}$ (fluxo de saída do ponto concentrador)
z_k	Variável binária que indica se o ponto concentrador $k \in K$ deve ser aberto ou não

A função objetivo (A.1) busca minimizar os custos de transportes e transbordo além dos custos fixos e variáveis da utilização dos CILs. As restrições (A.2) garantem que todo o volume do produto p enviado de cada ponto de produção i não exceda sua capacidade de produção. As restrições (A.3) estabelecem os volumes mínimos e máximos (capacidade) para a abertura dos CILs. As restrições (A.4) define a conservação dos fluxos, garantindo que todo fluxo de produtos que entra em um ponto concentrador seja igual ao fluxo de produtos que sai deste. As restrições (A.5) garantem o atendimento da demanda de cada produto p em cada zona de consumo j . Por fim, as restrições (A.6) a (A.9) estão relacionadas ao domínio das variáveis.

A.2 Atendimento da demanda par-a-par

GUIMARÃES [8] sugeriu adequações ao modelo matemático proposto por COSTA [2] visando garantir o atendimento das demandas par-a-par, resultando no modelo matemático (A.10)-(A.18).

A função objetivo (A.10) também busca minimizar os custos de transportes entre as zonas de produção e de consumo de diferentes produtos, considerando a integração modal e os investimentos necessários, bem como proposto inicialmente por COSTA [2]. Desta forma, a função objetivo manteve-se semelhante. As restrições (A.14), (A.16)-(A.18) também são semelhantes ao modelo inicial, equivalentes às restrições (A.3), (A.6)-(A.9) respectivamente.

As restrições (A.11)-(A.13) e (A.13) buscam garantir, em conjunto, a demanda par-a-par e substituem as restrições (A.2), (A.4) e (A.5) do modelo inicial. Para tornar possível o controle das origens e destinos dos fluxos que passam por um CIL, foi inserida uma nova variável de decisão, Y_{ipkj} , capaz de representar o volume de produto $p \in P$ transportado de $i \in I$ para $j \in J$ que utiliza o CIL $k \in K$. Os conjuntos e índices, parâmetros e demais variáveis de decisão podem ser consultados,

respectivamente, na Tabela A.1, Tabela A.2 e Tabela A.3).

As restrições (A.11) garantem o atendimento da demanda por um determinado produto de cada ponto de consumo (d_{pij}), seja por transporte direto entre a zona de produção e a de consumo ou passando pelo CIL.

As restrições (A.12) garantem que toda a quantidade o produto $p \in P$ com origem na zona de produção $i \in I$ para a zona de consumo $j \in J$ passando pelo CIL $k \in K$ seja exatamente igual a toda a quantidade de produto $p \in P$ com origem na zona de produção $i \in I$ que entra no CIL $k \in K$. As restrições (A.13) garantem que toda a quantidade o produto $p \in P$ com origem na zona de produção $i \in I$ para a zona de consumo $j \in J$ passando pelo CIL $k \in K$ seja exatamente igual a toda a quantidade de produto $p \in P$ com destino à zona de produção $j \in J$ que sai do CIL $k \in K$. Assim, todo fluxo que entra e sai em um CIL já possui uma destinação.

$$\begin{aligned}
\text{Minimize } (\nu_{\text{CILs}}) = & \\
& \sum_{p \in P} \sum_{i \in I} \sum_{j \in J} \sum_{m \in M_{pi}^{\text{dir}}} C_{pijm}^{\text{dir}} x_{pijm}^{\text{dir}} \\
& + \sum_{p \in P} \sum_{i \in I} \sum_{k \in K} \sum_{m \in M_{pk}^{\text{sai}}} C_{pikm}^{\text{sai}} x_{pikm}^{\text{ent}} \\
& + \sum_{p \in P} \sum_{k \in K} \left(g_{pk} z_k + v_{pk} \sum_{i \in I} \sum_{m \in M_{pi}^{\text{ent}}} x_{pikm}^{\text{ent}} \right) \\
& + \sum_{p \in P} \sum_{k \in K} \sum_{j \in J} \sum_{m \in M_{pk}^{\text{sai}}} (C_{pkjm}^{\text{sai}} + CT_{pkjm}^{\text{sai}}) x_{pkjm}^{\text{sai}}
\end{aligned} \tag{A.10}$$

Sujeito a:

$$\sum_{m \in M_{pij}^{dir}} x_{pijm}^{dir} + \sum_{k \in K} Y_{pikj} = d_{pij} \quad \forall p \in P, i \in I, j \in J \quad (\text{A.11})$$

$$\sum_{j \in J} Y_{ipkj} = \sum_{m \in M_{pi}^{ent}} x_{pikm}^{ent} \quad \forall i \in I, p \in P, k \in K \quad (\text{A.12})$$

$$\sum_{i \in I} Y_{ipkj} = \sum_{m \in M_{pk}^{sai}} x_{pkjm}^{sai} \quad \forall j \in J, p \in P, k \in K \quad (\text{A.13})$$

$$V_k^{min} z_k \leq \sum_{p \in P} \sum_{i \in I} \sum_{m \in M_{pi}^{ent}} x_{pikm}^{ent} \leq V_k^{max} z_k \quad \forall k \in K \quad (\text{A.14})$$

$$Y_{ipkj} \geq 0 \quad \forall i \in I, k \in K, j \in J \quad (\text{A.15})$$

$$x_{pijm}^{dir} \geq 0 \quad \forall p \in P, i \in I, j \in J, m \in M_{pi}^{dir} \quad (\text{A.16})$$

$$x_{pikm}^{ent} \geq 0 \quad \forall p \in P, i \in I, k \in K, m \in M_{pi}^{ent} \quad (\text{A.17})$$

$$x_{pkjm}^{sai} \geq 0 \quad \forall p \in P, k \in K, j \in J, m \in M_{pk}^{sai} \quad (\text{A.18})$$

$$z_k \in \{0, 1\} \quad \forall k \in K \quad (\text{A.19})$$

GUIMARÃES [8] propõe, ainda, duas restrições que podem ser adicionadas ao modelo como segue:

- Caso deseja-se limitar os investimentos financeiros em abertura de CILs, devido à restrições orçamentárias, pode-se adicionar as restrições (A.20), onde: F é o valor máximo (ou total) de recursos disponíveis para investimentos em CILs.
- Caso deseja-se limitar a quantidade de CILs abertos, não por questões orçamentárias, mas por definições prévias de número máximo de estruturas que se deseja instalar, pode-se adicionar as restrições (A.21), onde \bar{p} representa o número máximo de CILs a serem abertos.

$$\sum_{k \in K} g_{pk} z_k \leq F \quad \forall k \in K \quad (\text{A.20})$$

$$\sum_{k \in K} z_k \leq \bar{p} \quad \forall k \in K \quad (\text{A.21})$$

A.3 Incorporação de aspectos ambientais

Uma vez que este modelo matemático é uma evolução dos modelos proposto por COSTA [2] e GUIMARÃES [8], apresenta-se, na Tabela A.4, os conjuntos, índices e parâmetros equivalentes aos anteriormente apresentados (complementarmente, ver Tabela A.1, Tabela A.2 e Tabela A.3) e, na Tabela A.5, apresenta-se os parâmetros inseridos no modelo para incorporação da emissão de CO_2 .

Tabela A.4: Equivalência entre os parâmetros do modelo proposto por GUIMARÃES [3] e COSTA [2].

Notação GUIMARÃES [3]	Notação equivalente COSTA [2]
Conjuntos e índices	
M_{pij}^{dir}	M_{ij}^{dir}
M_{pik}^{ent}	M_{pk}^{ent}
M_{pkj}^{sai}	M_{pkj}^{sai}
Parâmetros	
θ_{pk}	u_{pk}

Tabela A.5: Parâmetros do modelo proposto por GUIMARÃES [3].

Notação	Descrição
α	Peso associado à dimensão econômica
β	Peso associado à dimensão ambiental
C_c	Custo associado às emissões de CO_2
$f e_m$	Fator de emissão do combustível usado pela alternativa de transporte $m \in M_{pij}^{dir}$, $m \in M_{pik}^{ent}$ and $m \in M_{pkj}^{sai}$
dt_{pijm}	Distância percorrida pela alternativa de transporte $m \in M_{pij}^{dir}$ entre as zonas de produção $i \in I$ e consumo $j \in J$ do produto $p \in P$
dt_{pikm}	Distância percorrida pela alternativa de transporte $m \in M_{pik}^{ent}$ entre a zona de produção $i \in I$ e o candidato a CIL $k \in K$ do produto $p \in P$
dt_{pkjm}	Distância percorrida pela alternativa de transporte $m \in M_{pkj}^{sai}$ entre o candidato a CIL $k \in K$ e a zona de consumo $j \in J$ do produto $p \in P$

$$\begin{aligned}
\text{Minimize } \alpha \left[\mathcal{Z}(C_{\text{logísticos}}) = \sum_{p \in P} \sum_{i \in I} \sum_{j \in J} \sum_{m \in M_{pij}^{dir}} C_{pijm}^{dir} x_{pijm}^{dir} \right. \\
+ \sum_{p \in P} \sum_{i \in I} \sum_{k \in K} \sum_{m \in M_{pik}^{ent}} C_{pikm}^{ent} x_{pikm}^{ent} \\
+ \sum_{p \in P} \sum_{k \in K} \left(g_k z_k + \theta_k \sum_{j \in J} \sum_{m \in M_{pkj}^{sai}} x_{pkjm}^{sai} \right) \\
\left. + \sum_{p \in P} \sum_{k \in K} \sum_{j \in J} \sum_{m \in M_{pkj}^{sai}} (C_{pkjm}^{sai} + CT_{pkjm}^{sai}) x_{pkjm}^{sai} \right] \quad (\text{A.22}) \\
+ \beta C_{CO_2} \left[\mathcal{Z}(\text{emissões}) = \sum_{p \in P} \sum_{i \in I} \sum_{j \in J} \sum_{m \in M_{pij}^{dir}} f e_m dt_{pijm} x_{pijm}^{dir} \right. \\
+ \sum_{p \in P} \sum_{i \in I} \sum_{k \in K} \sum_{m \in M_{pik}^{ent}} f e_m dt_{pikm} x_{pikm}^{ent} \\
\left. + \sum_{p \in P} \sum_{k \in K} \sum_{j \in J} \sum_{m \in M_{pkj}^{sai}} f e_m dt_{pkjm} x_{pkjm}^{sai} \right]
\end{aligned}$$

Sujeito a: Restrições (A.11)-(A.19)

O primeiro termo da função objetivo (A.22) ($\mathcal{Z}(C_{\text{logísticos}})$) busca minimizar os custos logísticos totais da rede através da alocação dos fluxos diretamente entre as zonas de produção e consumo ou através dos CILs que forem abertos. São considerados os custos de transporte e, para as facilidades abertas, os custos de abertura (fixos), operacionais (variáveis) e de transbordo. O segundo termo ($C_{CO_2}\mathcal{Z}(\text{emissões})$) busca minimizar os custos de emissão de CO_2 relacionados ao transporte do produto (modo rodoviário, se direto; ou multimodal, quando através de CILs). As emissões ambientais são expressas em valores monetários, uma vez que as emissões podem ser taxadas (como, por exemplo, através de políticas de carbono tax). O modelo não considera as emissões provenientes da abertura e operação das estruturas de integração, tendo em vista que a única atividade nela desenvolvida é o transbordo.

A função objetivo possui os pesos α e β associados, respectivamente, aos custos logísticos e ambientais. Estes pesos podem ser utilizados para definir o grau de importância de cada termo no processo de planejamento do setor de transporte.

A.4 Modelo Multiperíodo

A partir do modelo de GUIMARÃES [8] e de suas características previamente estabelecidas, MT [22] apresentou o modelo matemático multiperíodo (A.23)-(A.33) capaz de determinar em qual recorte temporal os CILs devem ser abertos, isto é, capaz de prever o momento em que um CIL será aberto em uma escala temporal. Para isto, foi inserido o índice $t \in T$, denotando o período de tempo que cada uma das variáveis, coeficientes e constantes do modelo se refere.

As restrições (A.28) garantem que cada candidato a CIL $k \in K$ seja aberto apenas em um período, mantendo-se aberto nos períodos subsequentes. Já o termo $\sum_{\theta=1}^t z_{\theta k}$ presente nas Restrições (A.27) garante que, após a abertura de um CIL em um período t , este se manterá aberto até o último período de tempo em análise.

$$\begin{aligned}
\text{Minimize } (\nu_{\text{CILs}}\text{-Multiperíodo}) = & \\
& \sum_{t \in T} \sum_{p \in P} \sum_{i \in I} \sum_{j \in J} \sum_{m \in M_{pi}^{dir}} C_{tpijm}^{dir} x_{tpijm}^{dir} \\
& + \sum_{t \in T} \sum_{p \in P} \sum_{i \in I} \sum_{k \in K} \sum_{m \in M_{pi}^{ent}} C_{tpikm}^{ent} x_{tpikm}^{ent} \\
& + \sum_{t \in T} \sum_{p \in P} \sum_{k \in K} \left(g_{tpk} z_{tk} + v_{tpk} \sum_{j \in J} \sum_{m \in M_{pk}^{sai}} x_{tpkjm}^{sai} \right) \\
& + \sum_{t \in T} \sum_{p \in P} \sum_{k \in K} \sum_{j \in J} \sum_{m \in M_{pk}^{sai}} (C_{tpkjm}^{sai} + CT_{tpkjm}^{sai}) x_{tpkjm}^{sai}
\end{aligned} \tag{A.23}$$

Sujeito a:

$$\sum_{m \in M_{pij}^{dir}} x_{tpijm}^{dir} + \sum_{k \in K} Y_{tpikj} = d_{tpij} \quad \forall t \in T, p \in P, i \in I, j \in J \quad (\text{A.24})$$

$$\sum_{j \in J} Y_{tpikj} = \sum_{m \in M_{pi}^{ent}} x_{tpikm}^{ent} \quad \forall t \in T, i \in I, p \in P, k \in K \quad (\text{A.25})$$

$$\sum_{i \in I} Y_{tpikj} = \sum_{m \in M_{pk}^{sai}} x_{tpkjm}^{sai} \quad \forall t \in T, j \in J, p \in P, k \in K \quad (\text{A.26})$$

$$V_{tk}^{min} \sum_{\theta=1}^t z_{\theta k} \leq \sum_{p \in P} \sum_{i \in I} \sum_{m \in M_{pi}^{ent}} x_{tpikm}^{ent} \leq V_{tk}^{max} \sum_{\theta=1}^t z_{\theta k} \quad \forall t \in T, k \in K \quad (\text{A.27})$$

$$\sum_{t \in T} z_{tk} = 1 \quad \forall k \in K \quad (\text{A.28})$$

$$Y_{tpikj} \geq 0 \quad \forall t \in T, p \in P, i \in I, k \in K, j \in J \quad (\text{A.29})$$

$$x_{tpijm}^{dir} \geq 0 \quad \forall t \in T, p \in P, i \in I, j \in J, m \in M_{pi}^{dir} \quad (\text{A.30})$$

$$x_{tpikm}^{ent} \geq 0 \quad \forall t \in T, p \in P, i \in I, k \in K, m \in M_{pi}^{ent} \quad (\text{A.31})$$

$$x_{tpkjm}^{sai} \geq 0 \quad \forall t \in T, p \in P, k \in K, j \in J, m \in M_{pk}^{sai} \quad (\text{A.32})$$

$$z_{tk} \in \{0, 1\} \quad \forall t \in T, k \in K \quad (\text{A.33})$$

Os modelos presentes na literatura e aqui descritos apresentam grande complexidade e estão correlacionados. Verifica-se que o modelo multiperíodo considera parte da evolução dos conhecimentos desenvolvidos para os modelos de localização-alocação de CILs, tornando-se mais aderentes à realidade e aprimorando os passos metodológicos. No entanto, este modelo ainda não considera os parâmetros para avaliação da emissão de CO_2 na minimização. Como limitação do modelo multiperíodo, MT [22] destaca a alta complexidade do modelo e que a formulação matemática requer um tempo computacional excessivo para ser solucionada, sendo indicadas técnicas específicas de otimização.

Apêndice B

Matrizes OD da soja em grãos consolidadas por região do IBGE

Este apêndice tem por objetivo apresentar as matrizes OD da soja em grãos, produto selecionado para aplicação do modelo matemático de PMLCIL proposto nesta tese. As Tabelas B.1 apresentam os volumes de produção e consumo dos produtos milho, soja, farelo de soja e açúcar.

B.1 Soja em grãos

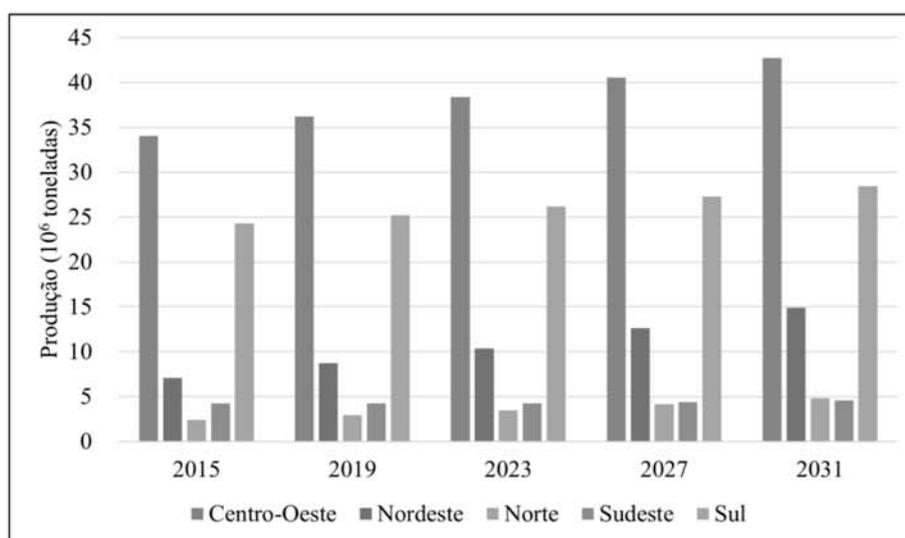


Figura B.1: Produção da soja entre as regiões brasileiras para cada horizonte de análise (em 10⁶ toneladas).

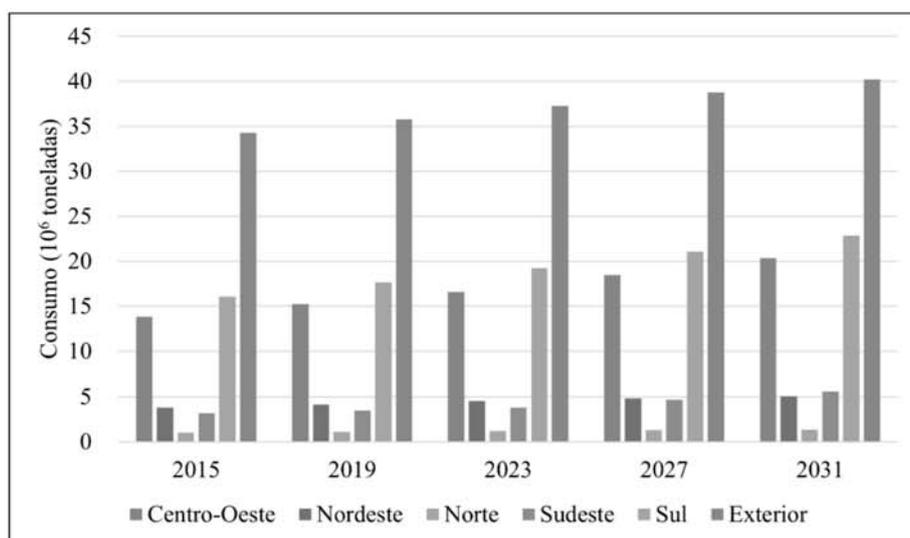


Figura B.2: Consumo da soja entre as regiões brasileiras para cada horizonte de análise (em 10^6 toneladas).

Tabela B.1: Matriz OD da soja (em toneladas)

Horizonte	Fonte	O \ D	Centro-Oeste	Nordeste	Norte	Sudeste	Sul	Exterior	Total	
2015	Disponível no PNLTL	Centro-Oeste	13.479.860	0	654.010	1.733.400	2.763.100	15.435.360	34.065.730	
		Nordeste	43.580	3.601.960	50.210	49.660	0	3.359.990	7.105.400	
		Norte	39.180	188.060	293.220	0	0	0	1.882.990	2.403.450
		Sudeste	295.910	0	0	1.150.110	259.140	0	2.560.430	4.265.590
		Sul	0	0	0	229.000	13.036.280	11.024.560	0	24.289.840
	Total	13.858.530	3.790.020	997.440	3.162.170	16.058.520	34.263.330	0	72.130.010	
2019	Regressão linear a partir das matrizes de 2015 e 2023	Centro-Oeste	14.797.135	0	707.690	1.940.020	3.039.390	15.734.805	36.219.040	
		Nordeste	65.435	3.975.750	58.335	77.015	0	4.569.195	8.745.730	
		Norte	46.640	192.075	330.300	0	0	0	2.366.965	2.935.980
		Sudeste	322.480	0	0	1.203.410	279.950	0	2.450.595	4.256.435
		Sul	0	0	0	255.075	14.330.310	10.646.755	0	25.232.140
	Total	15.231.690	4.167.825	1.096.325	3.475.520	17.649.650	35.768.315	0	77.389.325	
2023	Disponível no PNLTL	Centro-Oeste	16.114.410	0	761.370	2.146.640	3.315.680	16.034.250	38.372.350	
		Nordeste	87.290	4.349.540	66.460	104.370	0	5.778.400	10.386.060	
		Norte	54.100	196.090	367.380	0	0	0	2.850.940	3.468.510
		Sudeste	349.050	0	0	1.256.710	300.760	0	2.340.760	4.247.280
		Sul	0	0	0	281.150	15.624.340	10.268.950	0	26.174.440
	Total	16.604.850	4.545.630	1.195.210	3.788.870	19.240.780	37.273.300	0	82.648.640	
2027	Regressão linear a partir das matrizes de 2023 e 2027	Centro-Oeste	17.895.580	0	781.595	2.664.415	3.616.160	15.588.715	40.546.465	
		Nordeste	119.175	4.605.665	81.340	159.030	0	7.667.220	12.632.430	
		Norte	67.715	194.390	421.610	0	0	0	3.451.975	4.135.690
		Sudeste	394.840	0	0	1.456.835	329.230	0	2.223.985	4.404.890
		Sul	0	0	0	401.780	17.103.765	9.807.915	0	27.313.460
	Total	18.477.310	4.800.055	1.284.545	4.682.060	21.049.155	38.739.810	0	89.032.935	
2031	Disponível no PNLTL	Centro-Oeste	19.676.750	0	801.820	3.182.190	3.916.640	15.143.180	42.720.580	
		Nordeste	151.060	4.861.790	96.220	213.690	0	9.556.040	14.878.800	
		Norte	81.330	192.690	475.840	0	0	0	4.053.010	4.802.870
		Sudeste	440.630	0	0	1.656.960	357.700	0	2.107.210	4.562.500
		Sul	0	0	0	522.410	18.583.190	9.346.880	0	28.452.480
	Total	20.349.770	5.054.480	1.373.880	5.575.250	22.857.530	40.206.320	0	95.417.230	

Apêndice C

Microrregiões candidatas

Este apêndice tem por objetivo listar as informações das microrregiões candidatas a receberem a infraestrutura de CILs e ilustrado na Figura 2.15. São descritos na Tabela C.1 o código, segundo o PNLT, a microrregião, a unidade federativa (UF) e a região de localização.

Tabela C.1: Microrregiões candidatas para instalação de CIL.

Código	Microrregião	UF	Região
17002	Araguaína	TO	Norte
17003	Miracema do Tocantins	TO	Norte
17004	Rio Formoso	TO	Norte
17005	Gurupi	TO	Norte
17006	Porto Nacional	TO	Norte
17008	Dianópolis	TO	Norte
21009	Imperatriz	MA	Nordeste
21018	Chapadas do Alto Itapecuru	MA	Nordeste
21020	Gerais de Balsas	MA	Nordeste
22007	Alto Parnaíba Piauiense	PI	Nordeste
29001	Barreiras	BA	Nordeste
29003	Santa Maria da Vitoria	BA	Nordeste
31001	Unai	MG	Sudeste
31017	Ituiutaba	MG	Sudeste
31018	Uberlândia	MG	Sudeste
31022	Uberaba	MG	Sudeste
31023	Araxá	MG	Sudeste
35004	São José do Rio Preto	SP	Sudeste
35009	Barretos	SP	Sudeste
35010	São Joaquim da Barra	SP	Sudeste
35011	Ituverava	SP	Sudeste
35013	Jaboticabal	SP	Sudeste
35014	Ribeirão Preto	SP	Sudeste
35018	Birigui	SP	Sudeste
35021	Jau	SP	Sudeste

Continua na próxima página.

Tabela C.1 - Microrregiões candidatas para instalação de
CIL (continuação).

Código	Microrregião	UF	Região
35022	Avaré	SP	Sudeste
35024	Araraquara	SP	Sudeste
35036	Presidente Prudente	SP	Sudeste
35039	Assis	SP	Sudeste
35040	Ourinhos	SP	Sudeste
35041	Itapeva	SP	Sudeste
35046	Sorocaba	SP	Sudeste
41005	Campo Mourão	PR	Sul
41009	Maringá	PR	Sul
41011	Londrina	PR	Sul
41015	Cornélio Procópio	PR	Sul
41019	Telêmaco Borba	PR	Sul
41021	Ponta Grossa	PR	Sul
41022	Toledo	PR	Sul
41024	Foz do Iguaçu	PR	Sul
41026	Francisco Beltrão	PR	Sul
41027	Pato Branco	PR	Sul
41029	Guarapuava	PR	Sul
41037	Curitiba	PR	Sul
42002	Chapecó	SC	Sul
42003	Xanxerê	SC	Sul
42004	Joaçaba	SC	Sul
43004	Erechim	RS	Sul
43007	Santo Ângelo	RS	Sul
43008	Ijuí	RS	Sul
43009	Carazinho	RS	Sul
43010	Passo Fundo	RS	Sul
43011	Cruz Alta	RS	Sul
43017	Santiago	RS	Sul
43035	Litoral Lagunar	RS	Sul
50004	Campo Grande	MS	Centro-Oeste
50005	Cassilândia	MS	Centro-Oeste
50010	Dourados	MS	Centro-Oeste
50011	Iguatemi	MS	Centro-Oeste
51001	Aripuanã	MT	Centro-Oeste
51002	Alta Floresta	MT	Centro-Oeste
51004	Parecis	MT	Centro-Oeste
51006	Alto Teles Pires	MT	Centro-Oeste
51009	Norte Araguaia	MT	Centro-Oeste
51010	Canarana	MT	Centro-Oeste
51017	Cuiabá	MT	Centro-Oeste
51020	Tesouro	MT	Centro-Oeste
51021	Rondonópolis	MT	Centro-Oeste

Continua na próxima página.

Tabela C.1 - Microrregiões candidatas para instalação de
CIL (continuação).

Código	Microrregião	UF	Região
51022	Alto Araguaia	MT	Centro-Oeste
52001	São Miguel do Araguaia	GO	Centro-Oeste
52002	Rio Vermelho	GO	Centro-Oeste
52004	Porangatu	GO	Centro-Oeste
52006	Ceres	GO	Centro-Oeste
52007	Anápolis	GO	Centro-Oeste
52012	Entorno de Brasília	GO	Centro-Oeste
52013	Sudoeste de Goiás	GO	Centro-Oeste
52014	Vale do Rio dos Bois	GO	Centro-Oeste
52016	Pires do Rio	GO	Centro-Oeste
52017	Catalão	GO	Centro-Oeste
52018	Quirinópolis	GO	Centro-Oeste

Apêndice D

Resultados Método Exato

Este apêndice tem por objetivo apresentar as tabelas de solução por método exato da aplicação do PDLCIL à distribuição de soja.

D.1 Quantidade de CILs abertos

A Tabela D.1 apresenta a quantidade de candidatos a CIL abertos em cada região brasileira para cada cenário e instância avaliados. A primeira e segunda coluna indicam, respectivamente, a instância e cenários avaliados. A terceira coluna, a região brasileira. A quarta coluna indica a quantidade de facilidades que não foram abertas, enquanto as colunas cinco a oito apresentam a quantidade de CILs selecionados para abertura, respectivamente, nos horizontes 2019, 2023, 2027 e 2031. A última coluna apresenta o total de facilidades abertas.

Tabela D.1: CILs abertos em cada horizonte para as diferentes instâncias de soja.

Instância	Cenário	Região	CILs					Total abertos
			Não abertos	2019	2023	2027	2031	
CO	0a	N	5	1	0	0	0	1
		NE	4	2	0	0	0	2
		SE	12	8	0	0	0	8
		S	22	1	0	0	0	1
		CO	1	24	0	0	0	24
		Total	44	36	0	0	0	36
CO	0b	N	6	0	0	0	0	0
		NE	6	0	0	0	0	0
		SE	17	3	0	0	0	3
		S	23	0	0	0	0	0
		CO	12	10	0	2	1	13
		Total	64	13	0	2	1	16

Continua na próxima página.

Tabela D.1 - CILs abertos em cada horizonte para as diferentes instâncias de soja (continuação).

Instância	Cenário	Região	CILs					Total abertos
			Não abertos	2019	2023	2027	2031	
CO	1a	N	6	0	0	0	0	0
		NE	6	0	0	0	0	0
		SE	17	3	0	0	0	3
		S	23	0	0	0	0	0
		CO	14	11	0	0	0	11
		Total	66	14	0	0	0	14
CO	1b	N	6	0	0	0	0	0
		NE	6	0	0	0	0	0
		SE	17	3	0	0	0	3
		S	23	0	0	0	0	0
		CO	16	9	0	0	0	9
		Total	68	12	0	0	0	12
CO	2a	N	6	0	0	0	0	0
		NE	6	0	0	0	0	0
		SE	19	1	0	0	0	1
		S	23	0	0	0	0	0
		CO	19	6	0	0	0	6
		Total	73	7	0	0	0	7
CO	2b	N	6	0	0	0	0	0
		NE	6	0	0	0	0	0
		SE	19	1	0	0	0	1
		S	23	0	0	0	0	0
		CO	19	6	0	0	0	6
		Total	73	7	0	0	0	7
COS	0a	N	5	1	0	0	0	1
		NE	4	2	0	0	0	2
		SE	9	11	0	0	0	11
		S	0	23	0	0	0	23
		CO	1	24	0	0	0	24
		Total	19	61	0	0	0	61
COS	0b	N	6	0	0	0	0	0
		NE	6	0	0	0	0	0
		SE	17	3	0	0	0	3
		S	8	15	0	0	0	15
		CO	13	10	0	1	1	12
		Total	50	28	0	1	1	30

Continua na próxima página.

Tabela D.1 - CILs abertos em cada horizonte para as diferentes instâncias de soja (continuação).

Instância	Cenário	Região	CILs					Total abertos
			Não abertos	2019	2023	2027	2031	
COS	1a	N	6	0	0	0	0	0
		NE	6	0	0	0	0	0
		SE	17	3	0	0	0	3
		S	11	12	0	0	0	12
		CO	15	10	0	0	0	10
		Total	55	25	0	0	0	25
COS	1b	N	6	0	0	0	0	0
		NE	6	0	0	0	0	0
		SE	17	3	0	0	0	3
		S	11	12	0	0	0	12
		CO	16	9	0	0	0	9
		Total	56	24	0	0	0	24
COS	2a	N	6	0	0	0	0	0
		NE	6	0	0	0	0	0
		SE	19	1	0	0	0	1
		S	18	5	0	0	0	5
		CO	19	6	0	0	0	6
		Total	68	12	0	0	0	12
COS	2b	N	6	0	0	0	0	0
		NE	6	0	0	0	0	0
		SE	19	1	0	0	0	1
		S	18	5	0	0	0	5
		CO	19	6	0	0	0	6
		Total	68	12	0	0	0	12
COSNE	0a	N	5	1	0	0	0	1
		NE	0	6	0	0	0	6
		SE	9	11	0	0	0	11
		S	0	23	0	0	0	23
		CO	1	24	0	0	0	24
		Total	15	65	0	0	0	65
COSNE	0b	N	6	0	0	0	0	0
		NE	1	3	1	1	0	5
		SE	17	3	0	0	0	3
		S	8	15	0	0	0	15
		CO	12	11	0	1	1	13
		Total	44	32	1	2	1	36

Continua na próxima página.

Tabela D.1 - CILs abertos em cada horizonte para as diferentes instâncias de soja (continuação).

Instância	Cenário	Região	CILs					Total abertos
			Não abertos	2019	2023	2027	2031	
COSNE	1a	N	6	0	0	0	0	0
		NE	1	5	0	0	0	5
		SE	17	3	0	0	0	3
		S	11	12	0	0	0	12
		CO	16	9	0	0	0	9
		Total	51	29	0	0	0	29
COSNE	1b	N	6	0	0	0	0	0
		NE	2	3	1	0	0	4
		SE	17	3	0	0	0	3
		S	11	12	0	0	0	12
		CO	16	9	0	0	0	9
		Total	52	27	1	0	0	28
COSNE	2a	N	6	0	0	0	0	0
		NE	4	2	0	0	0	2
		SE	18	2	0	0	0	2
		S	18	5	0	0	0	5
		CO	19	6	0	0	0	6
		Total	65	15	0	0	0	15
COSNE	2b	N	6	0	0	0	0	0
		NE	4	2	0	0	0	2
		SE	18	2	0	0	0	2
		S	18	5	0	0	0	5
		CO	19	6	0	0	0	6
		Total	65	15	0	0	0	15
COSNESE	0a	N	2	4	0	0	0	4
		NE	0	6	0	0	0	6
		SE	0	20	0	0	0	20
		S	0	23	0	0	0	23
		CO	1	24	0	0	0	24
		Total	3	77	0	0	0	77
COSNESE	0b	N	6	0	0	0	0	0
		NE	1	3	1	1	0	5
		SE	15	5	0	0	0	5
		S	9	14	0	0	0	14
		CO	12	11	0	1	1	13
		Total	43	33	1	2	1	37

Continua na próxima página.

Tabela D.1 - CILs abertos em cada horizonte para as diferentes instâncias de soja (continuação).

Instância	Cenário	Região	CILs					Total abertos
			Não abertos	2019	2023	2027	2031	
COSNESE	1a	N	6	0	0	0	0	0
		NE	1	5	0	0	0	5
		SE	16	4	0	0	0	4
		S	11	12	0	0	0	12
		CO	16	9	0	0	0	9
		Total	50	30	0	0	0	30
COSNESE	1b	N	6	0	0	0	0	0
		NE	3	2	1	0	0	3
		SE	16	4	0	0	0	4
		S	12	11	0	0	0	11
		CO	16	9	0	0	0	9
		Total	53	26	1	0	0	27
COSNESE	2a	N	6	0	0	0	0	0
		NE	5	1	0	0	0	1
		SE	17	3	0	0	0	3
		S	18	5	0	0	0	5
		CO	19	6	0	0	0	6
		Total	65	15	0	0	0	15
COSNESE	2b	N	6	0	0	0	0	0
		NE	5	1	0	0	0	1
		SE	17	3	0	0	0	3
		S	18	5	0	0	0	5
		CO	19	6	0	0	0	6
		Total	65	15	0	0	0	15
COSNESEN	0a	N	0	6	0	0	0	6
		NE	0	6	0	0	0	6
		SE	0	20	0	0	0	20
		S	0	23	0	0	0	23
		CO	1	24	0	0	0	24
		Total	1	79	0	0	0	79
COSNESEN	0b	N	3	0	2	0	1	3
		NE	1	4	0	1	0	5
		SE	15	5	0	0	0	5
		S	8	15	0	0	0	15
		CO	12	11	0	1	1	13
		Total	39	35	2	2	2	41

Continua na próxima página.

Tabela D.1 - CILs abertos em cada horizonte para as diferentes instâncias de soja (continuação).

Instância	Cenário	Região	CILs					Total abertos
			Não abertos	2019	2023	2027	2031	
COSNESEN	1a	N	5	1	0	0	0	1
		NE	1	5	0	0	0	5
		SE	16	4	0	0	0	4
		S	11	12	0	0	0	12
		CO	16	9	0	0	0	9
		Total	49	31	0	0	0	31
COSNESEN	1b	N	5	0	1	0	0	1
		NE	2	4	0	0	0	4
		SE	16	4	0	0	0	4
		S	11	12	0	0	0	12
		CO	16	9	0	0	0	9
		Total	50	29	1	0	0	30
COSNESEN	2a	N	6	0	0	0	0	0
		NE	4	2	0	0	0	2
		SE	17	3	0	0	0	3
		S	18	5	0	0	0	5
		CO	19	6	0	0	0	6
		Total	64	16	0	0	0	16
COSNESEN	2b	N	6	0	0	0	0	0
		NE	4	2	0	0	0	2
		SE	17	3	0	0	0	3
		S	18	5	0	0	0	5
		CO	19	6	0	0	0	6
		Total	64	16	0	0	0	16

D.2 Volumes operacionais em cada CIL – Instância COSNESEN

Tabela D.2: Cenário 0a (Volumes em $\times 10^6$ ton.).

Região	CIL	2019	2023	2027	2031
Norte	17002	0,576	0,718	0,936	1,074
	17003	0,210	0,276	0,343	0,409
	17004	0,261	0,396	0,492	0,589
	17005	0,027	0,025	0,026	0,027
	17006	0,271	0,241	0,312	0,382
	17008	0,047	0,059	0,063	0,054

Continua na próxima página.

Tabela D.2: Cenário 0a
(Volumes em $\times 10^6$ ton.) (continuação).

Região	CIL	2019	2023	2027	2031
Nordeste	21009	0,593	0,794	0,954	1,114
	21018	0,167	0,237	0,293	0,350
	21020	1,741	1,990	2,451	2,914
	22007	0,763	0,989	1,701	2,411
	29001	0,112	0,152	0,226	0,282
	29003	0,719	0,825	0,888	0,952
Sudeste	31001	3,641	4,320	4,956	5,417
	31017	0,138	0,117	0,134	0,147
	31018	3,047	2,855	2,607	2,358
	31022	0,885	0,994	1,002	1,062
	31023	0,341	0,342	0,363	0,383
	35004	0,074	0,073	0,071	0,101
	35009	0,270	0,247	0,213	0,183
	35010	0,063	0,057	0,045	0,032
	35011	0,075	0,080	0,075	0,073
	35013	0,007	0,007	0,006	0,004
	35014	0,051	0,047	0,048	0,047
	35018	0,050	0,049	0,049	0,049
	35021	0,014	0,014	0,015	0,015
	35022	0,082	0,083	0,089	0,095
	35024	0,006	0,006	0,006	0,006
	35036	0,072	0,071	0,071	0,071
	35039	0,440	0,445	0,461	0,472
	35040	0,266	0,271	0,283	0,303
35041	0,320	0,325	0,345	0,363	
35046	0,004	0,005	0,005	0,006	
Sul	41005	0,394	0,342	0,410	0,363
	41009	1,519	1,686	1,564	1,727
	41011	0,956	0,984	1,027	1,068
	41015	0,506	0,527	0,549	0,573
	41019	0,728	0,676	0,809	0,754
	41021	0,405	0,400	0,400	0,401
	41022	2,446	2,520	2,728	2,443
	41024	0,426	0,438	0,449	0,825
	41026	0,404	0,410	0,414	0,268
	41027	0,699	0,727	0,762	0,950
	41029	1,414	1,457	1,524	1,573
	41037	0,514	0,530	0,548	0,567
	42002	0,385	0,372	0,366	0,360
	42003	0,362	0,359	0,371	0,382
42004	0,287	0,288	0,296	0,302	
43004	0,537	0,512	0,545	0,516	
43007	0,709	0,708	0,705	0,701	

Continua na próxima página.

Tabela D.2: Cenário 0a
(Volumes em $\times 10^6$ ton.) (continuação).

Região	CIL	2019	2023	2027	2031
	43008	1,287	1,279	1,267	1,257
	43009	0,898	0,891	0,869	0,910
	43010	0,494	0,563	0,525	0,517
	43011	1,365	1,343	1,367	1,552
	43017	0,771	0,782	0,759	0,545
	43035	0,097	0,095	0,092	0,089
	50004	1,434	1,350	1,347	1,343
	50005	0,246	0,267	0,307	0,348
	50010	1,791	1,699	1,767	1,836
	50011	0,418	0,477	0,455	0,558
	51001	5,304	5,752	6,011	6,269
	51002	0,166	0,332	0,348	0,364
	51004	1,387	1,145	1,785	1,555
	51006	7,013	7,203	7,663	8,123
	51009	1,074	1,456	1,568	1,680
	51010	0,542	0,586	0,674	0,763
	51017	0,301	0,693	0,385	0,947
	51020	0,488	0,480	0,603	0,651
Centro-Oeste	51021	0,453	0,503	0,488	0,547
	51022	0,074	0,076	0,092	0,108
	52001	0,049	0,079	0,095	0,070
	52002	0,000	0,000	0,000	0,000
	52004	0,144	0,197	0,198	0,228
	52006	0,059	0,086	0,090	0,097
	52007	0,040	0,055	0,055	0,102
	52012	0,402	0,475	0,513	0,554
	52013	0,677	0,656	0,636	0,607
	52014	0,277	0,287	0,305	0,322
	52016	0,146	0,154	0,163	0,173
	52017	0,210	0,216	0,230	0,244
	52018	0,001	0,001	0,001	0,001

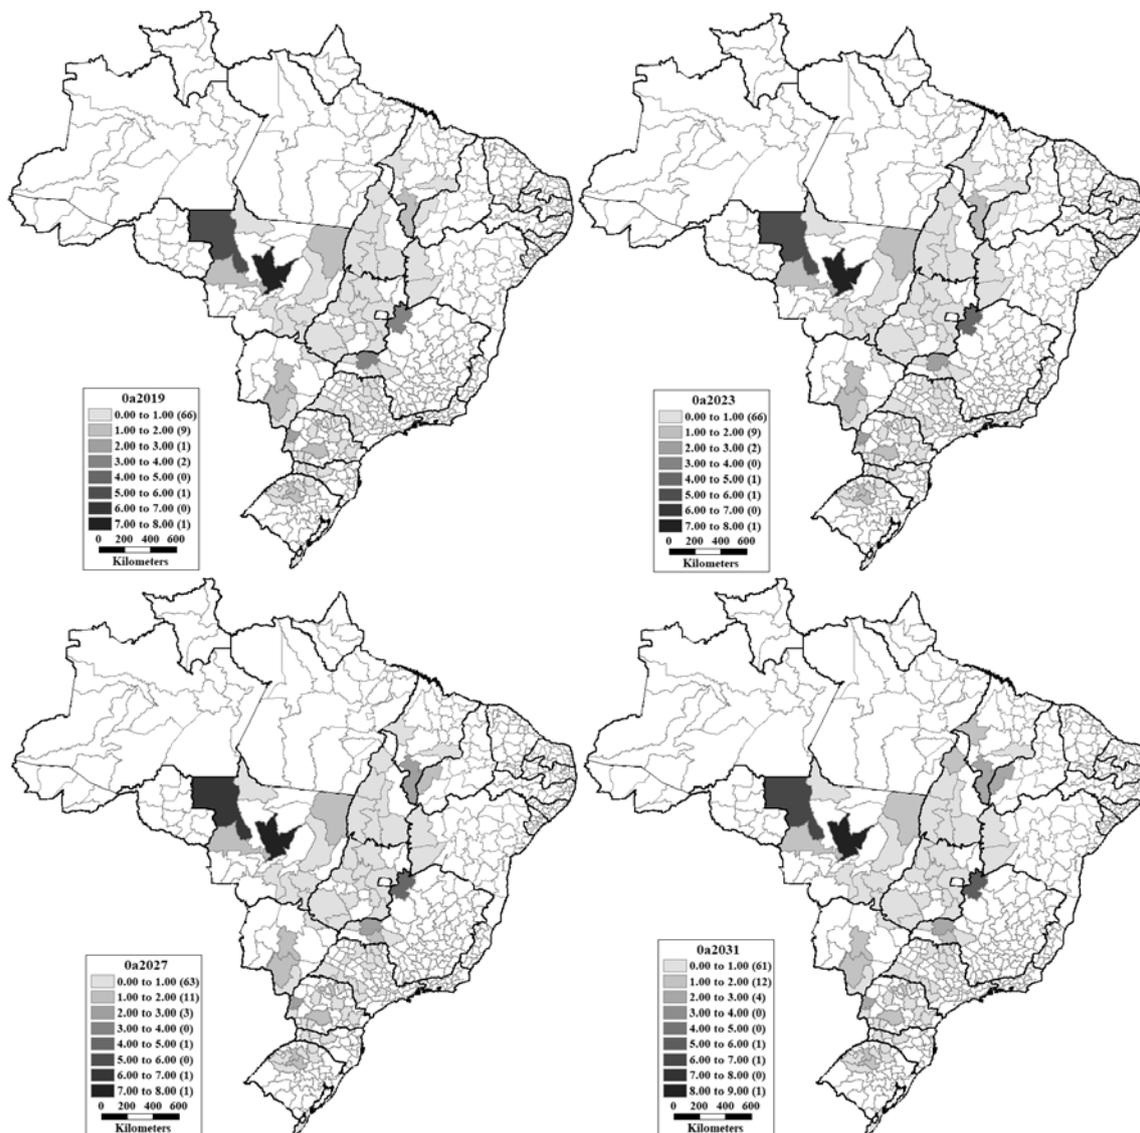


Figura D.1: Volume operacional dos CILs em cada horizonte para o Cenário 0a e instância *COSNESEN* (volumes em 10^6 toneladas).

Tabela D.3: Cenário 0b (Volumes em $\times 10^6$ ton.).

Região	CIL	2019	2023	2027	2031
Norte	17002	0,000	1,000	1,211	1,494
	17003	0,000	0,000	0,000	0,000
	17004	0,000	1,000	1,000	1,000
	17005	0,000	0,000	0,000	0,000
	17006	0,000	0,000	0,000	0,000
	17008	0,000	0,000	0,000	1,000
Nordeste	21009	1,000	1,000	1,000	1,114
	21018	0,000	0,000	0,000	0,000
	21020	2,056	2,070	2,754	3,276
	22007	1,000	1,000	1,691	2,400

Continua na próxima página.

Tabela D.3: Cenário 0b
(Volumes em x10⁶ ton.) (continuação).

Região	CIL	2019	2023	2027	2031
	29001	0,000	0,000	1,000	1,000
	29003	1,000	1,000	1,000	1,000
	31001	3,857	4,239	4,767	4,780
	31017	0,000	0,000	0,000	0,000
	31018	2,908	2,758	2,463	2,243
	31022	1,118	1,073	1,151	1,137
	31023	0,000	0,000	0,000	0,000
	35004	0,000	0,000	0,000	0,000
	35009	1,000	1,000	1,000	1,000
	35010	0,000	0,000	0,000	0,000
	35011	0,000	0,000	0,000	0,000
Sudeste	35013	0,000	0,000	0,000	0,000
	35014	0,000	0,000	0,000	0,000
	35018	0,000	0,000	0,000	0,000
	35021	0,000	0,000	0,000	0,000
	35022	0,000	0,000	0,000	0,000
	35024	0,000	0,000	0,000	0,000
	35036	0,000	0,000	0,000	0,000
	35039	1,000	1,000	1,000	1,000
	35040	0,000	0,000	0,000	0,000
	35041	0,000	0,000	0,000	0,000
	35046	0,000	0,000	0,000	0,000
	41005	0,000	0,000	0,000	0,000
	41009	1,495	1,554	1,566	1,605
	41011	1,000	1,000	1,000	1,000
	41015	1,000	1,000	1,000	1,000
	41019	1,000	1,000	1,000	1,000
	41021	0,000	0,000	0,000	0,000
	41022	1,711	1,826	2,029	2,202
	41024	1,000	1,000	1,000	1,000
	41026	0,000	0,000	0,000	0,000
	41027	1,088	1,126	1,166	1,192
	41029	1,394	1,449	1,584	1,743
Sul	41037	1,000	1,000	1,000	1,000
	42002	1,000	1,000	1,000	1,000
	42003	0,000	0,000	0,000	0,000
	42004	0,000	0,000	0,000	0,000
	43004	1,000	1,000	1,000	1,000
	43007	1,000	1,000	1,000	1,000
	43008	1,030	1,020	1,007	1,001
	43009	1,083	1,053	1,089	1,061
	43010	0,000	0,000	0,000	0,000
	43011	2,235	2,222	2,205	2,187

Continua na próxima página.

Tabela D.3: Cenário 0b
(Volumes em $\times 10^6$ ton.) (continuação).

Região	CIL	2019	2023	2027	2031
	43017	0,000	0,000	0,000	0,000
	43035	0,000	0,000	0,000	0,000
	50004	1,443	1,389	1,349	1,365
	50005	0,000	0,000	0,000	0,000
	50010	1,790	1,699	1,767	1,835
	50011	1,000	1,000	1,000	1,000
	51001	5,472	6,087	6,218	6,605
	51002	0,000	0,000	0,000	0,000
	51004	1,574	1,714	1,315	1,531
	51006	7,069	7,258	7,703	8,113
	51009	1,126	1,454	1,568	1,680
	51010	0,000	0,000	0,000	1,000
	51017	0,000	0,000	1,000	1,000
	51020	1,000	1,000	1,000	1,000
Centro-Oeste	51021	1,000	1,000	1,000	1,000
	51022	0,000	0,000	0,000	0,000
	52001	0,000	0,000	0,000	0,000
	52002	0,000	0,000	0,000	0,000
	52004	0,000	0,000	0,000	0,000
	52006	0,000	0,000	0,000	0,000
	52007	0,000	0,000	0,000	0,000
	52012	1,000	1,000	1,000	1,000
	52013	1,000	1,000	1,000	1,000
	52014	0,000	0,000	0,000	0,000
	52016	0,000	0,000	0,000	0,000
	52017	0,000	0,000	0,000	0,000
	52018	0,000	0,000	0,000	0,000

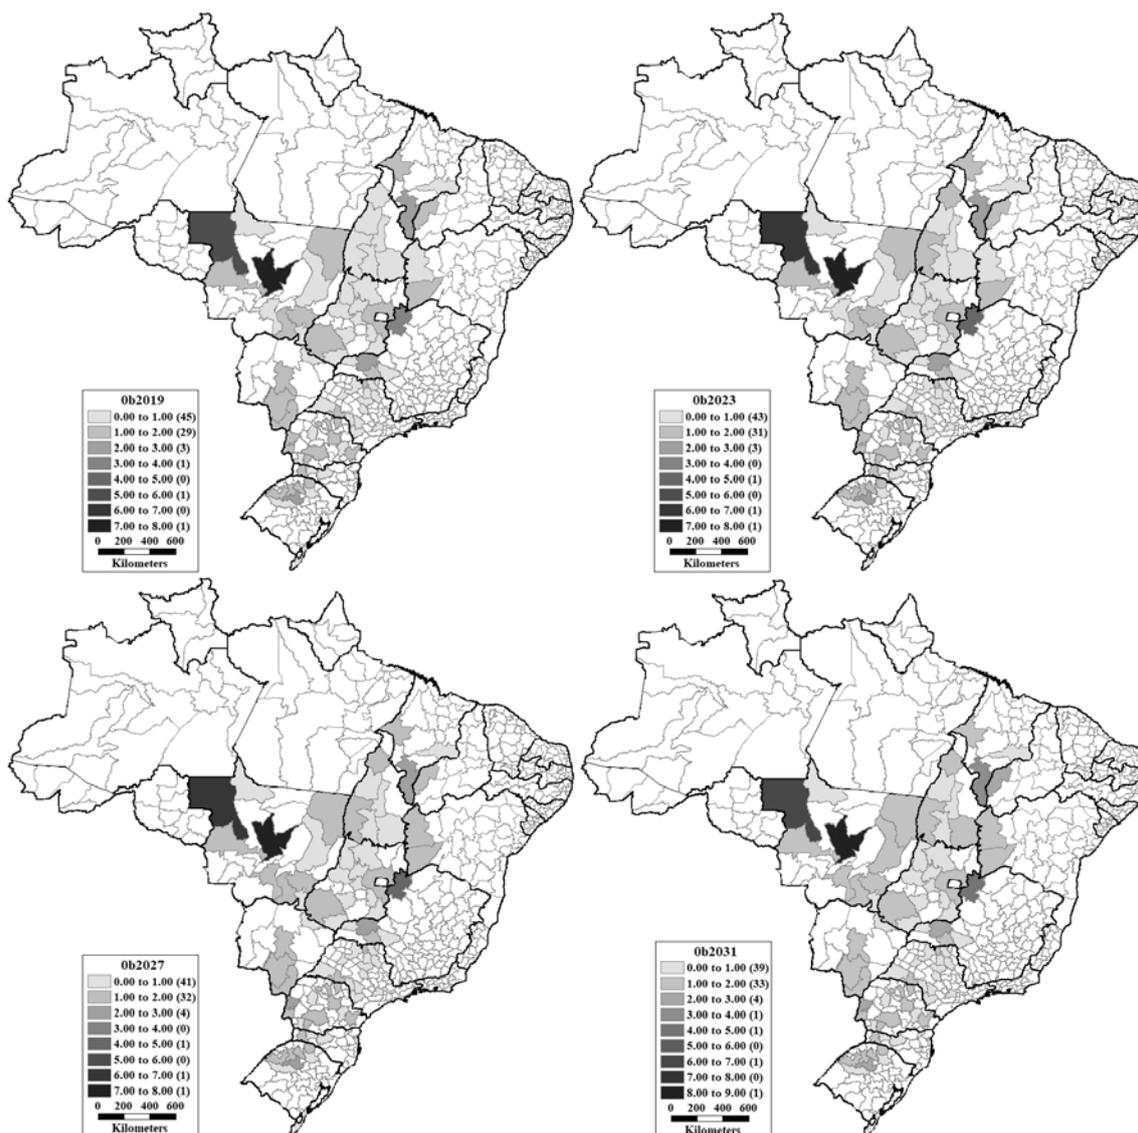


Figura D.2: Volume operacional dos CILs em cada horizonte para o Cenário 0b e instância *COSNESEN* (volumes em 10^6 toneladas).

Tabela D.4: Cenário 1a (Volumes em $\times 10^6$ ton.)

Região	CIL	2019	2023	2027	2031
Norte	17002	0,817	1,018	1,260	1,502
	17003	0,000	0,000	0,000	0,000
	17004	0,000	0,000	0,000	0,000
	17005	0,000	0,000	0,000	0,000
	17006	0,000	0,000	0,000	0,000
	17008	0,000	0,000	0,000	0,000
Nordeste	21009	0,592	0,793	0,954	1,114
	21018	0,000	0,000	0,000	0,000
	21020	1,939	2,254	2,774	3,295
	22007	0,758	0,989	1,701	2,411

Continua na próxima página.

Tabela D.4: Cenário 1a
(Volumes em $\times 10^6$ ton.) (continuação).

Região	CIL	2019	2023	2027	2031
	29001	0,187	0,252	0,335	0,405
	29003	0,730	0,842	0,888	0,952
	31001	4,110	4,934	5,614	6,380
	31017	0,000	0,000	0,000	0,000
	31018	3,394	3,185	2,953	2,743
	31022	1,609	1,711	1,735	1,723
	31023	0,000	0,000	0,000	0,000
	35004	0,000	0,000	0,000	0,000
	35009	0,000	0,000	0,000	0,000
	35010	0,000	0,000	0,000	0,000
	35011	0,000	0,000	0,000	0,000
Sudeste	35013	0,000	0,000	0,000	0,000
	35014	0,000	0,000	0,000	0,000
	35018	0,000	0,000	0,000	0,000
	35021	0,000	0,000	0,000	0,000
	35022	0,000	0,000	0,000	0,000
	35024	0,000	0,000	0,000	0,000
	35036	0,000	0,000	0,000	0,000
	35039	1,062	1,010	1,078	1,063
	35040	0,000	0,000	0,000	0,000
	35041	0,000	0,000	0,000	0,000
	35046	0,000	0,000	0,000	0,000
	41005	0,000	0,000	0,000	0,000
	41009	2,357	2,308	2,334	2,374
	41011	0,000	0,000	0,000	0,000
	41015	0,881	0,982	1,021	1,061
	41019	0,887	0,961	1,007	1,046
	41021	0,000	0,000	0,000	0,000
	41022	2,395	2,924	2,713	2,892
	41024	0,827	0,438	0,827	0,825
	41026	0,000	0,000	0,000	0,000
	41027	1,449	1,467	1,476	1,543
	41029	1,587	1,642	1,719	1,794
Sul	41037	0,874	0,868	0,876	0,896
	42002	0,000	0,000	0,000	0,000
	42003	0,000	0,000	0,000	0,000
	42004	0,000	0,000	0,000	0,000
	43004	1,155	1,147	1,158	1,165
	43007	0,000	0,000	0,000	0,000
	43008	1,941	1,914	1,892	1,869
	43009	1,311	1,342	1,302	1,293
	43010	0,000	0,000	0,000	0,000
	43011	2,241	2,229	2,198	2,196

Continua na próxima página.

Tabela D.4: Cenário 1a
(Volumes em $\times 10^6$ ton.) (continuação).

Região	CIL	2019	2023	2027	2031
	43017	0,000	0,000	0,000	0,000
	43035	0,000	0,000	0,000	0,000
	50004	1,855	1,756	1,755	1,759
	50005	0,000	0,000	0,000	0,000
	50010	1,799	1,707	1,778	1,850
	50011	0,000	0,000	0,000	0,000
	51001	5,478	6,094	6,371	6,649
	51002	0,000	0,000	0,000	0,000
	51004	1,574	1,715	2,029	2,344
	51006	7,078	7,266	7,729	8,190
	51009	1,090	1,469	1,579	1,690
	51010	0,000	0,000	0,000	0,000
	51017	0,000	0,000	0,000	0,000
	51020	0,000	0,000	0,000	0,000
Centro-Oeste	51021	0,873	0,959	1,125	1,286
	51022	0,000	0,000	0,000	0,000
	52001	0,000	0,000	0,000	0,000
	52002	0,000	0,000	0,000	0,000
	52004	0,000	0,000	0,000	0,000
	52006	0,000	0,000	0,000	0,000
	52007	0,000	0,000	0,000	0,000
	52012	0,450	0,547	0,598	0,643
	52013	0,995	0,962	0,968	0,976
	52014	0,000	0,000	0,000	0,000
	52016	0,000	0,000	0,000	0,000
	52017	0,000	0,000	0,000	0,000
	52018	0,000	0,000	0,000	0,000

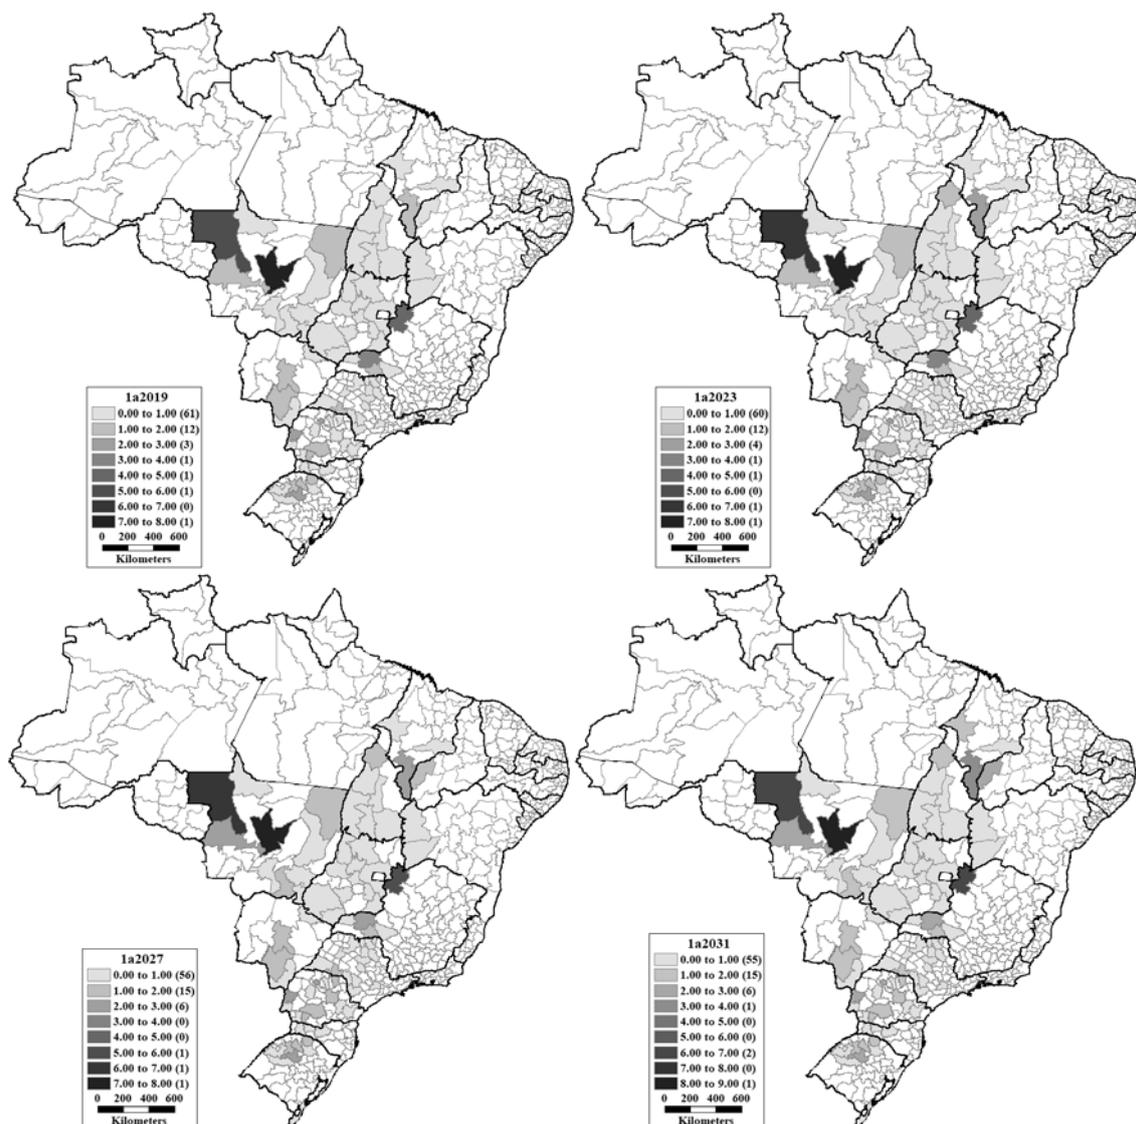


Figura D.3: Volume operacional dos CILs em cada horizonte para o Cenário 1a e instância *COSNESEN* (volumes em 10^6 toneladas).

Tabela D.5: Cenário 1b (Volumes em $\times 10^6$ ton.).

Região	CIL	2019	2023	2027	2031
Norte	17002	0,000	1,000	1,268	1,547
	17003	0,000	0,000	0,000	0,000
	17004	0,000	0,000	0,000	0,000
	17005	0,000	0,000	0,000	0,000
	17006	0,000	0,000	0,000	0,000
	17008	0,000	0,000	0,000	0,000
Nordeste	21009	1,000	1,000	1,000	1,114
	21018	0,000	0,000	0,000	0,000
	21020	2,029	2,157	2,807	3,339
	22007	1,000	1,000	1,701	2,399
	29001	0,000	0,000	0,000	0,000

Continua na próxima página.

Tabela D.5: Cenário 1b
(Volumes em $\times 10^6$ ton.) (continuação).

Região	CIL	2019	2023	2027	2031
	29003	1,000	1,000	1,054	1,172
	31001	3,897	4,831	5,569	6,276
	31017	0,000	0,000	0,000	0,000
	31018	3,347	3,230	2,962	2,779
	31022	1,607	1,647	1,715	1,720
	31023	0,000	0,000	0,000	0,000
	35004	0,000	0,000	0,000	0,000
	35009	0,000	0,000	0,000	0,000
	35010	0,000	0,000	0,000	0,000
	35011	0,000	0,000	0,000	0,000
Sudeste	35013	0,000	0,000	0,000	0,000
	35014	0,000	0,000	0,000	0,000
	35018	0,000	0,000	0,000	0,000
	35021	0,000	0,000	0,000	0,000
	35022	0,000	0,000	0,000	0,000
	35024	0,000	0,000	0,000	0,000
	35036	0,000	0,000	0,000	0,000
	35039	1,058	1,065	1,089	1,119
	35040	0,000	0,000	0,000	0,000
	35041	0,000	0,000	0,000	0,000
	35046	0,000	0,000	0,000	0,000
	41005	0,000	0,000	0,000	0,000
	41009	2,184	2,308	2,355	2,374
	41011	0,000	0,000	0,000	0,000
	41015	1,000	1,000	1,021	1,000
	41019	1,000	1,000	1,003	1,109
	41021	0,000	0,000	0,000	0,000
	41022	2,214	2,363	2,530	2,718
	41024	1,000	1,000	1,000	1,000
	41026	0,000	0,000	0,000	0,000
	41027	1,449	1,467	1,506	1,544
	41029	1,508	1,564	1,652	1,756
Sul	41037	1,000	1,000	1,000	1,000
	42002	0,000	0,000	0,000	0,000
	42003	0,000	0,000	0,000	0,000
	42004	0,000	0,000	0,000	0,000
	43004	1,154	1,147	1,159	1,169
	43007	0,000	0,000	0,000	0,000
	43008	1,941	1,914	1,905	1,869
	43009	1,344	1,343	1,341	1,343
	43010	0,000	0,000	0,000	0,000
	43011	2,241	2,229	2,213	2,196
	43017	0,000	0,000	0,000	0,000

Continua na próxima página.

Tabela D.5: Cenário 1b
(Volumes em $\times 10^6$ ton.) (continuação).

Região	CIL	2019	2023	2027	2031
	43035	0,000	0,000	0,000	0,000
	50004	1,853	1,747	1,753	1,739
	50005	0,000	0,000	0,000	0,000
	50010	1,799	1,707	1,778	1,850
	50011	0,000	0,000	0,000	0,000
	51001	5,478	6,094	6,371	6,649
	51002	0,000	0,000	0,000	0,000
	51004	1,574	1,715	2,029	2,343
	51006	7,076	7,266	7,729	8,190
	51009	1,141	1,467	1,579	1,690
	51010	0,000	0,000	0,000	0,000
	51017	0,000	0,000	0,000	0,000
	51020	0,000	0,000	0,000	0,000
Centro-Oeste	51021	1,000	1,000	1,138	1,308
	51022	0,000	0,000	0,000	0,000
	52001	0,000	0,000	0,000	0,000
	52002	0,000	0,000	0,000	0,000
	52004	0,000	0,000	0,000	0,000
	52006	0,000	0,000	0,000	0,000
	52007	0,000	0,000	0,000	0,000
	52012	1,000	1,000	1,000	1,000
	52013	1,000	1,000	1,000	1,000
	52014	0,000	0,000	0,000	0,000
	52016	0,000	0,000	0,000	0,000
	52017	0,000	0,000	0,000	0,000
	52018	0,000	0,000	0,000	0,000

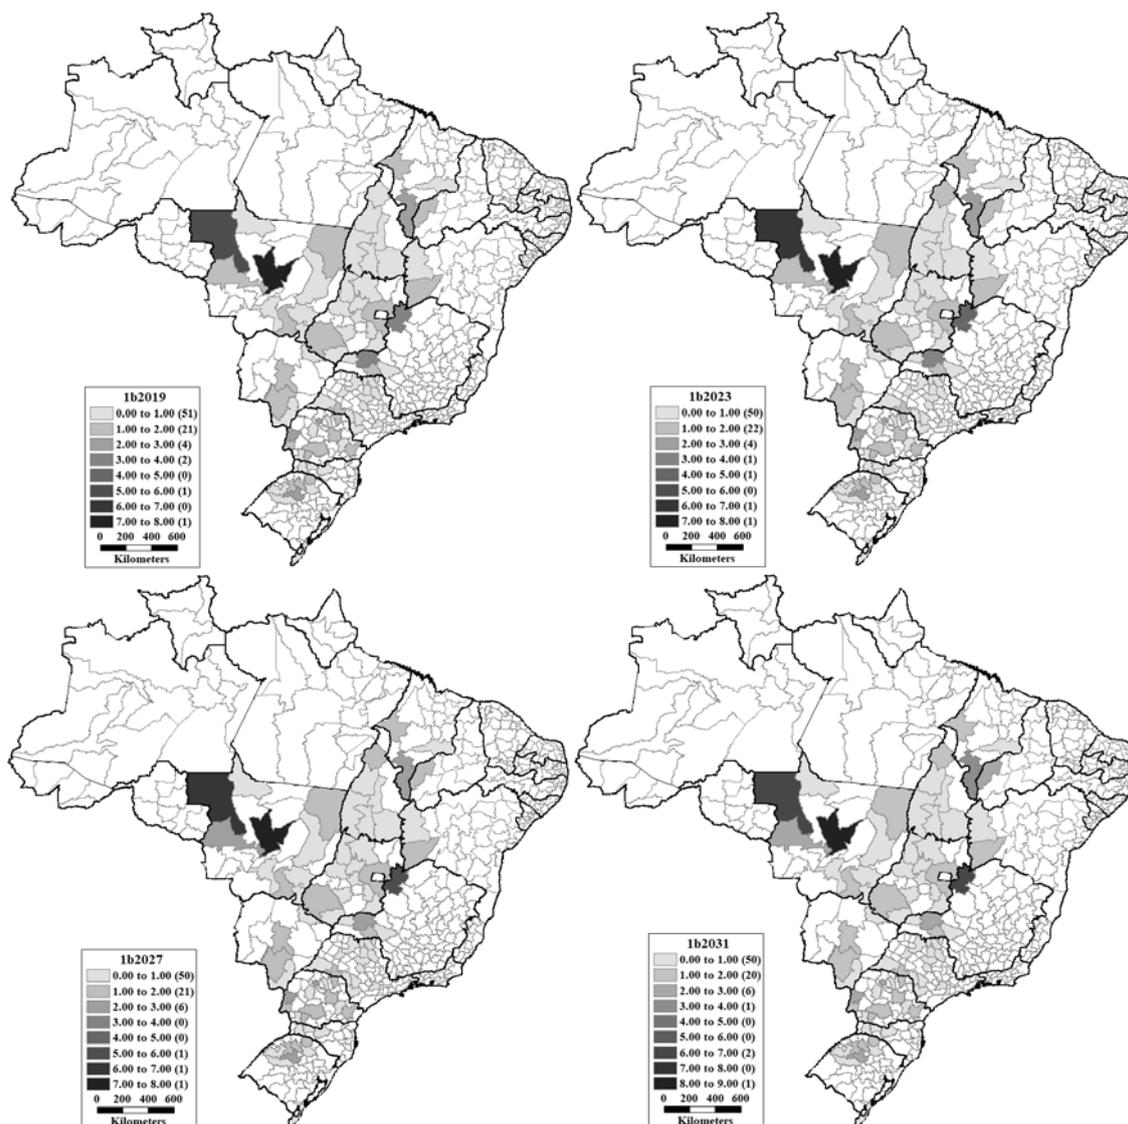


Figura D.4: Volume operacional dos CILs em cada horizonte para o Cenário 1b e instância *COSNESEN* (volumes em 10^6 toneladas).

Tabela D.6: Cenário 2a (Volumes em $\times 10^6$ ton.).

Região	CIL	2019	2023	2027	2031
Norte	17002	0,000	0,000	0,000	0,000
	17003	0,000	0,000	0,000	0,000
	17004	0,000	0,000	0,000	0,000
	17005	0,000	0,000	0,000	0,000
	17006	0,000	0,000	0,000	0,000
	17008	0,000	0,000	0,000	0,000
Nordeste	21009	0,695	0,955	1,164	1,373
	21018	0,000	0,000	0,000	0,000
	21020	3,126	3,747	5,108	6,469
	22007	0,000	0,000	0,000	0,000
	29001	0,000	0,000	0,000	0,000

Continua na próxima página.

Tabela D.6: Cenário 2a (Volumes em x10⁶ ton.) (continuação).

Região	CIL	2019	2023	2027	2031
	29003	0,000	0,000	0,000	0,000
Sudeste	31001	5,162	6,194	7,106	8,018
	31017	0,000	0,000	0,000	0,000
	31018	3,886	3,768	3,606	3,445
	31022	1,675	1,739	1,744	1,748
	31023	0,000	0,000	0,000	0,000
	35004	0,000	0,000	0,000	0,000
	35009	0,000	0,000	0,000	0,000
	35010	0,000	0,000	0,000	0,000
	35011	0,000	0,000	0,000	0,000
	35013	0,000	0,000	0,000	0,000
	35014	0,000	0,000	0,000	0,000
	35018	0,000	0,000	0,000	0,000
	35021	0,000	0,000	0,000	0,000
	35022	0,000	0,000	0,000	0,000
	35024	0,000	0,000	0,000	0,000
	35036	0,000	0,000	0,000	0,000
	35039	0,000	0,000	0,000	0,000
	35040	0,000	0,000	0,000	0,000
	35041	0,000	0,000	0,000	0,000
35046	0,000	0,000	0,000	0,000	
Sul	41005	0,000	0,000	0,000	0,000
	41009	4,565	4,646	4,736	4,827
	41011	0,000	0,000	0,000	0,000
	41015	0,000	0,000	0,000	0,000
	41019	0,000	0,000	0,000	0,000
	41021	0,000	0,000	0,000	0,000
	41022	3,190	3,328	3,503	3,678
	41024	0,000	0,000	0,000	0,000
	41026	0,000	0,000	0,000	0,000
	41027	1,768	1,782	1,827	1,872
	41029	2,425	2,475	2,554	2,633
	41037	0,000	0,000	0,000	0,000
	42002	0,000	0,000	0,000	0,000
	42003	0,000	0,000	0,000	0,000
	42004	0,000	0,000	0,000	0,000
	43004	0,000	0,000	0,000	0,000
	43007	0,000	0,000	0,000	0,000
	43008	0,000	0,000	0,000	0,000
	43009	0,000	0,000	0,000	0,000
43010	0,000	0,000	0,000	0,000	
43011	5,700	5,620	5,466	5,368	
43017	0,000	0,000	0,000	0,000	
43035	0,000	0,000	0,000	0,000	

Continua na próxima página.

Tabela D.6: Cenário 2a (Volumes em $\times 10^6$ ton.) (continuação).

Região	CIL	2019	2023	2027	2031
	50004	1,974	1,879	1,901	1,922
	50005	0,000	0,000	0,000	0,000
	50010	1,799	1,707	1,778	1,850
	50011	0,000	0,000	0,000	0,000
	51001	5,482	6,098	6,376	6,654
	51002	0,000	0,000	0,000	0,000
	51004	1,590	1,731	2,048	2,364
	51006	7,108	7,299	7,770	8,241
	51009	1,142	1,529	1,639	1,750
	51010	0,000	0,000	0,000	0,000
	51017	0,000	0,000	0,000	0,000
	51020	0,000	0,000	0,000	0,000
Centro-Oeste	51021	0,000	0,000	0,000	0,000
	51022	0,000	0,000	0,000	0,000
	52001	0,000	0,000	0,000	0,000
	52002	0,000	0,000	0,000	0,000
	52004	0,000	0,000	0,000	0,000
	52006	0,000	0,000	0,000	0,000
	52007	0,000	0,000	0,000	0,000
	52012	0,000	0,000	0,000	0,000
	52013	0,000	0,000	0,000	0,000
	52014	0,000	0,000	0,000	0,000
	52016	0,000	0,000	0,000	0,000
	52017	0,000	0,000	0,000	0,000
	52018	0,000	0,000	0,000	0,000

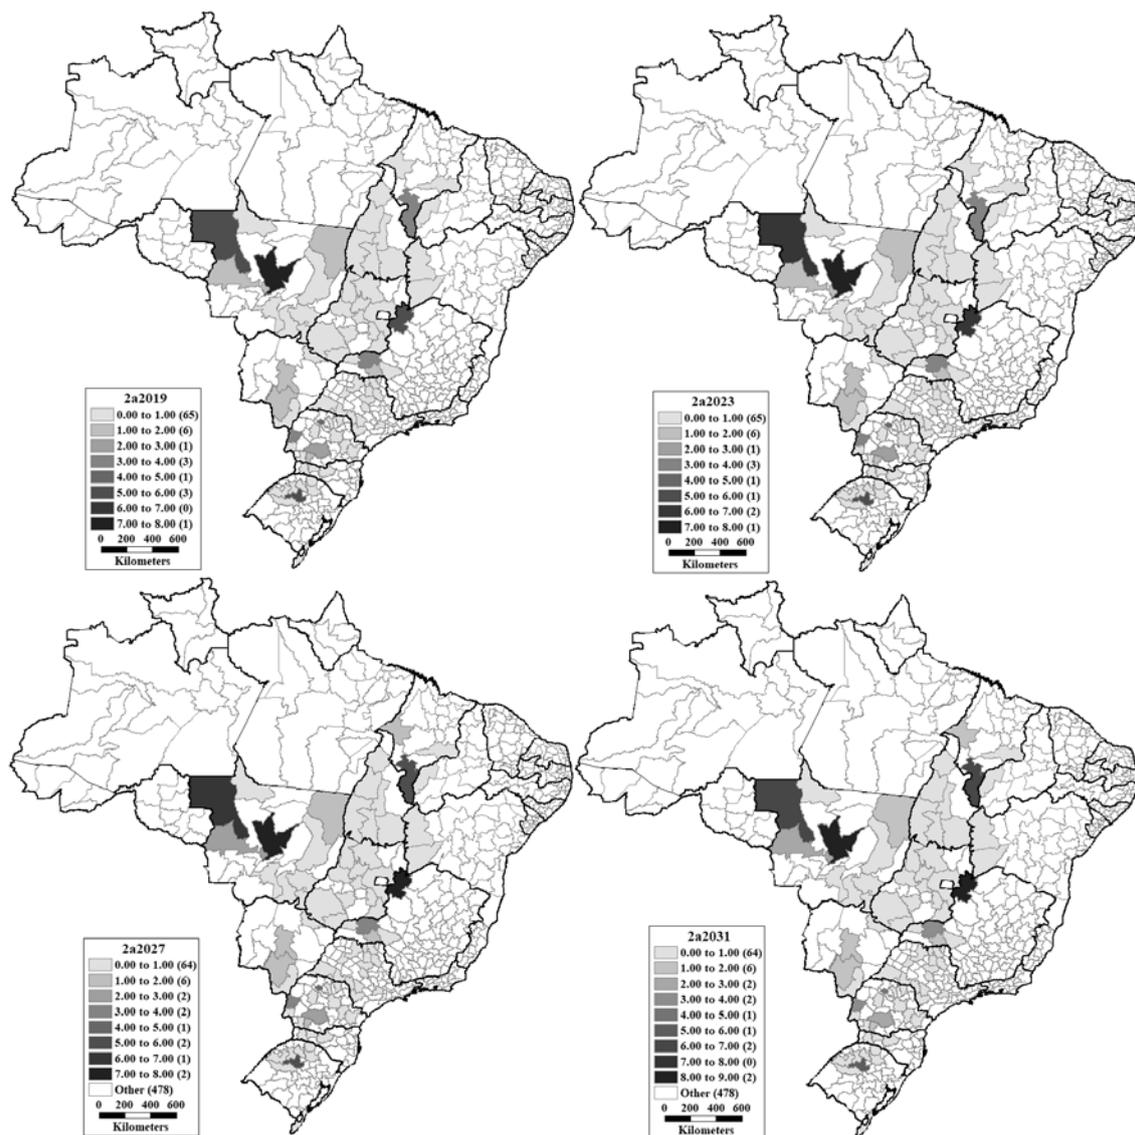


Figura D.5: Volume operacional dos CILs em cada horizonte para o Cenário 2a e instância *COSNESEN* (volumes em 10^6 toneladas).

Tabela D.7: Cenário 2b (Volumes em $\times 10^6$ ton.)

Região	CIL	2019	2023	2027	2031
Norte	17002	0,000	0,000	0,000	0,000
	17003	0,000	0,000	0,000	0,000
	17004	0,000	0,000	0,000	0,000
	17005	0,000	0,000	0,000	0,000
	17006	0,000	0,000	0,000	0,000
	17008	0,000	0,000	0,000	0,000
Nordeste	21009	1,000	1,000	1,164	1,373
	21018	0,000	0,000	0,000	0,000
	21020	2,822	3,703	5,108	6,469
	22007	0,000	0,000	0,000	0,000
	29001	0,000	0,000	0,000	0,000

Continua na próxima página.

Tabela D.7: Cenário 2b (Volumes em x10⁶ ton.) (continuação).

Região	CIL	2019	2023	2027	2031
	29003	0,000	0,000	0,000	0,000
	31001	5,162	6,184	7,061	7,973
	31017	0,000	0,000	0,000	0,000
	31018	3,886	3,778	3,652	3,489
	31022	1,675	1,737	1,742	1,746
	31023	0,000	0,000	0,000	0,000
	35004	0,000	0,000	0,000	0,000
	35009	0,000	0,000	0,000	0,000
	35010	0,000	0,000	0,000	0,000
	35011	0,000	0,000	0,000	0,000
Sudeste	35013	0,000	0,000	0,000	0,000
	35014	0,000	0,000	0,000	0,000
	35018	0,000	0,000	0,000	0,000
	35021	0,000	0,000	0,000	0,000
	35022	0,000	0,000	0,000	0,000
	35024	0,000	0,000	0,000	0,000
	35036	0,000	0,000	0,000	0,000
	35039	0,000	0,000	0,000	0,000
	35040	0,000	0,000	0,000	0,000
	35041	0,000	0,000	0,000	0,000
	35046	0,000	0,000	0,000	0,000
	41005	0,000	0,000	0,000	0,000
	41009	4,565	4,634	4,738	4,828
	41011	0,000	0,000	0,000	0,000
	41015	0,000	0,000	0,000	0,000
	41019	0,000	0,000	0,000	0,000
	41021	0,000	0,000	0,000	0,000
	41022	3,190	3,328	3,503	3,678
	41024	0,000	0,000	0,000	0,000
	41026	0,000	0,000	0,000	0,000
	41027	1,758	1,771	1,815	1,860
	41029	2,425	2,490	2,554	2,633
Sul	41037	0,000	0,000	0,000	0,000
	42002	0,000	0,000	0,000	0,000
	42003	0,000	0,000	0,000	0,000
	42004	0,000	0,000	0,000	0,000
	43004	0,000	0,000	0,000	0,000
	43007	0,000	0,000	0,000	0,000
	43008	0,000	0,000	0,000	0,000
	43009	0,000	0,000	0,000	0,000
	43010	0,000	0,000	0,000	0,000
	43011	5,711	5,631	5,478	5,381
	43017	0,000	0,000	0,000	0,000
	43035	0,000	0,000	0,000	0,000

Continua na próxima página.

Tabela D.7: Cenário 2b (Volumes em x10⁶ ton.) (continuação).

Região	CIL	2019	2023	2027	2031
	50004	1,968	1,874	1,893	1,912
	50005	0,000	0,000	0,000	0,000
	50010	1,799	1,707	1,778	1,850
	50011	0,000	0,000	0,000	0,000
	51001	5,482	6,098	6,376	6,654
	51002	0,000	0,000	0,000	0,000
	51004	1,590	1,731	2,048	2,364
	51006	7,113	7,304	7,778	8,251
	51009	1,142	1,529	1,639	1,750
	51010	0,000	0,000	0,000	0,000
	51017	0,000	0,000	0,000	0,000
	51020	0,000	0,000	0,000	0,000
Centro-Oeste	51021	0,000	0,000	0,000	0,000
	51022	0,000	0,000	0,000	0,000
	52001	0,000	0,000	0,000	0,000
	52002	0,000	0,000	0,000	0,000
	52004	0,000	0,000	0,000	0,000
	52006	0,000	0,000	0,000	0,000
	52007	0,000	0,000	0,000	0,000
	52012	0,000	0,000	0,000	0,000
	52013	0,000	0,000	0,000	0,000
	52014	0,000	0,000	0,000	0,000
	52016	0,000	0,000	0,000	0,000
	52017	0,000	0,000	0,000	0,000
	52018	0,000	0,000	0,000	0,000

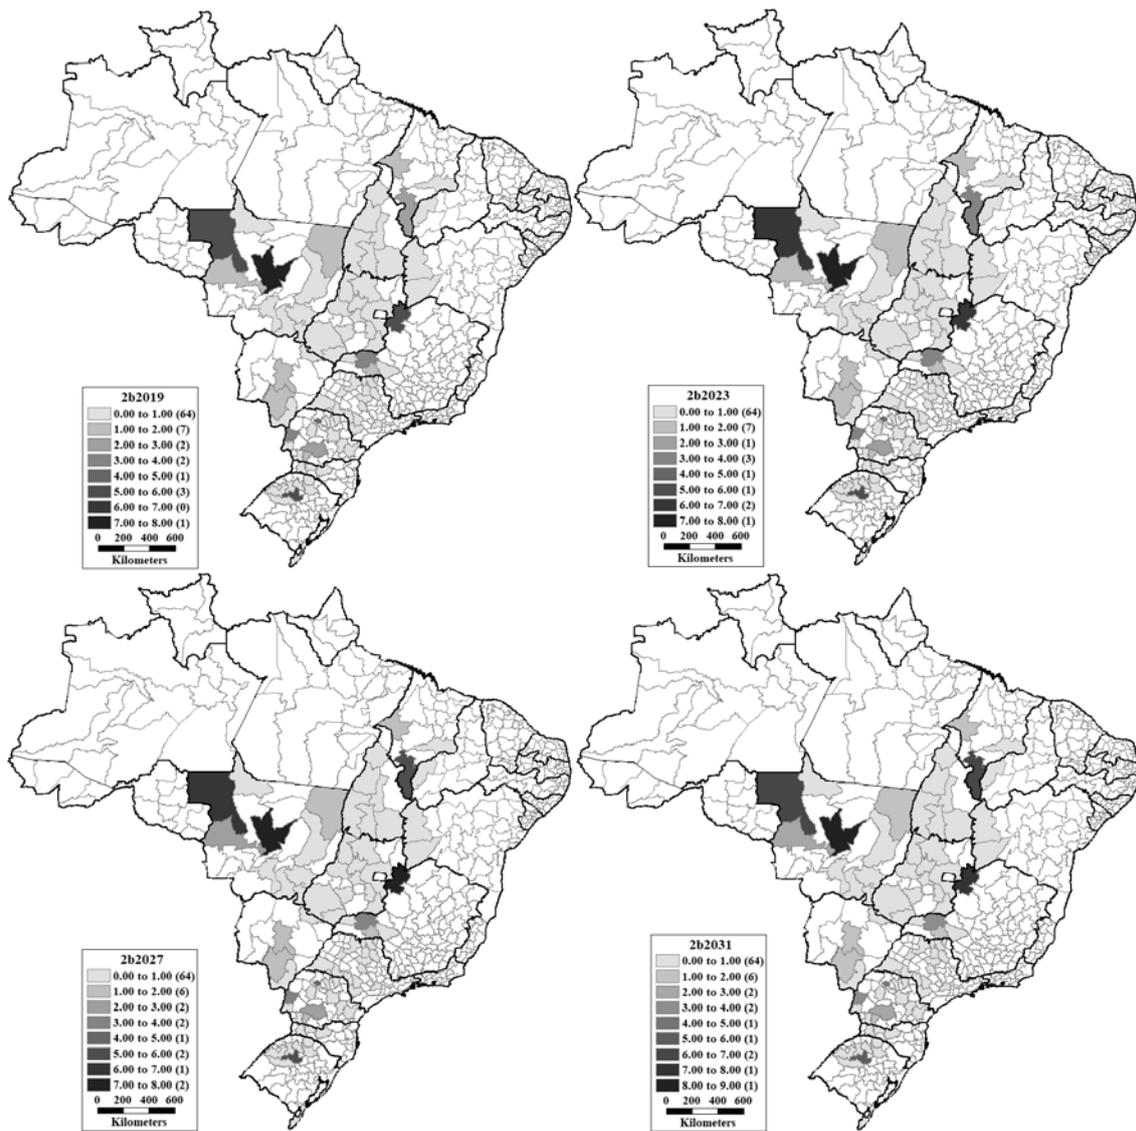


Figura D.6: Volume operacional dos CILs em cada horizonte para o Cenário 2b e instância *COSNESEN* (volumes em 10^6 toneladas).

Apêndice E

Desempenho da abordagem gulosa para o cálculo de aptidão

Para a verificação e validação da heurística construtiva gulosa proposta para o cálculo da aptidão dos indivíduos, apresentada na Seção 2.3.1, criou-se um conjunto com 500 cromossomos aleatórios e viáveis, que foram avaliados tanto utilizando-se um *solver* quanto pelo procedimento heurístico proposto. A Figura E.1 apresenta o gráfico de dispersão destes indivíduos segundo o valor da aptidão por método exato (abscissas) e heurística (ordenadas). Projeções com coeficiente angular igual a 45° (ilustrada nas figuras pela reta vermelha) indicam que ambas abordagens apresentaram resultados idênticos. Este comportamento pode ser observado nos cenários 0a, 1a e 2a, que não possuem restrição de volume mínimo para abertura dos CILs. Porém, para os cenários que exigem volume mínimo passando nos CILs, observou-se que o procedimento guloso resultou em valores acima do exato.

O desvio entre a solução heurística encontrada (SH) e a solução ótima do problema (SE), denominado de GAP, foi calculado através da Equação (E.1). A Figura E.2 apresenta o diagrama de caixas para o GAP resultante dos indivíduos avaliados. Como destacado anteriormente, para os cenários sem restrição de volume mínimo (cenários 0a, 1a e 2a), o método heurístico resultou nos valores exatos de aptidão (GAP igual a zero). Para os demais cenários, verificou-se que o terceiro quartil ficou abaixo de 5,5% para todos os casos, além das médias e medianas encontrarem-se abaixo de 4%. Destaca-se, ainda, a proximidade entre a média e a mediana, indicando simetria na distribuição. Cabe destacar que os ajustes dos parâmetros devem objetivar valores de GAP tão menores quanto possíveis, podendo variar de acordo com as dimensões do problema e as exigências quanto à qualidade da solução.

$$GAP = (SH - SE)/(SH) \tag{E.1}$$

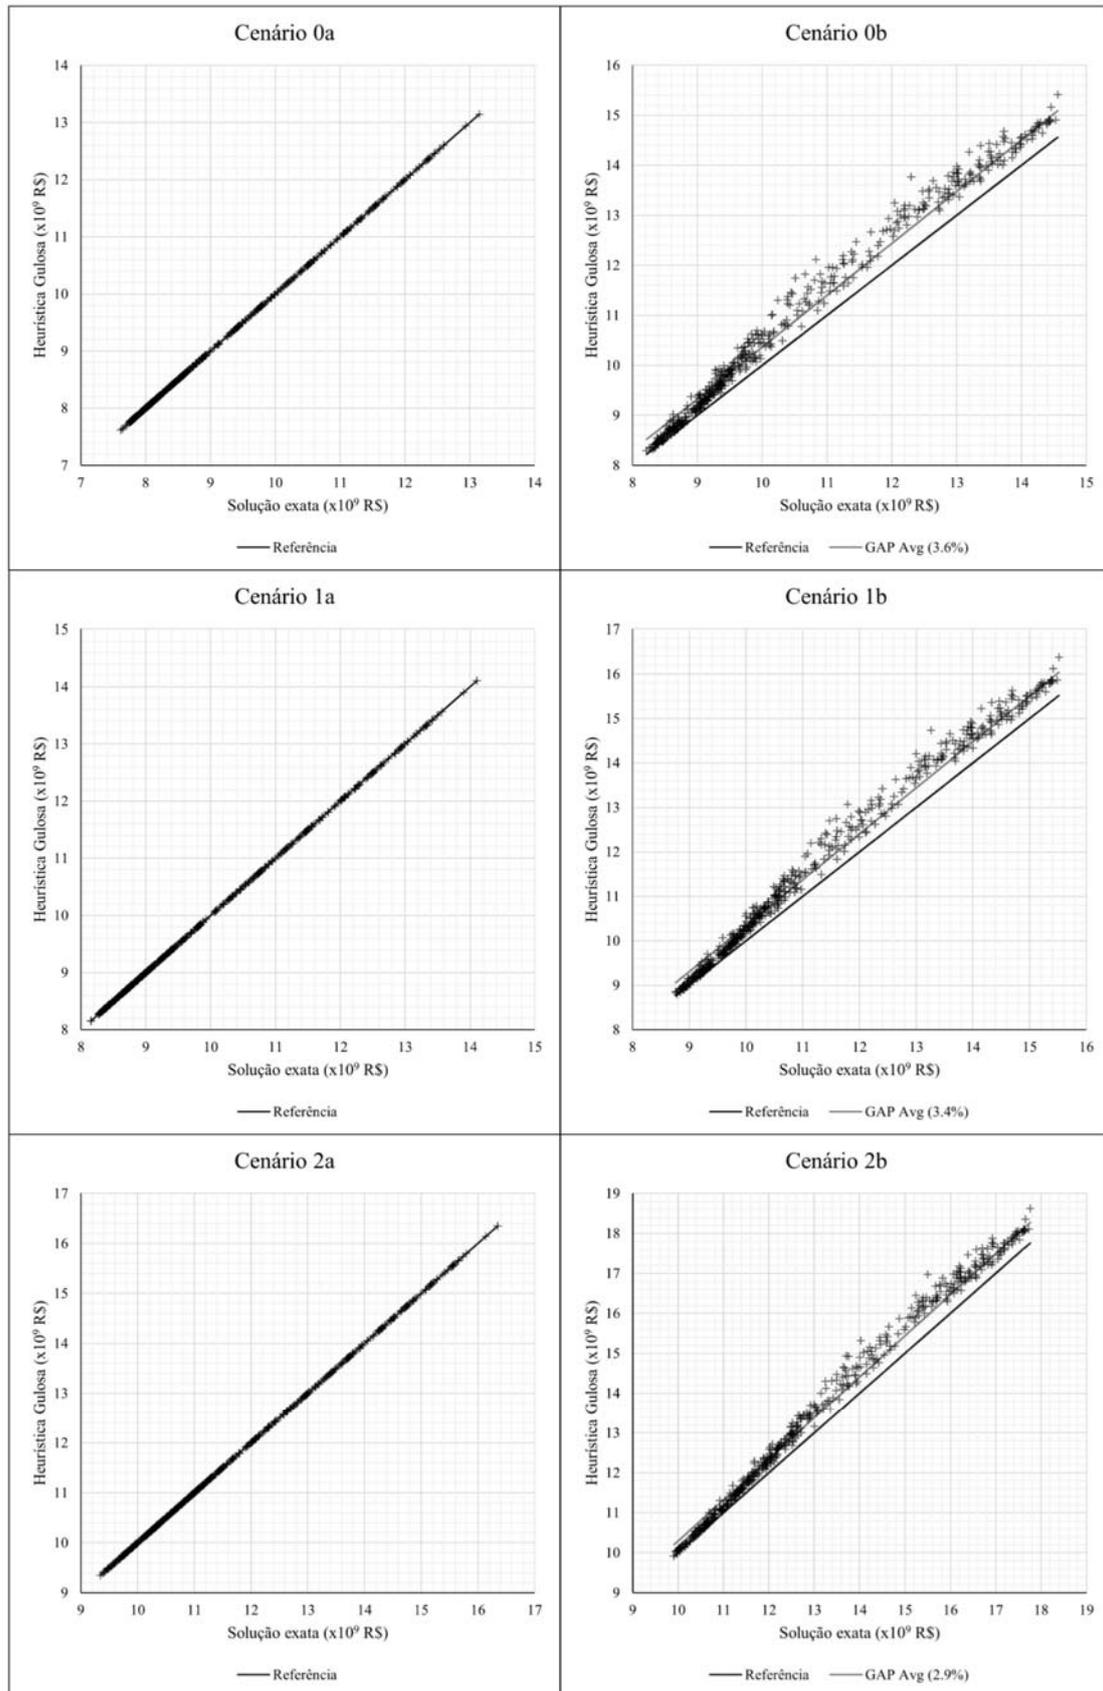


Figura E.1: Gráfico de dispersão dos valores de aptidão obtidos para uma amostra de 500 indivíduos aleatórios utilizando-se um *solver* comercial e a heurística gulosa proposta.

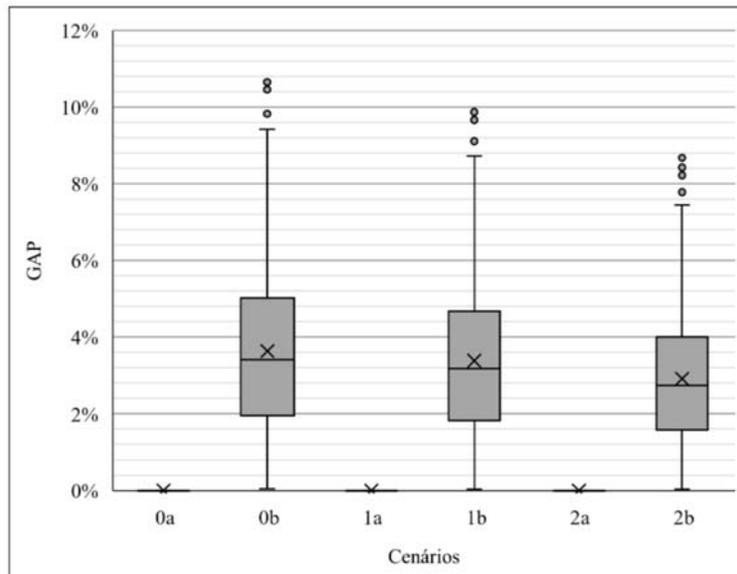


Figura E.2: GAP ao comparar o valor de aptidão de cada indivíduo para cada cenário de avaliação para uma amostra de 500 indivíduos aleatórios.

Já a Figura E.3 apresenta o diagrama de caixas para o tempo computacional de avaliação da aptidão de cada indivíduo. Observa-se que, utilizando-se o *solver*, este procedimento poderia levar entre 8 e 11 segundos, o que pode ser reduzido para abaixo de 1 segundo utilizando-se o procedimento heurístico. Este ganho faz-se relevante uma vez que, em cada iteração do AG, toda uma população de indivíduos deve ser avaliada.

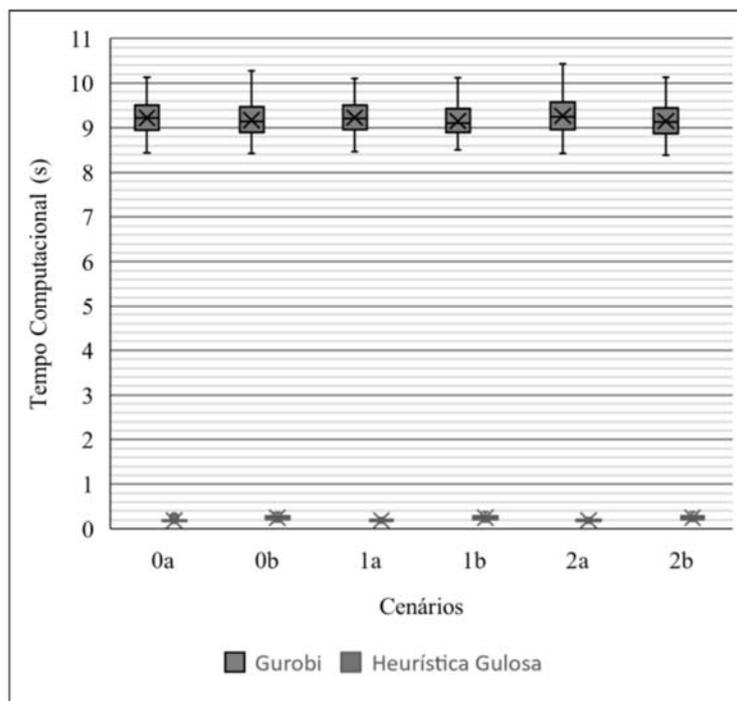


Figura E.3: Tempos computacionais para cálculo do valor de aptidão de cada indivíduo para cada cenário de avaliação para uma amostra de 500 indivíduos aleatórios.

Apêndice F

Parâmetros do AG

F.1 Calibragem dos parâmetros do AG

Os algoritmos genéticos possuem parâmetros importantes para a condução do processo evolutivo, como o tamanho da população e a taxa de probabilidade de mutação. O correto ajuste destes parâmetros podem influenciar na eficiência dos AGs tanto em escapar de mínimos locais quanto explorar o espaço de soluções viáveis com menor custo computacional. No entanto, de forma geral, o processo evolutivo dos AGs tem início a partir de uma população inicial constituída por indivíduos criados de forma aleatória. Além disto, há ainda aleatoriedade nos procedimentos de reprodução e construção da geração seguinte. Por tanto, o comportamento de convergência do processo evolutivo é diferente em cada aplicação do procedimento heurístico e, conseqüentemente, irá resultar em um custo computacional específico.

Sabendo-se deste comportamento estocástico dos AGs, os gráficos de *time-to-target*, ou ttt-plots, tem por objetivo apresentar a probabilidade que um algoritmo irá encontrar uma solução pré-definida (alvo, ou *target*) para a instância avaliada em função do tempo computacional gasto. Desta forma, são uma ferramenta útil para caracterizar os tempos de processamento de algoritmos estocásticos para problemas de otimização combinatória e para comparar diferentes algoritmos ou estratégias para solução destes problemas (AIEX *et al.* [127], REYES e RIBEIRO [128]).

A metodologia para a produção de ttt-plots tem início com a avaliação da instância utilizando-se o procedimento heurístico a ser testado até que seja obtida uma solução alvo. Realizadas n aplicações, os tempos computacionais são então ordenados de forma crescente e, posteriormente, para cada i -ésimo tempo computacional t_i , calcula-se a probabilidade de ocorrência a partir da equação $p_i = (i - 1/2)/n$. Por fim, são construídos os gráficos projetando-se os valores de probabilidade no eixo das ordenadas e de tempo no eixo das abscissas.

As soluções ótimas para as instâncias do problema (discutidas na Seção 2.4.3)

podem ser selecionadas como alvo, permitindo utilizar a metodologia de ttt-plots para orientar a decisão dos parâmetros do AG de acordo com os custos computacionais. Este procedimento foi implementado em Python para avaliação do AG proposto. Assim, visando avaliar a sensibilidade do comportamento estocástico de convergência do AG proposto a partir da alteração dos diferentes parâmetros de entrada, considerou-se, como alvo:

- A matriz de distribuição da soja produzida na região Centro-Oeste brasileira, denominada Instância *CO*, por ser a menor instância criada e ser a região com maior volume de soja a ser transportado;
- O Cenário 0b de avaliação, por ter sido o que exigiu maior custo computacional para obtenção da solução por método exato e, ainda, o único cenário que apresentou, para esta instância, abertura de CILs em períodos futuros (ver Tabela 2.11 e Tabela D.1).

Para a avaliação, considerou-se o AG apenas com indivíduos aleatórios na população inicial e sem máscara de viabilidade (ou seja, indivíduos inviáveis recebem o valor de aptidão igual a infinito). Como critério de parada (ou alvo), adotou-se soluções com GAP menores do que 5% em relação à solução ótima da instância elencada.

Os parâmetros selecionados para calibragem foram: tamanho da população (40, 60, 80 e 120 indivíduos), tamanho do conjunto elite (10% e 20% do tamanho da população) e probabilidade de mutação (5%, 10%, 15%, 25%). Para cada combinação de parâmetros, aplicou-se dez repetições do procedimento heurístico, registrando-se os tempos obtidos até atingir o critério de parada. Os gráficos dos ttt-plots estão localizados no Apêndice G.

Na Tabela F.1, é possível observar e comparar dois indicadores de desempenho importantes do processo evolutivo do AG proposto: tempo computacional e número de gerações. Assim, para as instâncias avaliadas, apresenta-se: nas três primeiras colunas, os parâmetros avaliados; na quarta e quinta colunas, o menor e o maior tempo computacional observados; na sexta e sétima colunas, os tempos recorridos para atingir a solução sub-ótima (com desvio de até 5%) para 50% e 80% dos testes; na oitava e nona coluna, o menor e maior número de gerações observados; e na décima e décima primeira colunas, a quantidade de gerações requeridas para atingir a solução sub-ótima para 50% e 80% dos testes.

Para avaliação dos resultados presentes na Tabela F.1, construiu-se diagrama de caixas com as informações de tempo computacional (Figura F.1) e de quantidade de gerações requeridas (Figura F.2). Cabe ressaltar que cada elemento do gráfico (ou caixa) representa o agrupamento dos parâmetros avaliados, ou seja, é constituído pelos dados de cada coluna da tabela, separando-os em $\mathcal{E}_{10\%}$ e $\mathcal{E}_{20\%}$.

Tabela F.1: Resultados da análise dos ttt-Plots para afinação dos parâmetros.

Elite	P_{mut}	Tamanho População	Tempo computacional (s)				Gerações			
			Menor	Maior	$p_{50\%}$	$p_{80\%}$	Menor	Maior	$p_{50\%}$	$p_{80\%}$
10%	5%	40	870	6.344	1.600	2.820	68	461	120	206
10%	5%	60	1.546	3.782	2.049	2.913	75	182	97	137
10%	5%	80	1.554	5.470	2.360	2.632	57	196	83	94
10%	5%	120	2.466	4.898	3.424	4.395	58	108	78	95
10%	15%	40	565	1.986	999	1.241	49	146	78	95
10%	15%	60	659	2.212	1.288	1.673	35	105	63	81
10%	15%	80	908	2.499	1.682	2.275	34	86	60	79
10%	15%	120	1.302	2.710	1.733	2.037	32	62	39	48
10%	25%	40	432	1.354	814	1.065	39	106	67	87
10%	25%	60	534	2.213	938	1.157	30	108	51	58
10%	25%	80	827	2.292	1.447	1.660	34	82	54	60
10%	25%	120	828	1.967	1.287	1.758	20	45	31	41
20%	5%	40	1.077	3.427	1.957	2.410	82	248	145	175
20%	5%	60	1.255	4.412	2.790	3.553	59	207	128	164
20%	5%	80	4.525	14.238	7.183	13.096	137	413	213	376
20%	15%	40	1.139	2.267	1.438	1.833	87	167	106	137
20%	15%	60	1.107	3.077	1.717	2.150	54	139	80	99
20%	15%	80	1.481	4.070	3.151	3.603	47	123	95	109
20%	15%	120	7.242	25.688	10.692	14.752	123	432	181	246
20%	25%	40	593	1.512	973	1.132	49	109	75	90
20%	25%	60	853	2.039	1.219	1.492	42	96	58	72
20%	25%	80	980	2.896	1.699	2.161	32	88	54	68
20%	25%	120	6.155	12.845	7.958	10.216	102	177	133	169

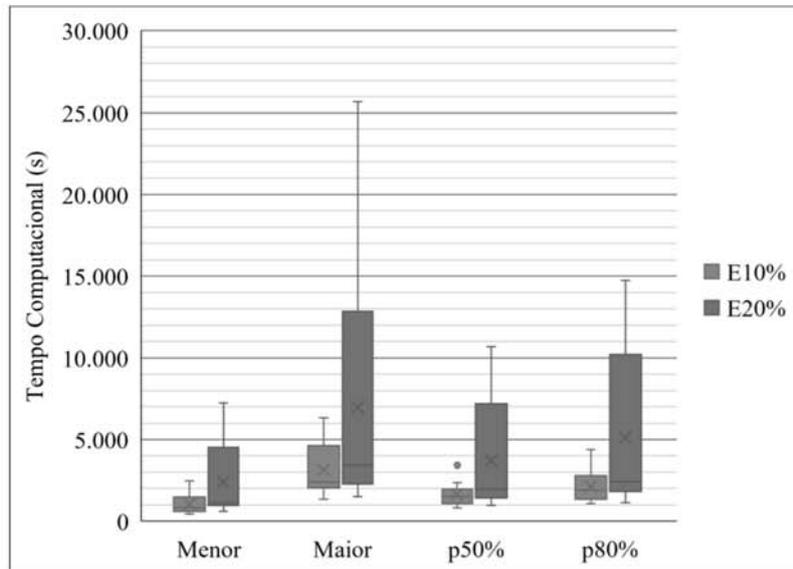


Figura F.1: Tempos computacionais observados para atingir o alvo para conjunto elite com tamanho equivalente a 10% e 20% do tamanho da população.

Ao avaliar os resultados obtidos para o conjunto $\mathcal{E}_{10\%}$, em comparação aos do conjunto $\mathcal{E}_{20\%}$, observou-se, de forma geral, menores médias e medianas, além de menores distâncias entre o primeiro e terceiro quartis, tanto para os tempos computacionais quanto para a quantidade de gerações requeridas para atingir a solução alvo ao variar os parâmetros. Nota-se que os maiores valores obtidos para cada caixa do

$\mathcal{E}_{10\%}$, tanto para tempo computacional quanto para as quantidades de gerações, são menores que as médias apresentadas para o $\mathcal{E}_{20\%}$. Comparando-se, ainda, as caixas que indicam os tempos computacionais e a quantidade de gerações necessárias para 80% das repetições atingirem o alvo (caixas denominadas “p80%”), verifica-se que, com o tamanho de 10%, os custos computacionais são menores. Por estes motivos, adotou-se o tamanho do conjunto \mathcal{E} igual a 10% do tamanho da população.

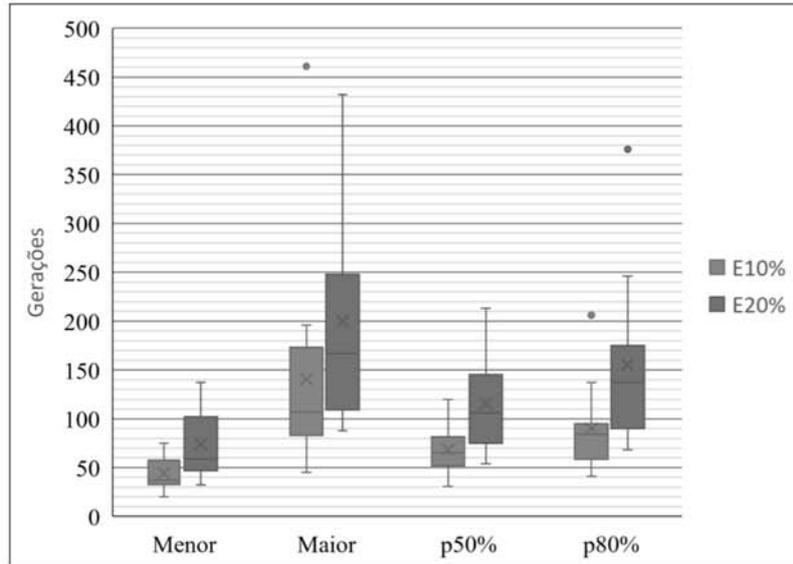


Figura F.2: Quantidade de gerações requeridas para atingir o alvo para conjunto elite com tamanho equivalente a 10% e 20% do tamanho da população.

Além do tamanho da população, a diversificação dos cromossomos é também importante para o processo de busca, pois permite explorar diferentes locais e, ainda, auxilia na fuga de mínimos locais. Assim, faz-se importante avaliar simultaneamente os resultados obtidos para os parâmetros tamanho da população e probabilidade de mutação (p_{mut}) presentes na Tabela F.1. A Figura F.3 e Figura F.4 apresentam, para cada tamanho de população (40, 60, 80 e 120 indivíduos) e para cada probabilidade de mutação (5%, 15% e 25%), os tempos computacionais e a quantidade de gerações requeridas para 80% dos testes atingirem a solução alvo. Foram considerado, nesta análise, apenas os resultados do $\mathcal{E}_{10\%}$, uma vez que este tamanho de conjunto elite foi selecionado para ser utilizado.

Ao avaliar visualmente o coeficiente angular de ambas figuras, observa-se que, para quase todos os tamanhos de população, há maior redução no custo computacional quando há o aumento da probabilidade de mutação de 5% para 15% (expresso pela maior inclinação da reta entre os pontos) do que para o aumento da probabilidade de 15% para 25%. Apenas quando utilizado 80 indivíduos na população que a redução no custo computacional foi quase similar para ambos aumentos da probabilidade de mutação.

Apesar do maior valor de mutação ter resultado em menores custos computaci-

onais, sabe-se que valores elevados para este parâmetro podem resultar em maiores chances de perda de alelos adaptados. Observa-se, ainda, que, embora a população com 120 indivíduos requiera menos gerações (iterações), o procedimento heurístico completo para este maior tamanho de população resultou em maior tempo computacional. Isto se deve à maior quantidade de aplicações dos operadores de reprodução e avaliação dos indivíduos.

Por este motivo, optou-se por utilizar população com 80 indivíduos e probabilidade de mutação de 15% para as instâncias com apenas indivíduos aleatórios na população inicial. Este tamanho de população atende a sugestão de ALANDER [80], que sugere o tamanho da população ao menos igual o comprimento do cromossomo. Por outro lado, para as instâncias com indivíduos relaxados na população inicial, optou-se por utilizar populações com 60 indivíduos, uma vez que são adicionados cromossomos bem adaptados desde a primeira geração.

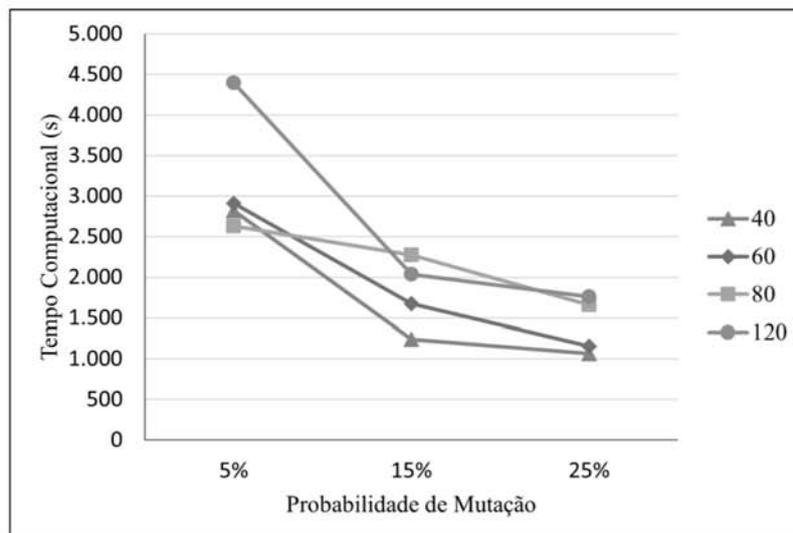


Figura F.3: Tempos computacionais para atingir o alvo em 80% das aplicações variando-se o tamanho da população e probabilidade de mutação.

F.2 Comparação entre as Máscaras de Viabilidade

Duas abordagens foram apresentadas para a transformação de cromossomos inviáveis em soluções viáveis: Máscara de viabilidade por período crescente (Máscara 1); e Máscara de viabilidade por período decrescente (Máscara 2). Com o objetivo de avaliar o impacto destas abordagens no AG, executou-se dez repetições do procedimento heurístico para cada máscara de viabilidade proposta até que uma solução com GAP de até 5% fosse obtida. Utilizou-se, para esta avaliação, a instância *CO* e Cenário 0b, além dos parâmetros já definidos anteriormente: população com 60 e 80 indivíduos, tamanho do conjunto \mathcal{E} de 10% do tamanho da população e proba-

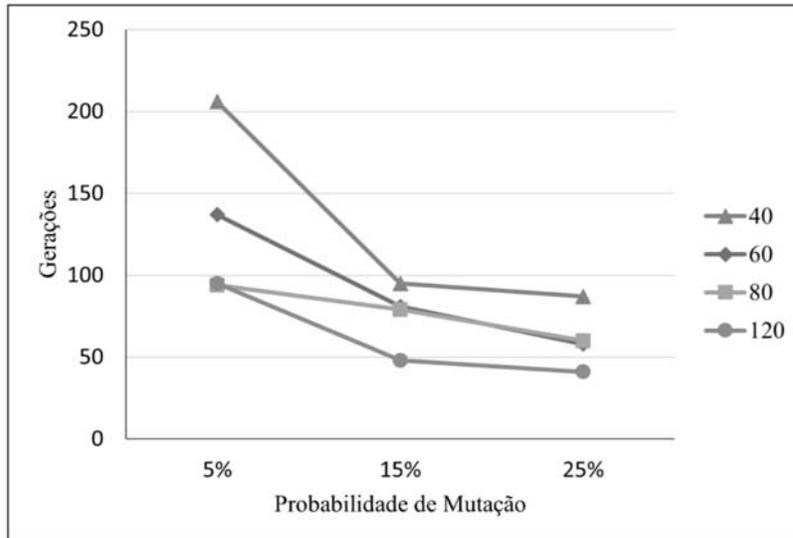


Figura F.4: Quantidade de gerações requeridas para atingir o alvo em 80% das aplicações variando-se o tamanho da população e probabilidade de mutação.

bilidade de mutação de 0,15. Desta avaliação, registrou-se o tempo computacional; a quantidade de gerações; e a quantidade de redefinições da população.

A Figura F.5 e a Figura F.6 apresentam, respectivamente, os diagramas de caixas formados pelo tempo computacional e número de gerações observados para as dez aplicações de cada situação avaliada. Observou-se que a utilização da Máscara 2 resultou em menores valores de tempo computacional para populações com 80 indivíduos. Por este motivo, esta foi adotada para aplicação

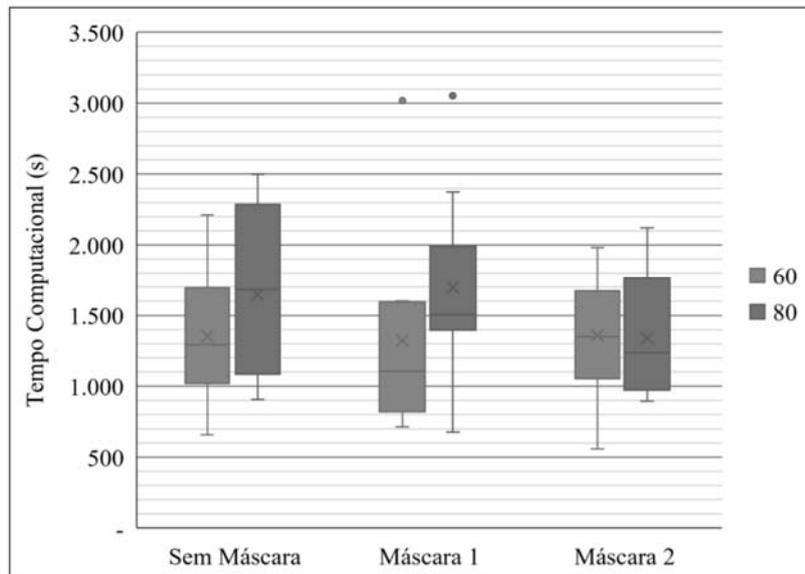


Figura F.5: Tempos computacionais observados ao aplicar o AG sem e com máscara de viabilidade em populações com 80 e 60 indivíduos.

Com o objetivo de investigar a relação entre a quantidade de gerações e a de redefinições da população, elaborou-se o gráfico de dispersão apresentado na Figura F.7.

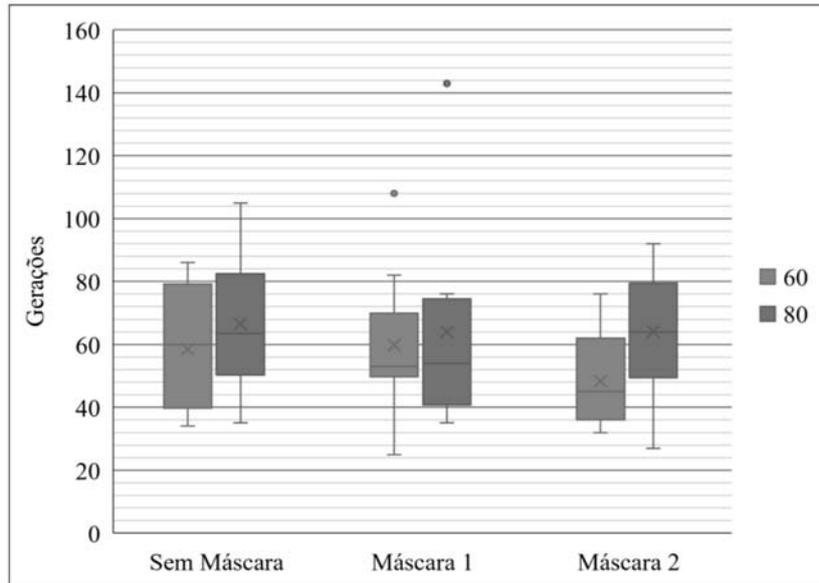


Figura F.6: Gerações requeridas ao aplicar o AG sem e com máscara de viabilidade em populações com 80 e 60 indivíduos.

Para os resultados de ambas as máscaras para os dois tamanhos de população, foi possível ajustar uma linha de tendência por regressão linear com coeficiente R^2 igual a 0,9959. A partir deste ajuste, conforme apresentado na figura, obteve-se que a quantidade aplicada de redefinições da população é de aproximadamente 43% do total de gerações (coeficiente angular). Este parâmetro é útil para orientar a escolha da quantidade mínima de redefinições da população como critério de parada (critério 6 da Tabela 2.5).

F.3 Escolha do método para indivíduos relaxados

A partir da solução relaxada obtida, utilizando-se o Gurobi, avaliou-se o desempenho de se inserir os indivíduos relaxados na população inicial. Para isso, utilizou-se os três métodos propostos para geração dos indivíduos relaxados: Método [1], melhora da solução; Método [2], abertura precoce; e Método [3], um indivíduo para cada período. Foram realizados ensaios considerando cada método individualmente e, posteriormente, combinações destes. Para cada situação, realizou-se cinco aplicações.

Apresenta-se, na Tabela F.2, o desempenho do AG sem e com indivíduos relaxados na população inicial para os cenários 0a e 0b da instância *CO* (indicados na primeira coluna). O método de construção do indivíduo relaxado é indicado na segunda coluna, sendo [0] a ausência de indivíduos relaxados na população inicial. Posteriormente, nas colunas três a dez, apresenta-se os valores mínimos, médios e máximos, além do desvio padrão, calculados para o GAP e o tempo computa-

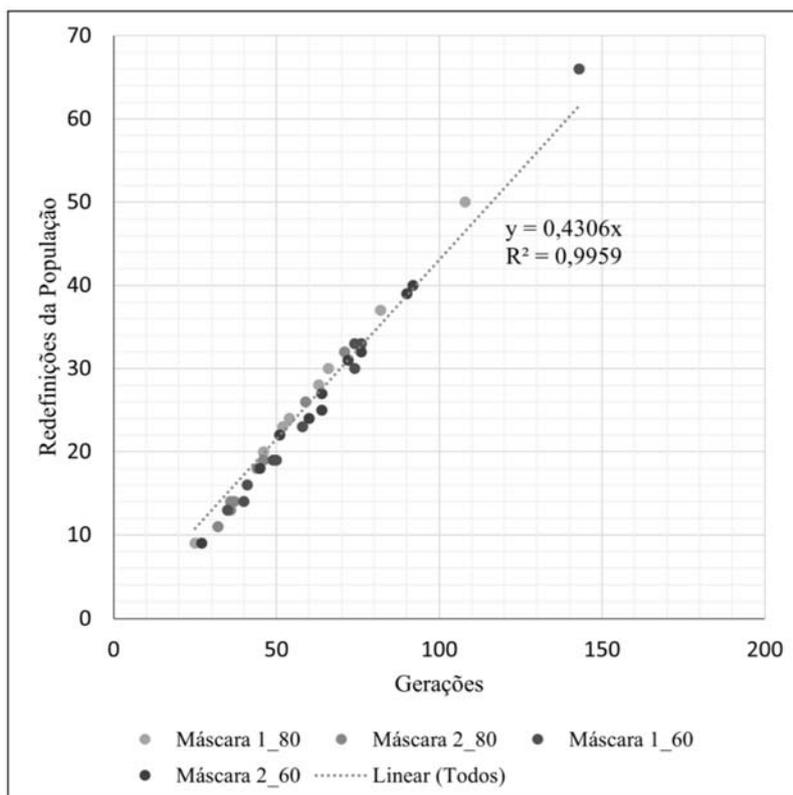


Figura F.7: Quantidade de redefinições da população em função do número de gerações.

cional total a partir das repetições realizadas. O GAP foi calculado através da Equação (2.13) e o tempo computacional total é resultado da soma entre o tempo necessário para a obtenção da solução relaxada no Gurobi e o tempo corrido da aplicação do AG. Os resultados de GAP e tempo computacional total para cada repetição realizada são ilustrados, respectivamente, na Figura F.8 e Figura F.9.

Para o Cenário 0a, verifica-se melhores resultados, tanto em GAP quanto em tempo computacional, ao serem inseridos indivíduos produzidos pelos métodos 2 ou 3 na população inicial. A melhora foi observada a partir da inserção tanto isolada destes indivíduos quanto combinada com outros métodos. Já para o Cenário 0b, obteve-se melhores resultados médios ao utilizar, tanto individualmente quanto em conjunto com outros métodos, indivíduos gerados a partir do método 1. Cabe destacar que, para todas as combinações de aplicação do método 1 para o cenário 0b (individualmente ou em conjunto com os demais métodos) foram avaliadas 20 gerações sem melhora, sendo o algoritmo interrompido em consequência do critério de parada 3 – número máximo de gerações consecutivas sem melhora da solução e com quantidade de redefinições da população variando entre 7 e 9 (abaixo do mínimo estabelecido, uma vez que o Critério 3 é independente, como ilustrado na Figura 2.11).

Neste contexto, optou-se, para aplicação às instâncias maiores, a inclusão de

Tabela F.2: Resultados do AG proposto para a instância CO sem e com indivíduos relaxados na população inicial.

Cenário	Método indivíduo relaxado	GAP (%)				Tempo Computacional (minutos)			
		Min.	Méd.	Max.	Desvio Padrão	Min.	Méd.	Max.	Desvio Padrão
0a	[0]	1.00	1.83	2.57	0.7	8.7	9.5	9.9	0.5
	[1]	0.9	1.7	2.3	0.6	10.5	11.9	14.2	1.4
	[2]	0.0	0.0	0.0	0.0	8.5	8.7	8.9	0.2
	[3]	0.0	0.0	0.0	0.0	8.5	8.7	8.8	0.1
	[1, 2]	0.0	0.0	0.0	0.0	8.8	9.0	9.1	0.1
	[1, 3]	0.0	0.0	0.0	0.0	8.7	8.8	8.9	0.0
	[2, 3]	0.0	0.0	0.0	0.0	8.6	8.6	8.8	0.1
	[1, 2, 3]	0.0	0.0	0.0	0.0	8.8	8.9	8.9	0.0
0b	[0]	1.1	3.7	10.0	3.7	18.8	37.1	50.6	13.6
	[1]	3.1	3.1	3.1	0.0	9.7	10.0	10.2	0.2
	[2]	0.3	3.7	13.3	5.5	12.8	39.6	56.2	19.3
	[3]	0.3	5.2	9.3	3.8	11.2	21.9	52.1	17.3
	[1, 2]	3.1	3.1	3.1	0.0	9.8	10.1	10.5	0.3
	[1, 3]	3.1	3.1	3.1	0.0	9.6	10.0	10.5	0.3
	[2, 3]	0.3	2.1	5.1	1.9	12.8	31.5	43.9	13.4
	[1, 2, 3]	3.1	3.1	3.1	0.0	9.7	10.0	10.4	0.3

Legenda: [0] - sem indivíduo relaxado; [1] - Método 1; [2] - Método 2; [3] - Método 3; [1, 2] - Métodos 1 e 2; [1, 3] - Métodos 1 e 3; [2, 3] - Métodos 2 e 3; [1, 2, 3] - Métodos 1, 2 e 3.

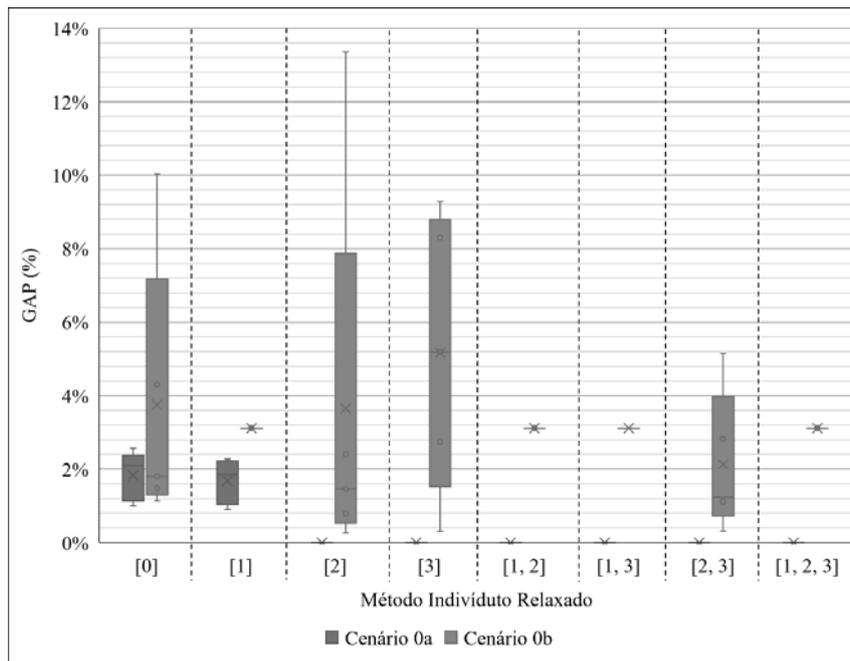


Figura F.8: Valores de GAP observados ao aplicar o AG proposto sem e com indivíduos relaxados na população para os cenários 0a e 0b.

indivíduos relaxados obtidos a partir dos três métodos simultaneamente. Assim, aumenta-se a probabilidade de inserção de cromossomos com informações bem adaptadas, auxiliando a convergência do procedimento evolutivo proposto.

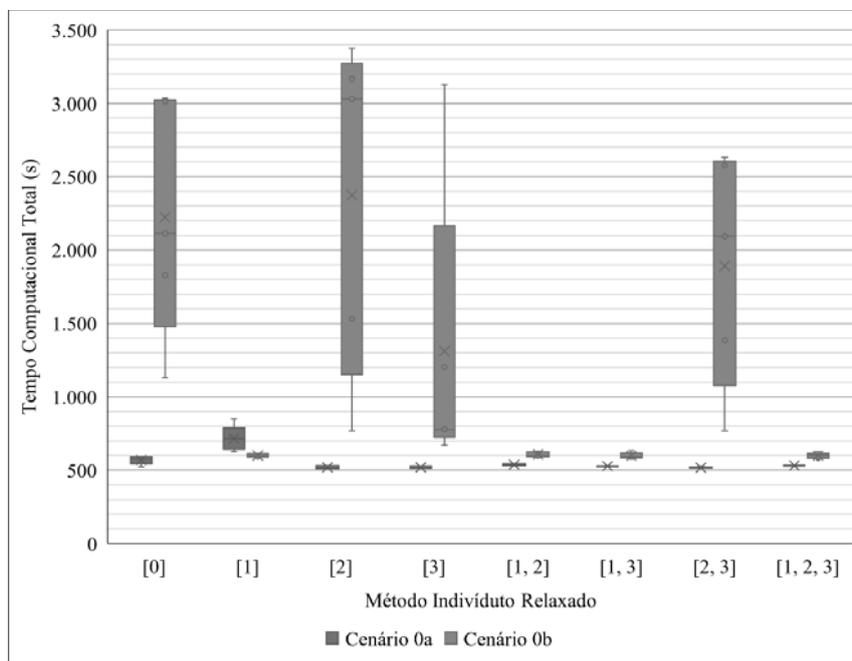


Figura F.9: Tempos computacionais observados ao aplicar o AG proposto sem e com indivíduos relaxados na população para os cenários 0a e 0b.

Apêndice G

Time-to-target plots

Este apêndice tem por objetivo apresentar os gráficos resultantes da aplicação da metodologia de *time-to-target* (ttt-plot) agrupados segundo o tamanho do conjunto elite, seguido da probabilidade de mutação (p_{mut}) e do tamanho da população.

G.1 Ttt-plots para $\mathcal{E}_{10\%}$

G.1.1 $p_{mut} = 0,05$

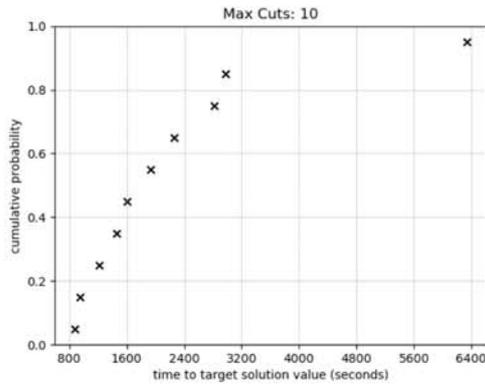


Figura G.1: População com 40 indivíduos.

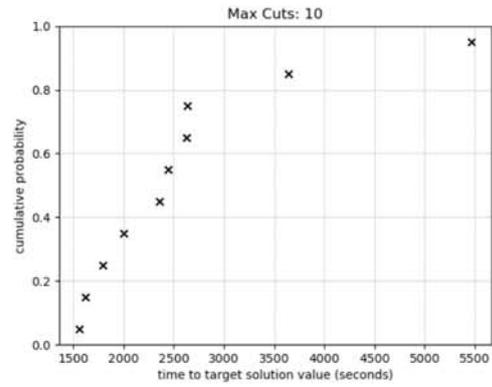


Figura G.3: População com 80 indivíduos.

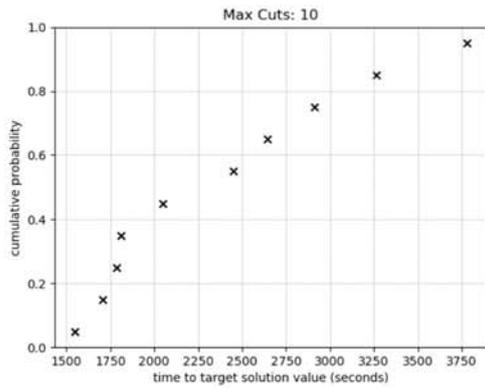


Figura G.2: População com 60 indivíduos.

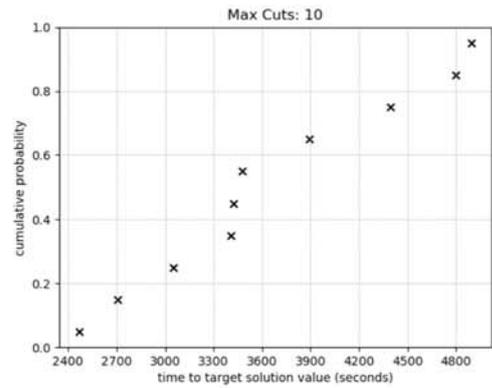


Figura G.4: População com 120 indivíduos.

G.1.2 $p_{mut} = 0,15$

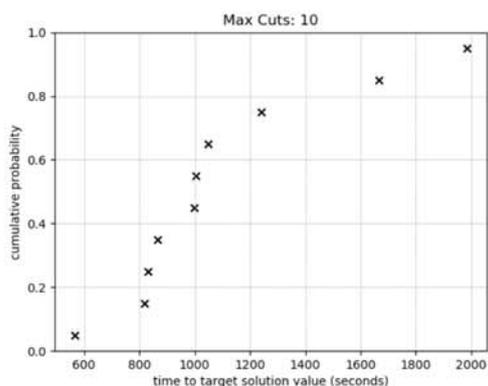


Figura G.5: Ttt-plot para população com 40 indivíduos.

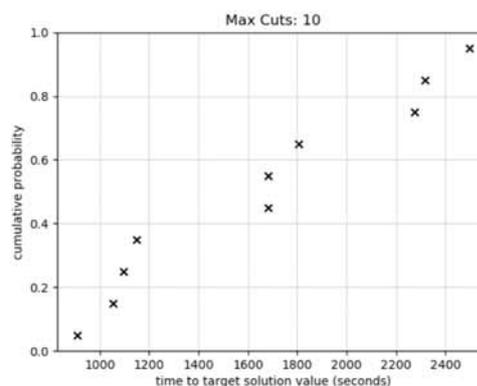


Figura G.7: Ttt-plot para população com 80 indivíduos.

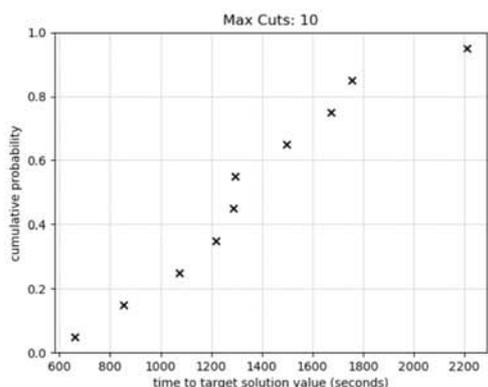


Figura G.6: Ttt-plot para população com 60 indivíduos.

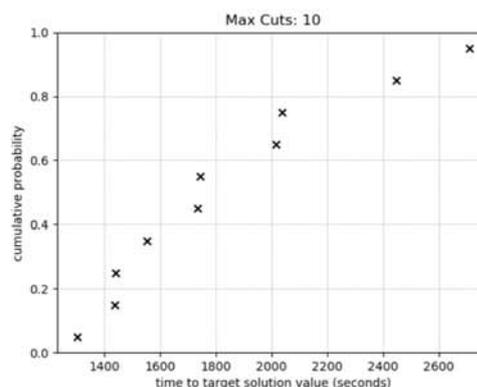


Figura G.8: Ttt-plot para população com 120 indivíduos.

G.1.3 $p_{mut} = 0,25$

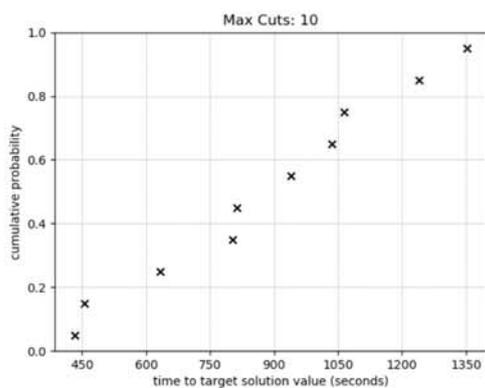


Figura G.9: Ttt-plot para população com 40 indivíduos.

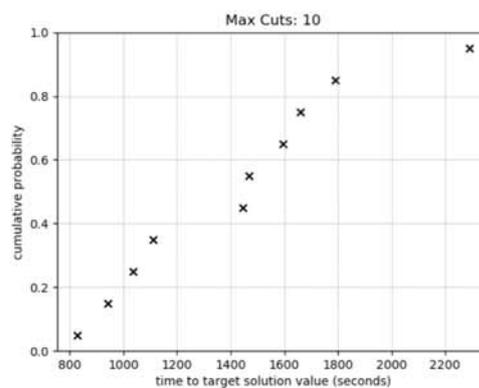


Figura G.11: Ttt-plot para população com 80 indivíduos.

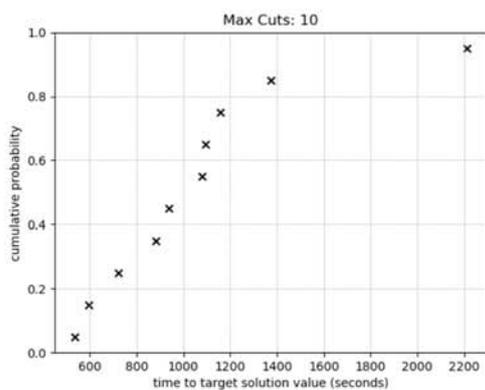


Figura G.10: Ttt-plot para população com 60 indivíduos.

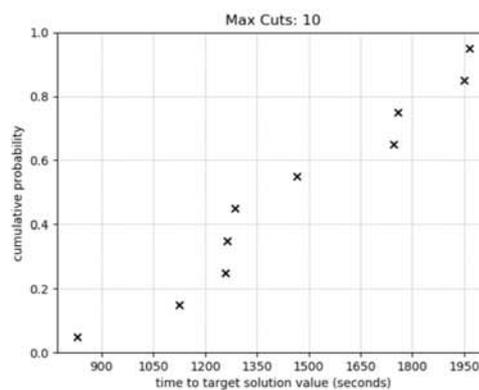


Figura G.12: Ttt-plot para população com 120 indivíduos.

G.2 ttt-plots para $\mathcal{E}_{20\%}$

G.2.1 $p_{mut} = 0,05$

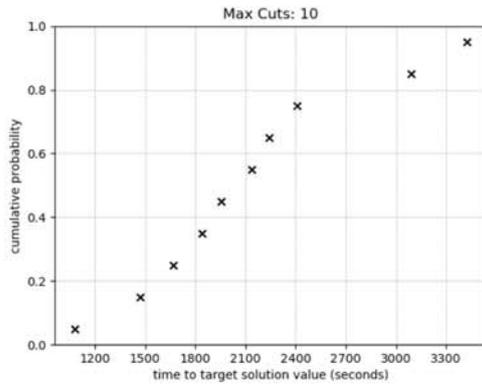


Figura G.13: Ttt-plot para população com 40 indivíduos.

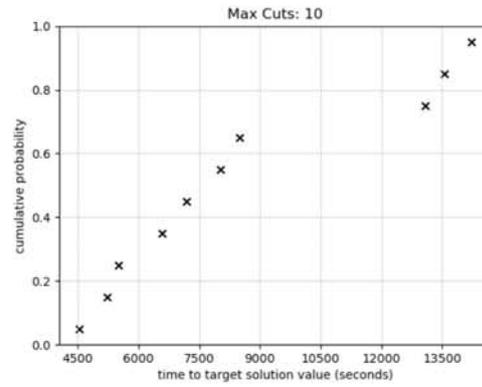


Figura G.15: Ttt-plot para população com 80 indivíduos.

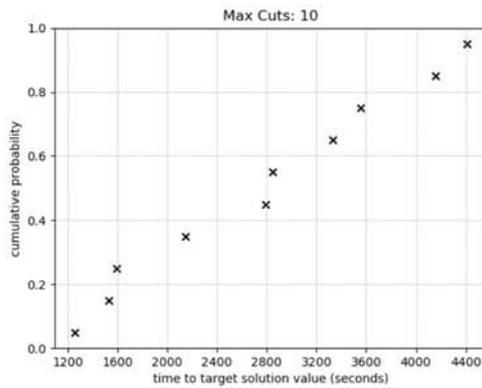


Figura G.14: Ttt-plot para população com 60 indivíduos.

G.2.2 $p_{mut} = 0,15$

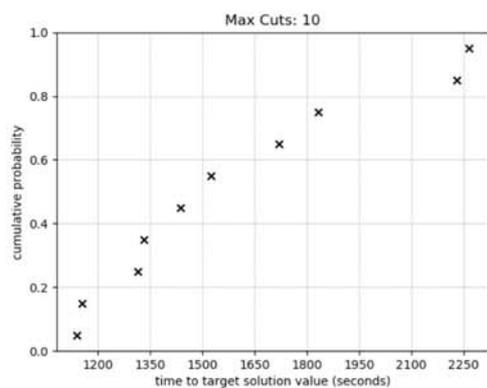


Figura G.16: Ttt-plot para população com 40 indivíduos.

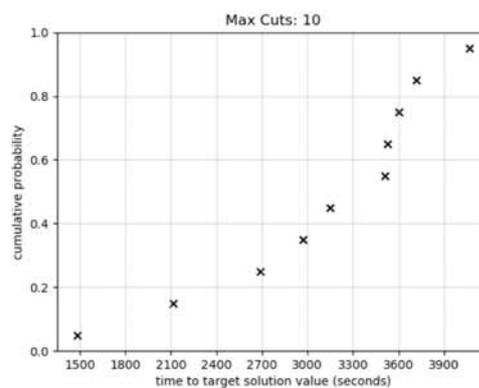


Figura G.18: Ttt-plot para população com 80 indivíduos.

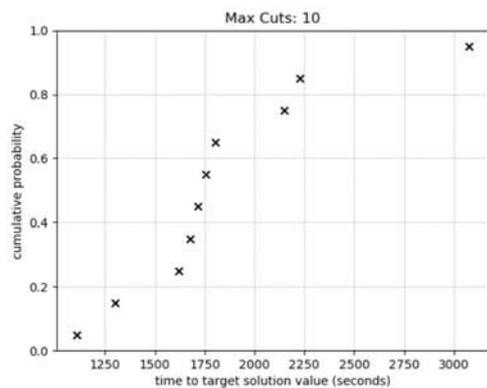


Figura G.17: Ttt-plot para população com 60 indivíduos.

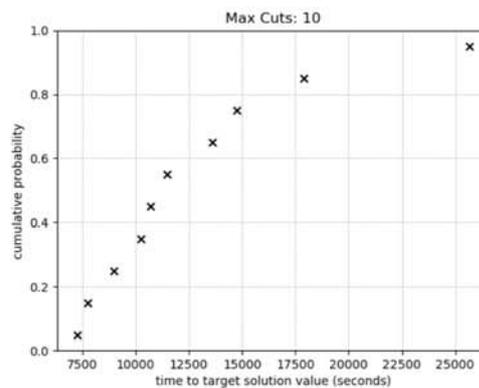


Figura G.19: Ttt-plot para população com 120 indivíduos.

G.2.3 $p_{mut} = 0,25$

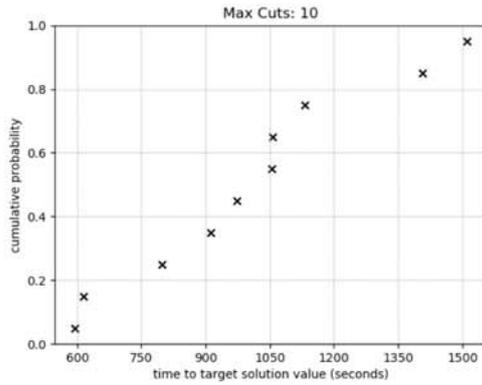


Figura G.20: Ttt-plot para população com 40 indivíduos.

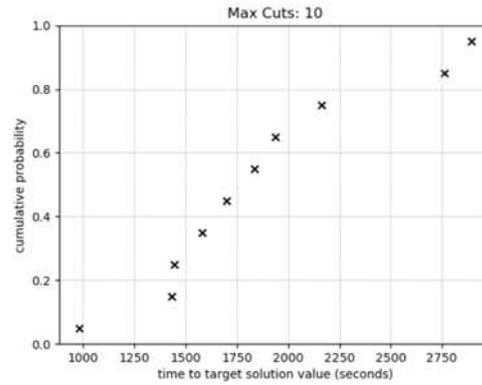


Figura G.22: Ttt-plot para população com 80 indivíduos.

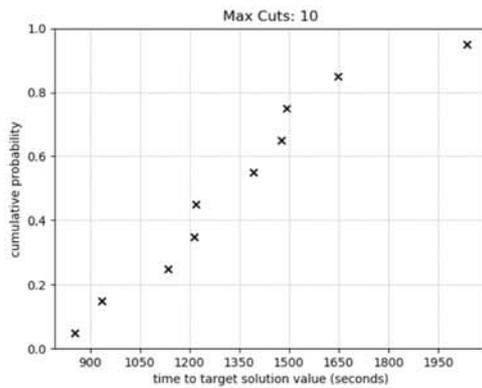


Figura G.21: Ttt-plot para população com 60 indivíduos.

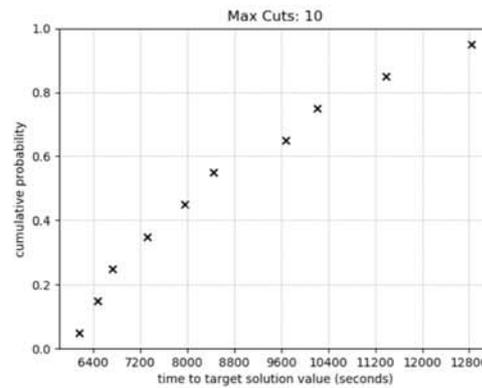


Figura G.23: Ttt-plot para população com 120 indivíduos.

Apêndice H

Resultados para as instâncias de distribuição de soja

Este apêndice tem por objetivo apresentar os diagramas de caixa resultantes da aplicação do Algoritmo Genético proposto para as instâncias *CO*, *COS*, *COSNE*, *COSNESE* e *COSNESEN*.

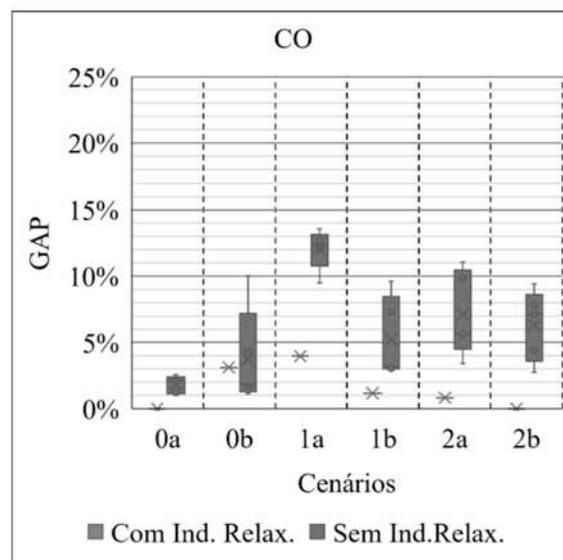


Figura H.1: Valores de GAP obtidos ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância *CO*.

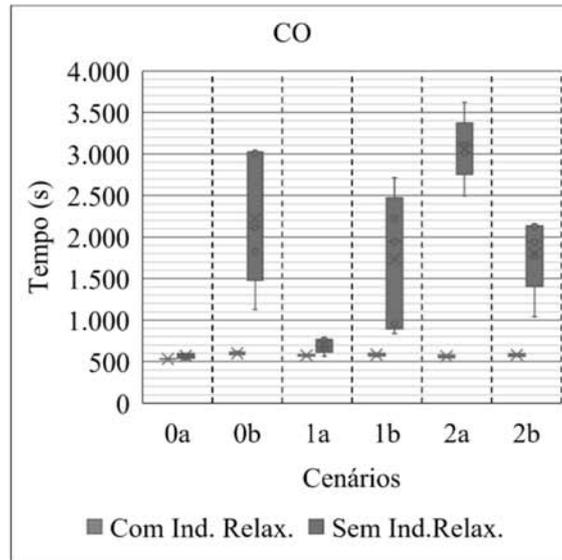


Figura H.2: Tempos computacionais observados ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância *CO*.

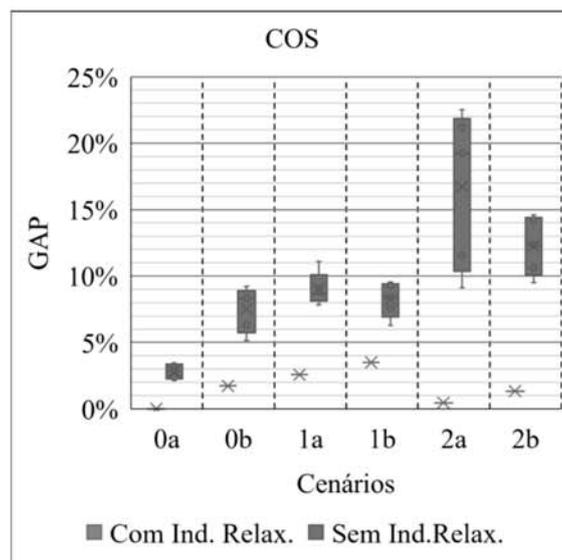


Figura H.3: Valores de GAP obtidos ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância *COS*.

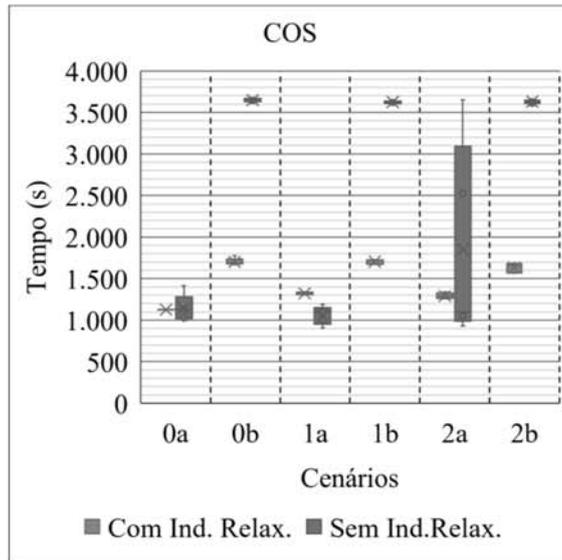


Figura H.4: Tempos computacionais observados ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância *COS*.

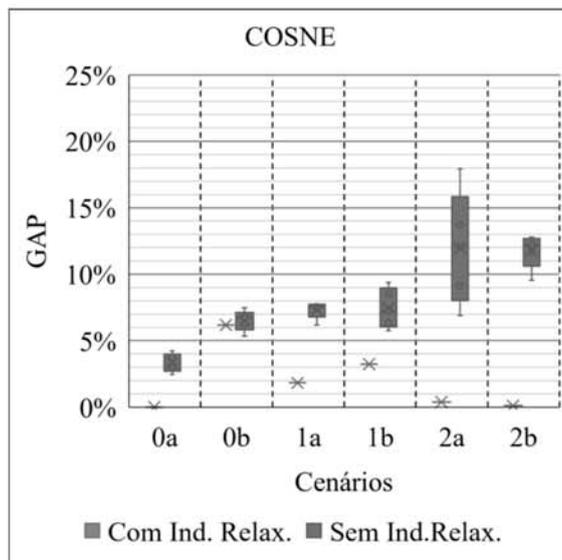


Figura H.5: Valores de GAP obtidos ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância *COSNE*.

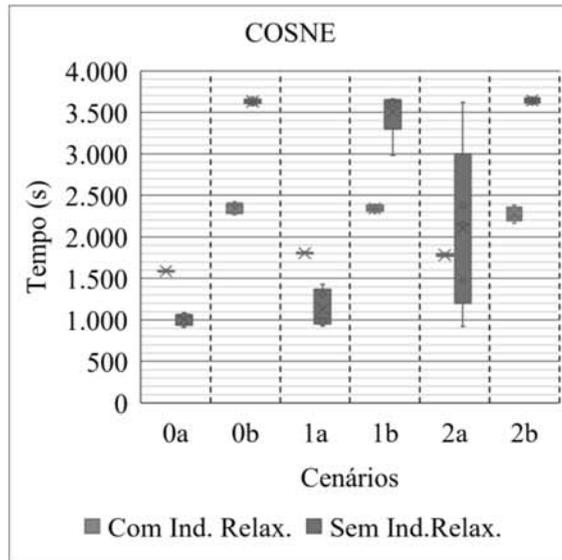


Figura H.6: Tempos computacionais observados ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância *COSNE*.

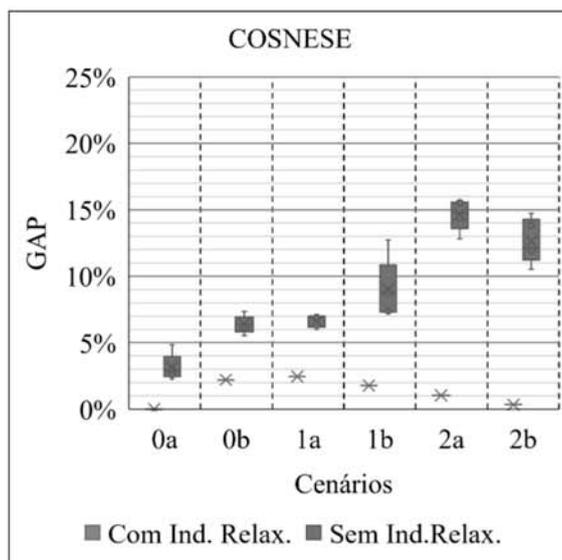


Figura H.7: Valores de GAP obtidos ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância *COSNESE*.

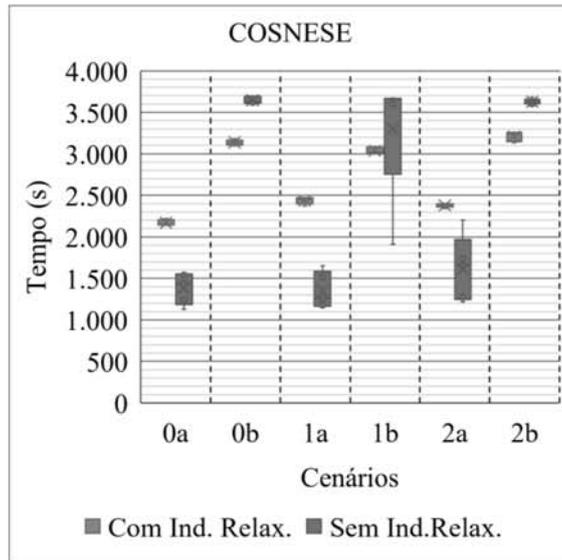


Figura H.8: Tempos computacionais observados ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância *COSNESE*.

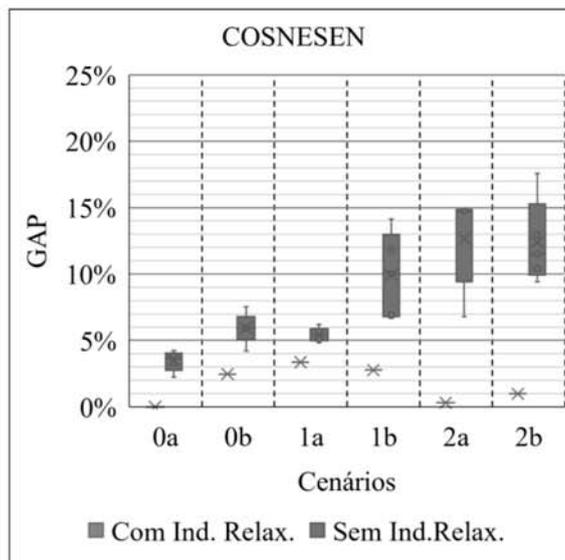


Figura H.9: Valores de GAP obtidos ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância *COSNESEN*.

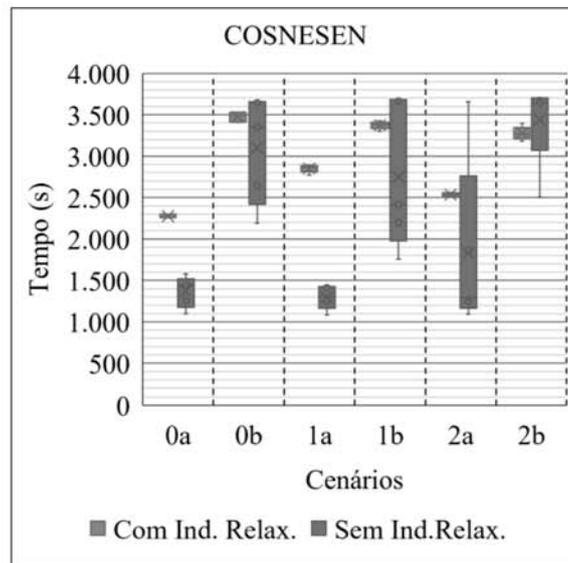


Figura H.10: Tempos computacionais observados ao aplicar o AG proposto sem e com indivíduos relaxados na população para cada cenário de avaliação - Instância *COSNESEN*.

Apêndice I

Análise de Sensibilidade Instâncias

Em uma análise adicional, executou-se uma avaliação de sensibilidade para as instâncias DF+GO_BR e MT_BR visando a possibilidade de obtenção da solução ótima quando reduzida a quantidade de pares OD no conjunto \mathcal{Q} . No entanto, a demanda foi ordenada em ordem decrescente de volume transportado, buscando-se eliminar os pares OD com pouca demanda, reduzindo-se o volume transportado em intervalos de 10% até que fosse atingido 50% do volume total. As informações da quantidade de pares OD e da quantidade de nós e arcos presentes na rede de transporte e nas redes transformadas de cada instância são apresentadas na Tabela I.1.

Tabela I.1: Instâncias avaliadas para a análise de sensibilidade.

Instância	Volume transp. (%)	#Pares OD	Rede de Transporte		Rede de Comunicação		Rede de Comunicação-Espaço-Temporal	
			Nós	Arcos	Nós	Arcos	Nós	Arcos
DF+GO_BR	100	150	92	220	2.424	12.990	14.596	40.052
DF+GO_BR_90	90	53	92	220	785	4.407	4.091	12.985
DF+GO_BR_80	80	35	92	220	522	2.887	8.120	43.335
DF+GO_BR_70	70	25	92	220	337	1.708	5.047	24.848
DF+GO_BR_60	60	19	92	220	259	1.348	3.714	17.488
DF+GO_BR_50	50	14	92	220	178	894	2.694	13.207
MT_BR	100	226	96	234	3.435	11.473	59.380	263.707
MT_BR_90	90	77	96	234	1.131	3.802	19.616	87.334
MT_BR_80	80	52	96	234	688	2.223	11.139	48.015
MT_BR_70	70	38	96	234	467	1.460	7.507	31.881
MT_BR_60	60	27	96	234	339	1.068	5.354	22.674
MT_BR_50	50	19	96	234	209	657	2.949	12.007

Os resultados desta avaliação para as instâncias DF+GO_BR e MT_BR são apresentados, respectivamente, na Tabela I.2 e Tabela I.3. Observa-se que, para as duas instâncias avaliadas, a utilização da solução primal inicial favoreceu o procedimento de otimização e busca da solução.

Tabela I.2: Resultados para a instância DF+GO_BR sem e com solução primal inicial.

Inst.	Sol. inic.	Método	Tempo (s)				Resultados		
			Pré-proc	Modelo	Otimiz.	Total	Solução	GAP (%)	Motivo da Interrupção
DF+GO_BR	Não	S	471	4.889	-	5.360	-	-	Out of Memory
		C	552	3.998	21.600	26.150	-	-	Time Out
		G1	551	4.201	-	4.752	-	-	Out of Memory
		G2	477	5.407	-	5.884	-	-	Out of Memory
		G3	550	4.433	-	4.983	-	-	Out of Memory
	Sim	S	626	7.225	0	7.851	-	-	Out of Memory
		C	464	3.470	21.600	25.534	303.321,61	4,22	Time Out
		G1	459	3.071	-	3.530	-	-	Out of Memory
		G2	467	3.657	-	4.124	-	-	Out of Memory
	G3	557	4.452	-	5.009	-	-	Out of Memory	
DF+GO_BR_90	Não	S	137	465	21.600	22.202	-	-	Time Out
		C	164	484	21.600	22.248	-	-	Time Out
		G1	132	682	21.600	22.414	-	-	Time Out
		G2	133	682	21.600	22.415	-	-	Time Out
		G3	132	701	21.600	22.433	-	-	Time Out
	Sim	S	132	697	21.601	22.430	101.400,55	3,65	Time Out
		C	140	723	21.600	22.463	101.562,60	4,13	Time Out
		G1	135	589	21.600	22.324	101.577,69	4,43	Time Out
		G2	133	585	21.600	22.318	101.532,67	4,27	Time Out
	G3	143	547	21.600	22.290	101.577,69	3,72	Time Out	
DF+GO_BR_80	Não	S	89	242	21.600	21.931	-	-	Time Out
		C	89	212	21.600	21.901	-	-	Time Out
		G1	89	247	21.600	21.936	-	-	Time Out
		G2	107	242	21.600	21.949	-	-	Time Out
		G3	109	245	21.600	21.954	-	-	Time Out
	Sim	S	113	294	21.601	22.008	69.591,55	2,76	Time Out
		C	108	219	21.600	21.927	69.651,60	4,28	Time Out
		G1	108	254	21.600	21.962	69.651,67	4,00	Time Out
		G2	95	255	21.600	21.950	69.646,59	4,29	Time Out
	G3	108	247	21.600	21.955	69.628,61	3,27	Time Out	
DF+GO_BR_70	Não	S	80	133	21.600	21.813	-	-	Time Out
		C	78	101	21.600	21.779	-	-	Time Out
		G1	63	97	21.600	21.760	-	-	Time Out
		G2	76	116	21.600	21.792	-	-	Time Out
		G3	76	115	21.600	21.791	-	-	Time Out
	Sim	S	77	116	21.603	21.796	47.992,51	1,36	Time Out
		C	76	97	21.600	21.773	48.037,68	2,12	Time Out
		G1	76	113	21.600	21.789	48.030,64	3,62	Time Out
		G2	78	120	21.600	21.798	48.008,57	3,82	Time Out
	G3	77	120	21.600	21.797	48.034,61	2,18	Time Out	
DF+GO_BR_60	Não	S	59	70	21.600	21.729	-	-	Time Out
		C	50	47	21.600	21.697	-	-	Time Out
		G1	48	60	21.600	21.708	-	-	Time Out
		G2	49	60	21.600	21.709	-	-	Time Out
		G3	47	56	21.600	21.703	-	-	Time Out
	Sim	S	48	56	13.507	13.611	36.790,47	0,01	Optimality
		C	49	52	21.642	21.743	36.827,50	1,13	Time Out
		G1	49	60	21.600	21.709	36.861,63	3,23	Time Out
		G2	48	58	21.600	21.706	36.841,48	3,01	Time Out
	G3	48	58	21.600	21.706	36.790,47	0,61	Time Out	
DF+GO_BR_50	Não	S	35	42	18.086	18.163	26.108,44	0,01	Optimality
		C	35	34	21.600	21.669	-	-	Time Out
		G1	35	42	21.600	21.677	-	-	Time Out
		G2	128	43	21.600	21.771	26.108,44	0,31	Time Out
		G3	47	61	19.062	19.170	26.108,44	0,01	Optimality
	Sim	S	49	44	13.990	14.083	26.108,44	0,01	Optimality
		C	36	36	21.600	21.672	26.108,44	0,32	Time Out
		G1	36	43	21.600	21.679	26.159,53	2,93	Time Out
		G2	35	42	13.253	13.330	26.108,44	0,01	Optimality
	G3	41	46	11.927	12.014	26.108,44	0,01	Optimality	

Tabela I.3: Resultados para a instância MT_BR sem e com solução primal inicial.

Inst.	Sol. inic.	Método	Tempo (s)				Resultados		
			Pré-proc	Modelo	Otimiz.	Total	Solução	GAP (%)	Motivo da Interrupção
MT_BR	Não	S	878	7.626	-	8.504	-	-	Out of Memory
		C	886	7.627	-	8.513	-	-	Out of Memory
		G1	833	7.431	-	8.264	-	-	Out of Memory
		G2	835	7.592	-	8.427	-	-	Out of Memory
		G3	852	7.766	-	8.618	-	-	Out of Memory
	Sim	S	860	7.742	-	8.602	-	-	Out of Memory
		C	819	8.541	21.600	30.960	519.565,69	5,13	Time Out
		G1	848	7.876	-	8.724	-	-	Out of Memory
		G2	848	7.864	-	8.712	-	-	Out of Memory
		G3	895	10.058	-	10.953	-	-	Out of Memory
MT_BR_90	Não	S	279	979	21.600	22.858	-	-	Time Out
		C	276	886	21.600	22.762	-	-	Time Out
		G1	260	902	21.600	22.762	-	-	Time Out
		G2	284	995	21.600	22.879	-	-	Time Out
		G3	273	930	21.600	22.803	-	-	Time Out
	Sim	S	270	815	-	1.085	-	-	Out of Memory
		C	260	788	21.600	22.648	166.787,66	4,16	Time Out
		G1	263	858	21.601	22.722	166.926,75	4,33	Time Out
		G2	260	857	21.601	22.718	166.926,78	4,29	Time Out
		G3	261	852	21.601	22.714	166.832,67	3,84	Time Out
MT_BR_80	Não	S	177	334	21.600	22.111	-	-	Time Out
		C	181	284	21.605	22.070	-	-	Time Out
		G1	179	319	21.600	22.098	-	-	Time Out
		G2	200	331	21.600	22.131	-	-	Time Out
		G3	200	331	21.600	22.131	-	-	Time Out
	Sim	S	200	329	21.601	22.130	106.632,60	2,50	Time Out
		C	200	306	21.600	22.106	106.769,62	3,35	Time Out
		G1	201	338	21.600	22.139	106.863,71	3,79	Time Out
		G2	199	337	21.600	22.136	106.863,72	3,75	Time Out
		G3	201	337	21.600	22.138	106.786,65	3,05	Time Out
MT_BR_70	Não	S	150	184	21.600	21.934	-	-	Time Out
		C	149	165	21.600	21.914	-	-	Time Out
		G1	152	237	21.600	21.989	-	-	Time Out
		G2	134	167	21.600	21.901	-	-	Time Out
		G3	134	166	21.600	21.900	-	-	Time Out
	Sim	S	129	157	21.600	21.886	77.034,62	1,99	Time Out
		C	129	139	21.600	21.868	77.091,64	3,16	Time Out
		G1	131	182	21.600	21.913	77.097,73	3,41	Time Out
		G2	130	159	21.600	21.889	77.097,64	3,20	Time Out
		G3	132	171	21.600	21.903	77.082,65	2,52	Time Out
MT_BR_60	Não	S	94	104	21.600	21.798	-	-	Time Out
		C	95	90	21.604	21.789	-	-	Time Out
		G1	110	117	21.600	21.827	-	-	Time Out
		G2	110	118	21.600	21.828	-	-	Time Out
		G3	96	98	21.600	21.794	-	-	Time Out
	Sim	S	99	97	21.601	21.797	55.871,59	1,50	Time Out
		C	94	85	21.600	21.779	55.894,60	2,48	Time Out
		G1	93	98	21.600	21.791	55.902,66	3,22	Time Out
		G2	93	99	21.600	21.792	55.899,65	3,07	Time Out
		G3	93	115	21.600	21.808	55.904,61	1,54	Time Out
MT_BR_50	Não	S	64	40	7.989	8.093	36.906,47	0,01	Optimality
		C	64	33	9.520	9.617	36.906,47	0,01	Optimality
		G1	64	40	21.600	21.704	36.906,47	0,11	Time Out
		G2	64	40	21.600	21.704	36.906,47	0,13	Time Out
		G3	64	40	6.156	6.260	36.906,47	0,01	Optimality
	Sim	S	64	40	9.069	9.173	36.906,47	0,01	Optimality
		C	63	36	12.619	12.718	36.906,47	0,01	Optimality
		G1	63	42	21.600	21.705	36.978,51	2,28	Time Out
		G2	61	39	21.600	21.700	36.978,54	1,83	Time Out
G3	45	29	7.238	7.312	36.906,47	0,01	Optimality		