

UNIVERSIDADE FEDERAL DE ITAJUBÁ

PROGRAMA DE PÓS-GRADUAÇÃO EM  
ENGENHARIA DE PRODUÇÃO

Uma Abordagem para Diminuição de Custos na Logística Reversa  
com o Auxílio de Gêmeos Digitais e Otimização Multiobjetivo

Alyson Benoni Matias Pereira

Itajubá, 2024

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

Alyson Benoni Matias Pereira

Uma Abordagem para Diminuição de Custos na Logística Reversa  
com o Auxílio de Gêmeos Digitais e Otimização Multiobjetivo

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

**Área:** Engenharia de Produção

**Orientador:** Prof. Dr. José Arnaldo Barra Monteve-  
chi

2024  
Itajubá - MG

*Dedico aos meus pais, minha irmã e sobrinho, minha noiva e principalmente à minha filha, que sempre me incentivaram e me deram forças para concluir esse trabalho.*

## Agradecimentos

Agradeço, primeiramente à Deus, que, nos momentos mais cansativos, me deu forças e sempre a capacidade e sabedoria suficientes para poder concluir esse trabalho.

Agradeço aos meus pais, David e Cida, que não mediram e ainda não medem esforços para me apoiar, e nos momentos difíceis, o fazem ainda com mais zelo e sempre investiram em minha educação, as vezes deixando de cuidar deles para cuidar de mim, me permitindo ter condições de atingir todos os meus objetivos.

Agradeço a minha irmã Bárbara e ao meu cunhado César, que auxiliaram na conclusão desse trabalho sempre me dando ideias de quais caminhos seguir e ao meu sobrinho Arthur, que sempre me fazia rir quando me chamava para brincar com ele, era uma forma de recarregar as energias para aguentar todo o trabalho pela frente.

Agradeço a minha noiva Ana Paula, que comemorou e comemora sempre comigo os momentos bons, me ajuda não somente dando apoio moral, mas também me auxilia em vários trabalhos, além de me suportar nos momentos de estresse e me apoiar nos momentos de dificuldade, sempre me dando forças pra seguir em frente quando a vontade era desistir. Agradeço-a, principalmente, por gerar e cuidar de nossa filha Alice, fonte de forças e incentivo para que eu pudesse seguir em frente mesmo nas maiores dificuldades. Agradeço também a minha filha, que veio em um momento difícil, porém hoje sei que veio para nos encher de esperança, alegria e vontade de sempre dar o nosso melhor para que ela possa ter um futuro melhor que o nosso.

Agradeço ao meu orientador, Prof. Dr. José Arnaldo que me mostrou sempre o melhor caminho, me cobrou e me forçou a procurar a melhor solução, principalmente quando eu mesmo achava ser impossível. Agradeço ao Prof. Dr. Rafael Miranda, que me deu muitas ideias e me auxiliou também a encontrar o melhor caminho para a conclusão desse trabalho. Por último, agradeço muito ao Prof. Dr. Rafael Frinhani, que em um momento crucial do meu trabalho me acolheu e me deu ideias valiosas para permitir que eu enriquecesse meu trabalho.

Agradeço também aos meus colegas de classe e aos meus amigos do NEEAD que estão comigo todos os dias, sofrendo e rindo juntos, Carlos, Wesley, João Victor, Jonathan, André, Guilherme e Arthur e aos que me ajudam muito mesmo à distância, Gustavo e Afonso que me ajudaram a superar várias dificuldades enfrentadas e me mostraram que esses problemas eram comuns para todos.

Agradeço, por fim, à todas as instituições que financiaram meu trabalho ou que de alguma maneira me permitiram ter condições de concluir todo o projeto, em especial à Universidade Federal de Itajubá, minha casa desde 2007 quando iniciei minha graduação, ao CNPq, Capes e Fapemig por todo o apoio durante minha jornada, à empresa FlexSim pela parceria que possui com nosso grupo de pesquisa e nos permite sempre obter todas as

atualizações recentes de seu software, sem essas atualizações a dificuldade desse trabalho seria bem maior. E principalmente à empresa que liberou seus dados para que esse estudo pudesse ser realizado e que me recebeu de portas abertas durante todo o período da pesquisa, também todos os gerentes e diretores que me auxiliaram sempre que foi necessário.

A todos vocês o meu muito obrigado.

*Quer você acredite que consiga  
fazer uma coisa ou não,  
você está certo.  
(Henry Ford)*

## Resumo

O DAI (Doutorado Acadêmico para Inovação) é uma iniciativa do CNPq que tem como objetivo de permitir que Programas de Pós-Graduação possam fomentar projetos de interação com empresas através de teses, dissertações e trabalhos de conclusão de cursos. A empresa parceira deste trabalho é uma multinacional que produz eletrônicos (smartphones, impressoras, notebooks, monitores) para grandes marcas como HP e Motorola. A empresa possui grande preocupação com o meio ambiente e os recursos naturais, cada vez mais escassos. Essa preocupação, inclusive, vem crescendo nos últimos tempos entre várias empresas, incentivada por novas leis que as obrigam a estarem cada vez mais atentas ao problema de escassez de recursos. A gestão de resíduos é uma das maneiras mais atuais de auxiliar na reutilização desses recursos naturais finitos e uma das principais técnicas utilizadas para ajudar nessa gestão é a Logística Reversa (LR). Ela compreende, principalmente, o retorno de produtos no final da sua vida útil, a partir do usuário até a empresa, a separação e seleção de materiais reutilizáveis. Um dos problemas de roteamento na Logística Reversa se refere ao veículo utilizado para as coletas, e, apesar desses problemas de serem amplamente abordados na literatura, uma nova abordagem vem surgindo. Ela permite realizar estudos que antes não eram possíveis, devido ao fato de ser difícil estudar a LR em um contexto que não seja o real, ou seja, sem enviar os veículos para realizar a rota e analisar os resultados. Tentando amenizar essa dificuldade, este trabalho busca utilizar Gêmeos Digitais (GDs), uma representação virtual de um modelo real, como uma forma de representar virtualmente esse sistema. Além dos GDs, também são utilizados Clusters em conjunto com ferramentas de otimização multiobjetivo, como os Algoritmos Genéticos, de modo a ser possível agrupar as coletas próximas e otimizá-las. Desse modo, foi possível minimizar os custos econômicos e os custos da emissão de  $CO_2$  com relação aos dados históricos disponibilizados pela empresa parceira deste estudo, ao mesmo tempo em que a quantidade de produtos coletados foi maximizada. Para testar a ferramenta criada, são utilizados os GDs em dois estudos de caso com dados reais. Sendo assim, foi possível definir diariamente as melhores coletas a serem realizadas, permitindo que a empresa possa calcular melhor seus custos e diminuir a emissão de gases poluentes, dois tópicos cada vez mais desejados pela empresa em questão. Foi criado um *Framework* capaz de agrupar as coletas, realizar os cálculos e auxiliar o tomador de decisão a verificar quais as melhores coletas a se fazer, diferentemente do modelo atual utilizado pela empresa que não permite essa decisão por parte da empresa, o responsável por essa decisão, hoje, é a transportadora responsável por coletar os resíduos eletrônicos. Os estudos de caso mostraram que a economia potencial pode chegar a 80% com relação ao valor pago pela empresa atualmente, demonstrando que o *Framework* criado possui grande potencial para ser utilizado e pode ser uma ferramenta poderosa de auxílio à tomada de decisão.

## Abstract

The DAI (Academic Doctorate for Innovation) is an initiative by CNPq with the objective of enabling Graduate Programs to foster interaction projects with companies through theses, dissertations, and final course projects. The partner company in this work is a multinational that produces electronics (smartphones, printers, laptops, monitors) for major brands such as HP and Motorola. The company is deeply concerned with the environment and the increasingly scarce natural resources. This concern has been growing recently among various companies, spurred by new laws that require them to be increasingly attentive to the problem of resource scarcity. Waste management is one of the most current ways to support the reuse of these finite natural resources, and one of the main techniques used for this management is Reverse Logistics (RL). This primarily involves the return of products at the end of their life cycle, from the user back to the company, followed by the separation and selection of reusable materials. One of the challenges about routing in Reverse Logistics concerns the vehicle used for collections, and although these routing issues are widely discussed in the literature, a new approach is emerging. This approach allows for studies that were previously difficult to conduct, given the challenge of analyzing RL outside a real-world context, i.e., without dispatching vehicles to perform the routes and analyze the results. To address this challenge, this work seeks to use Digital Twins (DTs), a virtual representation of a real-world model, as a way to virtually simulate this system. In addition to DTs, Clusters are used in conjunction with multi-objective optimization tools, such as Genetic Algorithms (GAs), to group nearby collections and optimize them. This approach made it possible to minimize economic costs and CO<sub>2</sub> emissions relative to the historical data provided by the partner company, while simultaneously maximizing the number of collected products. To test the developed tool, DTs were used in two case studies with real data. As a result, it was possible to determine the best collections to be performed on a daily basis, enabling the company to better calculate costs and reduce pollutant gas emissions—two increasingly important goals for the company. A Framework was created that can group collections, perform calculations, and assist decision-makers in identifying the best collections to undertake. This differs from the company's current model, where the decision-making responsibility lies with the carrier responsible for collecting electronic waste. The case studies showed that potential savings could reach up to 80% compared to the current amount paid by the company, demonstrating that the developed Framework has significant potential for implementation and can be a powerful decision-support tool.

# Sumário

<b>Sumário</b> . . . . .	<b>7</b>
<b>Lista de Figuras</b> . . . . .	<b>10</b>
<b>Lista de Tabelas</b> . . . . .	<b>16</b>
<b>1 INTRODUÇÃO</b> . . . . .	<b>18</b>
1.1 Contexto e Relevância da Pesquisa . . . . .	18
1.2 Problema de Pesquisa e Objetivos . . . . .	20
1.3 Justificativa . . . . .	22
1.4 Estrutura do Trabalho . . . . .	23
<b>2 FUNDAMENTAÇÃO TEÓRICA</b> . . . . .	<b>24</b>
2.1 Considerações Iniciais . . . . .	24
2.2 Logística Reversa . . . . .	24
2.3 Simulação . . . . .	32
2.3.1 Simulação a Eventos Discretos . . . . .	33
2.4 Gêmeos Digitais . . . . .	35
2.4.1 Estrutura de um Gêmeo Digital . . . . .	37
2.5 Cluster . . . . .	41
2.5.1 Clusters Hierárquicos . . . . .	42
2.5.2 Clusters Particionais . . . . .	43
2.5.3 Clusters Incrementais . . . . .	44
2.5.4 Algoritmo <i>Leader</i> . . . . .	45
2.6 Otimização Multiobjetivo . . . . .	46
2.7 Algoritmo Genético . . . . .	49
2.8 Revisão Sistemática da Literatura (RSL) . . . . .	53
2.8.1 Planejamento . . . . .	54
2.8.2 Pesquisa . . . . .	55
2.8.3 Análise e Apresentação . . . . .	57
2.8.3.1 QP1 - Quais são as principais diferenças entre simulação e GDs? . . . . .	58
2.8.3.2 QP2 - A Simulação é utilizada na Gestão Verde da Cadeia de Suprimentos (GVCS)?	59
2.8.3.3 QP3 - Quais características são necessárias para se ter um GD? . . . . .	61
2.8.3.4 QP4 - GD é uma tecnologia que vem sendo utilizada em conjunto com a Logística Reversa? . . . . .	62
2.8.3.5 QP5 - Quais softwares são utilizados para criar GDs? . . . . .	65

2.9	Considerações Finais . . . . .	68
	<b>3 MÉTODO DE PESQUISA . . . . .</b>	<b>69</b>
3.1	Considerações Iniciais . . . . .	69
3.2	Classificação da Pesquisa . . . . .	69
3.3	Método de Pesquisa . . . . .	71
3.4	Considerações Finais . . . . .	73
	<b>4 APLICAÇÃO . . . . .</b>	<b>74</b>
4.1	Informações Iniciais . . . . .	74
4.2	Formulação do problema . . . . .	74
4.3	Definição das Variáveis . . . . .	76
4.4	Clusters . . . . .	78
4.5	Framework . . . . .	79
4.5.1	<i>Framework</i> Multiveículo . . . . .	80
4.5.2	<i>Framework</i> Monoveículo . . . . .	83
4.6	Restrições para o trabalho . . . . .	84
4.7	Utilização do módulo GIS do software FlexSim como Gêmeo Digital . . . . .	85
4.8	Algoritmo Genético . . . . .	85
4.8.1	Custo de Emissão de $CO_2$ . . . . .	87
4.8.2	Custo total da viagem . . . . .	88
4.8.3	Tempo total da viagem . . . . .	88
4.8.4	Função <i>Fitness</i> . . . . .	88
4.9	O Algoritmo Genético . . . . .	90
4.10	Objetos de Estudo . . . . .	92
4.10.1	Considerações Iniciais . . . . .	92
4.10.2	Objeto de Estudo I - <i>Framework</i> Monoveículo . . . . .	93
4.10.3	Objeto de Estudo II - <i>Framework</i> Multiveículo . . . . .	94
4.11	Considerações Finais . . . . .	96
	<b>5 RESULTADOS . . . . .</b>	<b>97</b>
5.1	Considerações Iniciais . . . . .	97
5.2	Interface . . . . .	98
5.2.1	Interface Monoveículo . . . . .	98
5.2.2	Interface Multiveículo . . . . .	99
5.3	Objeto de Estudo I - <i>Framework</i> Monoveículo . . . . .	100
5.4	Simulação . . . . .	103
5.5	Objeto de Estudo II - <i>Framework</i> Multiveículo . . . . .	107
5.6	Comparação Entre os Estudos . . . . .	117
5.7	Considerações Finais . . . . .	119

	<b>6 CONCLUSÃO</b> . . . . .	<b>120</b>
<b>6.1</b>	<b>Conclusão</b> . . . . .	<b>120</b>
<b>6.2</b>	<b>Trabalhos Futuros</b> . . . . .	<b>123</b>
	<b>7 REFERÊNCIAS</b> . . . . .	<b>124</b>
	<b>8 APÊNDICE</b> . . . . .	<b>141</b>
<b>8.1</b>	<b>Apêndice I - Resultados do <i>Framework</i> Multiveículo</b> . . . . .	<b>141</b>
<b>8.2</b>	<b>Apêndice II - BoxPlots dos Clusters do <i>Framework</i> Multiveículo</b> . . . . .	<b>151</b>
<b>8.3</b>	<b>Apêndice III - BoxPlots dos Clusters do <i>Framework</i> Monoveículo</b> . . . . .	<b>178</b>
<b>8.4</b>	<b>Apêndice IV - Gráficos dos Clusters do <i>Framework</i> Monoveículo após a execução do modelo de simulação</b> . . . . .	<b>180</b>
<b>8.5</b>	<b>Apêndice V - Gráficos de Comparações Entre os modelos Multiveí- culo e Monoveículo</b> . . . . .	<b>184</b>
<b>8.6</b>	<b>Apêndice VI - Trabalhos Publicados</b> . . . . .	<b>187</b>

# Lista de Figuras

2.2.1	Atividades básicas de uma LR. . . . .	29
2.3.1	Metodologia de condução de pesquisa. . . . .	34
2.4.1	A simulação dentro do conceito de Gêmeo Digital. . . . .	37
2.4.2	Modelo de 5 camadas de um Gêmeo Digital. . . . .	39
2.4.3	Figura que mostra como o GD pode economizar tempo no desenvolvi- mento do projeto. . . . .	40
2.5.1	Exemplo de dendrogramas das abordagens de Link Único e Completo. . . . .	43
2.5.2	Exemplo de <i>K-means</i> . . . . .	44
2.7.1	Exemplo de <i>Crossover</i> . . . . .	51
2.7.2	Criação de um AG . . . . .	53
2.8.1	Resumo da pesquisa feita para este trabalho. . . . .	57
3.2.1	Classificação da Pesquisa. . . . .	71
4.5.1	Fluxograma resumindo o <i>Framework</i> desenvolvido. . . . .	82
4.7.1	Mapa do estado de São Paulo com uma das rotas nas quais houveram coletas nos anos de 2019 e 2020. . . . .	86
4.8.1	Interface criada para o <i>Fremakework</i> monoveículo. . . . .	89
5.2.1	Interface criada para o <i>Framework</i> monoveículo. . . . .	99
5.2.2	Interface criada para o <i>Framework</i> mutiveículo. . . . .	100
5.5.1	BoxPlot referente ao Cluster 2 da segunda semana. . . . .	107
5.5.2	BoxPlot referente ao Cluster 4 da quarta semana. . . . .	108
5.5.3	BoxPlot referente ao Cluster 8 da semana 5. . . . .	109
5.5.4	BoxPlot referente ao Cluster 9 da semana 5. . . . .	109
5.5.5	BoxPlot referente ao Cluster 3 da semana 6. . . . .	110
5.5.6	BoxPlot referente ao Cluster 1 da semana 7. . . . .	111
5.5.7	BoxPlot referente ao Cluster 6 da semana 7. . . . .	111
5.5.8	BoxPlot referente ao Cluster 5 da semana 8. . . . .	112
5.5.9	BoxPlot referente ao Cluster 8 da semana 8. . . . .	112
5.5.10	BoxPlot referente ao Cluster 9 da semana 5. . . . .	113
5.5.11	BoxPlot referente ao Cluster 9 da semana 6. . . . .	113
8.2.1	Cluster 1, semana 1, com p-value = 0,000. . . . .	151
8.2.2	Cluster 2, semana 1, com p-value = 0,000. . . . .	151
8.2.3	Cluster 3, semana 1, com p-value = 1,000. . . . .	151
8.2.4	Cluster 1, semana 2, com p-value = 1,000. . . . .	151
8.2.5	Cluster 2, semana 2, com p-value = 0,000. . . . .	151
8.2.6	Cluster 3, semana 2, com p-value = 1,000. . . . .	151
8.2.7	Cluster 4, semana 2, com p-value = 1,000. . . . .	152

8.2.8	Cluster 5, semana 2, com p-value = 1,000. . . . .	152
8.2.9	Cluster 6, semana 2, com p-value = 0,998. . . . .	152
8.2.10	Cluster 7, semana 2, com p-value = 1,000. . . . .	152
8.2.11	Cluster 8, semana 2, com p-value = 1,000. . . . .	152
8.2.12	Cluster 9, semana 2, com p-value = 0,998. . . . .	152
8.2.13	Cluster 1, semana 3, com p-value = 1,000. . . . .	153
8.2.14	Cluster 2, semana 3, com p-value = 1,000. . . . .	153
8.2.15	Cluster 3, semana 3, com p-value = 0,727. . . . .	153
8.2.16	Cluster 4, semana 3, com p-value = 0,999. . . . .	153
8.2.17	Cluster 5, semana 3, com p-value = 0,000. . . . .	153
8.2.18	Cluster 6, semana 3, com p-value = 0,210. . . . .	153
8.2.19	Cluster 7, semana 3, com p-value = 0,398. . . . .	154
8.2.20	Cluster 8, semana 3, com p-value = 1,000. . . . .	154
8.2.21	Cluster 9, semana 3, com p-value = 1,000. . . . .	154
8.2.22	Cluster 10, semana 3, com p-value = 1,000. . . . .	154
8.2.23	Cluster 11, semana 3, com p-value = 1,000. . . . .	154
8.2.24	Cluster 12, semana 3, com p-value = 1,000. . . . .	154
8.2.25	Cluster 13, semana 3, com p-value = 1,000. . . . .	155
8.2.26	Cluster 13, semana 3, com p-value = 1,000. . . . .	155
8.2.27	Cluster 15, semana 3, com p-value = 1,000. . . . .	155
8.2.28	Cluster 16, semana 3, com p-value = 1,000. . . . .	155
8.2.29	Cluster 17, semana 3, com p-value = 0,991. . . . .	155
8.2.30	Cluster 18, semana 3, com p-value = 1,000. . . . .	155
8.2.31	Cluster 19, semana 3, com p-value = 1,000. . . . .	156
8.2.32	Cluster 1, semana 4, com p-value = 1,000. . . . .	156
8.2.33	Cluster 2, semana 4, com p-value = 0,999. . . . .	156
8.2.34	Cluster 3, semana 4, com p-value = 0,927. . . . .	156
8.2.35	Cluster 4, semana 4, com p-value = 0,000. . . . .	156
8.2.36	Cluster 5, semana 4, com p-value = 1,000. . . . .	156
8.2.37	Cluster 6, semana 4, com p-value = 1,000. . . . .	157
8.2.38	Cluster 7, semana 4, com p-value = 0,996. . . . .	157
8.2.39	Cluster 8, semana 4, com p-value = 1,000. . . . .	157
8.2.40	Cluster 9, semana 4, com p-value = 1,000. . . . .	157
8.2.41	Cluster 1, semana 5, com p-value = 1,000. . . . .	157
8.2.42	Cluster 2, semana 5, com p-value = 1,000. . . . .	157
8.2.43	Cluster 3, semana 5, com p-value = 0,775. . . . .	158
8.2.44	Cluster 4, semana 5, com p-value = 0,999. . . . .	158
8.2.45	Cluster 5, semana 5, com p-value = 0,409. . . . .	158
8.2.46	Cluster 6, semana 5, com p-value = 1,000. . . . .	158

8.2.47	Cluster 7, semana 5, com p-value = 0,998. . . . .	158
8.2.48	Cluster 8, semana 5, com p-value = 0,000. . . . .	158
8.2.49	Cluster 9, semana 5, com p-value = 0,000. . . . .	159
8.2.50	Cluster 10, semana 5, com p-value = 0,111. . . . .	159
8.2.51	Cluster 11, semana 5, com p-value = 0,616. . . . .	159
8.2.52	Cluster 12, semana 5, com p-value = 0,002. . . . .	159
8.2.53	Cluster 13, semana 5, com p-value = 1,000. . . . .	159
8.2.54	Cluster 14, semana 5, com p-value = 0,152. . . . .	159
8.2.55	Cluster 15, semana 5, com p-value = 0,988. . . . .	160
8.2.56	Cluster 16, semana 5, com p-value = 0,975. . . . .	160
8.2.57	Cluster 17, semana 5, com p-value = 1,000. . . . .	160
8.2.58	Cluster 18, semana 5, com p-value = 1,000. . . . .	160
8.2.59	Cluster 19, semana 5, com p-value = 1,000. . . . .	160
8.2.60	Cluster 20, semana 5, com p-value = 1,000. . . . .	160
8.2.61	Cluster 21, semana 5, com p-value = 0,997. . . . .	161
8.2.62	Cluster 22, semana 5, com p-value = 1,000. . . . .	161
8.2.63	Cluster 23, semana 5, com p-value = 1,000. . . . .	161
8.2.64	Cluster 1, semana 6, com p-value = 0,997. . . . .	161
8.2.65	Cluster 2, semana 6, com p-value = 0,000. . . . .	161
8.2.66	Cluster 3, semana 6, com p-value = 0,000. . . . .	161
8.2.67	Cluster 4, semana 6, com p-value = 0,97. . . . .	162
8.2.68	Cluster 5, semana 6, com p-value = 0,240. . . . .	162
8.2.69	Cluster 6, semana 6, com p-value = 0,954. . . . .	162
8.2.70	Cluster 7, semana 6, com p-value = 0,999. . . . .	162
8.2.71	Cluster 8, semana 6, com p-value = 1,000. . . . .	162
8.2.72	Cluster 9, semana 6, com p-value = 0,996. . . . .	162
8.2.73	Cluster 10, semana 6, com p-value = 1,000. . . . .	163
8.2.74	Cluster 11, semana 6, com p-value = 1,000. . . . .	163
8.2.75	Cluster 12, semana 6, com p-value = 1,000. . . . .	163
8.2.76	Cluster 13, semana 6, com p-value = 0,532. . . . .	163
8.2.77	Cluster 14, semana 6, com p-value = 0,991. . . . .	163
8.2.78	Cluster 15, semana 6, com p-value = 0,999. . . . .	163
8.2.79	Cluster 16, semana 6, com p-value = 1,000. . . . .	164
8.2.80	Cluster 1, semana 7, com p-value = 0,000. . . . .	164
8.2.81	Cluster 2, semana 7, com p-value = 0,999. . . . .	164
8.2.82	Cluster 3, semana 7, com p-value = 0,000. . . . .	164
8.2.83	Cluster 4, semana 7, com p-value = 1,000. . . . .	164
8.2.84	Cluster 5, semana 7, com p-value = 1,000. . . . .	164
8.2.85	Cluster 6, semana 7, com p-value = 0,000. . . . .	165

8.2.86	Cluster 7, semana 7, com p-value = 0,031. . . . .	165
8.2.87	Cluster 8, semana 7, com p-value = 1,000. . . . .	165
8.2.88	Cluster 9, semana 7, com p-value = 1,000. . . . .	165
8.2.89	Cluster 10, semana 7, com p-value = 1,000. . . . .	165
8.2.90	Cluster 11, semana 7, com p-value = 1,000. . . . .	165
8.2.91	Cluster 12, semana 7, com p-value = 1,000. . . . .	166
8.2.92	Cluster 13, semana 7, com p-value = 1,000. . . . .	166
8.2.93	Cluster 14, semana 7, com p-value = 1,000. . . . .	166
8.2.94	Cluster 15, semana 7, com p-value = 0,996. . . . .	166
8.2.95	Cluster 1, semana 8, com p-value = 0,487. . . . .	166
8.2.96	Cluster 2, semana 8, com p-value = 1,000. . . . .	166
8.2.97	Cluster 3, semana 8, com p-value = 1,000. . . . .	167
8.2.98	Cluster 4, semana 8, com p-value = 0,999. . . . .	167
8.2.99	Cluster 5, semana 8, com p-value = 0,000. . . . .	167
8.2.100	Cluster 6, semana 8, com p-value = 1,000. . . . .	167
8.2.101	Cluster 7, semana 8, com p-value = 0,000. . . . .	167
8.2.102	Cluster 8, semana 8, com p-value = 0,001. . . . .	167
8.2.103	Cluster 9, semana 8, com p-value = 0,965. . . . .	168
8.2.104	Cluster 10, semana 8, com p-value = 1,000. . . . .	168
8.2.105	Cluster 11, semana 8, com p-value = 1,000. . . . .	168
8.2.106	Cluster 12, semana 8, com p-value = 0,990. . . . .	168
8.2.107	Cluster 13, semana 8, com p-value = 0,985. . . . .	168
8.2.108	Cluster 14, semana 8, com p-value = 1,000. . . . .	168
8.2.109	Cluster 15, semana 8, com p-value = 0,994. . . . .	169
8.2.110	Cluster 16, semana 8, com p-value = 1,000. . . . .	169
8.2.111	Cluster 17, semana 8, com p-value = 0,998. . . . .	169
8.2.112	Cluster 18, semana 8, com p-value = 0,997. . . . .	169
8.2.113	Cluster 19, semana 8, com p-value = 1,000. . . . .	169
8.2.114	Cluster 20, semana 8, com p-value = 1,000. . . . .	169
8.2.115	Cluster 1, semana 9, com p-value = 0,000. . . . .	170
8.2.116	Cluster 2, semana 9, com p-value = 1,000. . . . .	170
8.2.117	Cluster 3, semana 9, com p-value = 0,003. . . . .	170
8.2.118	Cluster 4, semana 9, com p-value = 1,000. . . . .	170
8.2.119	Cluster 5, semana 9, com p-value = 0,000. . . . .	170
8.2.120	Cluster 6, semana 9, com p-value = 0,000. . . . .	170
8.2.121	Cluster 7, semana 9, com p-value = 1,000. . . . .	171
8.2.122	Cluster 8, semana 9, com p-value = 0,999. . . . .	171
8.2.123	Cluster 9, semana 9, com p-value = 1,000. . . . .	171
8.2.124	Cluster 10, semana 9, com p-value = 0,718. . . . .	171

8.2.125	Cluster 11, semana 9, com p-value = 1,000.	171
8.2.126	Cluster 12, semana 9, com p-value = 1,000.	171
8.2.127	Cluster 13, semana 9, com p-value = 0,991.	172
8.2.128	Cluster 14, semana 9, com p-value = 1,000.	172
8.2.129	Cluster 15, semana 9, com p-value = 1,000.	172
8.2.130	Cluster 16, semana 9, com p-value = 1,000.	172
8.2.131	Cluster 17, semana 9, com p-value = 0,998.	172
8.2.132	Cluster 18, semana 9, com p-value = 0,875.	172
8.2.133	Cluster 19, semana 9, com p-value = 1,000.	173
8.2.134	Cluster 20, semana 9, com p-value = 1,000.	173
8.2.135	Cluster 1, semana 10, com p-value = 1,000.	173
8.2.136	Cluster 2, semana 10, com p-value = 1,000.	173
8.2.137	Cluster 3, semana 10, com p-value = 1,000.	173
8.2.138	Cluster 4, semana 10, com p-value = 1,000.	173
8.2.139	Cluster 5, semana 10, com p-value = 1,000.	174
8.2.140	Cluster 6, semana 10, com p-value = 0,000.	174
8.2.141	Cluster 7, semana 10, com p-value = 0,000.	174
8.2.142	Cluster 8, semana 10, com p-value = 0,000.	174
8.2.143	Cluster 9, semana 10, com p-value = 0,000.	174
8.2.144	Cluster 10, semana 10, com p-value = 1,000.	174
8.2.145	Cluster 11, semana 10, com p-value = 0,092.	175
8.2.146	Cluster 12, semana 10, com p-value = 1,000.	175
8.2.147	Cluster 13, semana 10, com p-value = 0,983.	175
8.2.148	Cluster 14, semana 10, com p-value = 1,000.	175
8.2.149	Cluster 15, semana 10, com p-value = 1,000.	175
8.2.150	Cluster 16, semana 10, com p-value = 1,000.	175
8.2.151	Cluster 17, semana 10, com p-value = 0,127.	176
8.2.152	Cluster 18, semana 10, com p-value = 1,000.	176
8.2.153	Cluster 19, semana 10, com p-value = 1,000.	176
8.2.154	Cluster 20, semana 10, com p-value = 1,000.	176
8.2.155	Cluster 21, semana 10, com p-value = 0,987.	176
8.2.156	Cluster 22, semana 10, com p-value = 1,000.	176
8.2.157	Cluster 23, semana 10, com p-value = 1,000.	177
8.3.1	BoxPlot referente à semana 1	178
8.3.2	BoxPlot referente à semana 3	178
8.3.3	BoxPlot referente à semana 5	178
8.3.4	BoxPlot referente à semana 2	178
8.3.5	BoxPlot referente à semana 4	178
8.3.6	BoxPlot referente à semana 6	178

8.3.7	BoxPlot referente à semana 7 . . . . .	179
8.3.8	BoxPlot referente à semana 9 . . . . .	179
8.3.9	BoxPlot referente à semana 8 . . . . .	179
8.3.10	BoxPlot referente à semana 10 . . . . .	179
8.4.1	Modelo referente a semana 1. . . . .	180
8.4.2	Modelo referente a semana 2. . . . .	180
8.4.3	Modelo referente a semana 3. . . . .	180
8.4.4	Resultados referentes a semana 1. . . . .	180
8.4.5	Resultados referentes a semana 2. . . . .	180
8.4.6	Resultados referentes a semana 3. . . . .	180
8.4.7	Modelo referente a semana 4. . . . .	181
8.4.8	Modelo referente a semana 5. . . . .	181
8.4.9	Modelo referente a semana 6. . . . .	181
8.4.10	Resultados referentes a semana 4. . . . .	181
8.4.11	Resultados referentes a semana 5. . . . .	181
8.4.12	Resultados referentes a semana 6. . . . .	181
8.4.13	Modelo referente a semana 7. . . . .	182
8.4.14	Modelo referente a semana 8. . . . .	182
8.4.15	Modelo referente a semana 9. . . . .	182
8.4.16	Resultados referentes a semana 7. . . . .	182
8.4.17	Resultados referentes a semana 8. . . . .	182
8.4.18	Resultados referentes a semana 9. . . . .	182
8.4.19	Modelo referente a semana 10. . . . .	183
8.4.20	Resultados referentes a semana 10. . . . .	183
8.5.1	BoxPlot comparando os <i>Frameworks</i> na semana 1. . . . .	184
8.5.2	BoxPlot comparando os <i>Frameworks</i> na semana 1, sem o outlier. . . . .	184
8.5.3	BoxPlot comparando os <i>Frameworks</i> na semana 2. . . . .	184
8.5.4	BoxPlot comparando os <i>Frameworks</i> na semana 3. . . . .	184
8.5.5	BoxPlot comparando os <i>Frameworks</i> na semana 4. . . . .	184
8.5.6	BoxPlot comparando os <i>Frameworks</i> na semana 6. . . . .	184
8.5.7	BoxPlot comparando os <i>Frameworks</i> na semana 7. . . . .	185
8.5.8	BoxPlot comparando os <i>Frameworks</i> na semana 8. . . . .	185
8.5.9	BoxPlot comparando os <i>Frameworks</i> na semana 9. . . . .	185
8.5.10	BoxPlot comparando a semana 5, com o Cluster 8. . . . .	185
8.5.11	BoxPlot comparando a semana 5, com o Cluster 9. . . . .	185
8.5.12	BoxPlot comparando a semana 10, com o Cluster 8. . . . .	185
8.5.13	BoxPlot comparando os <i>Frameworks</i> na semana 10, com o Cluster 9. . . . .	186

# Lista de Tabelas

2.2.1	Principais diferenças entre a Logística e a Logística Reversa. . . . .	30
2.4.1	Artigos que descrevem os modelos de GD utilizados . . . . .	38
2.5.1	Comparações entre os tipos mais comuns de Clusters. . . . .	45
2.8.1	Artigos que abordam Simulação e Logística Reversa. . . . .	60
2.8.2	Artigos utilizados para a Revisão Sistemática e as abordagens contidas neles. . . . .	63
2.8.3	Problemas e desafios apontados por Barricelli <i>et al.</i> , 2019 . . . . .	67
4.5.1	Comparações entre os tempos de acesso a API do Google Maps. . . . .	83
4.10.1	Medidas dos veículos utilizados para coleta de produtos . . . . .	92
4.10.2	Coletas utilizadas para realizar os testes. . . . .	95
5.3.1	Resultados do objeto de estudo I. . . . .	102
5.4.1	Resumo dos tempos de trabalho dos veículos por semana após a utiliza- ção da simulação. . . . .	106
5.5.1	Resumo da semana 10. . . . .	114
5.5.2	Resumo dos Clusters passíveis de serem coletados. . . . .	115
5.5.3	Custos de emissões de $CO_2$ para os Clusters estudados. . . . .	116
5.6.1	Comparação entre os Clusters das semanas 5 e 10. . . . .	118
5.6.2	Comparação do tempo de execução entre ambos os <i>Frameworks</i> . . . . .	118
5.6.3	Resumo das médias e desvios-padrão obtidos através dos AGs. . . . .	119
8.1.1	Valores calculados para a primeira semana. . . . .	141
8.1.2	Valores calculados para a segunda semana. . . . .	142
8.1.3	Valores calculados para a terceira semana. . . . .	143
8.1.4	Valores calculados para a quarta semana. . . . .	144
8.1.5	Valores calculados para a quinta semana. . . . .	145
8.1.6	Valores calculados para a sexta semana. . . . .	146
8.1.7	Valores calculados para a sétima semana. . . . .	147
8.1.8	Valores calculados para a oitava semana. . . . .	148
8.1.9	Valores calculados para a nona semana. . . . .	149
8.1.10	Valores calculados para a décima semana. . . . .	150

## Lista de Abreviaturas e Siglas

AG	<i>Algoritmo Genético</i>
ARLEC	<i>American Reverse Logistics Executive Council</i>
CEALR	<i>Conselho Executivo Americano de Logística Reversa</i>
CFCS	<i>Circuito Fechado da Cadeia de Suprimentos</i>
CS	<i>Cadeia de Suprimentos</i>
EC	<i>Economia Circular</i>
GD	<i>Gêmeo Digital</i>
GIS	<i>Geographic Information System</i>
GVCS	<i>Gestão Verde da Cadeia de Suprimentos</i>
IA	<i>Inteligência Artificial</i>
LR	<i>Logística Reversa</i>
M	<i>Manufatura</i>
MOPSO	<i>Multi-Objective Particle Swarm Optimization</i>
MTSP	<i>Multiple Traveller Salesman Problem</i>
NASA	<i>National Aeronautics and Space Administration</i>
NSGA-II	<i>Non-dominated Sorting Genetic Algorithm II</i>
QP	<i>Questões de Pesquisa</i>
PCVM	<i>Problema do Caixeiro Viajante Múltiplo</i>
PSO	<i>Particle Swarm Optimization</i>
RSL	<i>Revisão Sistemática da Literatura</i>
SBA	<i>Simulação Baseada em Agentes</i>
SD	<i>Sistemas Dinâmicos</i>
SED	<i>Simulação a Eventos Discretos</i>
Sim	<i>Simulação</i>
SWOT	<i>Strength, Weakness, Opportunities and Threats</i>
TD	<i>Tomada de Decisão</i>

# 1. INTRODUÇÃO

## 1.1 Contexto e Relevância da Pesquisa

Muitos recursos naturais são escassos e grande parte pode estar se esgotando. Garg, 2020 aponta que é necessário um ano e meio para que a Terra consiga restaurar os recursos naturais que uma pessoa consome em um ano. Os autores ainda afirmam que práticas para conservação dos recursos são necessárias e citam a adoção da Logística Reversa (LR) como uma opção.

As pesquisas em Logística Reversa e Gestão Verde da Cadeia de Suprimentos (GVCS) vem crescendo nos últimos 30 anos (Plaza-Úbeda *et al.*, 2020), primeiramente devido ao fato de que, com a tendência mundial de diminuir a emissão de gás carbônico, ela é importante para que as companhias possam garantir um lucro adicional (Hao *et al.*, 2021). Em segundo lugar, existem muitas preocupações hoje sobre o meio ambiente e vários países estabelecem leis que obrigam empresas a reciclar parte de seus produtos (Marić *et al.*, 2019).

Infelizmente, de acordo com Rocha *et al.*, 2021, a utilização da LR ainda está muito longe de ser realidade em grande parte do mundo. Segundo os autores, a estimativa é de que apenas 20% de todo o resíduo eletroeletrônico seja tratado adequadamente no mundo, enquanto na América Latina, essa taxa cai para 3%. Isso se deve à vários fatores, em especial à falta de conhecimento relacionada aos benefícios da LR (Garg, 2020). Problema que é suportado também por Uriarte-Miranda *et al.*, 2018, que citam o fato da LR não ser reconhecida como uma abordagem que traz vantagens competitivas para as empresas.

Um dos grandes problemas da LR é o fato de ser difícil testar soluções no mundo real, sendo necessário maneiras virtuais de testar essas possíveis soluções. Schützer *et al.*, 2019 dizem que a distância entre o mundo real e virtual vem diminuindo, criando a chamada Indústria 4.0, e isso auxilia na criação de novas abordagens para tratar problemas difíceis de serem solucionados. Segundo os autores, a indústria 4.0 vem transformando a manufatura, resultando em maiores eficiências e ganhos econômicos.

Entre as tecnologias emergentes na Indústria 4.0, se destacam os Gêmeos Digitais (GDs) (Fuller *et al.*, 2020), uma imagem espelhada de um processo físico que ocorre em conjunto com o processo em questão, normalmente correspondendo exatamente à operação do processo físico (Batty, 2018). Apesar de alguns autores afirmarem que o GD precisa ser atualizado em tempo real, outros autores como Malik *et al.*, 2018 dizem que isso não é necessário.

Dessa forma, o GD criado neste trabalho é capaz de auxiliar a empresa a tomar as decisões diariamente, pois permite que os dados do dia atual estejam sempre atualizados com base nas coletas realizadas no dia anterior. Assim se caracteriza um GD em tempo

quase real, uma vez a cada dia ele é executado e as decisões tomadas nesse dia irão influenciar a próxima execução dele.

Como resultado de uma revisão sistemática realizada para esse trabalho, foi possível concluir que os GDs foram pouco trabalhados em conjunto com a LR e essa é possivelmente uma área a ser explorada, buscando utilizar os GDs para auxiliar nas decisões relacionadas a qual veículo utilizar em uma coleta, por exemplo.

Os GDs podem ser baseados na simulação e, em seu trabalho, Kara *et al.*, 2007 mostram como a simulação pode ser benéfica para o estudo da LR e Golda *et al.*, 2016 também mostram que a simulação traz muitos benefícios para a Logística comum como eliminação do hardware real durante a pesquisa, redução do tempo de teste, repetibilidade e segurança nos testes em condições extremas.

Segundo Kuehn, 2018, a maior diferença entre GD e Simulação, é que o primeiro permite realizar melhorias no ambiente virtual e a transferir os resultados para o ambiente físico em tempo real ou não, essa troca constante de dados não é possível de ser realizada em um modelo de simulação puro (Kuehn, 2018).

Astanti *et al.*, 2018 também suportam essa ideia, segundo os autores, a simulação não é uma ferramenta que define a decisão a ser tomada, mas sim uma ferramenta de suporte à decisão e portanto, os resultados precisam ser interpretados de acordo com o propósito do usuário. Por outro lado, o GD pode permitir que o próprio sistema virtual controle o real, tomando decisões que podem afetar a produção. Levando em consideração todas as definições, é possível afirmar que este trabalho apenas auxilia a tomada de decisão e é necessário que o usuário interprete os resultados.

Porém, para Wright *et al.*, 2020, a principal diferença entre um modelo de simulação e um GD é que o segundo possui atualização constante dos dados entre o modelo real e o virtual. Essa atualização não necessita ser automática, podendo ser manual. Sendo assim, essa será a definição utilizada neste trabalho para caracterizar o GD utilizado.

Então, para que um modelo de simulação possa ser considerado um (GD), é necessário acrescentar dois objetos de acordo com Malik *et al.*, 2018. O primeiro é uma inteligência que permita que o GD possa otimizar o modelo e devolver ao usuário a melhor solução, o segundo é a comunicação entre o sistema real e virtual, essa comunicação pode ser em tempo real ou em tempo quase real (Malik *et al.*, 2018), que pode ser um intervalo de horas, minutos ou até, como no caso deste trabalho, diário.

Porém, outros autores, como Torres *et al.*, 2024 discordam dessa definição e dizem que o importante é a troca contínua de dados. De acordo com os autores, o conceito de GD foi definido nos anos 1960, mas apenas com a utilização da Inteligência Artificial o potencial da ferramenta pode ser realmente evidenciado.

Utilizando GDs para realizar os testes do modelo com dados históricos, esse trabalho se baseia no desenvolvimento de um método que possa ser capaz de identificar o melhor veículo e o melhor momento para se realizar uma coleta de resíduos eletroeletrônicos

(notebooks, smartphones, impressoras), ou seja, verificar se é preferível realizar uma única coleta em uma cidade ou acumular algumas coletas em cidades vizinhas e realizá-las todas de uma vez.

Para solucionar esse problema serão utilizados, primeiramente Clusters, que, no caso deste trabalho, podem ser definidos como agrupamentos de cidades próximas. Vale ressaltar que, apesar de Clusters poderem ser utilizados para qualquer tipo de agrupamento, principalmente quando relacionado à área da computação, nesse trabalho o termo irá se referir apenas ao conjunto de cidades pelas quais um veículo poderá realizar as coletas dos resíduos.

Após realizar esse agrupamento, a otimização será utilizada para verificar qual o melhor veículo para se utilizar em cada um dos Clusters. Além do tamanho do Cluster, também será alterado o modelo do veículo, o que acarreta em alterar também o consumo de combustível, o tamanho do veículo, a emissão de  $CO_2$  de cada um quando vazio ou em sua capacidade máxima.

Para definir a melhor solução, foram utilizados dois objetos para estudo em conjunto com dados históricos. O primeiro estudo trabalha apenas com um veículo por coleta e utiliza um algoritmo de Dijkstra para definir essa melhor rota única. Já o segundo utiliza um Algoritmo Genético (AG) capaz de identificar as menores rotas solucionando um problema do tipo MTSP (*Multiple Traveller Salesman Problem*) ou Problema do Caixeiro Viajante Múltiplo (PCVM), que permite utilizar uma frota multiveículos para encontrar várias rotas diferentes.

Após a definição das rotas, outro Algoritmo Genético foi programado para, então, definir os melhores veículos a realizarem cada uma das coletas nos Clusters criados pelo *framework*. No caso multiveículo, o AG encontra os melhores veículos para cada um dos Clusters existentes, mesmo que haja sobreposição de frotas, com isso o usuário pode verificar qual a melhor decisão a ser tomada dentre as soluções disponíveis.

Por outro lado, no caso monoveículo, apenas o melhor Cluster de cada dia é definido e um único veículo é sugerido para realizar essa coleta. Dessa forma é possível validar o modelo e definir se o resultado mostrado com ele é melhor ou pior do que o atual modelo utilizado (FIFO - First In, First out).

## 1.2 Problema de Pesquisa e Objetivos

A empresa utilizada como objeto de estudo para este trabalho necessita que um problema de coleta na LR seja resolvido. Ela recebe pedidos de coletas de resíduos eletroeletrônicos de diferentes tamanhos, desde celulares pequenos até impressoras industriais. As coletas também podem ser de apenas um resíduo ou, em caso de bancos, por exemplo, grandes quantidades de resíduos podem ser coletados ao mesmo tempo. Apesar de ter todo o processo de remanufatura bem estruturado, a empresa estudada utiliza transportadoras

terceirizadas para realizar as coletas.

Essa empresa possui veículos e motoristas disponíveis em seu centro de reciclagem. Porém, esse recursos não são utilizados hoje para realizar as coletas da LR, eles são utilizados apenas para buscar matérias-primas novas. Portanto, uma sugestão dada neste trabalho, é utilizar esses veículos para buscar também as coletas da LR, quando o *framework* identificar ser economicamente viável.

As coletas podem ser de dois tipos: fracionadas (coletas e entregas para vários usuários finais em uma mesma rota) ou dedicadas (coletas apenas para a empresa na rota) e a empresa precisa destinar um valor para o pagamento da empresa de logística. Porém, ocorrem casos em que o valor reservado pela empresa é menor do que o valor cobrado pela transportadora, sendo necessário um novo pedido de capital para cobrir a despesa extra.

Sendo assim, é necessário encontrar uma forma de auxiliar a empresa a definir melhor o valor a ser destinado para o pagamento das coletas, utilizando Clusters para agrupar várias coletas que podem ser realizadas com um caminhão dedicado ou definindo as coletas que podem ser cumpridas pelos veículos fracionados.

Além da questão econômica, também é de interesse da empresa dedicar-se à questão ambiental, tentando diminuir a emissão de  $CO_2$ . Portanto, esse trabalho também tem como objetivo auxiliar a empresa na redução de gases poluentes. Da mesma forma que a redução de custos, a ideia é utilizar os Clusters de cidades que são mais próximas e, desse modo, permitem que os veículos emitam menos gases tóxicos para realizar a mesma quantidade de coletas que poderiam fazer em cidades distantes.

Para que as decisões sejam tomadas pela empresa de forma contínua e rápida, é necessário uma ferramenta que permita uma interação contínua entre os modelos real e virtual. Para isso serão utilizados os GDs, que além de permitirem a troca de informação em tempo real ou quase real, também utilizam a simulação para, através de bibliotecas e módulos que trabalham com a tecnologia GIS (*Geographic Information System*), definir as rotas, distâncias e tempos para serem utilizados nos cálculos.

Por fim, a otimização proposta considera uma função objetivo que integra a minimização dos custos econômicos e das emissões de  $CO_2$  com a maximização da eficiência nas coletas realizadas. Para isso, serão utilizados veículos variados, de modo a permitir que a empresa obtenha os pontos de coletas ótimos para se enviar um veículo dedicado ou fracionado.

Considerando a lacuna encontrada na literatura sobre a utilização de GDs para definir quando e com qual veículo uma coleta deve ser realizada, a presente tese busca responder a seguinte pergunta de pesquisa: Qual o impacto de se utilizar Gêmeos Digitais para avaliar a diminuição de custos econômicos e os custos da emissão de  $CO_2$  na Logística Reversa ao agrupar as coletas e utilizar ferramentas de otimização para definir o melhor momento e veículo para realizá-las?

Portanto, o objetivo principal desta tese é utilizar Gêmeos Digitais na Logística Reversa, de modo a auxiliar o tomador de decisão a definir as coletas de resíduos eletrônicos que devem ser realizadas. Para isso, será trabalhada a otimização multiobjetivo, utilizando-se Algoritmos Genéticos, para definir as rotas, dentro de um agrupamento de cidades pré-definidas, e quais os melhores veículos para percorrê-las.

Além disso, este trabalho tem como objetivos específicos:

- Realizar uma revisão sistemática da literatura de forma a encontrar lacunas que permitam o embasamento deste trabalho;
- Desenvolver uma interface que permita a integração entre as ferramentas utilizadas e para que os usuários consigam entender os resultados obtidos pelo modelo e possam tomar as decisões de forma adequada. Essa interface é criada com o auxílio da ferramenta PyQT, uma biblioteca que permite a criação de interfaces gráficas no Python;
- Validar a abordagem proposta através de dois objetos de estudo utilizando Gêmeos Digitais juntamente com dados históricos;
- Utilizar um modelo de simulação para avaliar possíveis cenários nos quais possam ocorrer imprevistos que comprometam as coletas.

### 1.3 Justificativa

Com a revisão realizada para esse trabalho foi possível verificar que, dentre as oportunidades destacadas, nota-se uma lacuna na pesquisa relacionada à utilização de GDs para auxiliar na decisão sobre quando realizar coletas na LR e qual veículo é o melhor para ser utilizado.

O problema de roteamento na Logística é bastante abordado na literatura mas, de acordo com Wang *et al.*, 2024, esse mesmo problema é pouco abordado na LR. Apesar disso, ele precisa ser mais estudado, pois algumas diferenças entre as logísticas, como a incerteza das taxas de retorno, a incerteza em relação ao tempo e qualidade dos produtos coletados (Yu *et al.*, 2024) e a variação de valores dos produtos coletados (Roudbari *et al.*, 2021), fazem com que a LR seja mais complicada do que a logística comum.

Além das observações já realizadas, esse trabalho também pode ser justificado da seguinte forma:

- Ineditismo quanto à utilização da otimização multiobjetivo, Cluster e LR em conjunto com GDs, de forma a utilizar essa última ferramenta para avaliar os resultados obtidos e validar os cálculos realizados. De acordo com a revisão sistemática da literatura, os GDs e a otimização multiobjetivo são pouco explorados em conjunto com

a LR. Por outro lado, os Clusters são ferramentas já comumente integradas à LR, portanto, a utilização de todas as ferramentas em conjunto justifica esse trabalho;

- A questão de qual o melhor momento para se realizar uma coleta também ainda não foi abordada na literatura e a questão de qual o melhor veículo ou o melhor parceiro para se realizar o trabalho de LR ainda não foi explorado em conjunto com a utilização de GDs devido à complexidade na criação do problema utilizando modelos virtuais. Portanto, esse trabalho busca resolver essas duas questões utilizando ferramentas que, de acordo com a revisão feita para este trabalho, ainda não foram utilizadas.
- Por último, a utilização de otimização multiobjetivo em conjunto com os GDs para resolver problemas da LR ainda não foi abordada na literatura. Apesar da otimização multiobjetivo ser encontrada em alguns trabalhos que resolvem problemas da LR, uma pesquisa realizada nas bases de dados utilizadas para este trabalho utilizando as três palavras-chave não retornou nenhum resultado.

## 1.4 Estrutura do Trabalho

De forma a cumprir os objetivos propostos nesse trabalho, ele foi dividido em cinco capítulos. A fundamentação teórica é abordada no Capítulo 2, nela são demonstrados os principais assuntos utilizados nesse trabalho, como GDs, LR, Otimização e Cluster, descrevendo as principais técnicas utilizadas em cada um deles. Também será descrita uma revisão sistemática da literatura capaz de fornecer as bases para o desenvolvimento deste trabalho, identificando lacunas e ferramentas mais utilizadas.

O Capítulo 3 descreve o método de pesquisa adotado, incluindo a classificação desta pesquisa. O Capítulo 4 demonstra a abordagem inicialmente proposta e descreve o caso de uso utilizado para validar o trabalho. O Capítulo 5 descreve os resultados encontrados no trabalho e, por fim, o Capítulo 6 traz as conclusões e indica, também, possíveis trabalhos futuros que possam se originar desta pesquisa, bem como os trabalhos publicados a partir deste trabalho.

## 2. FUNDAMENTAÇÃO TEÓRICA

### 2.1 Considerações Iniciais

Este capítulo apresenta a fundamentação teórica realizada para este trabalho, indicando tópicos gerais na literatura nos quais esse trabalho se embasa. O capítulo demonstra, de forma geral, os tópicos sobre simulação, com enfoque maior nas Simulações a Eventos Discretos (SEDs), chegando até a Indústria 4.0 e os Gêmeos Digitais. Apesar de não ser necessária a utilização da simulação nesse último tópico, este trabalho utiliza essa ferramenta de forma a auxiliar na apresentação dos resultados obtidos. Será demonstrado o estado da arte sobre Gêmeos Digitais através de uma revisão da literatura que engloba também a Logística Reversa.

Outro ponto importante dessa fundamentação é a Logística Reversa, onde serão demonstrados conceitos importantes sobre esse tema, bem como trabalhos realizados nesta área. Uma revisão sistemática permitirá demonstrar que os Gêmeos Digitais ainda não foram trabalhados em conjunto com a Logística Reversa. Por fim, são também descritos tópicos gerais sobre Cluster e Otimização Multiobjetivo, bem como algumas técnicas utilizadas nos dois assuntos.

De modo a definir os problemas da LR e indicar como os GDs irão auxiliar na resolução deles, a Seção 2.2 traz uma revisão sobre a LR.

### 2.2 Logística Reversa

A necessidade de reciclar equipamentos eletrônicos que se encontram no final da sua vida útil vem aumentando bastante nos últimos anos não apenas devido a problemas ambientais, mas também por causa de fatores econômicos (Gonçalves *et al.*, 2019).

PAES, 2018, em seu trabalho, menciona que, no Brasil, a norma ABNT define o que são equipamentos eletrônicos e resíduos eletroeletrônicos, que são todos os materiais gerados pelo descarte no final da vida desses equipamentos. Portanto, é possível definir equipamentos eletrônicos como sendo:

equipamentos, partes e peças cujo funcionamento adequado depende de correntes elétricas ou campos eletromagnéticos, bem como os equipamentos para geração, transmissão, transformação e medição dessas correntes e campos, podendo ser de uso doméstico, industrial, comercial e de serviços. São exemplos de equipamentos eletroeletrônicos: eletrodomésticos, equipamentos de informática e telecomunicações, equipamentos de iluminação, ferramentas eletroeletrônicas, brinquedos e equipamentos de esporte e lazer, equipamentos eletromédicos, instrumentos de monitoramento e controle, dispensadores automáticos e outros (PAES, 2018).

Amirdadi *et al.*, 2021 mostram o motivo da urgência em aumentar o tratamento adequado de rejeitos. De acordo com os autores, em 2016 uma quantidade de 44.7 milhões de toneladas de resíduos eletroeletrônicos foram gerados mundialmente, isso equivale a 6.1 quilos por habitante naquele ano. Dessa quantidade de resíduos eletroeletrônicos, Rocha *et al.*, 2021 estimam que apenas 20% seja reciclado.

Bernardes *et al.*, 2024 também mostra que, em 2019, quase 54 milhões de toneladas de resíduos eletroeletrônicos foram descartadas no mundo todo e apenas 9 milhões foram coletadas e recicladas apropriadamente.

Segundo Rocha *et al.*, 2021, no Brasil a quantidade de resíduos eletroeletrônicos gerado é de 1.5 milhão de toneladas por ano, o que coloca o país como o segundo que mais gera esse tipo de rejeito nas Américas, atrás apenas dos Estados Unidos. Na América Latina essa situação é ainda pior, com menos de 3% dos resíduos totais sendo gerenciados de forma segura Rocha *et al.*, 2021. Isso mostra a urgência na utilização da Gestão Verde da Cadeia de Suprimentos (GVCS) para reciclagem dos produtos que são colocados no mercado.

De acordo com Souza, 2013, a GVCS é uma cadeia de suprimento que, além da típica logística direta (logística de entrega de produtos), também aborda um fluxo reverso de produtos utilizados (produtos de pós consumo, em final de vida ou devolvidos por qualquer motivo) de volta para os fabricantes.

Münch *et al.*, 2021 trazem uma definição mais detalhada. Eles escrevem que a GVCS trata do projeto, controle e operação de um sistema para maximizar a criação de valor ao longo de todo o ciclo de vida de um produto e dentro dessa cadeia de suprimentos se encontra a LR.

Existem algumas definições de LR que são encontradas na literatura, como no trabalho de Zatrochová *et al.*, 2021 que descrevem a LR como sendo a remoção de resíduos que se originam no processo de produção e distribuição dos produtos. É uma atividade que garante o armazenamento temporário desses materiais, sua posterior remoção do local de descarte, processamento, reutilização ou reciclagem.

Zhang *et al.*, 2021 dissertam que a LR pode ser definida como a coleta de resíduos ou o gerenciamento e descarte de resíduos perigosos e o tratamento e reutilização de recursos. Já Carter *et al.*, 1998 a definem como sendo o processo pelo qual as companhias podem se tornar mais eficientes ambientalmente através da reciclagem, reutilização e redução da quantidade de materiais utilizados.

Zatrochová *et al.*, 2021 trazem uma definição mais longa sobre LR, eles escrevem que ela é um termo para todos os tipos de logísticas que objetivam o movimento reverso de mercadorias e coleta de resíduos do cliente até o fabricante, de forma a registrar uma reclamação ou reutilização, reciclagem ou descarte de acordo com as regulações, preferivelmente de maneira ecológica. Somado a isso, também inclui a separação de resíduos, armazenamento e transporte, porém, não incluem a reciclagem em si, sendo

que a responsável por esta é a GVCS como um todo e a LR é uma parte importante da primeira.

Porém a definição de LR mais utilizada atualmente é a do Conselho Executivo Americano de Logística Reversa (CEALR) ou *American Reverse Logistics Executive Council (ARLEC)*. Vários autores como Islam *et al.*, 2021, Dutta *et al.*, 2020, Moslehi *et al.*, 2021, Panigrahi *et al.*, 2018 e Zhang *et al.*, 2021 utilizam essa definição, portanto ela será também a definição adotada neste trabalho.

Essa definição diz que a LR é o processo de planejar, implementar e controlar o fluxo eficiente e econômico de matérias-primas, estoque em processo, produtos acabados e informações relacionadas, desde o ponto de consumo até o ponto de origem, com a finalidade de recapturar valor ou realizar descarte adequado.

Vale ressaltar que a LR é diferente de gerenciamento de resíduos, pois o primeiro possui como foco adicionar valor aos produtos que já foram utilizados, enquanto o segundo busca realizar a coleta e o tratamento do rejeito sem produzir um novo produto (Vieira *et al.*, 2020).

A LR muitas vezes é confundida com a GVCS e, segundo Islam *et al.*, 2021, as duas áreas possuem algumas similaridades e algumas diferenças. Ainda de acordo com os autores a LR se inicia com o consumidor e vai até o fabricante que realiza as coletas, já a GVCS engloba toda a cadeia, incluindo a produção, distribuição, coleta e remanufatura ou descarte, portanto, pode se considerar a LR como uma parte importante da GVCS (Dutta *et al.*, 2020) que garante que os produtos possam ter uma recuperação socioeconômica e ecologicamente sustentável (Abid *et al.*, 2021).

Assumpção *et al.*, 2019 mostram as principais práticas da GVCS:

- Gestão Ambiental Interna - trocar matérias-primas tóxicas por outras ambientalmente corretas, utilizar menos matérias-primas e reciclar materiais e rejeitos;
- Compras verdes - compra de materiais ecologicamente corretos e comprar matérias-primas que não contenha substâncias proibidas;
- Cooperação com o cliente - utilizar menos energia durante o transporte ou alterar as especificações de produtos para que uma produção mais limpa;
- Ecodesign - realizar o design dos produtos de modo a reduzir o consumo de matérias-primas e auxiliar a reutilização, reciclar ou recuperar materiais e componentes;
- Recuperação de investimento - venda de sucata ou materiais usados e recuperar os equipamentos da empresa ao fim de suas vidas;
- Inovação ambiental - investir em equipamentos e tecnologias verdes, utilizar fontes de energia alternativas e utilizar processos mais limpos para economizar energia, água e rejeitos;

- Desempenho ambiental - certificados de práticas ambientais emitidas por terceiros;
- Conformidade ambiental - conformidade com legislações vigentes;
- Propaganda verde - realizar campanhas publicitárias relacionadas ao ambiente;
- Relacionamento com fornecedores - Alocar fundos para auxiliar os fornecedores em seus programas ambientais e requisitar certificações ambientais dos fornecedores;
- Logística reversa - Coleta e separação de materiais em final de vida, estabelecer um sistema de transporte para realizar as coletas e coletar e gerenciar produtos corretamente;

É possível notar, portanto, que em seu trabalho, Assumpção *et al.*, 2019 também definem a LR como uma parte fundamental das práticas para se ter uma gestão de recursos que afetam o ambiente o mínimo possível.

Abdel-Basset *et al.*, 2021 também reforçam que a LR é um fator importante nas cadeias de suprimento modernas e afirmam que as empresas vem utilizando a LR principalmente por dois motivos: (i) falta de matérias-primas, custos das mesmas e o aumento dos preços e (ii) devido à tendência de conscientização do governo para proteger o meio ambiente e a promulgação de leis e legislações que garantem essa proteção. Nos anos recentes, a LR vem atraindo atenção de pesquisadores e indústrias devido ao fato de que ela pode recuperar o valor de produtos em seu fim de vida (Zhang *et al.*, 2020).

No Brasil, desde 2010, existe a Política Nacional de Resíduos Sólidos (PNRS) (Brasil, 2010), que determina princípios, objetivos, instrumentos e outras diretrizes referentes à gestão de resíduos (Fagundes *et al.*, 2017). A PNRS indica que a LR é uma ferramenta capaz de viabilizar a coleta e o retorno dos produtos em fim de vida para as empresas capazes de destiná-los a processos ambientalmente adequados (Moraes *et al.*, 2023). Porém, o trecho referente aos resíduos eletrônicos domésticos foi criado apenas em 2020. Nele fica demonstrada a obrigatoriedade da implementação de sistemas de LR de produtos eletrônicos e seus componentes pelas empresas que os produzem (Brasil, 2020).

Apesar da obrigatoriedade em vários países, Panjehfouladgaran *et al.*, 2020 dizem que a LR não vem sendo amplamente implementada, por outro lado vem atraindo atenção de pesquisadores nas últimas duas décadas. Existem algumas razões pelas quais a LR vem sendo discutida nas pesquisas acadêmicas e na indústria, incluindo aumento da preocupação com o meio ambiente, vantagens competitivas, potencial financeiro promissor, leis e responsabilidade social (Marić *et al.*, 2019).

Somado à isso, há outro problema nas empresas, a tendência de trabalhar com uma LR reativa, ou seja, apenas tomar decisões após algum acontecimento. Criar ferramentas que auxiliam a melhorar essas decisões é difícil e as empresas costumam buscar ajuda no meio acadêmico (Zarbakhshnia *et al.*, 2020).

De acordo com Amirdadi *et al.*, 2021 a implementação de uma rede LR pode ser uma oportunidade, ao invés de uma obrigação, para produtores diminuírem seus custos através da recuperação e reciclagem de resíduos eletroeletrônicos. O estudo de Zhang *et al.*, 2021 mostra que produtos remanufaturados podem reduzir o custo total dos produtos em cerca de 50% a 60% e seu desempenho é tão bom quanto o desempenho de produtos novos. Esse estudo prova que os benefícios econômicos na utilização da LR podem ser interessantes para as empresas.

Somado à esses benefícios, ainda é possível destacar que o processo de remanufatura utiliza menos tempo de produção e consome menos matéria-prima e energia que o processo tradicional, portanto o consumidor pode pagar menos nos produtos, reduzindo os custos, aumentando as vendas e diminuindo o resíduo eletroeletrônico (Abid *et al.*, 2021).

A LR se tornou um elemento fundamental na cadeia de suprimentos ao permitir a redução do gasto total e, num primeiro momento, reduzir as emissões de  $CO_2$ , porém caso ocorra o aumento da demanda de coletas no futuro, é possível que as emissões também aumentem (Roudbari *et al.*, 2021). Devido à esse fato, um dos objetivos deste trabalho é tentar reduzir a emissão de  $CO_2$  durante as coletas da LR.

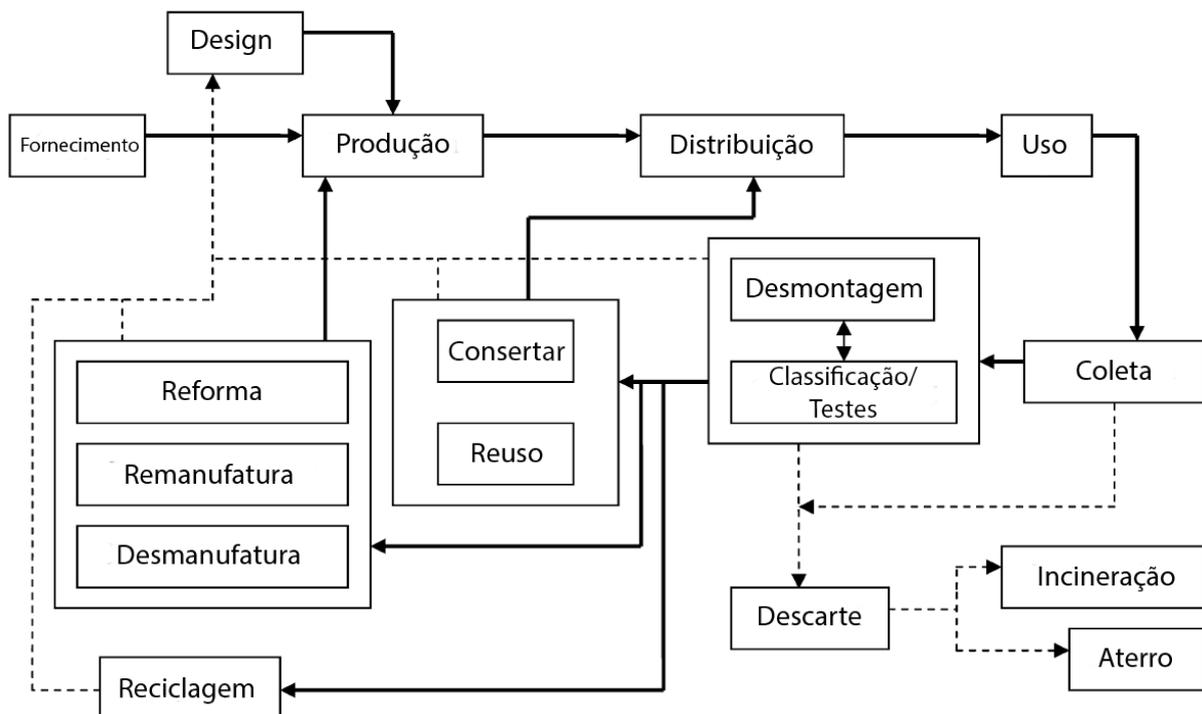
A LR não trata apenas do transporte de produtos do usuário para o fabricante, que é o foco deste trabalho, mas também da classificação e tratamento dos produtos e seus componentes (Cortés Pellicer *et al.*, 2018). Os resíduos podem ser classificados de várias formas e cada uma possui um tipo de tratamento diferente (Abid *et al.*, 2021).

- Reutilização: consiste na reutilização de produtos inteiros ou parte deles na criação de outros produtos. Esse é o processo que ocorre em lojas de produtos de segunda-mão e inclui toda a parte de teste dos produtos coletados mas não inclui a desmontagem dos mesmos;
- Conserto: consiste em recuperar componentes danificados para um estado funcional;
- Remanufatura: consiste em gerenciar e restaurar um produto não funcional, descartado ou trocado em um produto que possua condições quase novas. Neste caso os produtos são desmontados e cada parte é inspecionada separadamente, as peças que não funcionam são substituídas por outras novas;
- Reforma: consiste em reformar produtos pouco danificados ou que possuem um problema técnico que pode ser consertado rapidamente. O objetivo é recuperar o valor econômico de produtos e obter informações sobre o motivo do produto ter falhado em campo;
- Reciclagem: o propósito da reciclagem é recuperar todo o material do produto coletado e convertê-lo em materiais reutilizáveis sem conservar a estrutura do produto, esses materiais reutilizáveis são enviados para a criação de novos produtos;

- Canibalização: consiste em utilizar componentes recuperados de produtos usados para fornecer partes que podem servir de reposição para serem utilizados em serviços de atendimento ao consumidor, ou seja, se trata de recuperar partes funcionais de um produto descartado e utilizá-las para o conserto de outros produtos.

Sasikumar *et al.*, 2008 trazem, em seu trabalho, uma imagem bastante interessante e completa sobre a classificação dos resíduos e a sequência de tratamentos que devem ser realizados, dependendo da qualidade do produto recebido. A Figura 2.2.1 mostra uma adaptação dessa imagem.

Figura 2.2.1 – Atividades básicas de uma LR.



Fonte: Adaptado de Sasikumar *et al.*, 2008.

Como mencionado anteriormente, este trabalho possui como foco apenas a parte relacionada à coleta na LR e ela, como mostra Srivastava, 2007, é a primeira parte do processo de recuperação de produtos na qual os produtos são localizados, coletados e transportados para as fábricas que realizam a remanufatura. Ainda de acordo com os autores, os produtos são buscados em múltiplas fontes e levados para as fábricas que irão realizar a recuperação dos mesmos.

Apesar da LR ser um fator importante nas cadeias de suprimento, ela pode ser considerada uma das iniciativas mais difíceis de se implementar na GVCS (Bouzon *et al.*, 2018) e, portanto, é pouco explorada de forma prática. De acordo com o estudo realizado por Kazemi *et al.*, 2019, apenas 12% dos artigos utilizados em seu trabalho possuíam casos reais da indústria ou dados coletados.

Mesmo com todas as vantagens já mencionadas sobre a LR, sua implementação pode encontrar várias barreiras como: custo adicional na produção, a necessidade de recursos humanos e maior complexidade no planejamento (Plaza-Úbeda *et al.*, 2020).

Um segundo problema são os costumes e comportamentos dos clientes. Para que a LR funcione corretamente, é necessária a participação ativa dos clientes finais, que devem descartar seus produtos de forma correta (Bernardes *et al.*, 2024). Sendo assim, é possível destacar a importância da coleta seletiva, que permite que os resíduos eletrônicos possam realizar o fluxo reverso até a empresa que irá enviá-los para a destinação correta (Moraes *et al.*, 2023).

Além disso, Plaza-Úbeda *et al.*, 2020 também citam que a principal barreira à LR é a crença de que ela é apenas um processo que lida com o gerenciamento dos resíduos, subestimando a importância da contribuição para o meio ambiente. Outra crença errônea que existe na LR é a de que os produtos retornados não são importantes em termos de custo, avaliação de ativos e receitas e também existe o fato de que a LR não é reconhecida como um fator que gera uma vantagem competitiva (Uriarte-Miranda *et al.*, 2018).

De acordo com Melo *et al.*, 2021, muitos estudos evidenciam e quantificam ganhos devido à utilização de iniciativas sustentáveis, como cerca de 17% de redução de custos devido ao uso de energias sustentáveis, 31,5% de diminuição da emissão de CO<sub>2</sub> e economia de cerca de 33.5% no custo de transportes.

Por outro lado, Abid *et al.*, 2021 defendem que a principal dificuldade em desenvolver uma LR é a incerteza, isso se deve ao fato de que empresas de remanufatura regularmente precisam lidar com situações imprevisíveis (Tosarkani *et al.*, 2020). Somado à isso, Roudbari *et al.*, 2021 e Zarbakhshnia *et al.*, 2020 também escrevem que planejar a LR é mais difícil que planejar a logística direta, devido à incerteza da quantidade e qualidade dos produtos que serão retornados, além da variação de preços dos produtos recuperados. A Tabela 2.2.1 mostra as principais diferenças entre os dois tipos de logística.

Tabela 2.2.1 – Principais diferenças entre a Logística e a Logística Reversa.

<b>Crítérios</b>	<b>Logística</b>	<b>Logística Reversa</b>
<b>Especificação do Produto</b>	Qualidade e pacotes uniformes	Qualidade não uniforme e pacotes normalmente danificados
	Disposição clara	Disposição não é clara
	Ciclo de vida gerenciável	Ciclo de vida complexo
	Previsão direta	Previsão Difícil
<b>Transporte</b>	Um para muitos	Muitos para um
	Rota\destino claros	Rota\destino não são claros
<b>Custo</b>	Preço uniforme	Preço depende de muitos fatores
	Visível	Invisível

Fonte: Adaptado de Panjehfouladgaran *et al.*, 2020.

Também foram encontradas na literatura, barreiras impostas pela própria gerência da empresa como falta de interesse dos gerentes, falta de políticas apropriadas dentro das empresas, falta de infraestrutura tecnológica e problemas financeiros (Ali *et al.*, 2018). Waqas *et al.*, 2018 identificaram várias barreiras que são consideradas críticas para a implementação da LR como alto custo para a adoção da LR, falta de profissionais capacitados, falta de políticas de suporte governamentais, falta de cultura, falta de recursos humanos, falta de conhecimento das leis ambientais, falta de pressão da comunidade e políticas da companhia.

Kiatcharoenpol *et al.*, 2020 trazem uma tabela com várias barreiras divididas por categorias e elas são: gerenciais, organizacionais, barreiras do produto, barreiras legais, tecnológicas, infraestruturais, financeiras e barreiras de apoio à LR. Por fim, Waqas *et al.*, 2018 trazem uma discussão bastante interessante sobre as barreiras da LR e mostram vários artigos que as descrevem.

Para Voigt *et al.*, 2019, desenvolver métricas para medir o desempenho de uma cadeia de suprimentos é um problema complicado e tem se tornado mais complexo agora que a LR está também sendo levada em consideração, devido ao fato de dificultar a operação e coordenação do fluxo de materiais e informação. Portanto, várias pesquisas utilizam simulação para estudar esses desafios, o que reduz a complexidade se comparado à modelos matemáticos, pois a utilização da simulação frequentemente resulta na redução da necessidade de desenvolver modelos matemáticos complexos (Abid *et al.*, 2021).

Segundo Ni *et al.*, 2021, a LR pode ser dividida em algumas subcategorias de tomada de decisão: 1) previsão de volumes de resíduos eletroeletrônicos; 2) seleção de localização de instalações de LR; 3) seleção de fornecedores terceirizados de LR; 4) decisões relativas à roteamento de veículos e tipo de recipiente; 5) problemas relacionados à desmontagem e remanufatura. Levando em consideração que a distância é um fator que afeta os custos para se recuperar um produto (Gao *et al.*, 2021), este trabalho aborda uma dessas categorias, que são as decisões sobre roteirização de veículos e tipo de recipiente, visto que será discutido o melhor momento, local e veículo para se realizar uma coleta.

NETO *et al.*, 2006 dizem que um problema de roteirização é definido por três fatores:

- Decisões - contém o grupo de clientes que devem ser visitados, o conjunto de veículos e motoristas e o sequenciamento de visitas. No caso deste trabalho, é possível apontar decisões envolvendo as cidades que estão contidas em um Cluster e devem ser visitadas, os motoristas e veículos e a sequência dessas cidades;
- Objetivos - visa fornecer um serviço aos clientes que, ao mesmo tempo que possui alto nível, também mantém os custos o mínimo possível;
- Restrições - as rotas devem ser realizadas dentro de um tempo definido apenas com os veículos disponíveis, além de respeitar a carga horária dos motoristas e ajudantes;

Existem vários softwares específicos para realizar roteirização de veículos, porém muitos deles não possuem a capacidade de abordar o problema utilizando localização geográfica exata (NETO *et al.*, 2006). Isso pode ser sanado neste trabalho com a utilização de uma biblioteca em Python (GeoPy Developers, 2024) capaz de converter endereços em coordenadas geográficas, assim permitindo que seja possível utilizar a localização exata da coleta.

O conhecimento sobre as coordenadas geográficas permite que sejam criadas matrizes de distâncias utilizadas para solucionar o problema, porém, ainda é necessário uma maneira de encontrar as melhores rotas.

O problema descrito neste trabalho se refere ao do Caixeiro Viajante Múltiplo (PCVM) (NETO *et al.*, 2006). Nele existem mais de um caixeiro viajante (ou veículo) e todos eles iniciam e finalizam suas rotas exatamente em um mesmo ponto.

Em uma busca por Problemas de Roteirização de Veículos, foi encontrada outra biblioteca em Python chamada pyVRP (Valdecy, 2024), que permite solucionar questões sobre roteirização utilizando algoritmos genéticos, pois, de acordo com Singh, 2016, esse tipo de metaheurística é uma das mais utilizadas para resolver esse tipo de problema.

Alkahtani *et al.*, 2021 em seu trabalho escrevem sobre as futuras direções das pesquisas na área de LR e entre elas é possível destacar a digitalização, métodos de previsão para retorno de produtos, análise de incertezas, aspectos sociais e competição na coleta. Este trabalho aborda duas dessas áreas que são digitalização da LR e competição na coleta, visto que a LR nem sempre pode trazer receita, o objetivo é minimizar o custo (Bal *et al.*, 2018).

Panjehfouladgaran *et al.*, 2020 mostram algumas dificuldades de se implementar a LR, entre elas, destaca-se a dificuldade de testar as rotas em um sistema real. Esses testes podem ser executados com o auxílio de ferramentas de digitalização, como Simulação e GDs. Portanto, as próximas seções tratam esses dois assuntos.

## 2.3 Simulação

Montevecchi *et al.*, 2020 definem a simulação como um processo de imitar os sistemas reais. Essa ferramenta é capaz de descrever e analisar o comportamento do sistema e responder questões sobre ele. A simulação também pode ser descrita como sendo a importação do mundo real para o virtual, permitindo o estudo do comportamento do ambiente sem que seja necessário envolver custos ou riscos (Montevecchi *et al.*, 2007) e permitindo também, que o sistema seja testado em diferentes condições (Baines *et al.*, 2004).

Chwif *et al.*, 2014 descrevem sobre a dificuldade de definir o que exatamente é a simulação e, portanto, se propõem a dizer o que não é simulação e o que ela não se propõe a fazer. De acordo com os autores, a simulação não é uma ferramenta de otimização, mas sim algo capaz de permitir a análise de diferentes cenários, além de não trazer uma

resposta ótima e não ser capaz de substituir o pensamento humano.

Borshchev *et al.*, 2004 defendem que existem vários tipos de simulação mas apontam os três métodos principais que são os Sistemas Dinâmicos (SDs), a Simulação a Eventos Discretos (SEDs) e a Simulação Baseada em Agentes (SBA).

Porém, no trabalho de Scheidegger *et al.*, 2018, os autores escrevem que a SED vem sendo o principal tipo de simulação utilizado em trabalhos e de acordo com Santos *et al.*, 2021, esse tipo de simulação é utilizado em 90% das aplicações que envolvem GDs e, devido a esses fatos, ela será o tipo de simulação utilizada neste trabalho.

### 2.3.1 Simulação a Eventos Discretos

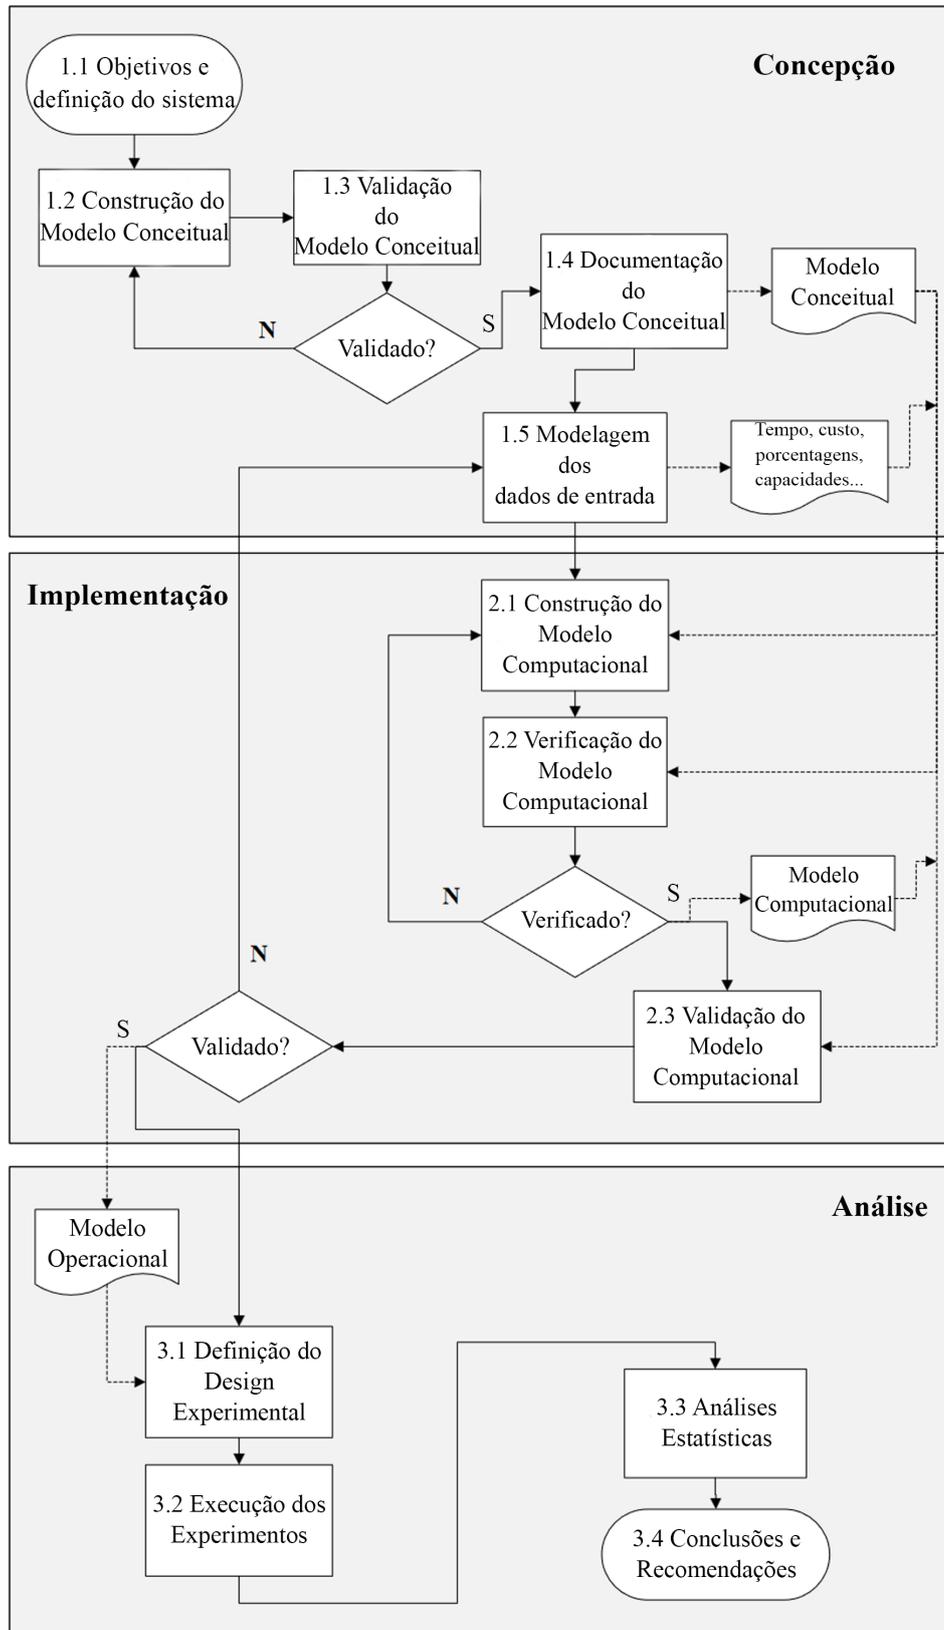
A SED vem sendo bastante utilizada na melhoria de processos, pois permite reproduzir modelos reais em virtuais, sendo assim possível explorar uma vasta gama de cenários possíveis para o problema (Melao *et al.*, 2006). Borshchev *et al.*, 2004 definem a SED como sendo uma técnica de modelagem baseada no conceito de entidades, recursos e filas que descrevem um fluxo de entidades e compartilhamento de recursos.

Segundo Schriber *et al.*, 2013, a SED é composta por entidades, recursos, elementos de controle e operações. A entidade é utilizada para designar uma unidade de tráfego no modelo, além de instigar e responder a eventos. O recurso é um elemento do sistema que fornece serviços, como um veículo ou operário. As entidades normalmente competem pelos recursos e, portanto, algumas vezes precisam esperar para poder utilizá-los, acarretando em filas que são resolvidas pelos elementos de controle. Esses são objetos que auxiliam a solucionar vários tipos de atrasos oferecendo alternativas lógicas. Por fim, a operação é um passo realizado por uma entidade ou sobre ela enquanto ela se move no sistema.

A criação das SEDs não é trivial e existem métodos disponíveis na literatura para auxiliá-la. Montevechi *et al.*, 2007 trazem os principais processos adotados nas abordagens mais tradicionais. A Figura 2.3.1 resume uma delas e os passos são detalhados a seguir:

- Passo 1.1: Objetivos e definição do sistema - a primeira parte de um projeto de simulação; garante que a definição do problema seja clara;
- Passo 1.2: Construção de um modelo conceitual - nessa etapa, o modelo real sob investigação é resumido utilizando uma série de relações lógicas relativas aos componentes e à estrutura do sistema;
- Passo 1.3: Validação do modelo conceitual - validar um modelo, de acordo com Sargent, 2000 é garantir que ele possua uma faixa de precisão consistente com a aplicação pretendida pelo modelo;
- Passo 1.4: Modelagem dos dados de entrada - consiste na coleta, identificação e modelagem dos dados que serão inseridos no modelo computacional de simulação;

Figura 2.3.1 – Metodologia de condução de pesquisa.



Fonte: Adaptado de Montevechi *et al.*, 2020.

- Passo 2.1: Construção do modelo computacional - Chwif *et al.*, 2014 escrevem que essa etapa é responsável por converter o modelo conceitual, criado nos passos de 1.1

a 1.4, em modelos de simulação;

- Passo 2.2: Verificação do modelo computacional - nesta etapa é verificado se o modelo computacional segue a lógica definida no modelo conceitual;
- Passo 2.3: Validação do modelo operacional - neste passo é necessário avaliar o quão próximo do sistema real o modelo é;
- Passo 3.1: Definição do design experimental - de acordo com Balci, 2012, nesta etapa ocorre a formulação de um plano para reunir as informações desejadas a um custo mínimo;
- Passo 3.2: Execução dos experimentos - executa os passos definidos na etapa 3.1;
- Passo 3.3: Análise estatística - nessa etapa são analisados os efeitos de cada um dos fatores do modelo de simulação;
- Passo 3.4: Conclusões e recomendações - tem relação com a tomada de decisão baseada nos resultados obtidos pelo modelo de simulação.

A integração de modelos de IA (Inteligência Artificial) e *Big Data* com a simulação é provavelmente um dos avanços mais importantes no campo da tecnologia, ou seja, os GDs. A abordagem de Montevechi *et al.*, 2020 é utilizada para a criação do modelo de simulação que compõe o GD que, de acordo com Barricelli *et al.*, 2019, é um modelo vivo e inteligente que é uma contraparte do processo físico.

## 2.4 Gêmeos Digitais

Desde a criação da ideia de um Gêmeo Digital, o interesse neste conceito vem aumentando e ele pode ser listado como uma estratégia importante para a área de tecnologia (Jones *et al.*, 2020) e uma solução moderna para suprir a necessidade de digitalização de processos (Botkina *et al.*, 2018).

Alguns autores como Okita *et al.*, 2019, Qamsane *et al.*, 2021 e Rajesh *et al.*, 2019 atribuem a primeira aparição do termo Gêmeos Digitais a uma palestra dada por Michael Grieves na Universidade de Michigan. Ele introduziu o conceito em uma apresentação sobre o gerenciamento do ciclo de vida de produtos intitulada “*Conceptual Ideal for PLM*” (Barricelli *et al.*, 2019). Segundo Xie *et al.*, 2021, Grieves atualizou sua teoria em dois artigos publicados após a ideia original e nomeou o conceito de “*Mirrored Space Model*” (Modelo Espelhado do Espaço) e “*Information Mirroring Model*” (Modelo de Espelhamento de Informações), ambos os termos não foram encontrados em nenhum artigo da revisão realizada nesse trabalho e portanto, não serão utilizados.

Após Grieves surgir com seu modelo, a NASA (*National Aeronautics and Space Administration* ou Administração Nacional da Aeronáutica e Espaço) desenvolveu, durante

o programa “*Apollo*”, o então chamado Hardware Gêmeo (Malik *et al.*, 2018). Ainda segundo os autores, esse modelo consistia em dois veículos idênticos, um deles era mantido na Terra enquanto o outro era enviado para o espaço. O veículo que estava em solo era atualizado com as condições de voo do veículo em órbita para permitir que os especialistas em solo assistissem astronautas durante as missões.

A primeira definição de GD vem sendo atribuída à NASA por vários autores, como sendo “uma simulação multi física, multiescala e probabilística integrada de um sistema que utiliza os melhores modelos físicos, sensores e históricos disponíveis para espelhar o ciclo de vida do seu gêmeo físico correspondente. Ele é ultra realista e pode considerar um ou mais sistemas veiculares importantes e interdependentes” (Qamsane *et al.*, 2021), (Schützer *et al.*, 2019), (Dittrich *et al.*, 2020) e (Rajesh *et al.*, 2019).

Apesar da definição dada pela NASA ser bastante difundida em vários artigos científicos, ela é bastante particular e se refere especificamente aos veículos utilizados para as missões espaciais. Nos dias de hoje, a definição de GD foi ampliada para englobar vários tipos de sistemas e pode ser descrita como uma réplica virtual de um sistema, objeto ou processo físico, através de todo seu ciclo de vida (Moyne *et al.*, 2020), (Jones *et al.*, 2020), (Talkhestani *et al.*, 2018), (Schützer *et al.*, 2019), (Jones *et al.*, 2019). Barricelli *et al.*, 2019 ainda escrevem que esses objetos podem ser processos, seres humanos ou qualquer característica relacionada aos seres humanos.

Um GD é diferente de um modelo de simulação. De acordo com Barricelli *et al.*, 2019, o que permite que um modelo de simulação seja considerado um GD é a aplicação da Inteligência Artificial e a troca de dados contínua entre os modelos físico e virtual. Porém, Torres *et al.*, 2024 não concordam com a necessidade da utilização de IA, eles dizem que o importante é apenas a troca contínua de dados e que a IA é um complemento capaz de melhorar o GD.

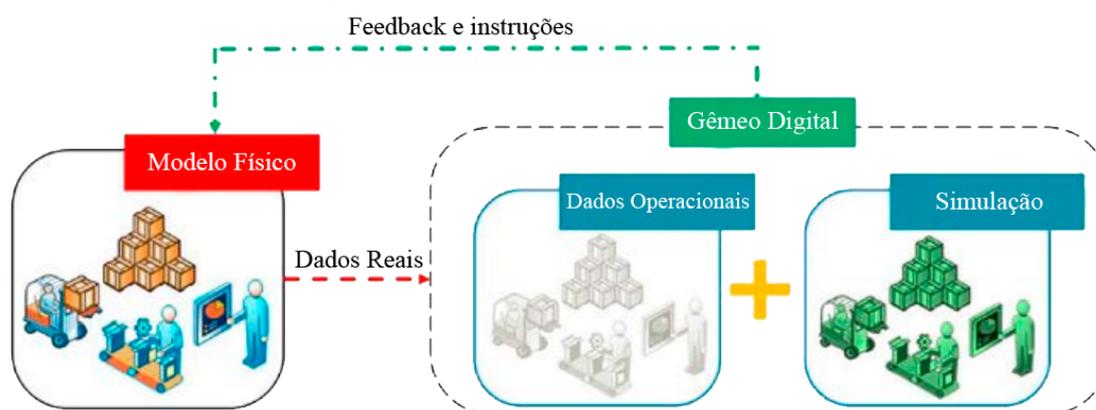
Enquanto a simulação permite resolver problemas que outros métodos da pesquisa operacional não são capazes de resolver e criar cenários que podem identificar o que aconteceria se uma ação fosse tomada no mundo real, o GD permite, também realizar a otimização, a visualização do processo completo (Schützer *et al.*, 2019) em tempo real e permite a tomada de decisões automáticas, sem a interferência de um usuário.

Dessa forma, é possível definir um GD como mais que apenas um modelo de simulação, mas algo que também contém dados operacionais (Talkhestani *et al.*, 2020). Segundo Martínez *et al.*, 2018, os GDs são capazes também de comparar e analisar dados medidos e previstos do objeto físico. Desse modo, um GD pode ser utilizado para simular, monitorar, otimizar e verificar várias atividades durante o ciclo de vida desse objeto.

Segundo Chen *et al.*, 2020, o GD é um modelo de simulação que integra objetos e dados, tornando o espaço virtual totalmente consistente com o espaço real. O modelo virtual depende de sensores instalados no modelo físico e, ao mesmo tempo, recebe um *feedback* com instruções do modelo físico, permitindo alterar seu estado.

De acordo com Dittrich *et al.*, 2020, do ponto de vista da simulação, o Gêmeo Digital é o próximo passo da tecnologia de modelagem e simulação. Dito isso, os Gêmeos Digitais só são possíveis através da integração de algumas tecnologias, como Internet das Coisas, Inteligência Artificial, Aprendizado de Máquina e Simulação, por exemplo (Tekinerdogan *et al.*, 2020). A Figura 2.4.1 mostra como a simulação funciona dentro do contexto de um GD. Um GD possui várias camadas e a próxima seção explica com detalhes a estrutura de cada uma delas.

Figura 2.4.1 – A simulação dentro do conceito de Gêmeo Digital.



Fonte: Adaptado de Santos *et al.*, 2021.

### 2.4.1 Estrutura de um Gêmeo Digital

Li *et al.*, 2020 e Kim *et al.*, 2020 assumem que o modelo inicial de Grieves era composto por duas camadas, uma física e uma virtual. A camada física é responsável por receber as decisões geradas pela camada virtual, além de coletar, processar e transmitir dados para a camada virtual. Já a camada virtual é responsável por tomar as decisões e realizar o controle da camada física. Segundo Malik *et al.*, 2018, o sistema virtual contém todas as informações do físico, sendo assim, o primeiro é uma cópia exata do segundo.

Por outro lado, autores como Jones *et al.*, 2020, Ghita *et al.*, 2020 e Jones *et al.*, 2019 dissertam que o modelo de Grieves possui, na verdade, três camadas: a camada física, a camada virtual e uma camada de comunicação entre as duas. Essa descrição é mais acurada, pois é necessário uma maneira de permitir que as duas camadas principais possam trocar informações e dados entre si. As camadas física e virtual são exatamente iguais às definidas no parágrafo anterior, somada a elas, a camada de comunicação fornece um tráfego bidirecional de dados que conecta as duas outras (Ghita *et al.*, 2020).

Porém, o modelo mais utilizado e aceito atualmente é o modelo de 5 camadas proposto por Tao *et al.*, 2017. Na revisão realizada para esse trabalho foram encontrados 8 artigos que trazem detalhes sobre qual o modelo utilizado. 4 deles descrevem o modelo de 5

camadas, 3 descrevem o modelo de 3 camadas e apenas 1 traz um modelo de 2 camadas. A tabela 2.4.1 mostra os artigos que descrevem cada um dos modelos.

Tabela 2.4.1 – Artigos que descrevem os modelos de GD utilizados

Artigo	GD		
	5 camadas	3 camadas	2 camadas
Ghita <i>et al.</i> , 2020		X	
Gu <i>et al.</i> , 2021	X		
Han <i>et al.</i> , 2020	X		
Jones <i>et al.</i> , 2019		X	
Jones <i>et al.</i> , 2020		X	
Li <i>et al.</i> , 2020			X
Ma <i>et al.</i> , 2019	X		
Ponomarev <i>et al.</i> , 2017	X		

Visto que o GD com 5 camadas é o mais descrito na literatura, esse trabalho também se baseia neste modelo. De acordo com Tao *et al.*, 2017, essas camadas são (Ma *et al.*, 2019):

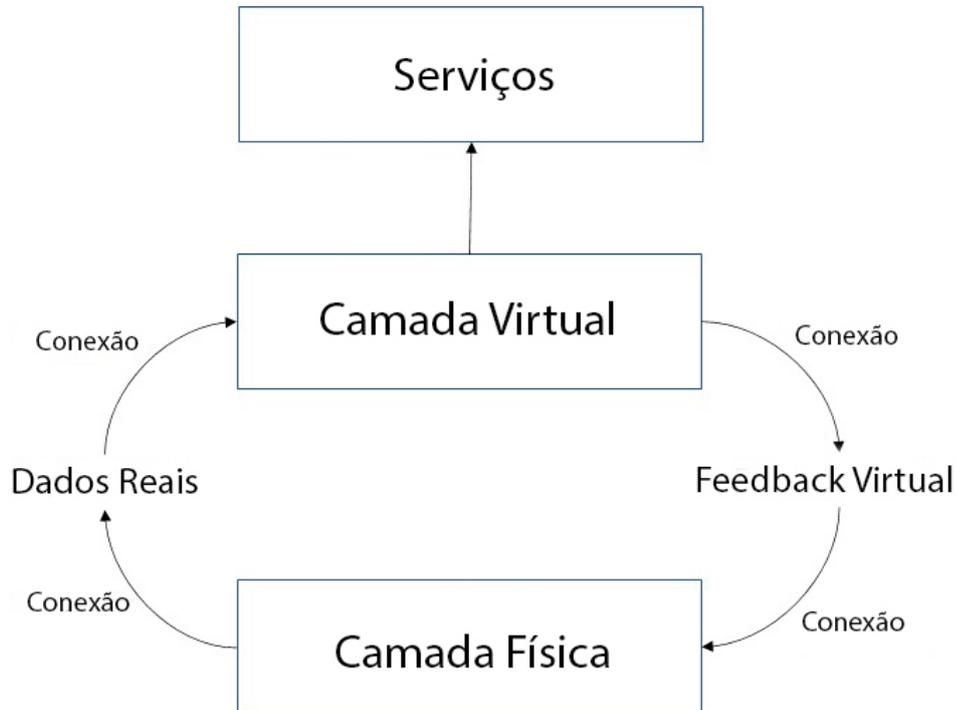
- O modelo físico - todos os sistemas que compõem o ambiente físico que se deseja modelar;
- O modelo virtual - a representação virtual do modelo físico (Gu *et al.*, 2021);
- O modelo de serviço - cria uma interface para que o usuário possa interagir com o modelo (Gu *et al.*, 2021);
- O modelo de dados - possui os dados dos modelos físico e virtual (Gu *et al.*, 2021);
- O modelo de conexão - realiza o transporte dos dados entre o restante dos modelos (Gu *et al.*, 2021).

A Figura 2.4.2 mostra o caminho da comunicação realizado por essas camadas.

Existem vários benefícios encontrados na literatura sobre a utilização de GDs e entre eles é possível destacar o que alguns autores escrevem:

- Kapustina *et al.*, 2020 mostram que o GD pode auxiliar na criação de um plano para alguns processos a fim de tentar prevenir situações imprevisíveis;
- Kalaboukas *et al.*, 2021 reuniram algumas vantagens como auxiliar a fábrica a simular seus processos, controlar e monitorar seu desempenho, aumentando a produção, manutenibilidade, além de ajudar a conectar e envolver os vários acionistas e otimizar a logística;
- Gu *et al.*, 2021 mostram que os GDs fornecem maior participação e interação dos clientes, ajudando a aumentar a customização em massa;

Figura 2.4.2 – Modelo de 5 camadas de um Gêmeo Digital.

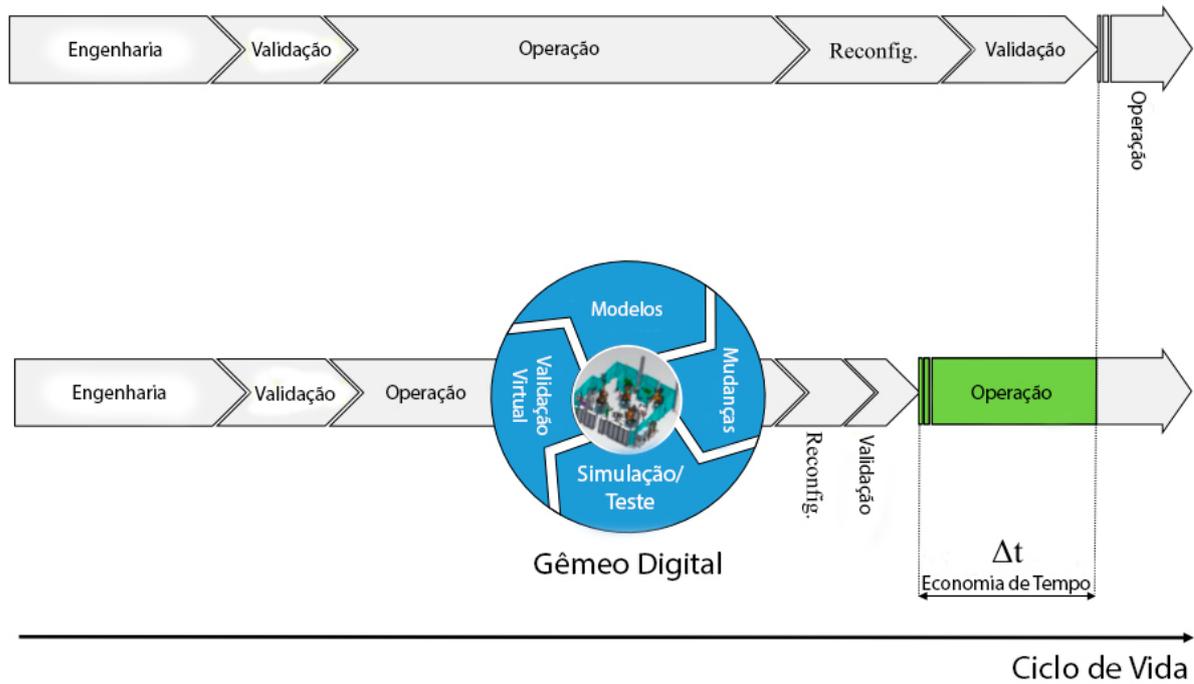


- O GD não depende do tempo nem da localização, isso significa que é possível simular e produzir comportamentos em qualquer local e momento (Czwick *et al.*, 2020);
- O GD também reduz a experimentação com produtos reais, reduzindo o custo e tempo de produção (Czwick *et al.*, 2020) (Avventuroso *et al.*, 2017);
- Jones *et al.*, 2020 citam vários autores que descrevem vantagens, como redução de custos, diminuição do risco e tempo de desenvolvimento (detalhado na Figura 2.4.3), melhoria dos serviços de pós-venda, melhoria na eficiência, aumento da segurança e confiança, melhorias na flexibilidade e competitividade do sistema de manufatura e o fomento da inovação;
- É possível realizar simulações durante o design dos produtos para facilitar as decisões sobre ele (Jones *et al.*, 2019);
- Melhora a reciclagem e recondicionamento de produtos, visto que os GDs possuem os materiais e instruções de montagem necessários para completar o desmonte ou conserto (Jones *et al.*, 2019).

Por outro lado, os GDs também possuem algumas desvantagens que devem ser superadas, como as descritas nos próximos itens:

- A maioria das empresas ainda possui baixo nível de automação para que um GD seja implementado (Kapustina *et al.*, 2020);

Figura 2.4.3 – Figura que mostra como o GD pode economizar tempo no desenvolvimento do projeto.



Fonte: Adaptado de Talkhestani *et al.*, 2018

- A aquisição dos dados é quase sempre um trabalho manual e pode ser errôneo, além de conflitarem com a definição de GDs, que mostra que eles devem, preferencialmente, receber dados automaticamente (Uhlemann *et al.*, 2017);
- Problemas com segurança dos dados (Uhlemann *et al.*, 2017);
- Os GDs cobrem características do produto mas não cobrem influências externas do ambiente no produto como temperatura, umidade do ar, entre outros (Czwick *et al.*, 2020);
- O processo de comparação realizado entre os dados esperados e obtidos é ineficiente (Avventuroso *et al.*, 2017);
- Os valores e retornos de investimentos em GD são, na prática, difíceis de serem analisados, isso faz com que as empresas ainda relutem em adotar GDs (Barth *et al.*, 2020). Além disso, Barth *et al.*, 2020 defendem também que é difícil para os operadores e empreiteiros notarem qual valor agregado um GD pode trazer;
- Alto custo para novos equipamentos de tecnologia inibem a aplicação da indústria 4.0 (Uhlemann *et al.*, 2017).

Além das vantagens e desvantagens associadas aos GDs, também existem alguns fatores que impactam a criação dos mesmos e esses são descritos no trabalho de Rivera

*et al.*, 2020, como sendo três: agregação dos dados em tempo-real (tem relação com a exploração de dados gerados pelo modelo real, porém não é um fator decisivo, visto que os GDs podem trabalhar com dados em tempo quase real); integração e interoperabilidade (refere-se à habilidade do modelo de interagir e fornecer serviços para outros sistemas); fidelidade (criar um modelo virtual que corresponda precisamente ao modelo real).

Como visto, os GDs são uma ferramenta que auxiliam nas tomadas de decisões de problemas complexos, apesar disso, eles ainda são pouco utilizados e Kapustina *et al.*, 2020 trazem alguns obstáculos que sugerem o motivo de ocorrer esse fato.

- Falta de capital suficiente para implementação dos recursos necessários;
- Falta da infraestrutura necessária, o que está diretamente conectado com a falta de capital;
- Baixa capacitação em Tecnologia da Informação;
- Nível de maturação do processo insuficiente ou nível de automação muito baixo.

Por fim, para se criar um GD é interessante utilizar modelos virtuais leves, selecionando apenas características obrigatórias sem inserir detalhes desnecessários, com isso é possível reduzir o modelo, além do fato de permitir processamentos de forma mais rápida (Kuehn, 2018). O autor também descreve que modelos leves são mais baratos e podem ser compartilhados dentro da empresa bem como com toda a rede de suprimentos, melhorando a qualidade do produto.

Para ser possível a criação do *Framework*, foram necessárias algumas ferramentas, como Clusters e Otimização Multiobjetivo, que serão definidos nas próximas seções (Seções 2.5 e 2.6)

## 2.5 Cluster

Clusterização é o processo de organizar um conjunto de objetos em um conjunto de grupos mutuamente excludentes de tal forma que a similaridade entre objetos dentro de um Cluster é maximizado enquanto a similaridade de objetos em diferentes agrupamentos é minimizada (Jain *et al.*, 1999).

Clusters podem ser aplicados em diversas situações, e Stichhauerova *et al.*, 2020 mostram sua utilização em indústrias. Segundo os autores, os Clusters são importantes nas políticas industriais baseando-se em competitividade, força, condições de frameworks e fomentando abordagens específicas da indústria, bem como no apoio a colaborações público-privadas.

Kincaid, 2005 mostra que os Clusters podem trazer muitos benefícios para todos os envolvidos, como melhorias na eficácia, produtividade e inovação, além de contribuir para o aumento do desempenho. Stichhauerova *et al.*, 2020 ainda afirmam que os Clusters

criam um ambiente propício para inovações e desenvolvimento de novas habilidades, além de acarretar vantagens econômicas, como o aumento da eficiência dos recursos, que leva à diminuição dos preços.

Saati *et al.*, 2013 escrevem que os Clusters são normalmente divididos em três tipos, Hierárquicos, Redes de Aprendizagem e Baseado em Distâncias. No entanto, Reddy *et al.*, 2013 descrevem apenas dois tipos de Clusters mais utilizados, Hierárquicos e Particionais. Portanto, essa será a classificação adotada neste trabalho, e as seções 2.5.1 e 2.5.2 os descrevem. Além desses dois tipos, ainda existe um Cluster pouco encontrado na literatura, porém muito importante para este trabalho, pois o algoritmo utilizado aqui se encaixa nessa classificação. Este tipo de Cluster é conhecido por Incremental e será abordado na seção 2.5.3.

### 2.5.1 Clusters Hierárquicos

Köhn *et al.*, 2014 definem os Clusters Hierárquicos como sendo a utilização de uma análise de dados que gera uma classificação hierárquica de um conjunto de objetos. Um exemplo bastante comum é citado por Capra, 2005, que escreve que os menus de softwares podem ser considerados Clusters Hierárquicos, pois o resultado do agrupamento é uma árvore que mostra os relacionamentos entre os itens, sendo que cada item só pode ser localizado em um único local nessa árvore. Segundo Reddy *et al.*, 2013, essa estrutura baseada em árvore é chamada de dendrograma.

De acordo com Ben-Arieh *et al.*, 2012, os Clusters Hierárquicos podem ser divididos em duas abordagens mais comuns: aglomerativa e divisiva.

Yim *et al.*, 2015 descrevem que a abordagem aglomerativa separa cada caso em seu Cluster individual, então o número inicial de Clusters é igual ao número total de objetos e os casos similares vão sendo agrupados em um único conjunto. Por outro lado, os mesmos autores definem a abordagem divisiva como o inverso da aglomerativa. Na abordagem divisiva, cada objeto começa em um grande Cluster e vai sendo separado em grupos até que cada objeto possua seu grupo individual (Ben-Arieh *et al.*, 2012), porém, por ser uma técnica que utiliza muita carga computacional, é pouco utilizada (Yim *et al.*, 2015).

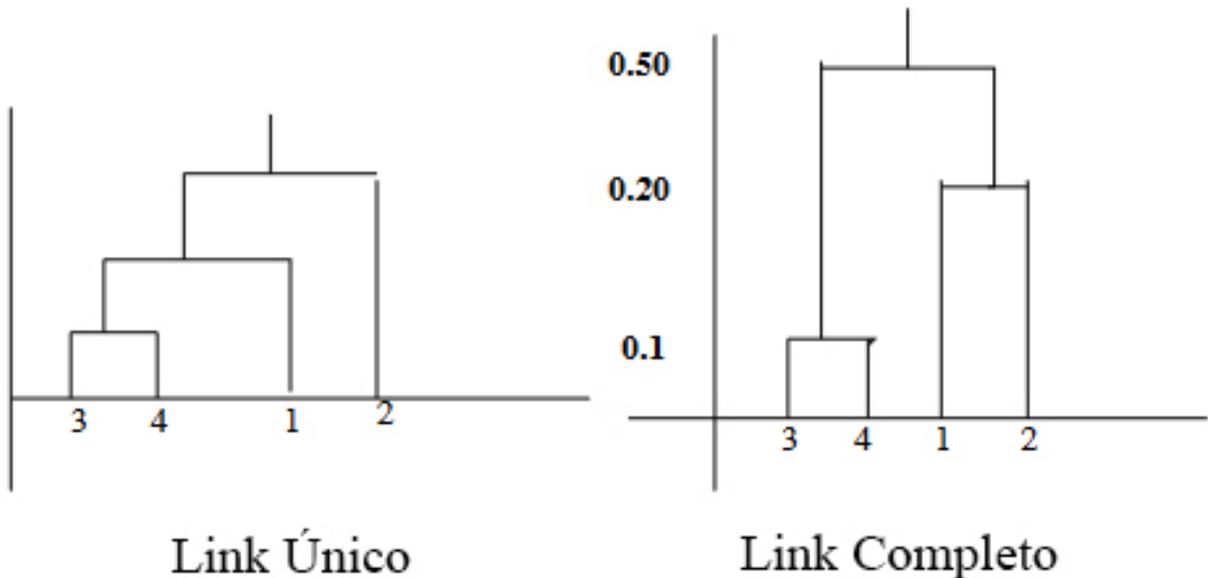
De acordo com Köhn *et al.*, 2014, a abordagem aglomerativa é descrita por alguns métodos. Entre os principais, os autores destacam os métodos de Link Único, Link Completo e o Método de Ward.

Yim *et al.*, 2015 descrevem que, na abordagem de link único, a distância entre dois clusters é a distância mínima encontrada entre um objeto do primeiro cluster e um objeto do segundo. Ainda de acordo com os autores, esse método possui um problema que pode gerar efeitos desastrosos, pois devido ao fato de utilizar a menor distância entre objetos, pode ocorrer o agrupamento de vários Clusters que não são similares.

Da mesma forma, Yim *et al.*, 2015 também discutem sobre o método do Link Completo. Segundo os autores, esse método, ao invés de buscar pela menor distância entre os

objetos, considera a maior distância entre eles. Apesar desse método resolver o problema de agrupamento de vários Clusters não similares, ele gera outro problema. Quando há muitos *outliers*, os Clusters podem não ser considerados próximos, apesar de serem. A Figura 2.5.1 mostra os dendrogramas das abordagens de Link Único e Completo.

Figura 2.5.1 – Exemplo de dendrogramas das abordagens de Link Único e Completo.



Fonte: Adaptado de Reddy *et al.*, 2013.

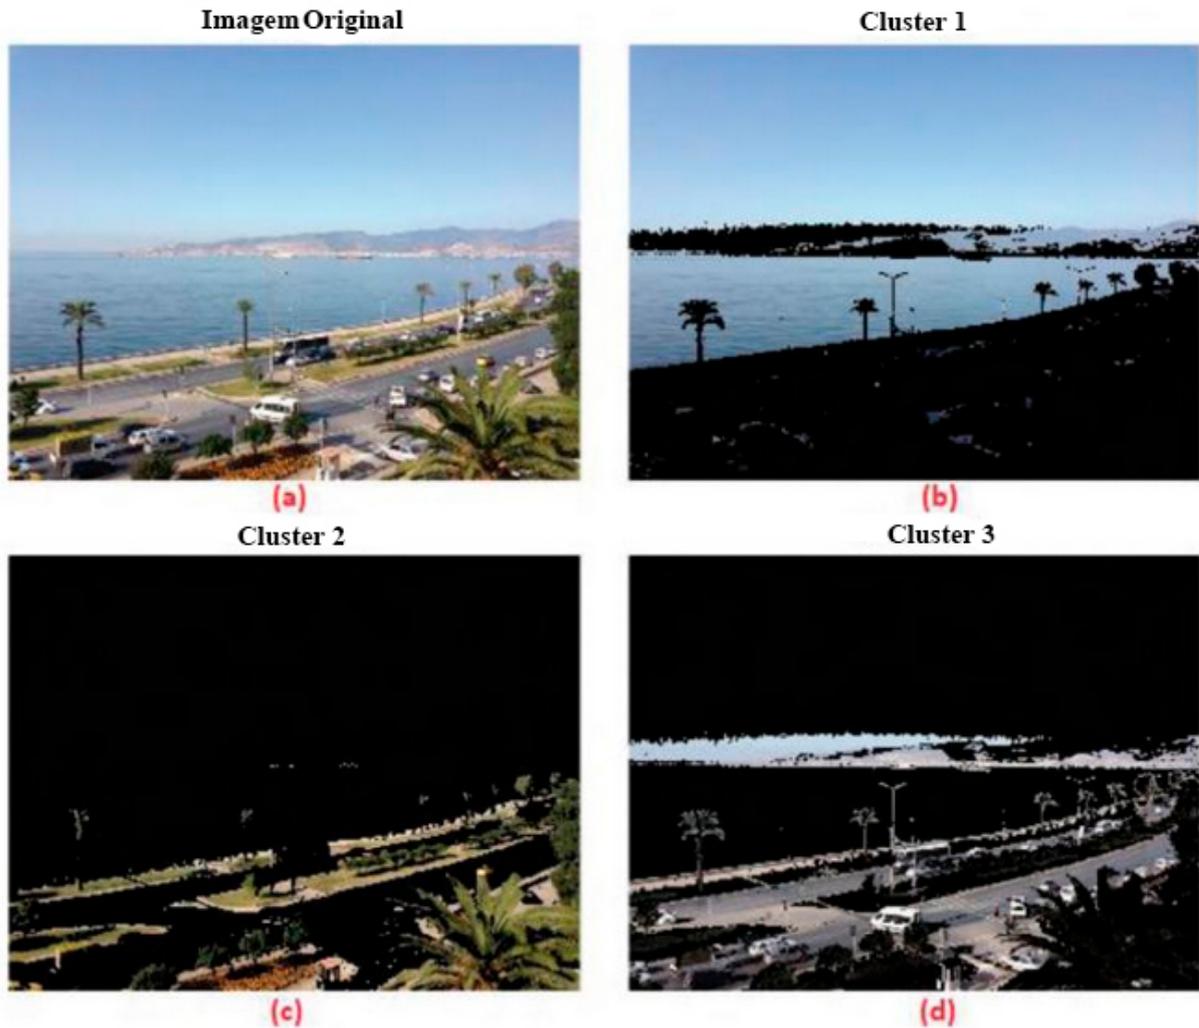
Por outro lado, o método de Ward trouxe uma inovação por resolver os dois problemas citados, pois nesse método não são utilizadas distâncias, os elementos são unidos em um mesmo Cluster de forma a minimizar a variância dentro dele.

## 2.5.2 Clusters Particionais

O conceito de Cluster Particional surgiu com o algoritmo *k-means*, ele divide os dados em grupos baseado em alguns critérios conhecidos, chamados de *fitness measure*, que afetam a formação dos Clusters. Uma vez que o *fitness measure* é escolhido, a tarefa se transforma em um problema de otimização (Nanda *et al.*, 2014).

De acordo com Zhu *et al.*, 2018, os Clusters Particionais são os tipos mais utilizados e o *k-means*, além de ser o primeiro, também é o mais popular devido à sua simplicidade e eficácia. O *k-means* buscam descobrir os grupos presentes nos dados ao otimizar uma função objetivo específica e, iterativamente, melhorar a qualidade das partições (Reddy *et al.*, 2013). A Figura 2.5.2 mostra um exemplo de Cluster Particional.

Baseado no algoritmo *k-means*, vários outros algoritmos foram criados como o algoritmo *k-means* genético (Krishna *et al.*, 1999), *k-means* genético rápido (Lu *et al.*, 2000), *k-medoids* e *k-medians* (Reddy *et al.*, 2013), porém esses algoritmos são baseados em um

Figura 2.5.2 – Exemplo de *K-means*.

Fonte: Adaptado de Kutbay *et al.*, 2018

número fixo de Clusters e funcionam melhor quando a quantidade de Clusters é previamente conhecido (Nanda *et al.*, 2014). Além disso, Paterlini *et al.*, 2006 escrevem que o *k-means* não consegue lidar bem com Clusters não esféricos, e os Clusters formados neste trabalho possuem formatos indefinidos.

### 2.5.3 Clusters Incrementais

Os Clusters incrementais vêm atraindo a atenção desde a criação do algoritmo de Hartigan (Simovici *et al.*, 2004). Nesse método, o primeiro objeto é atribuído a um Cluster, então o próximo objeto é atribuído a um Cluster existente ou a um novo, dependendo da semelhança entre o novo objeto e os já agrupados (Vijaya *et al.*, 2004).

Duas vantagens desse algoritmo são descritas por Vijaya *et al.*, 2004, os autores mostram que é necessário realizar uma única passagem por todos os elementos para utilizar o algoritmo e também citam que ele é bastante eficiente para grandes bases de dados, como

no caso deste trabalho. Porém ele é dependente de ordem, ou seja, ordens diferentes resultam em respostas diferentes (Vijaya *et al.*, 2004).

Jain *et al.*, 1999 também descrevem outra vantagem relacionada ao espaço de memória necessário para armazenar os resultados de um algoritmo incremental. Segundo os autores, por não ser necessário armazenar toda a matriz na memória, os requisitos de espaço para esses algoritmos são muito pequenos.

De acordo com Fisher, 1987, uma motivação para utilizar Clusters incrementais é que o conhecimento pode ser atualizado de forma constante, o que constitui uma base para reações a novos estímulos e torna o Cluster incremental uma alternativa para ser utilizado em sistemas do mundo real, que possuem restrições.

Entre outros exemplos de Clusters incrementais, podem ser citado o COBWEB (Fisher, 1987), IncrementalDBSCAN (Ester *et al.*, 1998), Shortest Spanning Path (SSP) (Jain *et al.*, 1999),  $C^2ICM$  (Can, 1993) e o algoritmo *Leader*, utilizado neste trabalho.

#### 2.5.4 Algoritmo *Leader*

O algoritmo *Leader* é um tipo de Cluster incremental (Vijaya *et al.*, 2004) que funciona selecionando um líder para o Cluster e utilizando distâncias Euclidianas para definir se um objeto faz parte do Cluster desse líder ou não (Srinivas *et al.*, 2010).

Este algoritmo é considerado de passagem única (itera apenas uma vez por todos os elementos) e, por isso, é considerado bastante eficiente em relação a outros algoritmos (Srinivas *et al.*, 2010). De acordo com Jain *et al.*, 1999, ele é um dos algoritmos mais simples em termos de complexidade, sendo apenas da ordem de  $kn$  ( $O(kn)$ ), onde  $k$  é a quantidade de líderes e  $n$  a quantidade total de objetos. Isso significa que a quantidade de iterações que ele realiza durante seu processo é de  $k*n$  e quando  $k=1$ , ele realiza apenas  $n$  iterações (Srinivas *et al.*, 2010). A Tabela 2.5.1 compara alguns tipos de Clusters mais comuns em termos de desempenho e espaço ocupado.

Tabela 2.5.1 – Comparações entre os tipos mais comuns de Clusters.

Algoritmo de Clusterização	Complexidade de Tempo	Complexidade de Espaço
Leader	$O(kn)$	$O(k)$
k-means	$O(nkl)$	$O(k)$
ISODATA	$O(nkl)$	$O(k)$
Menor Caminho	$O(n^2)$	$O(n)$
Link Único	$O(n^2 \log n)$	$O(n^2)$
Link Completo	$O(n^2 \log n)$	$O(n^2)$

Fonte: Adaptado de Jain *et al.*, 1999.

O Cluster *Leader* utiliza distâncias euclidianas para medir as distâncias entre os objetos e realizar os cálculos dos Clusters (Vijaya *et al.*, 2004). Porém, neste trabalho, as

distâncias serão calculadas utilizando a equação de Haversine 2.1. Isso se deve ao fato de que a ideia é expandir o estudo, inicialmente focado no estado de São Paulo, para o território nacional.

A equação de Haversine calcula a distância entre dois pontos na superfície de uma esfera a partir das suas latitudes e longitudes, utilizando também o raio da circunferência estudada, neste caso, o raio da Terra que é cerca de 6731km (Shen *et al.*, 2017).

$$\begin{aligned}
 a &= \sin^2\left(\frac{\phi_2 - \phi_1}{2}\right) + \cos(\phi_1)\cos(\phi_2)\sin^2\left(\frac{\psi_2 - \psi_1}{2}\right) \\
 c &= 2 \operatorname{atan}\left(\sqrt{\frac{a}{1-a}}\right) \\
 d &= R c
 \end{aligned} \tag{2.1}$$

Com  $\phi_1$  e  $\phi_2$  sendo a latitude dos pontos 1 e 2 respectivamente e  $\psi_1$  e  $\psi_2$  sendo a longitude dos pontos 1 e 2, respectivamente (Chopde *et al.*, 2013).

O que diferencia esse algoritmo de outros, como o k-means, é que, para o algoritmo *Leader*, não é necessário definir a quantidade de Clusters (Deng *et al.*, 2018). No caso do algoritmo *Leader*, é definido um limite de distância e um líder é selecionado. Todos os objetos que estiverem dentro do limite de distância são definidos como pertencentes ao Cluster (Srinivas *et al.*, 2010).

Porém, de acordo com Srinivas *et al.*, 2010, esse algoritmo possui algumas desvantagens como: o valor do limite deve ser bastante apropriado e a saída depende da ordem na qual os dados são apresentados. Neste trabalho, como o líder será sempre determinado previamente e o cluster será criado com base nesse líder, a segunda desvantagem pode ser mitigada. No algoritmo *Leader* tradicional, o primeiro objeto é considerado o líder. No entanto, neste trabalho, o líder será definido pela ordem dos pedidos de coleta recebidos. Isso significa que a ordem de entrada não pode ser variável, garantindo que a ordem de saída seja consistentemente determinada.

Apenas os Clusters não são capazes de auxiliar a solução dos problemas mostrados. Portanto é necessário a utilização de ferramentas de otimização capazes de definir, então, os veículos utilizados em cada um desses Clusters. A próxima seção fala sobre essas ferramentas.

## 2.6 Otimização Multiobjetivo

Modelos de otimização tentam expressar, em termos matemáticos, a solução de um problema da melhor maneira possível, seja maximizando lucros e eficiência ou minimizando perdas (Griva *et al.*, 2009). Existem dois tipos de otimização, a mono objetivo e a multiobjetivo. A primeira possui apenas uma função objetivo, enquanto a segunda possui múltiplas funções objetivos conflitantes entre si (Deb *et al.*, 2005).

A otimização multiobjetivo é um tópico de pesquisa importante não somente devido ao fato de que a maioria dos problemas reais são multiobjetivos, mas também porque ainda existem muitas questões nessa área (Coello Coello, 1999). Chiandussi *et al.*, 2012 definem a otimização multiobjetivo como sendo o problema de encontrar um vetor (ou tupla) de variáveis de decisão que satisfaça as restrições e otimiza uma função cujos elementos representam as funções objetivo, que normalmente se encontram em conflito umas com as outras.

A otimização multiobjetivo também é importante neste trabalho, pois ela permite trabalhar com vários objetivos de uma forma simples, como mostra Magnanini *et al.*, 2021. De acordo com os autores, a principal vantagem de se aplicar otimização multiobjetivo é poder determinar as melhores soluções enquanto considera parâmetros competitivos. Sem a otimização multiobjetivo, melhorar um aspecto de um sistema geralmente implica em sacrificar o desempenho de outro.

De acordo com Nedjah *et al.*, 2015, os objetivos são normalmente conflitantes e a melhora de um pode afetar o desempenho de outro. Além disso os autores dizem que é raro um conjunto de resultados otimizar todas as funções objetivo e normalmente existem vários resultados que oferecem o mesmo desempenho.

De acordo com Mokhtari *et al.*, 2017, existem três abordagens principais para lidar com problemas multiobjetivos: utilizar operadores para processar os objetivos de forma separada; otimização de Pareto, que tenta convergir as funções para uma Fronteira de Pareto; transformar um problema multiobjetivo em um problema mono objetivo.

Nedjah *et al.*, 2015 mostram que a primeira abordagem é simples de ser implementada, mas possui a limitação de, na maioria dos casos, não alcançar a Fronteira de Pareto global, apenas a local. Ainda de acordo com os autores a segunda abordagem utiliza métodos que convergem para a Fronteira de Pareto mais rapidamente. Já a última abordagem é a mais prática, porém realizar essa transformação de multi para mono objetivo não é simples. Essa transformação permite utilizar algoritmos mono objetivos mais simples e consolidados, como o Algoritmo Genético (AG), que será utilizado neste trabalho.

Além desse fato, como já descrito no capítulo 2.2, Singh, 2016 afirma que o AG é uma das principais metaheurísticas utilizadas para se trabalhar com LR, portanto serão utilizados neste trabalho dois Algoritmos Genéticos: um para solucionar o PCVM, cuja a resposta será utilizada para definir as rotas, e outro para encontrar a solução para o problema proposto neste trabalho.

A otimização multiobjetivo é utilizada para problemas de sistemas de distribuição sustentáveis e redes de GVCS (Jian *et al.*, 2019), porém não é utilizado em conjunto com GDs. Para Coello Coello, 1999, uma das maiores dificuldades na otimização multiobjetivo é determinar como será realizada a medição da qualidade da solução, e nesse aspecto os GDs podem ser uma alternativa promissora. Entre os trabalhos pesquisados, foi encontrado apenas um que utiliza Simulação a Eventos Discretos como Gêmeos Digitais e

otimização multiobjetivo. O artigo mostra a criação de um *framework* que une as três áreas e apresenta um estudo de caso em uma indústria de bebidas (Dehghanimohammadbadi *et al.*, 2021). Os autores utilizam o software Simio para criar o GD e a linguagem de programação Python para os algoritmos de otimização.

Além desse trabalho, foi encontrado outro que utiliza simulação, porém os autores não definem o tipo de simulação utilizado (Zhao *et al.*, 2022). No trabalho, é criado um GD para mapeamento de redes de satélites para melhoria da comunicação entre eles. Foi formulado um problema de otimização multiobjetivo e solucionado através de um algoritmo genético.

Apesar disso, existem outros trabalhos que utilizam otimização com GDs, porém todos trabalham com GDs criados em uma rede neural e, portanto, são bastante diferentes do trabalho apresentado aqui.

Entre esses artigos, é possível destacar alguns, como o trabalho de Akhlaghi *et al.*, 2020 que utiliza redes neurais e otimização evolucionária com o auxílio de algoritmos genéticos. Uma diferença entre o GD criado no trabalho de Akhlaghi *et al.*, 2020 e outros GDs, é que nele os GDs não monitoram apenas os dados do sistema, mas também dados externos a ele, como temperatura e umidade do ar.

Já o trabalho de Tariq *et al.*, 2022 cria um GD de uma chaminé solar utilizando modelos de regressão e redes neurais artificiais. Além disso, os autores incluem uma otimização multiobjetivo solucionada com a utilização de um algoritmo genético.

A otimização multiobjetivo em conjunto com GDs na Logística Reversa ainda não foi abordada na literatura, até onde é de conhecimento do autor, contudo, separadamente, a otimização já é utilizada para resolver problemas da LR. Alguns trabalhos encontrados na literatura se assemelham à utilização da otimização multiobjetivo nesse trabalho, porém todos envolvem apenas a simulação, e não os GDs.

Godichaud *et al.*, 2013 utilizam a simulação e a otimização multiobjetivo para determinar as melhores políticas de controle para uma GVCS com vários escalões.

O trabalho de Tosarkani *et al.*, 2020 tem como objetivo desenvolver uma abordagem probabilística para otimizar uma rede de LR. Nele, os autores consideram incertezas relacionadas aos custos fixos e variáveis, à quantidade da demanda e à quantidade e qualidade dos produtos retornados. Além da otimização, os autores utilizam a simulação de Monte Carlo para analisar o desempenho do modelo.

Moghaddam, 2015 desenvolveu um modelo multiobjetivo integrado com a simulação de Monte Carlo para identificar os fornecedores e encontrar a quantidade ótima de partes novas e remanufaturadas para se criar novos produtos na LR. As funções objetivo a serem otimizadas no trabalho são lucro, total de partes com defeito, total de partes entregues e riscos econômicos.

Costa-Salas *et al.*, 2017 utilizam técnicas de simulação discreta e otimização multiobjetivo para estudar a LR de pneus usados. Os autores utilizam um estudo de caso para

avaliar o modelo criado por eles e concluem que o processo de recuperação dos pneus é mais rentável e menos prejudicial ao meio ambiente.

O trabalho de Li *et al.*, 2019 possui um problema semelhante a este trabalho, porém é resolvido sem a utilização de GDs. Nele, os autores otimizam a seleção da localização de centros de processamento de resíduos, roteamento de veículos e as emissões de carbono na LR. Para solucionar o problema, os autores desenvolveram um algoritmo multiobjetivo baseado na Colônia de Formigas e utilizam a simulação para demonstrar a eficiência do modelo.

Entre os trabalhos encontrados nessa pesquisa, existem dois bastante parecidos que são os trabalhos de Lu *et al.*, 2008 e Lu *et al.*, 2008 que resolvem um mesmo problema de otimização que minimiza o custo e o impacto negativo da LR. Apesar do trabalho ser semelhante, são solucionados de formas relativamente diferentes, enquanto o primeiro utiliza um algoritmo de *Particle Swarm*, o segundo utiliza uma melhoria de um Algoritmo Genético combinando-o com o método de pesos aleatórios.

Por último, entre os trabalhos encontrados que utilizam otimização multiobjetivo com simulação, pode-se enfatizar o artigo de Wang *et al.*, 2019. Nele os autores resolvem problemas com peças de reposição na LR utilizando o algoritmo *Ant Lion* com simulações numéricas.

Através desses artigos, é possível notar que não há trabalho encontrado na literatura que envolva otimização multiobjetivo sendo aplicado em GDs para resolver problemas da LR. Portanto, isso também justifica o ineditismo do trabalho.

Como citado anteriormente, o AG será o método utilizado neste trabalho e, portanto, o próximo capítulo traz algumas definições sobre esse algoritmo e uma breve explicação sobre seu funcionamento.

## 2.7 Algoritmo Genético

Em 1859, Charles Darwin estabeleceu a teoria da seleção natural em seu livro *A Origem das Espécies* (The Origin of Species). Ela diz que, através das gerações, organismos evoluem com base no princípio da seleção natural ou na “sobrevivência do mais apto” (Sivanandam *et al.*, 2008). Os Algoritmos Genéticos, baseados nessa mesma ideia, são programas que imitam o processo de evolução biológica para resolver problemas (Mitchell, 1995).

Essa seleção garante que indivíduos que não possuem um bom desempenho tenham menos chance de sobreviver, ou seja, os mais fortes irão gerar descendentes que serão mais adaptados (Sivanandam *et al.*, 2008).

Em 1975, o cientista e professor John Holland apresentou o Algoritmo Genético (AG) como uma abstração da evolução biológica em seu livro *Adaptação em Sistemas Natural e Artificial* (*Adaptation in Natural and Artificial Systems*, (Holland, 1975) (Mitchell, 1995)).

Um algoritmo pode ser descrito como uma série de passos para resolver um problema (Sivanandam *et al.*, 2008). O AG criado por Holland é um método que utiliza a genética como um modelo para resolver problemas de otimização e busca (Sivanandam *et al.*, 2008).

O AG difere de outros algoritmos de otimização devido a alguns pontos (Sivanandam *et al.*, 2008):

- Outras técnicas de otimização buscam por um único ponto, enquanto o AG busca um conjunto de populações, ou seja, utiliza um conjunto de soluções ao invés de uma única. Isso aumenta as chances de encontrar um ótimo global e diminui as chances de chegar a um ponto estacionário;
- O AG utiliza funções de *fitness* para a avaliação das soluções, ao invés de utilizar derivadas. Isso significa que os AGs podem ser aplicados em qualquer problema de otimização contínua ou discreta.

Além disso, Lambora *et al.*, 2019 mostram outras vantagens de se utilizar AGs como: buscar encontrar as melhores soluções ao invés de uma única; possui uma resposta satisfatória que melhora com o tempo; funciona melhor em casos nos quais o espaço de busca é grande e com múltiplos parâmetros.

Ele consiste em mover uma população de cromossomos para uma nova população (Mitchell, 1995), cada uma dessas mudanças consiste em uma geração. Esses cromossomos podem ser qualquer dado e os mais simples e mais utilizados são sequências de bits (Lambora *et al.*, 2019) (que seriam como os genes, fazendo uma analogia à genética) (Forrest, 1996), que é o caso deste trabalho. Exemplos de cromossomos podem ser:

Cromossomo 1 1101100100110110

Cromossomo 2 1101111000011110

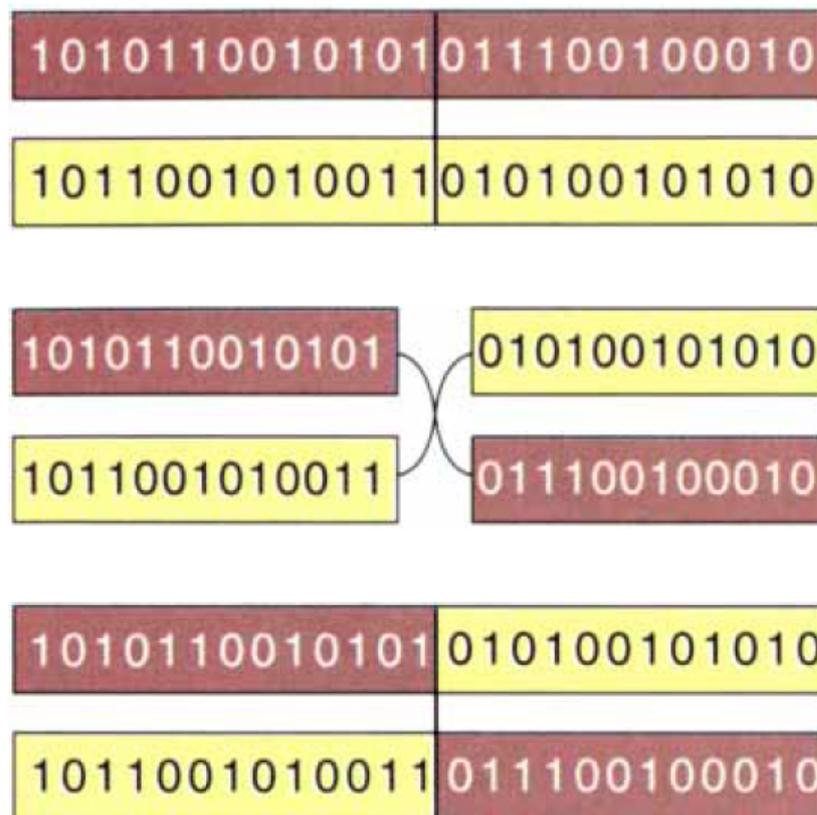
A população inicial é criada de forma completamente aleatória e, a cada execução do algoritmo, a população inicial é diferente. Isso garante uma ampla variedade de indivíduos, entre eles existem indivíduos melhores que outros e, inclusive, alguns que são inviáveis para resolver o problema. Porém, isso é necessário para que o AG possa, durante a execução, encontrar a melhor solução.

Em um primeiro momento, existem indivíduos excelentes e outros péssimos, conforme o AG é executado, os melhores indivíduos vão sendo selecionados e uma ordenação é realizada do melhor para o pior. Isso garante que após várias execuções, os melhores e mais viáveis indivíduos, estejam no topo da lista, sendo os escolhidos para resolver o problema.

O AG altera esses cromossomos utilizando alguns passos baseados na própria genética (Lambora *et al.*, 2019):

- Seleção - consiste em selecionar indivíduos que irão se reproduzir com base em suas aptidões (Sivanandam *et al.*, 2008), os melhores cromossomos são mais escolhidos para reproduzirem (Mitchell, 1995). Existem várias maneiras de selecionar os melhores indivíduos, porém, no caso deste trabalho, foi utilizada a ordenação de toda a população da melhor para a pior, e os melhores indivíduos reproduzem entre si;
- *Crossover* - serve para mesclar os genes dos pais, de modo a resultar em novos descendentes que podem ser melhores ou piores (Lambora *et al.*, 2019). A forma mais simples de realizar esse cruzamento, que também é a forma utilizada neste trabalho, é selecionar um ponto aleatório dentro do cromossomo e realizar uma troca entre os dois pais, resultando em dois descendentes que possuem as características de ambos os pais (Lambora *et al.*, 2019), como mostrado na Figura 2.7.1;

Figura 2.7.1 – Exemplo de *Crossover*.



Fonte: Holland, 1992

- Mutação - realiza uma troca de alguns bits em um cromossomo, porém, diferente do *Crossover*, possui uma probabilidade muito pequena de ocorrer (Mitchell, 1995). Em um cromossomo binário, a mutação escolhe aleatoriamente alguns bits que serão alterados de 0 para 1 ou de 1 para 0 (Lambora *et al.*, 2019). Por exemplo, o cromossomo `00010001000` poderia ter um bit alterado e resultar no cromossomo `00110001000`;

- Avaliação - as aptidões dos indivíduos são avaliadas para definir os melhores, que serão utilizados para gerar os melhores descendentes (Sivanandam *et al.*, 2008);

Além desses passos, um algoritmo genético também deve receber como entrada alguns parâmetros importantes como a probabilidade de se realizar um *crossover* e a probabilidade de se realizar uma mutação (Lambora *et al.*, 2019). O primeiro serve para indicar a frequência com que um *Crossover* ocorre e o segundo define a quantidade de mutações que irão ocorrer no algoritmo.

O maior desafio do AG consiste em calcular a aptidão de cada indivíduo, para isso, é utilizada uma função de *fitness* (Islam *et al.*, 2014). Ainda de acordo com Islam *et al.*, 2014, o valor da função de *fitness* deve aumentar a cada geração, fazendo com que os filhos sejam melhores que os pais. Cada cromossomo possui um valor associado a ele, que é a sua aptidão, e que indica quão boa é a solução em questão (Sivanandam *et al.*, 2008).

De acordo com Sivanandam *et al.*, 2008 os AGs lidam com problemas de maximização dessas funções de *fitness*. No entanto, caso seja necessário minimizar a função, a adaptação é simples: ou inverte-se a função ou a ordenação da população é realizada em ordem crescente, do menos apto para o mais apto.

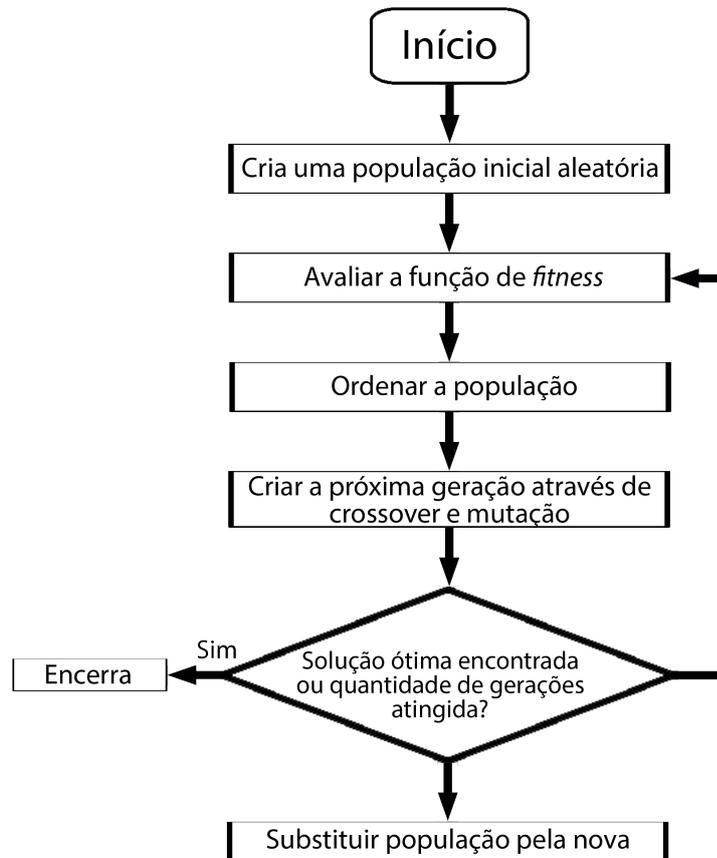
Mitchell, 1995 descreve um pseudocódigo que generaliza a criação de um GA:

1. Crie uma população aleatória que contém N cromossomos, que serão as possíveis soluções do problema;
2. Calcula a função de *fitness*  $F(x)$  para cada cromossomo  $x$  pertencente à população;
3. Repete os itens de (a) a (c) até que sejam gerados N novos descendentes:
  - a. Ordena a população de cromossomos e utilize pares de pais para criar novos filhos;
  - b. Utiliza uma probabilidade para definir se um *crossover* ocorrerá ou não. Caso ocorra, trocam-se os genes dos pais a partir de um ponto de *crossover*, caso não ocorra, os filhos serão exatamente iguais aos pais;
  - c. Realiza a mutação nos filhos, essa mutação possui uma probabilidade muito baixa de ocorrer. Então os filhos são inseridos em uma nova população;
4. Troca a população original pela nova população criada;
5. Repete os passos a partir de (2);

A Figura 2.7.2 mostra um fluxograma sobre os passos para se criar um AG.

Os Clusters e a Otimização são as ferramentas necessárias para a realização deste trabalho, porém, o foco do mesmo é a utilização de GDs para auxiliar na resolução de problemas da LR. Portanto, de forma a demonstrar que não existem artigos que envolvem

Figura 2.7.2 – Passos para se criar um AG.



Fonte: Adaptado de Sivanandam *et al.*, 2008

os GDs com a LR, foi realizada uma Revisão Sistemática da Literatura capaz de mostrar tanto o estado da arte dos assuntos, quanto as possíveis lacunas a serem preenchidas nesses temas.

## 2.8 Revisão Sistemática da Literatura (RSL)

Webster *et al.*, 2002 descrevem a revisão da literatura como sendo um processo importante em qualquer trabalho acadêmico. Os autores ainda pontuam algumas características necessárias para uma revisão sistemática ideal: motivar o tópico de pesquisa; descrever os conceitos chave; desenvolver um modelo para futuras pesquisas; mostrar a literatura relevante anteriormente publicada; delinear os limites da pesquisa; justificar propostas mostrando explicações teóricas e exemplos práticos.

Dessa forma, para verificar o estado da arte do assunto e também a fim de demonstrar que não existem pesquisas que relacionam Gêmeos Digitais à Logística Reversa, foi realizada uma Revisão Sistemática da Literatura. Ela aborda a literatura utilizando algumas etapas e, para este trabalho, serão utilizadas 4 etapas, como descrito em Oliveira *et al.*, 2016: planejamento, pesquisa, análise e apresentação.

A primeira etapa, o Planejamento, é importante pois permite definir o protocolo de pesquisa, quais as perguntas serão respondidas e como a pesquisa será realizada. A segunda etapa é a etapa de realização da pesquisa. A etapa de análise serve para analisar os resultados e por fim, a última etapa mostra os resultados encontrados (Oliveira *et al.*, 2016). A RSL é apresentada nas próximas seções.

### 2.8.1 Planejamento

O primeiro passo para se realizar essa RSL foi a busca por pesquisas sobre Gêmeos Digitais (GDs) e Logística Reversa (LR), de forma separada, a fim de identificar palavras-chave mais utilizadas nos dois contextos.

Os GDs são uma área relativamente nova mas as pesquisas relacionada à esse tema vêm crescendo desde 2016 (Dittrich *et al.*, 2020). Os GDs podem cobrir um ciclo de vida completo de um processo ou produto, desde o design até as operações, incluindo o processo contínuo de desenvolvimento em toda a cadeia (Detzner *et al.*, 2018).

Outra área que vem sendo o foco de vários estudos é a sustentabilidade, incluindo temas como Cadeia Verde de Suprimentos (*Green Supply Chain*), Circuito Fechado da Cadeia de Suprimentos (CFCS) (*Closed Loop Supply Chain*) e Economia Circular (*Circular Economy*) (Zou *et al.*, 2018). De acordo com Zou *et al.*, 2018, isso se deve ao fato de que a reciclagem de produtos utilizados vêm crescendo, auxiliando empresas a reduzir custos e aumentar seus lucros, além de reduzir a emissão de gases poluentes e aumentar a proteção ambiental. Para realizar a coleta e remanufatura desses produtos existe a GVCS e, como uma subárea dela, a LR é responsável pela primeira parte, que é a coleta.

De acordo com Riedelsheimer *et al.*, 2020, a discussão sobre sustentabilidade combinada com GDs ainda não foi investigada na literatura, portanto este trabalho busca unir essas duas áreas em uma Revisão Sistemática da Literatura para que seja possível descobrir quais trabalhos tem sido realizados utilizando essas duas técnicas em conjunto ou separadamente e responder algumas Questões de Pesquisa (QP) como:

- Quais são as principais diferenças entre Simulação e Gêmeos Digitais?
- A simulação é utilizada na Gestão Verde da Cadeia de Suprimentos?
- Quais são as características necessárias para se ter um GD?
- O GD é uma tecnologia que vem sendo utilizada em conjunto com a Logística Reversa?
- Quais são os softwares mais utilizados para a criação de GDs?

## 2.8.2 Pesquisa

Esta seção tem como objetivo definir a busca e os critérios de exclusão para os artigos que compõem este trabalho, mostrando o número total de artigos encontrados e quantos permaneceram, para leitura, após as exclusões.

A elaboração deste trabalho é baseada em duas bases de dados que são conhecidas por serem as mais completas e mais utilizadas em revisões, Scopus e Web Of Science (Aghaei Chadegani *et al.*, 2013). Somado a isso, os dados das duas bases são facilmente interpretados pelo software RStudio, que será utilizado para realizar algumas análises neste trabalho. Outra justificativa para utilizar apenas essas duas bases é citada por Mongeon *et al.*, 2016, os autores mostram que ambas as bases são as mais utilizadas para a realização de análises e revisões.

Este trabalho não aplica nenhum filtro relacionado ao ano da publicação do artigo, visto que os estudos sobre GD são relativamente novos e pouco aplicados à economia circular e LR, além disso, existem poucos artigos publicados antes de 2015 na área.

Para realizar a coleta de dados nas bases mencionadas, apenas resultados com acesso livre (*open access*) e em Inglês foram utilizados, visto que essa é a principal linguagem de trabalhos escritos pela comunidade científica mundial. Alguns filtros como “apenas artigos sobre Engenharia, Ciências da Computação e Matemática” foram aplicados para auxiliar a restringir os resultados.

Primeiramente, uma busca foi realizada utilizando apenas algumas palavras-chave como: “*green supply chain management*”, “*reverse logistics*”, “*circular economy*” e “*digital twins*”. A pesquisa resultou em poucos artigos, sendo encontrados apenas 18 na base de dados Scopus e 4 na Web of Science. Devido à falta de documentos, a palavra “*simulation*” também foi incluída na pesquisa. Essas palavras-chave então compuseram a busca utilizando, também, alguns conectores lógicos como AND e OR:

*(“green supply chain management” or “reverse logistics” or “circular economy”) and (“digital twins” or “simulation”);*

Com essa busca, os resultados foram melhores, 665 artigos foram encontrados na base de dados Scopus e 555 na Web of Science.

Esses dados foram inseridos no software RStudio para uma análise preliminar da nuvem de palavras e então outras palavras amplamente utilizadas em trabalhos nas áreas que compõem o centro deste trabalho foram encontradas, como “*recycling*”, “*life cycle*”, “*sustainable development*” e “*computer simulation*”. Após esses novos resultados, outra busca foi realizada nas bases de dados utilizando todas as palavras encontradas, criando outra chave de busca, mostrada a seguir:

*(“sustainable development” or “life cycle” or “recycling” or “green supply chain management” or “reverse logistics” or “circular economy”) and (“digital twins” or “simulation” or “computer simulation”)*

Nessa nova busca, um grande número de trabalhos foram encontrados:

- 6834 artigos foram encontrados na Scopus;
- 1948 artigos foram encontrados na Web of Science.

Buscando realizar a avaliação dos trabalhos relevantes, primeiramente o título de todos os artigos foram lidos e vários artigos que se tratavam, por exemplo, de turbinas ou hidrologia e que não possuíam relação direta com o assunto principal deste trabalho, foram removidos nessa etapa.

Do restante, cerca de 600 artigos, foram lidos os resumos e palavras-chave, seguindo alguns critérios, e os trabalhos que não possuísem pelo menos um dos critérios a seguir foram eliminados nessa etapa preliminar. Os critérios são:

- Trabalhos que contém GD utilizado em GVCS;
- Trabalhos relacionados aos GDs e os processos para criá-los;
- Trabalhos que contém técnicas e algoritmos utilizados para a criação de GDs;
- Trabalhos que incluem GDs, simulação, economia circular e logística reversa.

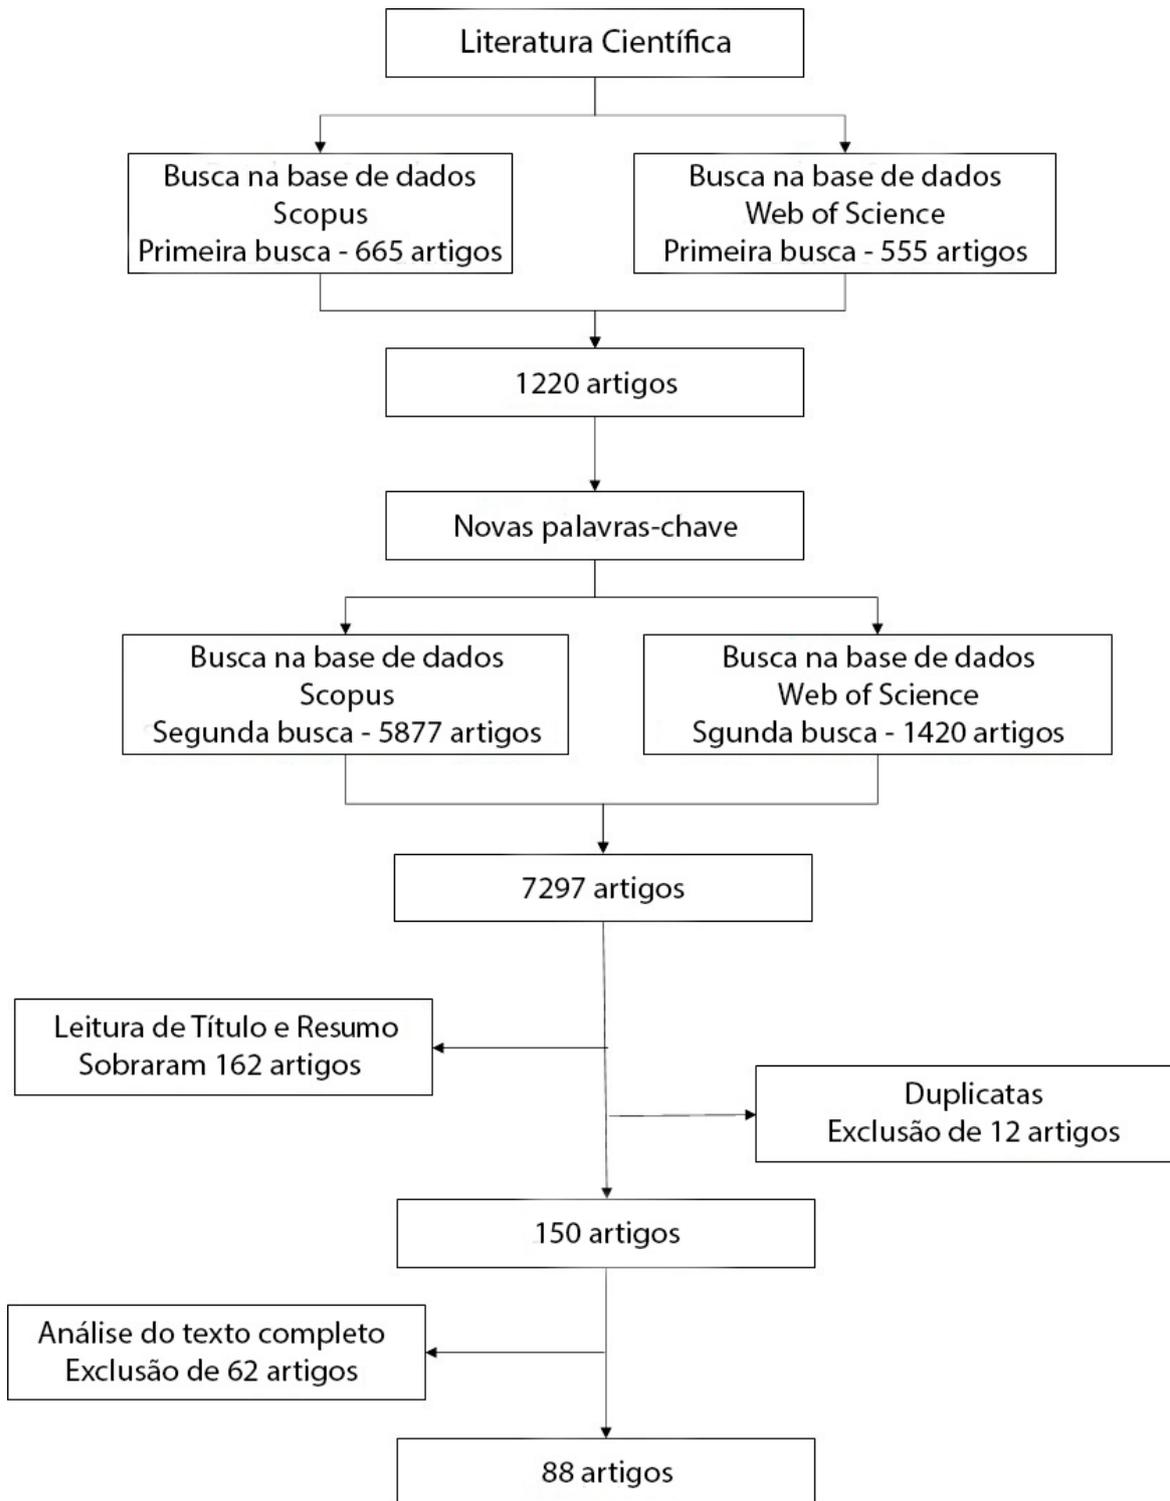
Após a leitura dos títulos e resumos, foi verificado que alguns artigos estavam duplicados nas duas bases, resultando na exclusão de um deles.

Após a eliminação das duplicatas, além daqueles que não se enquadraram nos critérios do estudo, restou uma pequena porção dos artigos: 132 artigos restaram da base de dados Scopus e apenas 18 da busca na Web of Science. Alguns trabalhos pareciam ser relevantes quando o resumo foi lido, porém, após a leitura integral dos mesmos, foram descartados por não serem úteis. Após a análise cuidadosa de todos os trabalhos relevantes, entre todos os selecionados restaram apenas:

- 78 artigos da base de dados Scopus;
- 10 artigos da base de dados Web of Science;

Portanto, da busca inicial que possuía mais de 7000 artigos, apenas 88 se mostraram relevantes para o tema proposto e a Figura 2.8.1 mostra um resumo da pesquisa realizada para esse trabalho.

Figura 2.8.1 – Resumo da pesquisa feita para este trabalho.



### 2.8.3 Análise e Apresentação

Essa seção mostra os resultados encontrados através da análise dos artigos que auxiliam a responder as questões propostas na seção 2.8.1.

### 2.8.3.1 QP1 - Quais são as principais diferenças entre simulação e GDs?

Existem algumas diferenças entre a simulação e os GDs, mas antes de mostrá-las, é necessário entender o que é uma simulação e o que é um GD. De acordo com Puryani *et al.*, 2018, a simulação é um modelo computacional que imita um sistema para auxiliar a avaliação e melhorar seu desempenho. Por outro lado, o GD é uma réplica virtual de um sistema que troca informações com o sistema real. Embora seja possível utilizar a simulação como uma parte do GD, (Kuehn, 2018), Schleich *et al.*, 2017 descrevem que um GD não é um modelo completo mas um conjunto de processos, dados e modelos de simulação, contribuindo para defender que o GD pode ser composto por um modelo de simulação.

Outra diferença entre as duas técnicas, além do fato da simulação ser um componente do GD, é que ambos auxiliam a tomada de decisão mas apenas o GD é uma ferramenta de otimização em tempo real de acordo com Gu *et al.*, 2021. A simulação, por outro lado, é capaz de mostrar as possibilidades para que o tomador de decisão possa escolher qual aparenta ser a melhor opção (Puryani *et al.*, 2018). Apesar de ambas as ferramentas poderem ser utilizadas como otimizadores, apenas o GD pode realizar esse processo em tempo real e trocar informações com o sistema real, podendo ter autonomia para controlar o sistema real.

O que cria essa distinção é o fato de que o GD utiliza Inteligência Artificial (IA) e também possui uma troca de dados contínua entre os modelos que pode ser feita de forma automática, enquanto a simulação não possui essas características (Barricelli *et al.*, 2019). Zhang *et al.*, 2019 defendem que uma das diferenças entre um GD e um modelo digital é que o segundo não possui um fluxo de dados automático entre os modelos virtuais e físicos.

Kuehn, 2018 disserta que o uso da simulação pelos GDs permite operar todo o processo ou parte dele e testar várias alternativas em um ambiente virtual antes da decisão ser aplicada no sistema real. O autor também escreve que, com a IA, os GDs podem abordar questões específicas sobre os modelos de simulação da produção, produto ou logística, permitindo o teste de vários cenários diferentes.

Somado a isso, Kuehn, 2018 mostra quais são as vantagens de se utilizar GD com simulação e GD com Inteligência Artificial. O autor descreve que, ao se utilizar a simulação, o GD é capaz de testar algumas alternativas fora do mundo real antes dessas alternativas serem aplicadas, evitando problemas. Por outro lado, ao se utilizar GD com IA, é possível criar modelos avançados.

Em conclusão, como definido por Schleich *et al.*, 2017 em seu trabalho, O GD é a próxima geração da modelagem, simulação e otimização, o que significa que um GD é capaz de unir todas essas ferramentas em uma única. Essa ferramenta é capaz de trocar informações entre elas e auxiliar o processo de tomada de decisão.

### 2.8.3.2 QP2 - A Simulação é utilizada na Gestão Verde da Cadeia de Suprimentos (GVCS)?

Braun *et al.*, 2018 descrevem que a LR e a GVCS são ideias pouco exploradas na literatura, o que reflete, também, em sua baixa utilização em conjunto com a simulação. Isso é assegurado por essa Revisão que mostra que de 88 artigos lidos, apenas 9 usam a simulação no contexto da LR.

A Tabela 2.8.1 mostra os artigos que utilizam simulação e LR ou GVCS apontando os autores, títulos e um breve resumo sobre eles.

Tabela 2.8.1 – Artigos que abordam Simulação e Logística Reversa.

<b>Autores</b>	<b>Título</b>	<b>Resumo</b>
Braun <i>et al.</i> , 2018	Case study analyzing potentials to improve material efficiency in manufacturing supply chains, considering circular economy aspects	Checa a eficiência do material de uma amostra ao longo da sua cadeia de suprimentos e avalia a recuperação de resíduos. Utiliza simulação para determinar a eficiência do material
Matskul <i>et al.</i> , 2021	Optimization of the cold supply chain logistics network with an environmental dimension	Cria um modelo matemático que auxilia a logística de caminhões refrigerados. Utiliza simulação para calcular os custos dos transportes e as rotas pela perspectiva ambiental
Umeda, 2013	Simulation analysis of supply chain systems with reverse logistics	O artigo propõe metodologias de modelos de simulação na Cadeia de Suprimentos na LR
Golda <i>et al.</i> , 2016	The application of virtual reality systems as a support of digital manufacturing and logistics	O artigo mostra métodos para criar aplicações com realidade virtual de forma a modelar e simular processos logísticos. Cria simulações para logística e mostra exemplos.
Straka <i>et al.</i> , 2019	Environmental assessment of waste total recycling based on principles of logistics and computer simulation design	Usa logística, modelagem e simulação para tentar separar resíduos para que materiais crus e outros recursos possam ser utilizados.
Rocca <i>et al.</i> , 2020	Integrating Virtual Reality and Digital Twin in Circular Economy Practices: Laboratory Application Case	Introduz uma aplicação em laboratório que demonstra como tecnologias baseadas na indústria 4.0 podem auxiliar a Economia Circular e testar a configuração da planta de desmonte de resíduos eletrônicos usando ferramentas de simulação.
Moreno <i>et al.</i> , 2019	Opportunities for redistributed manufacturing and digital intelligence as enablers of a circular economy	Esse artigo mostra se a Simulação a Eventos Discretos pode ser utilizada em cenários circulares para determinar os valores econômicos tradicionais. No estudo, a simulação também avalia o efeito da EC (Economia Circular) em uma cadeia de suprimentos.

Autores	Título	Resumo
Pandian <i>et al.</i> , 2017	Performance evaluation of reverse logistics enterprise: an agent-based simulation approach	Mede o desempenho da LR utilizando um modelo de simulação baseado em agentes. Os agentes (coletores, remanufaturadores, recicladores, etc) agem independentemente.
Tako <i>et al.</i> , 2012	The application of discrete event simulation and system dynamics in the logistics and supply chain context	Uma revisão da Simulação a Eventos Discretos e Sistemas Dinâmicos para encontrar qual o mais utilizado para Logística e Gestão da Cadeia de Suprimentos. Mostra que de 127 artigos lidos, apenas 7 abordam LR.
Gonçalves <i>et al.</i> , 2019	Discrete Event Simulation as a Decision-Making Tool For End-of-Life Tire Reverse Logistics in a Brazilian City Consortium	Propõe novas alternativas para que cidades pequenas possam planejar e implementar a LR para pneus sem uso.

### 2.8.3.3 QP3 - Quais características são necessárias para se ter um GD?

A subseção 2.8.3.1 mostrou que a simulação e o GD são dois assuntos diferentes e essa subseção mostra quais as principais características que um GD deve ter.

Uma característica que o GD precisa ter é o compartilhamento de local, isso significa que várias pessoas podem acessar o mesmo modelo de GD a partir de diferentes localidades ao mesmo tempo (Avventuroso *et al.*, 2017).

Somado a isso, Moyne *et al.*, 2020 descrevem que todas as definições de GD possuem algumas propriedades como: ser uma réplica de um ativo real; positivamente impactar o ambiente onde o ativo físico se encontra; utilizar dados para manter a sincronização com o ativo real.

Martínez *et al.*, 2018 e Chen *et al.*, 2020 também descrevem algumas características que são necessárias para se ter um GD. Os autores defendem que ele é uma réplica em tempo-real de um modelo físico e que ele precisa ser integrado com o sistema real e trocar dados atuais e históricos que possam ser utilizados para otimizar várias atividades. Embora a primeira característica não seja obrigatória, como descrito por Malik *et al.*, 2018, é desejável que um GD possa realizar suas tarefas em tempo real, apesar de nem sempre ser possível. De acordo com Barricelli *et al.*, 2019, as atualizações em tempo real entre os modelos físicos e virtuais permitem que o GD possa ficar ciente do que está acontecendo com o seu gêmeo físico.

Uma das principais características dos GDs, de acordo com Samir *et al.*, 2019, é que um GD possui controle crítico do processo, o que o difere de modelos de monitoramento.

O GD é um mapeamento dinâmico que depende de sensores instalados no modelo físico e, ao mesmo tempo, o GD retroalimenta o mundo físico com dados, o que permite que esse mude seus estados (Chen *et al.*, 2020). Essa troca bilateral de informações é uma das principais particularidades de um GD.

Embora os GDs estejam fortemente relacionados com a simulação, ela não é o único recurso que possibilita um GD. De acordo com Tekinerdogan *et al.*, 2020 e Broo *et al.*, 2021, existem quatro tecnologias que podem ser inseridas no modelo para torná-lo um GD: internet das coisas, inteligência artificial, aprendizado de máquina e ciência dos dados. Essas ferramentas ajudam o GD a continuamente aprender e atualizar a si mesmo e ao mundo físico, utilizando dados coletados dos sensores, por exemplo.

Em resumo, o que diferencia a simulação de um GD é que o GD possui a capacidade de trocar dados com o sistema real e a autonomia para que o primeiro possa controlar o segundo quando necessário. Apesar de ser um diferencial importante, outras tecnologias como IA e Aprendizado de Máquina não são cruciais para um GD.

#### 2.8.3.4 QP4 - GD é uma tecnologia que vem sendo utilizada em conjunto com a Logística Reversa?

Uma leitura realizada nos 88 artigos que compuseram essa revisão revelou que nenhum estudo relaciona GD com LR. De forma a comprovar essa afirmação todos os estudos foram avaliados e a Tabela 2.8.2 mostra todos os artigos utilizados nessa revisão e os temas que eles abordam.

Vale notar que nem sempre é necessário utilizar simulação para se ter um GD, alguns trabalhos como Anagnostopoulos *et al.*, 2015, Chen *et al.*, 2020 e Garrido *et al.*, 2019 utilizam as duas ferramentas em conjunto em seus trabalhos, proporcionando maior robustez. Porém, alguns trabalhos como Barricelli *et al.*, 2019, Cannella *et al.*, 2016 e Dev *et al.*, 2020 utilizam apenas um dos dois recursos, demonstrando que o GD pode ser utilizado para auxiliar a simulação, mas não é algo obrigatório.

Também se pode concluir que a simulação é pouco utilizada na GVCS, de acordo com os artigos avaliados na revisão, apenas três deles trabalham com a simulação. Além disso, essa ferramenta é utilizada em sete artigos. Isso permite concluir que, como a simulação é pouco utilizada na LR, o GD com a utilização de simulação é ainda menos utilizado.

Por outro lado, a simulação e os GDs são duas ferramentas bastante comuns de serem utilizadas em conjunto. Dentro os artigos utilizados nesta RSL, onze deles trabalham as duas ao mesmo tempo. Porém, entre 42 trabalhos sobre GDs, apenas esses onze trabalham também com simulação, demonstrando, mais uma vez, que não é necessário que haja a simulação para haver um GD.

É possível perceber, por fim, que nenhum artigo combina GD com LR no mesmo trabalho. O único que se assemelha à esse tema é o trabalho de Wang *et al.*, 2019, porém os

autores focam em manufatura e remanufatura em uma GVCS, mas não abordam a fase da coleta.

Tabela 2.8.2 – Artigos utilizados para a Revisão Sistemática e as abordagens contidas neles.

Citação	Software	Sim	GD	LR	M	GVCS	EC	TD
(Anagnostopoulos <i>et al.</i> , 2015)	-	X	X	-	-	-	-	-
(Avventuroso <i>et al.</i> , 2017)	-	-	-	-	X	-	-	X
(Balci, 2011)	-	X	-	-	-	-	-	-
(Bamberg <i>et al.</i> , 2021)	-	-	X	-	-	-	-	-
(Barricelli <i>et al.</i> , 2019)	-	-	X	-	-	-	-	-
(Barth <i>et al.</i> , 2020)	-	-	X	-	-	-	-	-
(Beloglazov <i>et al.</i> , 2020)	DYNSIM	X	X	-	-	-	-	-
(Botkina <i>et al.</i> , 2018)	ToolMaker	-	X	-	-	-	-	-
(Braun <i>et al.</i> , 2018)	R	X	-	-	-	-	X	-
(Braun <i>et al.</i> , 2020)	-	-	X	-	X	-	-	-
(Broo <i>et al.</i> , 2021)	-	-	X	-	X	-	-	X
(Cannella <i>et al.</i> , 2016)	-	X	-	X	-	X	X	-
(Charnley <i>et al.</i> , 2019)	AnyLogic	X	-	-	X	-	X	X
(Chen <i>et al.</i> , 2020)	-	X	X	-	-	-	-	-
(Chiang <i>et al.</i> , 2014)	-	X	-	X	-	-	-	-
(Czwick <i>et al.</i> , 2020)	-	X	X	-	X	-	-	-
(Detzner <i>et al.</i> , 2018)	-	-	X	-	X	-	-	-
(Dev <i>et al.</i> , 2020)	-	X	-	X	-	-	X	-
(Dittrich <i>et al.</i> , 2020)	-	-	X	-	-	-	-	-
(Eldabi <i>et al.</i> , 2019)	-	X	-	-	-	-	-	-
(Elia <i>et al.</i> , 2016)	AnyLogic	X	-	-	-	-	-	-
(Erkoyuncu <i>et al.</i> , 2020)	-	-	X	-	-	-	-	-
(Fakhimi <i>et al.</i> , 2013)	-	X	-	-	-	-	-	-
(Garrido <i>et al.</i> , 2019)	Flexsim e Plant Simulator	X	X	-	X	-	-	-
(Ghita <i>et al.</i> , 2020)	SIMIT	-	X	-	X	-	-	-
(Golda <i>et al.</i> , 2016)	Enterprise Dynamics, Flexsim, Roboguide e Process Simulate	X	-	-	X	X	-	-
(Gonçalves <i>et al.</i> , 2019)	ProModel	X	-	X	-	-	-	-

Citação	Software	Sim	GD	LR	M	GVCS	EC	TD
(Gopalakrishnan <i>et al.</i> , 2020)	Siemens NX 11.0 CAD	-	X	-	X	-	-	-
(Gu <i>et al.</i> , 2021)	-	-	X	-	-	-	-	-
(Han <i>et al.</i> , 2020)	-	-	X	-	-	-	-	-
(Jones <i>et al.</i> , 2019)	-	-	X	-	X	-	-	-
(Jones <i>et al.</i> , 2020)	-	-	X	-	-	-	-	-
(Kaewunruen <i>et al.</i> , 2021)	Revit2018	-	X	-	-	-	-	-
(Kalaboukas <i>et al.</i> , 2021)	-	-	X	-	-	-	X	-
(Kapustina <i>et al.</i> , 2020)	-	-	X	-	-	-	-	-
(Khajavi <i>et al.</i> , 2019)	-	-	X	-	-	-	-	-
(Kim <i>et al.</i> , 2020)	-	-	X	-	-	-	-	-
(Kuehn, 2018)	-	-	X	-	-	X	X	X
(La Russa <i>et al.</i> , 2020)	-	-	X	-	-	-	-	-
(Lee <i>et al.</i> , 2019)	ProModel	X	-	-	-	-	-	-
(Li <i>et al.</i> , 2020)	-	-	X	-	X	-	-	-
(Liu <i>et al.</i> , 2019)	-	X	-	-	X	-	-	-
(Lv <i>et al.</i> , 2021)	-	X	X	-	-	-	-	-
(Ma <i>et al.</i> , 2019)	-	-	X	-	-	-	-	-
(Malik <i>et al.</i> , 2018)	-	X	X	-	X	-	-	-
(Martínez <i>et al.</i> , 2018)	-	X	X	-	-	-	-	-
(Matskul <i>et al.</i> , 2021)	Excel	X	-	-	-	-	-	-
(Moi <i>et al.</i> , 2020)	Fedem	-	X	-	-	-	-	-
(Moreno <i>et al.</i> , 2019)	-	X	-	-	X	-	X	-
(Moyne <i>et al.</i> , 2020)	-	-	X	-	-	-	-	-
(Okita <i>et al.</i> , 2019)	-	-	X	-	-	-	-	-
(Page <i>et al.</i> , 2010)	Umberto e Material Flow Simulator	X	-	-	-	-	-	-
(Pandian <i>et al.</i> , 2017)	-	X	-	X	X	-	-	-
(Ponomarev <i>et al.</i> , 2017)	-	-	X	-	X	-	-	-
(Puryani <i>et al.</i> , 2018)	Promodel	X	-	-	-	-	-	-
(Putz <i>et al.</i> , 2021)	-	-	X	-	-	-	-	-
(Qamsane <i>et al.</i> , 2021)	-	-	X	-	X	-	-	-
(Rajesh <i>et al.</i> , 2019)	CREO Simulate	-	X	-	-	-	-	-
(Reuter, 2016)	Simulink	X	-	-	-	-	X	-
(Reuter <i>et al.</i> , 2015)	HSC Sim	X	-	-	-	-	-	-
(Riedelsheimer <i>et al.</i> , 2020)	-	-	X	-	X	-	-	-
(Rivera <i>et al.</i> , 2020)	-	-	X	-	-	-	-	-
(Rocca <i>et al.</i> , 2020)	CIROS e Simulink	-	X	-	X	-	X	-
(Rödger <i>et al.</i> , 2021)	GaBi	X	-	-	X	-	-	-

Citação	Software	Sim	GD	LR	M	GVCS	EC	TD
(Rosen <i>et al.</i> , 2019)	-	-	X	-	-	-	-	-
(Samir <i>et al.</i> , 2019)	-	-	X	-	X	-	-	-
(Sargent, 2000)	-	X	-	-	-	-	-	-
(Schenk <i>et al.</i> , 2015)	CoSMOS	X	-	-	-	-	-	-
(Schleich <i>et al.</i> , 2017)	-	-	X	-	-	-	-	-
(Schützer <i>et al.</i> , 2019)	-	X	X	-	X	-	-	-
(Seilov <i>et al.</i> , 2021)	-	-	X	-	-	-	-	-
(Simões-Marques, 2015)	-	X	-	-	-	-	-	-
(Singh <i>et al.</i> , 2020)	-	-	X	-	X	-	-	-
(Straka <i>et al.</i> , 2019)	-	X	-	-	-	-	-	-
(Talkhestani <i>et al.</i> , 2018)	-	-	X	-	X	-	-	-
(Talkhestani <i>et al.</i> , 2020)	Arena2036	-	X	-	X	-	-	-
(Tanimizu <i>et al.</i> , 2014)	-	X	-	X	X	X	-	-
(Tekinerdogan <i>et al.</i> , 2020)	-	-	X	-	-	-	-	-
(Uhlemann <i>et al.</i> , 2017)	-	-	X	-	X	-	-	-
(Umeda, 2013)	-	X	-	X	-	-	-	-
(Robinson, 2017)	-	X	-	-	-	-	-	-
(Wang <i>et al.</i> , 2019)	Max-Plus Algebra e Simulink	X	X	-	X	-	-	-
(Wang <i>et al.</i> , 2019)	-	-	X	-	X	X	-	-
(Widok <i>et al.</i> , 2011)	-	X	-	-	-	-	-	-
(Xie <i>et al.</i> , 2021)	-	X	X	-	-	-	-	-
(Yu <i>et al.</i> , 2020)	-	-	X	-	-	-	-	-
(Zhang <i>et al.</i> , 2019)	-	-	X	-	X	-	-	-
(Zou <i>et al.</i> , 2018)	-	-	-	-	-	X	-	-

### 2.8.3.5 QP5 - Quais softwares são utilizados para criar GDs?

A Tabela 2.8.2 demonstra que apenas 21 artigos entre os 88 lidos para esse trabalho mostram qual software foi utilizado na pesquisa e, entre eles, apenas 11 mencionam GD. A maioria dos trabalhos é teórico e não utilizam nenhum software, da mesma forma, alguns trabalhos práticos também não especificam o software foi utilizado. Somado a isso, alguns trabalhos citam o software utilizado mas não trabalham com GDs e então não são descritos nessa seção.

O uso de software para a criação de GDs aborda diferentes áreas. Beloglazov *et al.*, 2020 utilizam DYNOSIM para a criação de um GD para realizar o treinamento de técnicos para manusear equipamentos utilizados em minas. Botkina *et al.*, 2018 mostram o uso de um software chamado ToolMaker para a criação de um GD, baseado na ISO 13399, de uma ferramenta de corte.

Embora muitos usos sejam focados em pequenos produtos, existem trabalhos como o de Moi *et al.*, 2020 que criam um GD para um guindaste utilizando o software Fedem. Os autores implementam um método para tentar estimar o peso e a força aplicadas no guindaste.

Outra área importante é a prevenção de riscos, que também pode ser abordada pelos GDs, e o trabalho de Rajesh *et al.*, 2019 trata desse problema. Os autores criaram um GD para prever a manutenção em freios automotivos e utilizam o software CREO Simulate para criar um modelo de equipamento para esse estudo. Outro trabalho que segue essa área é o estudo de Kaewunruen *et al.*, 2021. Nesse estudo os autores aplicam o GD para prevenir riscos em pontes e utilizam o software Revit2018 para construir o modelo 3D.

Rocca *et al.*, 2020 descrevem uma aplicação laboratorial que virtualmente testa a configuração de uma planta que desmonta resíduos elétricos e eletrônicos. Para a modelagem da estação de trabalho nesse artigo, é utilizado o software CIROS Studio, e a função do MATLAB no Simulink é utilizada para extrair os valores adquiridos. Wang *et al.*, 2019 propõem um GD para criar sistemas de manufatura que possuam eficiência energética. Nesse trabalho, os autores utilizam três softwares: o Max-Plus Algebra para criar os modelos matemáticos dos sistemas a eventos discretos e, assim como Rocca *et al.*, 2020, também utilizam MATLAB e Simulink.

Alguns artigos são teóricos e descrevem frameworks para se trabalhar com GDs, entretanto alguns deles definem o software que será utilizado na fase prática do trabalho. Esse é o caso do trabalho de Garrido *et al.*, 2019, que apresentam um framework que automaticamente gera GDs para indústrias e realiza comparações entre alguns softwares. O estudo resultou na identificação de dois softwares que os autores descrevem como os melhores para a área de simulação, FlexSim e PlantSimulator. No entanto, os autores não descrevem qual será utilizado, apenas defendem que a escolha depende exclusivamente de argumentos financeiros e industriais.

Outro trabalho teórico foi realizado por Ghita *et al.*, 2020, que produziram uma revisão da literatura e mostraram um estudo de caso no ecossistema industrial de Marrocos. Para apresentar o estudo de caso, os autores utilizaram o software SMIT. Gopalakrishnan *et al.*, 2020 também apresentam um trabalho teórico com um caso de uso para mostrar o *framework* descrito. Os autores desenvolveram um *framework* para auxiliar o armazenamento, atualização, busca e recuperação de informações relevantes e demonstram essa ideia por meio de uma análise de tolerância de uma engrenagem de um compressor.

Talkhestani *et al.*, 2020 utilizam um método de ponto de ancoragem para manter atualizado um modelo de GD de um sistema de manufatura e avaliar as vantagens de um GD sincronizado. Para essa avaliação foi utilizado o software ARENA2036.

Esses artigos são os que descrevem quais softwares foram utilizados e é possível notar que nenhum software é unânime, mas essa escolha depende do tipo de trabalho que será realizado e também das preferências dos autores.

Com essa revisão foi possível, também, encontrar ideias de pesquisas e lacunas que podem auxiliar na elaboração deste trabalho e nas próximas pesquisas na área. Avventuroso *et al.*, 2017 afirmam que a comparação feita entre os dados esperados e obtidos é ineficiente, isso significa que é necessário criar *frameworks* que auxiliem os pesquisadores

na comparação desses dados e realizar decisões de forma mais rápida.

Em seu trabalho, Czwick *et al.*, 2020 escrevem que é necessário criar uma ferramenta que permita a comunicação constante entre o produto real e o GD, com uma adaptação que possibilita modelar também o comportamento do produto real. Barricelli *et al.*, 2019 identificam alguns problemas e desafios em várias áreas e eles são descritos na Tabela 2.8.3.

Tabela 2.8.3 – Problemas e desafios apontados por Barricelli *et al.*, 2019

Áreas	Problemas e Desafios	Soluções
Ética	Registros Médicos Pessoais	Testes Clínicos Dados Anônimos Utilizar os dados apenas com o consento dos pacientes
Segurança e Privacidade	Ataques de Hackers	Criar soluções de segurança para prevenir que os dados sejam vistos por pessoas não autorizadas
Custos de Desenvolvimento	Custos com software e hardware	Repositórios grátis para propósitos de pesquisa com alguns modelos experimentais de GD
Regulamentos Governamentais	Validações devem ser feitas para assegurar a credibilidade dos modelos biológicos	Definir regulamentos para virtualização de seres humanos
Limitações Técnicas	São necessários dispositivos que não oferecem dados confiáveis; conexões lentas de internet; grande quantidade de dados faz com que seja difícil visualizá-los	É necessário melhorar os hardwares que hoje em dia são limitados

Embora todos os desafios sejam importantes na literatura, existe um problema mencionado pelos mesmos autores que eles consideram o mais relevante, a criação de um GD com o qual os usuários possam interagir facilmente. De acordo com os autores, a maioria dos desenvolvedores está apenas preocupados com a criação do GD e não com o processo de documentação desde o início, e isso pode ser facilmente resolvido com uma documentação bem desenvolvida.

Ghita *et al.*, 2020 realizaram uma análise SWOT (do inglês, Força, Fraquezas, Oportunidades e Ameaças) de um GD e destacaram algumas oportunidades e ameaças em seu trabalho. Na análise são destacadas algumas áreas, como segurança, regulamentações nacionais, riscos de acessibilidade, alta dependência da nuvem e grande consumo de energia.

Czwick *et al.*, 2020 descrevem dois problemas que podem ser resolvidos com o auxílio de GDs. O primeiro é que os GDs comumente representam as características dos produtos,

mas não as influências externas a eles. O segundo problema está relacionado ao feedback do objeto virtual para o físico. É necessário estabelecer uma comunicação constante entre ambos para possibilitar a troca de informações.

Ma *et al.*, 2019 mostraram um GD que auxilia na melhoria da interação homem-máquina e como trabalho futuro é sugerido que mais pesquisas sobre esse tema sejam realizadas. Somado a isso, Qamsane *et al.*, 2021 desenvolveram uma solução para sistemas de manufatura, mas afirmam que ainda é necessário um *framework* que possa criar uma infraestrutura universal capaz de atender alguns requisitos dos GDs como escalabilidade, verificação e validação e manutenibilidade.

Uhlemann *et al.*, 2017 citam uma dificuldade sobre a qualidade dos dados e escrevem que, na maioria dos casos, eles são insuficientes para uma aplicação de simulação. Finalmente, Widok *et al.*, 2011 sugerem a utilização de uma combinação de diferentes perspectivas de sustentabilidade para a criação de um único modelo.

Na Revisão Sistemática da literatura realizada, foi possível notar que não existem trabalhos que utilizam GDs para solucionar problemas da LR, principalmente problemas relacionados à coleta de produtos no estágio final de vida e, portanto, o ineditismo desse trabalho se justifica, em partes, nessa lacuna.

Diversos problemas relacionados à coleta são pouco abordados na literatura e dois deles serão tratados neste trabalho. Pela literatura foi possível notar que nenhum trabalho aborda qual o melhor momento para se realizar uma coleta, assim que o pedido é recebido pelas empresas ou se outro tipo de estratégia pode ser mais vantajosa. Para tanto, será utilizada neste trabalho uma abordagem que envolve Clusters e otimização, que serão abordados nas seções 2.5 e 2.6 respectivamente.

A próxima seção traz uma breve definição de Clusters e mostra qual o algoritmo será utilizado neste trabalho, bem como o motivo dele ter sido escolhido e as vantagens de utilizá-lo.

## 2.9 Considerações Finais

Este capítulo apresentou a fundamentação teórica realizada para este trabalho. Foram demonstrados tópicos sobre Logística Reversa, Simulação, Gêmeos Digitais, Clusters e Otimização Multiobjetivo, utilizados para embasar este trabalho. Também foi trazida uma fundamentação teórica, apontando possíveis lacunas que poderiam ser exploradas para a definição do tema deste estudo.

O próximo capítulo apresenta o método de pesquisa utilizado neste trabalho, descrevendo sua classificação quanto à natureza, objetivo, abordagem e método, de acordo com os conceitos apresentados em Prodanov *et al.*, 2013.

## 3. Método de Pesquisa

### 3.1 Considerações Iniciais

Este capítulo descreve o método de pesquisa adotado neste trabalho. A classificação da pesquisa será apresentada, inserindo este trabalho na classificação correspondente quanto à natureza, objetivo, abordagem e método.

Serão também descritos os métodos de pesquisa adotados, Modelagem e Simulação, e apresentadas as etapas que seguirão esse trabalho.

### 3.2 Classificação da Pesquisa

De acordo com Prodanov *et al.*, 2013 o objetivo da pesquisa é conhecer vários aspectos sobre um assunto e seu resultado deve contribuir para o crescimento da humanidade. As pesquisas científicas podem ser classificadas de quatro formas diferentes (Prodanov *et al.*, 2013):

1. De acordo com sua natureza - a pesquisa pode ser:
  - a) Básica - tem como objetivo gerar conhecimento para o avanço da ciência;
  - b) Aplicada - tem como objetivo gerar conhecimento em aplicações práticas voltadas para problemas específicos.
2. De acordo com seus objetivos:
  - a) Exploratória - proporciona informações sobre um assunto a ser investigado e facilita impor limites para a pesquisa, como uma Revisão Sistemática da Literatura, por exemplo;
  - b) Descritiva - serve para descrever as características de uma população e utiliza técnicas de coleta de dados como questionários, por exemplo. Nesse tipo de pesquisa, o pesquisador não interfere nos fatos, apenas os registra;
  - c) Explicativa - procura descobrir e explicar o motivo da ocorrência de um dado fenômeno;
  - d) Normativa - procura desenvolver políticas, estratégias e ações para melhorar o resultado disponível na literatura, encontrar uma solução ótima para um problema definido ou comparar várias estratégias para abordar um problema específico (Bertrand *et al.*, 2002).
3. De acordo com os métodos (Miguel *et al.*, 2010) e (Prodanov *et al.*, 2013):

- a) Pesquisa de avaliação (*Survey*) - As variáveis são avaliadas através de um questionário ou outro instrumento de pesquisa;
- b) Modelagem/Simulação - o pesquisador pode manipular as variáveis no modelo de pesquisa, mas não pode alterar o sistema real. Esse modelo nada mais é do que uma representação virtual ou matemática do sistema;
- c) Experimento - há a criação de um experimento capaz de testar o relacionamento entre as variáveis de pesquisa, ou seja, o pesquisador é capaz de manipular as variáveis independentes e observa os resultados das variáveis dependentes;
- d) Pesquisa de campo - tem como objetivo obter informações sobre um problema o qual se procura alguma resposta ou uma hipótese que se queira confirmar;
- e) Estudo de caso - envolve um estudo profundo sobre poucos objetos de forma a permitir o conhecimento detalhado de um assunto;
- f) Pesquisa-ação - requer uma interação estreita entre os pesquisadores e os participantes da pesquisa, o resultado de uma ação aplicada é estudado de forma a poder definir qual será a próxima ação.

#### 4. De acordo com a abordagem:

- a) Pesquisa quantitativa - requer que as informações sejam traduzidas em números para que seja possível analisá-las;
- b) Pesquisa qualitativa - considera que a relação entre o mundo real e o sujeito a ser pesquisado não pode ser convertida em números e não requer técnicas estatísticas, mas se baseiam na subjetividade.

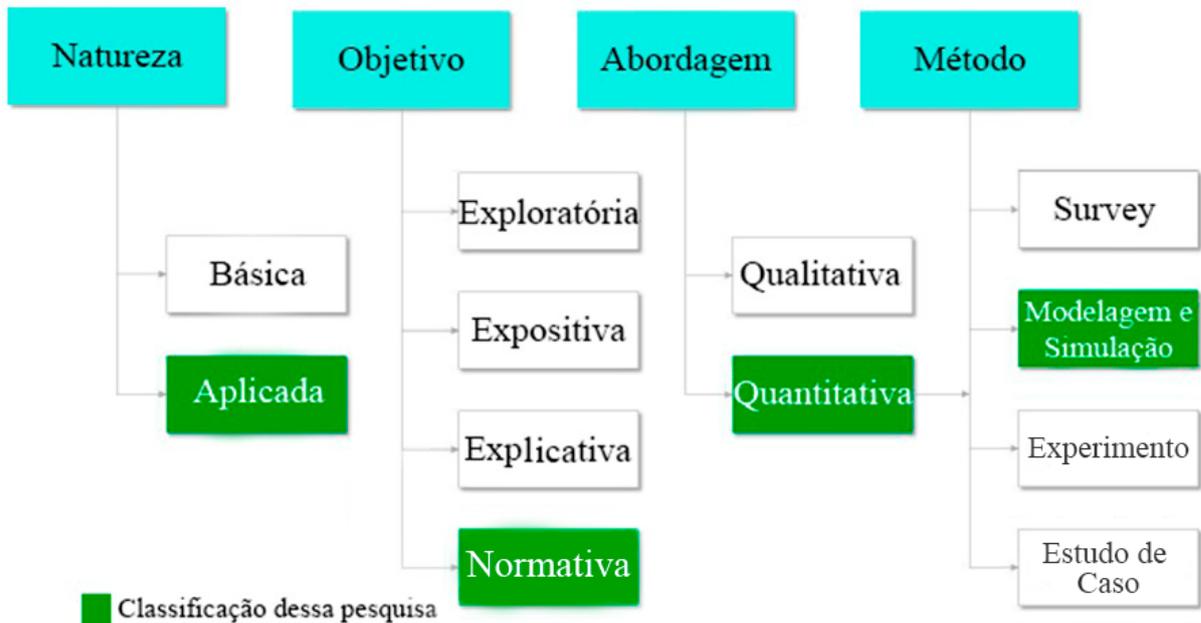
Portanto essa pesquisa pode ser classificada como aplicada, pois possui o objetivo de resolver problemas de aplicações práticas, como o problema descrito neste trabalho, relacionado à quando e com qual veículo uma coleta deve ser realizada e também porque essa pesquisa gera conhecimento para problema específicos.

Essa pesquisa também se classifica como normativa, pois, além de buscar explicar as relações entre os fenômenos reais e seus parâmetros, como peso das coletas, emissão de CO<sub>2</sub>, gasto de combustível, também se preocupa em encontrar uma solução ótima para o problema definido.

Com relação aos métodos, essa pesquisa pode ser classificada como modelagem e simulação, pois, apesar do trabalho utilizar a linguagem de programação Python, foram definidas equações capazes de descrever o comportamento do sistema real. Essa capacidade de espelhamento pode ser definida como uma simulação do sistema real. Além disso, o modelo em si é criado baseando-se em Gêmeos Digitais, que por si só, podem ser considerados uma forma de modelagem e simulação e por fim, serão utilizados modelos de simulação para auxiliar na diminuição do erro do modelo criado com o Python.

Por fim, esse trabalho possui abordagem quantitativa, pois as informações são sempre traduzidas em números pois são coletadas de sistemas físicos, como peso coletado e distância do ponto inicial até o ponto de coleta, além de ser necessária a utilização de técnicas estatísticas, como médias, para inserir e analisar os dados. A Figura 3.2.1 resume a classificação dessa pesquisa de acordo com os métodos definidos no capítulo.

Figura 3.2.1 – Classificação da Pesquisa.



### 3.3 Método de Pesquisa

Como descrito na Seção 2.3.1, o modelo utilizado para este trabalho é o de (Montevecchi *et al.*, 2020), ele descreve vários passos para se ter um modelo de simulação funcional.

O primeiro passo do modelo é a definição dos objetivos. Esses objetivos são a criação de um modelo capaz de auxiliar a empresa na tomada de decisões referentes às coletas que ela precisa realizar. Para isso é necessário utilizar equações capazes de calcular os custos econômicos e de emissão de  $CO_2$ , sendo esses objetivos específicos do trabalho.

Para o modelo de simulação, também foram definidos os objetivos, que são a criação de imprevistos que podem ocorrer durante o percurso do veículo de modo a diminuir os erros que porventura possam ocorrer no modelo inicial, visto que o primeiro modelo não permite a inserção de imprevistos de forma simples como o modelo de simulação no FlexSim permite.

A construção do modelo conceitual, que é o segundo passo, constituiu na criação dessas equações para realizar os cálculos necessários. Dessa forma, é possível iniciar o modelo. Essas equações são mostradas na seção 2.7.

O modelo conceitual para o FlexSim também foi definido aqui, ele consiste na criação de mapas, utilizando a ferramenta GIS do FlexSim, e a criação de veículos capazes de percorrer as rotas definidas. Como essa ferramenta é recente, também foi necessário, nesse momento, estudar se seria possível a criação do modelo como esperado e, então num próximo passo, foi documentado como criar o modelo.

O terceiro passo, que é a validação do modelo conceitual, consistiu em verificar se os cálculos realizados pela equação criada eram compatíveis com os valores pagos pela empresa. Eles são detalhados em uma planilha enviada pela própria empresa, portanto, é possível validar o modelo conceitual comparando as respostas encontradas com os valores obtidos na planilha.

Após validado o modelo, a documentação foi escrita para a qualificação deste trabalho, demonstrando as equações utilizadas e os resultados preliminares das mesmas.

Então, a última parte da concepção do trabalho foi realizada, a definição dos dados que alimentariam o modelo. Foi definido que eles viriam das planilhas fornecidas pela própria empresa, elas contêm os veículos utilizados, bem como suas características, além dos custos dos veículos para a empresa, custos com o motorista e ajudante e os pesos coletados em cada semana.

Além disso, como os resultados do primeiro modelo serão utilizados para abastecer o modelo de simulação, as variáveis de entrada foram identificadas. Desse modo foi possível ajustar o modelo na linguagem de programação Python para ter como dados de saída, os dados necessários para alimentar o modelo de simulação. Se os dois modelos não trabalhassem em conjunto, poderiam ocorrer vários erros.

Os passos da implementação do modelo, constituem na construção, verificação e validação do mesmo. Portanto, foram criados, de forma separada, os modelos no Python e no FlexSim. A verificação e validação dos cálculos realizados no Python foram simples de serem validados, visto que já se possuía uma planilha com os valores pagos pela empresa e foi apenas necessário realizar comparações para definir a validade do modelo.

Já o modelo do FlexSim foi mais difícil de ser validado, pois não é possível descobrir as rotas que os veículos realizaram no sistema real, quando as coletas foram feitas. Dessa forma, para validar o modelo, de simulação, foram utilizadas as rotas criadas pelo Python após todos os cálculos e as distâncias dessas rotas obtidas pelo FlexSim, foram validadas utilizando-se a ferramenta Google Maps. Como o mapa criado estava com as distâncias corretas, foi considerado que estava validado.

Para a definição do design experimental, que é a primeira etapa da análise dos resultados, foi utilizado um DOE (Design of Experiments), mais especificamente o método fatorial completo. Ele consistiu em definir alguns valores que pudessem ser utilizado para o AG, como por exemplo, taxa de *crossover* e mutação, número de indivíduos, número de gerações e pesos para cada um dos parâmetros da equação. Para a criação desse DOE foi utilizado o software MiniTab, pois, de acordo com Joshi *et al.*, 2023 ele é o melhor

software para se trabalhar com grandes quantidades de dados.

Os resultados gerados pelo MiniTab foram inseridos diretamente no código em Python na forma de uma matriz na qual cada linha indicava uma combinação de fatores a serem utilizadas. Desse modo foi possível, em um único teste, recuperar todos os resultados de cada uma das combinações de dados sugeridas pelo DOE.

Os resultados obtidos de todas as combinações de fatores foram inseridas no MiniTab para que fosse possível analisá-los e, dessa forma, definir as melhores propriedades de cada um dos elementos necessários para o funcionamento do AG.

Para a análise dos resultados, foram comparados os valores obtidos com os valores já definidos pela empresa e a criação de gráficos do tipo *BoxPlot* foi utilizada para auxiliar a visualização dos resultados.

Esses resultados também alimentaram o modelo de simulação, no qual imprevistos foram adicionados de modo a serem coletados novos valores de tempo e custos. Para a simulação, foram realizadas 10 testes com dados de 10 semanas diferentes e cada teste incluiu 200 replicações.

Por fim, foram novamente criados gráficos com os novos dados obtidos e a conclusão pode ser criada, baseando-se nos resultados com e sem o modelo de simulação.

### 3.4 Considerações Finais

Esse capítulo serviu para descrever o método de pesquisa adotado neste trabalho, apresentando a classificação da pesquisa realizada nesta tese, e também, as etapas seguidas para a realização deste trabalho.

O próximo capítulo apresenta a abordagem proposta, será formulado o problema, demonstrado o *framework* criado para resolver o problema proposto neste trabalho, as funções matemáticas utilizadas para realizar os cálculos necessários, bem como os objetos de estudo utilizados para validar o método definido.

## 4. Aplicação

### 4.1 Informações Iniciais

Neste capítulo será apresentada primeiramente uma abordagem proposta de como o sistema irá avaliar qual o melhor momento e o melhor veículo a ser utilizado para a realização de coletas em uma rede de LR. Serão apresentadas também algumas imagens demonstrando como os Clusters irão funcionar dentro do módulo GIS do software FlexSim, que foi uma das ferramentas escolhidas para a realização deste trabalho. Por último, de forma a verificar a aplicabilidade e qualidade da ferramenta desenvolvida, serão utilizados dois objetos de estudo com dados históricos de uma multinacional de coleta, reciclagem e remanufatura de produtos eletrônicos. A filial estudada se situa no Brasil, mais especificamente no estado de São Paulo.

Vale ressaltar que, primeiramente, o estudo será realizado apenas no estado onde se encontra a empresa. Isso se deve ao fato de que, ao estudar os dados históricos disponibilizados, verificou-se que esse estado é o que mais recebeu pedidos de coletas nos anos de 2019 e 2020, período a partir do qual a empresa iniciou o processo de documentação.

Nesse capítulo, primeiramente, será formulado o problema a ser resolvido, em seguida serão definidas as restrições para o trabalho, pois a falta delas o tornaria complexo e possivelmente inviável. Após as restrições, será descrito o trabalho e como ele foi realizado, explicando sobre a criação dos mapas, como os Clusters serão criados dentro dele, como serão realizados os cálculos para definir os melhores momentos e veículos para se realizar as coletas e como o GD será utilizado para o monitoramento em tempo quase real das coletas.

### 4.2 Formulação do problema

Um dos maiores problemas da LR encontrado na literatura é definir o melhor veículo para realizar uma coleta, além disso, um dos problemas ainda não abordados, que gera transtornos para a empresa utilizada como objeto de estudo, é o fato de se encontrar o melhor momento para que uma coleta seja realizada. Esses são dois problemas que esse trabalho busca solucionar.

A empresa em questão é uma multinacional parceira e montadora de várias marcas tais como Motorola, HP e Lexmark e a filial estudada está localizada no estado de São Paulo e opera em toda a GVCS, ou seja, a empresa realiza as coletas, remanufatura de produtos, revenda de produtos de segunda mão e montagem de produtos novos para as empresas parceiras.

Ela realiza o reaproveitamento de diferentes tipos de resíduos, desde celulares peque-

nos, até grandes impressoras. Além disso, em uma coleta é possível ter um único objeto pequenos ou vários objetos grandes que demandam grande esforço durante a coleta e, em alguns casos, é necessário que um veículo vá a um único ponto de coleta para pegar os resíduos disponíveis nela.

A empresa possui toda a estrutura de LR bem organizada e consolidada, desde o recebimento de produtos, passando por todo o processo de remanufatura até a reciclagem dos componentes que não podem ser reutilizados. No entanto, a fase de coleta da empresa é realizada, atualmente, por empresas terceirizadas.

A empresa utilizada para este trabalho possui veículos alugados disponíveis para sua utilização, bem como motoristas já contratados. Porém, esse recursos não são utilizados hoje para realizar as coletas da LR, esses veículos são utilizados para buscar matérias-primas novas, compradas de outras empresas. Portanto, uma possível ideia neste trabalho, é a utilização desses veículos já disponíveis, para realizar também as coletas da LR, quando for economicamente viável.

As coletas realizadas pela empresa terceirizada pode ser de duas formas: fracionada e dedicada.

Na coleta dedicada, um veículo realiza coletas apenas para a empresa em questão, podendo ser única ou não. No caso da coleta única, os produtos coletados em um único local são suficientes para preencher toda a carga do veículo. Quando a coleta não é única, um veículo realiza várias coletas até que toda sua carga esteja completa, porém essas coletas precisam, obrigatoriamente, ser da mesma empresa.

Por outro lado, a coleta fracionada permite que um mesmo veículo realize coletas em diferentes locais para diferentes empresas, esse método é vantajoso quando existem coletas distantes de todas as outras, pois permite que a transportadora aproveite rotas existentes de outras empresas, tanto de logística quanto de LR.

Porém, o fato da coleta na LR ser realizada por empresas terceirizadas acarreta alguns problemas como:

- Falta de controle dos valores para a realização da coleta;
- Cobrança de valores excessivos e, as vezes, improcedentes por parte das empresas terceirizadas;
- Falta de controle sobre os locais de coleta.

Porém, o maior problema que a empresa enfrenta é a grande diferença entre os valores reservados para realizar pagamentos e os valores cobrados pelas transportadoras. Por exemplo, a empresa realiza um cálculo de R\$1000,00 para realizar uma coleta e separa esse valor, porém a transportadora envia a nota fiscal com um valor cinco vezes maior. Isso acarreta em vários problemas, pois é necessário realizar novos pedidos de pagamento com

valores maiores do que os calculados a princípio, além de ser necessário criar justificativas para esses valores extras, o que às vezes é inadmissível por parte da empresa.

Essa possível diferença de valores ocorre por alguns motivos. O usuário final, que realiza o pedido de coleta, pode informar o peso ou medida errados do produto a ser coletado. Esse problema pode ser resolvido através de previsões de coleta, porém ele não é abordado nesse trabalho, mas sugerido como trabalho futuro. Outro motivo é que a transportadora pode realizar a coleta utilizando um veículo maior do que o necessário. Esse é um problema que este trabalho tenta solucionar, utilizando a otimização para verificar qual o melhor veículo para se realizar uma coleta.

O terceiro e principal motivo para ocorrer a diferença entre os valores é o fato das coletas poderem ser fracionadas ou dedicadas. Não é raro a empresa calcular que uma coleta pode ser feita de forma fracionada (mais barata) e receber a nota de uma coleta dedicada (mais cara e desnecessária) e esse também é um problema que esse trabalho tenta auxiliar na resolução.

Dessa forma, o principal requisito para que uma empresa possa utilizar este trabalho em suas atividades de LR é que ela possua registro de todos os produtos coletados a partir do momento em que o pedido de coleta é realizado. Esses registros precisam ter obrigatoriamente, o código postal do local da coleta, o peso estimado do objeto coletado, as medidas estimadas do objeto coletado e as datas do pedido e da coleta.

Além dos requisitos, também é possível definir o público-alvo desta pesquisa como sendo caracterizado por qualquer empresa que queira reduzir os custos econômicos e os custos de emissão de gases poluentes na LR, seja ela de logística ou de remanufatura (como no caso deste trabalho).

Como uma das ferramentas utilizadas para trabalhar com os GDs foi o FlexSim, é necessário que a empresa possua esta ferramenta para aproveitar todas as vantagens deste trabalho. A não utilização desse software não implica na inviabilização deste trabalho, porém o FlexSim garante que uma maior confiabilidade nos resultados obtidos. Como o FlexSim é um software relativamente caro para se comprar, pequenas empresas podem não se adequar ao público-alvo desta pesquisa.

As próximas seções explicam como serão utilizadas cada uma das ferramentas nesse trabalho e também descrevem o *framework* criado para o desenvolvimento do mesmo.

### 4.3 Definição das Variáveis

Antes de iniciar a explicação sobre o trabalho proposto, é necessário definir algumas variáveis que serão utilizadas futuramente. Para tanto, essa seção é destinada a descrever cada uma das variáveis usadas nas equações e no *framework* proposto para esse trabalho.

Dessa forma, foram definidas algumas variáveis para tentar transformar o modelo, apesar das restrições, em uma cópia o mais fiel possível do modelo real. As variáveis

utilizadas foram:

- Distância - distância total percorrida pelo veículo, desde a saída do centro de logística, passando por todas as cidades onde as coletas podem ser realizadas e voltando ao centro novamente, essa distância deve ser minimizada;
- Jornada de trabalho - a jornada de trabalho não pode ser maior do que oito horas por dia. A princípio será utilizado esse tempo como o limite para realizar as coletas. No entanto, futuramente, serão incluídos no cálculo, valores relacionados a horas extras e diárias em hotéis, para que se possa verificar se fornecer pernoites ao motorista para continuar a coleta no dia seguinte pode ser uma solução viável;
- $Q_m^k$  - Capacidade do veículo k - quantidade, em quilos, que um veículo consegue transportar;
- $\rho_0$  - Consumo do veículo vazio - distância que um veículo consegue percorrer com um litro de combustível quando se encontra sem nenhuma carga;
- $\rho^*$  - Consumo do veículo cheio - distância que um veículo consegue percorrer com um litro de combustível quando se encontra totalmente carregado;
- N - Conjunto de pontos de coleta, 0,  $i$  e  $j \in \mathbb{N}$ , sendo 0 o ponto inicial do veículo;
- $\omega$  - Fator de emissão de  $CO_2$ . De acordo com ÁLVARES JR *et al.*, 2001, o fator de emissão de  $CO_2$  para veículos pesados movidos a Diesel é de 770g/km e o de veículos menores é de 280g/km;
- $d_{ij}$  - distância do ponto de coleta  $i$  para o ponto de coleta  $j$ ;
- $q_i$  - capacidade atual carregada no veículo, após a coleta  $i$ ;
- Peso estimado da coleta - peso estimado a ser coletado em cada ponto  $i$ ;
- Valor estimado da coleta - valor estimado baseado no peso estimado de cada coleta  $i$ ;
- Local da coleta - local informado pelo usuário final, onde a coleta será realizada;
- $C_1^k$  - Custo do veículo - Custo fixo do veículo k, dependendo do modelo, para o estudo realizado, a empresa possui uma tabela com os valores para cada veículo que realiza a coleta em uma dada localização;
- Peso cubado - peso medido pela empresa de coleta, calculado utilizando o volume do produto (altura X largura X profundidade) multiplicado por um fator de cubagem (o valor adotado é de 300);

- Valor cubado - valor definido após a realização da cubagem dos produtos coletados;
- $L_c$  - Lista de pedidos a serem coletados - contém a lista com todos os pedidos realizados pelo usuário final que ainda não foram enviados para a transportadora realizar a coleta;
- R - Raio do Cluster - as cidades que se encontram dentro desse raio de distância serão inseridas no Cluster;
- C - Clusters criados após a verificação da possibilidade de realização de coletas nas cidades contidas nele. Para a criação do Cluster, é verificado se existe algum veículo cuja carga máxima  $Q_m$  se aproxime do valor total de todas as coletas existentes dentro do agrupamento;
- $C_o$  - Coletas obrigatórias - define-se como coletas obrigatórias, as coletas cujo pedido foi realizado há 5 dias e ainda não foram coletadas. Nesse caso, é obrigatório que as coletas sejam realizadas imediatamente;

## 4.4 Clusters

Como descrito na Seção 2.5, Clusters são agrupamentos de quais objetos semelhantes. No caso deste trabalho, os Clusters serão considerados como agrupamentos de cidades as quais possuem alguma coleta para ser realizada.

Para definir os Clusters, foi utilizado o algoritmo *Leader*, mostrado na Seção 2.5.4, ele define um líder para o grupo e verifica, utilizando distâncias Euclidianas, quais os objetos próximos do líder.

No caso deste trabalho, as coletas pertencentes a um Cluster, podem ser consideradas como as cidades dentro de um raio definido, com o centro sendo o líder. Todas as coletas dentro desse raio, são consideradas pertencentes a um mesmo Cluster.

Para definir o valor do raio a ser utilizado no trabalho, foram testados alguns valores diferentes (5km, 10km, 20km, 40km e 60km). Valores baixos, até 20km, resultaram em Clusters pequenos (com até 5 cidades) e inviáveis. Por outro lado, utilizando o raio de 60Km, os Clusters foram extremamente grandes e impossíveis de serem coletados em um único dia. Portanto, o valor escolhido para o raio foi de 40Km. Os Clusters foram, então, definidos como sendo todas as coletas que possuem distâncias Euclidianas menores do que 40Km e, portanto, estão dentro do raio utilizado.

O algoritmo *Leader* possui resultados diferentes dependendo da ordem dos dados inseridos nele, então a ordem escolhida para este trabalho foi a ordem que as coletas são recebidas. A primeira coleta recebida na semana será o primeiro líder e as distâncias entre todas as outras coletas são testadas, ou seja, a distância Euclidiana entre o líder e cada uma das cidades é calculada e as que possuem menores do que 40Km de distância são inseridas no Cluster.

Então a próxima cidade não pertencente a nenhum Cluster se torna o próximo líder e o processo de calcular a distância entre todas as cidades é refeito. Se uma coleta pertencente a um Cluster e a coleta testada no momento possuírem distância menor do que o raio definido, a primeira é inserida no Cluster já existente.

Desse modo, este trabalho testa as coletas na lista e, após finalizar, retorna uma lista com todos os Clusters disponíveis. O tamanho dos Clusters podem variar e é possível encontrar agrupamentos de apenas uma cidade, por exemplo.

Quando o algoritmo termina de verificar as coletas, uma verificação é feita para definir se um agrupamento é viável para ser coletado ou não, um Cluster viável é aquele que possui ao menos peso total de 450kg. Esse valor foi definido como sendo 10% a menos do que a capacidade do menor veículo disponível e caso um Cluster não atinja esse peso, ele é descartado.

Os Clusters restantes serão os utilizados para definir as melhores coletas no *Framework* e ele é explicado na próxima Seção.

## 4.5 Framework

De modo a resolver os problemas descritos no trabalho, serão utilizadas as três áreas descritas no capítulo 2: Clusters, otimização e Gêmeos Digitais. Além disso, serão utilizadas duas ferramentas para o desenvolvimento do problema, a linguagem de programação Python e o software de simulação FlexSim.

Os Clusters são utilizados de modo a ser capaz de agrupar as coletas próximas que podem ser coletadas utilizando-se um veículo dedicado, de modo a otimizar o custo para esse tipo de coleta. As coletas que não puderem ser agrupadas em um Cluster podem, futuramente, serem coletadas utilizando-se veículos fracionados. Desse modo, o tomador de decisão da empresa é capaz de decidir quando enviar cada tipo de veículo e também possui uma base científica para contestar as transportadoras caso o valor cobrado seja muito distante do valor calculado previamente.

Após os Clusters serem criados, serão utilizadas ferramentas de otimização multiobjetivo para definir quais os melhores agrupamentos de coletas de modo a permitir que o tomador de decisões possa entender onde é vantajoso realizar as coletas e possa tomar as decisões de forma mais consciente do que a forma atual, que ocorre utilizando-se o sistema FIFO (*First-in, First-out*, ou seja, o primeiro pedido recebido é o primeiro enviado para a transportadora realizar a coleta).

Tanto os Clusters quanto os resultados recebidos após a utilização dos métodos de otimização serão inseridos no software de simulação FlexSim de forma que seja possível criar nele um modelo que auxiliará o GD. O software FlexSim possui um módulo que permite a criação de mapas e é explicado na seção 4.7.

Por fim, a linguagem de programação Python é utilizada nas primeiras etapas. Ela

será necessária para realizar os cálculos cujos resultados serão enviados para o FlexSim. Através da linguagem de programação Python é possível recuperar as coordenadas de cada uma das coletas e enviar os valores para serem inseridos no FlexSim. Também utilizando essa linguagem de programação, serão implementados os métodos de otimização e, com o PyQt, uma biblioteca do Python, será criada uma interface para que os usuários possam inserir os dados e visualizar os resultados.

De modo a definir o passo a passo do trabalho, foram criados dois *Frameworks*, um multiveículo e um monoveículo, para fins de comparação. Ambos são explicados nas próximas seções.

#### 4.5.1 *Framework* Multiveículo

Nesse primeiro *framework*, são assumidos vários veículos diferentes, isso significa que, como existem sete tipos de veículos, o *framework* também pode assumir até sete veículos. Esse primeiro modelo é explicado na Figura 4.5.1:

1. O *Framework* se inicia com a lista  $L_c$  de pedidos de coleta realizados, além de uma planilha de valores pagos pela empresa, contendo valores fracionados e dedicados. Além disso, também são inseridos no sistema valores como aluguel de veículos, e os dados dos veículos (tamanho, carga máxima, consumo de combustível, entre outros dados);
2. As planilhas são convertidas em matrizes para que a linguagem de programação Python possa trabalhar com elas;
3. Utilizando a matriz contendo as coletas, os Clusters são criados. O primeiro pedido de coleta se torna o centro de um Cluster com raio R;
4. Todas as coletas em aberto  $i \in L_c$  são avaliadas iterativamente para que sejam montados todos os Clusters C possíveis;
5. Para a criação de um Cluster, é necessário que  $\sum_{i=1}^{Col} peso(i) \approx \min(Q_m)$ ;
6. Para se criar o Cluster é utilizada a equação de Haversine explicada na Eq. 2.1. Além disso, as prioridades das coletas são calculadas nessa etapa. Ela é igual a quantidade de dias que uma coleta está em atraso, portanto quanto mais tempo um produto está esperando para ser coletado, maior será a prioridade para aquele Cluster. A Eq. 4.1 mostra o cálculo da prioridade do Cluster ( $P_C$ ).

$$P_C = \max [dia\_atual_i - dia\_pedido_i] \forall i \in L_C \quad (4.1)$$

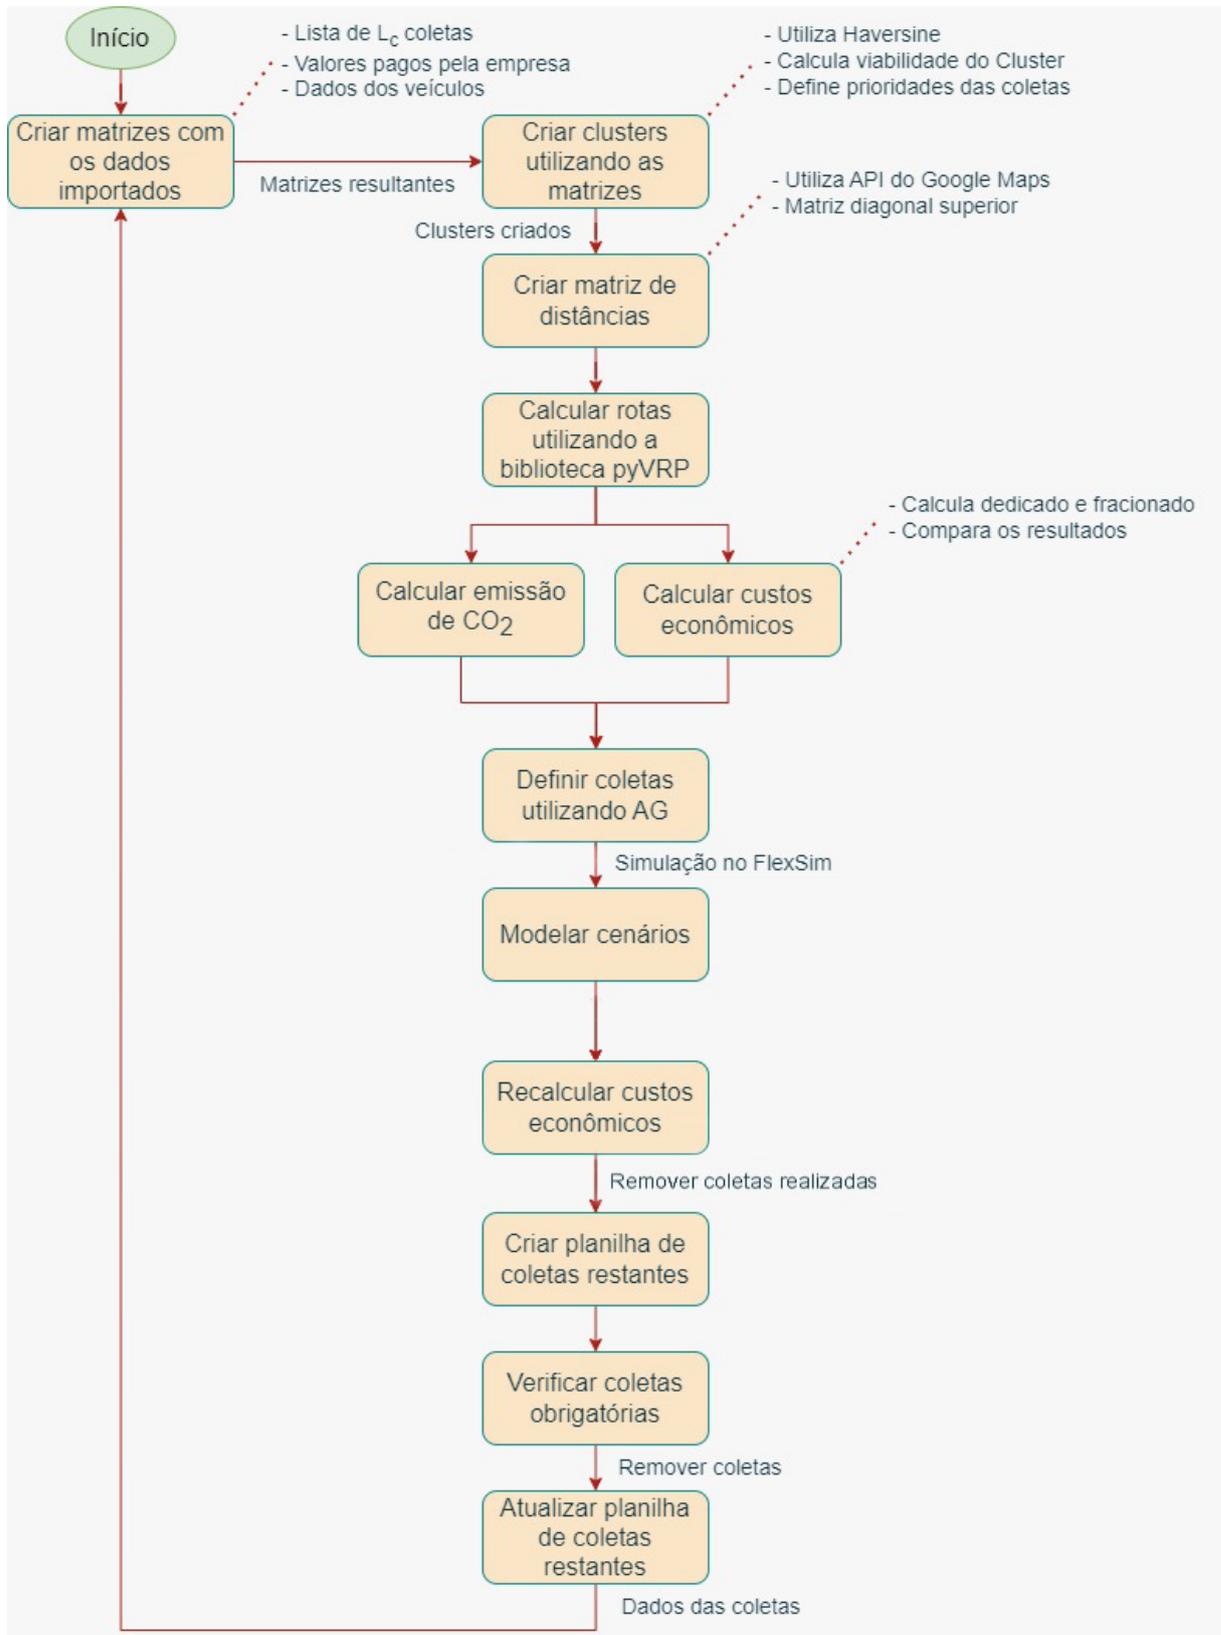
7. Após a criação de todos os Clusters com valores aproximados, a API do Google Maps (Svennerberg, 2010) é utilizada para realizar os cálculos das distâncias reais;

8. Com a utilização da API mencionada, uma matriz de distâncias é criada para que as melhores rotas sejam calculadas utilizando-se a biblioteca pyVRP (Valdecy, 2024);
9. Após a definição das rotas, são calculados os custos econômicos e os custos da emissão de  $CO_2$ . Esses valores são utilizados na função de *fitness* do AG;
10. O AG recebe as rotas calculadas utilizando-se o pyVRP além de outras variáveis como: a quantidade de veículos utilizada para resolver o problema, a lista de prioridades dos Clusters, os Clusters (contendo as coordenadas, pesos, custos, entre outros dados), a matriz de distância original e a sequência de coletas de cada uma das rotas criadas pelo pyVRP;
11. O AG devolve, como resposta, uma lista com os melhores veículos para serem utilizados em cada um dos Clusters. Vale ressaltar que cada Cluster pode ser percorrido por mais de um veículo, visto que este trabalho leva em consideração o Problema do Caixeiro Viajante Múltiplo;
12. Os valores encontrados no AG são inseridos no software FlexSim para que seja possível a criação de cenários que podem ocasionar imprevistos na viagem (pneu furado, parada para almoço, entre outros problemas).
13. Com os dados de saída da simulação, os custos são recalculados para que possam ser comparados com os custos definidos pelo AG. Desse modo, é possível encontrar uma faixa de valores no qual o custo da viagem possivelmente se encontra;
14. Os Clusters definidos pelo método são considerados ótimos e podem ser coletados com a utilização de um veículo dedicado;
15. Dentre os pedidos de coletas que não pertencem a nenhum Cluster, é verificado a obrigatoriedade da realização da coleta;
16. Caso haja algum pedido em  $C_o$  para ser coletado, é enviado um veículo fracionado;
17. Após todas as verificações, os pedidos de coletas restantes são armazenados e o *Framework* é utilizado novamente no dia seguinte, com os novos pedidos de coleta recebidos acrescentados aos pedidos restantes.

O passo 7 define primeiro a criação dos Clusters para então utilizar a API do Google Maps, isso se deve a alguns fatos.

- A API do Google Maps é paga e, portanto, era necessário desenvolver uma maneira de reduzir a quantidade de acessos a ela. A solução encontrada foi criar uma matriz diagonal superior e, então, espelhá-la para criar a matriz simétrica;

Figura 4.5.1 – Fluxograma resumindo o *Framework* desenvolvido.



- Pelo mesmo motivo de diminuição de custos, primeiro os Clusters são calculados e, apenas posteriormente, a API do Google Maps é acessada. Desse modo, ao invés

de se criar uma matriz com muitas linhas e colunas, são criadas várias matrizes de tamanhos menores, garantindo uma diminuição na quantidade de acessos à API;

- Além do custo econômico, também é possível apontar o custo computacional para a criação dos Clusters antes da utilização da API do Google Maps. Alguns testes foram realizados para verificar o tempo gasto para se criar primeiro os Clusters e, então, a matriz de distância e o tempo para definir uma matriz completa utilizando apenas a API do Google Maps. As comparações podem ser vistas na tabela 4.5.1

Tabela 4.5.1 – Comparações entre os tempos de acesso a API do Google Maps.

Quant. Coletas	Algoritmo Cluster	Matriz Completa
100	67.35	197.09
200	133.02	394.19
300	228.66	680.03
400	390.65	1182.24

#### 4.5.2 *Framework* Monoveículo

O *framework* monoveículo funciona de forma parecida com o multiveículo até o passo 7, após a criação da matriz de distâncias com a API do Goggle Maps, o algoritmo monoveículo se torna diferente e segue os próximos passos:

1. Executa o algoritmo de Dijkstra (Dijkstra, 2022) para encontrar o melhor caminho;
2. Os custos econômicos e os custos da emissão de  $CO_2$  são calculados com as mesmas equações do *framework* multiveículo;
3. São calculados os custos para cada um dos veículos capazes de realizar a rota e esses valores são utilizados para uma função de *fitness* em outro AG;
4. Esse AG é responsável apenas por escolher a melhor combinação rota/veículo e indicar ao usuário qual a melhor decisão.

Devido ao fato de que todo o algoritmo é dependente de ser encontrada a melhor rota, foi necessário avaliar a capacidade do algoritmo de Dijkstra criado de encontrar a melhor solução. Para tanto, foram utilizados outros algoritmos e os resultados obtidos foram comparados.

Os algoritmos utilizados para essa avaliação foram Tabu Search, Colônia de formigas, Algoritmo Genético, Simulated Annealing e um algoritmo de Força Bruta (Valdecy, 2024).

A principal desvantagem dessa segunda abordagem é limitar ao tomador de decisão a utilizar apenas um veículo, o que nem sempre acarreta a melhor solução. Por outro lado, esse algoritmo tende a ser mais rápido, pois realiza menos processamentos.

A próxima seção explica algumas restrições utilizadas nesse trabalho, visto que implementar todos os detalhes de uma LR tornaria o trabalho extenso, complexo e, possivelmente, inviável.

## 4.6 Restrições para o trabalho

Como mostrado ao final da seção 2.4, é preferível que o modelo de GD seja leve para diminuir custos e poupar tempo na construção e no processamento (Kuehn, 2018). Portanto, para isso, foram criadas algumas restrições e suposições para esse trabalho.

1. Para o cálculo de distância entre as cidades, serão consideradas as latitudes e longitudes definidas pela biblioteca GeoPy (GeoPy Developers, 2024);
2. Existe apenas um centro de reciclagem, situado em uma cidade do estado de São Paulo, seu estoque é grande o suficiente e existem múltiplos veículos terceirizados e próprios de diferentes modelos que realizam as coletas;
3. Cada veículo possui diferentes cargas nominais, porém os custos para a empresa contratante são fixos, baseando-se apenas no tipo de veículo;
4. A quantidade coletada não excede a capacidade do veículo;
5. Cada veículo tem um limite de tempo de trabalho diário de seu motorista, que são de oito horas;
6. O combustível utilizado em veículos Flex é gasolina e o óleo diesel é utilizado em outros veículos;
7. Considera-se, para efeitos de estudo de veículos dedicados, que na primeira coleta o veículo encontra-se vazio;
8. Para o estudo das coletas será utilizado o período dos dias anteriores (D-1 a D-5), ou seja, em um dia D serão avaliados todos os pedidos de coletas realizados nos últimos cinco dias e que ainda não foram coletados anteriormente;
9. De forma a simplificar o modelo, não será levado em consideração as características da rota para a escolha do tipo de veículo. Por exemplo, não será modelado se um veículo de grande porte poderá realizar a coleta em uma via estreita;
10. Um estudo realizado utilizando-se os dados reais fornecidos pela empresa, demonstrou que o local que mais realiza pedidos de coleta é o estado de São Paulo. Por esse motivo, esse estado foi escolhido para a validação do *Framework*. Futuramente este estudo poderá ser expandido para outros locais;

11. Como o estudo será concentrado em um único estado, apenas transportes terrestres serão considerados em um primeiro momento;
12. De forma a poder calcular a quantidade de horas de trabalho dos motoristas dos veículo, será considerado um tempo de 5 minutos para se realizar uma coleta. Ou seja, se uma viagem de um ponto de coleta a outro possui duração de 1h, o tempo total da viagem, realização da coleta e armazenamento do produto no veículo é de 1:05h. Esse tempo também poderá ser alterado durante os cenários desenvolvidos no software FlexSim.

## 4.7 Utilização do módulo GIS do software FlexSim como Gêmeo Digital

O módulo GIS do software FlexSim foi introduzido a partir da versão 2021b do programa, lançado no segundo semestre do ano de 2021. De acordo com o próprio fabricante, com esse módulo é possível modelar cadeias de suprimentos, logística e qualquer outro tipo de transporte nos quais o tempo e a distância da viagem sejam fatores fundamentais.

Para a criação do mapa foi utilizada a biblioteca geoPy (GeoPy Developers, 2024) do Python, com ela é possível, para cada coleta, descobrir suas respectivas coordenadas geográficas. Para a criação do mapa foi utilizada uma planilha com as cidades, fornecida pela empresa, cujas respectivas coordenadas geográficas foram obtidas a partir da biblioteca geoPy.

Com as coordenadas geográficas, os dados foram inseridos no FlexSim e o mapa com as coletas no estado de São Paulo foi montado. O mapa, mostrado na Figura 4.7.1 possui um exemplo de coletas e rotas. Para evitar sobrecarga de dados e possível travamento do modelo, as rotas entre elas são geradas somente no momento em que o Cluster, definido pelos pontos azuis é criado.

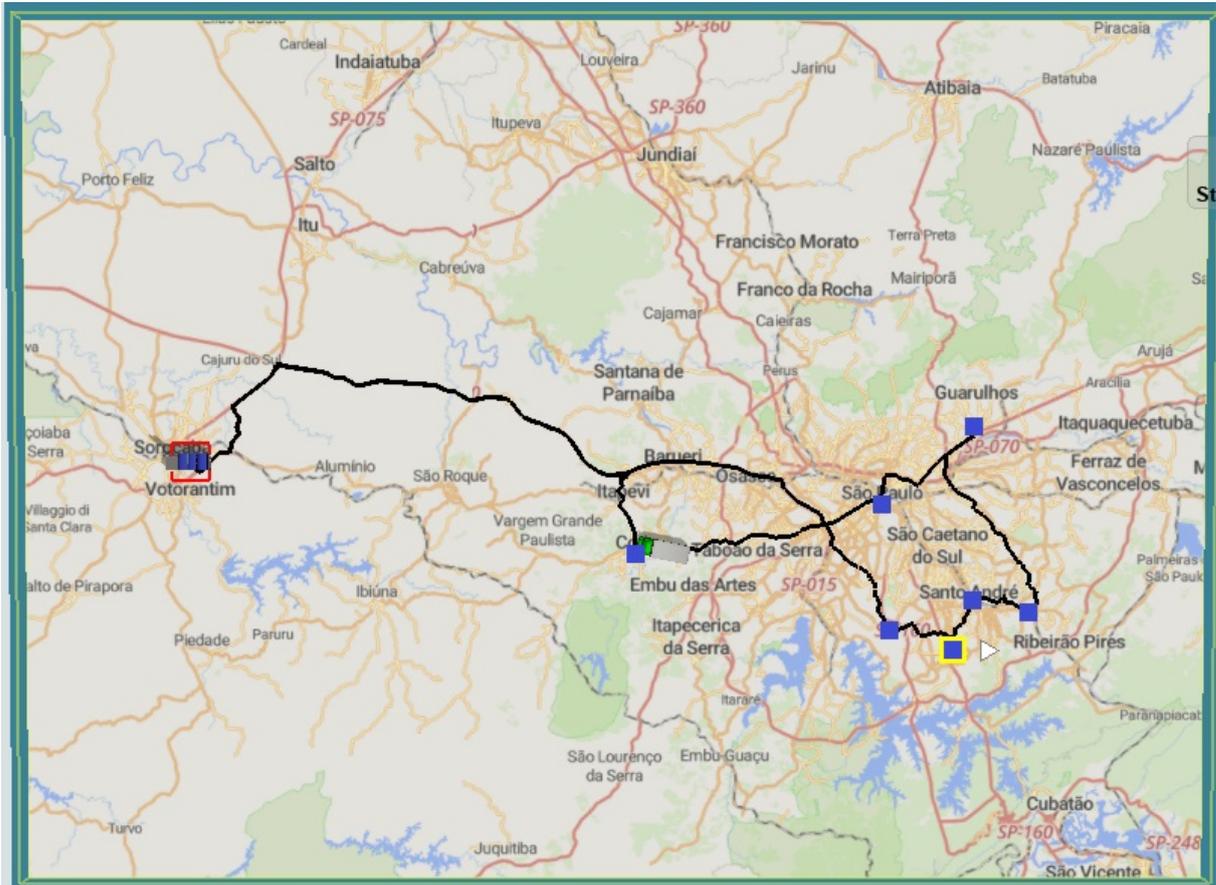
Os dados históricos são utilizados para a criação do modelo de simulação e também para o modelo do Algoritmo Genético, usado na otimização necessária para a realização deste trabalho.

## 4.8 Algoritmo Genético

A Seção 2.7 explicou o funcionamento do algoritmo genético e esta Seção mostrará como ele foi criado para a otimização do problema definido. Primeiramente serão descritos os parâmetros do AG, como a função de *fitness* e os parâmetros de entrada e, então, serão demonstradas cada uma das equações utilizadas para calcular os valores necessários à otimização.

Os valores que devem ser otimizados e vão compor a função de *fitness* deste trabalho são: custo de emissão de  $CO_2$  por viagem total (incluindo todas as coletas), menor custo

Figura 4.7.1 – Mapa do estado de São Paulo com uma das rotas nas quais houveram coletas nos anos de 2019 e 2020.



para realizar as coletas e maior quantidade de produtos coletados (em kg), além de, a princípio, minimizar o tempo de coleta, que deve ser menor do que 8h por Cluster. Futuramente estuda-se a possibilidade da utilização de valores como pernoite ou hora extra do motorista para serem integrados nos cálculos.

As variáveis a serem otimizadas possuem unidades de medidas diferentes e, portanto, foi necessário definir um método de normalização para transformar esses dados em uma escala comum, sem perder as relações entre os valores originais.

O método de normalização utilizado neste trabalho foi o Z-score (Patro, 2015), que transforma os dados para que se tenha uma média 0 e desvio padrão de 1. Essa transformação torna os dados comparáveis, sendo possível, então, utilizar a função de *fitness* sem problemas com as unidades de medidas diferentes.

Como definido na Seção 2.7, o AG funciona calculando as aptidões dos cromossomos através de uma função de *fitness*. Neste trabalho, a função criada busca minimizar a aptidão dos cromossomos, visto que é necessário encontrar a função que diminua custos. Para tanto, a função foi definida como maximização e, então, multiplicada pelo valor de 1 negativo, para transformá-la em uma função de minimização. Ela é mostrada na Eq 4.2 e a definição dos pesos utilizados na função será explicada na Seção 4.9.

$$fitness = -(10 * custo\_total - 2 * peso + 10 * tempo + 5 * emiss\tilde{a}oCO_2) * prioridade \quad (4.2)$$

O `custo_total` é definido na Seção 4.8.2, o peso é o total somando-se todas as coletas de um Cluster, a variável tempo contém o tempo gasto para coletar todos os produtos em um Cluster, adicionando o tempo de 5 minutos para realizar cada uma das coletas e o custo da emissão de  $CO_2$  é explicado na Seção 4.8.1.

#### 4.8.1 Custo de Emissão de $CO_2$

Para realizar o cálculo de emissão de  $CO_2$  será utilizada uma adaptação da fórmula mostrada em (Gao *et al.*, 2021), que foi desenvolvida para modelos multi veículos. Essa adaptação foi necessária, pois na equação original, levava-se em consideração a possibilidade de haver mais de um veículo do mesmo tipo, uma suposição que não será assumida neste trabalho.

Desse modo, é calculado cada emissão separadamente e antes de serem adicionados à função de *fitness* cada uma delas é somada. A Eq 4.3 calcula o custo da emissão de  $CO_2$  para modelos multi veículos.

$$E_{CO_2} = \sum_{m=0}^M \sum_{k=1}^{K_m} \sum_{i=0}^N \sum_{j=0}^N \omega * C_1^m * X_{ij}^{mk} * d_{ij} * \rho(q_{ki}) \quad (4.3)$$

A Seção 4.3 define as variáveis utilizadas nas equações, porém segue uma breve explicação sobre a Eq. 4.3. As variáveis  $i$  e  $j$  definem dois pontos de coletas, Cidade1 e Cidade2, por exemplo, e  $N$  é a quantidade total de cidades. Portanto, Os dois primeiros somatórios indicam que serão percorridas as  $N$  cidades duas a duas. O valor de  $k$  indica a quantidade de veículos de cada tipo  $M$ .

Então é possível definir a Eq 4.3 como os somatórios de cada tipo de veículo e de suas quantidades percorrendo pares de locais de coletas. A variável  $\omega$  é o fator de emissão de  $CO_2$ ,  $C_1^m$  é o custo de cada um dos veículos,  $X_{ij}^{mk}$  é uma variável binária que indica se a quantidade  $k$  de veículos tipo  $m$  realiza essa coleta,  $d_{ij}$  define a distância entre as cidades  $i$  e  $j$ , e  $\rho$  é uma função linear calculada utilizando a distância, consumo de combustível e peso do veículo, essa função é mostrada na Eq 4.5.

Como neste trabalho será utilizado apenas um tipo veículo por vez, a equação pode ser simplificada para a Eq 4.4.

$$E_{CO_2} = \sum_{m=0}^N \sum_{i=0}^N \sum_{j=0}^N \omega * C_1^m * d_{ij} * \rho(q_{mi}) \quad (4.4)$$

Todas as variáveis foram definidas na seção 4.3 com exceção de  $\rho$ , que é uma função linear relacionada ao consumo de combustível por unidade de distância e peso, e calculada utilizando a fórmula 4.5:

$$\rho(q_{mi}) = \rho_0 + \frac{(\rho^* - \rho_0)}{Q_m} * q_i \quad (4.5)$$

Com  $\rho_0$  sendo o consumo do veículo vazio,  $\rho^*$  é o consumo do veículo cheio,  $Q_m$  a capacidade total do veículo e  $q_i$  é a carga do veículo no momento em que ele chega na coleta  $i$ . Por exemplo, em sua primeira coleta, o peso do veículo é igual a  $\rho_0$ , a segunda coleta, o peso se torna  $\rho_0 + peso\_coletado$ .

#### 4.8.2 Custo total da viagem

O custo da viagem utilizado para definir o melhor Cluster é baseado na distância entre as coletas e o tipo de veículo, pois o valor do aluguel de cada um deles varia de acordo com o tamanho. No modelo serão inseridos os valores reais dos alugueis pagos pela empresa utilizada como objeto de estudo, foi calculado o custo por quilômetro percorrido com cada veículo.

Além do custo do veículo, também será levado em consideração o custo do motorista para a empresa, o custo de um ajudante para realizar a coleta e o valor dos impostos. Ao final, a equação utilizada para calcular o custo de uma viagem pode ser definida em Eq 4.6.

$$C_{ij} = (valor\_por\_km * d_{ij} + custo\_motorista + custo\_ajudante) * 1.0355 \quad (4.6)$$

#### 4.8.3 Tempo total da viagem

O tempo da viagem pode ser calculado utilizando-se a velocidade média de cada veículo, a quantidade de coletas que ele irá realizar e o tempo necessário para realizar a coleta (ser atendido pelo cliente, receber o produto e acomodá-lo no veículo) e, para converter o tempo em horas, foi realizado a divisão por 60 minutos. A Eq 4.7 mostra como o tempo foi calculado.

$$T_{ij} = (d_{ij}/velocidade\_media + quant\_coletas * tempo\_coleta)/60 \quad (4.7)$$

#### 4.8.4 Função *Fitness*

A função *fitness* é a função que se deseja maximizar ou minimizar, dependendo do problema em questão. Ela pode receber valores com unidades de medidas diferentes contando que seja realizada uma normalização dos dados para transformá-los em uma mesma escala, tornando-os comparáveis. Apenas após essa normalização, é possível utilizá-los no AG para realizar a otimização.

Os dados utilizados para a função de *fitness* são custo para coleta, peso coletado, tempo gasto, o custo de emissão de  $CO_2$  e a prioridade de coleta de cada Cluster. Com exceção das prioridades, os outros dados são calculados com base na resposta dada pela biblioteca pyVRP. Essa resposta é recebida na forma de dois vetores, um vetor de distância e um vetor de rotas, ambos contendo o mesmo comprimento sendo correlacionados, a distância é

baseada na rota calculada pelo pyVRP a partir do ponto inicial, que é a empresa estudada. A seguir é possível notar um exemplo de resposta do modelo.

$$\begin{aligned} \text{distancias} &= [218.45, 127.12, 58.40] \\ \text{rotas} &= [[3], [2, 4, 7, 1], [5, 6]] \end{aligned}$$

Dessa forma, o AG define os veículos que irão percorrer cada uma das rotas. Por exemplo, um veículo irá percorrer a rota que sai do centro de reciclagem, vai à coleta 3 e retorna ao centro, percorrendo uma distância de 218,45km. Outro veículo irá partir do centro de reciclagem, percorrerá as cidades 2, 4, 7 e 1 e retornará ao centro, totalizando 127,12km. O mesmo ocorre com o veículo 3, que percorrerá quase 59km, saindo do centro, passando pelas cidades 5 e 6 e retornando com os produtos coletados. A Figura 4.8.1 resume as coletas utilizadas nesse exemplo.

Figura 4.8.1 – Interface criada para o *Fremakework* monoveículo.



Então os custos são calculados utilizando-se a equação Eq 4.6 e as respostas enviadas para a função de *fitness*, demonstrada na equação Eq 4.8. Vale ressaltar que os dados (custo, custo de emissão, tempo e peso) possuem unidades de medidas diferentes e, portanto, foi necessário fazer uma normalização dos dados utilizando o normalizados Z-score. A forma como o AG define o veículo e realiza os cálculos é mostrado na Seção 4.9.

$$\text{fitness} = - \sum_{k=0}^{M_1} \sum_{i=0}^n \sum_{j=1}^n P_c * C_{ij}^k - \sum_{k=0}^{M_1} \sum_{i=0}^n \sum_{j=1}^n P_{eco2} * Eco_{2ij}^k + \sum_{i=0}^n P_P * P_i - \sum_{i=0}^n P_T * T_i \quad (4.8)$$

Sendo  $C_{ij}^k$  o custo para o veículo k realizar a rota da coleta i até a coleta j,  $Eco_{2ij}^k$  o custo da emissão de  $CO_2$  para o veículo k do ponto i ao ponto j,  $P_i$  o peso coletado no ponto i e  $T_i$  o tempo para realizar a coleta nesse mesmo ponto. Além disso, define-se  $P_c, P_{eco2}, P_P$  e  $P_T$  como sendo, respectivamente, os pesos para o custo, emissão, peso coletado e tempo de coleta.

## 4.9 O Algoritmo Genético

Antes de demonstrar a lógica do AG, é necessário definir as variáveis que serão utilizadas. Como descrito na Seção 2.7, o AG necessita de alguns parâmetros para funcionar, como número de gerações, taxa de *crossover*, taxa de mutação e valores dos pesos.

Para definir os parâmetros, foi feito um planejamento de experimentos, mostrado na Seção 3.3, que utilizou valores diferentes para avaliar os melhores parâmetros. Após o DOE foram definidos o número de gerações, a taxa de *crossover* e de mutação, e os pesos para cada uma das variáveis utilizadas na função de *fitness*. Os valores definidos são:

- Número de gerações - valores de 100, 300 e 500;
- Taxa de *crossover* - valores de 0.7, 0.8 e 0.9;
- Taxa de mutação - valores de 0.1, 0.2 e 0.3;
- Pesos -  $P_c = 10$  ou 2,  $P_{eco2} = 0.2$  ou 2,  $P_p = 1$  e  $P_T = 10$  ou 2

Após a análise dos experimentos, os dados que permitiram que o AG obtivesse melhor resultado foram 300 gerações, 0.9 de taxa de *crossover*, a taxa de mutação foi de 0.1.

Da mesma forma foi realizado um DOE (*Design of Experiments*) para verificar os melhores pesos para a função *fitness*. Os pesos testados foram de 2, 5 e 10 para cada uma das variáveis. Após a análise, foi verificado que os pesos que forneciam o melhor resultado foram:

- 10 para o peso do custo;
- 2 para o peso do peso coletado;
- 10 como o peso do tempo da coleta;
- 5 como peso da emissão de  $CO_2$ ;

Para os testes foram utilizados três veículos, isso significa que, entre os 7 disponíveis, o algoritmo poderia escolher 3. Essa escolha de 3 veículos compõe um cromossomo e o conjunto de 100 cromossomos é a população do AG desenvolvido. Cada cromossomo é criado de forma aleatória, criando vários vetores de valores binários, sendo 1 para um veículo realizar a coleta e 0 para um veículo não realizar a coleta. É necessário que cada vetor possua exatamente três valores 1 e quatro valores 0.

$$\text{cromossomo} = [0, 1, 1, 0, 0, 1, 0]$$

A quantidade de vetores criados é equivalente a quantidade de Clusters definidos. Considerando, por exemplo, 30 Clusters em um grupo de coletas, a quantidade de elementos criados para a população será de 30 vetores para cada cromossomo e 100 cromossomos, ou seja, nesse caso são utilizados 3000 vetores para definir a população. Assim como a população, as distâncias definidas pelo pyVRP também conterão 30 vetores, portanto é possível utilizar um vetor de distância para cada conjunto de veículos, resultando em 30 valores de aptidões que serão somados, calculando a aptidão para cada cromossomo.

Utilizando agora os dados do exemplo na Seção 4.8.4, é possível definir os veículos e as rotas para realizar os cálculos necessários à função de *fitness*:

$$\begin{aligned} \text{distancias} &= [218.45, 127.12, 58.40] \\ \text{rotas} &= [[3], [2, 4, 7, 1], [5, 6]] \end{aligned}$$

O AG entende que o primeiro veículo não irá realizar nenhuma coleta, o segundo veículo irá realizar a coleta que sai do ponto 0 e vai ao ponto 3 e tem distância de 218.45km, o veículo 3 irá realizara segunda coleta que sai do ponto 0, passa pelos pontos 2, 4, 7 e 1 e volta ao ponto 0, com distância de 127.12km e assim sucessivamente.

Cada cromossomo da população possui seu próprio valor de aptidão, calculado a partir da função de *fitness* 4.2 e, após calcular todos os 100 valores, o algoritmo ordena a população, em ordem crescente, de acordo com a aptidão de cada um. Os melhores indivíduos irão realizar o *crossover*, com uma probabilidade de 0.9 de ocorrer, que foi definido de duas maneiras sorteadas pelo algoritmo:

1. Calculando um ponto de *crossover*, dividindo os pais e realizando o cruzamento entre eles ou;
2. Trocando os dois pais completos entre si;

Dessa forma se garante que os *crossover* ocorrerão apenas entre veículos dentro de um mesmo Cluster, evitando que os Clusters se misturem, como mostrado abaixo. Desse modo, os *crossover* só ocorrem entre possíveis resultados para um mesmo Cluster:

$$\text{Cromossomo1} = [1, 1, 1, 0, 0, 0, 0], [0, 1, 1, 0, 0, 0, 1], [0, 0, 1, 0, 1, 0, 1]...$$

$$\text{Cromossomo2} = [1, 0, 1, 1, 0, 0, 0], [0, 1, 0, 1, 1, 0, 0], [1, 1, 0, 0, 0, 0, 1]...$$

Após o *crossover*

$$\text{Cromossomo1} = [1, 0, 1, 1, 0, 0, 0], [0, 1, 1, 0, 0, 0, 1], [0, 1, 0, 0, 1, 0, 1]...$$

$$\text{Cromossomo2} = [1, 1, 1, 0, 0, 0, 0], [0, 1, 0, 1, 1, 0, 0], [1, 0, 1, 0, 0, 0, 1]...$$

Após realizado o *crossover*, ocorre a mutação, com uma taxa menor de 0.1. A mutação define se um gene (um valor binário dentro do cromossomo) será alterado ou não. Caso ocorra uma mutação, o valor 0 é transformado para 1 ou vice-versa.

Aqui vale ressaltar uma alteração na mutação. Ao se alterar um gene, a quantidade de veículos utilizados para as coletas é sempre alterada para 2 ou 4, pois um gene 0 pode se tornar 1, ou vice-versa. Para resolver esse problema, toda mutação ocorre em pares. Quando um gene é alterado, outro gene é sorteado para que seja alterado, até que se tenha novamente 3 números 1 no vetor de veículos.

Após as 300 gerações, o AG irá apresentar como resposta uma sequência de vetores ótimos com os possíveis veículos para se realizar as coletas em cada Cluster.

A próxima Seção define os objetos de estudo utilizados para testar o *Framework* criado neste trabalho, mostrando alguns dados dos veículos utilizados para o modelo.

## 4.10 Objetos de Estudo

### 4.10.1 Considerações Iniciais

Para este trabalho foram utilizados dados históricos de coletas de 2019 e 2020 de uma empresa especializada em remanufatura de produtos eletrônicos, localizada no estado de São Paulo. Devido ao fato de que a empresa terceiriza toda a coleta dos produtos no fim da vida, ela possui alguns problemas como divergências entre o valor estimado para a coleta e o valor posteriormente cobrado e problemas com o tipo de veículo enviado para realizar a coleta.

A empresa possui todo o processo da GVCS bem definido, desde a chegada do produto até a sua desmontagem para reutilização ou reciclagem e também lida com a venda de produtos remanufaturados, além de fabricar produtos novos para empresas parceiras. Porém, o maior problema para a empresa ainda se concentra na coleta dos produtos dos usuários finais.

Os valores de frete são confidenciais e, portanto, são inseridos somente no modelo do GD, porém os veículos utilizados, bem como suas capacidades e gasto de combustível são mostrados na Tabela 4.10.1.

Tabela 4.10.1 – Medidas dos veículos utilizados para coleta de produtos

Medidas de Veículos							
Medidas	Fiorino	Van	.3/4	VUC	Toco	Truck	Carreta
Capacidade $M^3$	3	9	20	22	46	50	95
Capacidade peso (Kg)	500	1500	3500	3500	7000	12000	25000
Capacidade Peso Cubado	900	2700	6000	6600	13800	15000	28500
Consumo de Combustível com veículo vazio (Km/L)	12	9.1	8	6.2	5.5	5.10	4.01
Consumo de Combustível com veículo cheio (Km/L)	9.6	7.28	6.4	5.00	4.75	2.50	1.47
Comprimento	1.9	2.95	4.45	4.3	7	7.5	14
Largura	1.09	1.7	2.1	2.3	2.5	2.5	2.5
Altura	1.4	1.8	2.14	2.2	2.65	2.7	2.6

Ambos os estudos de caso criados utilizam dados semanais. Isso significa que cada teste foi realizado em uma semana e cada semana possuía uma quantidade de coletas realizadas. No total, foram usadas 2.305 coletas para os testes, divididas em dez semanas, as quantidades estão indicadas na tabela 4.10.2. Essas coletas possuem alguns dados importantes para a criação do algoritmo:

- Local da coleta - utilizado para encontrar as coordenadas geográficas do local de coleta para se realizarem os cálculos;
- Capital ou interior - o custo das rotas fracionadas são divididas nessas duas categorias, coletas realizadas na capital possuem custos menores que as realizadas no interior;
- Data da coleta - utilizada para definir a prioridade da coleta, quanto mais antiga for a data da coleta, maior será a prioridade dela;
- Peso estimado - estimativa do peso da coleta que será realizada;
- Valor + impostos - valor real pago pela empresa. Esse valor é utilizado apenas durante a validação do *Framework* e não é utilizado no cálculo;

Após os testes utilizando os dois estudos de caso, foram realizadas comparações para verificar se havia alguma diferença entre utilizar apenas uma rota e dividir em várias rotas que serão coletadas de forma simultânea por veículos diferentes.

#### 4.10.2 Objeto de Estudo I - *Framework* Monoveículo

O estudo com esse *framework* monoveículo era o estudo original imaginado para este trabalho. No entanto, após a criação do algoritmo foi verificada a necessidade de expansão para o cálculo com vários veículos. Desse modo, foram criados os dois estudos para que seja possível comparar as respostas de ambos.

O primeiro estudo com o *framework* monoveículo se diferencia do segundo por levar em consideração apenas um veículo a cada momento e, conseqüentemente, apenas uma rota considerada ótima. Nesse caso foi utilizado o algoritmo de Dijkstra (Dijkstra, 2022) para definir a menor distância em cada um dos Clusters que podem ser criados em cada semana.

Para cada Cluster criado, todos os veículos que podem realizar a coleta nele são testados, resultando em uma matriz que contém os seguintes dados: O veículo, o custo para ele realizar a coleta, o peso coletado no Cluster, o tempo para percorrer a coleta, o custo da emissão de  $CO_2$  para cada veículo e a distância da rota. Os valores referentes ao consumo e carga dos veículos e as equações utilizadas para os cálculos são os mesmos demonstrados nas seções 4.8 e 4.10.1

Essa matriz é enviada para outro AG que calcula as melhores soluções para cada Cluster. No entanto, diferente do *Framework* multiveículo, o AG define os melhores valores para cada uma das variáveis estudadas (custo, peso, tempo e custo de emissão). Dessa forma, o usuário pode escolher qual variável deseja estudar.

Por exemplo, caso o usuário selecione o custo, o AG irá retornar qual combinação Cluster/veículo possui o menor custo para a empresa, esse Cluster e esse veículo são os sugeridos para a coleta. Um exemplo de resposta do AG para a semana 10 é mostrado, nele é possível verificar o custo do Cluster, o veículo utilizado para a coleta, qual o Cluster dentro dessa semana será realizada a coleta (Cluster 9), a quantidade de cidades e a distância total para percorrê-las.

$$[[3733,66],[Carreta],[9],[13],[396,457]]$$

A quantidade de semanas e de Clusters criados, assim como no *Framework* multiveículo, seguem a tabela 4.10.2. A principal diferença é que a população do AG multiveículo é formada por dois vetores, um vetor de distância e um vetor binário que identifica os veículos utilizados na coleta. Por outro lado, no AG monoveículo, a população é formada pelo cruzamento de todos os Clusters com os veículos capazes de realizar a coleta.

Desse modo, a população do primeiro *Framework* é sempre fixa em 100 indivíduos, mas a população do segundo varia de acordo com a quantidade de Clusters criados e a quantidade de veículos que podem realizar as coletas.

Por exemplo, se o primeiro Cluster puder ser coletado pelos veículos 5 e 6, haverá dois indivíduos para o Cluster 1 (Cluster 1/ veículo 5 e Cluster 1/ veículo 6). Cada indivíduo irá possuir o valor calculado, o peso coletado, o tempo para a rota e o custo da emissão de  $CO_2$ , como no exemplo abaixo.

$$\text{Indivíduo 1} = [1483.03, 4094.15, 6.42, 13.33]$$

$$\text{Indivíduo 2} = [1648.13, 4094.15, 6.42, 21.63]$$

### 4.10.3 Objeto de Estudo II - *Framework* Multiveículo

O segundo estudo foi realizado com o *framework* multiveículo. Foram realizados testes utilizando até três veículos simultaneamente e as melhores rotas foram definidas com o auxílio do AG para solucionar problemas de caixeiro viajante múltiplo encontrado em Valdecy, 2024.

Apesar do AG ser uma metaheurística mais eficiente que outros métodos de otimização, o problema do caixeiro viajante é um problema NP-hard que cresce exponencialmente. Para este trabalho a maior quantidade de cidades testadas foram 16. Isso significa que, até 16 cidades e 3 veículos simultâneos, o *Framework* é capaz de encontrar uma solução. Para valores maiores do que esses, são necessários mais testes para verificar se o método é capaz de ser solucionado em um tempo computacionalmente viável.

Assim como no primeiro estudo, neste também foram realizados testes em dados de coletas durante 10 semanas, totalizando 2.305 coletas. Este *framework* retorna, como resposta, todos os possíveis Clusters criados para cada uma das semanas, sendo assim, ele define os veículos necessários para se realizar as coletas de cada um dos agrupamentos.

A tabela 4.10.2 mostra as quantidades de coletas e Clusters criados em cada uma das semanas estudadas.

Tabela 4.10.2 – Coletas utilizadas para realizar os testes.

Semana	Quantidade de coletas	Quantidade de Clusters
1	62	3
2	118	9
3	205	13
4	102	7
5	303	19
6	269	12
7	285	13
8	274	17
9	288	16
10	399	17

Após a definição dos Clusters, um segundo AG é executado para encontrar as melhores soluções para cada um desses agrupamentos. A população inicial para esse AG é de 100 valores e cada elemento contém  $C*2$  vetores, com  $C$  sendo a quantidade de Clusters criados para essa semana.

Esses vetores são combinações de distâncias e veículos, ou seja, ao criar a população, as distâncias são embaralhadas e um vetor é criado. Então um vetor binário de veículos também é criado contendo exatamente três veículos. Esse vetor, assim como o primeiro, é aleatório, e garante uma variedade de indivíduos para o início do AG. Como um exemplo de população, é possível ter a seguinte combinação de indivíduos.

Indivíduo 1 =  $[[0, 289.41, 87.43], [0, 0, 1, 1, 1, 0, 0], [0, 266.30, 97.29], [1, 1, 1, 0, 0, 0, 0] \dots]$

Indivíduo 2 =  $[[289.41, 0, 87.43], [0, 1, 0, 1, 0, 1, 0], [266.30, 97.29, 0], [0, 1, 1, 0, 0, 1, 0] \dots]$

As respostas são dadas no formato de uma matriz e dois vetores: a matriz possui os vetores com as rotas, os vetores contém as distâncias para cada uma das rotas e os veículos que serão utilizados para cada uma delas, como no exemplo mostrado abaixo.

$[[0, 2, 1, 0], [0, 4, 5, 0], [0, 3, 0]], [238.0, 270.5, 107.1], [0, 1, 1, 0, 1, 0, 0]$

As rotas e as distâncias um, dois e três, serão percorridas pelos veículos 1, 2 e 3. Esses veículos são representados pelo valor 1, o vetor de veículos e seguem a ordem mostrada

na tabela 4.10.1. Sendo assim, no exemplo demonstrado, a resposta ótima seria a Van coletar a rota 1, o .3/4 a rota 2 e o Toco a rota 3.

Para calcular, então, os custos e as emissões de  $CO_2$ , como mostrado nas equações 4.6 e 4.4, basta utilizar os valores definidos na tabela 4.10.1 para cada um dos veículos que irão realizar as coletas, juntamente com as distâncias das rotas 1, 2 e 3.

Após a definição das rotas ótimas, elas são enviadas para o FlexSim para que sejam simulados cenários com imprevistos que podem ocorrer durante o trajeto. As probabilidades desses imprevistos ocorrer é pequena, portanto serão inseridas no modelo simulação distribuições de probabilidades com parâmetros que permitem que os imprevistos ocorram com baixa frequência.

Os imprevistos podem ser:

- Pneu furado - tempo necessário para troca de pneu;
- Problemas mecânicos leves - problemas que podem ser resolvido facilmente e, apesar de atrasar a rota, não interferem nas entregas;
- Problemas mecânicos graves - problemas que não permitem que o veículo prossiga com a rota designada;
- Tráfego - problemas que fazem com que o veículo não possa seguir viagem momentaneamente, como acidentes, manutenção de estradas, entre outros;
- Problemas de acesso ao destino - problemas não modelados nesse *framework*, como vias estreitas nas quais o veículo não pode entrar, vias interditadas ou vias de mão única;
- Emergências pessoais - emergências que podem ocorrer com o motorista ou o ajudante;
- Coletas infrutíferas - um problema muito comum enfrentado pela empresa, ocorre quando o motorista chega ao destino, porém não há ninguém para realizar a entrega do produto.

## 4.11 Considerações Finais

Esse capítulo mostrou o *framework* criado, bem como as ferramentas utilizadas para a realização deste trabalho. Além disso, foram descritas as restrições impostas para o trabalho, as variáveis e as equações utilizadas para otimizar o problema proposto, bem como o funcionamento do Algoritmo Genético.

O próximo capítulo traz os resultados encontrados e mostra possíveis trabalhos futuros que podem ser continuados a partir deste.

## 5. Resultados

### 5.1 Considerações Iniciais

Neste capítulo serão apresentados os resultados do estudo. Primeiramente, serão mostrados os dados obtidos do estudo multiveículo com gráficos e comparações com relação aos valores pagos pela empresa. Então serão descritos os valores obtidos do estudo monoveículo. Por fim, serão realizadas comparações entre os dois métodos criados, a fim de verificar se houve diferenças significativas entre ambos.

Vale ressaltar que, apesar dos valores pagos pela empresa serem confidenciais, os valores apresentados aqui serão a soma de todas as coletas de um Cluster. Portanto, não será possível identificar corretamente os valores pagos de forma individual em cada coleta, apenas a soma de todos os valores.

Como descrito anteriormente, para o estudo foram utilizadas coletas referentes a 10 semanas, resultando em um total de 2.305 coletas. Elas geraram 126 Clusters para serem coletados e eles foram otimizados pelo AG criado.

O AG foi executado 10 vezes para cada uma das semanas, e os resultados foram inseridos no software Minitab para verificar o poder dos testes e, futuramente, as diferenças estatísticas entre os valores calculados e os valores pagos pela empresa. Como não havia desvio-padrão conhecido, o teste selecionado para se realizar no Minitab foi o *one sample t*, com a hipótese nula sendo a de que os valores calculados são menores do que os valores pagos pela empresa.

Segundo o software Minitab, para todos os testes, a quantidade de 10 amostras foi o suficiente para se ter um poder alto, cerca de 98%, portanto a quantidade de amostras é considerada suficiente. O teste utilizado para se verificar o poder da amostra foi o *One-sample t*, pois eram conhecidos os valores encontrados e havia apenas uma amostra (amostras do multiveículo ou do monoveículo).

No entanto, ao realizar os testes, foi constatado um desvio-padrão alto, isso indica dados mais dispersos e uma incerteza maior com relação à eles. Então foram realizados testes com 50 amostras, a fim de diminuir o valor desse desvio-padrão.

Após alguns testes serem refeitos, foi verificado que, tanto para 10 quanto para 50 amostras, os resultados não possuíam diferença estatisticamente significante e a escolha de utilizar apenas 10 amostras foi feita levando em consideração o tempo para executar cada um dos testes e a pouca diferença no desvio-padrão das amostras e, em alguns casos, o desvio-padrão aumentou.

Em relação ao tempo de execução, para 10 amostras em um teste foi necessário em média 29,06 minutos, para 50 amostras, o tempo médio foi de 85,46 minutos. Já a média das 10 amostras na semana 10 foi 587,18, enquanto a média para 50 amostras nessa mesma

semana foi de 629,55.

Como o teste *One-sample t* do Minitab indicou que testes com 10 amostras possuíam um poder alto e a diferença de tempo entre executar 10 ou 50 amostras é muito alta, é possível justificar o motivo da utilização de apenas 10 amostras nos testes.

## 5.2 Interface

Esta seção mostra as interfaces criadas para o trabalho. Primeiramente são definidos os componentes de cada uma delas e então explicado como elas funcionam. Após as explicações, uma imagem delas é mostrada, de modo a deixá-las mais compreensível.

Ambas as interfaces são divididas em quatro áreas: inserção da planilha; Clusters e veículos sugeridos; resultados; botão de coleta. A maioria dos elementos estão presentes nas duas interfaces, como a seleção de planilha, outras são diferentes, como o componente que mostra os veículos sugeridos. Dessa forma, todos os componentes serão definidos na próxima seção e os elementos exclusivos do modelo multiveículo são mostrados na seção [5.2.2](#).

### 5.2.1 Interface Monoveículo

A área das planilhas possui um espaço para preencher o nome da planilha que será utilizada para realizar os cálculos. Há também dois botões: o botão selecionar abre a caixa de diálogo para realizar a seleção da planilha e o botão iniciar executa o código que realiza os cálculos.

A área que contém os Clusters e os veículos permite que o usuário selecione um dos Clusters criados pelo *Framework* e, então, uma lista com os veículos sugeridos para se realizar a coleta são impressos abaixo. Desse modo, é possível verificar qual veículo deverá percorrer cada uma das rotas.

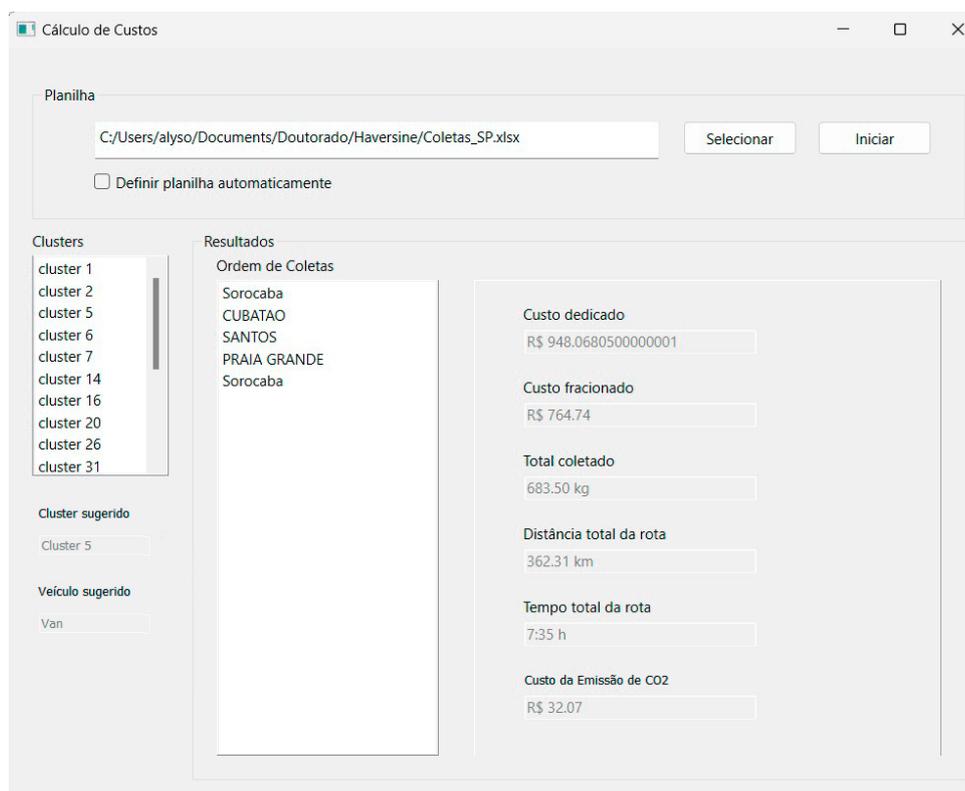
Nesta interface o usuário pode verificar o valor de qualquer outro Cluster quando é percorrido por qualquer veículo. Essa opção não é viável para o multiveículo, visto que existe uma grande quantidade de combinações de veículos e Clusters e calcular todos seria inviável.

Desse modo, o usuário escolhe a planilha a ser utilizada e inicia a execução do algoritmo. Na lateral esquerda da interface, há um espaço para a seleção dos Clusters e logo abaixo, o veículo e o Cluster sugerido para ser coletado.

No painel central há uma lista com as cidades dessa rota, bem como os valores de custos, tempo e distância. No painel lateral, o usuário pode selecionar qual Cluster deseja analisar e os dados do painel são alterados de acordo com o Cluster selecionado. Apenas os dados de rotas e Clusters sugeridos permanecem os mesmos, portanto o usuário pode comparar o resultado ótimo com outros resultados e tomar uma decisão de forma mais consciente.

Abaixo do painel central, também há um botão para indicar que a coleta foi realizada e deve ser retirada da planilha. A Figura 5.2.1 mostra a interface do *Framework* monoveículo, é possível notar que, no geral, ela é bastante parecida com a multiveículo e possui apenas algumas diferenças no painel lateral e central.

Figura 5.2.1 – Interface criada para o *Framework* monoveículo.



## 5.2.2 Interface Multiveículo

A interface multiveículo é bastante similar à monoveículo. A principal diferença é que ela mostra todos os Clusters com os custos de cada um deles.

O painel onde se encontram os resultados é o local onde se encontram a maior parte dos dados. Primeiramente, o usuário pode selecionar um dos Clusters disponíveis na lateral da interface. Ao ser selecionado, as listas com as cidades que estão contidas em cada uma das coletas pode ser lida.

Além das listas com as rotas, também é possível verificar um resumo delas. No topo da área há uma caixa na qual é possível selecionar qual rota será analisada e, então, os valores na lateral são alterados. Esses valores mostram alguns dados necessários para o usuário tomar sua decisão com maior certeza.

Na área lateral, são mostrados os valores calculados pelo *Framework*, o custo pago pela empresa, o peso coletado, a distância total da rota, o tempo total para coletá-la e o custo da emissão de  $CO_2$  para essa rota.

Por último, há uma quarta área que possui apenas um botão reservado para identificar se uma rota foi coletada ou não e, dessa forma, retirar esses dados da planilha. A Figura 5.2.2 mostra a interface criada para este trabalho.

Figura 5.2.2 – Interface criada para o *Framework* mutiveículo.

Resultados	
<b>Custo dedicado</b>	R\$ 1500,00
<b>Custo fracionado</b>	R\$ 2000,00
<b>Total coletado</b>	1000,00 kg
<b>Distância total da rota</b>	250 km
<b>Tempo total da rota</b>	7:35 h
<b>Custo da Emissão de CO2</b>	R\$ 12,70

As próximas seções mostram os resultados dos estudos de casos realizados.

### 5.3 Objeto de Estudo I - *Framework* Monoveículo

O primeiro estudo gera um resultado mais simples de ser interpretado do que o segundo. Isso se deve ao fato de que, apesar de problemas multiobjetivos levarem a uma fronteira de Pareto com várias soluções, o problema deste trabalho resolvido com AG, levou a resultados próximos, demonstrados na tabela 5.3.1, que indica intervalos de confiança relativamente pequenos. Portanto, para cada semana, esse estudo gerou respostas ótimas semelhantes, e isso facilita a interpretação dos resultados.

Os custos econômicos foram calculados e a Tabela 5.3.1 mostra os intervalos de confiança referentes ao *Framework* monoveículo. Para o cálculo desse intervalo, foram utilizadas as médias e desvios-padrão calculados, a amostra de 10 observações e o nível de confiança de 95%.

Ao contrário do custo, não é possível calcular a quantidade de  $CO_2$  que a empresa emitiu, pois não é possível definir qual veículo foi utilizado para as coletas já realizadas. Da mesma forma não há como definir o caminho realizado nem o peso do veículo em cada uma das coletas. Portanto, no resultado serão mostrados apenas as menores emissões de  $CO_2$  que estão atreladas ao menor custo encontrado.

Visto que os estudos foram realizados semanalmente, os resultados também serão analisados da mesma forma. Sendo assim, serão mostrados os Clusters que poderão ser coletados e um gráfico do tipo BoxPlot que auxilia na demonstração que os valores são estatisticamente menores do que os pagos pela empresa.

Como só é possível realizar a comparação do custo calculado com o custo que a empresa teve, a Tabela 5.3.1 mostra as coletas com menores custos e a conclusão retirada neste estudo será reafirmada após a conclusão do segundo estudo.

É possível notar que os melhores resultados foram os dos Clusters que possuíam maior quantidade de coletas e maior volume, bem como menores distâncias. A Tabela 5.3.1 mostra que os Clusters com melhores resultados possuem distâncias menores do que 400km no total e quantidade de coletas de até 15 cidades. Após verificar os resultados do segundo estudo, será possível afirmar se ambos os estudos são viáveis para Clusters próximos e com mais coletas.

Neste estudo, foram criados BoxPlots que permitem afirmar que os valores calculados são estatisticamente menores do que os valores pagos pela empresa, indicando que as coletas possuem uma grande chance de serem viáveis. Esses Gráficos são mostrados no Apêndice 8.3.

Tabela 5.3.1 – Resultados do objeto de estudo I.

Semana	Custo Médio (R\$)	Peso (Kg)	Custo Fracionado (R\$)	Veículo	Cluster	Tamanho	Distância (Km)	Economia (%)
1	[1717,30, 2080,56]	4094,15	3246,74	Truck	1	7	283,54	34% - 49%
2	[2271,52, 2600,98],48	7125,95	6234,04	Truck	13	12	346,59	57% - 86%
3	[2699,87, 3329,03]	12625,73	11538,15	Carreta	8	12	326,41	70% - 78%
4	[1819,28, 1995,70],48	3987,09	4165,07	Toco	4	9	290,92	51% - 57%
5	[3340,31, 3436,49]	15801,32	16598,48	Carreta	9	11	360,31	79% - 80%
6	[2755,67, 3427,89]	12973	11862,62	Carreta	3	13	336,07	70% - 78%
7	3284,59	13745,81	15049,15	Carreta	6	13	344,76	78%
8	[2963,44, 3338,08]	4519,75	17379,17	Carreta	5	15	336,89	80% - 83%
9	[2832,90, 3043,40]	3345,14	14198,21	Carreta	6	12	319,31	78% - 80%
10	[3446,39, 3779,53]	22666,16	17678,00	Carreta	8	12	388,13	78% - 81%

## 5.4 Simulação

De modo a complementar o GD e criar uma visualização da rota, foram criados modelos de simulação que permitiram, também, inserir imprevistos como pneu furado e abastecimentos. Assim foi possível verificar se uma rota, aparentemente viável, realmente é viável caso ocorra qualquer imprevisto.

Vale ressaltar que o FlexSim possui um banco de dados que recupera os tempos das rotas automaticamente. É possível realizar cálculos e fazer com que o tempo de coleta seja a distância dividida pelo tempo, mas é necessário possuir conhecimento avançado na ferramenta para fazê-lo. Isso torna esses cálculos inviáveis, visto que a maioria dos usuários do software não possuem esse conhecimento.

Os mapas e os gráficos resultantes do estudo após 200 replicações do modelo de simulação são mostrados na Seção 8.4. O modelo foi executado por um dia, tempo esse que é a restrição do modelo. Os modelos utilizaram apenas um veículo e os multiveículos serão sugeridos como trabalhos futuros.

A Figura 8.4.1 mostra o Cluster 1 da primeira semana, pois, como foi definido na Seção 5.3, esse é o Cluster sugerido para ser coletado nessa semana. Em todas as 200 replicações, o veículo conseguiu coletar todos os pedidos e descarregar na empresa, mesmo com os imprevistos que podem ocorrer, isso significa que ele é um Cluster viável e as porcentagens de utilização do veículo se encontram na Figura 8.4.4.

Nas semanas 2 e 3, o resultado foi um pouco diferente. De acordo com as 200 replicações das simulações, coletar nos Clusters sugeridos pode não ser viável. No primeiro caso, o veículo não descarregou seus produtos nenhuma vez e no segundo caso, foram descarregadas 33 vezes, isso significa que apenas em 16% das replicações, o veículo conseguiu terminar a rota completamente.

As Figuras 8.4.2 e 8.4.3 mostram os modelos das semanas 2 e 3, respectivamente, enquanto as Figuras 8.4.5 e 8.4.6 mostram os resultados obtidos a partir do software FlexSim. É possível notar que 0% do tempo o veículo foi ocupado com descarregamento, isso significa que ele não conseguiu realizar essa etapa nas replicações feitas.

Na semana 4 já foi possível assumir que o Cluster sugerido pelo AG é viável e pode ser coletado. Nele, todas as replicações resultaram em estados nos quais o veículo conseguia coletar todos os produtos. Isso significa que nessa semana, 100% das replicações indicaram que o veículo consegue realizar as coletas e retornar ao centro de reciclagem, com tempo de sobra. A Figura 8.4.7 mostra o modelo criado nessa semana e a Figura 8.4.10 mostra os resultados obtidos das simulações.

As semanas 5, 6 e 7 também obtiveram resultados negativos. Após as 200 replicações foram constatadas poucas coletas finalizadas completamente, indicando que, caso a manutenção do veículo não esteja feita corretamente e o risco de imprevistos seja alto, essas coletas não são viáveis.

A Figura 8.4.8 mostra a rota criada para a semana 5 e a Figura 8.4.11 mostra que 0% das vezes foram realizados descarregamentos, indicando que o veículo não foi capaz de chegar ao centro de processamento de resíduos.

As Figuras 8.4.9 e 8.4.12 mostram, respectivamente, a rota criada para a semana 6 e os resultados obtidos após as replicações dos cenários criados. É possível notar, também, que 0% das vezes foram realizados descarregamentos, mais uma vez um indicativo de que o veículo não chegou ao centro de reciclagem para realizar o descarregamento dos produtos coletados.

Como descrito anteriormente, a semana 7 também possuiu um resultado negativo e as Figuras 8.4.9 e 8.4.12 mostram, respectivamente, a rota criada para a semana 7 e os resultados obtidos após as replicações dos cenários criados. Mais uma vez, não foram realizadas quantidades relevantes de descarregamentos.

Nas semanas 8 e 10, os resultados também não foram tão bons, a quantidade de descarregamentos realizados foi baixa, indicando que, nas 200 replicações, o veículo não conseguiu completar as coletas em quase todas elas. A Figura 8.4.14 mostra o modelo criado para a semana 8 enquanto a Figura 8.4.19 mostra o modelo para a semana 10. Já as Figuras 8.4.17 e 8.4.20 trazem os resultados obtidos nos testes para as semanas 8 e 10, respectivamente.

Os testes realizados na semana 9 já trouxeram resultados melhores. Entre todas as replicações realizadas, apenas em 19 delas o veículo não conseguiu terminar completamente as coletas e descarregar os produtos. Isso é demonstrado pelo resultado constatado na Figura 8.4.18, que mostra que a porcentagem de tempo de descarregamento foi mais alta do que outros testes. Além disso, a Figura 8.4.15 mostra o modelo criado para essa semana.

As conclusões que podem ser obtidas a partir destas replicações é de que todos os Clusters são viáveis de serem coletados, levando-se em consideração que a manutenção do veículo esteja em dia. Esses dados não são informados neste trabalho, porém, o responsável por tomar a decisão de realizar a coleta ou não, possui a informação sobre a manutenção do veículo.

Em suma, a Simulação é capaz de permitir que sejam feitos testes que não são possíveis de serem realizados em outros softwares. Esta seção mostrou que, após a utilização do software FlexSim e a criação de cenários, 30% dos Clusters criados podem ser considerados viáveis.

Por outro lado, os outros 70% dos Clusters podem necessitar de horas extras ou outros custos que não são definidos nesse trabalho e, portanto, precisam ser estudados pelo tomador de decisão para definir se a coleta deve ser realizada ou não.

De modo a facilitar a visualização e comparação dos dados do modelo de simulação, os resultados foram compilados e resultaram na Tabela 5.4.1. Verificar a viabilidade do Cluster é simples, basta analisar, principalmente, o tempo gasto descarregando. Se esse

tempo for maior do que 0%, significa que o veículo coletou todos os produtos da rota e teve tempo suficiente para descarregá-los no centro de reciclagem.

Os outros tempos são descritos a seguir:

- Tempo Vazio - tempo de viagem com o caminhão vazio, desde o centro de reciclagem até a primeira coleta;
- Tempo Carregado - tempo de viagem com o veículo carregado com alguma coleta realizada;
- Tempo Carregando - tempo gasto coletando os produtos e armazenando-os no veículo;
- Tempo Parado - tempo parado devido há algum imprevisto ocorrido;
- Tempo Descarregando - tempo gasto descarregando o veículo no centro de reciclagem;
- Tempo Almoço - tempo no qual o veículo ficou parado para que o motorista pudesse almoçar.

É possível notar, através da tabela, que após a simulação utilizando o FlexSim para a criação de imprevistos, apenas três semanas continuaram sendo viáveis de serem coletadas, as semanas 1, 4 e 9. As outras semanas podem vir a ser viáveis também, porém é necessário realizar mais estudos nelas, pois para definir a viabilidade é preciso tratar de outras variáveis, como hora extra ou custo de pernoite, que não são abordadas neste estudo.

A próxima seção mostra os resultados para o objeto de estudo II.

Tabela 5.4.1 – Resumo dos tempos de trabalho dos veículos por semana após a utilização da simulação.

Semana	Tempo Vazio	Tempo Carregado	Tempo Carregando	Tempo Parado	Tempo Descarregando	Tempo Almoço
1	24%	34%	12%	4%	6%	20%
2	9%	47%	20%	4%	0%	20%
3	9%	47%	20%	8%	0%	16%
4	15%	38%	16%	8%	7%	16%
5	10%	47%	19%	8%	0%	16%
6	9%	47%	20%	8%	0%	16%
7	9%	45%	22%	8%	0%	16%
8	10%	41%	25%	8%	0%	16%
9	10%	43%	19%	8%	4%	16%
10	10%	47%	19%	8%	0%	16%

## 5.5 Objeto de Estudo II - *Framework* Multiveículo

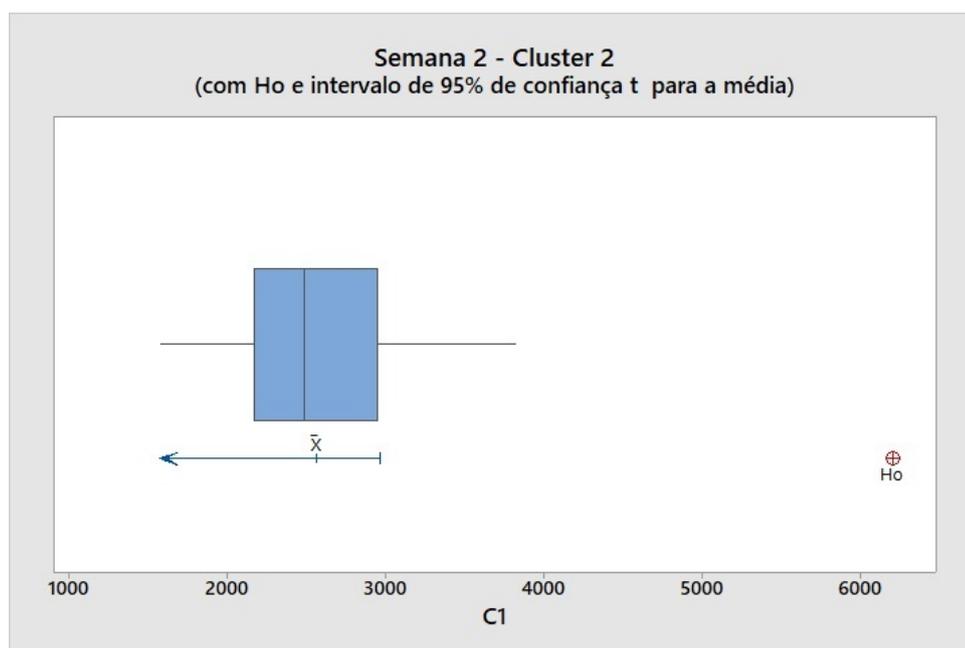
O segundo objeto de estudo foi o *Framework* multiveículo. Nele foram utilizados até três veículos para realizar as coletas de forma paralela e para facilitar demonstrar os resultados, foram selecionadas as respostas mais relevantes pro estudo, ou seja, as que resultaram em maior economia para empresa com relação ao valor que foi pago por ela.

No Apêndice 8.1 estão descritas as tabelas com todos os dados comparativos obtidos a partir dos testes. É importante lembrar que as coletas são apenas sugestões feitas pelo AG e acatar a sugestão ou não cabe ao responsável pelas tomadas de decisões na empresa.

Na primeira semana foram criados apenas três Clusters, pois a quantidade de coletas era pequena, apenas 62 coletas nessa semana e apenas um Cluster foi considerado viável para ser coletado. Porém, o valor para se coletar esse Cluster não foi considerado estatisticamente diferente do valor pago pela empresa e não foi incluído nas coletas. A tabela 8.1.1 mostra os valores encontrados pelo AG.

Na segunda semana há um Cluster candidato a ser coletado, entre 9 formados. A média de custo referente à ele é de R\$2561.60 com um desvio-padrão de 696.82, enquanto o valor pago pela empresa foi de R\$6199.03. Sendo assim, pode-se considerar que o valor calculado pelo AG é estatisticamente menor do que o valor pago pela empresa e a Figura 5.5.1 confirma essa afirmação. Nesse caso, a economia da empresa pode chegar a quase 50%.

Figura 5.5.1 – BoxPlot referente ao Cluster 2 da segunda semana.

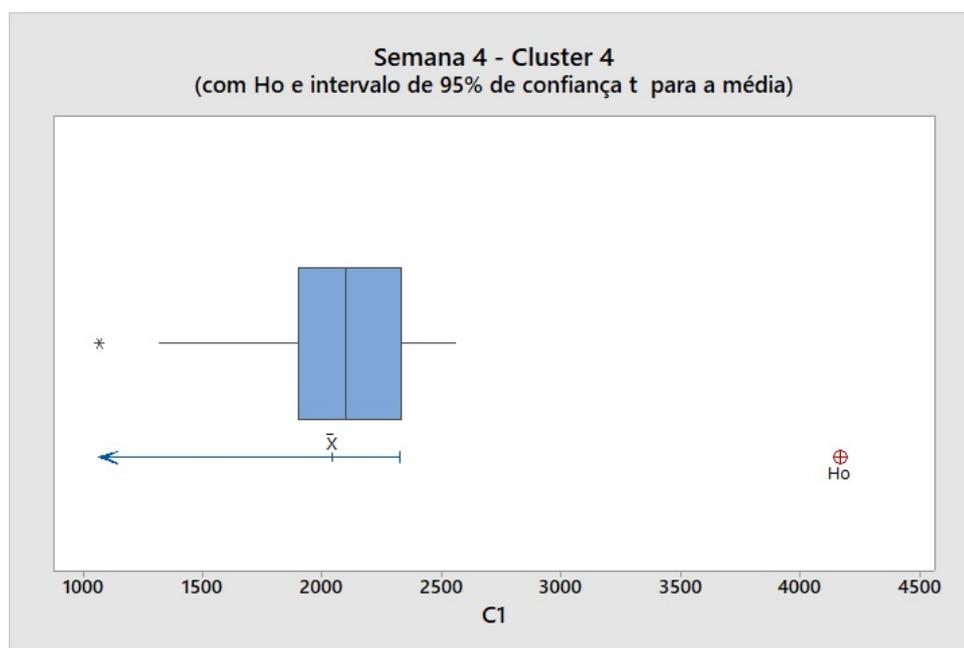


Na semana três foram criados 19 Clusters e, entre eles, houve apenas um candidato a ser coletado. Infelizmente, devido à restrição de tempo, não é possível analisar essa coleta sem maiores estudos. A duração calculada dela foi de mais de quase 11 horas, portanto,

seria necessário verificar se é viável a remuneração de horas extras ou pagamento de uma diária para o motorista realizar toda a coleta. Esses estudos não são contemplados neste trabalho e sugeridos como trabalhos futuros.

Já a quarta semana possui um Cluster para ser coletado que não extrapola as restrições de tempo, entre 9 criados. O valor gasto pela empresa para realizar as coletas foi de R\$4165.07, enquanto o valor calculado foi de R\$2040.69, com desvio-padrão de 486.95. A Figura 5.5.2 mostra o BoxPlot que confirma que o valor calculado é estatisticamente menor do que o pago pela empresa, resultando em uma economia de, no mínimo, 40%.

Figura 5.5.2 – BoxPlot referente ao Cluster 4 da quarta semana.



Na semana 5 foram criados 23 Clusters e dois dois deles podem ser coletados, porém o tempo gasto para realizar a coleta é bem próximo às 8 horas, que é a restrição de tempo para o problema. Isso significa que, caso ocorra qualquer imprevisto, a coleta desses produtos pode estar sujeita a pagamentos de diárias ou horas extras para o motorista e seu ajudante, podendo acarretar na inviabilidade da mesma, sendo necessário mais estudos para auxiliar na decisão.

Os dois Clusters que podem ser coletados na semana 5 possuem tempos de coleta de 7.77 e 7.43 horas, mas apesar de talvez ser necessário realizar o pagamento de horas extras para a finalização dela, o valor que pode ser economizado, provavelmente, torna ambos os Clusters viáveis de serem coletados.

De acordo com os dados da empresa, para realizar essas coletas, foram gastos R\$14552.44 e R\$16478.47. Os valores calculados pelo AG obtiveram médias de R\$2441.75 e R\$2532.23 com desvios de 690.53 e 790.52. Desse modo, é possível notar que existe uma grande chance das coletas serem viáveis, mesmo sendo necessário desembolsar um valor um pouco maior para cobrir gastos com horas extras, por exemplo. As Figuras 5.5.3 e 5.5.4 mostram

os BoxPlots para esses dois Clusters.

Figura 5.5.3 – BoxPlot referente ao Cluster 8 da semana 5.

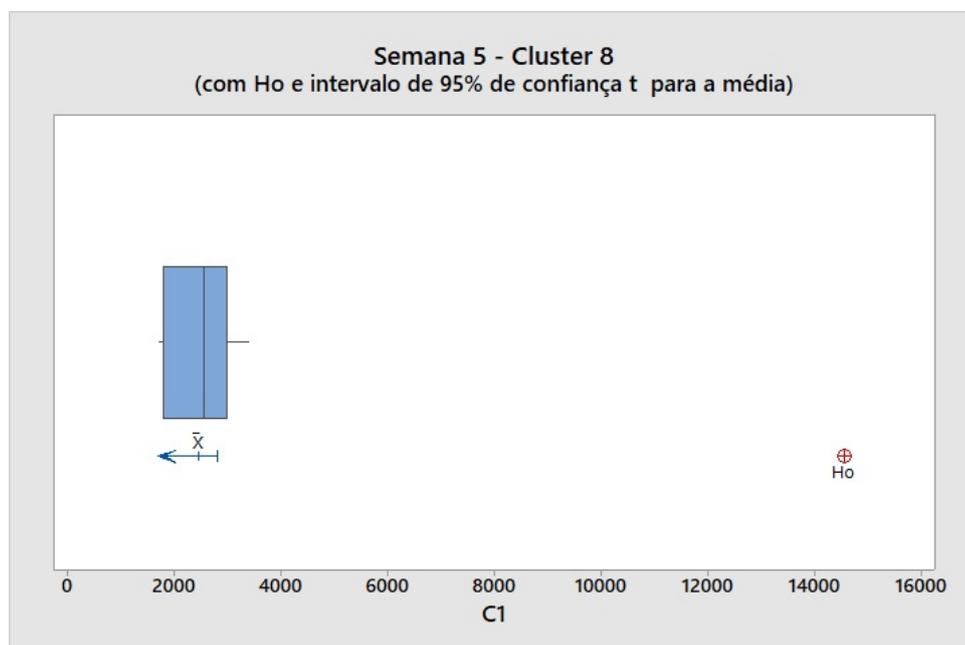
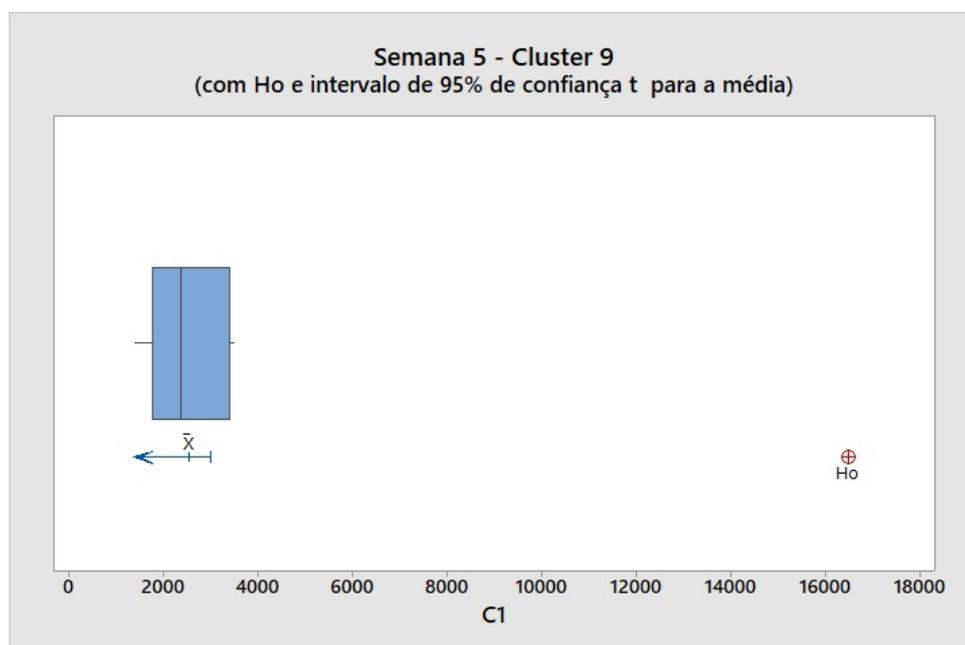
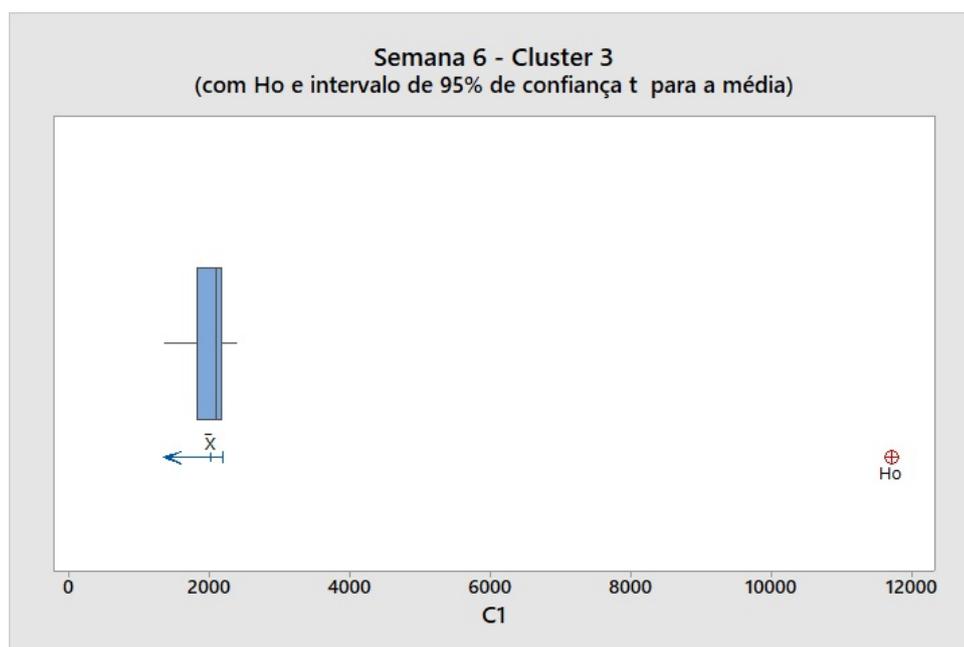


Figura 5.5.4 – BoxPlot referente ao Cluster 9 da semana 5.



A semana 6 possui 16 Clusters e apenas um apto a ser coletado e ele não possui nenhuma restrição relacionada ao tempo, que é de 6.8 horas. O custo para a empresa coletar esse Cluster foi de R\$11708.14 e o valor calculado foi de R\$2019.70 com desvio-padrão de 300.26. Sendo assim, é possível afirmar que essas coletas podem ser realizadas, como mostrado na Figura 5.5.5

Figura 5.5.5 – BoxPlot referente ao Cluster 3 da semana 6.



A semana 7 possui 2 Clusters que valem a pena serem coletados, dentre os 15 formados pelo *Framework*. Desses dois Clusters, um possui uma porcentagem de economia menor, cerca de 16%, e outro possui uma economia bastante alta, cerca de 80%.

Essa economia provavelmente se deve ao fato de que o peso coletado em apenas um local foi grande o suficiente para que, na coleta fracionada, o custo fosse alto devido ao peso, mas na dedicada o peso não influencia da mesma forma no custo final. É importante dizer que o cálculo dos valores fracionadas levam em consideração o peso coletado. Portanto, quanto maior o peso, maior o custo. Na coleta dedicada, o peso influencia apenas no consumo de combustível, mas influência é pequena, se comparada à outra forma de coleta.

Os BoxPlots referentes à essas coletas são mostrados nas Figuras 5.5.6 e 5.5.7. Neles é possível notar que, no Cluster 1, a empresa teve um custo de R\$3622.87 e no Cluster 6 o custo foi de R\$14250.13. Nos valores definidos pelo *Framework* o custo foi mais baixo. Para o Cluster 1 o custo foi de R\$2472.72 com desvio padrão de 540.06 e de R\$1449.32 com desvio de 492.76 para o Cluster 6.

Na semana 8, foram definidos dois possíveis Clusters para serem coletados. Um deles necessita de maiores estudos para verificar a viabilidade, já o outro possui uma alta probabilidade de poder ser percorrido para coleta.

No primeiro Cluster, o maior problema é a restrição do tempo. Apesar da provável economia feita pela empresa ser de aproximadamente 10%, o tempo necessário é de 8.8 horas e, portanto, é preciso realizar estudos levando em consideração os custos de horas extras ou de pernoites para o motorista e seu assistente.

Em outro Cluster criado na semana 8, os resultados já foram diferentes. O valor médio

Figura 5.5.6 – BoxPlot referente ao Cluster 1 da semana 7.

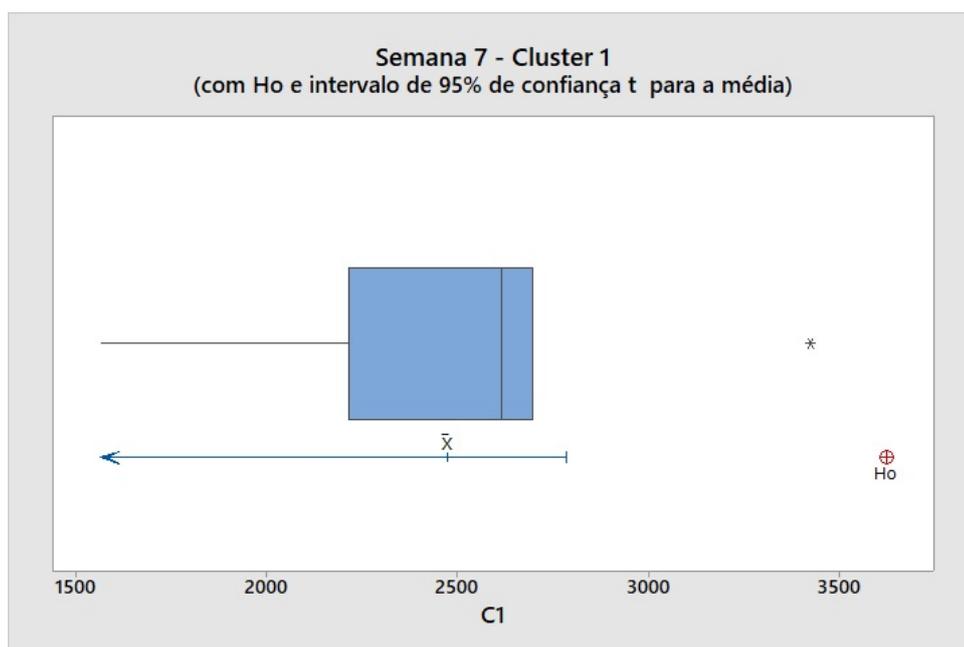
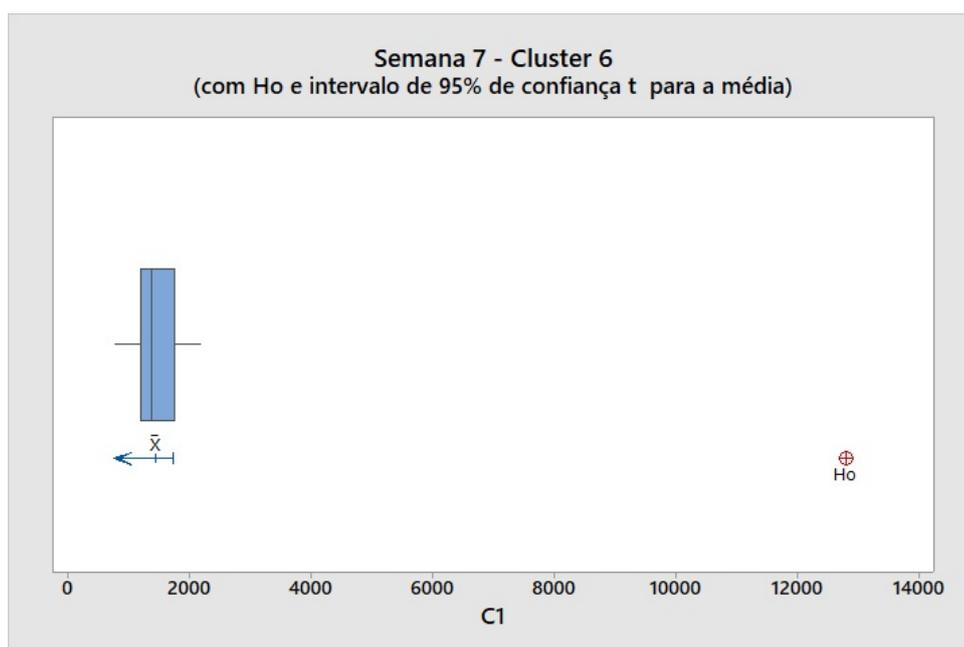


Figura 5.5.7 – BoxPlot referente ao Cluster 6 da semana 7.



calculado pelo AG foi de R\$1904,25 com desvio-padrão de 527,30, enquanto o custo da empresa para realizar as mesmas coletas foi de 17319,17. Essa diferença de valores pode ser motivada pela mesma ocasião que ocorreu na semana 7, com alguma coleta com maiores quantidades de produtos.

Os BoxPlots desses Clusters são mostrados nas Figuras 5.5.8 e 5.5.9 e auxiliam na afirmação de que os valores calculados são estatisticamente menores do que os valores pagos pela empresa.

Na semana 9 ocorre o mesmo problema da semana 8. Um dos Clusters possui tempo

Figura 5.5.8 – BoxPlot referente ao Cluster 5 da semana 8.

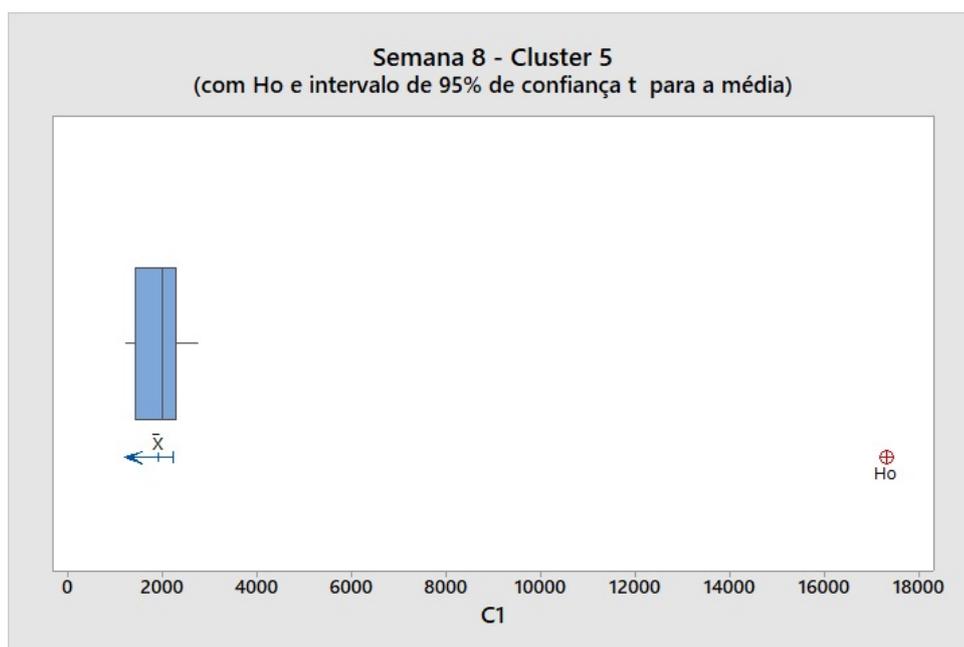
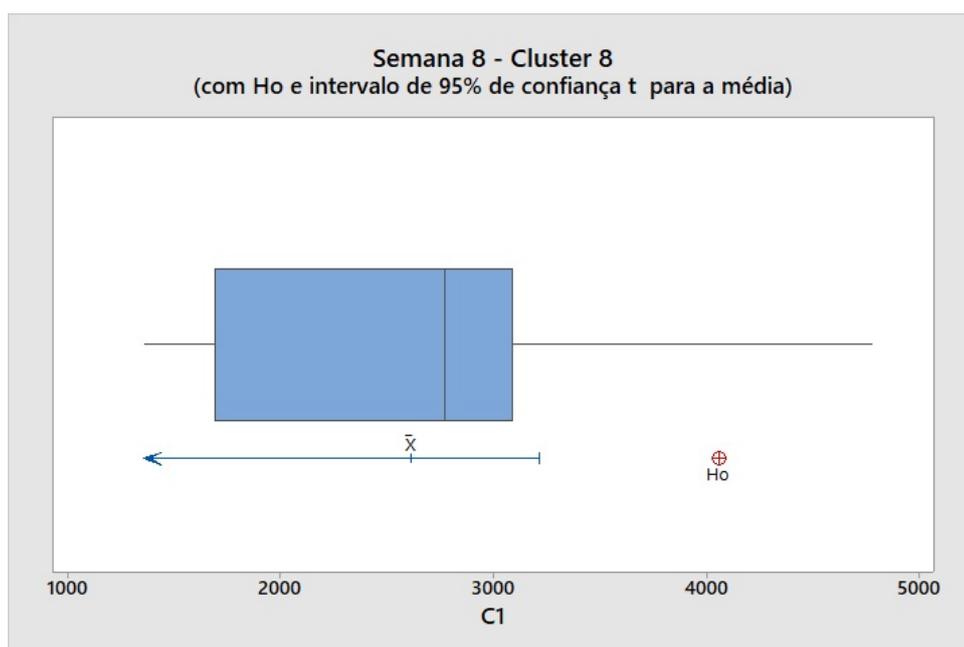


Figura 5.5.9 – BoxPlot referente ao Cluster 8 da semana 8.



de coleta maior do que a restrição, porém a economia aparenta ser grande o suficiente para justificar o pagamento de algumas horas extras para o motorista e seu ajudante. Outro Cluster, além de ter um custo menor do que o que a empresa pagou para as mesmas coletas, também possui tempo de coleta menor do que 8 horas e, portanto, é um candidato a ser coletado.

O primeiro Cluster possui custo de R\$2248,58  $\pm$  305,93, enquanto a empresa pagou, para essas coletas, um valor total de 13240,57. No entanto, o tempo para esse agrupamento extrapola a restrição de 8 horas e, portanto, deve ser mais estudado para garantir a

viabilidade com mais certeza.

Já no segundo Cluster, o tempo de coleta é menor do que a restrição e a economia feita pelos cálculos do *Framework* chega próximo a 75%. O valor calculado foi de R\$2560,06  $\pm$  418,71, enquanto o valor pago pela empresa foi de R\$13240,57.

Os BoxPlots referentes a semana 9 são mostrados nas Figuras 5.5.10 e 5.5.11.

Figura 5.5.10 – BoxPlot referente ao Cluster 9 da semana 5.

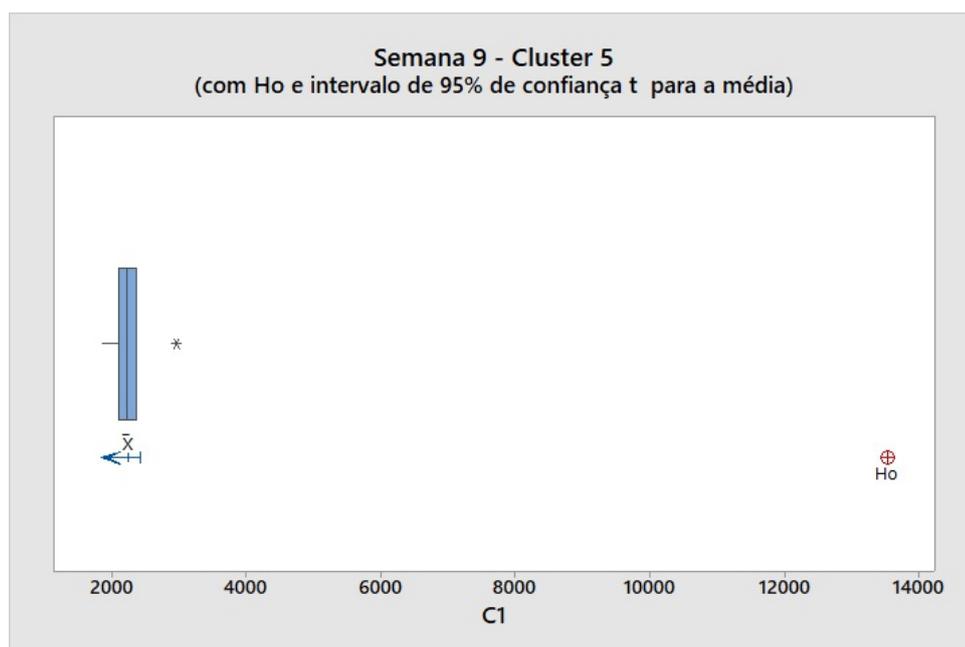
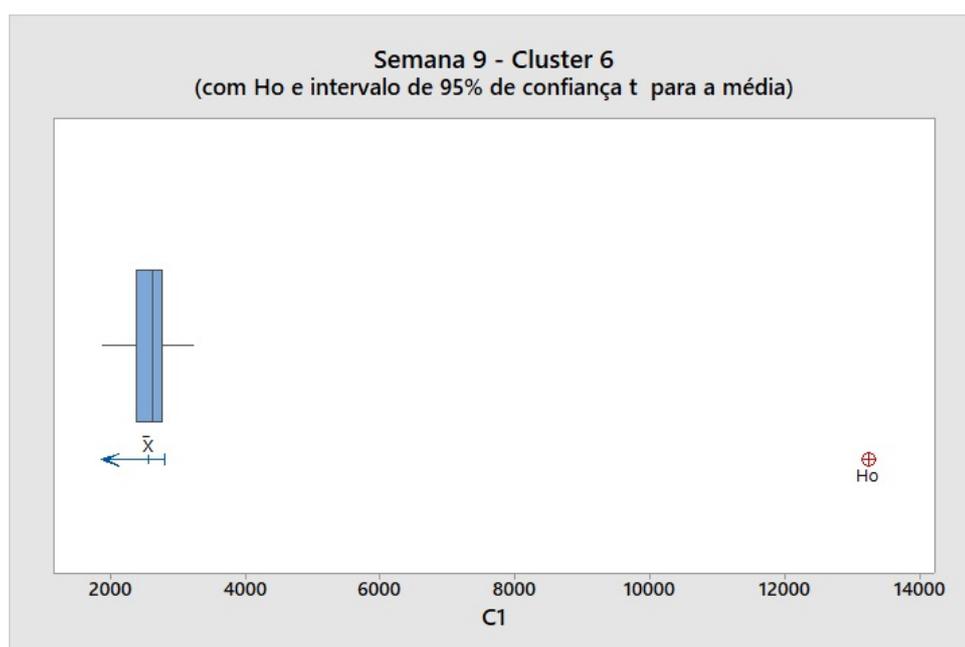


Figura 5.5.11 – BoxPlot referente ao Cluster 9 da semana 6.



Por último, na semana 10 houve 4 Clusters que podem ser coletados, dois deles precisam de mais estudos, pois o tempo para a coleta é maior do que 8 horas e dois deles são

candidatos a serem coletados. Um resumo desses agrupamentos da semana 10 é mostrado na Tabela 5.5.1

Tabela 5.5.1 – Resumo da semana 10.

	<b>Cluster</b>	<b>Custo Médio (R\$)</b>	<b>Custo Fracionado (R\$)</b>	<b>Economia (%)</b>	<b>Tempo (h)</b>
<b>1</b>	6	[2199,95, 3608,85]	17565,9	70%	10,31
<b>2</b>	7	[1857,92, 2557,64]	18152,62	80%	7,7
<b>3</b>	8	[2258,45, 3097,97]	17386,22	80%	8,06
<b>4</b>	9	[1235,39, 2095,69]	17670,62	85%	4,89

Analisando os resultados dos Clusters criados é possível chegar a uma conclusão importante sobre o *Framework* desenvolvido. Os agrupamentos mais promissores para serem coletados são os que se localizam próximo ao centro de coleta (empresa) e que possuem uma maior quantidade de produtos para reciclagem.

A Tabela 5.5.2 mostra um resumo com os Clusters demonstrados nesta seção de resultados. na Tabela é possível verificar que todas as linhas possuem algumas características em comum: na maioria deles, a distância da rota é pequena, no máximo 400km; o peso coletado é alto; o tamanho do Cluster é grande, ou seja, quase todos possuem mais do que 10 cidades.

Tabela 5.5.2 – Resumo dos Clusters passíveis de serem coletados.

Semana	Cluster	Custo Médio (R\$)	Custo Fracionado (R\$)	Peso (kg)	Tamanho do Cluster	Distância do Cluster (km)	Economia (%)
2	2	[2063,45,3059,75]	6199,03	7125,95	12	394,39	47% - 70%
3	5	3357,29 ± 797,06	11328,15	12625,73	12	359,04	63% - 77%
4	4	[1692,35, 2389,03]	4165,07	3987,09	9	377,44	39% 63%
5	8	[2007,86, 2875,64]	14552,44	15801,32	7	429,22	79% - 87%
5	9	[1966,73, 3097,73]	16478,47	18167,56	11	363,72	80% - 89%
6	3	[1805,06, 2234,34]	11708,14	12973,77	13	301,8	85% - 85%
7	1	[2082,19, 2863,25]	3622,87	3244	8	361,95	17% - 47%
7	6	[1096,96, 1801,68]	14250,13	13745,81	11	218,31	86% - 93%
8	5	[1526,41, 2282,09]	17319,17	21592,05	15	268,85	86% - 92%
8	8	[1866,22, 3360,36]	4058,67	4627,75	10	517,71	10% - 61%
9	5	[2029,67, 2467,49]	13533,11	16380,24	12	310,44	81% - 86%
9	6	[2259,64, 2860,48]	13240,57	15903,4	12	414,31	78% - 84%
10	6	[2198,55, 3610,25]	17565,90	23789,04	12	539,93	78% - 89%
10	7	[1858,46, 2557,10]	18152,62	23515,41	13	327,43	85% - 91%
10	8	[2258,78, 3097,64]	17386,22	23445,45	12	394,19	81% - 88%
10	9	[1237,17, 2093,91]	17670,62	22666,16	13	227,41	87% - 94%

Até o momento foi descrito apenas os resultados com relação ao custo, isso se deve ao fato de que, infelizmente, não é possível definir o custo da emissão de  $CO_2$  que ocorreu durante as coletas reais da empresa.

Para este trabalho não é possível definir quais os veículos foram utilizados nas coletas, quais as rotas percorridas nem o peso do veículo durante uma coleta. Sem esses dados, não é possível calcular a emissão real, e portanto, o custo, para compará-la com o que foi calculado neste trabalho.

No entanto é possível mostrar que as emissões calculadas aqui foram pequenas. A maioria das emissões teve um custo abaixo de 40 reais. Isso significa que a empresa necessitaria investir esse valor para auxiliar na diminuição da emissão de  $CO_2$  e, portanto, poderia ser inserido como custo econômico.

A Tabela 5.5.3 mostra que os custos para realizar as coletas nos Clusters são relativamente baixos e, portanto, provavelmente não inviabilizaria nenhuma delas.

Tabela 5.5.3 – Custos de emissões de  $CO_2$  para os Clusters estudados.

Semana	Cluster	Custo Médio da Emissão de $CO_2$ (em R\$)
2	2	[13,10, 29,52]
3	5	[28,03, 43,37]
4	4	[6,03, 14,13]
5	8	[10,24, 30,98]
5	9	[13,95, 31,01]
6	3	[15,45, 31,79]
7	1	[23,38, 28,76]
7	6	[35,15, 46,87]
8	5	[43,25, 49,53]
8	8	[11,95, 34,43]
9	5	[34,96, 41,46]
9	6	[34,77, 39,33]
10	6	[41,20, 50,70]
10	7	[43,14, 47,48]
10	8	[36,75, 41,81]
10	9	[39,46, 45,20]

É possível notar que, assim como no primeiro objeto de estudo, neste segundo os melhores resultados também foram os dos Clusters que possuíam maior quantidade de coletas e maior volume, bem como menores distâncias. Levando à afirmação de que, ambos os estudos são viáveis para Clusters próximos e com mais coletas.

Para finalizar, é preciso, agora, comparar ambos os estudos para verificar se algum *Framework* obteve resultado melhor ou igual ao outro e essa comparação é realizada na próxima seção.

## 5.6 Comparação Entre os Estudos

Ambos os *Frameworks* geraram o mesmo resultado geral. Através deles foi possível notar que, para Clusters próximos e com quantidades maiores de coletas, é viável utilizar qualquer um deles para definir a melhor coleta e veículos.

Esta seção define qual dos dois métodos criados neste trabalho obteve melhores resultados (maior economia). Desse modo, é possível avaliar qual deles é o mais adequado para a utilização e as vantagens e desvantagens de se utilizar cada um dos métodos.

Na primeira semana, o modelo monoveículo resultou um valor médio estatisticamente menor. A Figura 8.5.1 mostra o BoxPlot desta semana e é possível verificar a diferença de valores. A princípio, se imaginava que o *Framework* monoveículo teria um resultado melhor, como confirmado pela primeira semana, porém, essa semana foi a única na qual isso ocorreu.

Com relação à possível economia para a empresa, o modelo monoveículo gerou em torno de 34% a 50% de redução de custos. Já para o modelo multiveículo, essa redução foi de 9% a 40%. Ao se retirar o outlier encontrado nesta semana, a diferença se torna ainda mais evidente e a Figura 8.5.2 demonstra que a média do *Framework* monoveículo diminuiu um pouco mais.

Nas semanas 2, 3 e 4, o resultado já se torna diferente da primeira semana. Nestas semanas, não é possível afirmar que as médias são estatisticamente diferentes entre ambos os modelos. Como é possível ver na Tabela 5.6.3, como os desvios-padrão do *Framework* multiveículo são altos, os intervalos se sobrepõem e isso pode ser visualizado nos BoxPlots 8.5.3, 8.5.4 e 8.5.5 que mostram, respectivamente, as semanas 2, 3 e 4, e neles é possível perceber que as médias são estatisticamente próximas.

Nas semanas próximas, o resultado foi ainda mais diferente do obtido na primeira semana. Nelas, os valores obtidos com o *Framework* monoveículo não podem ser considerados estatisticamente menores do que os do multiveículo, pois mesmo com os desvios-padrão alto, os valores não se sobrepõem, sendo que o *Framework* multiveículo possui sempre um valor mais alto que o outro utilizado na comparação. As Figuras de 8.5.6 a 8.5.9 mostram os BoxPlots para as semanas de 6 a 9.

As semanas 5 e 10 também foram um pouco diferentes quando o *Framework* monoveículo foi executado. Nelas, ele resultou em dois possíveis Clusters para serem coletados. Portanto, ao executar o modelo multiveículo, ambos os Clusters foram levados em consideração para as duas semanas. Para ambas as semanas, os Clusters 8 e 9 foram testados, resultando nos Boxplots 8.5.10 e 8.5.11 para a semana 5 e 8.5.12 e 8.5.13 para a semana 10.

Nas quatro Figuras é possível notar que os valores calculados utilizando-se o *Framework* monoveículo não pode ser considerado estatisticamente menor do que os calculados no multiveículo. A Tabela 5.6.1 mostra as comparações entre as economias geradas

pelos testes com essas duas semanas e, nela, é possível verificar que o *Framework* multiveículo possui uma economia ligeiramente maior que o outro.

Tabela 5.6.1 – Comparação entre os Clusters das semanas 5 e 10.

Semana	Cluster	Economia Monoveículo	Economia Multiveículo
5	8	80%	80%-88%
5	9	80%	80%-89%
10	8	80%-82%	82%-88%
10	9	80%-82%	88%-94%

É possível, concluir que ambos os Clusters obtiveram resultados relativamente similares, porém, o *Framework* multiveículo foi um pouco melhor, quando comparado com o outro. Isso se deve ao fato de que, ao se dividir o Cluster e mais de um, pode ocorrer uma diminuição das distâncias percorridas.

A decisão de qual modelo utilizar é pessoal, mas é possível destacar algumas vantagens e desvantagens que auxiliam nessa escolha. O *Framework* multiveículo resultou em valores um pouco menores com relação ao outro modelo. Porém, o multiveículo tem um tempo de execução um pouco maior, o que pode acarretar em problemas, caso um menor tempo de execução seja essencial para a decisão. A Tabela 5.6.2, mostra a comparação entre os tempos de ambos os modelos criados neste trabalho.

Tabela 5.6.2 – Comparação do tempo de execução entre ambos os *Frameworks*.

Semana	Tempo monoveículo (em s)	Tempo multiveículo (em s)
1	118,09	150,35
2	201,78	319,31
3	492,41	573,74
4	280,40	364,60
5	660,42	663,88
6	571,04	685,14
7	548,47	524,95
8	646,15	680,70
9	456,43	590,12
10	732,27	866,34

Outra vantagem do modelo multiveículo é que, com ele, é possível cobrir uma maior gama de opções para as coletas. Caso a conclusão do AG utilizado para o cálculo das rotas seja de que uma única rota é ideal para a coleta, o modelo multiveículo se tornará similar ao monoveículo.

Para facilitar a visualização, a Tabela 5.6.3 traz um resumo das médias e desvios-padrão obtidos a partir dos resultados do AG nos dois estudos. Essas médias e desvios são os valores mostrados nos Boxplots encontrados no Apêndice 8.5

Através de uma avaliação da tabela, é possível notar que o *Framework* multiveículo obteve melhores resultados em 6 das 10 semanas estudadas, indicando uma leve tendência

Tabela 5.6.3 – Resumo das médias e desvios-padrão obtidos através dos AGs.

Semana	Cluster	Valor Multiveículo	Valor Monoveículo
2	2	[2063,45,3059,75]	[2271,52, 2600,98]
3	5	[2786,91,3927,67]	[2699,87, 3329,03]
4	4	2040,69 ± 486,95	[1819,28, 1995,70]
5	8	2441,75 ± 606,53	[3340,31, 3436,49]
5	9	2532,23 ± 790,52	[3340,31, 3436,49]
6	3	2019,7 ± 300,26	[2755,67, 3427,89]
7	6	1449,32 ± 492,76	3284,56
8	5	1904,25 ± 527,30	[2962,82, 3338,70]
9	5	2248,58 ± 305,93	[2832,90, 3043,40]
10	9	1665,54 ± 601,24	[3446,39, 3779,53]

a utilização desse modelo, pois apesar de ser um pouco mais lento, obteve melhores resultados em relação ao multiveículo.

Dadas as vantagens e desvantagens de ambos os modelos, como dito anteriormente, a decisão é pessoal. Caso o tempo de execução não seja um problema que afete a decisão a ser feita, o uso do *Framework* multiveículo é aconselhável.

## 5.7 Considerações Finais

Esta seção mostrou a interface criada para os modelos trabalhados, explicando os componentes inseridos nela, bem como seu funcionamento. Também foi descrito aqui o resultado de ambos os testes e realizadas comparações entre eles.

Foi possível concluir que, ambos os *Frameworks* são viáveis para Clusters próximos do centro de reciclagem e com quantidades de coletas maiores. Nesses casos, as possíveis economias calculadas podem chegar a valores altos, como quase 90%. Já para outros Clusters, distantes e com poucas quantidades de coleta, os *Frameworks* não obtiveram resultados satisfatórios.

Apesar de, nesta seção, só estarem disponíveis os BoxPlots dos principais Clusters, no Apêndice 8.1 se encontram todos os BoxPlots criados para este trabalho. Utilizando as tabelas do Apêndice 8.2 e os gráficos do 8.1, é possível verificar a afirmação de que Clusters mais distantes ou com poucas coletas devem continuar sendo coletados de forma fracionada, como ocorre atualmente.

A próxima seção traz a conclusão desse trabalho, e também mostra trabalhos futuros que podem ser utilizados para complementar este.

## 6. Conclusão

Após aplicar e testar a abordagem proposta em objetos de estudo para avaliar sua aplicabilidade e eficiência, é possível destacar as conclusões deste trabalho, focando nos principais resultados obtidos, nas discussões realizadas, nas limitações identificadas e nas oportunidades para futuras pesquisas.

Nas seções seguintes, serão abordados esses tópicos: primeiro, será apresentada uma síntese dos resultados; em seguida, serão discutidas as limitações da pesquisa; por fim, serão oferecidas recomendações para trabalhos futuros.

### 6.1 Conclusão

Este trabalho teve como objetivo criar um *Framework* que une as vantagens dos Gêmeos Digitais e utiliza-as na Logística Reversa, de modo a auxiliar o tomador de decisão a definir as coletas de resíduos eletrônicos que devem ser realizadas. A maneira como essa coleta ocorre hoje é baseada no sistema FIFO, o primeiro pedido feito é o primeiro a ser coletado e isso acarreta em alguns problemas para a empresa como a falta de controle sobre os locais de coleta e sobre o valor reservado para o pagamento as mesmas.

Com o auxílio deste trabalho, a empresa será capaz de tomar decisões mais conscientes sobre os valores das coletas, evitando gastos desnecessários e sobretaxa por parte da transportadora.

Além disso os objetivos específicos também foram concluídos. A Seção 2.8 mostrou a revisão da literatura feita para embasar este trabalho. Uma interface foi desenvolvida para que os usuários possam inserir os dados de forma mais simples e recuperar os resultados resumidos para facilitar a decisão. A abordagem foi validada utilizando-se GDs e um modelo de simulação foi criado para validar cenários e complementar o GD.

Como visto na Revisão Sistemática da Literatura na Seção 2.8, a utilização de Gêmeos Digitais em conjunto com a Logística Reversa ainda não foi explorada na literatura, isso se deve ao fato de que há várias dificuldades relacionadas à LR, como falta de conhecimento sobre os produtos a serem coletados, custos elevados e falta de apoio das empresas.

Ainda é possível destacar que, um dos tópicos mais discutidos atualmente, é a Economia Circular e a necessidade de diminuição de emissão de  $CO_2$ , obrigatórias devido às leis governamentais, além do iminente esgotamento de matérias primas que fazem com que os preços de compra das mesmas se elevem.

As empresas estão enxergando na LR uma maneira de evitar a escassez de matérias-primas, ao mesmo tempo em que são capazes de aumentar a margem de lucro com a venda de produtos remanufaturados, pois eles consomem menos energia para serem produzidos e podem ser vendidos por um valor menor do que produtos novos.

Isso abre várias possibilidades de pesquisa, entre elas, a que foi apresentada neste trabalho. Apesar das dificuldades de se trabalhar com a LR, foi possível, neste trabalho, criar de um GD que permitisse trabalhar, em tempo quase real, para auxiliar a tomada de decisões.

Considerando uma lacuna na literatura relacionada à melhores momentos e melhores veículos para se realizar uma coleta na LR utilizando o auxílio de GDs e que a empresa busca a diminuição de custos econômicos e de emissão de  $CO_2$ , havia uma necessidade de se criar uma ferramenta capaz de auxiliar nesse processo. Sendo assim, utilizando-se Clusters e AGs, foi possível criar um *Framework* que se provou ser viável sob algumas condições.

A abordagem proposta foi baseada em quatro etapas: a criação dos Clusters, utilizando a equação de Haversine para calcular as distâncias Euclidianas e permitir menos acesso aos serviços da API do Google Maps; a segunda etapa foi a criação de uma matriz de distâncias utilizando as distâncias reais encontradas na API do Google Maps; a terceira etapa foi utilizar a matriz criada para calcular as rotas utilizando-se um AG, no caso do mutiveículo, e o algoritmo de Dijkstra, no caso do monoveículo; por último, a quarta etapa consistiu em uma otimização multiobjetivo capaz de auxiliar o tomador de decisões.

O GD permitiu que seja possível verificar dia a dia as coletas a serem realizadas. As coletas do dia anterior, influenciam as do próximo dia e essa foi a principal vantagem do GD utilizado aqui. As coletas realizadas em um dia, não precisam novamente ser coletadas no dia seguinte, portanto, a realimentação de dados é o que faz esse trabalho ser considerado um GD.

Vale ressaltar que, os testes foram feitos utilizando-se dados semanais, pois, apesar do *Framework* precisar ser executado diariamente, ele utiliza dados históricos da semana anterior ao dia atual. Se o *Framework* for executado em uma segunda-feira, ele irá utilizar dados históricos dos 5 dias anteriores (de segunda a sexta-feira).

Além dos passos do *Framework*, também foram criados interfaces gráficas para auxiliar os usuários a inserir os dados e visualizar as respostas. Essas interfaces foram criadas de forma mais simples para tentar evitar equívocos.

Os resultados encontrados foram de que os *Frameworks* criados neste trabalho são bastante viáveis em casos específicos nos quais a distância da rota não é grande, mas o peso coletado sim. Isso faz com que seja interessante para a empresa utilizar os veículos dedicados para realizar essas coletas, acarretando em economias que podem chegar a 80% em algumas coletas.

Quando se trata do custo da emissão de  $CO_2$ , infelizmente não foi possível comparar com as emissões realizadas durante as coletas no sistema real, visto que não é possível definir os veículos utilizados, os pesos e as rotas traçadas. Sendo assim, foi verificado se o custo da emissão impactaria na viabilidade das coletas. Desse modo, nenhum dos Clusters sofreram impactos após a adição do custo da emissão.

Os custos das emissões foram relativamente baixos, menos de 50 reais nas coletas estudadas, e como a diferença dos custos econômicos foram grandes, mesmo somando os custos de emissão, o valor pago pela empresa ainda é maior que o valor calculado pelo *Framework*.

Além disso, também foram realizadas comparações entre os métodos criados para verificar as vantagens e desvantagens de cada um deles e também para definir qual deles geraria melhores respostas. Foi notado que o *Framework* multiveículo gerou resultados ligeiramente melhores na maioria dos testes realizados.

Os tempos de execução de ambos os modelos foram relativamente altos, as vezes acima de 10 minutos para chegar à resposta ótima. Isso se deve ao fato de que as consultas para converter endereços em coordenadas geográficas e, posteriormente, para capturar as distâncias reais através do Google Maps, são realizadas utilizando-se a internet. Essa conexão não pode ser controlada, e pode apresentar oscilações, quedas, ou funcionar corretamente, sendo praticamente impossível prever o tempo correto para se realizar todas as buscas.

Por fim, a escolha entre qual método utilizar depende se o tomador de decisão precisa de resultados mais precisos ou resultados mais rápidos. Enquanto o *Framework* monoveículo foi cerca de 15% mais rápido do que o multiveículo, o segundo pode devolver respostas mais confiáveis ao usuário. Isso se deve ao fato de que no segundo *Framework*, o AG pode ser considerado mais completo, pois ele trabalha com mais possibilidades tanto de Clusters, quanto de veículos, do que o primeiro.

Caso o usuário necessite de uma resposta confiável em um tempo mais rápido, é aconselhável a utilização do método monoveículo. Caso o tempo não seja um empecilho, o multiveículo é mais indicado para a tomada de decisão, pois ele engloba mais casos e pode devolver uma resposta mais completa.

Atualmente, a empresa utilizada no estudo trabalha com o modelo FIFO, ou seja, o primeiro pedido a entrar no sistema será o primeiro pedido a ser enviado para a transportadora realizar o transporte. Com o auxílio deste trabalho, a empresa terá mais controle sobre as coletas, podendo tomar melhores decisões.

Ao utilizar o *Framework* criado, a empresa pode ser capaz de ter uma economia em potencial de até 80% do valor gasto atualmente, indicando a viabilidade deste estudo. Vale ressaltar que essa economia depende de outros fatores, porém, em condições ideais, ela pode ocorrer. Além dessa economia, a empresa também poderá diminuir seus custos de emissão de  $CO_2$ , auxiliando-a, para que ela sempre se mantenha adequada às leis sobre emissões, cada vez mais exigentes.

A próxima seção traz os trabalhos futuros sugeridos a partir deste estudo.

## 6.2 Trabalhos Futuros

Os métodos criados possuem algumas limitações que podem ser estudadas mais a fundo no futuro e atenuadas ou até mesmo sanadas completamente. Entre essas oportunidades, é possível destacar:

- A utilização de outros métodos de otimização multiobjetivo a fim de comparar os resultados e os tempos de execução na tentativa de diminuir o tempo gasto e aumentar a precisão das respostas;
- Utilizar métodos de previsão para estimar dados de coletas futuras. Visto que os usuários finais pedem para que coletas sejam realizadas em seu endereço, mas nem sempre o peso estimado por eles é o peso correto. Seria muito vantajoso para a empresa um método para prever o erro dessa estimativa e identificar, com a maior precisão possível, os pesos e dimensões das coletas.
- Visto que a API do Google Maps é paga, seria interessante buscar uma alternativa gratuita para recuperar as distâncias e tempos de cada coleta;
- Os *Frameworks* levaram em consideração apenas um veículo de cada tipo. Então, uma possibilidade de trabalho futuro seria a utilização de vários veículos idênticos. Desse modo, seria possível testar se é mais vantagem realizar as coletas com um veículo grande (1 tonelada, por exemplo), ou dois pequenos (500kg cada);
- Este estudo se concentrou no estado de São Paulo, onde a maioria das coletas se encontra. Sugere-se, no futuro, expandir esse estudo para a região Sudeste e, futuramente, para o restante do país;
- É possível, no futuro, realizar estudos utilizando vários pontos de coletas, de modo a concentrar várias coletas neles e entregar para a empresa em um único veículo. Criando assim vários pontos de coleta, porém um único ponto central de processamento dos produtos;
- Os modelos de simulação foram criados levando-se em consideração apenas um veículo. Sugere-se criar modelos que funcionem com vários veículos e várias rotas para testar o modelo multiveículo.

## 7. Referências

- Abdel-Basset, Mohamed *et al.* “A Conceptual Hybrid Approach from a Multicriteria Perspective for Sustainable Third-party Reverse Logistics Provider Identification”. Em: *Sustainability* 13.9 (2021), p. 4615.
- Abid, Salma e Fatima Zahra Mhada. “Simulation Optimisation Methods Applied in Reverse Logistics: a Systematic Review”. Em: *International Journal of Sustainable Engineering* 14.6 (2021), pp. 1463–1483.
- Aghaei Chadegani, Arezoo *et al.* “A Comparison Between two Main Academic Literature Collections: Web of Science and Scopus Databases”. Em: *Asian Social Science* 9.5 (2013), pp. 18–26.
- Akhlaghi, Yousef Golizadeh *et al.* “A Constraint Multi-Objective Evolutionary Optimization of a State-of-the-art Dew Point Cooler Using Digital Twins”. Em: *Energy Conversion and Management* 211 (2020), p. 112772.
- Ali, Syed Mithun *et al.* “Barriers to Reverse Logistics in the Computer Supply Chain Using Interpretive Structural Model”. Em: *Global journal of flexible systems management* 19.1 (2018), pp. 53–68.
- Alkahtani, Mohammed *et al.* “An Insight into Reverse Logistics with a Focus on Collection Systems”. Em: *Sustainability* 13.2 (2021), p. 548.
- ÁLVARES JR, O de M e RENATO RICARDO ANTÔNIO LINKE. “Metodologia Simplificada de Cálculo das Emissões de Gases do Efeito Estufa de Frotas de Veículos no Brasil”. Em: *São Paulo: CETESB* 182 (2001).
- Amirdadi, Masoud e Farzad Dehghanian. “A Robust Fuzzy Optimization Approach for Reverse Logistics Network Design with Buyback Offers”. Em: *Journal of Modelling in Management* (2021).
- Anagnostopoulos, T *et al.* “Assessing Dynamic Models for High Priority Waste Collection in Smart Cities”. Em: *Journal of Systems and Software* 110 (2015), pp. 178–192. ISSN: 01641212. DOI: [10.1016/j.jss.2015.08.049](https://doi.org/10.1016/j.jss.2015.08.049).
- Assumpção, Jairo José *et al.* “Green Supply Chain Practices: a Comprehensive and Theoretically Multidimensional Framework for Categorization”. Em: *Production* 29 (2019), e20190047.
- Astanti, Yuli Dwi e Gity Nur Fitriani. “A Case Study of Supply Chain Simulation for Determining the Best Stock Allocation”. Em: *MATEC Web of Conferences*. Vol. 154. EDP Sciences. 2018, p. 01052.
- Avventuroso, Giuseppe, Marco Silvestri e Paolo Pedrazzoli. “A Networked Production System to Implement Virtual Enterprise and Product Lifecycle Information Loops”. Em: *IFAC-PapersOnLine* 50.1 (2017), pp. 7964–7969. ISSN: 24058963. DOI: [10.1016/j.ifacol.2017.08.902](https://doi.org/10.1016/j.ifacol.2017.08.902).

- Baines, Tim *et al.* “Humans: the Missing Link in Manufacturing Simulation?” Em: *Simulation modelling practice and theory* 12.7-8 (2004), pp. 515–526.
- Bal, Alperen e Sule Itir Satoglu. “A Goal Programming Model for Sustainable Reverse Logistics Operations Planning and an Application”. Em: *Journal of cleaner production* 201 (2018), pp. 1081–1091.
- Balci, Osman. “How to Successfully Conduct Large-Scale Modeling and Simulation Projects”. Em: *Proceedings - Winter Simulation Conference* (2011), pp. 176–182. ISSN: 08917736. DOI: [10.1109/WSC.2011.6147749](https://doi.org/10.1109/WSC.2011.6147749).
- “A Life Cycle for Modeling and Simulation”. Em: *Simulation* 88.7 (2012), pp. 870–883.
- Bamberg, A *et al.* “The Digital Twin – Your Ingenious Companion for Process Engineering and Smart Production”. Em: *Chemical Engineering and Technology* 44.6 (2021), pp. 954–961. ISSN: 09307516. DOI: [10.1002/ceat.202000562](https://doi.org/10.1002/ceat.202000562).
- Barricelli *et al.* “A Survey on Digital Twin: Definitions, Characteristics, Applications, and Design Implications”. Em: *IEEE ACCESS* 7 (2019), pp. 167653–167671. ISSN: 2169-3536.
- Barth, Linard *et al.* “Systematization of Digital Twins: Ontology and Conceptual Framework”. Em: *ACM International Conference Proceeding Series* (2020), pp. 13–23. DOI: [10.1145/3388176.3388209](https://doi.org/10.1145/3388176.3388209).
- Batty, Michael. *Digital twins*. 2018.
- Beloglazov, I I, P A Petrov e V.Yu. Bazhin. “The Concept of Digital Twins for Tech Operator Training Simulator Design for Mining and Processing Industry”. Em: *Eurasian Mining* 2020.2 (2020), pp. 50–54. DOI: [10.17580/em.2020.02.12](https://doi.org/10.17580/em.2020.02.12).
- Ben-Arieh, David e Deep Kumar Gullipalli. “Data Envelopment Analysis of Clinics with Sparse Data: Fuzzy clustering Approach”. Em: *Computers & Industrial Engineering* 63.1 (2012), pp. 13–21.
- Bernardes, Mariana *et al.* “Engaging the End User in Waste from Electrical and Electronic Equipment Management: an Action Research Study”. Em: *Systemic Practice and Action Research* 37.1 (2024), pp. 105–126.
- Bertrand, J Will M e Jan C Fransoo. “Operations management research methodologies using quantitative modeling”. Em: *International journal of operations & production management* 22.2 (2002), pp. 241–264.
- Borshchev, Andrei e Alexei Filippov. “From System Dynamics and Discrete Event to Practical Agent Based Modeling: Reasons, Techniques, Tools”. Em: *Proceedings of the 22nd international conference of the system dynamics society*. Vol. 22. Citeseer. 2004, pp. 25–29.
- Botkina, Darya *et al.* “Digital Twin of a Cutting Tool”. Em: *Procedia CIRP* 72 (2018), pp. 215–218. ISSN: 22128271.
- Bouzon, Marina, Kannan Govindan e Carlos M Taboada Rodriguez. “Evaluating Barriers for Reverse Logistics Implementation Under a Multiple Stakeholders’ Perspective

- Analysis Using Grey Decision Making Approach”. Em: *Resources, conservation and recycling* 128 (2018), pp. 315–335.
- Brasil. *Lei nº 12.305, de 2 de agosto de 2010*. [http://www.planalto.gov.br/ccivil\\_03/\\_ato2007-2010/2010/lei/l12305.htm](http://www.planalto.gov.br/ccivil_03/_ato2007-2010/2010/lei/l12305.htm). Acesso em: 07 março 2024. 2010.
- *Decreto nº 10.240, de 12 de fevereiro de 2020*. Acesso em: 08 out. 2024. 2020. URL: <https://www2.camara.leg.br/legin/fed/decret/2020/decreto-10240-12-fevereiro-2020-789763-norma-pe.html>.
- Braun, Anja T *et al.* “Case Study Analysing Potentials to Improve Material Efficiency in Manufacturing Supply Chains, Considering Circular Economy Aspects”. Em: *Sustainability* 10.3 (2018), p. 880.
- Braun, D *et al.* “A Concept for the Automated Layout Generation of an Existing Production Line Within the Digital Twin”. Em: *Procedia CIRP*. Ed. por Makris S. Vol. 97. Elsevier B.V., 2020, pp. 302–307. DOI: [10.1016/j.procir.2020.05.242](https://doi.org/10.1016/j.procir.2020.05.242).
- Broo, Didem Gurdur e Jennifer Schooling. “A Framework for Using Data as an Engineering Tool for Sustainable Cyber-Physical Systems”. Em: *IEEE Access* 9 (2021), pp. 22876–22882.
- Can, Fazli. “Incremental Clustering for Dynamic Information Processing”. Em: *ACM Transactions on Information Systems (TOIS)* 11.2 (1993), pp. 143–164.
- Cannella, S, M Bruccoleri e J M Framinan. “Closed-Loop Supply Chains: What Reverse Logistics Factors Influence Performance?” Em: *International Journal of Production Economics* 175 (2016), pp. 35–49. ISSN: 09255273. DOI: [10.1016/j.ijpe.2016.01.012](https://doi.org/10.1016/j.ijpe.2016.01.012).
- Capra, Miranda G. “Factor Analysis of Card Sort Data: an Alternative to Hierarchical Cluster Analysis”. Em: *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*. Vol. 49. 5. SAGE Publications Sage CA: Los Angeles, CA. 2005, pp. 691–695.
- Carter, Craig R e Lisa M Ellram. “Reverse Logistics: a Review of the Literature and Framework for Future Investigation”. Em: *Journal of business logistics* 19.1 (1998), p. 85.
- Charnley, Fiona *et al.* “Simulation to Enable a Data-Driven Circular Economy”. Em: *SUSTAINABILITY* 11.12 (jun. de 2019). ISSN: 2071-1050. DOI: [10.3390/su11123379](https://doi.org/10.3390/su11123379).
- Chen, Yukun *et al.* “Research on Application of Digital Twin in Simulation of Equipment Maintenance Support”. Em: *IOP Conference Series: Materials Science and Engineering*. Vol. 782. 3. IOP Publishing. 2020, p. 032088.
- Chiandussi, Giorgio *et al.* “Comparison of Multi-Objective Optimization Methodologies for Engineering Applications”. Em: *Computers & Mathematics with Applications* 63.5 (2012), pp. 912–942.
- Chiang, T.-A., Z H Che e Z Cui. “Designing a Multistage Supply Chain in Cross-Stage Reverse Logistics Environments: Application of Particle Swarm Optimization Algo-

- rithms”. Em: *The Scientific World Journal* 2014 (2014). ISSN: 1537744X. DOI: [10.1155/2014/595902](https://doi.org/10.1155/2014/595902).
- Chopde, Nitin R e Mangesh Nichat. “Landmark Based Shortest Path Detection by Using A\* and Haversine Formula”. Em: *International Journal of Innovative Research in Computer and Communication Engineering* 1.2 (2013), pp. 298–302.
- Chwif, Leonardo e Afonso Medina. Modelagem e Simulação de Eventos Discretos, 4a Edição: Teoria e Aplicações. Vol. 4. Elsevier Brasil, 2014.
- Coello Coello, Carlos A. “A Comprehensive Survey of Evolutionary-Based Multiobjective Optimization Techniques”. Em: *Knowledge and Information systems* 1.3 (1999), pp. 269–308.
- Cortés Pellicer, Pascual e Faustino Alarcón Valero. “Identification of Reverse Logistics Decision Types from Mathematical Models”. Em: *Journal of Industrial Engineering and Management (JIEM)* 11.2 (2018), pp. 239–249.
- Costa-Salas, Yasel, William Sarache e Margarethe Überwimmer. “Fleet Size Optimization in the Discarded Tire Collection Process”. Em: *Research in transportation business & management* 24 (2017), pp. 81–89.
- Czwick, Cordula e Reiner Anderl. “Cyber-Physical Twins - Definition, Conception and Benefit”. Em: *Procedia CIRP* 90 (2020), pp. 584–588. ISSN: 2212-8271. DOI: <https://doi.org/10.1016/j.procir.2020.01.070>.
- Deb, Kalyanmoy e Santosh Tiwari. “Omni-Optimizer: A Procedure for Single and Multi-Objective Optimization”. Em: *International Conference on Evolutionary Multi-Criterion Optimization*. Springer. 2005, pp. 47–61.
- Dehghanimohammadabadi, Mohammad, Sahil Belsare e Renee Thiesing. “Simulation-Optimization of Digital Twin”. Em: *2021 Winter Simulation Conference (WSC)*. IEEE. 2021, pp. 1–10.
- Deng, Hongbo e Jiawei Han. “Probabilistic Models for Clustering”. Em: *Data Clustering*. Chapman e Hall/CRC, 2018, pp. 61–86.
- Detzner, A e M Eigner. “A Digital Twin for Root Cause Analysis and Product Quality Monitoring”. Em: *Proceedings of International Design Conference, DESIGN*. Ed. por Bojetic N Pavkovic N Skec S Marjanovic D. Storga M. Vol. 4. Faculty of Mechanical Engineering e Naval Architecture, 2018, pp. 1547–1558. ISBN: 9789537738594. DOI: [10.21278/idc.2018.0418](https://doi.org/10.21278/idc.2018.0418).
- Dev, N K, R Shankar e F H Qaiser. “Industry 4.0 and Circular Economy: Operational Excellence for Sustainable Reverse Supply Chain Performance”. Em: *Resources, Conservation and Recycling* 153 (2020). ISSN: 09213449. DOI: [10.1016/j.resconrec.2019.104583](https://doi.org/10.1016/j.resconrec.2019.104583).
- Dijkstra, Edsger W. “A Note on Two Problems in Connexion With Graphs”. Em: *Edsger Wybe Dijkstra: His Life, Work, and Legacy*. "ACM Digital Library", 2022, pp. 287–290.

- Dittrich, Marc André *et al.* “Shifting Value Stream Patterns Along the Product Lifecycle With Digital Twins”. Em: *Procedia CIRP* 86 (2020), pp. 3–11. ISSN: 22128271.
- Dutta, Pankaj *et al.* “A Multiobjective Optimization Model for Sustainable Reverse Logistics in Indian E-commerce Market”. Em: *Journal of Cleaner Production* 249 (2020), p. 119348.
- Eldabi, T *et al.* “Hybrid Simulation Challenges and Opportunities: A Life-Cycle Approach”. Em: *Proceedings - Winter Simulation Conference*. Vol. 2018-Decem. Institute of Electrical e Electronics Engineers Inc., 2019, pp. 1500–1514. ISBN: 9781538665725. DOI: [10.1109/WSC.2018.8632465](https://doi.org/10.1109/WSC.2018.8632465).
- Elia, V, M G Gnani e F Tornese. “Assessing the Efficiency of a PSS Solution for Waste Collection: A Simulation Based Approach”. Em: *Procedia CIRP*. Ed. por Pezzotta G Ceretti E Tolio T. Cavalieri S. Vol. 47. Elsevier B.V., 2016, pp. 252–257. DOI: [10.1016/j.procir.2016.03.086](https://doi.org/10.1016/j.procir.2016.03.086).
- Erkoyuncu, J A *et al.* “A Design Framework for Adaptive Digital Twins”. Em: *CIRP Annals* 69.1 (2020), pp. 145–148. ISSN: 00078506. DOI: [10.1016/j.cirp.2020.04.086](https://doi.org/10.1016/j.cirp.2020.04.086).
- Ester, Martin e Rüdiger Wittmann. “Incremental Generalization for Mining in a Data Warehousing Environment”. Em: *International Conference on Extending Database Technology*. Springer. 1998, pp. 135–149.
- Fagundes, Liliame Dolores, Edvaldo Santos Amorim e Renato da Silva Lima. “Action Research in Reverse Logistics for End-of-Life Tire Recycling”. Em: *Systemic Practice and Action Research* 30 (2017), pp. 553–568.
- Fakhimi, M *et al.* “A Review of Literature in Modeling Approaches for Sustainable Development”. Em: *Proceedings of the 2013 Winter Simulation Conference - Simulation: Making Decisions in a Complex World, WSC 2013*. 2013, pp. 282–290. ISBN: 9781479939503. DOI: [10.1109/WSC.2013.6721427](https://doi.org/10.1109/WSC.2013.6721427).
- Fisher, Douglas H. “Knowledge Acquisition Via Incremental Conceptual Clustering”. Em: *Machine learning* 2.2 (1987), pp. 139–172.
- Forrest, Stephanie. “Genetic Algorithms”. Em: *ACM computing surveys (CSUR)* 28.1 (1996), pp. 77–80.
- Fuller, Aidan *et al.* “Digital Twin: Enabling Technologies, Challenges and Open Research”. Em: *IEEE access* 8 (2020), pp. 108952–108971.
- Gao, Zhaohui e Caiyun Ye. “Reverse Logistics Vehicle Routing Optimization Problem Based on Multivehicle Recycling”. Em: *Mathematical Problems in Engineering* 2021 (2021).
- Garg, Chandra Prakash. “A Robust Hybrid Decision Model to Evaluate Critical Factors of Reverse Logistics Implementation Using Grey-DEMATEL Framework”. Em: *Opsearch* 57.3 (2020), pp. 837–873.
- Garrido, J e J Sáez. “Integration of Automatic Generated Simulation Models, Machine Control Projects and Management Tools to Support Whole Life Cycle of Industrial

- Digital Twins”. Em: *IFAC-PapersOnLine*. Ed. por Yalaoui F Ivanov D. Dolgui A. Vol. 52. 13. Elsevier B.V., 2019, pp. 1814–1819. DOI: [10.1016/j.ifacol.2019.11.465](https://doi.org/10.1016/j.ifacol.2019.11.465).
- GeoPy Developers. GeoPy Documentation. Acessado em: 17 de fevereiro de 2022. 2024. URL: <https://geopy.readthedocs.io/en/stable/>.
- Ghita, M, B Siham e M Hicham. “Digital Twins Development Architectures and Deployment Technologies: Moroccan Use Case”. Em: *International Journal of Advanced Computer Science and Applications* 2 (2020), pp. 468–478. ISSN: 2158107X.
- Godichaud, Matthieu e Lionel Amodeo. “Comparing Inventory Policies for Closed-Loop Supply Chain Using Simulation-Based Optimization”. Em: *IFAC Proceedings Volumes* 46.9 (2013), pp. 418–423.
- Golda, G, A Kampa e I Paprocka. “The Application of Virtual Reality Systems as a Support of Digital Manufacturing and Logistics”. Em: *IOP Conference Series: Materials Science and Engineering*. Vol. 145. 4. IOP Publishing. 2016, p. 042017.
- Gonçalves, Andriani Tavares Tenório *et al.* “Discrete Event Simulation as a Decision-Making Tool for End-of-Life Tire Reverse Logistics in a Brazilian City Consortium”. Em: *Environmental Science and Pollution Research* 26 (2019), pp. 23994–24009.
- Gopalakrishnan, S, N W Hartman e M D Sangid. “Model-Based Feature Information Network (MFIN): A Digital Twin Framework to Integrate Location-Specific Material Behavior Within Component Design, Manufacturing, and Performance Analysis”. Em: *Integrating Materials and Manufacturing Innovation* 9.4 (2020), pp. 394–409. ISSN: 21939764. DOI: [10.1007/s40192-020-00190-4](https://doi.org/10.1007/s40192-020-00190-4).
- Griva, Igor, Stephen G Nash e Ariela Sofer. *Linear and Nonlinear Optimization*. Vol. 108. Siam, 2009.
- Gu, Y, S Zhang e L Qiu. “Digital Twin Driven Requirement Conversion in Smart Customized Design”. Em: *IEEE Access* 9 (2021), pp. 64414–64426. ISSN: 21693536. DOI: [10.1109/ACCESS.2021.3075069](https://doi.org/10.1109/ACCESS.2021.3075069).
- Han, Z *et al.* “Digital Twin-Driven 3D Visualization Monitoring and Traceability System for General Parts in Continuous Casting Machine”. Em: *Journal of Advanced Mechanical Design, Systems and Manufacturing* 14.7 (2020). ISSN: 18813054. DOI: [10.1299/jamdsm.2020jamdsm0100](https://doi.org/10.1299/jamdsm.2020jamdsm0100).
- Hao, Hao *et al.* “Reverse Logistics Network Design of Electric Vehicle Batteries Considering Recall Risk”. Em: *Mathematical Problems in Engineering* 2021 (2021).
- Holand, John H. “Adaptation in Natural and Artificial Systems”. Em: *Ann Arbor: The University of Michigan Press* (1975), p. 32.
- Holland, John H. “Genetic Algorithms”. Em: *Scientific american* 267.1 (1992), pp. 66–73.
- Islam, Badar ul *et al.* “Optimization of Neural Network Architecture Using Genetic Algorithm for Load Forecasting”. Em: *2014 5th International Conference on Intelligent and Advanced Systems (ICIAS)*. IEEE. 2014, pp. 1–6.

- Islam, Md Shamimul *et al.* “A Literature Review on Environmental Concerns in Logistics: Trends and Future Challenges”. Em: *International Journal of Logistics Research and Applications* 24.2 (2021), pp. 126–151.
- Jain, Anil K, M Narasimha Murty e Patrick J Flynn. “Data Clustering: a Review”. Em: *ACM computing surveys (CSUR)* 31.3 (1999), pp. 264–323.
- Jian, Jie *et al.* “A Multi-Objective Optimization Model for Green Supply Chain Considering Environmental Benefits”. Em: *Sustainability* 11.21 (2019), p. 5911.
- Jones, D. *et al.* “Characterising the Digital Twin: A Systematic Literature Review”. Em: *CIRP Journal of Manufacturing Science and Technology* 29 (2020), pp. 36–52. ISSN: 17555817.
- Jones, David Edward *et al.* “Early stage digital twins for early stage engineering design”. Em: *Proceedings of the Design Society: International Conference on Engineering Design*. Vol. 1. 1. Cambridge University Press. 2019, pp. 2557–2566.
- Joshi, Ninad e Pawan Bhandari. “Statistical Analysis of Welding Parameters Affecting the Tensile Strength of Mild Steel Plates”. Em: *Proceedings of the Second Australian International Conference on Industrial Engineering and Operations Management*. IEOM Society International. Melbourne, Australia: IEOM Society International, 2023.
- Kaewunruen, S *et al.* “Digital Twin Aided Vulnerability Assessment and Risk-Based Maintenance Planning of Bridge Infrastructures Exposed to Extreme Conditions”. Em: *Sustainability (Switzerland)* 13.4 (2021), pp. 1–19. ISSN: 20711050. DOI: [10.3390/su13042051](https://doi.org/10.3390/su13042051).
- Kalaboukas, K *et al.* “Implementation of Cognitive Digital Twins in Connected and Agile Supply Networks - An Operational Model”. Em: *Applied Sciences (Switzerland)* 11.9 (2021). ISSN: 20763417. DOI: [10.3390/app11094103](https://doi.org/10.3390/app11094103).
- Kapustina, I *et al.* “The Logistics Network Digital Twin in View of Concept of the Non-Destructive Quality Control Methods”. Em: *E3S Web of Conferences*. Ed. por Murgul V Kudriavtcev S. Vol. 157. EDP Sciences, 2020. DOI: [10.1051/e3sconf/202015705001](https://doi.org/10.1051/e3sconf/202015705001).
- Kara, Sami, Fatida Rugrungruang e Hartmut Kaebernick. “Simulation Modelling of Reverse Logistics Networks”. Em: *International journal of production economics* 106.1 (2007), pp. 61–69.
- Kazemi, Nima, Nikunja Mohan Modak e Kannan Govindan. “A Review of Reverse Logistics and Closed Loop Supply Chain Management Studies Published in IJPR: a Bibliometric and Content Analysis”. Em: *International Journal of Production Research* 57.15-16 (2019), pp. 4937–4960.
- Khajavi, S H *et al.* “Digital Twin: Vision, Benefits, Boundaries, and Creation for Buildings”. Em: *IEEE Access* 7 (2019), pp. 147406–147419. ISSN: 21693536. DOI: [10.1109/ACCESS.2019.2946515](https://doi.org/10.1109/ACCESS.2019.2946515).

- Kiatcharoenpol, Tossapol e Pornwasin Sirisawat. “A Selection of Barrier Factors Affecting Reverse Logistics Performance of Thai Electronic Industry”. Em: *Int. J. Intell. Eng. Syst* 13 (2020), pp. 117–126.
- Kim, J e S.-A. Kim. “Lifespan Prediction Technique for Digital Twin-Based Noise Barrier Tunnels”. Em: *Sustainability (Switzerland)* 12.7 (2020). ISSN: 20711050.
- Kincaid, Bonnie L. *Competitive Advantage of Clusters Within Lesser Developed Countries of the South Pacific: An Empirical Case Study Extending the Porter Diamond Model*. Capella University, 2005.
- Köhn, Hans-Friedrich e Lawrence J Hubert. “Hierarchical Cluster Analysis”. Em: *Wiley StatsRef: Statistics Reference Online* (2014), pp. 1–13.
- Krishna, K e M Narasimha Murty. “Genetic K-means Algorithm”. Em: *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)* 29.3 (1999), pp. 433–439.
- Kuehn, Wolfgang. “Digital Twins for Decision Making in Complex Production and Logistic Enterprises”. Em: *International Journal of Design & Nature and Ecodynamics* 13.3 (2018), pp. 260–271.
- Kutbay, Uğurhan *et al.* “Partitional Clustering”. Em: *Recent Applications in Data Clustering* 10 (2018).
- La Russa, F M e C Santagati. “Historical Sentient – Building Information Model: A Digital Twin for the Management of Museum Collections in Historical Architectures”. Em: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*. Vol. 43. B4. International Society for Photogrammetry e Remote Sensing, 2020, pp. 755–762. DOI: [10.5194/isprs-archives-XLIII-B4-2020-755-2020](https://doi.org/10.5194/isprs-archives-XLIII-B4-2020-755-2020).
- Lambora, Annu, Kunal Gupta e Kriti Chopra. “Genetic Algorithm - A Literature Review”. Em: *2019 international conference on machine learning, big data, cloud and parallel computing (COMITCon)*. IEEE. 2019, pp. 380–384.
- Lee, C K M, S Zhang e K K H Ng. “In-Plant Logistics Simulation Model for the Catering Service Industry Towards Sustainable Development: A Case Study”. English. Em: *Sustainability (Switzerland)* 11.13 (2019). ISSN: 20711050. DOI: [10.3390/su11133655](https://doi.org/10.3390/su11133655).
- Li, Dan, Chunhong Liu e Kang Li. “A Remanufacturing Logistics Network Model Based on Improved Multi-Objective Ant Colony Optimization”. Em: *Journal Européen des Systèmes Automatisés* 52.4 (2019), pp. 391–395.
- Li, L *et al.* “Sustainability Assessment of Intelligent Manufacturing Supported by Digital Twin”. Em: *IEEE Access* 8 (2020), pp. 174988–175008. ISSN: 21693536.
- Liu, Y, A Syberfeldt e M Strand. “Review of Simulation-Based Life Cycle Assessment in Manufacturing Industry”. Em: *Production and Manufacturing Research* 7.1 (2019), pp. 490–502. ISSN: 21693277. DOI: [10.1080/21693277.2019.1669505](https://doi.org/10.1080/21693277.2019.1669505).

- Lu, Y *et al.* “A Fast Genetic K-Means Clustering Algorithm”. Em: *Wayne State University, Kansas State University Manhattan, USA* (2000).
- Lu, Yanchao, Xiaoyan Li e Litao Liang. “Multi-Objective Optimization of Reverse Logistics Network Based on Improved Particle Swarm Optimization”. Em: *2008 7th World Congress on Intelligent Control and Automation*. IEEE. 2008, pp. 7476–7480.
- Lu, Yanchao, Pengchao Lu e Litao Liang. “Multi-Objective Optimization of Reverse Logistics Network Based on Random Weights and Genetic Algorithm”. Em: *2008 IEEE International Conference on Networking, Sensing and Control*. IEEE. 2008, pp. 1196–1200.
- Lu, Jun e Shichang Du. “Kriging Method-Based Return Prediction of Waste Electrical and Electronic Equipment in Reverse Logistics”. Em: *Applied Sciences* 11.8 (2021), p. 3536.
- Ma, Xin *et al.* “Digital Twin Enhanced Human-Machine Interaction in Product Lifecycle”. Em: *Procedia CIRP* 83 (2019), pp. 789–793. ISSN: 22128271. DOI: [10.1016/j.procir.2019.04.330](https://doi.org/10.1016/j.procir.2019.04.330).
- Magnanini, Maria Chiara *et al.* “A Digital Twin-Based Approach for Multi-Objective Optimization of Short-Term Production Planning”. Em: *IFAC-PapersOnLine* 54.1 (2021), pp. 140–145.
- Malik, Ali Ahmad e Arne Bilberg. “Digital Twins of Human Robot Collaboration in a Production Setting”. Em: *Procedia Manufacturing* 17 (2018), pp. 278–285. ISSN: 23519789.
- Marić, Josip e Marco Opazo-Basáez. “Green Servitization for Flexible and Sustainable Supply Chain Operations: A Review of Reverse Logistics Services in Manufacturing”. Em: *Global Journal of Flexible Systems Management* 20.1 (2019), pp. 65–80.
- Martínez, G S *et al.* “Automatic Generation of a Simulation-Based Digital Twin of an Industrial Process Plant”. Em: *Proceedings: IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society*. Institute of Electrical e Electronics Engineers Inc., 2018, pp. 3084–3089. ISBN: 9781509066841. DOI: [10.1109/IECON.2018.8591464](https://doi.org/10.1109/IECON.2018.8591464).
- Matskul, V., A. Kovalyov e M. Saiensus. “Optimization of the Cold Supply Chain Logistics Network With an Environmental Dimension”. Em: *IOP Conference Series: Earth and Environmental Science* 628.1 (2021). ISSN: 17551315. DOI: [10.1088/1755-1315/628/1/012018](https://doi.org/10.1088/1755-1315/628/1/012018).
- Melao, Nuno e Michael Pidd. “Using Component Technology to Develop a Simulation Library for Business Process Modelling”. Em: *European Journal of Operational Research* 172.1 (2006), pp. 163–178.
- Melo, André Cristiano Silva *et al.* “Frameworks for Reverse Logistics and Sustainable Design Integration Under a Sustainability Perspective: A Systematic Literature Review”. Em: *Research in Engineering Design* 32.2 (2021), pp. 225–243.

- Miguel, Cauchick *et al.* “Metodologia de Pesquisa em Engenharia de Produção e Gestão de Operações”. Em: *Rio de Janeiro: Elsevier* (2010).
- Mitchell, Melanie. “Genetic Algorithms: An Overview.” Em: *Complex*. Vol. 1. 1. Citeseer. 1995, pp. 31–39.
- Moghaddam, Kamran S. “Fuzzy Multi-Objective Model for Supplier Selection and Order Allocation in Reverse Logistics Systems Under Supply and Demand Uncertainty”. Em: *Expert Systems with Applications* 42.15-16 (2015), pp. 6237–6254.
- Moi, T, A Cibicik e T Rølvåg. “Digital Twin-Based Condition Monitoring of a Knuckle Boom Crane: An Experimental Study”. Em: *Engineering Failure Analysis* 112 (2020). ISSN: 13506307. DOI: [10.1016/j.engfailanal.2020.104517](https://doi.org/10.1016/j.engfailanal.2020.104517).
- Mokhtari, Hadi e Aliakbar Hasani. “An Energy-Efficient Multi-Objective Optimization for Flexible Job-Shop Scheduling Problem”. Em: *Computers & Chemical Engineering* 104 (2017), pp. 339–352.
- Mongeon, Philippe e Adèle Paul-Hus. “The Journal Coverage of Web of Science and Scopus: A Comparative Analysis”. Em: *Scientometrics* 106.1 (2016), pp. 213–228.
- Montevecchi *et al.* “A Method Proposal for Conducting Simulation Projects in Industry 4.0: A Cyber-Physical System in an Aeronautical Industry”. Em: *2020 Winter Simulation Conference (WSC)*. 2020, pp. 2731–2742. DOI: [10.1109/WSC48552.2020.9384041](https://doi.org/10.1109/WSC48552.2020.9384041).
- Montevecchi, Josh Arnaldo Barra *et al.* “Application of Design of Experiments on the Simulation of a Process in Automotive Industry”. Em: *2007 Winter Simulation Conference*. IEEE. 2007, pp. 1601–1609.
- Moraes, Flávia Tuane Ferreira *et al.* “Transitioning towards a sustainable circular city: How to evaluate and improve urban solid waste management in Brazil”. Em: *Waste Management & Research* 41.5 (2023), pp. 1046–1059.
- Moreno, M *et al.* “Opportunities for Redistributed Manufacturing and Digital Intelligence as Enablers of a Circular Economy”. English. Em: *International Journal of Sustainable Engineering* 12.2 (2019), pp. 77–94. ISSN: 19397038. DOI: [10.1080/19397038.2018.1508316](https://doi.org/10.1080/19397038.2018.1508316).
- Moslehi, M Saleh, Hadi Sahebi e Ashkan Teymouri. “A Multi-Objective Stochastic Model for a Reverse Logistics Supply Chain Design with Environmental Considerations”. Em: *Journal of Ambient Intelligence and Humanized Computing* 12.7 (2021), pp. 8017–8040.
- Moyne, J *et al.* “A Requirements Driven Digital Twin Framework: Specification and Opportunities”. Em: *IEEE Access* 8 (2020), pp. 107781–107801. ISSN: 21693536.
- Münch, Christopher, A Heiko e Evi Hartmann. “The Future Role of Reverse Logistics as a Tool for Sustainability in Food Supply Chains: A Delphi-Based Scenario Study”. Em: *Supply Chain Management: An International Journal* (2021).

- Nanda, Satyasai Jagannath e Ganapati Panda. “A Survey on Nature Inspired Metaheuristic Algorithms for Partitional Clustering”. Em: *Swarm and Evolutionary computation* 16 (2014), pp. 1–18.
- Nedjah, Nadia e Luiza de Macedo Mourelle. “Evolutionary Multi-Objective Optimisation: A Survey”. Em: *International Journal of Bio-Inspired Computation* 7.1 (2015), pp. 1–25.
- NETO, ALBERTO e RENATO LIMA. “Roteirização de Veículos de uma Rede Atacadista com o Auxílio de Sistemas de Informações Geográficas (SIG)”. Em: *Revista Pesquisa e Desenvolvimento Engenharia de Produção* 5 (2006), pp. 18–39.
- Ni, Zhiqin, Hing Kai Chan e Zhen Tan. “Systematic Literature Review of Reverse Logistics for E-waste: Overview, Analysis, and Future Research Agenda”. Em: *International Journal of Logistics Research and Applications* (2021), pp. 1–29.
- Okita, Taira *et al.* “A New Concept of Digital Twin of Artifact Systems: Synthesizing Monitoring/Inspections, Physical/Numerical Models, and Social System Models”. Em: *Procedia CIRP* 79 (2019), pp. 667–672. ISSN: 22128271.
- Oliveira, Josenildo Brito, Renato Silva Lima e José Arnaldo Barra Montevechi. “Perspectives and Relationships in Supply Chain Simulation: A Systematic Literature Review”. Em: *Simulation Modelling Practice and Theory* 62 (2016), pp. 166–191.
- PAES, Catia Emiliana. “Logística Reversa e Gestão de Resíduos de Equipamentos de Informática na Universidade Federal de Itajubá (UNIFEI). 158 f”. Tese de dout. Dissertação de Mestrado). Programa de Pós-Graduação em Engenharia de . . . , 2018.
- Page, B e V Wohlgemuth. “Advances in Environmental Informatics: Integration of Discrete Event Simulation Methodology With Ecological Material Flow Analysis for Modelling Eco-efficient Systems”. Em: *Procedia Environmental Sciences*. Vol. 2. 2010, pp. 696–705. DOI: [10.1016/j.proenv.2010.10.079](https://doi.org/10.1016/j.proenv.2010.10.079).
- Pandian, Gowtham Ravi Sankara e Walid Abdul-Kader. “Performance Evaluation of Reverse Logistics Enterprise - An Agent-Based Simulation Approach”. Em: *International Journal of Sustainable Engineering* 10.6 (2017), pp. 384–398.
- Panigrahi, Shrikant Krupasindhu *et al.* “A Strategic Initiative for Successful Reverse Logistics Management in Retail Industry”. Em: *Global Business Review* 19.3\_suppl (2018), S151–S175.
- Panjehfouladgaran, Hamidreza e Stanley Frederick WT Lim. “Reverse Logistics Risk Management: Identification, Clustering and Risk Mitigation Strategies”. Em: *Management Decision* (2020).
- Paterlini, Sandra e Thiemo Krink. “Differential Evolution and Particle Swarm Optimisation in Partitional Clustering”. Em: *Computational statistics & data analysis* 50.5 (2006), pp. 1220–1247.
- Patro, S. “Normalization: A preprocessing stage”. Em: *arXiv preprint arXiv:1503.06462* (2015).

- Plaza-Úbeda, José Antonio *et al.* “Trends and New Challenges in the Green Supply Chain: The Reverse Logistics”. Em: *Sustainability* 13.1 (2020), p. 331.
- Ponomarev, Kirill *et al.* “Main Principals and Issues of Digital Twin Development for Complex Technological Processes”. Em: *Annals of DAAAM and Proceedings of the International DAAAM Symposium* (2017), pp. 523–528. ISSN: 17269679. DOI: [10.2507/28th.daaam.proceedings.074](https://doi.org/10.2507/28th.daaam.proceedings.074).
- Prodanov, Cleber Cristiano e Ernani Cesar De Freitas. *Metodologia do Trabalho Científico: Métodos e Técnicas da Pesquisa e do Trabalho Acadêmico-2ª Edição*. Editora Feevale, 2013.
- Puryani, Y D Astanti e G N Fitriani. “A Case Study of Supply Chain Simulation for Determining the Best Stock Allocation”. Em: *MATEC Web of Conferences*. Ed. por Tamura H Ma'mun S. Purnomo M.R.A. Vol. 154. EDP Sciences, 2018. DOI: [10.1051/mateconf/201815401052](https://doi.org/10.1051/mateconf/201815401052).
- Putz, B *et al.* “EtherTwin: Blockchain-Based Secure Digital Twin Information Management”. Em: *Information Processing and Management* 58.1 (2021). ISSN: 03064573. DOI: [10.1016/j.ipm.2020.102425](https://doi.org/10.1016/j.ipm.2020.102425).
- Qamsane, Y *et al.* “A Methodology to Develop and Implement Digital Twin Solutions for Manufacturing Systems”. Em: *IEEE Access* 9 (2021), pp. 44247–44265. ISSN: 21693536.
- Rajesh, P. K. *et al.* “Digital Twin of an Automotive Brake Pad for Predictive Maintenance”. Em: *Procedia Computer Science* 165 (2019 2019), pp. 18–24. ISSN: 18770509.
- Reddy, Chandan K e Bhanukiran Vinzamuri. “A Survey of Partitional and Hierarchical Clustering Algorithms”. Em: *Data clustering: Algorithms and applications* 87 (2013).
- Reuter, M A. “Digitalizing the Circular Economy: Circular Economy Engineering Defined by the Metallurgical Internet of Things”. Em: *Metallurgical and Materials Transactions B: Process Metallurgy and Materials Processing Science* 47.6 (2016), pp. 3194–3220. ISSN: 10735615. DOI: [10.1007/s11663-016-0735-5](https://doi.org/10.1007/s11663-016-0735-5).
- Reuter, M A e A van Schaik. “Product-Centric Simulation-Based Design for Recycling: Case of LED Lamp Recycling”. English. Em: *Journal of Sustainable Metallurgy* 1.1 (2015), pp. 4–28. ISSN: 21993823. DOI: [10.1007/s40831-014-0006-0](https://doi.org/10.1007/s40831-014-0006-0).
- Riedelsheimer, T, L Dorfhuber e R Stark. “User Centered Development of a Digital Twin Concept With Focus on Sustainability in the Clothing Industry”. Em: *Procedia CIRP*. Ed. por Paris H Riel A Brissaud D. Zwolinski P. Vol. 90. Elsevier B.V., 2020, pp. 660–665. DOI: [10.1016/j.procir.2020.01.123](https://doi.org/10.1016/j.procir.2020.01.123).
- Rivera, L F *et al.* “On the Engineering of IoT-Intensive Digital Twin Software Systems”. Em: *Proceedings - 2020 IEEE/ACM 42nd International Conference on Software Engineering Workshops, ICSEW 2020*. Association for Computing Machinery, Inc, 2020, pp. 631–638. ISBN: 9781450379632. DOI: [10.1145/3387940.3392195](https://doi.org/10.1145/3387940.3392195).
- Robinson, Stewart. “A Tutorial on Simulation Conceptual Modeling”. Em: *2017 Winter Simulation Conference (WSC)*. IEEE. 2017, pp. 565–579.

- Rocca, Roberto *et al.* “Integrating Virtual Reality and Digital Twin in Circular Economy Practices: A Laboratory Application Case”. Em: *SUSTAINABILITY* 12.6 (mar. de 2020). DOI: [10.3390/su12062286](https://doi.org/10.3390/su12062286).
- Rocha, Tiago Barreto e Carmenlucia Santos Giordano Penteado. “Life Cycle Assessment of a Small WEEE Reverse Logistics System: Case Study in the Campinas Area, Brazil”. Em: *Journal of Cleaner Production* 314 (2021), p. 128092.
- Rödger, J.-M. *et al.* “Combining Life Cycle Assessment and Manufacturing System Simulation: Evaluating Dynamic Impacts from Renewable Energy Supply on Product-Specific Environmental Footprints”. Em: *International Journal of Precision Engineering and Manufacturing - Green Technology* 8.3 (2021), pp. 1007–1026. ISSN: 22886206. DOI: [10.1007/s40684-020-00229-z](https://doi.org/10.1007/s40684-020-00229-z).
- Rosen, Roland, Jan Fischer e Stefan Boschert. “Next Generation Digital Twin: An Ecosystem for Mechatronic Systems?” Em: *IFAC-PapersOnLine* 52.15 (2019), pp. 265–270. ISSN: 24058963. DOI: [10.1016/j.ifacol.2019.11.685](https://doi.org/10.1016/j.ifacol.2019.11.685).
- Roudbari, Erfan Shafiee, SMT Fatemi Ghomi e Mohsen S Sajadieh. “Reverse Logistics Network Design for Product Reuse, Remanufacturing, Recycling and Refurbishing Under Uncertainty”. Em: *Journal of Manufacturing Systems* 60 (2021), pp. 473–486.
- Saati, Saber *et al.* “A Fuzzy Data Envelopment Analysis for Clustering Operating Units With Imprecise Data”. Em: *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems* 21.01 (2013), pp. 29–54.
- Samir, Kousay, Antonio Maffei e Mauro A. Onori. “Real-Time Asset Tracking; A Starting Point for Digital Twin Implementation in Manufacturing”. Em: *Procedia CIRP* 81 (2019), pp. 719–723. ISSN: 22128271. DOI: [10.1016/j.procir.2019.03.182](https://doi.org/10.1016/j.procir.2019.03.182).
- Santos, Carlos Henrique dos *et al.* “Decision Support in Productive Processes Through DES and ABS in the Digital Twin Era: A Systematic Literature Review”. Em: *International Journal of Production Research* 60.8 (2021), pp. 2662–2681.
- Sargent, Robert G. “Verification, Validation and Accreditation of Simulation Models”. Em: *2000 Winter Simulation Conference Proceedings (Cat. No. 00CH37165)*. Vol. 1. IEEE. 2000, pp. 50–59.
- Sasikumar, P e G Kannan. “Issues in Reverse Supply Chains, Part I: End-of-Life Product Recovery and Inventory Management - An Overview”. Em: *International Journal of Sustainable Engineering* 1.3 (2008), pp. 154–172.
- Scheidegger, Anna Paula Galvão *et al.* “An Introductory Guide for Hybrid Simulation Modelers on the Primary Simulation Methods in Industrial Engineering Identified Through a Systematic Review of the Literature”. Em: *Computers & Industrial Engineering* 124 (2018), pp. 474–492.
- Schenk, T *et al.* “Architecture for Modeling and Simulation of Technical Systems Along Their Lifecycle”. Em: *Computing and Visualization in Science* 17.4 (2015), pp. 167–183. ISSN: 14329360. DOI: [10.1007/s00791-015-0256-9](https://doi.org/10.1007/s00791-015-0256-9).

- Schleich, B *et al.* “Shaping the Digital Twin for Design and Production Engineering”. Em: *CIRP Annals - Manufacturing Technology* 66.1 (2017), pp. 141–144. ISSN: 00078506. DOI: [10.1016/j.cirp.2017.04.040](https://doi.org/10.1016/j.cirp.2017.04.040).
- Schriber, Thomas J, Daniel T Brunner e Jeffrey S Smith. “Inside Discrete-Event Simulation Software: How it Works and Why it Matters”. Em: *2013 Winter Simulations Conference (WSC)*. IEEE. 2013, pp. 424–438.
- Schützer, Klaus *et al.* “Contribution to the Development of a Digital Twin Based on Product Lifecycle to Support the Manufacturing Process”. Em: *Procedia CIRP* 84 (2019). Teórico, pp. 82–87. ISSN: 22128271.
- Seilov, S Z *et al.* “The Concept of Building a Network of Digital Twins to Increase the Efficiency of Complex Telecommunication Systems”. Em: *Complexity* 2021 (2021). ISSN: 10762787. DOI: [10.1155/2021/9480235](https://doi.org/10.1155/2021/9480235).
- Shen, Wenbin e Sung-Ho Na. “Atmospheric acceleration and Earth-expansion deceleration of the Earth rotation”. Em: *Geodesy and Geodynamics* 8.6 (2017), pp. 421–426.
- Simões-Marques, M J. “Modeling and Simulation in System Life Cycle”. Em: *Procedia Manufacturing* 3 (2015), pp. 785–792. ISSN: 23519789. DOI: [10.1016/j.promfg.2015.07.331](https://doi.org/10.1016/j.promfg.2015.07.331).
- Simovici, Dan, Namita Singla e Michael Kuperberg. “Metric Incremental Clustering of Nominal Data”. Em: *Fourth IEEE International Conference on Data Mining (ICDM'04)*. IEEE. 2004, pp. 523–526.
- Singh, Amarbir. “A Review on Algorithms Used to Solve Multiple Travelling Salesman Problem”. Em: *International Research Journal of Engineering and Technology (IRJET)* 3.4 (2016), pp. 598–603.
- Singh, Sumit *et al.* “Towards Information Management Framework for Digital Twin in Aircraft Manufacturing”. Em: *Procedia CIRP* 96 (2020), pp. 163–168. ISSN: 22128271. DOI: [10.1016/j.procir.2021.01.070](https://doi.org/10.1016/j.procir.2021.01.070).
- Sivanandam, S.N. e S.N. Deepa. “Genetic Algorithms”. Em: *Introduction to Genetic Algorithms*. Springer Berlin Heidelberg, 2008, pp. 15–37. ISBN: 978-3-540-73190-0. DOI: [10.1007/978-3-540-73190-0\\_2](https://doi.org/10.1007/978-3-540-73190-0_2).
- Souza, Gilvan C. “Closed-Loop Supply Chains: A Critical Review, and Future Research”. Em: *Decision Sciences* 44.1 (2013), pp. 7–38.
- Srinivas, M e C Krishna Mohan. “Efficient Clustering Approach Using Incremental and Hierarchical Clustering Methods”. Em: *The 2010 International Joint Conference on Neural Networks (IJCNN)*. IEEE. 2010, pp. 1–7.
- Srivastava, Samir K. “Green Supply-Chain Management: A State-of-the-Art Literature Review”. Em: *International journal of management reviews* 9.1 (2007), pp. 53–80.
- Stichhauerova, Eva, Miroslav Zizka e Natalie Pelloneova. “Comparison of the Significance of Clusters for Increasing Business Performance”. Em: *Journal of Competitiveness* 12.3 (2020), p. 172.

- Straka, M *et al.* “Environmental Assessment of Waste Total Recycling Based on Principles of Logistics and Computer Simulation Design”. Em: *Polish Journal of Environmental Studies* 28.3 (2019), pp. 1367–1375. ISSN: 12301485. DOI: [10.15244/pjoes/89540](https://doi.org/10.15244/pjoes/89540).
- Svennerberg, Gabriel. *Beginning Google Maps API 3*. Apress, 2010.
- Tako, Antuela A e Stewart Robinson. “The Application of Discrete Event Simulation and System Dynamics in the Logistics and Supply Chain Context”. Em: *DECISION SUPPORT SYSTEMS* 52.4, SI (mar. de 2012), pp. 802–815. ISSN: 0167-9236. DOI: [10.1016/j.dss.2011.11.015](https://doi.org/10.1016/j.dss.2011.11.015).
- Talkhestani, Behrang Ashtari *et al.* “Consistency Check to Synchronize the Digital Twin of Manufacturing Automation Based on Anchor Points”. Em: *Procedia CIRP* 72 (2018), pp. 159–164. ISSN: 22128271.
- Talkhestani, Behrang Ashtari *et al.* “Qualitative and Quantitative Evaluation of Reconfiguring an Automation System Using Digital Twin”. Em: *Procedia CIRP* 93 (2020), pp. 268–273. ISSN: 22128271.
- Tanimizu, Y e Y Shimizu. “A Study on Closed-Loop Supply Chain Model for Parts Reuse With Economic Efficiency”. English. Em: *Journal of Advanced Mechanical Design, Systems and Manufacturing* 8.5 (2014). ISSN: 18813054. DOI: [10.1299/jamdsm.2014jamdsm0068](https://doi.org/10.1299/jamdsm.2014jamdsm0068).
- Tao, Fei e Meng Zhang. “Digital Twin Shop-Floor: a New Shop-Floor Paradigm Towards Smart Manufacturing”. Em: *Ieee Access* 5 (2017), pp. 20418–20427.
- Tariq, Rasikh *et al.* “Digital Twin Models for Optimization and Global Projection of Building-Integrated Solar Chimney”. Em: *Building and Environment* 213 (2022), p. 108807.
- Tekinerdogan, B e C Verdouw. “Systems Architecture Design Pattern Catalog for Developing Digital Twins”. Em: *Sensors (Switzerland)* 20 (18 2020), pp. 1–20. ISSN: 14248220.
- Torres, Jorge *et al.* “Building Digital Twins to Overcome Digitalization Barriers for Automating Construction Site Management”. Em: *Buildings* 14.7 (2024), p. 2238.
- Tosarkani, Babak Mohamadpour, Saman Hassanzadeh Amin e Hossein Zolfagharinia. “A Scenario-Based Robust Possibilistic Model for a Multi-Objective Electronic Reverse Logistics Network”. Em: *International Journal of Production Economics* 224 (2020), p. 107557.
- Uhlemann, T.H.-J., C Lehmann e R Steinhilper. “The Digital Twin: Realizing the Cyber-Physical Production System for Industry 4.0”. Em: *Procedia CIRP*. Ed. por Takata S Umeda Y. Kondoh S. Vol. 61. Elsevier B.V., 2017, pp. 335–340. DOI: [10.1016/j.procir.2016.11.152](https://doi.org/10.1016/j.procir.2016.11.152).
- Umeda, S. “Simulation Analysis of Supply Chain Systems With Reverse Logistics”. Em: *Proceedings of the 2013 Winter Simulation Conference - Simulation: Making Decisions in a Complex World, WSC 2013*. 2013, pp. 3375–3384. ISBN: 9781479939503. DOI: [10.1109/WSC.2013.6721701](https://doi.org/10.1109/WSC.2013.6721701).

- Uriarte-Miranda, Maria-Lizbeth *et al.* “Reverse Logistic Strategy for the Management of Tire Waste in Mexico and Russia: Review and Conceptual Model”. Em: *Sustainability* 10.10 (2018), p. 3398.
- Valdecy. pyVRP: Vehicle Routing Problem in Python. <https://github.com/Valdecy/pyVRP>. Acessado em: 28 de setembro de 2023. 2024.
- Vieira, Barbara de Oliveira *et al.* “Prioritizing Barriers to be Solved to the Implementation of Reverse Logistics of E-waste in Brazil Under a Multicriteria Decision Aid Approach”. Em: *Sustainability* 12.10 (2020), p. 4337.
- Vijaya, PA, M Narasimha Murty e DK Subramanian. “Leaders-Subleaders: An Efficient Hierarchical Clustering Algorithm for Large Data Sets”. Em: *Pattern Recognition Letters* 25.4 (2004), pp. 505–513.
- Voigt, Derek *et al.* “Performance Evaluation of Reverse Logistics: Opportunities for Future Research”. Em: *Sustainability* 11.19 (2019), p. 5291.
- Wang, Hongyu, Huicheng Hao e Mengdi Wang. “Optimization research on multi-trip distribution of reverse logistics terminal for automobile scrap parts under the background of sustainable development strategy”. Em: *Scientific Reports* 14.1 (2024), p. 17305.
- Wang, Junfeng *et al.* “Event-Driven Online Machine State Decision for Energy-Efficient Manufacturing System Based on Digital Twin Using Max-Plus Algebra”. Em: *Sustainability (Switzerland)* 11.18 (2019). ISSN: 20711050. DOI: [10.3390/su11185036](https://doi.org/10.3390/su11185036).
- Wang, X V e L Wang. “Digital Twin-Based WEEE Recycling, Recovery and Remanufacturing in the Background of Industry 4.0”. English. Em: *International Journal of Production Research* 57.12 (2019), pp. 3892–3902. ISSN: 00207543. DOI: [10.1080/00207543.2018.1497819](https://doi.org/10.1080/00207543.2018.1497819).
- Wang, Yadong e Quan Shi. “Spare Parts Closed-Loop Logistics Network Optimization Problems: Model Formulation and Meta-Heuristics Solution”. Em: *IEEE access* 7 (2019), pp. 45048–45060.
- Waqas, Muhammad *et al.* “Critical Barriers to Implementation of Reverse Logistics in the Manufacturing Industry: A Case Study of a Developing Country”. Em: *Sustainability* 10.11 (2018), p. 4202.
- Webster, Jane e Richard T Watson. “Analyzing the Past to Prepare for the Future: Writing a Literature Review”. Em: *MIS quarterly* (2002), pp. xiii–xxiii.
- Widok, A H, V Wohlgemuth e B Page. “Combining Sustainability Criteria With Discrete Event Simulation”. Em: *Proceedings - Winter Simulation Conference*. 2011, pp. 859–870. ISBN: 9781457721083. DOI: [10.1109/WSC.2011.6147812](https://doi.org/10.1109/WSC.2011.6147812).
- Wright, Louise e Stuart Davidson. “How to Tell the Difference Between a Model and a Digital Twin”. Em: *Advanced Modeling and Simulation in Engineering Sciences* 7.1 (2020), pp. 1–13.
- Xie, R *et al.* “Digital Twin Technologies for Turbomachinery in a Life Cycle Perspective: A Review”. Em: *Sustainability (Switzerland)* 13 (5 2021), pp. 1–21. ISSN: 20711050.

- Yim, Odilia e Kylee T Ramdeen. “Hierarchical Cluster Analysis: Comparison of Three Linkage Measures and Application to Psychological Data”. Em: *The quantitative methods for psychology* 11.1 (2015), pp. 8–21.
- Yu, G *et al.* “Prediction of Highway Tunnel Pavement Performance Based on Digital Twin and Multiple Time Series Stacking”. Em: *Advances in Civil Engineering* 2020 (2020). ISSN: 16878086. DOI: [10.1155/2020/8824135](https://doi.org/10.1155/2020/8824135).
- Yu, Hao e Xu Sun. “Uncertain remanufacturing reverse logistics network design in industry 5.0: Opportunities and challenges of digitalization”. Em: *Engineering Applications of Artificial Intelligence* 133 (2024), p. 108578.
- Zarbakshnia, Navid *et al.* “A Novel Sustainable Multi-Objective Optimization Model for Forward and Reverse Logistics System Under Demand Uncertainty”. Em: *Annals of Operations Research* 295.2 (2020), pp. 843–880.
- Zatrochová, Monika, Martina Kuperová e Július Golej. “Analysis of the Principles of Reverse Logistics in Waste Management”. Em: *Acta Logistica* 8.2 (2021), pp. 95–106.
- Zhang, Haiwen *et al.* “Digital Twin in Services and Industrial Product Service Systems: Review and Analysis”. Em: *Procedia CIRP* 83 (2019), pp. 57–60. ISSN: 22128271. DOI: [10.1016/j.procir.2019.02.131](https://doi.org/10.1016/j.procir.2019.02.131).
- Zhang, Xumei *et al.* “A Review on Remanufacturing Reverse Logistics Network Design and Model Optimization”. Em: *Processes* 10.1 (2021), p. 84.
- Zhang, Xumei *et al.* “An Integrated Multicriteria Decision-Making Approach for Collection Modes Selection in Remanufacturing Reverse Logistics”. Em: *Processes* 9.4 (2021), p. 631.
- Zhang, Xumei, Zhizhao Li e Yan Wang. “A Review of the Criteria and Methods of Reverse Logistics Supplier Selection”. Em: *Processes* 8.6 (2020), p. 705.
- Zhao, Liang *et al.* “INTERLINK: A Digital Twin-Assisted Storage Strategy for Satellite-Terrestrial Networks”. Em: *IEEE Transactions on Aerospace and Electronic Systems* (2022).
- Zhu, Erzhou e Ruhui Ma. “An Effective Partitional Clustering Algorithm Based on New Clustering Validity Index”. Em: *Applied soft computing* 71 (2018), pp. 608–621.
- Zou, H *et al.* “A Coordinated Revenue-Sharing Model for a Sustainable Closed-Loop Supply Chain”. Em: *Sustainability (Switzerland)* 10.9 (2018). ISSN: 20711050. DOI: [10.3390/su10093198](https://doi.org/10.3390/su10093198).

## 8. Apêndice

### 8.1 Apêndice I - Resultados do *Framework* Multiveículo

Tabela 8.1.1 – Valores calculados para a primeira semana.

	<b>Cluster1</b>	<b>Cluster 2</b>	<b>Cluster 3</b>
<b>Custo Médio</b>	2467,4 ± 493	2406,5 ± 415,2	2521,7 ± 459,2
<b>Peso</b>	4094,15	601,78	527
<b>Custo Médio de Emissão de CO2</b>	27,03 ± 9,02	10,96 ± 7,96	10,59 ± 0,06
<b>Tempo</b>	7,46	6,54	7,86
<b>Custo Fracionado</b>	3246,74	687,34	583,36
<b>Número do Cluster</b>	9	17	18
<b>Tamanho</b>	7	5	1
<b>Distância</b>	419,08	266,3	505,24

Tabela 8.1.2 – Valores calculados para a segunda semana.

	<b>Custo Médio</b>	<b>Peso</b>	<b>Custo Médio de Emissão de CO2</b>	<b>Tempo</b>	<b>Custo Fracionado</b>	<b>Número do Cluster</b>	<b>Tamanho</b>	<b>Distância</b>
Cluster 1	2431±506,7	555	28,96±12,32	6,16	818,07	3	3	367,99
Cluster 2	2561,6±696,8	7125,95	21,31±11,47	8,07	6199,03	13	12	394,39
Cluster 3	1761,3±277,2	597,56	21,28±8,38	4,36	696,44	16	5	229,07
Cluster 4	2398,6±220,1	1226,61	27,34±14,30	7,63	1227,07	17	8	409,57
Cluster 5	1947,6±422,2	722,32	13,01±7,89	4,6	825,97	18	4	277,1
Cluster 6	1851,7±564,7	1201,4	8,44±7,00	5,29	1169,54	19	7	305,61
Cluster 7	2546,2±528,5	510,48	36,39±16,80	7,63	662,75	28	5	441,69
Cluster 8	21128,3±481	789,84	8,95±6,95	5,13	725,41	32	4	311,62
Cluster 9	1788,9±641	481,7	8,95±6,94	5,01	410,29	35	3	309,56

Tabela 8.1.3 – Valores calculados para a terceira semana.

	<b>Custo Médio</b>	<b>Peso</b>	<b>Custo Médio de Emissão de CO2</b>	<b>Tempo</b>	<b>Custo Fracionado</b>	<b>Número do Cluster</b>	<b>Tamanho</b>	<b>Distância</b>
<b>Cluster 1</b>	1552,7±569,4	1687,72	8,92±5,90	4,47	1439,61	10	6	642,84
<b>Cluster 2</b>	2234,4±401,3	1638,5	21,77±8,19	5,72	1714,68	14	5	216,23
<b>Cluster 3</b>	1254,9±307,7	1755,82	8,11±3,82	3,99	1337,14	20	5	311,9
<b>Cluster 4</b>	1490,6±430,7	1564,5	8,55±6,83	4,71	1526,91	25	4	248,63
<b>Cluster 5</b>	2010,8±481,2	913,96	17,84±8,74	4,90	868,74	28	4	242,97
<b>Cluster 6</b>	2747,8±683,7	568,81	32,94±19,74	7,26	546,71	29	5	296,09
<b>Cluster 7</b>	2382,2±736,2	754,79	17,35±11,83	6,26	839,85	30	6	332,36
<b>Cluster 8</b>	2672,4±499,8	718,79	29,87±11,02	7,74	704,10	32	6	438,1
<b>Cluster 9</b>	915,12±325,61	453	4,24±3,27	2,01	378,81	33	2	119,79
<b>Cluster 10</b>	1700,5±576,1	553,79	8,79±4,54	5,20	577,32	42	5	414,41
<b>Cluster 11</b>	1194,7±657,7	670,98	10,05±8,04	3,53	585,72	43	3	293,07
<b>Cluster 12</b>	1344,1±324,7	570	4,84±0,02	3,66	586,10	44	1	232,61
<b>Cluster 13</b>	2728,8±441	521,38	35,05±17,64	6,66	517,85	54	4	389,42

Tabela 8.1.4 – Valores calculados para a quarta semana.

	Custo Médio	Peso	Custo Médio de Emissão de CO <sub>2</sub>	Tempo	Custo Fracionado	Número do Cluster	Tamanho	Distância
Cluster 1	2564,8±500,4	879,5	35,84±16,34	6,52	1217,81	1	4	380,57
Cluster 2	2151,4±616	932	14,54±9,88	5,44	1256,38	4	4	331,79
Cluster 3	1486,8±401,6	965	9,99±5,34	3,66	1284,38	7	4	216,55
Cluster 4	2040,7±487	3987,09	10,08±5,66	6,56	4165,07	8	9	377,44
Cluster 5	2117,9±576,8	1190,5	24,21±11,63	5,65	1507,43	16	4	323,71
Cluster 6	2022,9±696	772,81	6,05±0,04	5,46	897,66	20	6	322,32
Cluster 7	2021,2±323,1	463	24,63±6,69	4,87	496,67	24	2	295,14

Tabela 8.1.5 – Valores calculados para a quinta semana.

	Custo Médio	Peso	Custo Médio de Emissão de CO2	Tempo	Custo Fracionado	Número do Cluster	Tamanho	Distância
Cluster 1	1870,7±641,3	561,5	9,12±4,61	5,52	783,05	2	3	342,97
Cluster 2	2277,9±693,9	1682,75	29,28±9,85	6,46	2104,31	3	6	354,63
Cluster 3	1889,4±825,2	541	10,61±8,45	5,09	647,39	4	5	304,05
Cluster 4	1584,4±637,1	1831,5	12,47±9,11	4,83	1631,97	5	2	302,90
Cluster 5	874,9±167,9	524,5	2,68±1,15	1,96	663,28	8	3	111,21
Cluster 6	2441,8±606,5	15801,32	20,61±14,47	7,77	14552,44	10	7	429,22
Cluster 7	2532,2±790,5	18167,56	22,48±11,92	7,43	16478,47	12	11	363,72
Cluster 8	1798,3±432,8	2139,56	10,36±5,63	4,91	1977,53	13	6	286,69
Cluster 9	2214,2±472,1	2912,31	9,70±5,23	6,82	2169,02	14	7	405,58
Cluster 10	1331,2±451,9	2094,8	7,51±6,58	3,73	1879,58	15	4	220,95
Cluster 11	2536,8±406	1458,38	28,87±8,84	7,46	1450,68	16	6	417,7
Cluster 12	1616,7±363,2	1845,80	9,65±7,30	3,87	1741,94	17	4	229,71
Cluster 13	1565±467,1	1153,74	6,51±5,38	4,39	1168,22	18	3	268,96
Cluster 14	1715,5±677,3	1263,5	11,88±7,86	5,29	1230,36	20	5	316,46
Cluster 15	2429,2±816,3	514	26,37±8,43	6,60	586,91	22	4	385,4
Cluster 16	2204,2±482,3	687	26,12±9,01	5,83	761,40	28	4	335,43
Cluster 17	1537,1±623,4	756,25	8,98±6,45	4,70	819,28	31	4	283,52
Cluster 18	2168,4±468,8	548	24,06±9,13	5,12	656,72	37	3	300,04
Cluster 19	1277,2±292,9	643	5,32±2,31	3,66	643,24	41	3	221,9

Tabela 8.1.6 – Valores calculados para a sexta semana.

	<b>Custo Médio</b>	<b>Peso</b>	<b>Custo Médio de Emissão de CO2</b>	<b>Tempo</b>	<b>Custo Fracionado</b>	<b>Número do Cluster</b>	<b>Tamanho</b>	<b>Distância</b>
<b>Cluster 1</b>	2013,1±336,5	2580,8	15,57±6,91	5,36	2721,27	5	5	293,93
<b>Cluster 2</b>	2019,7±300,3	12973,77	23,62±11,40	6,81	11708,14	10	13	301,8
<b>Cluster 3</b>	2398,4±720	1521,96	26,44±10,01	7,41	1867,92	11	9	384,35
<b>Cluster 4</b>	2291,8±376,8	2219,3	21,46±8,18	5,02	2379,72	13	4	282,88
<b>Cluster 5</b>	2592,6±642	2016,5	22,61±8,71	6,73	2209,07	17	5	383,39
<b>Cluster 6</b>	2481,3±531,1	2667,46	31,19±5,68	7,16	1689,58	20	7	389,47
<b>Cluster 7</b>	2017,8±509,1	633,52	21,60±9,89	5,10	767,57	21	5	277,28
<b>Cluster 8</b>	2533,2±432,1	557,98	34,35±9,52	7,06	530,69	27	3	426,28
<b>Cluster 9</b>	1150±387,8	464,5	7,76±6,19	3,14	460,56	28	2	193,43
<b>Cluster 10</b>	1742,4±479,1	1505,6	10,30±7,00	4,23	1729,77	33	7	237,24
<b>Cluster 11</b>	1929±349,1	1430,95	21,00±8,68	5,02	1611,71	35	6	261,09
<b>Cluster 12</b>	1364,9±232,3	978,79	7,64±5,06	3,31	1052,59	36	4	193,69

Tabela 8.1.7 – Valores calculados para a sétima semana.

	<b>Custo Médio</b>	<b>Peso</b>	<b>Custo Médio de Emissão de CO2</b>	<b>Tempo</b>	<b>Custo Fracionado</b>	<b>Número do Cluster</b>	<b>Tamanho</b>	<b>Distância</b>
<b>Cluster 1</b>	2472,72±540,06	3244	26,07±3,76	6,9	3622,87	1	8	361,95
<b>Cluster 2</b>	2014,42±746,09	530,5	13,15±6,55	6,27	911,03	2	4	386,07
<b>Cluster 3</b>	2147,32±632,23	3032,5	11,00±8,77	6,46	3247,06	6	8	224,22
<b>Cluster 4</b>	1799,61±455,09	869,5	17,39±7,56	3,95	870,05	8	3	224,22
<b>Cluster 5</b>	1974,41±306,61	1026	19,49±7,17	5,08	1261,32	9	5	276,03
<b>Cluster 6</b>	1449,32±492,76	13745,81	42,01±8,20	4,44	14250,13	11	13	218,31
<b>Cluster 7</b>	2726,78±922,5	3769,02	26,46±15,55	8,62	3349,97	12	10	451,74
<b>Cluster 8</b>	1643,9±272,91	836,45	16,39±7,27	4,23	877,97	14	5	221,09
<b>Cluster 9</b>	3081,08±1016,78	482	11,95±0,09	8,84	666,61	15	1	569,08
<b>Cluster 10</b>	2022,13±402,46	826	23,45±14,00	4,89	869,76	16	3	285,32
<b>Cluster 11</b>	2432,83±717,66	556	10,55±0,04	7,86	654,28	21	1	505,24
<b>Cluster 12</b>	2135,13±196,08	1852,07	11,74±7,82	5,75	1769,55	25	7	336,05
<b>Cluster 13</b>	2163,68±473,17	1334,94	22,12±12,42	6,36	1769,55	26	4	370,04
<b>Cluster 14</b>	1228,55±260,49	582	6,61±4,35	2,83	549,10	33	2	173,03
<b>Cluster 15</b>	1934,97±775,11	1052,23	14,66±9,66	6,5	1105,91	41	6	390,01

Tabela 8.1.8 – Valores calculados para a oitava semana.

	<b>Custo Médio</b>	<b>Peso</b>	<b>Custo Médio de Emissão de CO2</b>	<b>Tempo</b>	<b>Custo Fracionado</b>	<b>Número do Cluster</b>	<b>Tamanho</b>	<b>Distância</b>
<b>Cluster 1</b>	1393,70±464,20	962,5	6,09±4,71	3,42	1398,77	1	3	206,27
<b>Cluster 2</b>	3422,86±684,55	899,5	44,15±16,50	8,47	1017,88	2	3	513,37
<b>Cluster 3</b>	4014,67±887	635	51,50±24,63	15,04	760,71	3	3	945,09
<b>Cluster 4</b>	2082,45±815,01	769,5	9,27±4,71	5,68	872,13	4	2	358,33
<b>Cluster 5</b>	1904,25±527,30	21592,05	46,39±4,40	6,64	17319,17	7	15	268,85
<b>Cluster 6</b>	2052,59±646,46	486,06	11,11±9,60	5,74	858,07	8	2	362,28
<b>Cluster 7</b>	1203,46±519,16	2411,92	6,35±4,73	3,83	2097,75	12	8	205,81
<b>Cluster 8</b>	2643,29±1044,12	4627,75	23,19±15,72	8,80	4058,67	13	10	217,71
<b>Cluster 9</b>	1113,11±330,65	894,44	3,65±1,60	2,44	898,81	15	1	153,12
<b>Cluster 10</b>	4634,72±902,64	577	71,39±36,36	13,79	674,17	18	2	874,88
<b>Cluster 11</b>	2002,15±602,45	734,5	6,32±0,07	4,80	758,49	19	1	306,58
<b>Cluster 12</b>	2024,42±415,93	2116,62	21,91±8,22	5,29	1651,70	21	7	267,75
<b>Cluster 13</b>	2010,77±453,02	2111,49	22,16±10,76	6,46	1643,60	22	6	355,17
<b>Cluster 14</b>	2853,33±531,90	1162,46	41,49±11,09	7,48	1286,46	23	6	420,88
<b>Cluster 15</b>	2216,68±363,40	2285,67	21,64±10,27	6,17	1850,86	24	6	335,96
<b>Cluster 16</b>	1839,08±265,08	1806,28	21,32±11,41	5,82	1316,13	25	3	345,97
<b>Cluster 17</b>	1577,50±471,68	908,31	5,72±0,02	4,60	984,30	26	5	271,6
<b>Cluster 18</b>	1518,59±714,85	691,44	11,73±9,72	4,50	715,81	37	4	270,8
<b>Cluster 19</b>	2742,66±752,79	1418,24	36,55±18,89	7,57	1144,80	46	5	437,87
<b>Cluster 20</b>	2585,60±533,97	474,9	27,88±13,07	6,31	484,88	47	3	377,63

Tabela 8.1.9 – Valores calculados para a nona semana.

	<b>Custo Médio</b>	<b>Peso</b>	<b>Custo Médio de Emissão de CO2</b>	<b>Tempo</b>	<b>Custo Fracionado</b>	<b>Número do Cluster</b>	<b>Tamanho</b>	<b>Distância</b>
<b>Cluster 1</b>	455,09±74,61	543	0,73±0,31	0,55	766,51	1	1	30,30
<b>Cluster 2</b>	2612,81±718,43	651	14,79±6,39	9,25	822,79	2	2	590,34
<b>Cluster 3</b>	2204,63±575,53	2452,5	27,47±14,30	5,90	2842,96	9	5	329,31
<b>Cluster 4</b>	2821,04±1180,12	495,5	16,49±12,32	12,12	604,58	10	1	782,14
<b>Cluster 5</b>	2248,58±305,93	16380,24	38,21±4,56	6,78	13533,11	11	12	310,44
<b>Cluster 6</b>	2560,06±418,71	15903,4	37,05±3,20	8,37	13240,57	13	12	414,31
<b>Cluster 7</b>	2289,40±477,59	462	27,13±8,69	4,78	577,96	14	3	278,45
<b>Cluster 8</b>	1806,46±692,06	752,10	9,93±8,17	5,47	914,68	18	2	344,58
<b>Cluster 9</b>	2073,33±590,88	562,5	23,91±8,29	5,57	139,21	24	4	318,82
<b>Cluster 10</b>	2559,36±486,26	3345,14	32,92±18,01	8,27	2467,30	25	8	450,99
<b>Cluster 11</b>	2248,71±532,37	1211,76	29,56±9,80	6,18	1185,74	27	6	336,69
<b>Cluster 12</b>	2192,84±475,39	1936,43	22,58±12,80	6,77	1354,17	28	5	385,73
<b>Cluster 13</b>	2501,62±788,49	2519,54	32,92±9,72	7,28	1785,19	30	7	397,28
<b>Cluster 14</b>	2135,20±658,17	894,43	14,27±6,32	4,89	358,34	31	2	306,79
<b>Cluster 15</b>	2352,78±886,84	585	9,45±0,04	7,06	604,60	32	1	453,6
<b>Cluster 16</b>	2743,13±694,73	459,5	15,97±9,54	6,39	494,77	34	2	404,75
<b>Cluster 17</b>	1755,15±761,55	689,60	7,13±0,06	5,39	818,53	37	1	344,73
<b>Cluster 18</b>	1402,52±555,34	1839,47	9,63±8,45	4,20	1186,17	43	5	246,05
<b>Cluster 19</b>	1255,75±283,40	858,43	3,98±0,06	3,07	299,60	44	1	194,18
<b>Cluster 20</b>	1881,33±291,83	574,72	14,15±9,60	4,27	495,88	53	2	266,89

Tabela 8.1.10 – Valores calculados para a décima semana.

	<b>Custo Médio</b>	<b>Peso</b>	<b>Custo Médio de Emissão de CO2</b>	<b>Tempo</b>	<b>Custo Fracionado</b>	<b>Número do Cluster</b>	<b>Tamanho</b>	<b>Distância</b>
<b>Cluster 1</b>	4395,32±1132,22	718	56,50±27,61	14,51	912,51	1	2	921,78
<b>Cluster 2</b>	2303,35±440,44	985,39	42,48±16,52	7,25	1004,49	2	4	428,10
<b>Cluster 3</b>	1545,94±515	1192,2	6,96±3,57	4,38	652,08	5	4	262,84
<b>Cluster 4</b>	2703,61±808,34	536	11,92±0,07	8,84	696,68	6	1	569,08
<b>Cluster 5</b>	2266,11±464,33	669,94	26,99±12,50	6,49	895,81	7	6	356,65
<b>Cluster 6</b>	2904,40±984,76	23789,04	45,95±6,65	10,31	17565,90	10	12	539,93
<b>Cluster 7</b>	2207,78±489,07	23515,41	45,31±3,05	7,20	18152,62	11	13	327,43
<b>Cluster 8</b>	2678,21±586,79	23443,45	39,28±3,54	8,06	17386,22	12	12	394,19
<b>Cluster 9</b>	1665,54±601,24	22666,16	42,23±4,03	4,58	17670,62	13	13	227,42
<b>Cluster 10</b>	1736,42±337,23	583,12	9,41±4,87	4,89	680,11	14	5	291,04
<b>Cluster 11</b>	1698,22±540,21	1917,34	11,19±7,41	5,13	1944,25	16	7	295,35
<b>Cluster 12</b>	3104,13±544,03	900,61	34,50±17,65	7,96	840,15	20	4	473,89
<b>Cluster 13</b>	2149,52±614,88	1169,95	11,74±7,04	5,56	1666,46	26	5	333,99
<b>Cluster 14</b>	3108,44±614,88	483,5	20,26±0,18	14,88	512,93	27	1	962,08
<b>Cluster 15</b>	1891,79±643,34	632,39	11,32±7,47	4,83	547,68	31	3	297,94
<b>Cluster 16</b>	1992,35±425,39	871,41	10,75±8,84	6,33	1019,08	34	5	384,08
<b>Cluster 17</b>	1651,2±282,88	1857,03	20,91±7,86	5,16	1760,05	35	6	270,28
<b>Cluster 18</b>	1782,35±347,27	683,5	11,56±8,29	5,22	764,74	38	3	322,96
<b>Cluster 19</b>	2352,47±705,04	653,91	17,74±10,40	5,94	720,66	41	3	369,56
<b>Cluster 20</b>	3313,37±859,06	697,61	48,66±18,14	8,37	576,91	43	3	511,41
<b>Cluster 21</b>	1751,62±342,36	1694,28	20,03±7,49	3,91	1464,32	50	4	210,94
<b>Cluster 22</b>	1445,57±455,71	547,2	5,08±0,02	3,82	330,41	51	1	242,9
<b>Cluster 23</b>	1126,77±397,32	458	9,72±7,30	3,50	494,62	58	2	216,88

## 8.2 Apêndice II - BoxPlots dos Clusters do *Framework* Multi-veículo

Em todos os boxplots a seguir foram utilizados o teste One Sample-t para testar as amostras. A hipótese nula  $H_0$  é a de que a média hipotética (valor pago pela empresa) é menor que o valor calculado pelo *Framework*. Portanto, quando p-value se aproxima de 0, é possível rejeitar a hipótese alternativa com mais certeza.

Figura 8.2.1 – Cluster 1, semana 1, com p-value = 0,000.

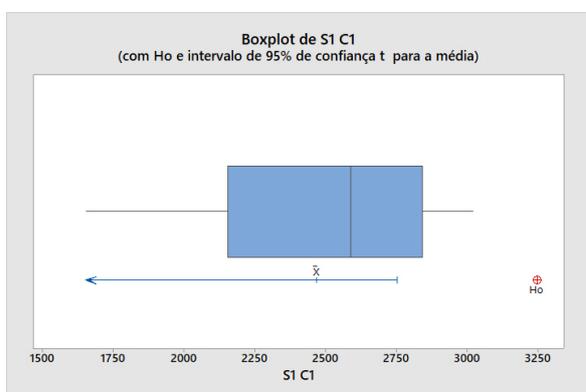


Figura 8.2.4 – Cluster 1, semana 2, com p-value = 1,000.

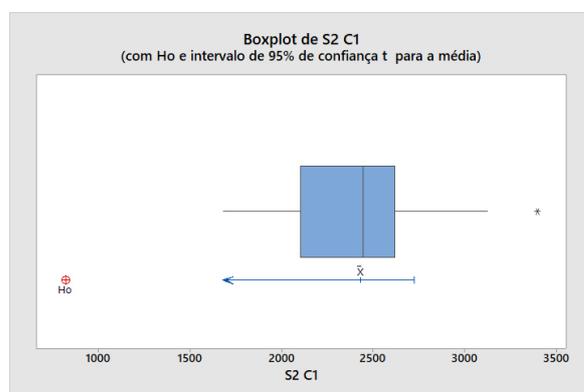


Figura 8.2.2 – Cluster 2, semana 1, com p-value = 0,000.

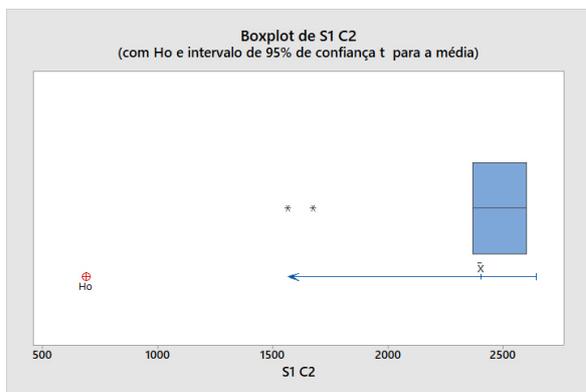


Figura 8.2.5 – Cluster 2, semana 2, com p-value = 0,000.

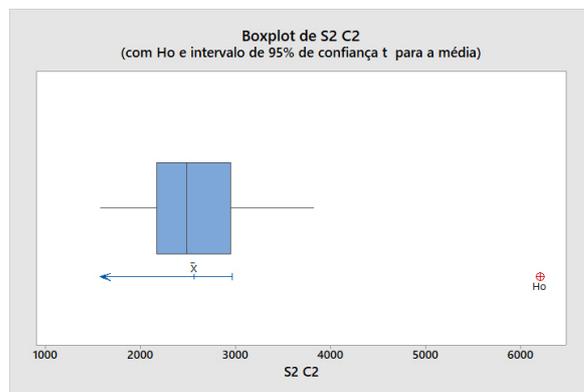


Figura 8.2.3 – Cluster 3, semana 1, com p-value = 1,000.

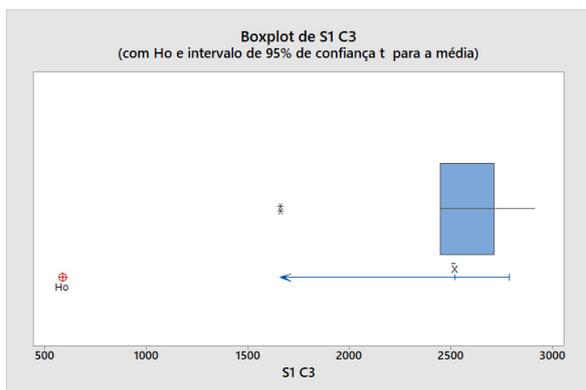


Figura 8.2.6 – Cluster 3, semana 2, com p-value = 1,000.

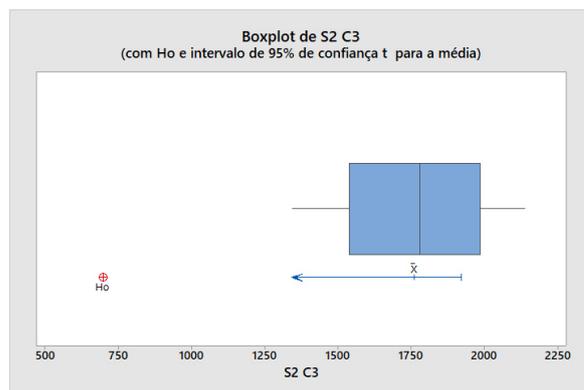


Figura 8.2.7 – Cluster 4, semana 2, com p-value = 1,000.

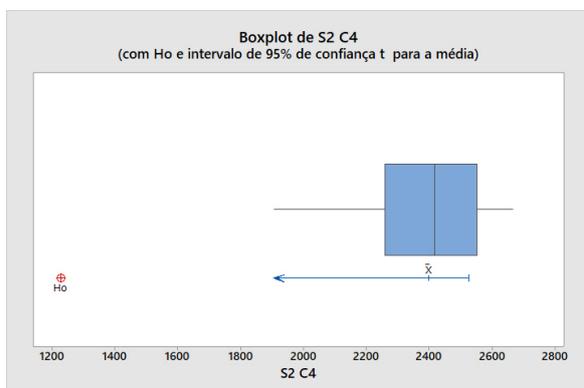


Figura 8.2.10 – Cluster 7, semana 2, com p-value = 1,000.

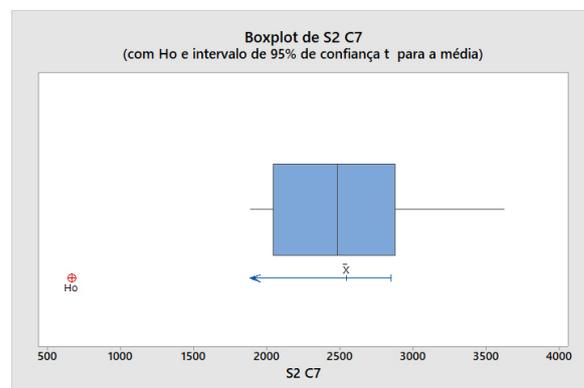


Figura 8.2.8 – Cluster 5, semana 2, com p-value = 1,000.

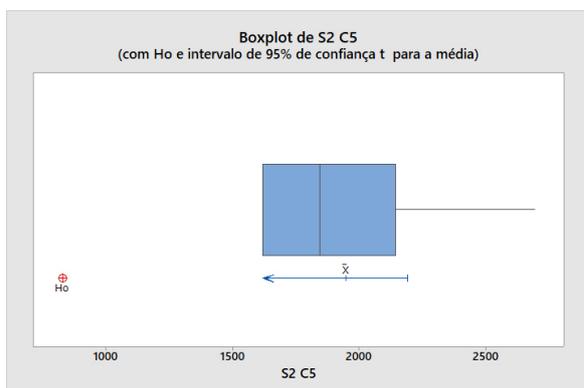


Figura 8.2.11 – Cluster 8, semana 2, com p-value = 1,000.

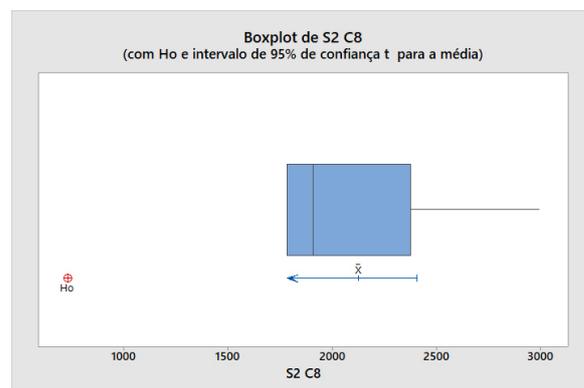


Figura 8.2.9 – Cluster 6, semana 2, com p-value = 0,998.

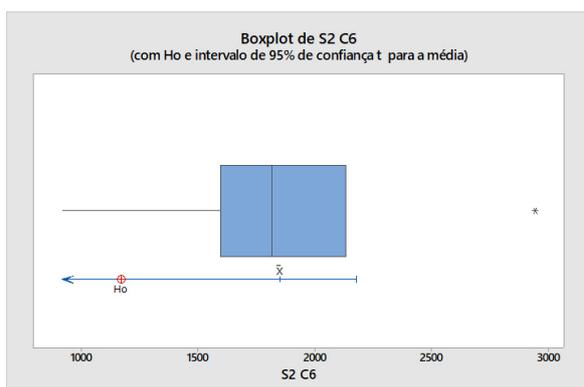


Figura 8.2.12 – Cluster 9, semana 2, com p-value = 0,998.

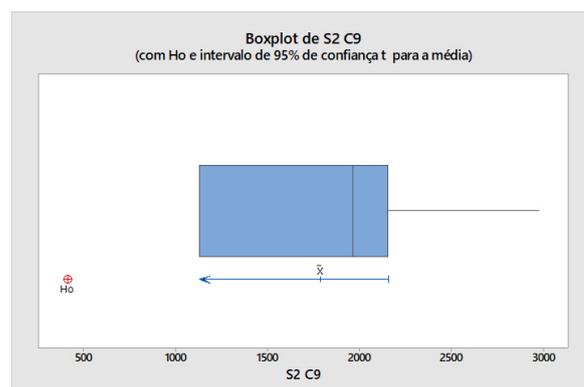


Figura 8.2.13 – Cluster 1, semana 3, com p-value = 1,000.

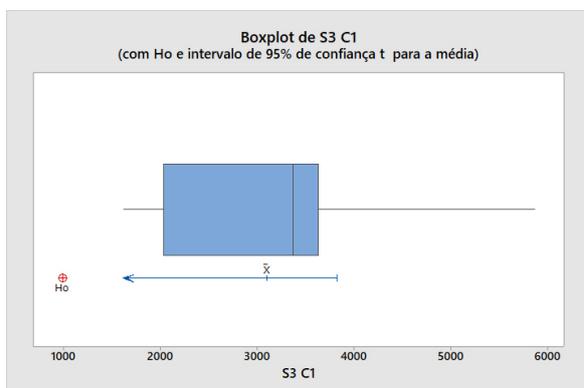


Figura 8.2.16 – Cluster 4, semana 3, com p-value = 0,999.

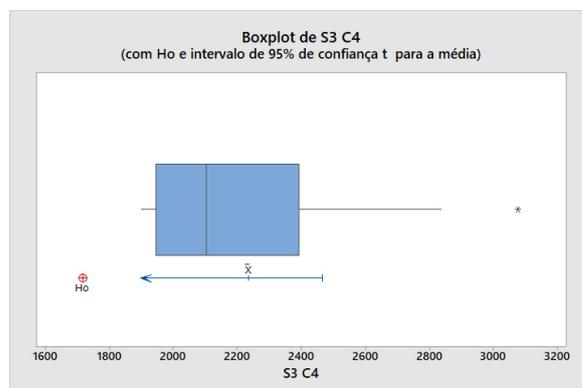


Figura 8.2.14 – Cluster 2, semana 3, com p-value = 1,000.

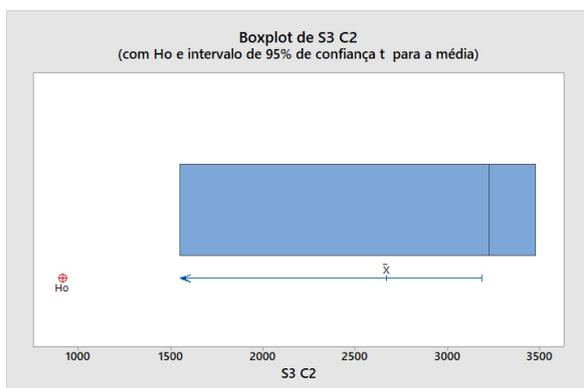


Figura 8.2.17 – Cluster 5, semana 3, com p-value = 0,000.

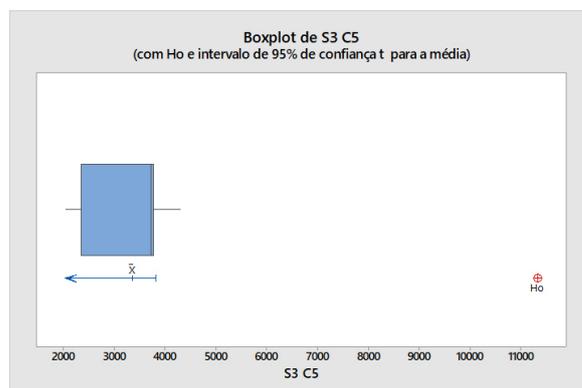


Figura 8.2.15 – Cluster 3, semana 3, com p-value = 0,727.

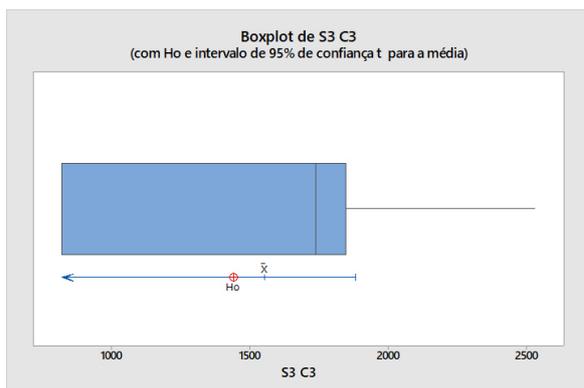


Figura 8.2.18 – Cluster 6, semana 3, com p-value = 0,210.

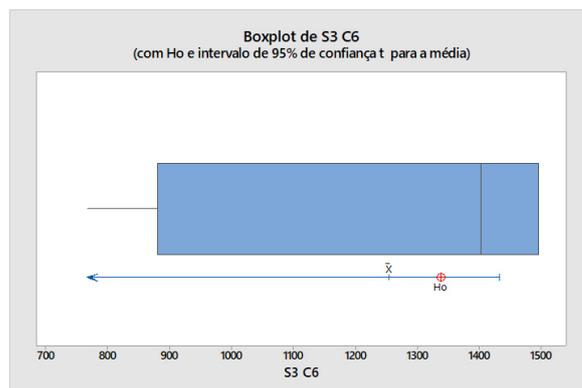


Figura 8.2.19 – Cluster 7, semana 3, com p-value = 0,398.

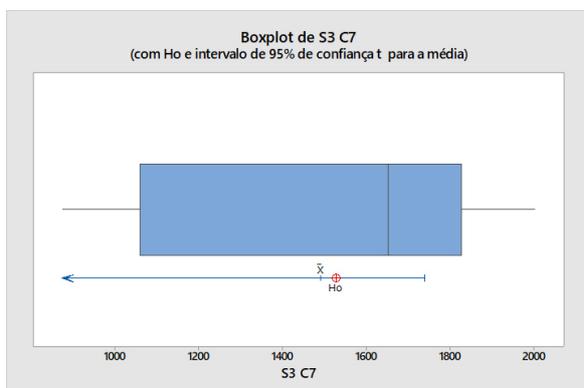


Figura 8.2.22 – Cluster 10, semana 3, com p-value = 1,000.

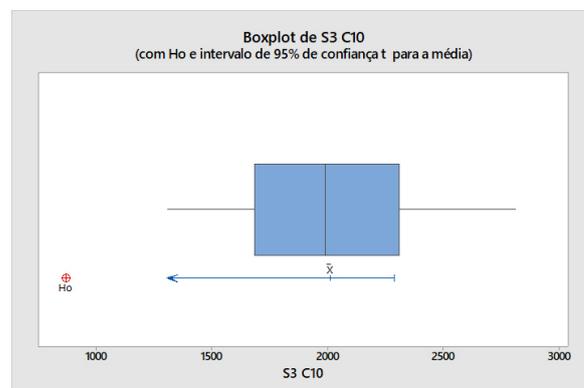


Figura 8.2.20 – Cluster 8, semana 3, com p-value = 1,000.

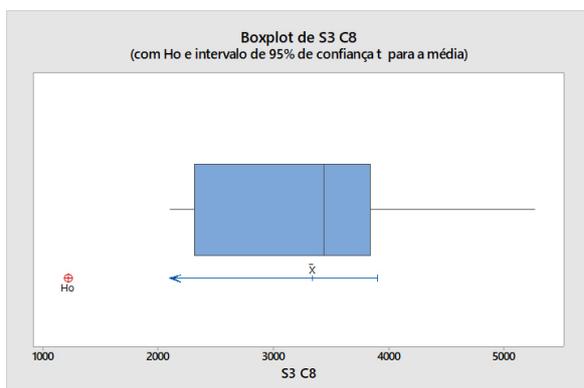


Figura 8.2.23 – Cluster 11, semana 3, com p-value = 1,000.

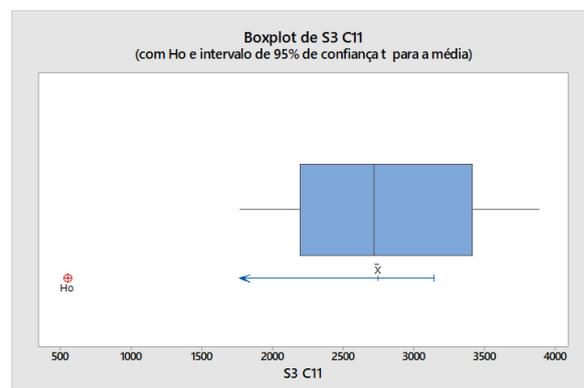


Figura 8.2.21 – Cluster 9, semana 3, com p-value = 1,000.

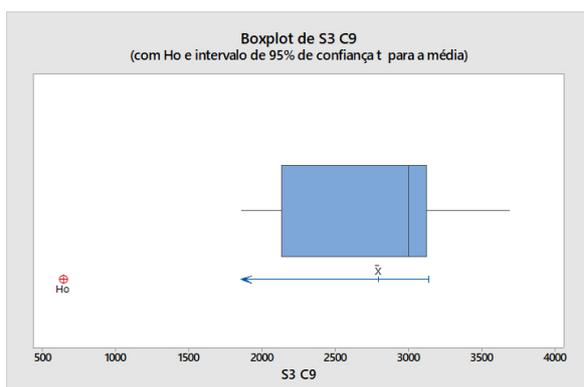


Figura 8.2.24 – Cluster 12, semana 3, com p-value = 1,000.

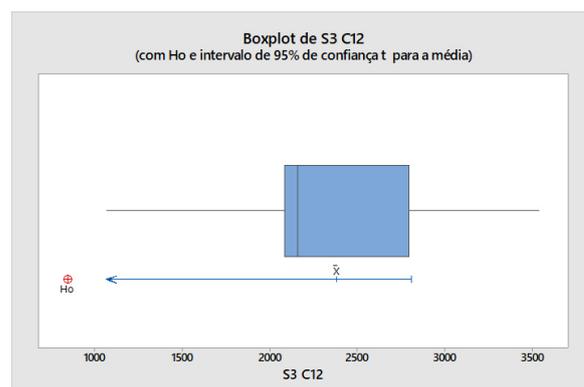


Figura 8.2.25 – Cluster 13, semana 3, com p-value = 1,000.

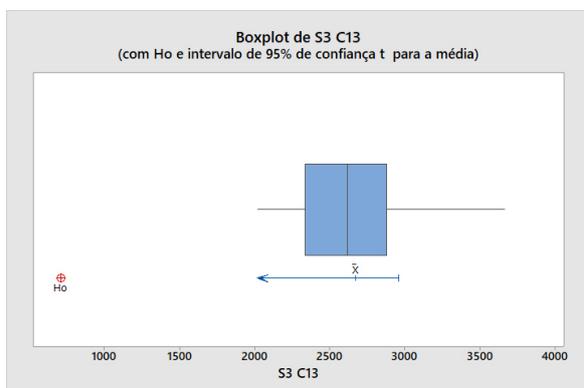


Figura 8.2.28 – Cluster 16, semana 3, com p-value = 1,000.

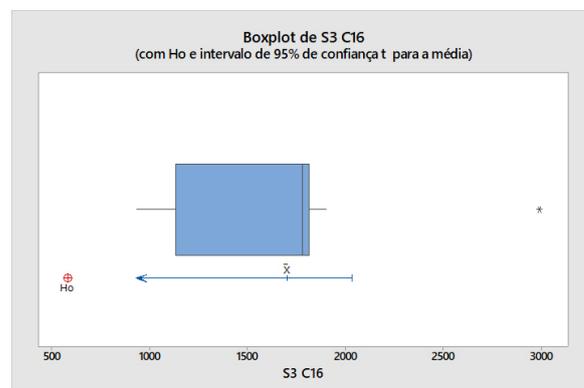


Figura 8.2.26 – Cluster 13, semana 3, com p-value = 1,000.

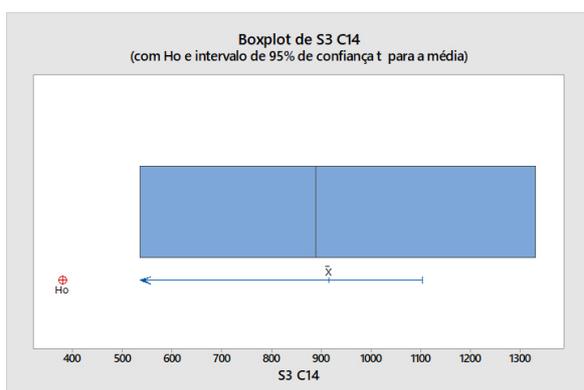


Figura 8.2.29 – Cluster 17, semana 3, com p-value = 0,991.

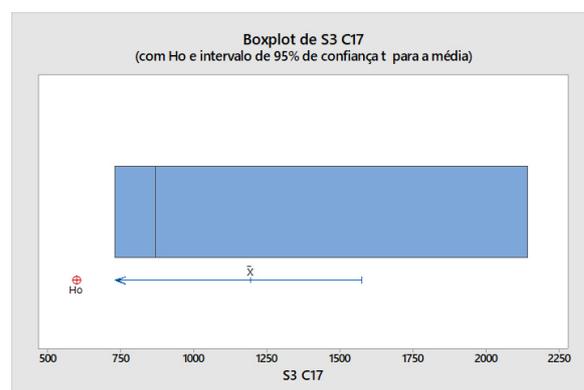


Figura 8.2.27 – Cluster 15, semana 3, com p-value = 1,000.

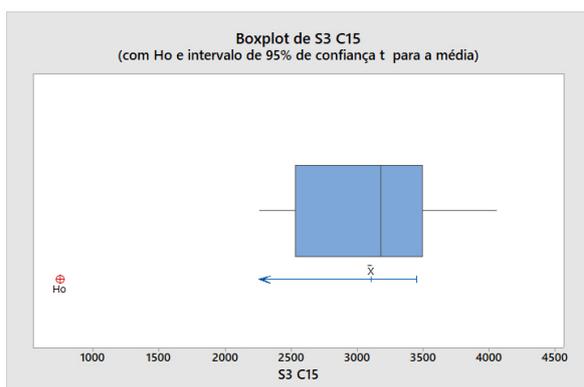


Figura 8.2.30 – Cluster 18, semana 3, com p-value = 1,000.

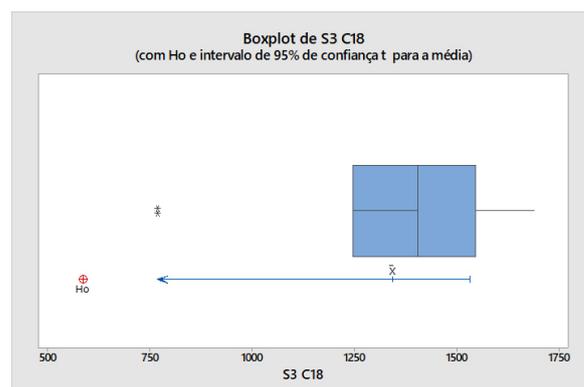


Figura 8.2.31 – Cluster 19, semana 3, com p-value = 1,000.

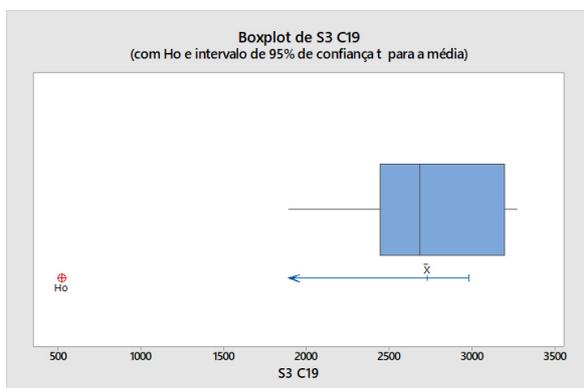


Figura 8.2.34 – Cluster 3, semana 4, com p-value = 0,927.

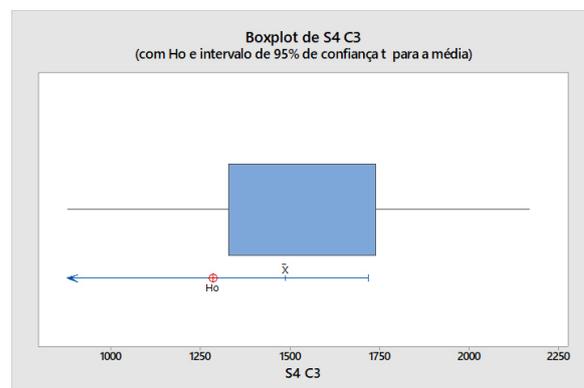


Figura 8.2.32 – Cluster 1, semana 4, com p-value = 1,000.

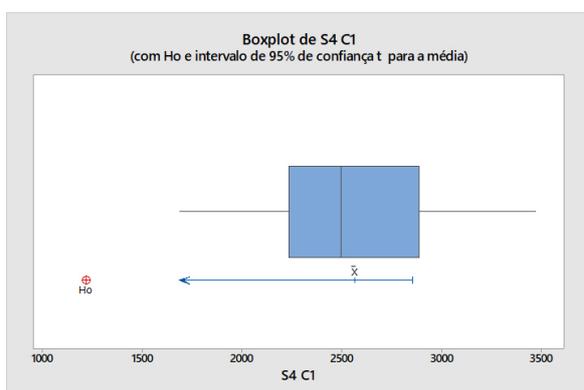


Figura 8.2.35 – Cluster 4, semana 4, com p-value = 0,000.

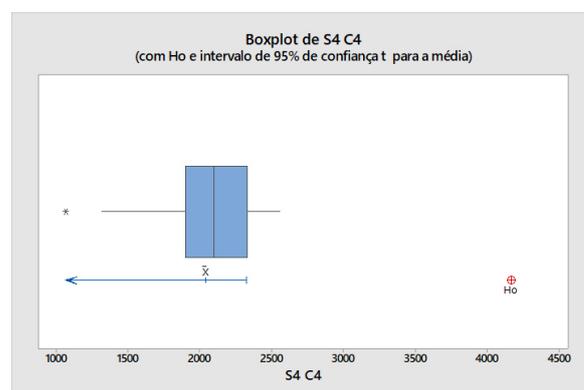


Figura 8.2.33 – Cluster 2, semana 4, com p-value = 0,999.

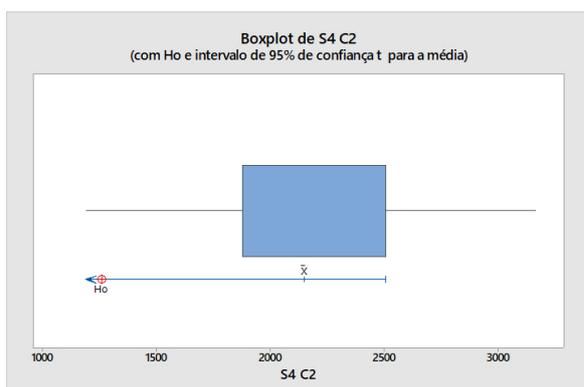


Figura 8.2.36 – Cluster 5, semana 4, com p-value = 1,000.

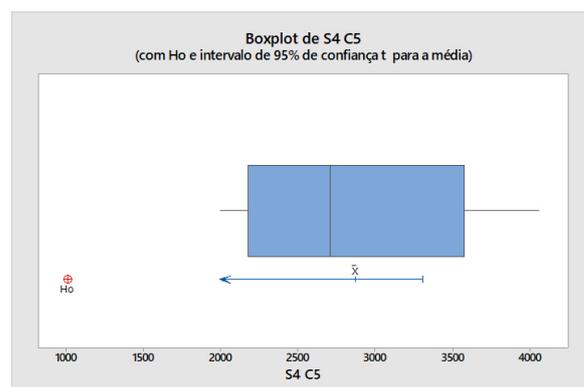


Figura 8.2.37 – Cluster 6, semana 4, com p-value = 1,000.

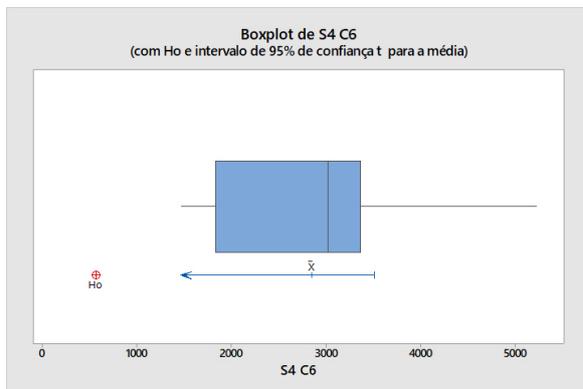


Figura 8.2.40 – Cluster 9, semana 4, com p-value = 1,000.

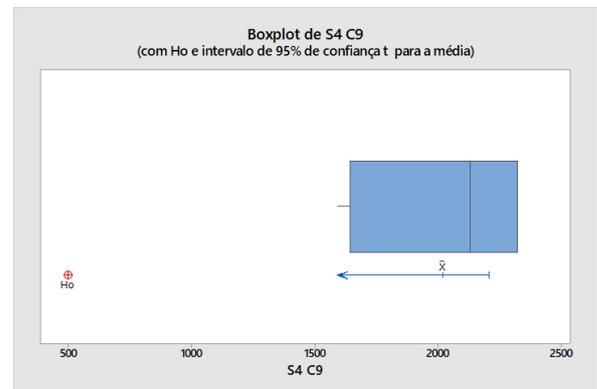


Figura 8.2.38 – Cluster 7, semana 4, com p-value = 0,996.

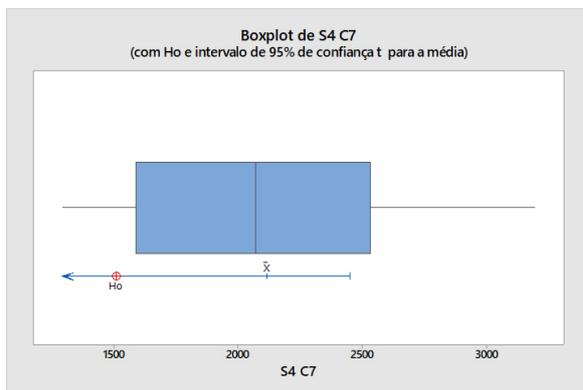


Figura 8.2.41 – Cluster 1, semana 5, com p-value = 1,000.

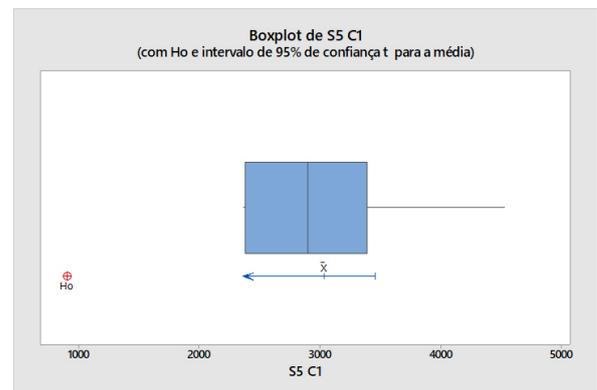


Figura 8.2.39 – Cluster 8, semana 4, com p-value = 1,000.

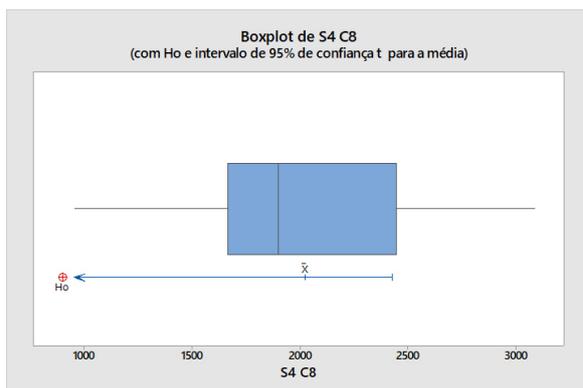


Figura 8.2.42 – Cluster 2, semana 5, com p-value = 1,000.

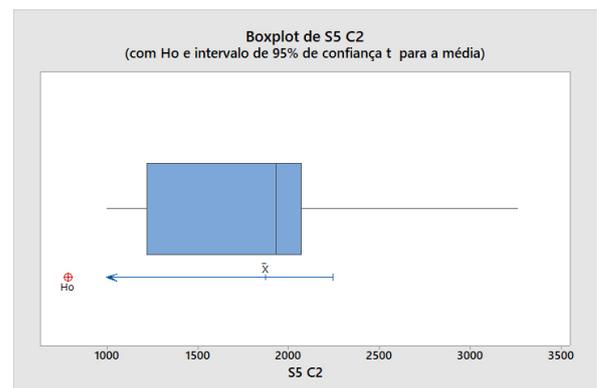


Figura 8.2.43 – Cluster 3, semana 5, com p-value = 0,775.

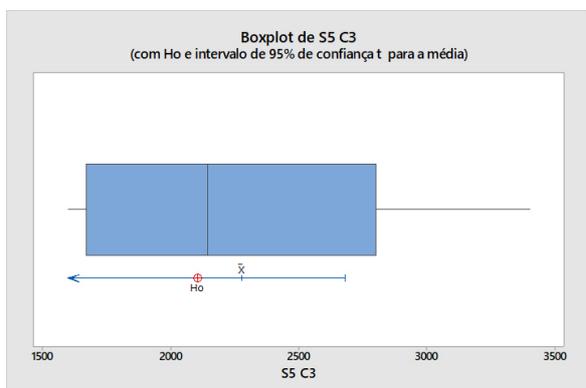


Figura 8.2.46 – Cluster 6, semana 5, com p-value = 1,000.

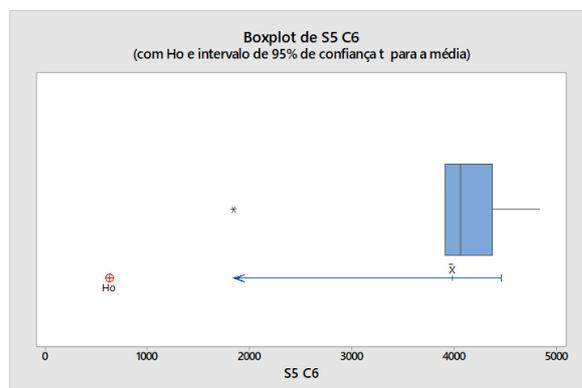


Figura 8.2.44 – Cluster 4, semana 5, com p-value = 0,999.

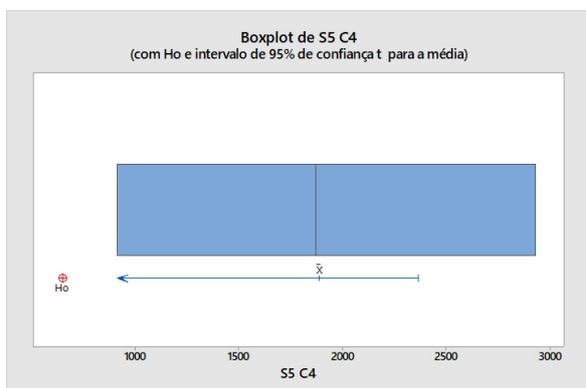


Figura 8.2.47 – Cluster 7, semana 5, com p-value = 0,998.

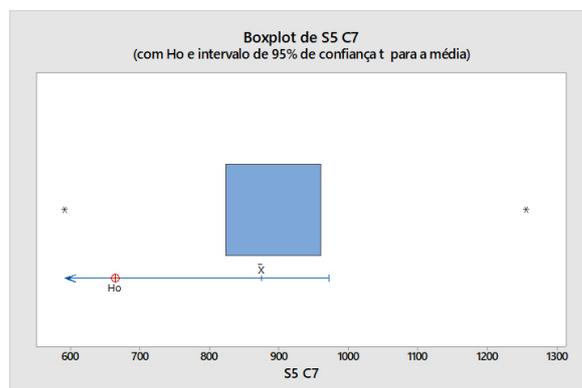


Figura 8.2.45 – Cluster 5, semana 5, com p-value = 0,409.

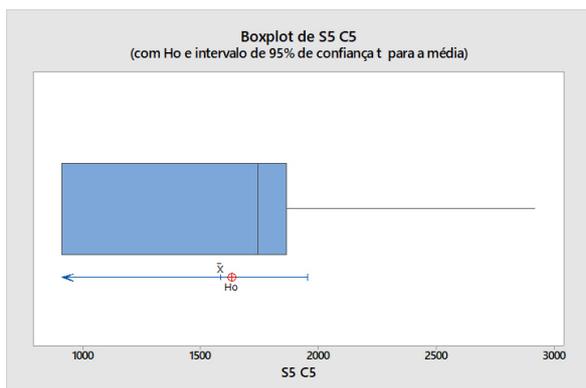


Figura 8.2.48 – Cluster 8, semana 5, com p-value = 0,000.

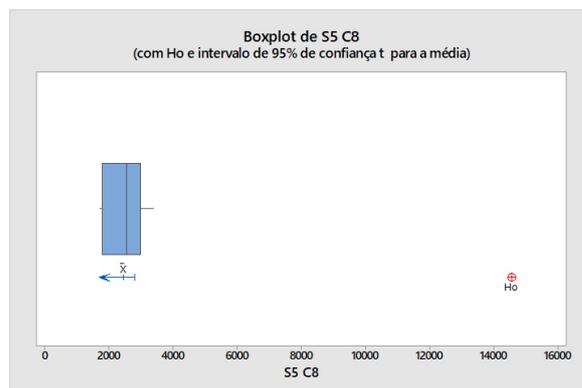


Figura 8.2.49 – Cluster 9, semana 5, com p-value = 0,000.

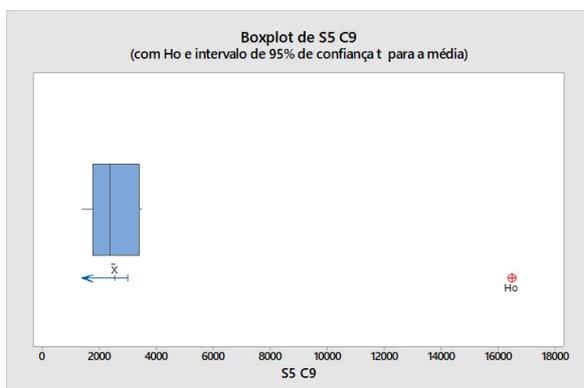


Figura 8.2.52 – Cluster 12, semana 5, com p-value = 0,002.

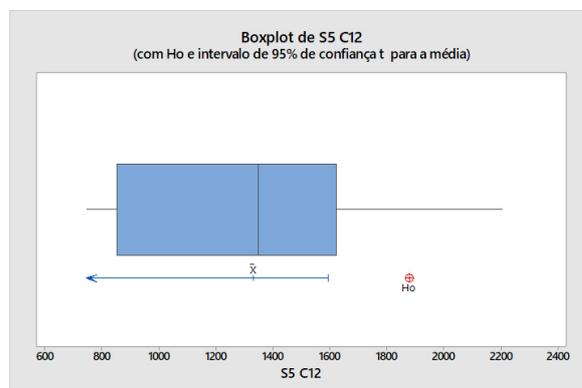


Figura 8.2.50 – Cluster 10, semana 5, com p-value = 0,111.

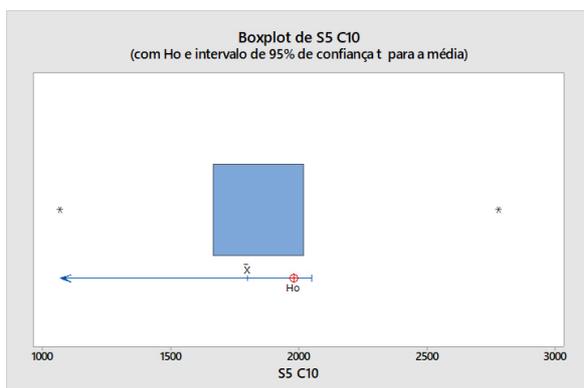


Figura 8.2.53 – Cluster 13, semana 5, com p-value = 1,000.

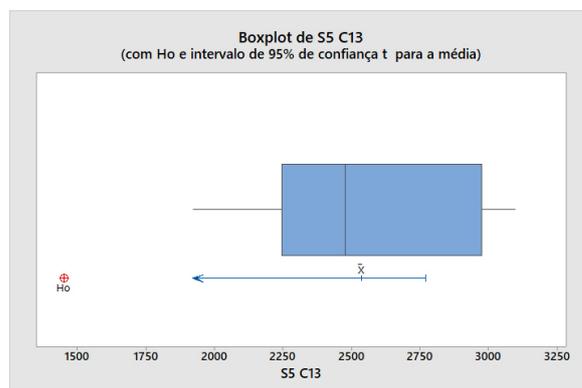


Figura 8.2.51 – Cluster 11, semana 5, com p-value = 0,616.

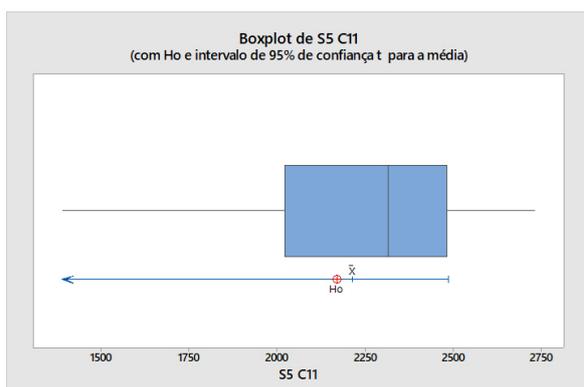


Figura 8.2.54 – Cluster 14, semana 5, com p-value = 0,152.

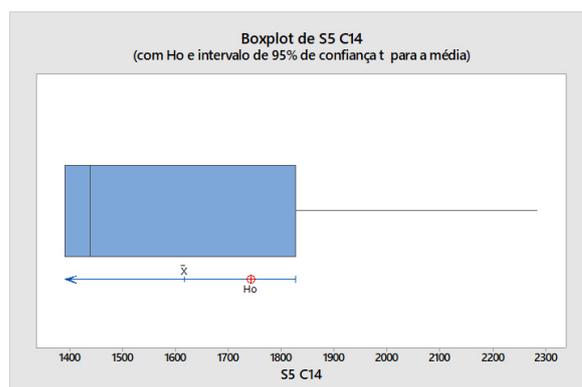


Figura 8.2.55 – Cluster 15, semana 5, com p-value = 0,988.

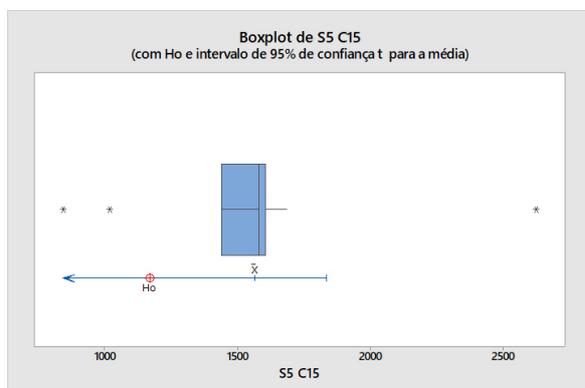


Figura 8.2.58 – Cluster 18, semana 5, com p-value = 1,000.

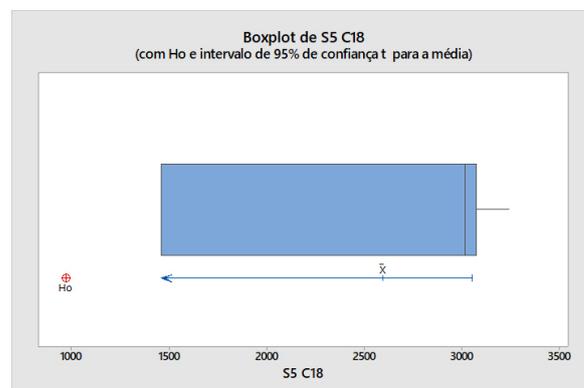


Figura 8.2.56 – Cluster 16, semana 5, com p-value = 0,975.

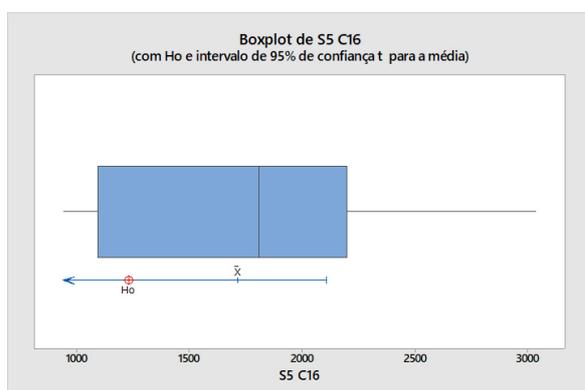


Figura 8.2.59 – Cluster 19, semana 5, com p-value = 1,000.

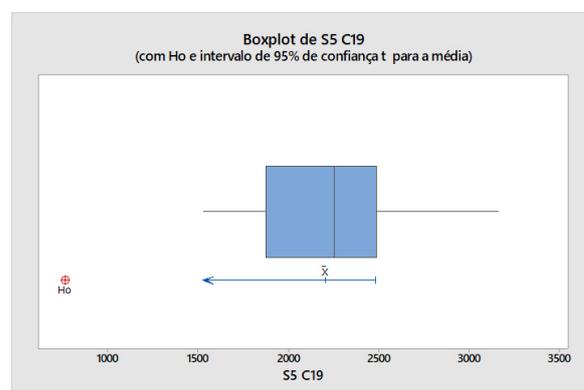


Figura 8.2.57 – Cluster 17, semana 5, com p-value = 1,000.

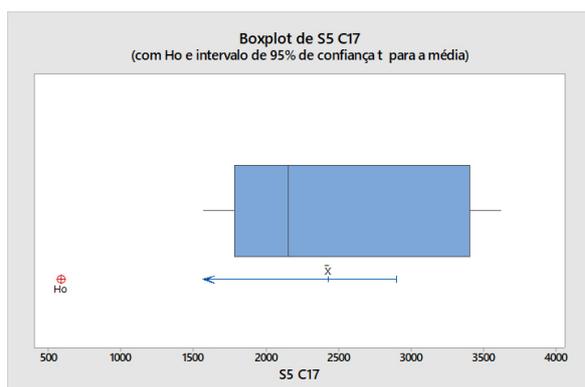


Figura 8.2.60 – Cluster 20, semana 5, com p-value = 1,000.

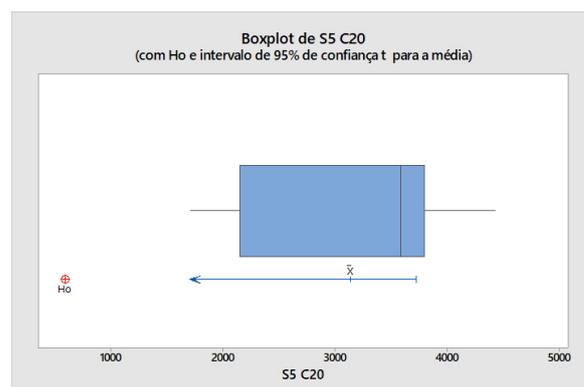


Figura 8.2.61 – Cluster 21, semana 5, com p-value = 0,997.

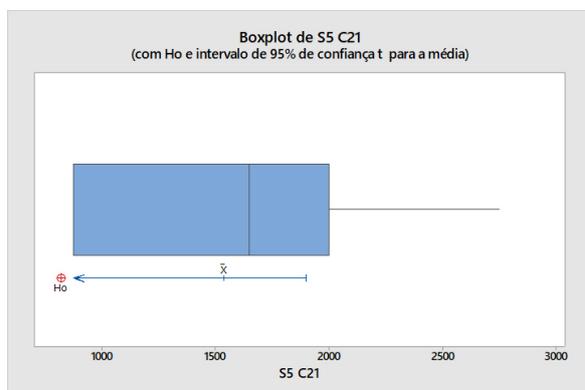


Figura 8.2.64 – Cluster 1, semana 6, com p-value = 0,997.

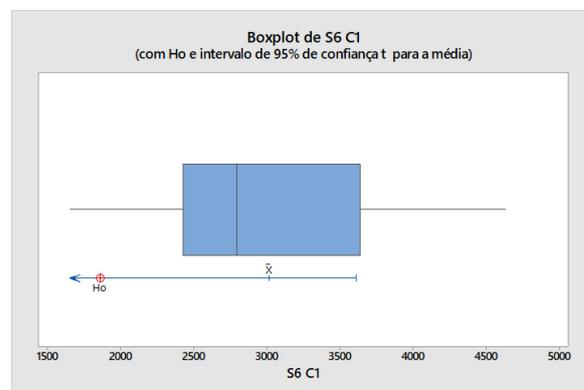


Figura 8.2.62 – Cluster 22, semana 5, com p-value = 1,000.

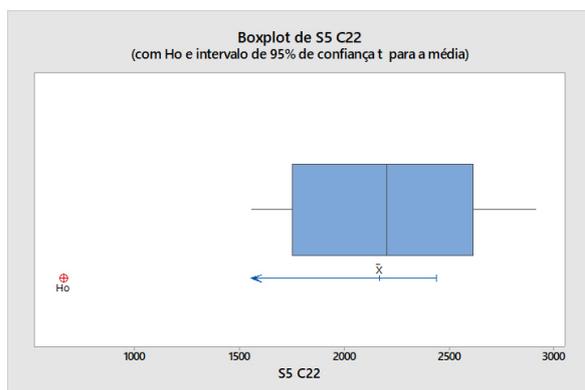


Figura 8.2.65 – Cluster 2, semana 6, com p-value = 0,000.

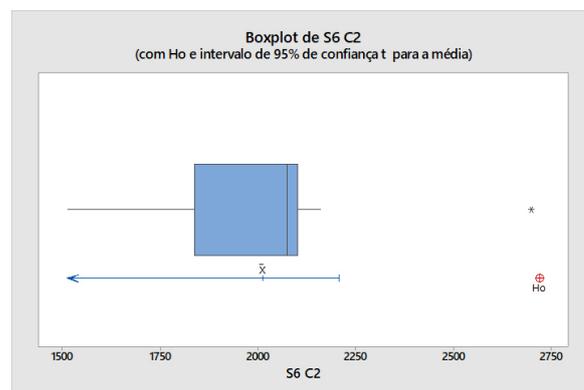


Figura 8.2.63 – Cluster 23, semana 5, com p-value = 1,000.

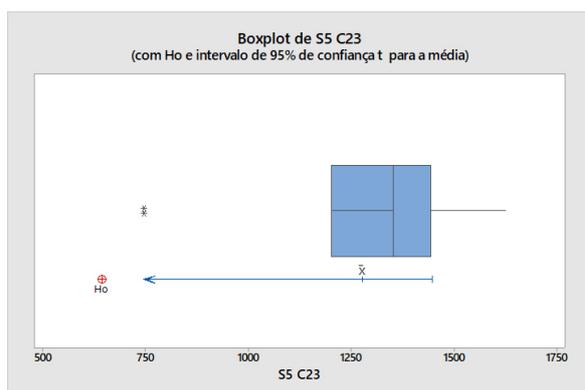


Figura 8.2.66 – Cluster 3, semana 6, com p-value = 0,000.

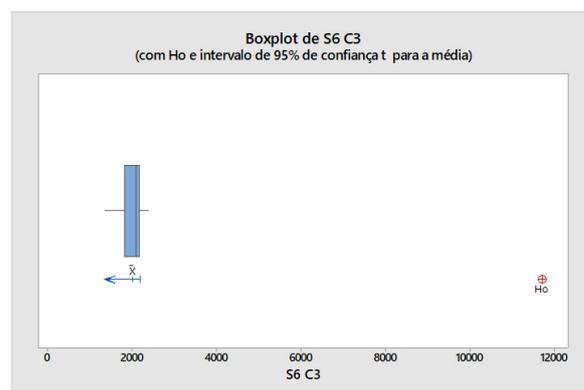


Figura 8.2.67 – Cluster 4, semana 6, com p-value = 0,97.

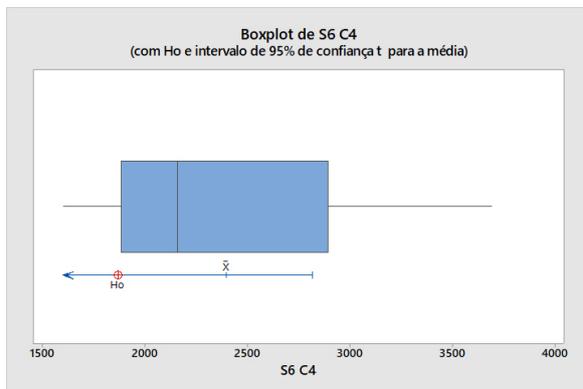


Figura 8.2.70 – Cluster 7, semana 6, com p-value = 0,999.

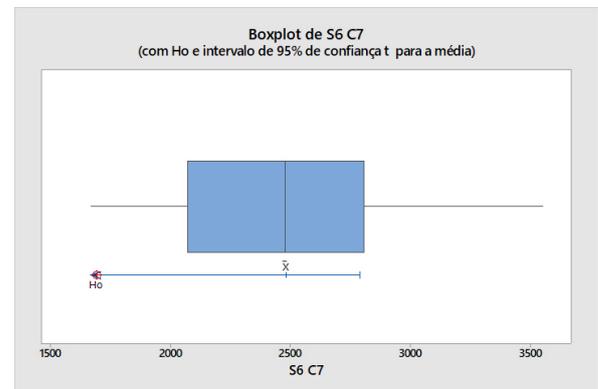


Figura 8.2.68 – Cluster 5, semana 6, com p-value = 0,240.

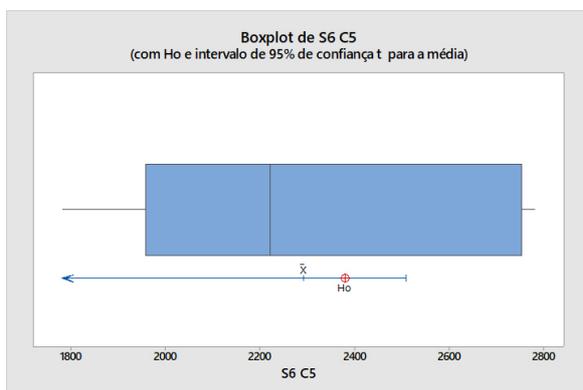


Figura 8.2.71 – Cluster 8, semana 6, com p-value = 1,000.

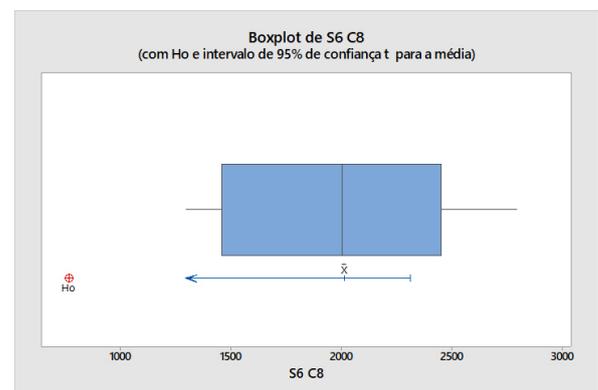


Figura 8.2.69 – Cluster 6, semana 6, com p-value = 0,954.

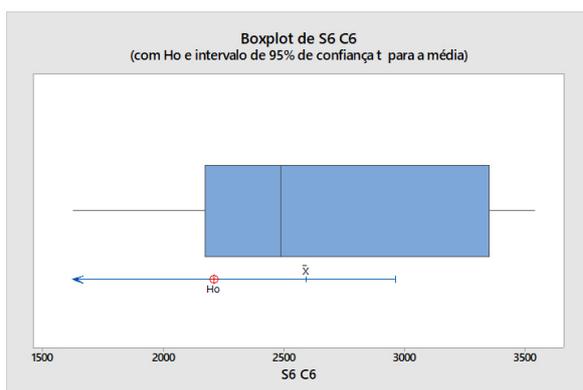


Figura 8.2.72 – Cluster 9, semana 6, com p-value = 0,996.

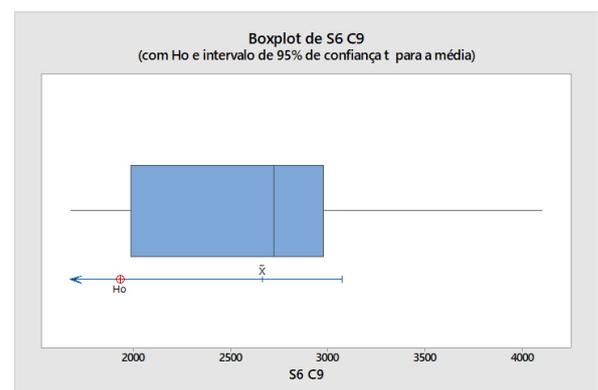


Figura 8.2.73 – Cluster 10, semana 6, com p-value = 1,000.

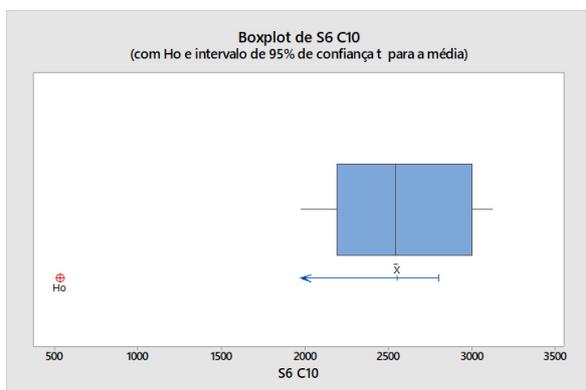


Figura 8.2.76 – Cluster 13, semana 6, com p-value = 0,532.

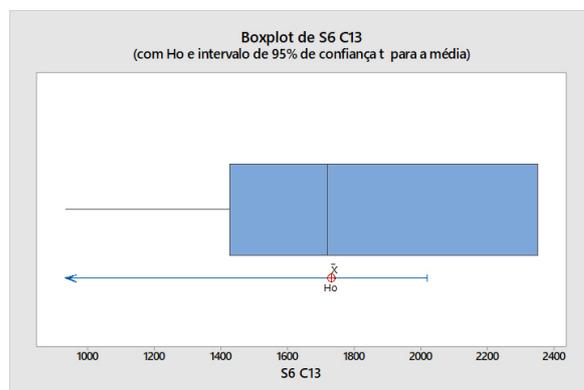


Figura 8.2.74 – Cluster 11, semana 6, com p-value = 1,000.

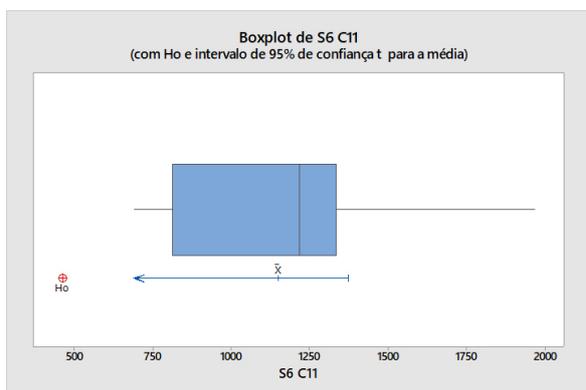


Figura 8.2.77 – Cluster 14, semana 6, com p-value = 0,991.

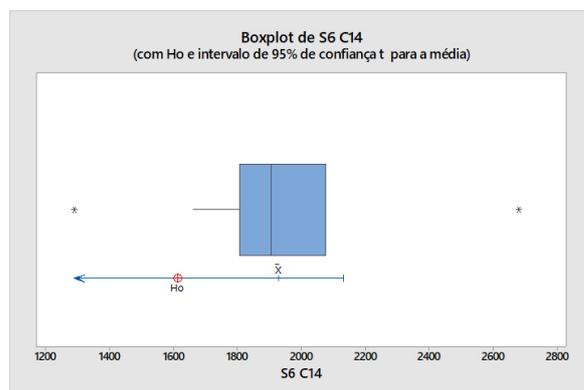


Figura 8.2.75 – Cluster 12, semana 6, com p-value = 1,000.

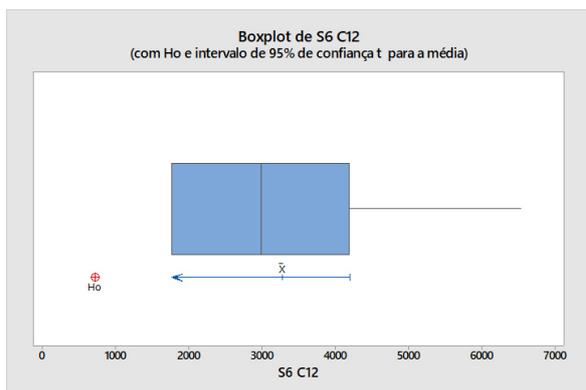


Figura 8.2.78 – Cluster 15, semana 6, com p-value = 0,999.

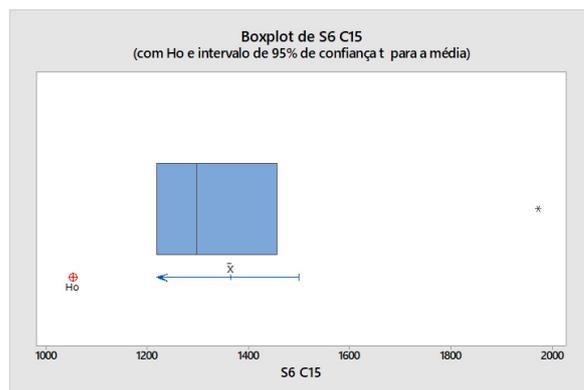


Figura 8.2.79 – Cluster 16, semana 6, com p-value = 1,000.

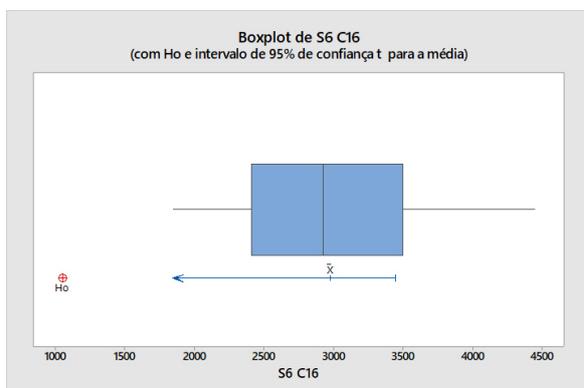


Figura 8.2.82 – Cluster 3, semana 7, com p-value = 0,000.

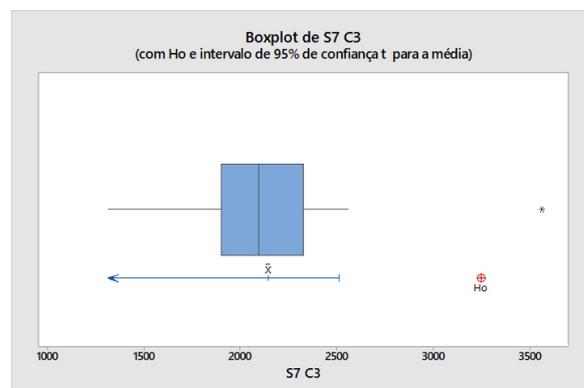


Figura 8.2.80 – Cluster 1, semana 7, com p-value = 0,000.

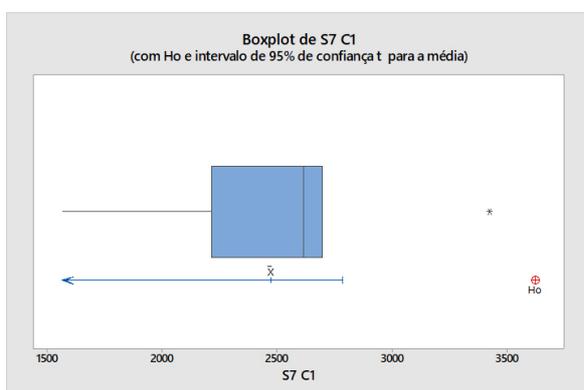


Figura 8.2.83 – Cluster 4, semana 7, com p-value = 1,000.

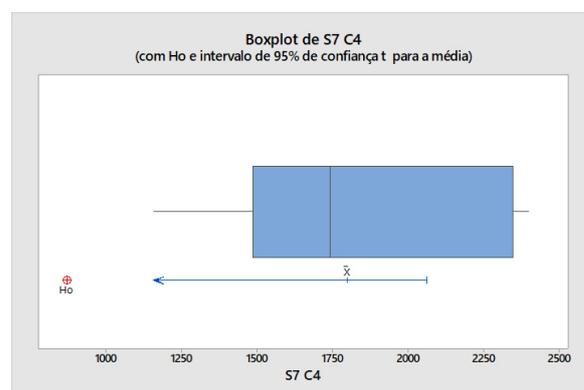


Figura 8.2.81 – Cluster 2, semana 7, com p-value = 0,999.

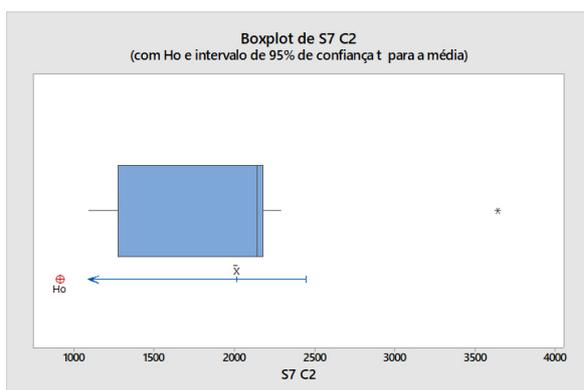


Figura 8.2.84 – Cluster 5, semana 7, com p-value = 1,000.

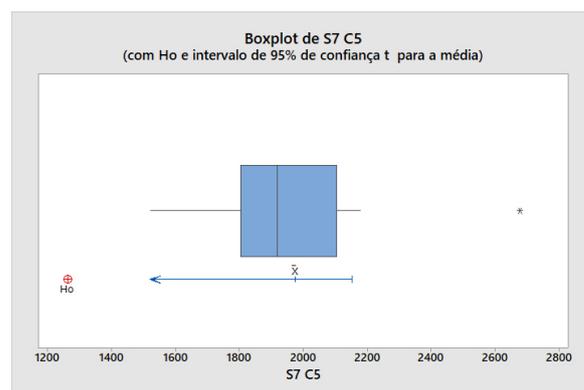


Figura 8.2.85 – Cluster 6, semana 7, com p-value = 0,000.

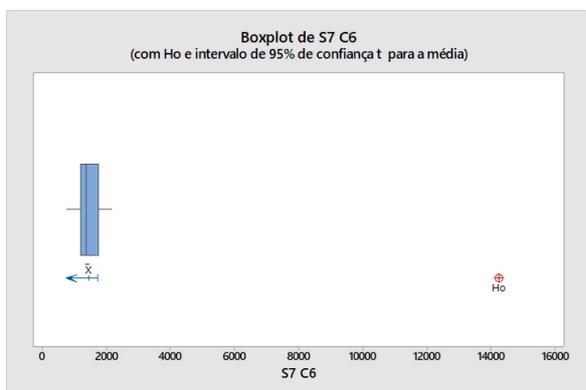


Figura 8.2.88 – Cluster 9, semana 7, com p-value = 1,000.

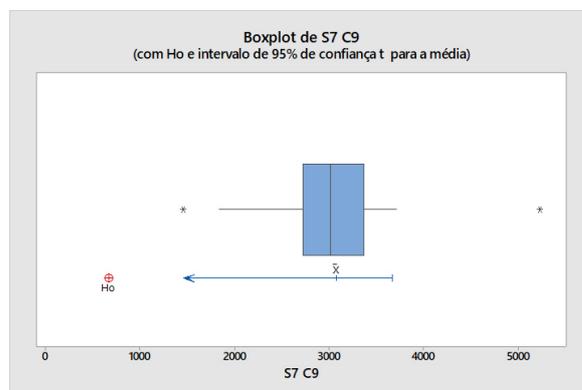


Figura 8.2.86 – Cluster 7, semana 7, com p-value = 0,031.

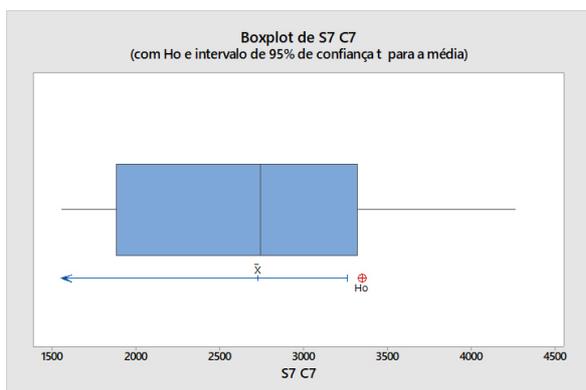


Figura 8.2.89 – Cluster 10, semana 7, com p-value = 1,000.

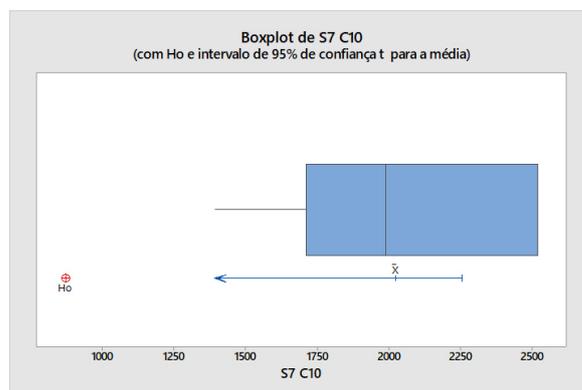


Figura 8.2.87 – Cluster 8, semana 7, com p-value = 1,000.

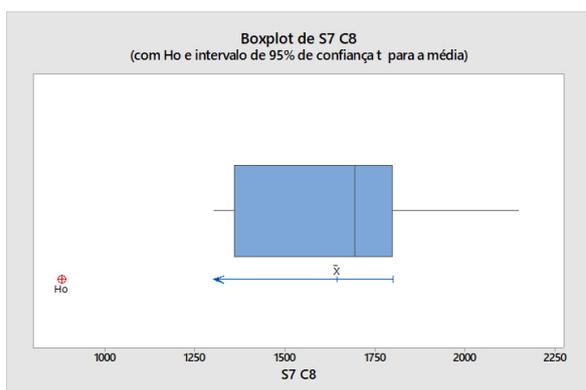


Figura 8.2.90 – Cluster 11, semana 7, com p-value = 1,000.

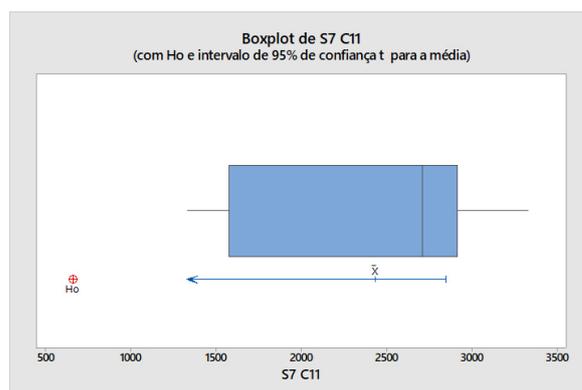


Figura 8.2.91 – Cluster 12, semana 7, com p-value = 1,000.

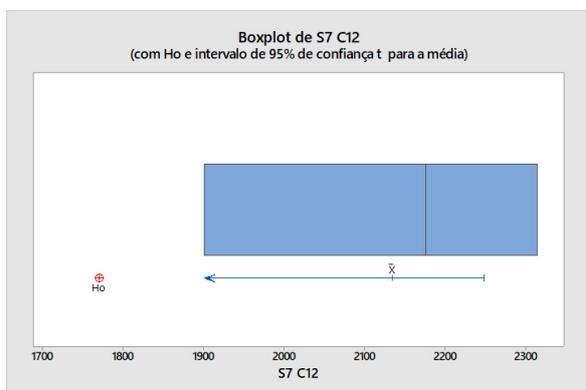


Figura 8.2.94 – Cluster 15, semana 7, com p-value = 0,996.

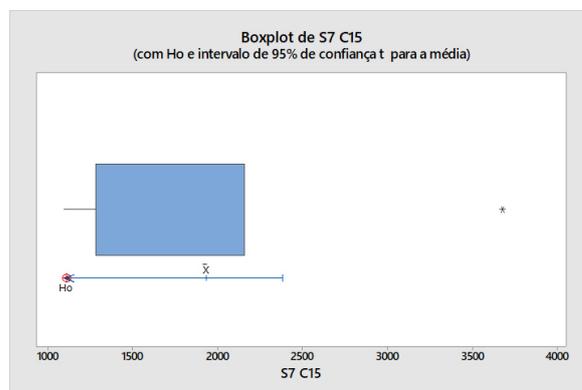


Figura 8.2.92 – Cluster 13, semana 7, com p-value = 1,000.

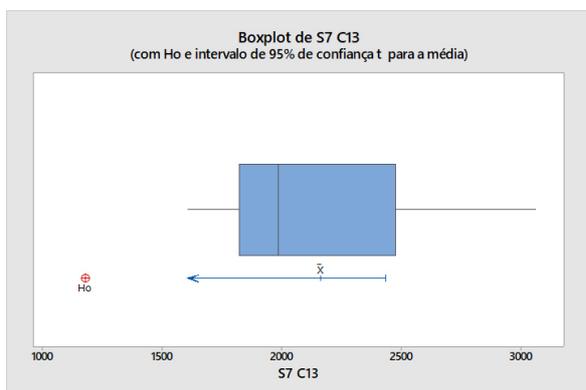


Figura 8.2.95 – Cluster 1, semana 8, com p-value = 0,487.

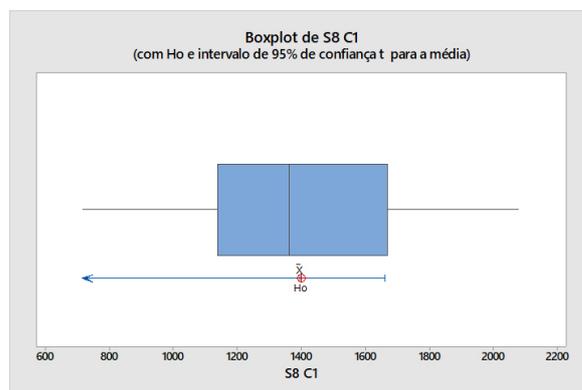


Figura 8.2.93 – Cluster 14, semana 7, com p-value = 1,000.

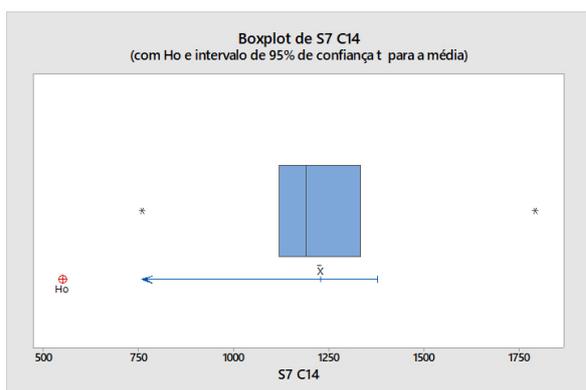


Figura 8.2.96 – Cluster 2, semana 8, com p-value = 1,000.

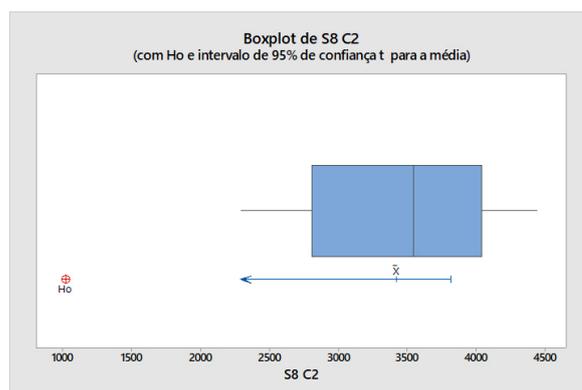


Figura 8.2.97 – Cluster 3, semana 8, com p-value = 1,000.

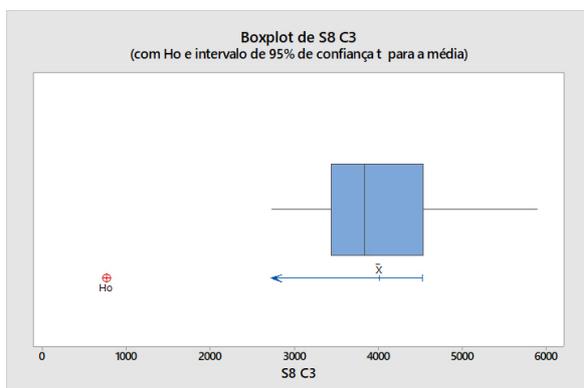


Figura 8.2.100 – Cluster 6, semana 8, com p-value = 1,000.

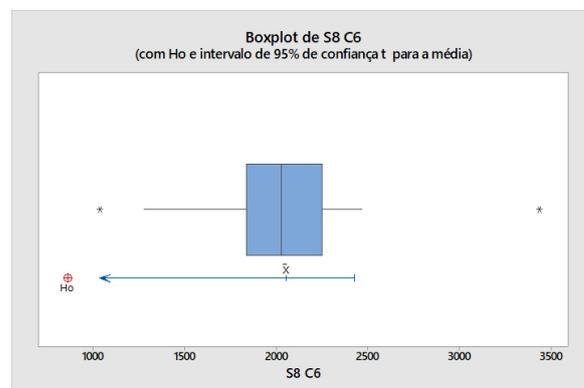


Figura 8.2.98 – Cluster 4, semana 8, com p-value = 0,999.

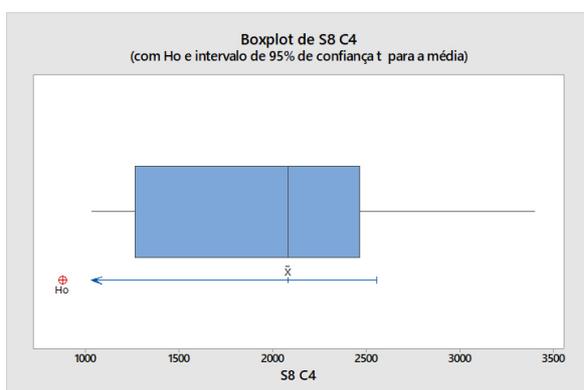


Figura 8.2.101 – Cluster 7, semana 8, com p-value = 0,000.

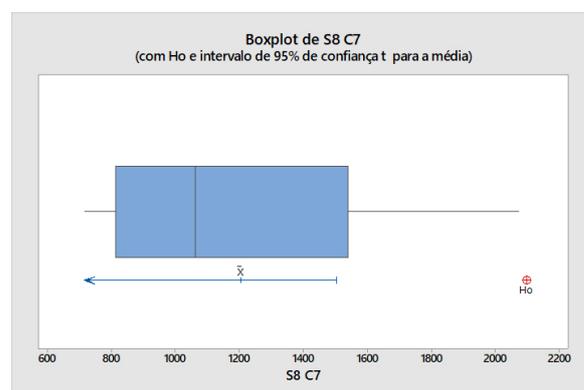


Figura 8.2.99 – Cluster 5, semana 8, com p-value = 0,000.

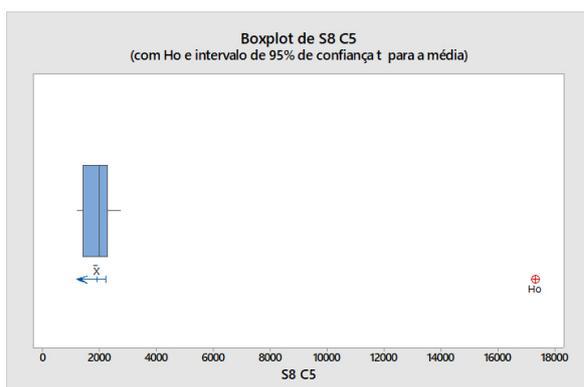


Figura 8.2.102 – Cluster 8, semana 8, com p-value = 0,001.

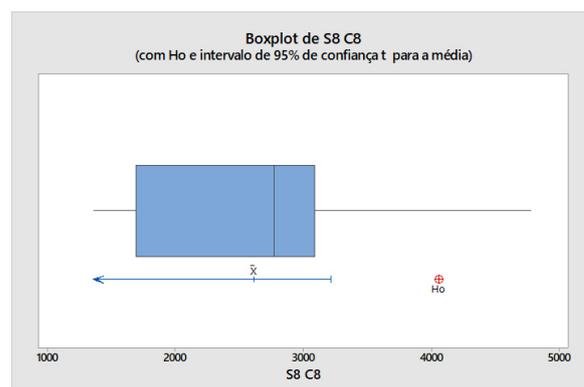


Figura 8.2.103 – Cluster 9, semana 8, com p-value = 0,965.

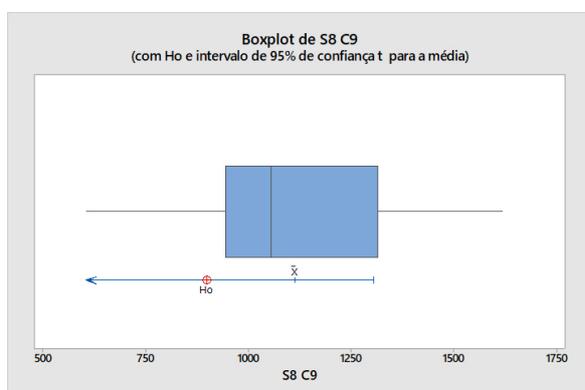


Figura 8.2.106 – Cluster 12, semana 8, com p-value = 0,990.

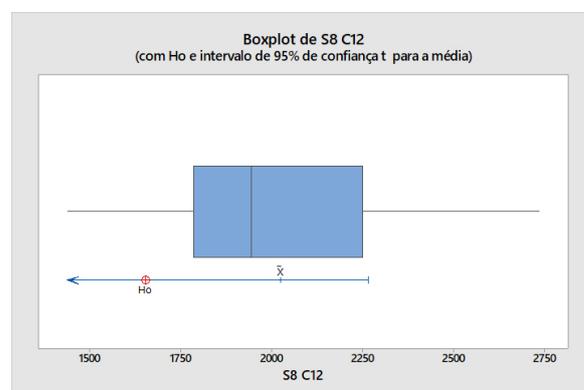


Figura 8.2.104 – Cluster 10, semana 8, com p-value = 1,000.

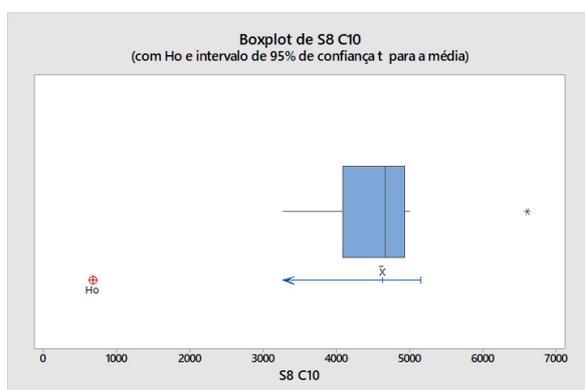


Figura 8.2.107 – Cluster 13, semana 8, com p-value = 0,985.

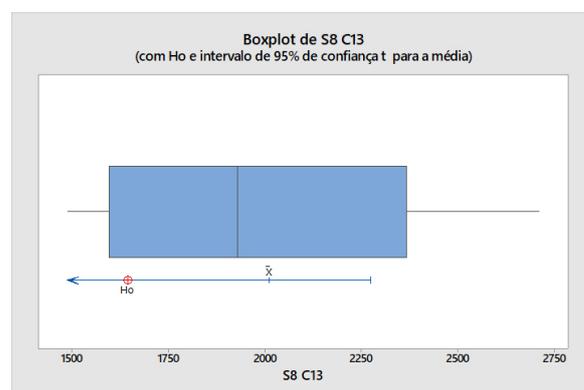


Figura 8.2.105 – Cluster 11, semana 8, com p-value = 1,000.

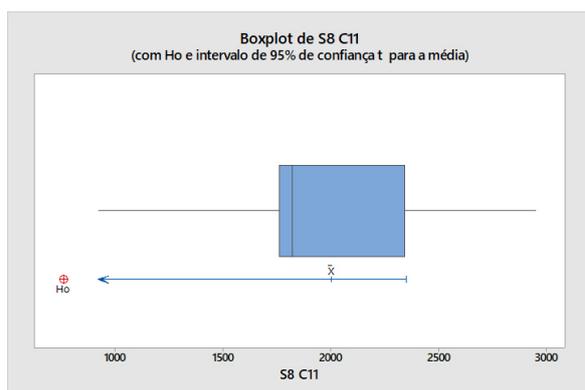


Figura 8.2.108 – Cluster 14, semana 8, com p-value = 1,000.

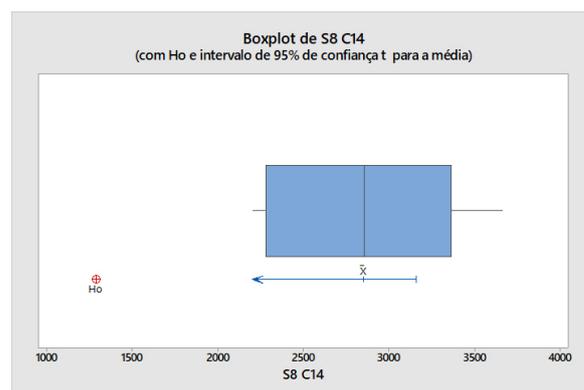


Figura 8.2.109 – Cluster 15, semana 8, com p-value = 0,994.

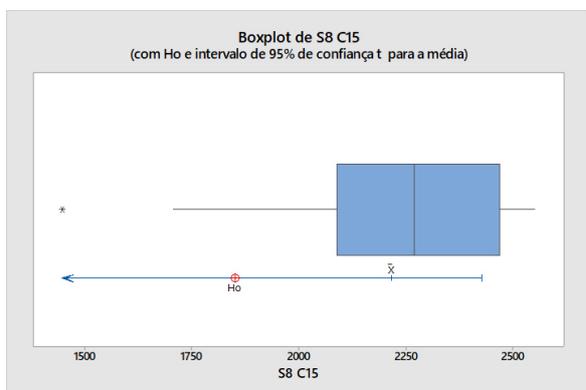


Figura 8.2.112 – Cluster 18, semana 8, com p-value = 0,997.

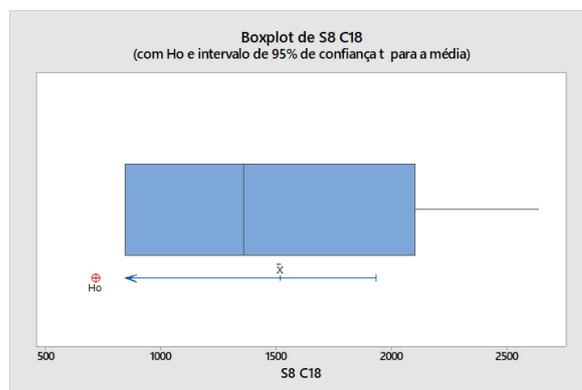


Figura 8.2.110 – Cluster 16, semana 8, com p-value = 1,000.

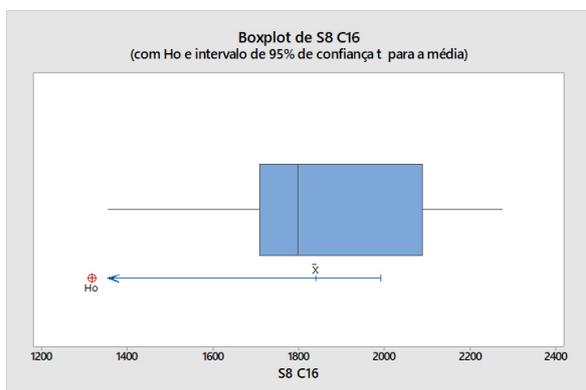


Figura 8.2.113 – Cluster 19, semana 8, com p-value = 1,000.

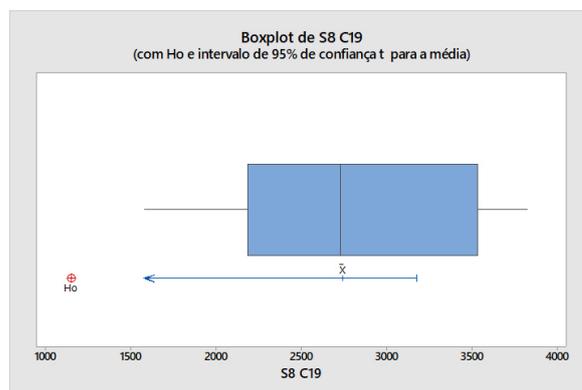


Figura 8.2.111 – Cluster 17, semana 8, com p-value = 0,998.

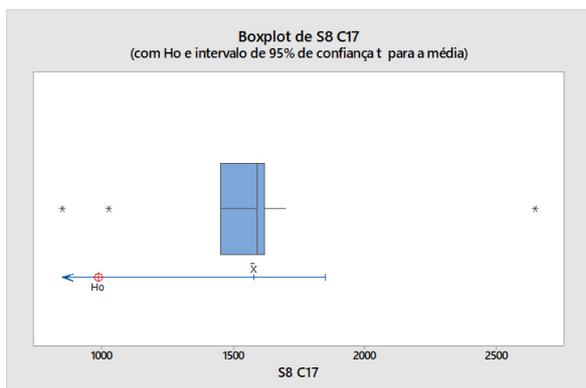


Figura 8.2.114 – Cluster 20, semana 8, com p-value = 1,000.

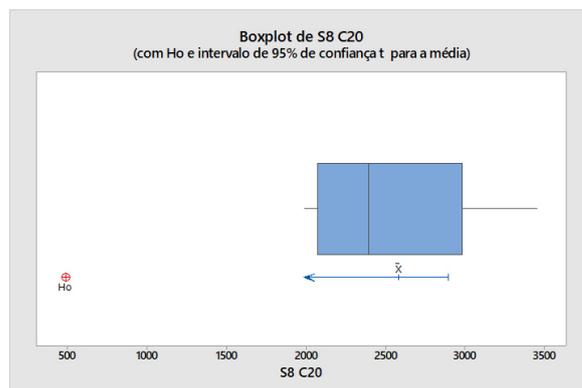


Figura 8.2.115 – Cluster 1, semana 9, com p-value = 0,000.

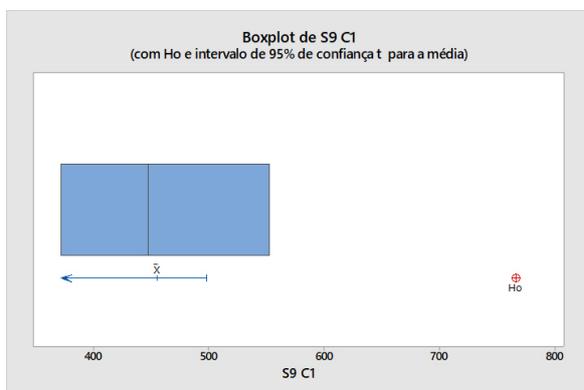


Figura 8.2.118 – Cluster 4, semana 9, com p-value = 1,000.

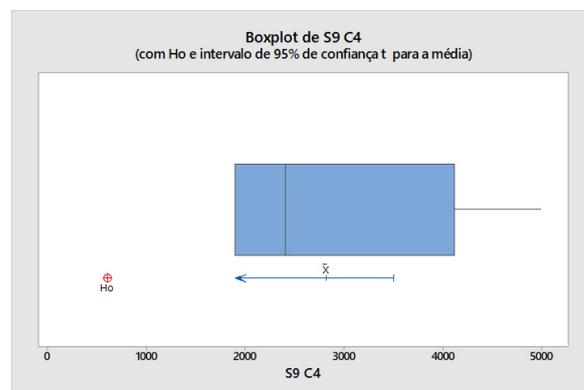


Figura 8.2.116 – Cluster 2, semana 9, com p-value = 1,000.

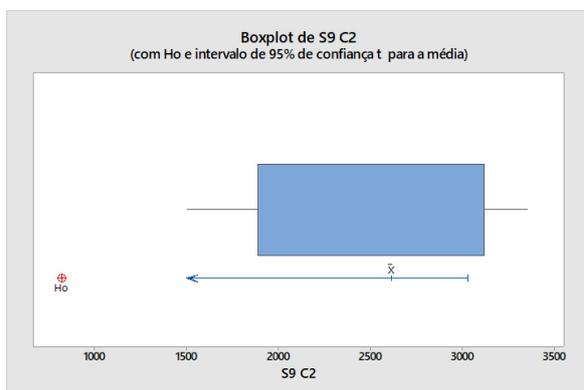


Figura 8.2.119 – Cluster 5, semana 9, com p-value = 0,000.

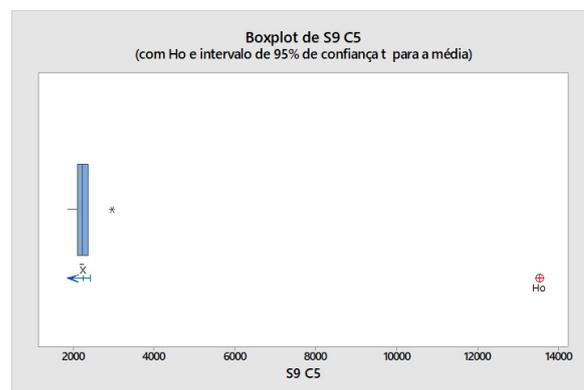


Figura 8.2.117 – Cluster 3, semana 9, com p-value = 0,003.

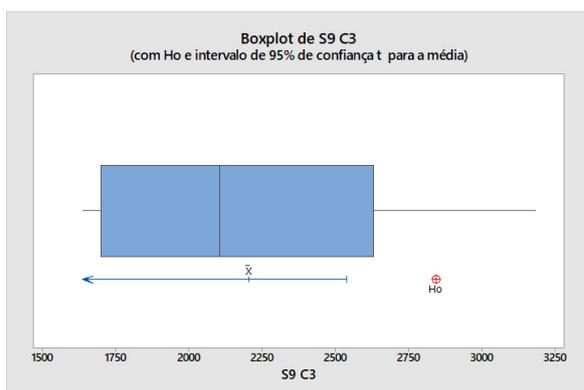


Figura 8.2.120 – Cluster 6, semana 9, com p-value = 0,000.

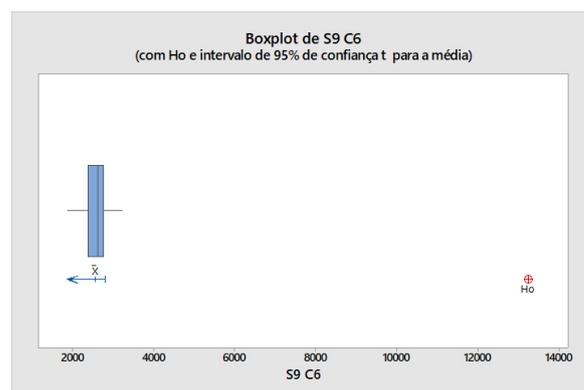


Figura 8.2.121 – Cluster 7, semana 9, com p-value = 1,000.

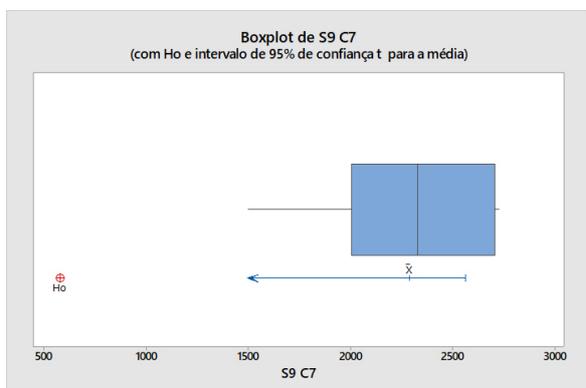


Figura 8.2.124 – Cluster 10, semana 9, com p-value = 0,718.

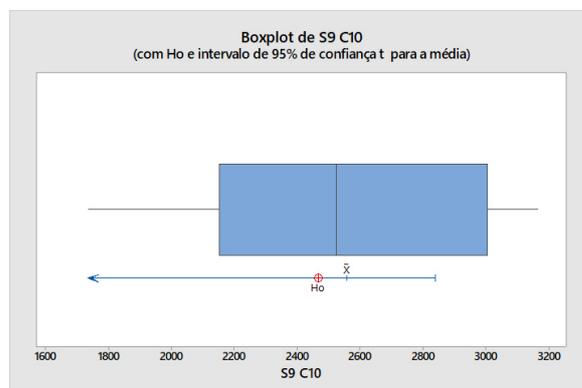


Figura 8.2.122 – Cluster 8, semana 9, com p-value = 0,999.

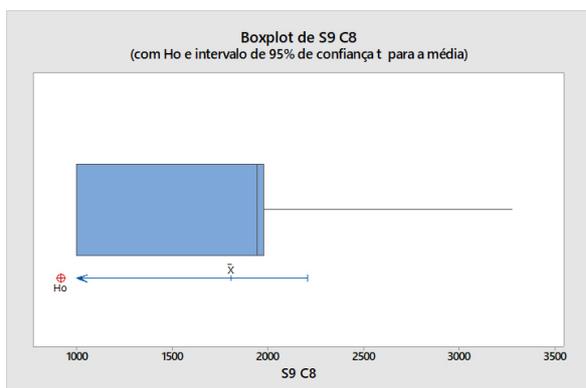


Figura 8.2.125 – Cluster 11, semana 9, com p-value = 1,000.

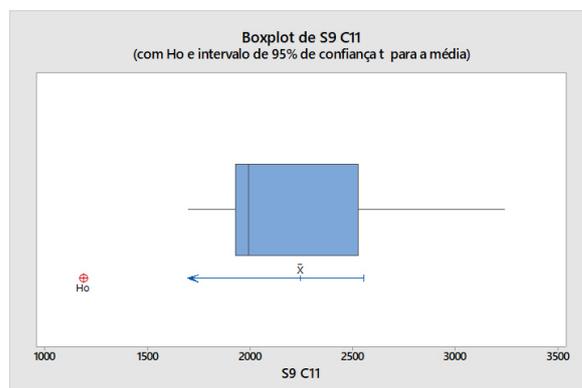


Figura 8.2.123 – Cluster 9, semana 9, com p-value = 1,000.

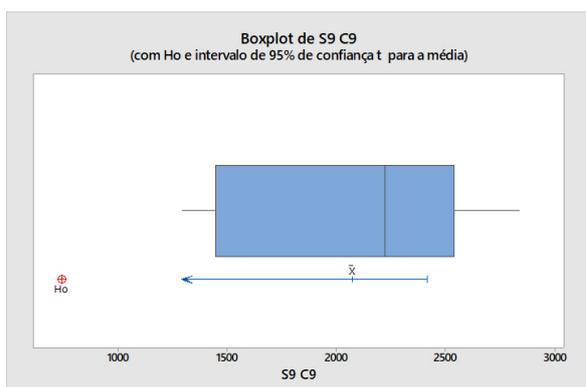


Figura 8.2.126 – Cluster 12, semana 9, com p-value = 1,000.

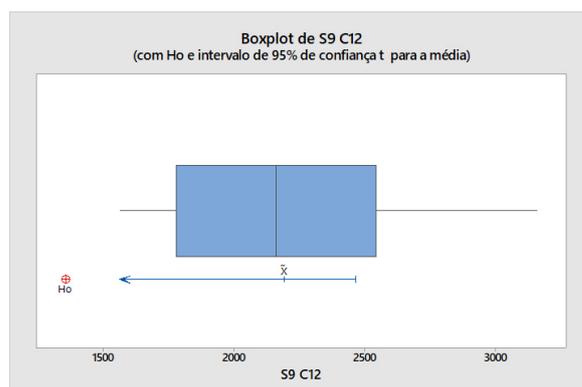


Figura 8.2.127 – Cluster 13, semana 9, com p-value = 0,991.

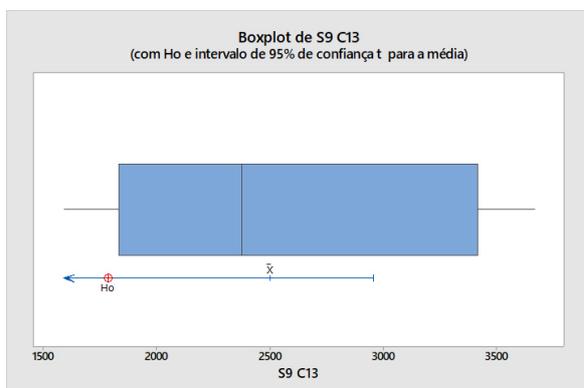


Figura 8.2.130 – Cluster 16, semana 9, com p-value = 1,000.

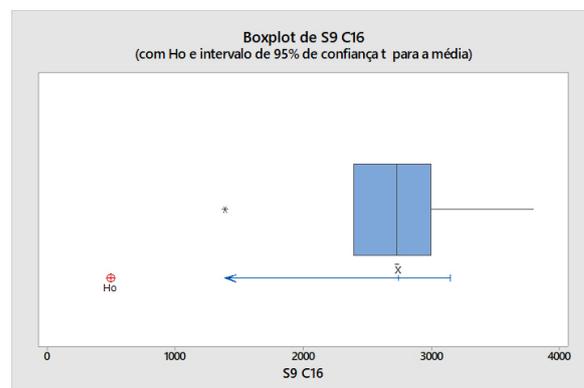


Figura 8.2.128 – Cluster 14, semana 9, com p-value = 1,000.

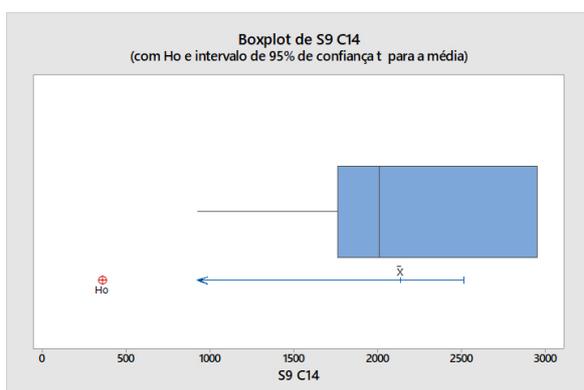


Figura 8.2.131 – Cluster 17, semana 9, com p-value = 0,998.

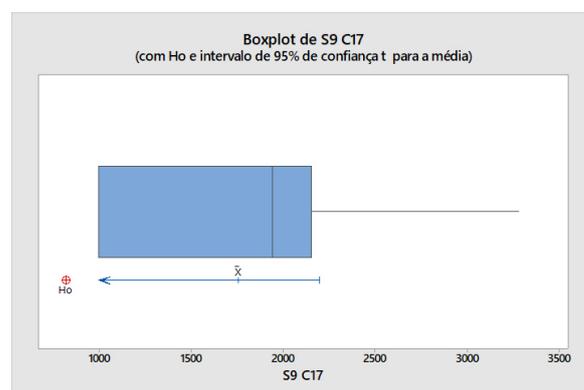


Figura 8.2.129 – Cluster 15, semana 9, com p-value = 1,000.

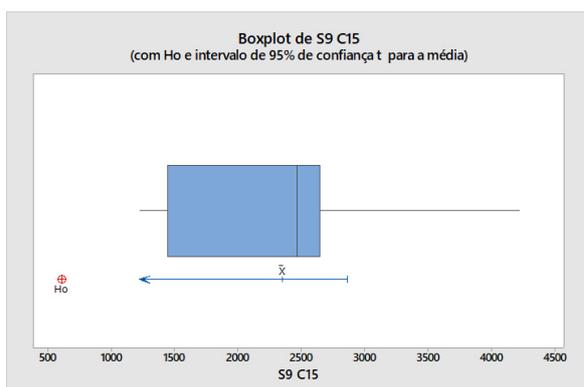


Figura 8.2.132 – Cluster 18, semana 9, com p-value = 0,875.

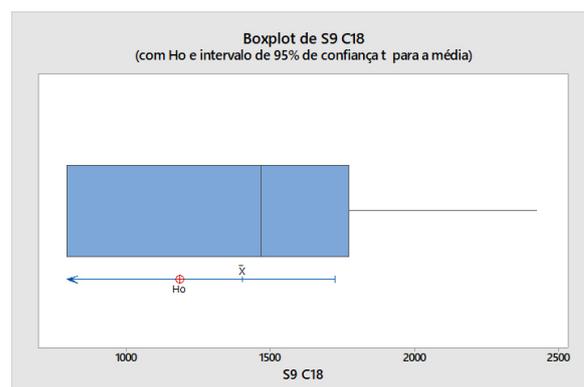


Figura 8.2.133 – Cluster 19, semana 9, com p-value = 1,000.

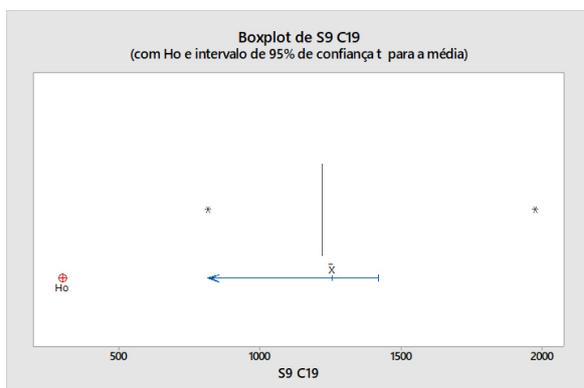


Figura 8.2.136 – Cluster 2, semana 10, com p-value = 1,000.

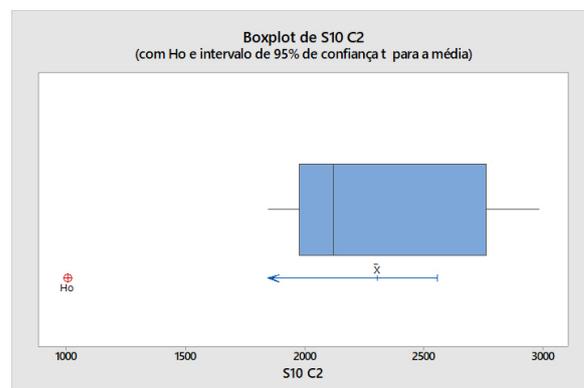


Figura 8.2.134 – Cluster 20, semana 9, com p-value = 1,000.

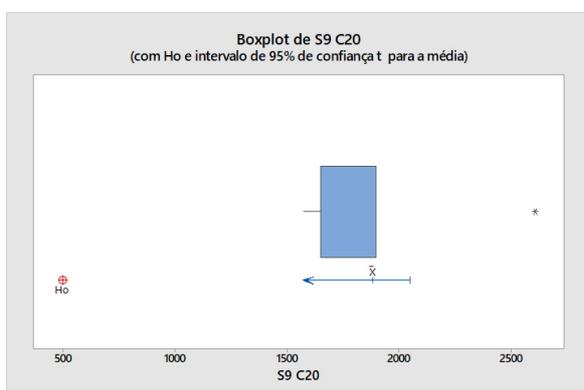


Figura 8.2.137 – Cluster 3, semana 10, com p-value = 1,000.

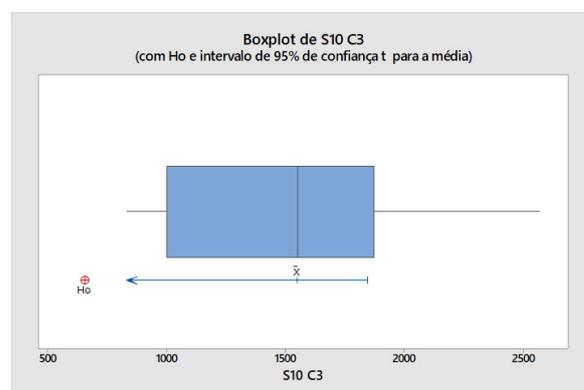


Figura 8.2.135 – Cluster 1, semana 10, com p-value = 1,000.

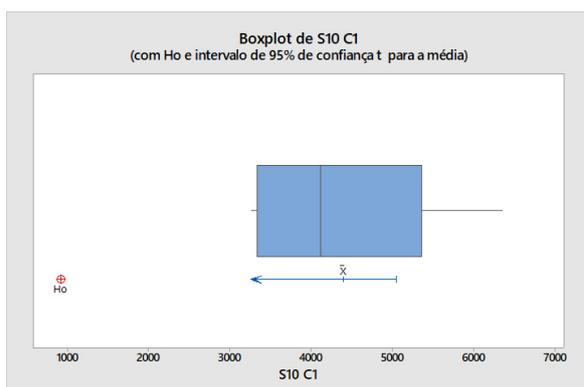


Figura 8.2.138 – Cluster 4, semana 10, com p-value = 1,000.

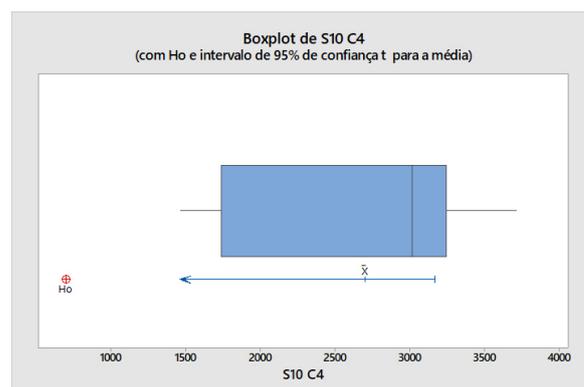


Figura 8.2.139 – Cluster 5, semana 10, com p-value = 1,000.

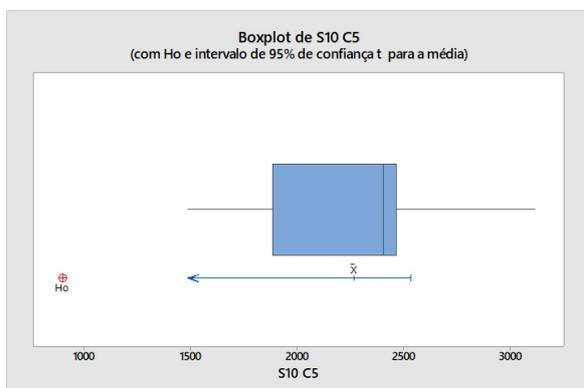


Figura 8.2.142 – Cluster 8, semana 10, com p-value = 0,000.

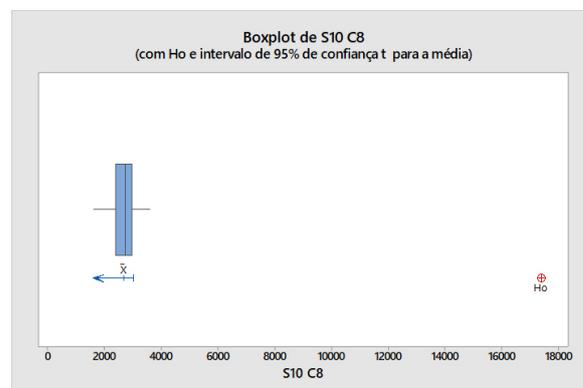


Figura 8.2.140 – Cluster 6, semana 10, com p-value = 0,000.

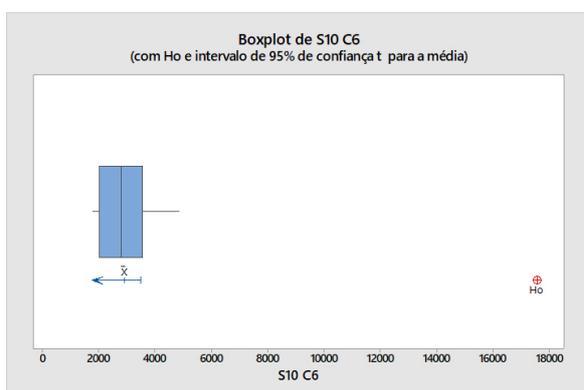


Figura 8.2.143 – Cluster 9, semana 10, com p-value = 0,000.

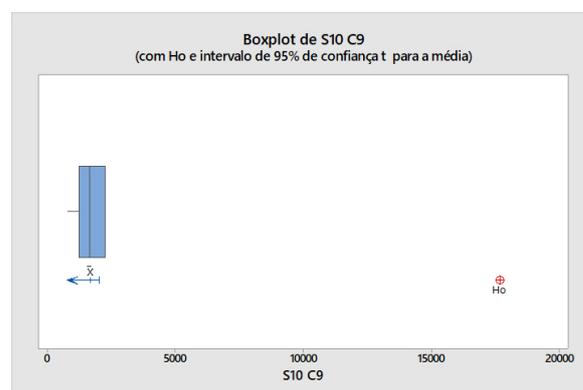


Figura 8.2.141 – Cluster 7, semana 10, com p-value = 0,000.

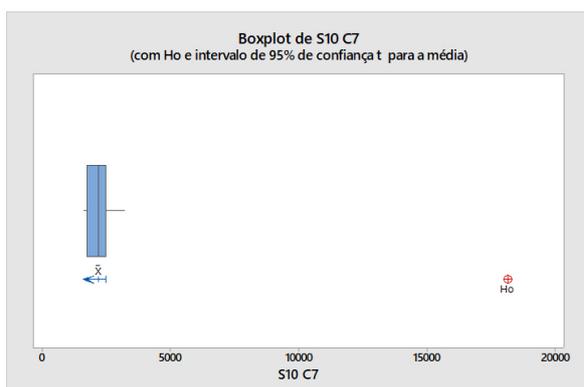


Figura 8.2.144 – Cluster 10, semana 10, com p-value = 1,000.

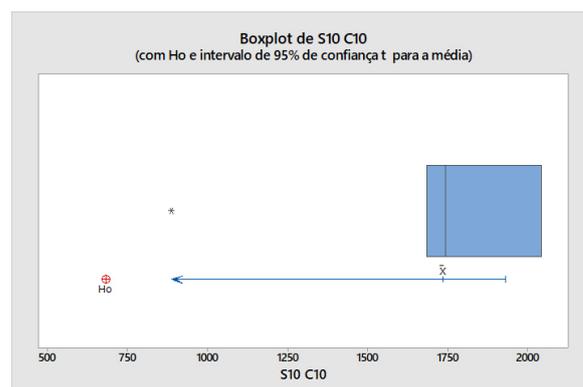


Figura 8.2.145 – Cluster 11, semana 10, com p-value = 0,092.

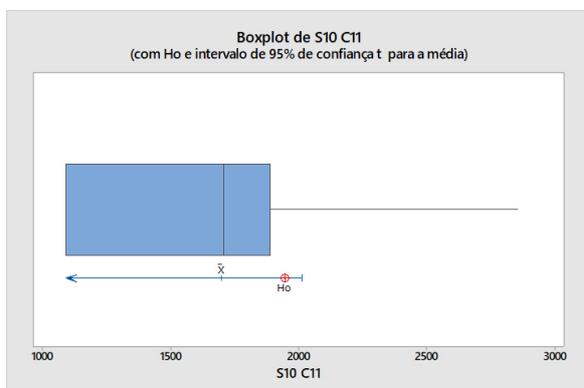


Figura 8.2.148 – Cluster 14, semana 10, com p-value = 1,000.

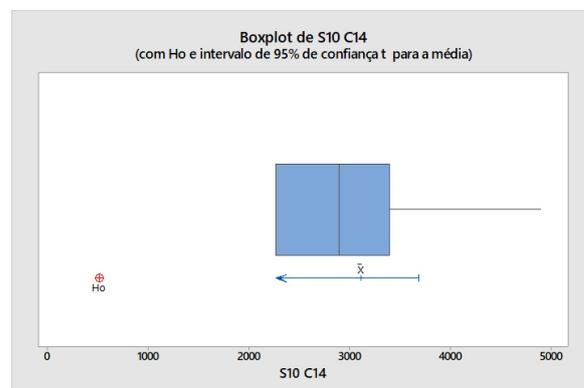


Figura 8.2.146 – Cluster 12, semana 10, com p-value = 1,000.

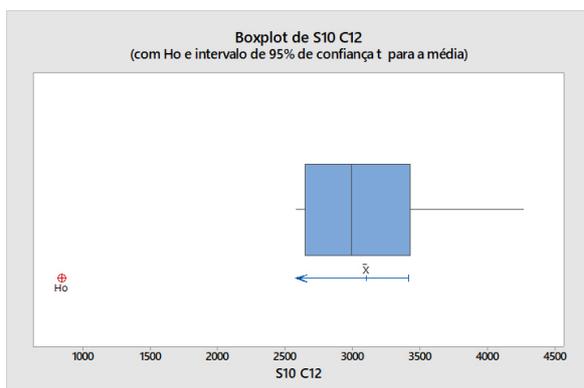


Figura 8.2.149 – Cluster 15, semana 10, com p-value = 1,000.

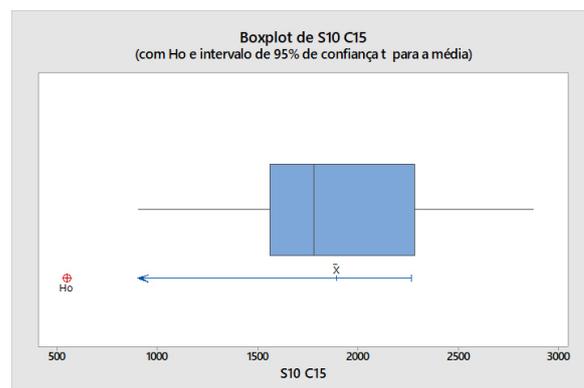


Figura 8.2.147 – Cluster 13, semana 10, com p-value = 0,983.

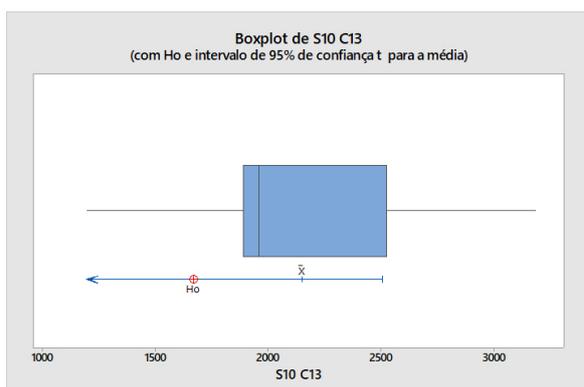


Figura 8.2.150 – Cluster 16, semana 10, com p-value = 1,000.

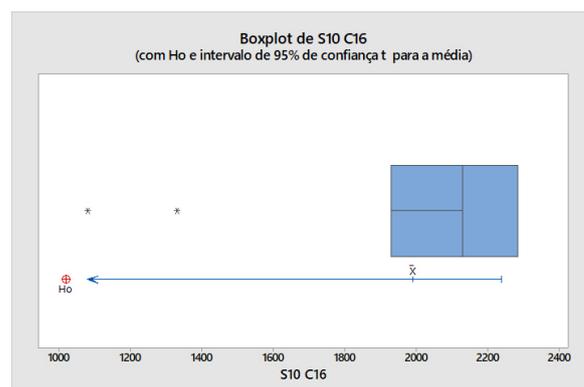


Figura 8.2.151 – Cluster 17, semana 10, com p-value = 0,127.

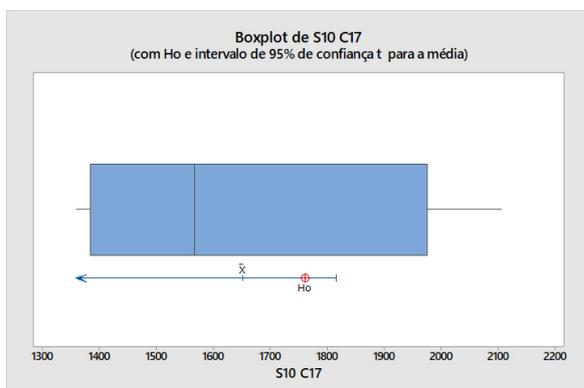


Figura 8.2.154 – Cluster 20, semana 10, com p-value = 1,000.

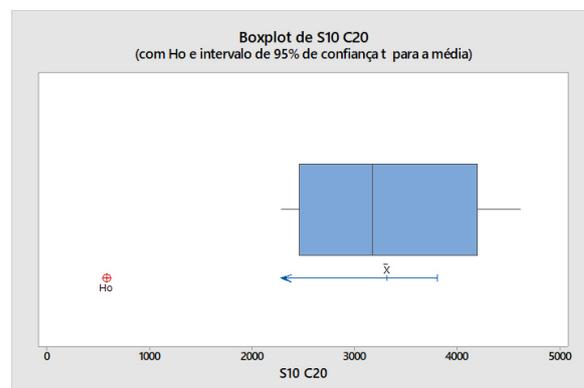


Figura 8.2.152 – Cluster 18, semana 10, com p-value = 1,000.

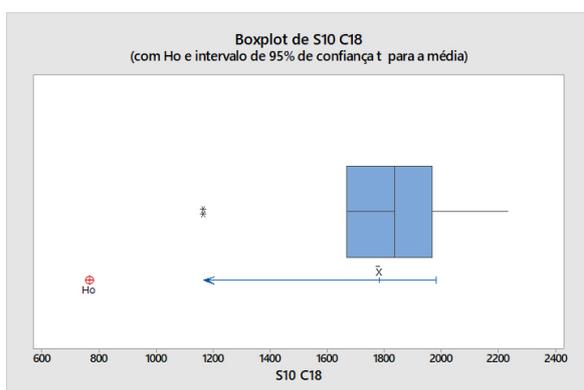


Figura 8.2.155 – Cluster 21, semana 10, com p-value = 0,987.

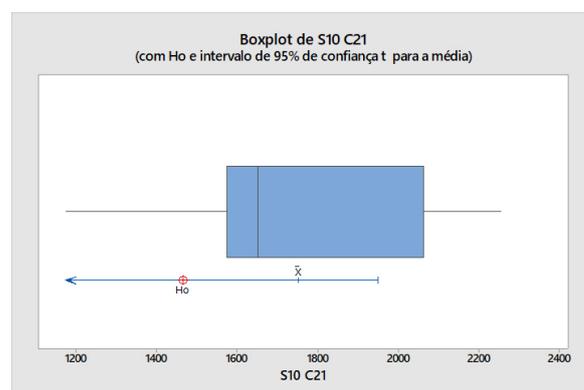


Figura 8.2.153 – Cluster 19, semana 10, com p-value = 1,000.

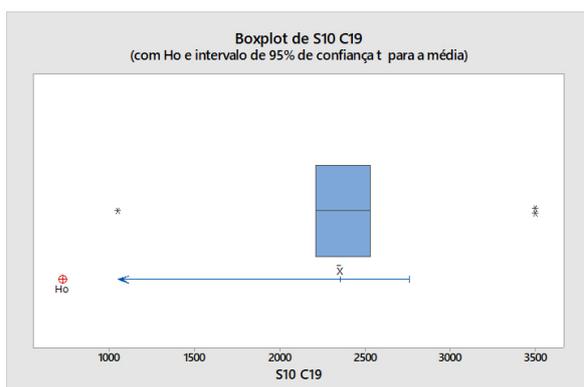


Figura 8.2.156 – Cluster 22, semana 10, com p-value = 1,000.

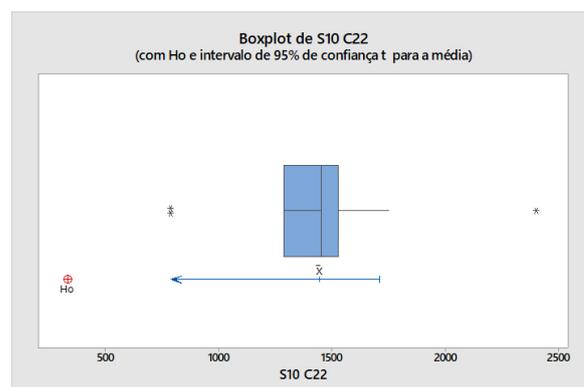
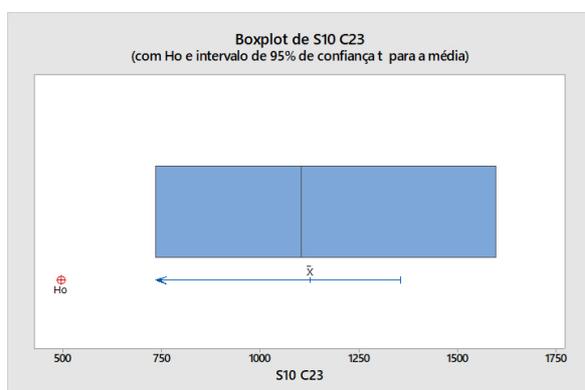


Figura 8.2.157 – Cluster 23, semana 10, com  
p-value = 1,000.



### 8.3 Apêndice III - BoxPlots dos Clusters do *Framework* Mono-veículo

Figura 8.3.1 – BoxPlot referente à semana 1

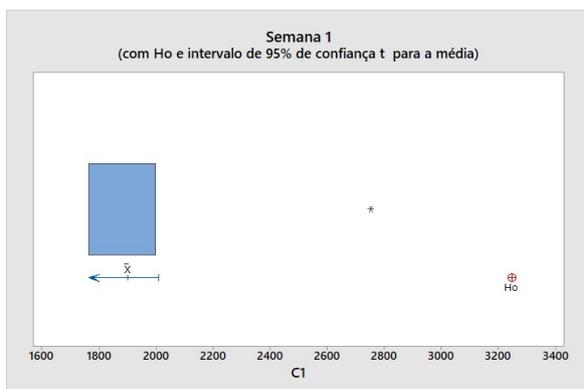


Figura 8.3.4 – BoxPlot referente à semana 2

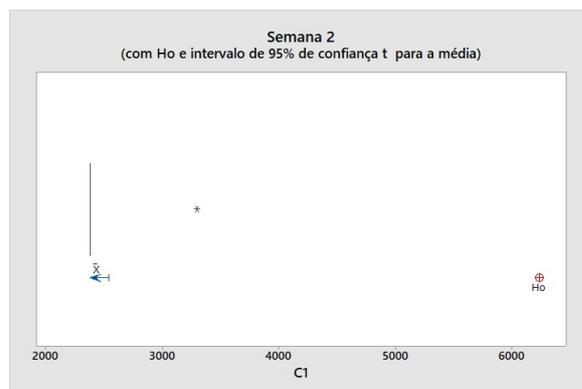


Figura 8.3.2 – BoxPlot referente à semana 3

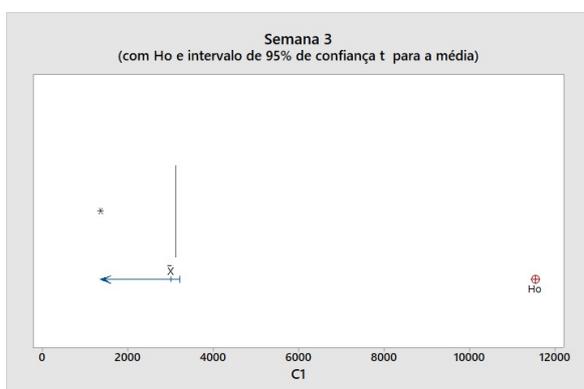


Figura 8.3.5 – BoxPlot referente à semana 4

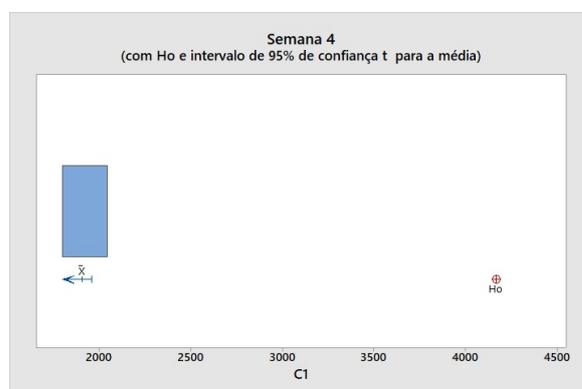


Figura 8.3.3 – BoxPlot referente à semana 5

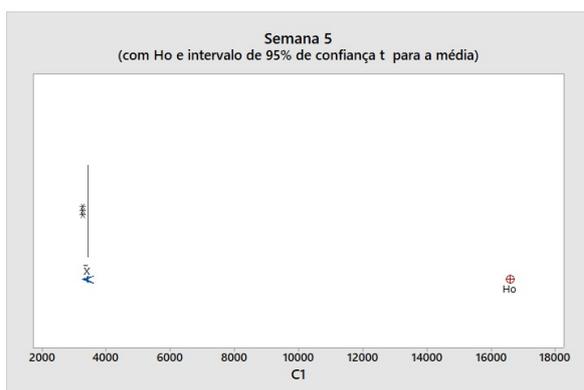


Figura 8.3.6 – BoxPlot referente à semana 6

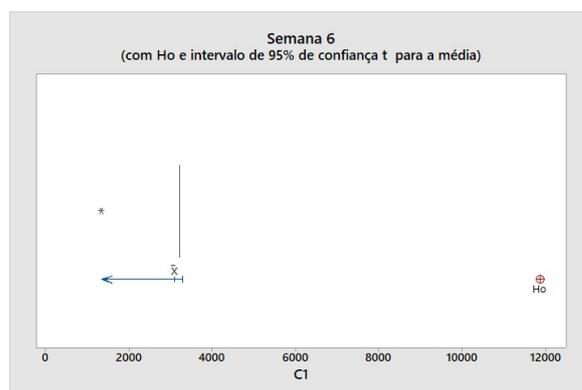


Figura 8.3.7 – BoxPlot referente à semana 7

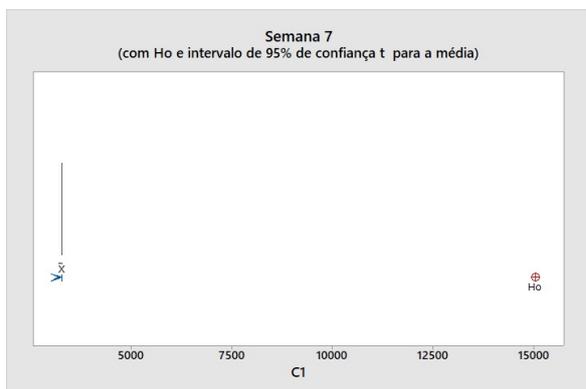


Figura 8.3.9 – BoxPlot referente à semana 8

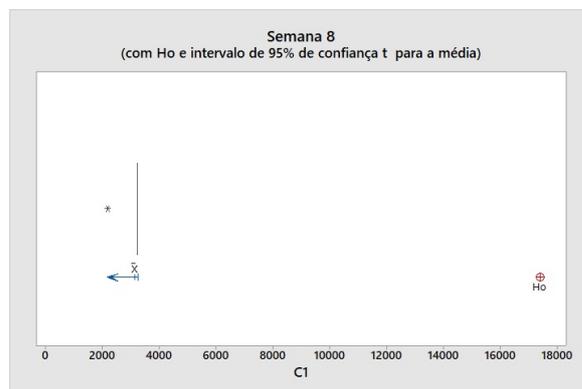


Figura 8.3.8 – BoxPlot referente à semana 9

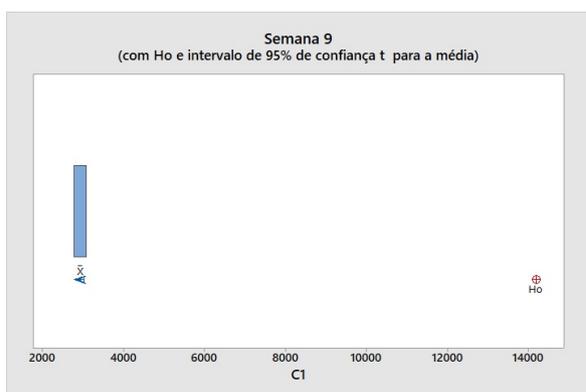
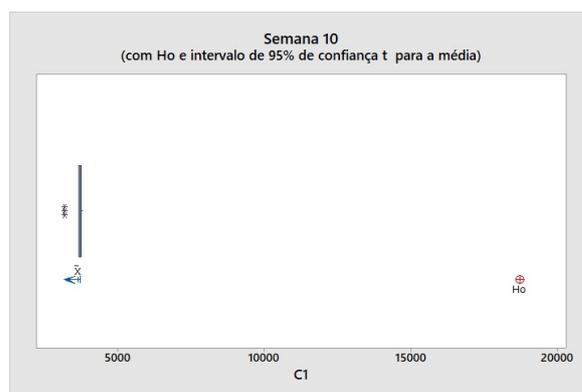


Figura 8.3.10 – BoxPlot referente à semana 10



## 8.4 Apêndice IV - Gráficos dos Clusters do *Framework* Mono-veículo após a execução do modelo de simulação

Figura 8.4.1 – Modelo referente a semana 1.

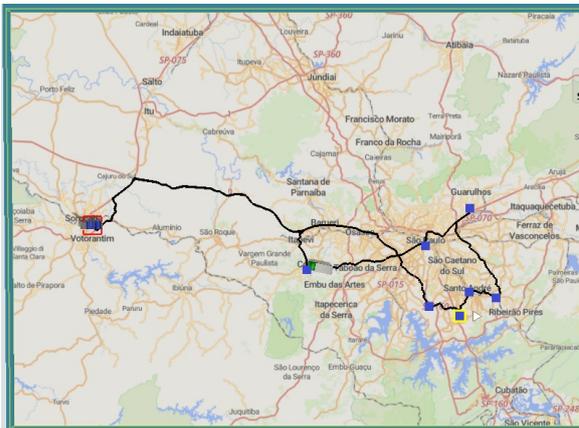


Figura 8.4.4 – Resultados referentes a semana 1.

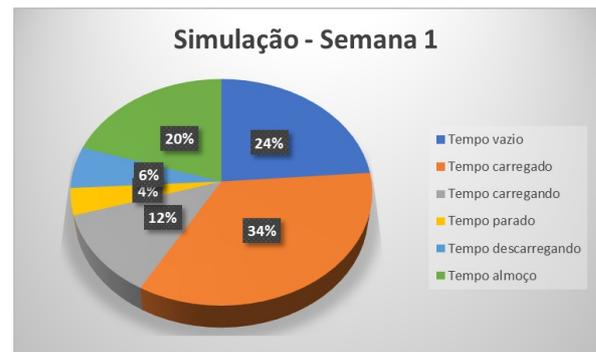


Figura 8.4.2 – Modelo referente a semana 2.

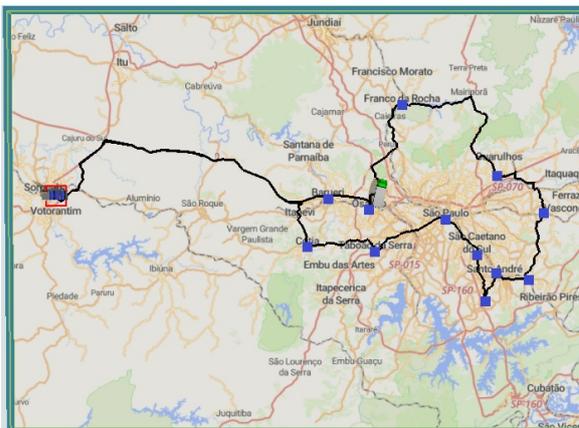


Figura 8.4.5 – Resultados referentes a semana 2.

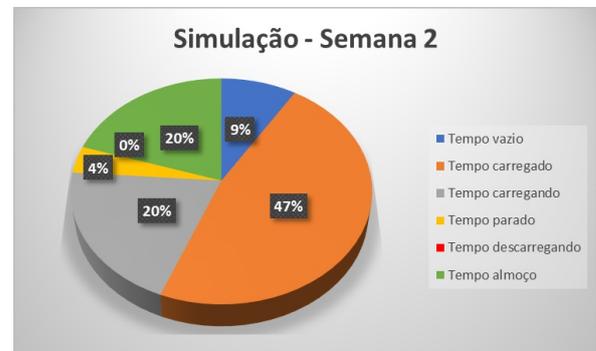


Figura 8.4.3 – Modelo referente a semana 3.

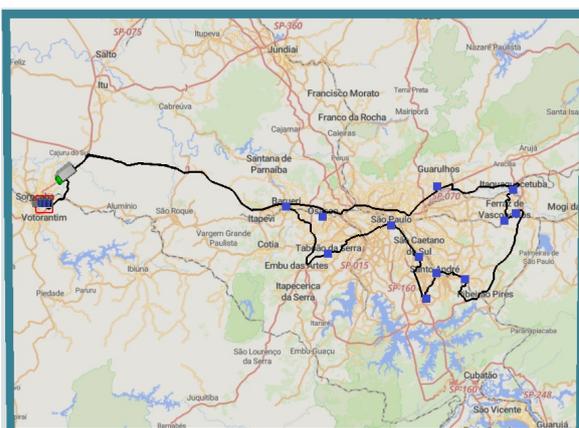


Figura 8.4.6 – Resultados referentes a semana 3.

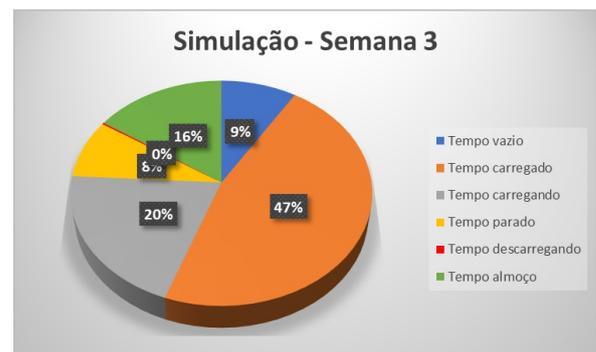


Figura 8.4.7 – Modelo referente a semana 4.

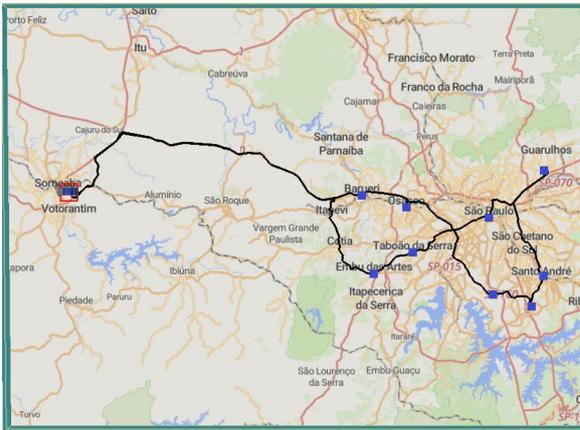


Figura 8.4.10 – Resultados referentes a semana 4.

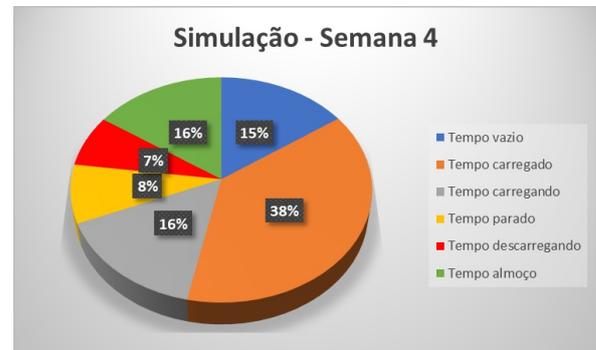


Figura 8.4.8 – Modelo referente a semana 5.

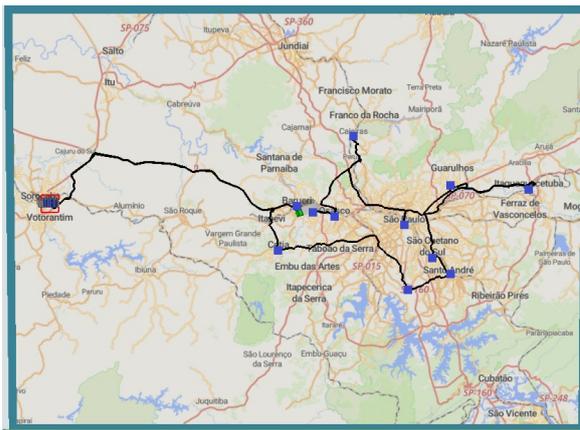


Figura 8.4.11 – Resultados referentes a semana 5.

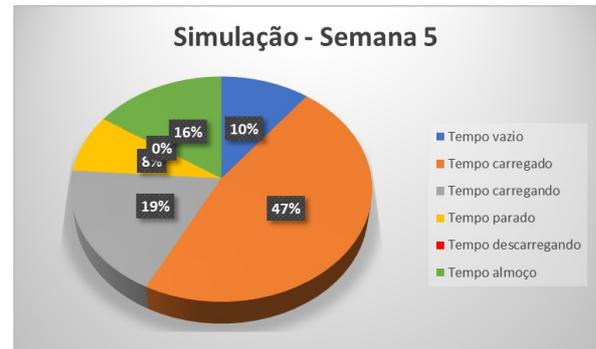


Figura 8.4.9 – Modelo referente a semana 6.

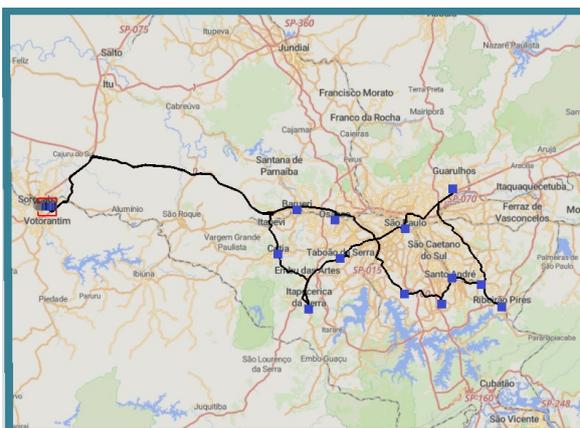


Figura 8.4.12 – Resultados referentes a semana 6.

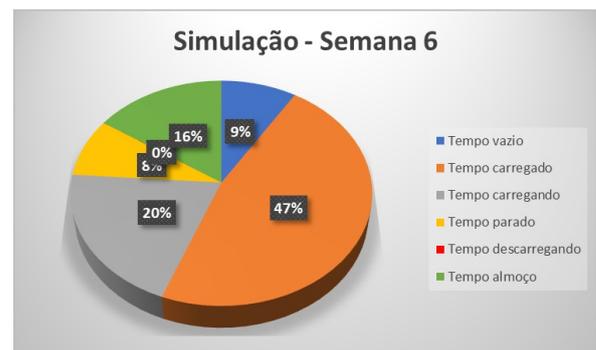


Figura 8.4.13 – Modelo referente a semana 7.

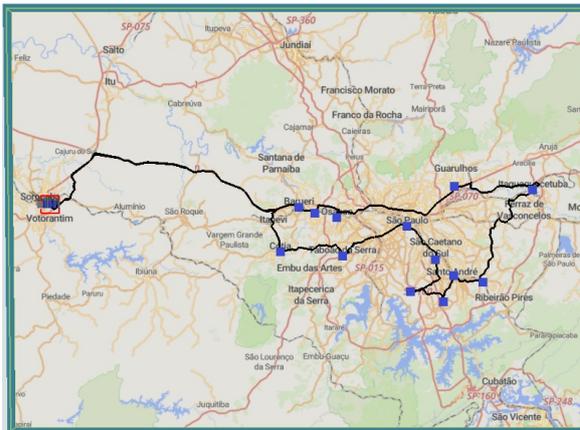


Figura 8.4.16 – Resultados referentes a semana 7.

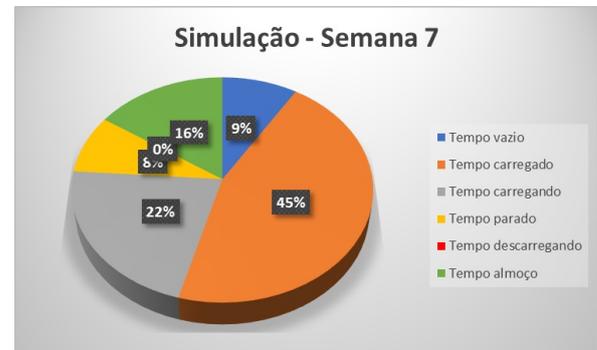


Figura 8.4.14 – Modelo referente a semana 8.

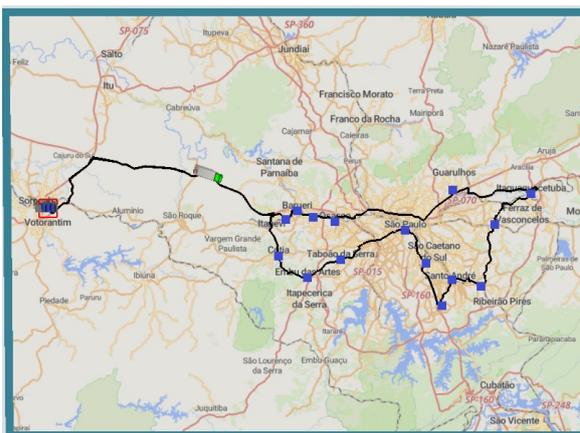


Figura 8.4.17 – Resultados referentes a semana 8.

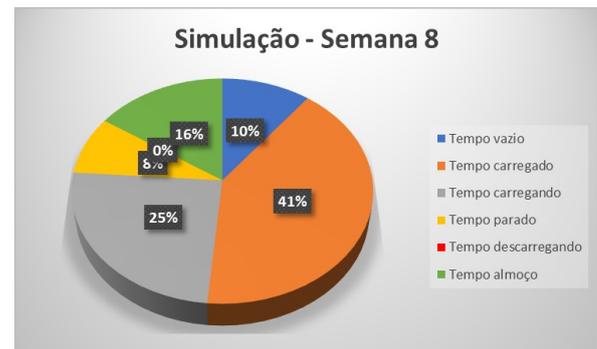


Figura 8.4.15 – Modelo referente a semana 9.

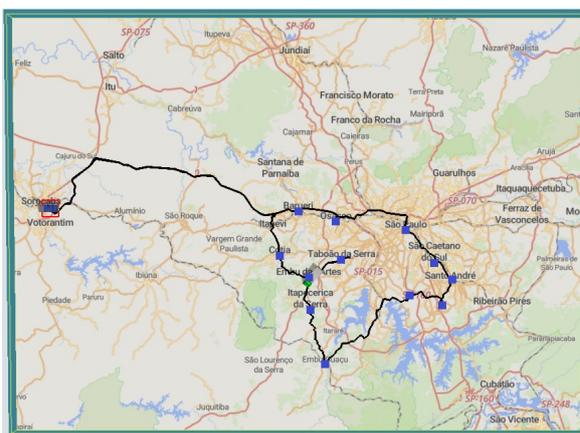


Figura 8.4.18 – Resultados referentes a semana 9.

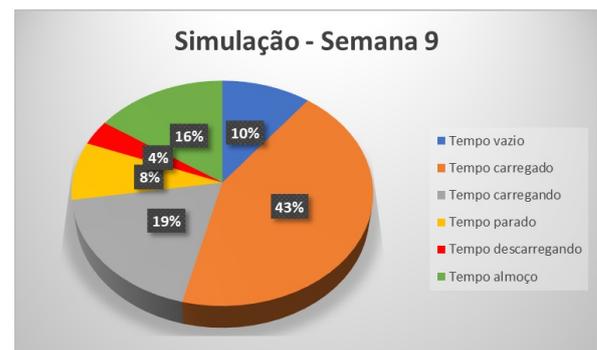


Figura 8.4.19 – Modelo referente a semana 10.

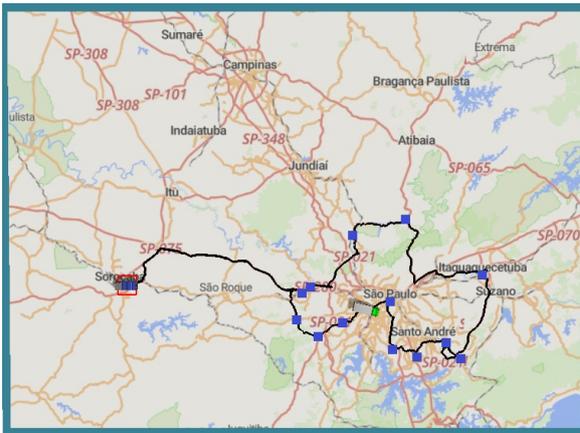
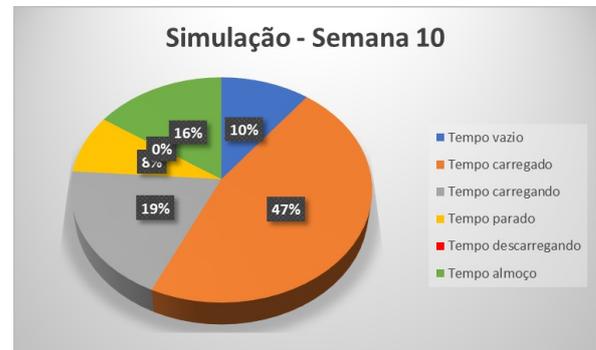


Figura 8.4.20 – Resultados referentes a semana 10.



## 8.5 Apêndice V - Gráficos de Comparações Entre os modelos Multiveículo e Monoveículo

Figura 8.5.1 – BoxPlot comparando os *Frame-works* na semana 1.

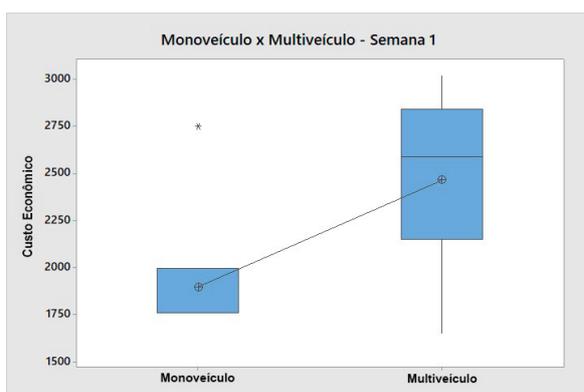


Figura 8.5.4 – BoxPlot comparando os *Frame-works* na semana 3.

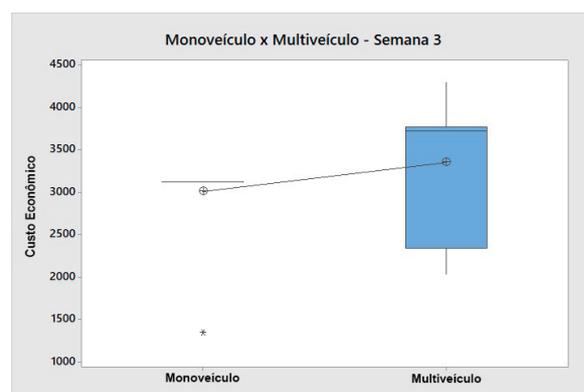


Figura 8.5.2 – BoxPlot comparando os *Frame-works* na semana 1, sem o outlier.

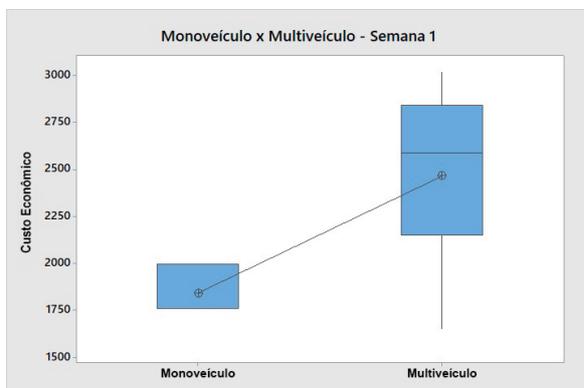


Figura 8.5.5 – BoxPlot comparando os *Frame-works* na semana 4.

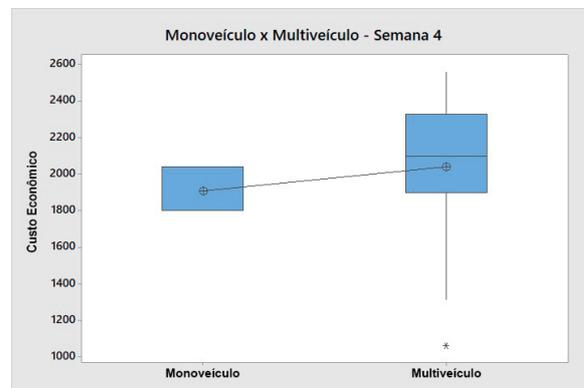


Figura 8.5.3 – BoxPlot comparando os *Frame-works* na semana 2.

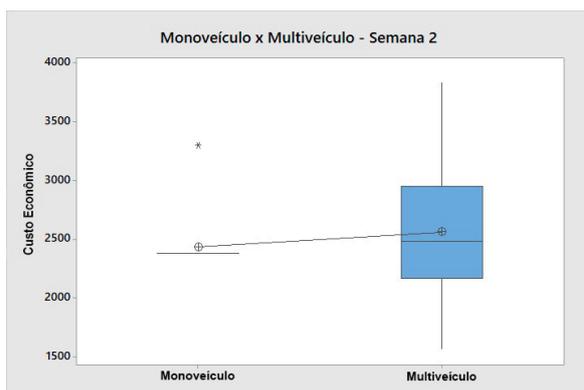


Figura 8.5.6 – BoxPlot comparando os *Frame-works* na semana 6.

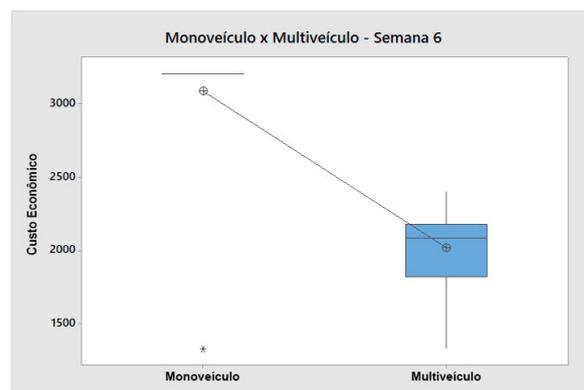


Figura 8.5.7 – BoxPlot comparando os *Frameworks* na semana 7.

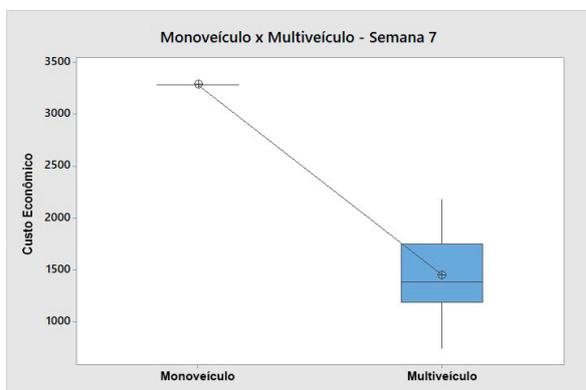


Figura 8.5.10 – BoxPlot comparando a semana 5, com o Cluster 8.

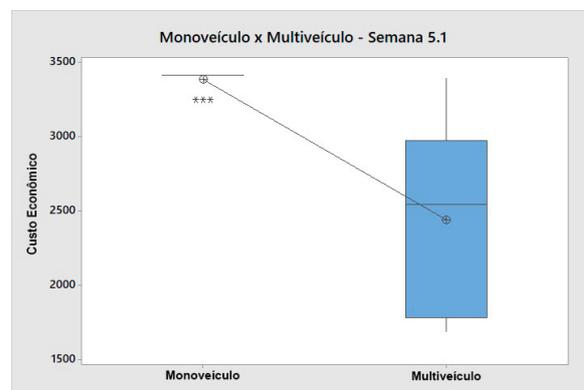


Figura 8.5.8 – BoxPlot comparando os *Frameworks* na semana 8.

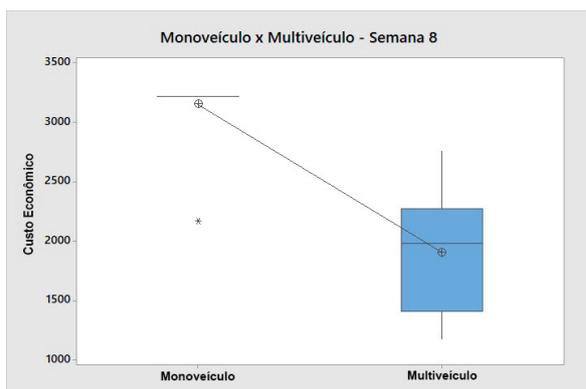


Figura 8.5.11 – BoxPlot comparando a semana 5, com o Cluster 9.

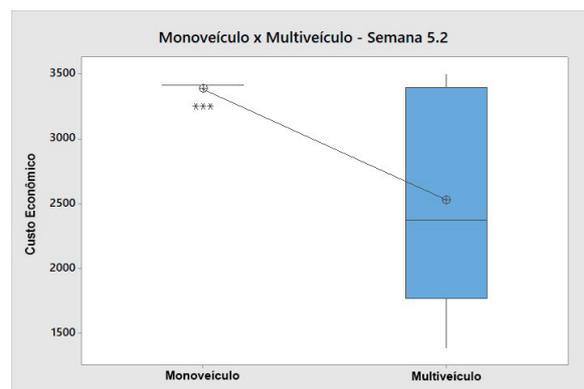


Figura 8.5.9 – BoxPlot comparando os *Frameworks* na semana 9.

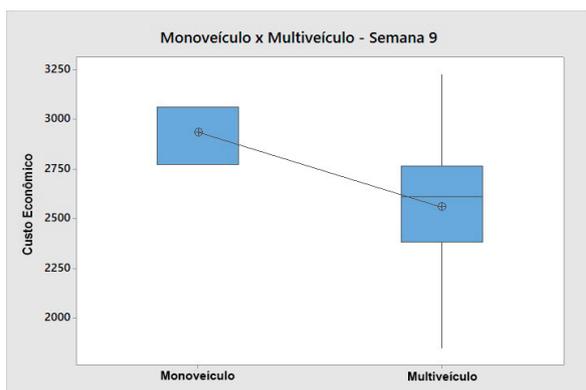


Figura 8.5.12 – BoxPlot comparando a semana 10, com o Cluster 8.

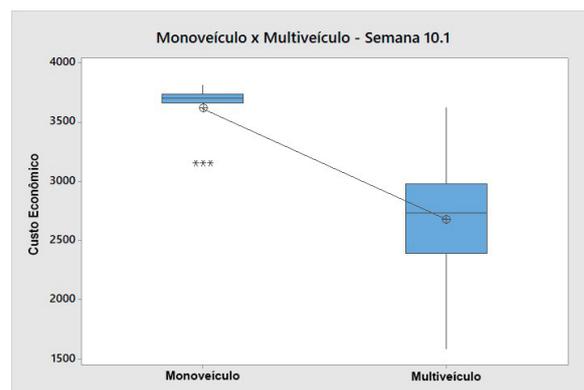
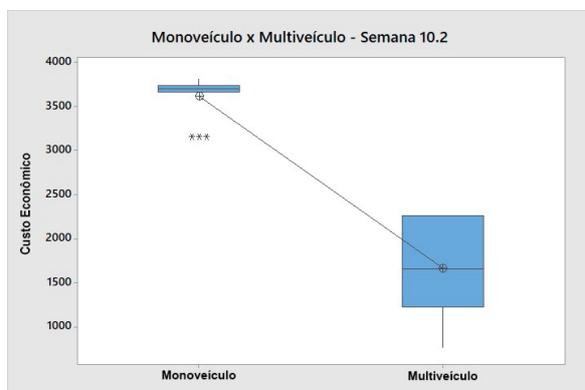


Figura 8.5.13 – BoxPlot comparando os *Frameworks* na semana 10, com o Cluster 9.



## 8.6 Apêndice VI - Trabalhos Publicados

AMARAL, João Victor Soares do; MONTEVECHI, José Arnaldo Barra; SANTOS, Carlos Henrique dos; PEREIRA, Alyson Benoni Matias; LOPES, Guilherme Ferreira. Metamodelagem adaptativa em otimização via simulação. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO (ENEGEP). São Paulo: Instituto de Engenharia de Produção e Gestão, 2023. p. 401-1969.

MARTINS, Anderson Lino de Paula; PEREIRA, Alyson Benoni Matias; LIMA, Yago Toledo; PINHO, Alexandre Ferreira de; MONTEVECHI, José Arnaldo Barra. Integrando inteligência artificial no software AnyLogic® utilizando Pathmind®. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL. São Paulo. 2021. v. 53, p. 139266.

PEREIRA, Alyson Benoni Matias; MONTEVECHI, José Arnaldo Barra; PINTO, Wesley Gabriel de Mendonça; SANTOS, Carlos Henrique dos. Simulation and digital twins to support reverse logistics decisions: a review. International Journal of Simulation and Modelling, v. 22, n. 3, p. 381-391, 2023.

PEREIRA, Alyson Benoni Matias; MONTEVECHI, José Arnaldo Barra; PINTO, Wesley Gabriel de Mendonça; SANTOS, Carlos Henrique dos; AMARAL, João Victor Soares do. Gêmeos digitais para apoio à tomada de decisões na logística reversa. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO (ENEGEP). São Paulo: Instituto de Engenharia de Produção e Gestão, 2023. p. 400-1966.

PEREIRA, Alyson Benoni Matias; MONTEVECHI, José Arnaldo Barra; SANTOS, Carlos Henrique dos; LÚCIO, Jonathan Serafim. Uma revisão sobre gêmeos digitais para apoio à tomada de decisões na logística reversa. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL. São Paulo, 2023. v. 55, p. 160973.

PINTO, Wesley Gabriel de Mendonça; MIRANDA, Rafael de Carvalho; SANTOS, Carlos Henrique dos; AMARAL, João Victor Soares do; PEREIRA, Alyson Benoni Matias. Otimização via simulação aplicado à logística reversa: uma revisão sistemática de literatura. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO (ENEGEP). São Paulo: Instituto de Engenharia de Produção e Gestão, 2022. p. 383-1897.

### Trabalhos aprovados

PEREIRA, Alyson Benoni Matias; MONTEVECHI, José Arnaldo Barra; PINTO, Wesley Gabriel de Mendonça. Gêmeos digitais na logística reversa: uma abordagem focada na otimização. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO (ENEGEP). "Reindustrialização no Brasil". Porto Alegre, Rio Grande do Sul, Brasil, 2024.