



Pós-Graduação em Ciência da Computação

Luciano Soares de Souza

SELEÇÃO MULTIOBJETIVO DE CASOS DE TESTE UTILIZANDO TÉNICAS DE BUSCA HÍBRIDAS



Universidade Federal de Pernambuco
posgraduacao@cin.ufpe.br
<www.cin.ufpe.br/~posgraduacao>

RECIFE
2016

Luciano Soares de Souza

**SELEÇÃO MULTIOBJETIVO DE CASOS DE TESTE UTILIZANDO
TÉNICAS DE BUSCA HÍBRIDAS**

*Trabalho apresentado ao Programa de Pós-graduação em
Ciência da Computação do Centro de Informática da Univer-
sidade Federal de Pernambuco como requisito parcial para
obtenção do grau de Doutor em Ciência da Computação.*

Orientador: *Ricardo Bastos Cavalcante Prudêncio*

Co-Orientadora: *Flávia de Almeida Barros*

RECIFE

2016

Catálogo na fonte
Bibliotecária Monick Raquel Silvestre da S. Portes, CRB4-1217

S729s Souza, Luciano Soares de
Seleção Multiobjetivo de Casos de Teste Utilizando Técnicas de Busca Híbridas / Luciano Soares de Souza. – 2016.
216 f.: il., fig., tab.

Orientador: Ricardo Bastos Cavalcante Prudêncio.
Tese (Doutorado) – Universidade Federal de Pernambuco. CIn, Ciência da Computação, Recife, 2016.
Inclui referências e apêndices.

1. Engenharia de software. 2. Inteligência artificial. I. Prudêncio, Ricardo Bastos Cavalcante (orientador). II. Título.

005.1 CDD (23. ed.) UFPE- MEI 2017-20

Luciano Soares de Souza

Seleção Multiobjetivo de Casos de Teste Utilizando Técnicas de Busca Híbridas

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Doutora em Ciência da Computação.

Aprovado em: 11/03/2016.

Orientador: Prof. Dr. Ricardo Bastos Cavalcanti Prudêncio

BANCA EXAMINADORA

Prof. Dr. Juliano Manabu Iyoda
Centro de Informática / UFPE

Prof. Dr. Adriano Lorena Inacio de Oliveira
Centro de Informática / UFPE

Prof. Dr. Alexandre Cabral Mota
Centro de Informática / UFPE

Profª. Dra. Aurora Trindad Ramirez Pozo
Departamento de Informática / UFPR

Profª. Dra. Anne Magály de Paula Canuto
Departamento de Informática e Matemática Aplicada / UFRN

*Dedico essa tese à minha família, amigos, orientadores e
professores que me deram o suporte necessário para chegar
até aqui.*

Agradecimentos

Aos meus orientadores Ricardo Bastos de Cavalcante Prudêncio e Flávia de Almeida Barros, pela amizade, pelos conselhos, pela paciência e pela compreensão. Nesses 7 anos trabalhando juntos (desde o mestrado) não tenho palavras para agradecer tudo que fizeram por mim. Ao Centro de Informática da UFPE por ter proporcionado as condições de realização deste trabalho. Ao Grupo de Pesquisa e ao Projeto BTC-Motorola, onde todo este meu trabalho começou e o início de minha carreira acadêmica. Ao professor Paulo Borba pelas orientações na fase embrionária deste trabalho. Aos colegas Leandro Nascimento e Hugo Nascimento que começaram a empreender as bases deste trabalho comigo. Às amigas Michelle Silva e Laís Neves pela ajuda sempre prestada. Aos meus amigos Washington Azevedo e Elleno Kennedy, por todo o apoio. E por último, mas não menos importante, tenho um agradecimento especial a fazer à meus avós, à minha mãe e aos meus irmãos que me proporcionaram condições (de todos os tipos) para que eu pudesse chegar até aqui.

Não basta ensinar ao homem uma especialidade, porque se tornará assim uma máquina utilizável, mas não uma personalidade. É necessário que adquira um sentimento, um senso prático daquilo que vale a pena ser empreendido, daquilo que é belo, do que é moralmente correto. A não ser assim, ele se assemelhará, com seus conhecimentos profissionais, mais a um cão ensinado do que a uma criatura harmoniosamente desenvolvida. Deve aprender a compreender as motivações dos homens, suas quimeras e suas angústias, para determinar com exatidão seu lugar preciso em relação a seus próximos e à comunidade.

—ALBERT EINSTEIN (FÍSICO ALEMÃO)

Resumo

O processo de geração automática de casos de teste de software pode produzir grandes suítes que podem ser custosas para executar. Por causa disso, é necessária uma forma de selecionar um subconjunto de casos de teste de forma a adequar a execução dos testes aos recursos disponíveis no ambiente de testes. Essa tarefa é conhecida como seleção de casos de teste. Assim como a execução dos testes, a seleção de casos de teste pode ser custosa, pois normalmente é realizada de forma manual. Além disso, essa tarefa não é trivial, pois a mesma é equivalente ao problema NP-Completo de cobertura de conjuntos. Portanto, técnicas de busca são indicadas na resolução desse tipo de problema. Essa área de pesquisa é conhecida como Engenharia de Software Baseada em Busca. A maioria dos trabalhos relacionados aos testes de software dentro dessa área consideram apenas um único critério de seleção (objetivo). Entretanto, em alguns ambientes de testes é necessário atender a mais de um objetivo durante o processo de seleção. Nesses casos o problema de seleção é considerado como multicritério (ou multiobjetivo). Dentro desse contexto, o presente trabalho propôs novas técnicas de busca (híbridas e não híbridas) para a seleção multiobjetivo de casos de teste. Essas técnicas foram comparadas (através de experimentos controlados) em relação à qualidade das fronteiras de Pareto retornadas e em relação à capacidade de detecção de falhas. Adicionalmente, restrições impostas pelo ambiente de testes foram consideradas e técnicas híbridas com mecanismos de tratamento de restrições foram propostas e comparadas. Por fim, das técnicas propostas a técnica BSMPSO-FB (*Binary Speed-constrained Multi-objective Particle Swarm Optimization with Forward Selection and Backward Elimination*) foi a que obteve melhores resultados.

Palavras-chave: Seleção Multiobjetivo de Casos de Teste. Testes de Software. Inteligência Artificial. Engenharia de Software. Técnicas de Busca. Engenharia de Software Baseada em Busca.

Abstract

The automatic test generation process can produce large test suites that can be very expensive to execute. Because of this, it is necessary to select a subset of test cases in order to fit the test execution to the available resources. This task is known as test case selection. Like manual test execution, test case selection can be very expensive because it is usually performed by humans. Furthermore, this is not a trivial task because it is equivalent to the NP-Complete set covering problem. Hence, search techniques are well suited to deal with this problem. This research area is known as Search Based Software Engineering. Most of the test case selection works considers only one criterion (objective) at a time. But, some test environments need to consider more than one objective during the test case selection. In this light, the problem is referred as multi-criteria search (or multi-objective). According to this scenario, this work proposed new search techniques (hybrid and non hybrid) for multi-objective test case selection. These techniques were compared (through controlled experiments) by considering the quality of the returned Pareto frontiers and its faults detection ability. Furthermore, environments constraints were considered and new hybrid techniques with constraints treatment mechanisms were proposed and evaluated. In the end the BSMPSO-FB (*Binary Speed-constrained Multi-objective Particle Swarm Optimization with Forward Selection and Backward Elimination*) technique was the one with the best results.

Keywords: Multi-objective Test Case Selection. Software Testing. Artificial Intelligence. Software Engineering. Search Techniques. Search Based Software Engineering.

Lista de Figuras

2.1	Modelo V	25
2.2	Modelo V mais detalhado	27
2.3	Dominância	32
2.4	Exemplo de seis vetores no espaço dos objetivos	33
2.5	Fronteira de Pareto	34
2.6	Otimização com restrições	36
3.1	Processo de Busca <i>Forward Selection</i>	53
3.2	Processo de Busca <i>Backward Elimination</i>	53
A.1	Boxplots métrica HV - Subgrupo 1	154
A.2	Boxplots métrica GD - Subgrupo 1	155
A.3	Boxplots métrica IGD - Subgrupo 1	156
A.4	Boxplots métrica CVR - Subgrupo 1	157
A.5	Boxplots métrica MS - Subgrupo 1	158
A.6	Boxplots métrica HV - Subgrupo 2	159
A.7	Boxplots métrica GD - Subgrupo 2	160
A.8	Boxplots métrica IGD - Subgrupo 2	161
A.9	Boxplots métrica CVR - Subgrupo 2	162
A.10	Boxplots métrica MS - Subgrupo 2	163
A.11	Boxplots métrica HV - Subgrupo 3	164
A.12	Boxplots métrica GD - Subgrupo 3	165
A.13	Boxplots métrica IGD - Subgrupo 3	166
A.14	Boxplots métrica CVR - Subgrupo 3	167
A.15	Boxplots métrica MS - Subgrupo 3	168
A.16	Boxplots métrica HV - Subgrupo 4	169
A.17	Boxplots métrica GD - Subgrupo 4	170
A.18	Boxplots métrica IGD - Subgrupo 4	171
A.19	Boxplots métrica CVR - Subgrupo 4	172
A.20	Boxplots métrica MS - Subgrupo 4	173
A.21	Boxplots métrica HV - Subgrupo 5	174
A.22	Boxplots métrica GD - Subgrupo 5	175
A.23	Boxplots métrica IGD - Subgrupo 5	176
A.24	Boxplots métrica CVR - Subgrupo 5	177
A.25	Boxplots métrica MS - Subgrupo 5	178
A.26	Convergência métrica HV - Subgrupo 1	179
A.27	Convergência métrica GD - Subgrupo 1	180

A.28	Convergência métrica IGD - Subgrupo 1	181
A.29	Convergência métrica CVR - Subgrupo 1	182
A.30	Convergência métrica MS - Subgrupo 1	183
A.31	Convergência métrica HV - Subgrupo 2	184
A.32	Convergência métrica GD - Subgrupo 2	185
A.33	Convergência métrica IGD - Subgrupo 2	186
A.34	Convergência métrica CVR - Subgrupo 2	187
A.35	Convergência métrica MS - Subgrupo 2	188
A.36	Convergência métrica HV - Subgrupo 3	189
A.37	Convergência métrica GD - Subgrupo 3	190
A.38	Convergência métrica IGD - Subgrupo 3	191
A.39	Convergência métrica CVR - Subgrupo 3	192
A.40	Convergência métrica MS - Subgrupo 3	193
A.41	Convergência métrica HV - Subgrupo 4	194
A.42	Convergência métrica GD - Subgrupo 4	195
A.43	Convergência métrica IGD - Subgrupo 4	196
A.44	Convergência métrica CVR - Subgrupo 4	197
A.45	Convergência métrica MS - Subgrupo 4	198
A.46	Convergência métrica HV - Subgrupo 5	199
A.47	Convergência métrica GD - Subgrupo 5	200
A.48	Convergência métrica IGD - Subgrupo 5	201
A.49	Convergência métrica CVR - Subgrupo 5	202
A.50	Convergência métrica MS - Subgrupo 5	203
B.1	Boxplots Métricas - GUAVA	206
B.2	Convergência Métricas - GUAVA	207
B.3	Boxplots Métricas - GUAVA - Cobertura x Falhas	208
B.4	Boxplots Métricas - GUAVA - Custo x Falhas	209
C.1	Boxplots Métricas - GUAVA (Cobertura de Requisitos $\geq 50\%$)	213
C.2	Boxplots Métricas - GUAVA (Custo de Execução $\leq 50\%$)	214
C.3	Boxplots Métricas - GUAVA (Cobertura de Requisitos $\geq 90\%$)	215
C.4	Boxplots Métricas - GUAVA (Custo de Execução $\leq 10\%$)	216

Lista de Tabelas

2.1	Comparativo dos trabalhos relacionados	46
3.1	Exemplo de uma suíte de testes	55
4.1	Detalhes sobre os programas	63
4.2	Divisão dos Subgrupos	63
4.3	Quantidade de vezes melhor - Subgrupo 1	70
4.4	Quantidade de vezes melhor - Subgrupo 2	71
4.5	Quantidade de vezes melhor - Subgrupo 3	73
4.6	Quantidade de vezes melhor - Subgrupo 4	74
4.7	Quantidade de vezes melhor - Subgrupo 5	75
4.8	Média, desvio padrão e Kruskal-Wallis - Todas as Métricas - GUAVA	77
4.9	Quantidade de vezes melhor - Melhores Técnicas	77
4.10	Média, desvio padrão e Kruskal-Wallis - Todas as Métricas - Cobertura x Falhas - GUAVA	79
4.11	Média, desvio padrão e Kruskal-Wallis - Todas as Métricas - Custo x Falhas - GUAVA	79
4.12	Quantidade de vezes melhor - Melhores Técnicas no estudo da capacidade de detecção de falhas	80
4.13	Média, desvio padrão e Kruskal-Wallis - Todas as Métricas - GUAVA (Cobertura de Requisitos $\geq 50\%$)	82
4.14	Média, desvio padrão e Kruskal-Wallis - Todas as Métricas - GUAVA (Custo de Execução $\leq 50\%$)	82
4.15	Média, desvio padrão e Kruskal-Wallis - Todas as Métricas - GUAVA (Cobertura de Requisitos $\geq 90\%$)	83
4.16	Média, desvio padrão e Kruskal-Wallis - Todas as Métricas - GUAVA (Custo de Execução $\leq 10\%$)	83
4.17	Quantidade de vezes melhor - Estudo com Restrições	84
4.18	Média, desvio padrão e Kruskal-Wallis - Todas as Métricas - Cobertura x Falhas - GUAVA (Cobertura de Requisitos $\geq 50\%$)	85
4.19	Média, desvio padrão e Kruskal-Wallis - Todas as Métricas - Cobertura x Falhas - GUAVA (Custo de Execução $\leq 50\%$)	86
4.20	Média, desvio padrão e Kruskal-Wallis - Todas as Métricas - Cobertura x Falhas - GUAVA (Cobertura de Requisitos $\geq 90\%$)	86
4.21	Média, desvio padrão e Kruskal-Wallis - Todas as Métricas - Cobertura x Falhas - GUAVA (Custo de Execução $\leq 10\%$)	87

4.22	Média, desvio padrão e Kruskal-Wallis - Todas as Métricas - Custo x Falhas - GUAVA (Cobertura de Requisitos $\geq 50\%$)	87
4.23	Média, desvio padrão e Kruskal-Wallis - Todas as Métricas - Custo x Falhas - GUAVA (Custo de Execução $\leq 50\%$)	88
4.24	Média, desvio padrão e Kruskal-Wallis - Todas as Métricas - Custo x Falhas - GUAVA (Cobertura de Requisitos $\geq 90\%$)	88
4.25	Média, desvio padrão e Kruskal-Wallis - Todas as Métricas - Custo x Falhas - GUAVA (Custo de Execução $\leq 10\%$)	89
4.26	Quantidade de vezes melhor no estudo com restrições e capacidade de detecção de falhas	89
A.1	Média, desvio padrão e Kruskal-Wallis - Métrica HV - Subgrupo 1	104
A.2	Resultados do teste Steel-Dwass - Métrica HV - Subgrupo 1	105
A.3	Média, desvio padrão e Kruskal-Wallis - Métrica GD - Subgrupo 1	106
A.4	Resultados do teste Steel-Dwass - Métrica GD - Subgrupo 1	107
A.5	Média, desvio padrão e Kruskal-Wallis - Métrica IGD - Subgrupo 1	108
A.6	Resultados do teste Steel-Dwass - Métrica IGD - Subgrupo 1	109
A.7	Média, desvio padrão e Kruskal-Wallis - Métrica CVR - Subgrupo 1	110
A.8	Resultados do teste Steel-Dwass - Métrica CVR - Subgrupo 1	111
A.9	Média, desvio padrão e Kruskal-Wallis - Métrica MS - Subgrupo 1	112
A.10	Resultados do teste Steel-Dwass - Métrica MS - Subgrupo 1	113
A.11	Média, desvio padrão e Kruskal-Wallis - Métrica HV - Subgrupo 2	114
A.12	Resultados do teste Steel-Dwass - Métrica HV - Subgrupo 2	115
A.13	Média, desvio padrão e Kruskal-Wallis - Métrica GD - Subgrupo 2	116
A.14	Resultados do teste Steel-Dwass - Métrica GD - Subgrupo 2	117
A.15	Média, desvio padrão e Kruskal-Wallis - Métrica IGD - Subgrupo 2	118
A.16	Resultados do teste Steel-Dwass - Métrica IGD - Subgrupo 2	119
A.17	Média, desvio padrão e Kruskal-Wallis - Métrica CVR - Subgrupo 2	120
A.18	Resultados do teste Steel-Dwass - Métrica CVR - Subgrupo 2	121
A.19	Média, desvio padrão e Kruskal-Wallis - Métrica MS - Subgrupo 2	122
A.20	Resultados do teste Steel-Dwass - Métrica MS - Subgrupo 2	123
A.21	Média, desvio padrão e Kruskal-Wallis - Métrica HV - Subgrupo 3	124
A.22	Resultados do teste Steel-Dwass - Métrica HV - Subgrupo 3	125
A.23	Média, desvio padrão e Kruskal-Wallis - Métrica GD - Subgrupo 3	126
A.24	Resultados do teste Steel-Dwass - Métrica GD - Subgrupo 3	127
A.25	Média, desvio padrão e Kruskal-Wallis - Métrica IGD - Subgrupo 3	128
A.26	Resultados do teste Steel-Dwass - Métrica IGD - Subgrupo 3	129
A.27	Média, desvio padrão e Kruskal-Wallis - Métrica CVR - Subgrupo 3	130
A.28	Resultados do teste Steel-Dwass - Métrica CVR - Subgrupo 3	131

A.29 Média, desvio padrão e Kruskal-Wallis - Métrica MS - Subgrupo 3	132
A.30 Resultados do teste Steel-Dwass - Métrica MS - Subgrupo 3	133
A.31 Média, desvio padrão e Kruskal-Wallis - Métrica HV - Subgrupo 4	134
A.32 Resultados do teste Steel-Dwass - Métrica HV - Subgrupo 4	135
A.33 Média, desvio padrão e Kruskal-Wallis - Métrica GD - Subgrupo 4	136
A.34 Resultados do teste Steel-Dwass - Métrica GD - Subgrupo 4	137
A.35 Média, desvio padrão e Kruskal-Wallis - Métrica IGD - Subgrupo 4	138
A.36 Resultados do teste Steel-Dwass - Métrica IGD - Subgrupo 4	139
A.37 Média, desvio padrão e Kruskal-Wallis - Métrica CVR - Subgrupo 4	140
A.38 Resultados do teste Steel-Dwass - Métrica CVR - Subgrupo 4	141
A.39 Média, desvio padrão e Kruskal-Wallis - Métrica MS - Subgrupo 4	142
A.40 Resultados do teste Steel-Dwass - Métrica MS - Subgrupo 4	143
A.41 Média, desvio padrão e Kruskal-Wallis - Métrica HV - Subgrupo 5	144
A.42 Resultados do teste Steel-Dwass - Métrica HV - Subgrupo 5	145
A.43 Média, desvio padrão e Kruskal-Wallis - Métrica GD - Subgrupo 5	146
A.44 Resultados do teste Steel-Dwass - Métrica GD - Subgrupo 5	147
A.45 Média, desvio padrão e Kruskal-Wallis - Métrica IGD - Subgrupo 5	148
A.46 Resultados do teste Steel-Dwass - Métrica IGD - Subgrupo 5	149
A.47 Média, desvio padrão e Kruskal-Wallis - Métrica CVR - Subgrupo 5	150
A.48 Resultados do teste Steel-Dwass - Métrica CVR - Subgrupo 5	151
A.49 Média, desvio padrão e Kruskal-Wallis - Métrica MS - Subgrupo 5	152
A.50 Resultados do teste Steel-Dwass - Métrica MS - Subgrupo 5	153
 B.1 Resultados do teste Steel-Dwass - GUAVA	 204
B.2 Resultados do teste Steel-Dwass - Cobertura x Falhas - GUAVA	205
B.3 Resultados do teste Steel-Dwass - Custo x Falhas - GUAVA	205
 C.1 Resultados do teste Steel-Dwass - GUAVA (Cobertura de Requisitos $\geq 50\%$) . . .	 210
C.2 Resultados do teste Steel-Dwass - GUAVA (Custo de Execução $\leq 50\%$) . . .	210
C.3 Resultados do teste Steel-Dwass - GUAVA (Cobertura de Requisitos $\geq 90\%$) . . .	211
C.4 Resultados do teste Steel-Dwass - GUAVA (Custo de Execução $\leq 10\%$) . . .	211
C.5 Resultados do teste Steel-Dwass - Cobertura x Falhas - GUAVA (Cobertura de Requisitos $\geq 50\%$)	211
C.6 Resultados do teste Steel-Dwass - Cobertura x Falhas - GUAVA (Cobertura de Requisitos $\geq 90\%$)	211
C.7 Resultados do teste Steel-Dwass - Custo x Falhas - GUAVA (Cobertura de Requisitos $\geq 50\%$)	212
C.8 Resultados do teste Steel-Dwass - Custo x Falhas - GUAVA (Custo de Execução $\leq 50\%$)	212

C.9 Resultados do teste Steel-Dwass - Custo x Falhas - GUAVA (Cobertura de Requisitos $\geq 90\%$)	212
C.10 Resultados do teste Steel-Dwass - Custo x Falhas - GUAVA (Custo de Execução $\leq 10\%$)	212

Lista de Acrônimos

MOPSO-CDR	<i>Multi-Objective Particle Swarm Optimization with Crowding Distance and Roulette Wheel</i>	38
NSGA-II	<i>Non-dominated Sorting Genetic Algorithm</i>	38
SPEA2	<i>Strength Pareto Evolutionary Algorithm</i>	38
TAEA	<i>Two-Archive Evolutionary Algorithm</i>	38
SMPSO	<i>Speed-constrained Multi-objective Particle Swarm Optimization</i>	40
BMOPSO-CDR	<i>Binary Multi-Objective Particle Swarm Optimization with Crowding Distance and Roulette Wheel</i>	51
BSMPSO	<i>Binary Speed-constrained Multi-objective Particle Swarm Optimization</i>	51
FB	<i>Forward Selection and Backward Elimination</i>	52
AG	<i>Additional Greedy</i>	52
HS	<i>Busca Harmônica - Harmony Search</i>	52
BMOPSO-CDR-FB	<i>Binary Multi-Objective Particle Swarm Optimization with Crowding Distance, Roulette Wheel, Forward Selection and Backward Elimination</i>	53
BSMPSO-FB	<i>Binary Speed-constrained Multi-objective Particle Swarm Optimization with Forward Selection and Backward Elimination</i>	53
NSGA-II-FB	<i>Non-dominated Sorting Genetic Algorithm with Forward Selection and Backward Elimination</i>	53
SPEA2-FB	<i>Strength Pareto Evolutionary Algorithm with Forward Selection and Backward Elimination</i>	53
TAEA-FB	<i>Two-Archive Evolutionary Algorithm with Forward Selection and Backward Elimination</i>	53
BMOPSO-CDR-1opt	<i>Binary Multi-Objective Particle Swarm Optimization with Crowding Distance, Roulette Wheel and 1-opt</i>	54
BSMPSO-1opt	<i>Binary Speed-constrained Multi-objective Particle Swarm Optimization with 1-opt</i>	54
NSGA-II-1opt	<i>Non-dominated Sorting Genetic Algorithm with 1-opt</i>	54
SPEA2-1opt	<i>Strength Pareto Evolutionary Algorithm with 1-opt</i>	54
TAEA-1opt	<i>Two-Archive Evolutionary Algorithm with 1-opt</i>	54
BMOPSO-CDR-AG	<i>Binary Multi-Objective Particle Swarm Optimization with Crowding Distance, Roulette Wheel and Additional Greedy</i>	55

BSMPSO-AG	<i>Binary Speed-constrained Multi-objective Particle Swarm Optimization with Additional Greedy</i>	55
NSGA-II-AG	<i>Non-dominated Sorting Genetic Algorithm with Additional Greedy</i>	55
SPEA2-AG	<i>Strength Pareto Evolutionary Algorithm with Additional Greedy</i>	55
TAEA-AG	<i>Two-Archive Evolutionary Algorithm with Additional Greedy</i>	55
BMOPSO-CDR-HS	<i>Binary Multi-Objective Particle Swarm Optimization with Crowding Distance, Roulette Wheel and Harmony Search</i>	57
BSMPSO-HS	<i>Binary Speed-constrained Multi-objective Particle Swarm Optimization with Harmony Search</i>	57
NSGA-II-HS	<i>Non-dominated Sorting Genetic Algorithm with Harmony Search</i>	57
SPEA2-HS	<i>Strength Pareto Evolutionary Algorithm with Harmony Search</i>	57
TAEA-HS	<i>Two-Archive Evolutionary Algorithm with Harmony Search</i>	57
CBSMPSO-FB-C	<i>Constrained Binary Speed-constrained Multi-objective Particle Swarm Optimization with Coello's approach</i>	58
CBSMPSO-FB-F	<i>Constrained Binary Speed-constrained Multi-objective Particle Swarm Optimization with Erdong's Fitness approach</i>	58
SIR	<i>Software-Artifact Infrastructure Repository</i>	61
GUAVA	<i>Google Guava Core Libraries</i>	61
HV	<i>Hypervolume</i>	65
GD	<i>Distância Geracional - Generational Distance</i>	66
IGD	<i>Distância Geracional Inversa - Inverted Generational Distance</i>	66
CVR	<i>Cobertura do Pareto de Referência - Coverage</i>	66
MS	<i>Espalhamento Máximo - Maximum Spread</i>	66

Sumário

1	Introdução	19
1.1	Motivação e Relevância	19
1.2	Objetivos	22
1.2.1	Objetivo Geral	22
1.2.2	Objetivos Específicos	22
1.3	Estrutura da Tese	23
2	Conceitos Fundamentais	24
2.1	Testes de Software	24
2.1.1	Minimização, Seleção e Priorização	27
2.1.2	Seleção de Casos de Teste Utilizando Técnicas de Busca	30
2.1.2.1	Seleção Multiobjetivo de Casos de Teste	31
2.1.2.2	Seleção Multiobjetivo com Restrições	35
2.2	Técnicas de Busca	37
2.2.1	MOPSO-CDR	38
2.2.2	SMPSO	40
2.2.3	NSGA-II	42
2.2.4	SPEA2	42
2.2.5	TAEA	43
2.3	Trabalhos Relacionados	43
2.4	Considerações Finais	49
3	Métodos Propostos	50
3.1	Técnicas de Busca Propostas para o Problema de Seleção Multiobjetivo de Casos de Teste	50
3.1.1	Formulação do Problema	50
3.1.2	Técnicas Não Híbridas	51
3.1.3	Técnicas Híbridas	52
3.1.3.1	Mecanismo FB	52
3.1.3.2	Mecanismo 1-opt	54
3.1.3.3	Mecanismo AG	55
3.1.3.4	Mecanismo HS	56
3.2	Técnicas de Busca Propostas para o Problema de Seleção Multiobjetivo de Casos de Teste com Restrições	58
3.3	Considerações Finais	60

4	Experimentos e Resultados	61
4.1	Organização dos Experimentos	61
4.1.1	Objetos de Estudo	61
4.1.2	Questões de Estudo e Preparação dos Experimentos	63
4.1.3	Métricas	65
4.1.4	Configurações de Execução dos Experimentos e das Técnicas	66
4.2	Resultados para Cada Subgrupo	68
4.2.1	Subgrupo 1 - BMOPSO-CDR	68
4.2.2	Subgrupo 2 - BSMPPO	70
4.2.3	Subgrupo 3 - NSGA-II	72
4.2.4	Subgrupo 4 - SPEA2	73
4.2.5	Subgrupo 5 - TAEA	74
4.2.6	Considerações Finais dos subgrupos	75
4.3	Resultados das Melhores Técnicas	76
4.3.1	Comparação das Fronteiras de Pareto	76
4.3.2	Comparação da Capacidade de Detecção de Falhas	77
4.3.3	Considerações Finais das Melhores Técnicas	80
4.4	Resultados do Estudo com Restrições	80
4.4.1	Comparação das Fronteiras de Pareto	80
4.4.2	Comparação da Capacidade de Detecção de Falhas	84
4.4.3	Considerações Finais Estudo com Restrições	85
4.5	Considerações Finais	90
5	Conclusão	91
5.1	Principais Contribuições	92
5.2	Trabalhos Futuros	93
	Referências	94
	Apêndice	102
A	Dados Adicionais para Cada Subgrupo	103
B	Dados Adicionais para as Melhores Técnicas	204
C	Dados Adicionais para o Estudo com Restrições	210

1

Introdução

Em mercados competitivos, onde estão inseridas companhias de desenvolvimento de software, a entrega de produtos de má qualidade pode fazer com que essas companhias percam rapidamente seus clientes. De forma a evitar isso, as mesmas devem garantir que a qualidade dos seus produtos esteja de acordo com as expectativas dos seus clientes. Nesse contexto, as atividades de testes de software são realizadas visando garantir a qualidade de um produto de software. Essas atividades consistem em tentar detectar falhas no software através de sua execução (manual ou automática) (JORGENSEN, 2008).

De acordo com Ramler e Wolfmaier (2006), o processo de testes de software é caro e demorado, chegando a consumir cerca de 40% dos custos totais envolvidos no desenvolvimento do software. Em vista disso, métodos e técnicas capazes de agilizar esse processo são necessários para reduzir os custos associados.

A criação de casos de testes, que sejam efetivos, é um dos grandes desafios das estratégias de testes de software atualmente utilizadas na indústria. O que se deseja é que os recursos disponíveis sejam utilizados de forma otimizada, comprometendo o mínimo possível o orçamento destinado à produção daquele produto de software (BORBA et al., 2010).

1.1 Motivação e Relevância

Uma das atividades realizadas durante os testes de software é a criação (geração) dos testes. Geralmente essa atividade depende de especialistas humanos, que ficam responsáveis por criar uma suíte de testes de forma a testar o programa da forma mais completa possível dentro dos limites de recursos disponíveis na empresa. Essa atividade é considerada custosa, tanto por necessitar de um especialista humano, quanto pelo fato de ser feita de forma manual.

Tendo isso em vista, pesquisadores desenvolveram ferramentas (estratégias) para geração automática de casos de teste que são agrupados e formam uma ou mais suítes de testes. Para tal, essas ferramentas se utilizam de alguma forma de especificação do software. Alguns exemplos desses tipos de ferramenta são a TaRGeT (NOGUEIRA et al., 2007), o Autolink (FEIJS et al., 2002) e o LTSBT (CARTAXO et al., 2008).

Ainda que estas ferramentas colaborem com a atividade de geração de testes, elas podem

introduzir um outro problema: a elevada quantidade de casos de teste que formam a suíte gerada. Essas ferramentas procuram criar tantos casos de teste quantos sejam necessários para cobrir, como um todo, a especificação utilizada como entrada. Isso acaba resultando, geralmente, em suítes de teste grandes. Contudo, não são apenas as suítes geradas automaticamente, através de ferramentas, que podem apresentar uma quantidade elevada de casos de teste. Assim como a geração automática, o processo manual também pode produzir suítes grandes.

Independentemente da abordagem utilizada na geração das suítes de teste (manual ou automática), as suítes geradas são, em geral, grandes a fim de cobrir todas as funcionalidades do software em teste. Por conseguinte, o processo de execução desses testes de software acaba por se tornar uma atividade cara (custosa), uma vez que a execução de uma suíte de testes completa pode consumir muitos recursos (tempo, pessoas, etc.).

A criação de testes cuja execução possa ser feita de forma automática, ajuda a reduzir os custos associados ao processo de execução das suítes de teste. Mas em geral, as duas formas de execução (manual e automática) são combinadas, pois nem sempre é possível criar casos de teste com execução automática por restrições tecnológicas ou porque se necessita de um feedback do usuário. Mesmo num cenário onde é possível a execução automática de todos os testes de uma suíte, o custo de execução pode ser alto. Portanto, é necessária alguma forma de selecionar uma determinada quantidade de casos de teste (um subconjunto dos testes disponíveis) objetivando adequar a execução dos testes aos recursos disponíveis (tempo, pessoas, dispositivos, etc.) para execução dos mesmos. À essa atividade damos o nome de Seleção de Casos de Teste.

A seleção de um subconjunto apropriado de casos de teste de uma suíte não é uma tarefa trivial. Tradicionalmente essa seleção pode ser baseada numa variedade de critérios (muitas vezes heurísticos). Alguns critérios utilizados incluem partição em classes de equivalência, cobertura de pedaços do código fonte (blocos, ramificações, decisões, caminhos) (FEIJS et al., 2002), cobertura de especificações formais de requisitos (funcionais ou não-funcionais) (HAROLD; GUPTA; SOFFA, 1993), similaridade de caminhos (CARTAXO; MACHADO; NETO, 2009), relações de definição e uso (def-use) no código (HAROLD; GUPTA; SOFFA, 1993), dentre outros.

De acordo com Lin e Huang (2009), esse problema não é trivial pois o mesmo é equivalente ao problema NP-Completo de cobertura de conjuntos (GAREY; JOHNSON, 1979). Devido a isso, é impraticável (computacionalmente) encontrar as soluções perfeitas para esse problema. Nesse contexto, o problema de seleção de casos de teste pode ser definido em termos de um processo de busca no qual se pretende encontrar um subconjunto de casos de teste, que atenda a um determinado critério, dentro de um grande número de possibilidades (espaço de busca).

A utilização de técnicas de busca para resolução de problemas relacionados à engenharia de software é uma área de pesquisa (HARMAN; JONES, 2001) conhecida como Engenharia de Software Baseada em Busca (em inglês *Search Based Software Engineering*). A utilização de técnicas de busca aplicadas aos testes de software é considerada como uma subárea desta. Normalmente, os trabalhos que utilizam técnicas de busca na resolução de problemas relacio-

nados aos testes de software se concentram na utilização de apenas um critério (objetivo) por vez (MANSOUR; EL-FAKIH, 1999; MA; SHENG; YE, 2005; WALCOTT et al., 2006; LI; HIERONS; HARMAN, 2007; KAUR; BHATT, 2011).

Contudo, muitas vezes o atendimento de apenas um critério (objetivo) não é suficiente. Em muitos ambientes de testes, por exemplo em um contexto de seleção de casos de teste, pode ser que se deseje utilizar vários critérios simultaneamente, pois nem sempre há consenso sobre um critério ideal. Dessa forma, quando se considera o atendimento de mais de um critério, o problema é considerado como busca multicritério (ou multiobjetivo) (HARMAN, 2011).

Existem duas formas clássicas de se trabalhar nesse sentido: (1) combinar os vários objetivos em um só, ou (2) otimizar os objetivos separadamente. Na primeira forma utilizam-se técnicas de busca de maneira clássica (com apenas uma função objetivo). O que muda é a forma como essa função objetivo é formulada. Nessa abordagem os objetivos são combinados em uma única função através de utilização de pesos ou heurísticas para definir a importância de cada objetivo para o problema como um todo. A desvantagem evidente dessa abordagem é a necessidade de um especialista com conhecimento sobre o ambiente para definir pesos ou heurísticas que realmente reflitam o contexto onde as técnicas serão utilizadas. Exemplos dessas técnicas podem ser encontrados em Black, Melachrinoudis e Kaeli (2004), Mirarab, Esfahani e Tahvildari (2012), Wang, Ali e Gotlieb (2013).

A segunda abordagem, que é a utilizada no presente trabalho, utiliza técnicas um pouco mais complexas que irão procurar várias soluções ótimas para o problema combinando todos os objetivos. Tradicionalmente essas técnicas retornam um conjunto de soluções ótimas para o usuário e o mesmo poderá escolher aquela que melhor se adeque ao seu contexto. Nessa linha podemos citar os trabalhos relacionados de Yoo e Harman (2007), Maia et al. (2009), Yoo e Harman (2010b), Yoo, Nilsson e Harman (2011), Yoo, Harman e Ur (2011), Lucia et al. (2012), Kumari, Srinivas e Gupta (2012), Bozkurt (2013).

Dentre as técnicas de busca utilizadas nesses trabalhos verificamos que a grande maioria das técnicas é baseada no bem difundido Algoritmo Genético. Porém, de acordo com Windisch, Wappler e Wegener (2007), os algoritmos genéticos têm sido constantemente comparados com outras técnicas de busca como, por exemplo, o algoritmo de Otimização por Enxames de Partículas (sigla PSO, em inglês). De fato, vários trabalhos mostraram que PSO é aplicável e até mesmo igualmente apto ou mesmo melhor que os algoritmos genéticos na resolução de diversos problemas em outros contextos (EBERHART; SHI, 1998; HODGSON, 2002; CLOW; WHITE, 2004; WEI; QIQIANG, 2004; HASSAN et al., 2005; REYES-SIERRA; COELLO, 2006; JONES, 2005) e no contexto de testes de software Windisch, Wappler e Wegener (2007), Lefticaru e Ipate (2008), Carvalho et al. (2008), Sun e Wang (2010), Ahmed e Zamli (2011).

Não foi possível encontrar na literatura nenhum outro trabalho utilizando o PSO no problema de seleção multiobjetivo de casos de teste além dos trabalhos derivados da presente tese.

Outra característica importante concernente ao problema de seleção de casos de teste

é a possível existência de restrições no ambiente de testes. Essas restrições podem influenciar o processo de busca no que tange ao fato de tornar várias soluções inviáveis para o problema. Exemplos de restrições podem ser: o custo (tempo) disponível para executar uma suíte, o tamanho máximo desejado de uma suíte, a cobertura mínima de requisitos, etc (HARMAN, 2011; MIRARAB; ESFAHANI; TAHVILDARI, 2012). A presença de restrições no ambiente de teste tem sido negligenciada pelos trabalhos de seleção multiobjetivo de casos de teste. De fato, apenas o trabalho de Maia et al. (2009) formula o problema de seleção de caso de testes incorporando restrições do ambiente de testes. Embora esse trabalho considere as restrições do ambiente, nenhum estudo sobre o impacto dessas restrições ou proposição de novas técnicas multiobjetivo com tratamento de restrições foi feito.

Tendo isso em vista, uma das contribuições deste trabalho é a proposição de novas técnicas de busca com mecanismos de tratamento de restrições. Além disso, essas técnicas são comparadas com uma das técnicas que não possui mecanismo de tratamento de restrições de forma a avaliar qual o impacto disso nas soluções.

Outro aspecto negligenciado pelos trabalhos relacionados na área de seleção multiobjetivo de casos de teste é a capacidade de detecção de falhas das técnicas utilizadas. Essa capacidade de detecção de falhas diz respeito a quantidade de falhas que os testes são capazes de encontrar quando executados. Apenas o trabalho de Yoo, Nilsson e Harman (2011) aborda a capacidade de detecção de falhas da técnica utilizada. Entretanto, eles não comparam essa técnica com nenhuma outra.

Os trabalhos relacionados que não abordam a capacidade de detecção de falhas têm apenas se concentrado na comparação da qualidade das soluções retornadas pelas técnicas utilizadas sob o ponto de vista de otimização. Isto é, verificar qual técnica consegue retornar soluções melhores (melhores fronteiras de Pareto¹) para o problema.

1.2 Objetivos

A seguir é apresentada uma síntese dos objetivos considerados no presente trabalho.

1.2.1 Objetivo Geral

Propor novas técnicas de busca para resolução do problema de seleção multiobjetivo de casos de teste.

1.2.2 Objetivos Específicos

- Propor novas técnicas de busca para a resolução do problema de seleção multiobjetivo de casos de teste em ambientes com restrições;

¹ Os conceitos relativos à otimização multiobjetivo e fronteiras de Pareto serão apresentados no próximo capítulo.

- Avaliar o desempenho das técnicas propostas na resolução do problema de seleção multiobjetivo de casos de teste;
- Comparar essas técnicas sob o ponto de vista de otimização e capacidade de detecção de falhas;
- Avaliar o impacto da utilização de mecanismos de tratamento de restrições na qualidade das soluções.

1.3 Estrutura da Tese

Os próximos capítulos estão organizados da seguinte forma: o Capítulo 2 introduz os conceitos relativos a testes de software, detalha o problema de seleção de casos de teste utilizando técnicas de busca, assim como descreve as técnicas multiobjetivo utilizadas no como base; o Capítulo 3 descreve as técnicas propostas neste trabalho; o Capítulo 4 apresenta os experimentos realizados e a discussão dos resultados e o Capítulo 5 discute as conclusões e trabalhos futuros.

2

Conceitos Fundamentais

O objetivo deste capítulo é apresentar os conceitos e algumas formalizações matemáticas que se relacionam ao problema de Seleção Multiobjetivo de Casos de Teste (foco deste trabalho), assim como descrever as técnicas multiobjetivo utilizadas como base para as técnicas propostas (apresentadas no próximo capítulo). Inicialmente são introduzidos os conceitos sobre testes de software. Após isso, os conceitos específicos a Minimização, Seleção e Priorização são mostrados. Em sequência, é abordada a resolução do problema de Seleção através de utilização de técnicas de busca. Dando continuidade, são apresentados os conceitos de Seleção Multiobjetivo e Seleção Multiobjetivo com restrições. Por fim, são descritas as técnicas de busca Multiobjetivo utilizadas como base das técnicas propostas nesse trabalho.

2.1 Testes de Software

De acordo com Myers e Sandler (2004), teste de software é um processo, ou uma série de processos, utilizados para verificar se os programas de computadores (softwares) fazem aquilo que foram designados fazer.

Durante todo o ciclo de desenvolvimento de um software existem diversas atividades relacionadas aos testes de software. De forma a ilustrar como as atividades de teste se relacionam ao ciclo de desenvolvimento, o conhecido Modelo V (DESIKAN; RAMESH, 2007) é apresentado na Figura 2.1.

O modelo V considera que o ciclo de desenvolvimento de um software é formado por várias fases. O lado esquerdo mostra as fases típicas de desenvolvimento de um software e o lado direito apresenta as fases de testes. É possível observar que cada fase de testes está correlacionada à uma fase de desenvolvimento. Essas fases de testes são responsáveis por verificar e/ou validar, através da execução do software, se as especificações criadas durante as fases de desenvolvimento foram devidamente atendidas.

Por exemplo, a fase de Requisitos de Negócio é responsável por especificar os requisitos de negócio do cliente e sua fase de testes correspondente (Testes de Aceitação) objetiva verificar se o software realmente atendeu essas especificações. A mesma lógica pode ser aplicada às




Figura 2.1: Modelo V

demais fases¹. É importante ressaltar que, dependendo do processo de desenvolvimento adotado, cada fase de testes pode ser repetida quantas vezes sejam necessárias até que o programa esteja pronto para seguir para a próxima fase de testes.

Na literatura é possível encontrar a existência de outros processos e/ou metodologias de desenvolvimento de software, porém não é o escopo deste trabalho dar maiores detalhes sobre os mesmos. O objetivo aqui é apenas introduzir alguns conceitos relativos aos testes de software que servirão como base para o bom entendimento deste trabalho.

Além das fases de teste já mencionadas, existem alguns tipos de teste que não estão diretamente relacionados a uma fase de teste específica. Podemos citar, por exemplo, os Testes de Regressão, os Testes de Mutação e os Testes de Performance (DESIKAN; RAMESH, 2007; MYERS; SANDLER, 2004).

Os Testes de Regressão são aplicados sempre que uma nova versão (com modificações) do programa P , chamada de P' , é criada. Seu objetivo é testar se as partes modificadas do programa funcionam como esperado e se as partes não modificadas não foram afetadas por essas modificações. Geralmente os Testes de Regressão são realizados sempre que houver correções de defeitos e/ou introdução de novas funcionalidades no programa.

Já os Testes de Mutação têm por objetivo avaliar a qualidade de uma suíte de testes através da inserção de pequenas modificações (chamadas de mutações) no código fonte. Após isso, os testes são executados de forma a verificar se os mesmos foram capazes de detectar a modificação introduzida. Caso os testes não identifiquem que ocorreu a mutação, ou seja, não

¹ Para mais detalhes acerca de cada fase consultar Desikan e Ramesh (2007)

identifiquem que o comportamento esperado da execução do código foi modificado, isso significa que os testes estão negligenciando algum aspecto que deveria ser testado. Os Testes de Mutação são realizados sempre que se deseja verificar a qualidade de detecção de falhas de uma suíte.

Os Testes de Performance, por sua vez, são focados em determinar como o programa se comporta em termos de performance (tempo de resposta, estabilidade, disponibilidade, etc) sob cenários específicos. Esses cenários, geralmente, tentam sobrecarregar o software ou simular situações onde a performance é crucial para o usuário. Os Testes de Performance costumam ser realizados durante as fases de Testes de Sistema e Testes de Aceitação.

Além dessa divisão dos testes em fases, os testes de software podem ser divididos de acordo com a abordagem utilizada: Testes Estruturais (caixa branca) ou Testes Funcionais (caixa preta). De acordo com Desikan e Ramesh (2007), os testes estruturais testam as funcionalidades de um software através de acesso direto ao código do programa que o realiza. Para tal, conhecimento sobre o código (estruturas, fluxo de dados, etc) são utilizados. De forma contrária, os testes funcionais envolvem a utilização apenas das especificações do software (conjunto de entradas e resultados esperados) para testar o programa. Portanto, não dependem de nenhum conhecimento acerca do código do programa, apenas conhecimento sobre suas funcionalidades.

Na literatura também é possível encontrar uma divisão das atividades de testes em: planejamento dos testes e execução dos testes. As atividades de planejamento dos testes ocorrem antes que o código do programa esteja pronto para execução dos testes. Elas são realizadas em conjunto com as atividades das fases de desenvolvimento do software e consistem em planejar/criar/modificar os testes que serão depois executados de forma a validar e/ou verificar os artefatos de software criados durante as fases de desenvolvimento. Por exemplo, as atividades de Planejamento dos Testes de Integração são realizadas durante a fase de desenvolvimento de alto-nível. A Figura 2.2 mostra um modelo V mais detalhado que divide as atividades em planejamento e execução dos testes.

As atividades de execução dos testes, por sua vez, consistem na execução dos casos de teste num dado programa P com entradas selecionadas a partir do espaço de entradas possíveis, de forma a detectar falhas nesse programa. Esses casos de teste representam cenários de utilização do software e são formados por: um conjunto de entradas/ações para testar o programa, pré-condições de execução e condições de passar/falhar (resultados esperados).

Os casos de teste são criados e/ou modificados durante as atividades de planejamento dos testes. Cada de teste é criado objetivando cobrir algum critério de adequação. Um critério de adequação consiste em uma propriedade, definida pelo ambiente de testes, que deve ser atendida pela suíte para que ela seja considerada adequada a testar o programa. Exemplos de critérios de adequação são: cobertura de código, cobertura de casos de uso, cobertura de transições numa máquina de estado, etc.

A criação e/ou modificação de casos de teste não é uma tarefa trivial, além de ser custosa (em termos de tempo e pessoas). Procurando reduzir os custos de criação/modificação dos testes pesquisadores desenvolveram técnicas para agilizar esse processo (como pode ser visto em Ali et




Figura 2.2: Modelo V mais detalhado

al. (2010).

No caso das atividades de execução, os custos são associados a quantidade de recursos (pessoas, dispositivos, tempo, etc) necessários para execução dos testes provenientes das fases de planejamento. Uma situação comum, por exemplo, caso a quantidade de testes seja grande é que não haja recursos suficientes para execução de todos os testes. Devido a isso, uma maneira de otimizar o processo de execução dos casos de teste deve ser buscada.

As próximas seções abordam formas de tentar reduzir o custo do processo de execução dos testes.

2.1.1 Minimização, Seleção e Priorização

Objetivando reduzir os custos associados ao processo de execução de testes como um todo, pesquisadores têm se focado em três maiores áreas de pesquisa: minimização de casos de teste (também conhecida como redução de casos de testes), seleção de casos de teste e priorização de casos de teste.

A minimização procura identificar e então eliminar casos de teste obsoletos e/ou redundantes dentro de uma suíte. Já a seleção foca no problema de selecionar um subconjunto de casos de teste com o propósito de satisfazer um determinado critério de seleção. Por fim, a priorização busca encontrar uma ordenação ideal para os casos de teste de forma a maximizar uma propriedade desejada como, por exemplo, antecipação de detecção de falhas.

Uma definição formal de minimização e seleção, adaptadas de Harman (2011), é dada a seguir²:

²Está fora do escopo deste trabalho dar maiores detalhes acerca do problema de priorização de casos de teste.

Definição 2.1. Minimização/Seleção de Casos de Teste: Seja T uma suíte de testes e R um objetivo de teste. T' é uma minimização/seleção de T , com respeito a R , se e somente se T' é um subconjunto de T que maximiza $R(T)$.

Em geral, R é definido como um conjunto de requisitos (critérios) de adequação $\{r_1, \dots, r_n\}$ a serem cobertos pela suíte de teste de tal forma que $R(T)$ representa o número de elementos em $\{r_1, \dots, r_n\}$ cobertos por T . As técnicas de minimização/seleção tentam encontrar o T' mínimo, o que significa que nenhuma outra suíte de testes minimizada deve ser menor que T' .

Na minimização (redução) T' deve cobrir todos os elementos $\{r_1, \dots, r_n\}$. Dessa forma, T' é o menor subconjunto que cobre R integralmente. Por exemplo, seja o critério de adequação cobrir todas as transições de um conjunto de máquinas de estado que especificam o comportamento do programa que irá ser testado. Então, a suíte T' minimizada representaria o menor subconjunto de casos de teste que cobrisse todas as transições das máquinas de estado.

A seleção de casos de teste é muito similar à minimização. De acordo com Harman (2011), a minimização se refere à remoção permanente dos testes redundantes e/ou obsoletos sob a perspectiva da cobertura dos requisitos de adequação. Na minimização, a suíte minimizada T' tem a mesma cobertura dos critérios de adequação que T . Já a seleção, por sua vez, também busca encontrar um subconjunto de casos de teste que cubram os critérios de adequação, mas sem que haja uma remoção permanente dos casos de teste (apenas uma seleção temporária). Além disso, na seleção a cobertura dos critérios de adequação de T' pode não ser a mesma de T .

Ambos problemas (minimização e seleção) são considerados como NP-Completo por serem equivalentes ao conhecido problema de cobertura de conjuntos. Ademais, essa diferenciação entre minimização e seleção é adotada apenas por alguns autores por ser bastante conceitual. É comum encontrar na literatura os termos minimização e seleção usados como sinônimos.

É importante salientar que a maioria dos estudos sobre técnicas de seleção de casos de teste estão relacionadas a área de Testes de Regressão. Seleção de Teste de Regressão (sigla RTS em inglês), se refere às técnicas de seleção que são focadas em identificar quais partes de um programa foram modificadas e selecionar quais testes são relevantes para testar essas modificações. As técnicas RTS se diferem umas das outras de acordo com a forma como elas definem, procuram e identificam essas modificações feitas nos programas.

O conceito de seleção de casos de teste adotado nesse trabalho se refere à seleção de testes que maximizem a cobertura de algum critério de adequação. Esse conceito se difere um pouco do RTS por ser mais geral. As técnicas RTS somente estão focadas em identificar e selecionar todos os casos de teste que sejam relevantes para testar as modificações feitas num determinado programa. Quer dizer, o critério de adequação de uma técnica RTS sempre é cobrir todas as modificações feitas no programa.

Na literatura relacionada é possível observar que as abordagens para o problema de minimização estão concentradas em criar diferentes heurísticas para resolução do problema NP-Completo de cobertura de conjuntos (HAROLD; GUPTA; SOFFA, 1993; OFFUTT; PAN; VOAS, 1995; CHEN; LAU, 1998; MARRE; BERTOLINO, 2003; TALLAM; GUPTA, 2006).

Enquanto com relação às abordagens de seleção, elas se diferem umas das outras pelo uso de diferentes requisitos de adequação que devem ser cobertos.

Podemos citar algumas abordagens de seleção (incluindo RTS) que têm sido estudadas: análise de fluxo de dados (HARROLD; SOFFA, 1988; HARROLD; SOFFA, 1989; GUPTA; HARROLD; SOFFA, 1992), execução simbólica (YAU; KISHIMOTO, 1987), particionamento dinâmico (AGRAWAL et al., 1993), grafo de fluxo de controle (ROTHERMEL, 1996; ROTHERMEL; HARROLD, 1997), diferenças textuais no código-fonte (VOKOLOS; FRANKL, 1997; VOKOLOS; FRANKL, 1998), firewall (LEUNG; WHITE, 1990; WHITE; LEUNG, 1992), testes baseados em modelo (BRIAND; LABICHE; SOCCAR, 2002), similaridade (CARTAXO; MACHADO; NETO, 2009; HEMMATI et al., 2010; HEMMATI; ARCURI; BRIAND, 2013; ROGSTAD; BRIAND; TORKAR, 2013).

O principal problema dessas abordagens é que as mesmas são determinísticas e, caso estejam trabalhando com um suíte de testes muito grande, o custo computacional pode ser impraticável.

Procurando resolver esse problema alguns estudos recentes têm focado no uso de técnicas de busca e otimização para seleção de casos de teste (assim como para minimização e priorização). Dentre elas destacamos o uso de Têmpura Simulada (MANSOUR; EL-FAKIH, 1999), Algoritmos Genéticos (MANSOUR; EL-FAKIH, 1999; MA; SHENG; YE, 2005; WALCOTT et al., 2006; LI; HIERONS; HARMAN, 2007) e Otimização por Enxame de Partículas (KAUR; BHATT, 2011).

A maioria dos trabalhos de seleção de casos de teste costuma trabalhar com apenas um critério de seleção (adequação) por vez, pois torna mais simples o processo de busca. Entretanto, de acordo com Yoo e Harman (2010b), as atividades de testes podem se beneficiar ao considerarem múltiplos critérios de adequação, pois não há um único critério que seja sempre ideal. Devido a isso, um problema das técnicas determinísticas e também das técnicas baseadas em busca citadas anteriormente é a utilização de apenas um único critério de adequação (objetivo) por vez.

Poucos estudos têm utilizado múltiplos critérios para seleção. As primeiras abordagens nesse sentido combinavam os múltiplos critérios em um único critério. Para tal, eram usados pesos ou alguma outra heurística para combinar os critérios (BLACK; MELACHRINOUDIS; KAEI, 2004; MIRARAB; ESFAHANI; TAHVILDARI, 2012; WANG; ALI; GOTLIEB, 2013). O problema com essas abordagens é não fornecer uma variedade de soluções para o testador escolher aquela que mais se adeque aos seus recursos disponíveis, pois as mesmas retornam apenas uma solução final. Além disso, essas técnicas necessitam de um especialista ou conhecimento prévio do ambiente de testes para dar valores corretos aos pesos e/ou criar heurísticas específicas para combinar os critérios.

Levando isso em consideração, alguns estudos novos têm considerado o uso de múltiplos critérios através do mapeamento de cada critério em um objetivo específico no processo de busca. Esses estudos utilizam os conceitos de otimização de Pareto e retornam, ao final do processo,

um conjunto de soluções ótimas ao testador (YOO; HARMAN, 2007; MAIA et al., 2009; YOO; HARMAN, 2010b; YOO; NILSSON; HARMAN, 2011; YOO; HARMAN; UR, 2011; LUCIA et al., 2012; KUMARI; SRINIVAS; GUPTA, 2012; BOZKURT, 2013). Esse conjunto de soluções ótimas permite ao testador (usuário final) verificar as relações entre os objetivos e escolher a solução que mais se adeque aos seus recursos disponíveis para execução dos testes.

De acordo com Harman (2011), o primeiro estudo nessa área de seleção/minimização multiobjetivo de casos de teste foi o trabalho de Yoo e Harman (2007). Por isso, essa é uma área de pesquisa considerada recente e existem ainda poucos trabalhos que abordam o tratamento do problema de seleção de casos de teste dessa forma. É importante salientar que, de acordo com Harman (2011), não há diferença entre seleção e minimização do ponto de vista de busca/otimização.

A próxima seção dará mais detalhes sobre o problema de Seleção Multiobjetivo através da utilização de técnicas de busca.

2.1.2 Seleção de Casos de Teste Utilizando Técnicas de Busca

Uma forma promissora de tratar o problema de seleção de casos de teste é através da utilização de técnicas de busca (HARMAN, 2011). Essas técnicas exploram o espaço de soluções possíveis (subconjuntos de testes), buscando pela solução (ou soluções no caso de técnicas multiobjetivo) que melhor atenda ao critério (ou critérios) de adequação.

Devido ao fato desse problema ser considerado como NP-Completo, não é indicada a utilização de técnicas de busca exaustiva (força bruta). Também não é recomendado utilizar busca aleatória, pois a mesma dificilmente encontraria um subconjunto representativo caso o problema tenha um grande espaço de busca. Levando isso em consideração, técnicas de busca mais sofisticadas devem ser consideradas para tratar o problema de seleção de casos de teste.

Técnicas de busca demandam a utilização de uma ou mais funções de aptidão que irão determinar a qualidade de cada solução possível (nesse caso um subconjunto de casos de teste). Cada função de aptidão corresponde a um objetivo (critério de adequação) de teste diferente.

Independente da técnica a ser utilizada no processo de seleção, é necessário formular o problema considerando o critério de adequação escolhido. Esse critério está relacionado à abordagem de testes a ser utilizada (funcional ou estrutural).

Para os testes estruturais o critério de adequação mais comum é a cobertura de código que representa o montante de pedaços de código-fonte do software (blocos, ramificações, linhas, decisões, etc) que serão executados pelos testes selecionados (HAROLD; GUPTA; SOFFA, 1993). Já os teste funcionais normalmente adotam como critério de adequação a cobertura de especificações formais (requisitos em forma textual, máquinas de estado, casos de uso, etc) dos casos de teste (BORBA et al., 2010).

2.1.2.1 Seleção Multiobjetivo de Casos de Teste

Muitos ambientes de teste apresentam múltiplos critérios de adequação que devem ser considerados durante a seleção. Para tal, é possível a utilização de técnicas de busca multiobjetivo. Essa abordagem multiobjetiva para o problema de seleção (aqui referenciada como Seleção Multiobjetivo de casos de teste) é considerada uma área de pesquisa recente. De acordo com Harman (2011), o trabalho de Yoo e Harman (2007) é considerado como o primeiro trabalho dessa área.

Além do trabalho citado anteriormente, existem poucos trabalhos que abordam a utilização de técnicas de busca para seleção multiobjetivo de casos de teste. É possível citar, apenas, os trabalhos de Yoo e Harman (2007), Maia et al. (2009) Yoo e Harman (2010b), Yoo, Nilsson e Harman (2011), Yoo, Harman e Ur (2011), Lucia et al. (2012), Kumari, Srinivas e Gupta (2012) e Bozkurt (2013), que serão discutidos na seção 2.3.

A vantagem da utilização de técnicas de busca para Seleção Multiobjetivo de casos de teste é que as mesmas permitem a otimização de vários objetivos simultaneamente, independentemente dos objetivos serem complementares ou contrastantes. Para tal, são criadas funções mapeando cada objetivo (critério de adequação). Além disso, outra vantagem de utilizar essas técnicas é que elas retornam um conjunto de soluções ótimas que permitem ao testador ver como os objetivos se relacionam e possibilitam a escolha da solução que melhor se adeque aos recursos disponíveis no ambiente de testes.

Dentro do paradigma multiobjetivo não é trivial definir o que é uma solução ótima. O problema é a presença de objetivos conflitantes onde, uma melhora em um objetivo pode acarretar uma piora nos outros. O importante nesses casos é tentar encontrar soluções que balanceiem os conflitos entre os objetivos. Essas soluções somente existem quando não é possível para uma solução melhorar em um objetivo sem que haja uma regressão nos outros objetivos. Esse tipo de solução é referida como solução não dominada. Geralmente, para um problema multiobjetivo existem várias soluções não dominadas.

Formalmente, uma solução $\mathbf{t} = (t_1, t_2, \dots, t_{n_t}) \in S$ é chamada de vetor decisão, onde $S \subseteq \mathbb{R}^{n_t}$ é o espaço de busca (ou espaço de decisão) n_t -dimensional. Já as avaliações da função $f_k(\mathbf{t})$ formam o vetor objetivo $\mathbf{f}(\mathbf{t}) = (f_1(\mathbf{t}), f_2(\mathbf{t}), \dots, f_{n_k}(\mathbf{t})) \in O \subseteq \mathbb{R}^{n_k}$, onde O representa o espaço objetivo.

O conjunto de vetores decisão (soluções) não dominados é chamado de Conjunto Pareto Ótimo, já os vetores objetivos correspondentes formam a Fronteira Pareto Ótima. A seguir são dadas definições formais a respeito de Dominância, Pareto Ótimo, conjunto Pareto Ótimo e Fronteira Pareto Ótima:

Definição 2.2. Dominância: Um vetor decisão $\mathbf{t}_1$ domina um vetor decisão $\mathbf{t}_2$ (denotado por $\mathbf{t}_1 \preceq \mathbf{t}_2$), se e somente se

- $\mathbf{t}_1$ não é pior que $\mathbf{t}_2$ em todos os objetivos, i.e. $f_k(\mathbf{t}_1) \leq f_k(\mathbf{t}_2), \forall k = 1, \dots, n_k$, e

- $\mathbf{t}_1$ é estritamente melhor que $\mathbf{t}_2$ em pelo menos um objetivo, i.e. $\exists k = 1, \dots, n_k : f_k(\mathbf{t}_1) < f_k(\mathbf{t}_2)$.

Se alguma dessas condições não é alcançada, $\mathbf{t}_1$ não domina $\mathbf{t}_2$. O mesmo pode ser dito sobre os vetores objetivo correspondentes, isto é, um vetor objetivo $\mathbf{f}_1$ domina um vetor objetivo $\mathbf{f}_2$, se $\mathbf{f}_1$ não é pior que $\mathbf{f}_2$ em todos os valores dos objetivos e $\mathbf{f}_1$ é melhor que $\mathbf{f}_2$ em pelo menos um valor de objetivo (denotado por $\mathbf{f}_1 \preceq \mathbf{f}_2$).

A Figura 2.3 ilustra o conceito de dominância para um problema com duas funções objetivo que se deseja minimizar (do ponto de vista de otimização), ou seja, onde $\mathbf{f}(\mathbf{t}) = (f_1(\mathbf{t}), f_2(\mathbf{t}))$. A área cinza representa a área dominada por $\mathbf{f}$, onde a presença de qualquer outro vetor objetivo $\mathbf{f}'$ implica que o mesmo é dominado por $\mathbf{f}$ ($\mathbf{f} \preceq \mathbf{f}'$).




Figura 2.3: Dominância

A Figura 2.4 também ilustra o conceito de dominância a partir de seis vetores objetivo. Através da Definição 2.2 é possível ver quais soluções dominam as outras. Por exemplo, comparando-se os vetores **4** e **5** observamos que **5** é melhor que **4** para a função objetivo f_1 ($f_1(\mathbf{5}) < f_1(\mathbf{4})$) e também é melhor para a função objetivo f_2 ($f_2(\mathbf{5}) < f_2(\mathbf{4})$). Como todas as condições da Definição 2.2 foram satisfeitas, então o vetor **5** domina o vetor **4** ($\mathbf{5} \preceq \mathbf{4}$). Continuando com outro exemplo, se compararmos os vetores **1** e **3** é possível verificar que o vetor **1** é melhor que o vetor **3** para a função objetivo f_1 ($f_1(\mathbf{1}) < f_1(\mathbf{3})$), mas é pior para a função objetivo f_2 ($f_2(\mathbf{1}) \not\leq f_2(\mathbf{3})$). Portanto **1** não domina **3**, nem **3** domina **1**.




Figura 2.4: Exemplo de seis vetores no espaço dos objetivos

É importante salientar que alguns autores dividem o conceito de dominância em dominância fraca e dominância forte. A Definição 2.2, apresentada anteriormente, representa o caso de dominância fraca.

Definição 2.3. Dominância Forte: Um vetor decisão $\mathbf{t}_1$ domina fortemente um vetor decisão $\mathbf{t}_2$ (denotado por $\mathbf{t}_1 \prec \mathbf{t}_2$), se e somente se

- $\mathbf{t}_1$ é estritamente melhor que $\mathbf{t}_2$ em todos os objetivos, i.e. $f_k(\mathbf{t}_1) \leq f_k(\mathbf{t}_2), \forall k = 1, \dots, n_k$.

Nesse trabalho é utilizado o conceito de dominância fraca, pois foi considerado que o fato de $\mathbf{t}_1 \preceq \mathbf{t}_2$ representa uma melhora de $\mathbf{t}_1$ sobre $\mathbf{t}_2$. Devido a isso, todas as referências à dominância no restante desse trabalho utilizam o conceito de dominância fraca (Definição 2.2).

Definição 2.4. Pareto Ótimo: Um vetor decisão $\mathbf{t}^* \in S$ é Pareto Ótimo se não existe um vetor decisão, $\mathbf{t} \neq \mathbf{t}^* \in S$, que o domine. Isto é $\nexists k : f_k(\mathbf{t}) < f_k(\mathbf{t}^*)$. Por sua vez, um vetor objetivo $\mathbf{f}^*(\mathbf{t})$ é Pareto Ótimo se $\mathbf{t}$ é Pareto Ótimo.

Definição 2.5. Conjunto Pareto Ótimo: O conjunto de todos os vetores decisão que são Pareto Ótimos formam o Conjunto Pareto Ótimo P^* . Isto é,

$$P^* = \{\mathbf{t}^* \in S | \nexists \mathbf{t} \in S : \mathbf{t} \preceq \mathbf{t}^*\} \quad (2.1)$$

O Conjunto Pareto Ótimo, P^* , contém soluções balanceadas para o problema multiobjetivo. Além disso, os vetores objetivo correspondentes ao Conjunto Pareto Ótimo formam a Fronteira Pareto Ótima.

Definição 2.6. Fronteira Pareto Ótima: Dado o vetor objetivo $\mathbf{f}(\mathbf{t})$ e o Conjunto Pareto Ótimo P^* , a Fronteira Pareto Ótima, $PF^* \subseteq O$, é definida como:

$$PF^* = \{\mathbf{f} = (f_1(\mathbf{t}^*), f_2(\mathbf{t}^*), \dots, f_k(\mathbf{t}^*)) | \mathbf{t}^* \in P\} \quad (2.2)$$

A Fronteira Pareto Ótima contém todos os vetores objetivos que não são dominados por nenhum outro vetor objetivo (como pode ser visto na figura 2.5). A linha conectando os vetores não dominados foi inserida apenas para dar a ideia da formação da fronteira, não havendo nenhuma conexão real entre esses vetores.




Figura 2.5: Fronteira de Pareto

O objetivo das técnicas de busca multiobjetivo é encontrar fronteiras de Pareto que mais se aproximem da Fronteira de Pareto Ótima. Entretanto muitas vezes encontrar a Fronteira de Pareto Ótima (i. e. todos vetores decisão Pareto Ótimos em S) seja computacionalmente impraticável. Portanto, uma boa técnica multiobjetivo busca encontrar uma aproximação à fronteira de Pareto Ótima de tal forma que:

- a distância para a Fronteira de Pareto Ótima seja minimizada, e
- o conjunto de vetores decisão não dominados (Conjunto Pareto Ótimo) seja o mais diverso possível

A formulação do problema de seleção multiobjetivo de casos de teste, em conformidade com os conceitos relacionados ao paradigma de otimização multiobjetivo apresentados, é dada a seguir:

Definição 2.7. Seleção Multiobjetivo de Casos de Teste: O problema de seleção multiobjetivo de casos de teste consiste em encontrar um subconjunto $T' \subset T$, tal que T' seja o Conjunto Pareto Ótimo, ou uma aproximação deste, com respeito às funções objetivo.

2.1.2.2 Seleção Multiobjetivo com Restrições

Outro aspecto importante relacionado a seleção de casos de teste é a existência de restrições no ambiente de testes. Essas restrições influenciam o processo de seleção, pois restringem o espaço de busca (ou o espaço objetivo) criando regiões onde soluções ali presentes se tornam inviáveis para o problema. Nesses casos o ideal seria a utilização de técnicas de busca que contenham mecanismos de tratamento de restrições.

Dentro das possíveis restrições existentes, nós destacamos o custo (esforço) necessário para executar uma suíte de testes. Por exemplo, é comum que o tempo disponível para execução de uma suíte de testes seja reduzido.

Embora a existência de restrições seja algo muito impactante dentro do processo de seleção de casos de teste, é possível observar que esse aspecto é ainda pouco abordado na literatura de seleção de casos de teste. A maioria dos trabalhos que consideram isso estão concentrados na área de priorização (YOO; HARMAN, 2010a).

Não é o propósito desse trabalho discutir quais critérios de adequação e/ou restrições são mais importantes para o problema de seleção de casos de teste. É sugerida a leitura de Harman (2011) para conhecimento de outros critérios e/ou restrições trabalhadas na literatura relacionada.

A Definição 2.8 (ENGELBRECHT, 2005), a seguir, formaliza o problema de otimização com restrições:

Definição 2.8. Problema de Otimização com Restrições:

$$\begin{aligned}
 &\text{otimize} && f(\mathbf{t}), && \mathbf{t} = (t_1, \dots, t_{n_t}) \\
 &\text{sujeito a} && g_m(\mathbf{t}) \leq 0, && m = 1, \dots, n_g \\
 &&& h_m(\mathbf{t}) = 0, && m = n_g + 1, \dots, n_g + n_h \\
 &&& t_j \in \text{dom}(t_j)
 \end{aligned} \tag{2.3}$$

onde n_t é a dimensão do problema; g_m e h_m são, respectivamente, as restrições de desigualdade e

igualdade; n_g e n_h representam a quantidade dessas restrições; $dom(t_j)$ é o domínio da variável t_j .

A Figura 2.6 ilustra um processo de otimização com restrições. A área abaixo da restrição de desigualdade é considerada inviável, qualquer solução dentro desse espaço não é uma solução válida para o problema. De forma contrária, soluções dentro da área viável são consideradas soluções válidas.




Figura 2.6: Otimização com restrições

Como dito anteriormente, é possível a existência de restrições em ambientes de testes. Essas restrições são independentes da quantidade de critérios (objetivos) considerados durante a seleção.

Dentro da literatura de otimização multiobjetivo com restrições existem diversos mecanismos de tratamento dessas restrições. Um dos mecanismos mais utilizados é o proposto por Deb et al. (2000). Esse mecanismo é bastante similar ao proposto por Coello, Pulido e Lechuga (2004) que será mostrado na seção 3.2. Outra forma de tratamento de restrições é através da utilização de funções de penalidade para reparar as soluções inviáveis. Esse tipo de mecanismo é bastante utilizado na otimização com restrições e apenas um objetivo. Nessa linha, Deb e Kalyanmoy (2001) propõem a utilização de penalidade estática e penalidade dinâmica para

reparar as soluções inviáveis. Já Coello e Christiansen (1999) propuseram a penalidade de morte onde todas as soluções inviáveis, encontradas durante o processo de busca, são eliminadas.

Além da utilização de funções de penalidade, Yen e Leong (2010) propuseram transformar as restrições em objetivos a serem otimizados. Eles transformaram um problema com dois objetivos e uma restrição em um problema com três objetivos e sem restrições. Por fim, alguns trabalhos recentes têm procurado estudar o papel que soluções inviáveis podem ter durante o processo de busca (SINGH; RAY; SARKER, 2013; YU et al., 2014). Esses trabalhos mostraram que técnicas de busca guiadas por soluções inviáveis é uma forma promissora de abordagem para o problema de otimização multiobjetivo com restrições.

Voltando ao contexto de seleção multiobjetivo de casos de teste, só foi possível encontrar o trabalho de Maia et al. (2009). Nesse trabalho o mecanismo de restrições proposto por Deb et al. (2000) é utilizado.

Finalmente, é possível definir formalmente o problema de seleção multiobjetivo com restrições como:

Definição 2.9. Seleção Multiobjetivo de Casos de Teste com Restrições: O problema de seleção multiobjetivo de casos de teste com restrições consiste em encontrar um subconjunto $T' \subset T$, tal que T' seja o Conjunto Pareto Ótimo, ou uma aproximação deste, com respeito às funções objetivo e sujeito à $g_m(\mathbf{t}) \leq 0, m = 1, \dots, n_g$ e $h_m(\mathbf{t}) = 0, m = n_g + 1, \dots, n_g + n_h$.

onde g_m e h_m são, respectivamente, as restrições de desigualdade e igualdade; n_g e n_h representam a quantidade dessas restrições.

2.2 Técnicas de Busca

Como dito anteriormente, o presente trabalho pretende propor novas técnicas de busca para resolução do problema de Seleção Multiobjetivo de Casos de Teste. A presente seção detalha as técnicas que foram utilizadas como base para as técnicas propostas que serão apresentadas no próximo capítulo.

Primeiramente, são apresentadas as técnicas baseadas no Algoritmo de Otimização por Enxame de Partículas - PSO (KENNEDY; EBERHART, 1995). O PSO é um algoritmo populacional que simula o comportamento social de um bando de pássaros. De acordo com Kennedy e Eberhart (1995), a intenção inicial de utilizar o conceito de enxame de partículas era o de simular a graciosidade e a coreografia de um bando de pássaros com o objetivo de descobrir os padrões que governam sua habilidade de voo de maneira síncrona e repentinamente mudarem de direção conseguindo se reagrupar de maneira ótima. A partir dessa observação, criou-se uma técnica de busca e otimização simples e eficiente.

Os indivíduos, no PSO, são chamados de partículas e "voam" através do espaço de busca, sendo que mudanças de posição neste espaço são baseadas na tendência social dos indivíduos imitarem o sucesso dos outros. Essas mudanças, que ocorrem com uma partícula do enxame,

são influenciadas por sua própria experiência e pelo conhecimento obtido em sua vizinhança. Assim, o comportamento de busca de uma partícula também é afetado pelas outras partículas do enxame.

No PSO cada partícula representa uma solução candidata para o problema sendo resolvido e a partícula é composta por quatro atributos principais: (1) sua posição $\mathbf{t}$ no espaço de busca (cada posição representa uma solução), (2) sua velocidade $\mathbf{v}$ que indica em que direção a partícula está se movimentando no espaço de busca, (3) sua melhor posição $\hat{\mathbf{t}}$ encontrada (também chamada de memória da partícula ou guia local) e (4) a melhor posição $\hat{\mathbf{g}}$ encontrada na vizinhança da partícula (também chamada de guia global). Por um determinado número de iterações as partículas mudam sua posição e velocidade buscando alcançar melhores posições de forma a otimizar a função (ou funções) que se deseja otimizar.

De acordo com Engelbrecht (2007), as partículas seguem um comportamento bem simples: emular o sucesso dos indivíduos da vizinhança e seus próprios sucessos. O comportamento coletivo que emerge deste simples comportamento é a descoberta de regiões ótimas em um espaço de busca que pode ser de uma dimensão elevada. A consequência de modelar esse comportamento é que o processo de busca é tal que partículas são estocasticamente atraídas pelas regiões que representam sucesso no espaço de busca.

O presente trabalho propõe a utilização de técnicas baseadas no algoritmo PSO pelo fato do mesmo ter demonstrado sucesso em aplicações em diversos domínios (EBERHART; SHI, 1998; HODGSON, 2002; TAŞGETIREN; LIANG, 2003; CLOW; WHITE, 2004; WEI; QIQIANG, 2004; HASSAN et al., 2005; JONES, 2005; REYES-SIERRA; COELLO, 2006). Além do presente trabalho (e publicações derivadas do mesmo) não foi possível encontrar a utilização de técnicas baseadas no PSO aplicadas ao problema de seleção multiobjetivo de casos de teste. Entretanto, os seguintes trabalhos utilizaram técnicas baseadas no PSO em problemas relacionados aos testes de software: geração de casos de teste (WINDISCH; WAPPLER; WEGENER, 2007; AHMED; ZAMLI, 2011), geração de dados de testes (LEFTICARU; IPATE, 2008), predição de falhas (CARVALHO et al., 2008), minimização de suíte de testes (SUN; WANG, 2010).

Além das técnicas baseadas no PSO, esta seção também detalha as técnicas *Non-dominated Sorting Genetic Algorithm* (NSGA-II) (DEB et al., 2000), *Strength Pareto Evolutionary Algorithm* (SPEA2) (ZITZLER; LAUMANN; THIELE, 2001) e *Two-Archive Evolutionary Algorithm* (TAEA) (PRADITWONG; YAO, 2006) que são utilizadas como base para proposição de novas técnicas híbridas que serão apresentadas no próximo capítulo.

2.2.1 MOPSO-CDR

A técnica *Multi-Objective Particle Swarm Optimization with Crowding Distance and Roulette Wheel* (MOPSO-CDR) (SANTANA; PONTES; BASTOS-FILHO, 2009) é baseada na versão multiobjetivo do PSO proposta inicialmente por Coello, Pulido e Lechuga (2004).

A seguir os passos da técnica são sumarizados e maiores detalhes podem ser obtidos em Santana, Pontes e Bastos-Filho (2009).

É importante ressaltar que todas as equações mostradas durante as descrições das técnicas neste capítulo devem ser realizadas para cada dimensão do problema (cada dimensão das soluções). As notações vetoriais são utilizadas para simplificar e facilitar a leitura das descrições das técnicas.

O MOPSO-CDR utiliza um arquivo externo (EA) para armazenar as soluções não dominadas encontradas pelas partículas durante o processo de busca. O EA pode ser visto como um enxame secundário que interage com o enxame primário durante a definição dos valores de $\hat{\mathbf{g}}$ e $\hat{\mathbf{t}}$.

1. Inicie aleatoriamente a posição $\mathbf{t}$ e velocidade $\mathbf{v}$ de cada partícula;
2. Avalie cada partícula de acordo com as funções objetivo utilizadas;
3. Armazene no EA as soluções consideradas não dominadas;
4. Gere o *crowding distance*³ de cada solução do EA;
5. Inicie a memória $\hat{\mathbf{t}}$ de cada partícula:

$$\hat{\mathbf{t}} = \mathbf{t} \quad (2.4)$$

6. **ENQUANTO** o critério de parada não for atingido **FAÇA**

- (a) Calcule a velocidade $\mathbf{v}$ de cada partícula como:

$$\mathbf{v} = \omega \mathbf{v} + C_1 r_1 (\hat{\mathbf{t}} - \mathbf{t}) + C_2 r_2 (\hat{\mathbf{g}} - \mathbf{t}) \quad (2.5)$$

onde ω representa o peso de inércia (proposto por Shi e Eberhart (1998)), r_1 e r_2 são valores aleatórios no intervalo $[0,1]$ e C_1 e C_2 são constantes que controlam o impacto de $\hat{\mathbf{t}}$ e $\hat{\mathbf{g}}$ no cálculo da velocidade da partícula. O guia global $\hat{\mathbf{g}}$ nessa equação é definido como uma das soluções não dominadas armazenadas no EA. O seguinte procedimento é utilizado para selecionar $\hat{\mathbf{g}}$ para cada partícula:

- i. Selecione uma das soluções do EA através da utilização da Seleção por Roleta⁴. A probabilidade de selecionar uma determinada solução do EA é proporcional ao seu valor de *crowding distance*,

³O cálculo de *crowding distance* utilizado é o mesmo proposto por Deb et al. (2000) e representa a distância média de uma solução para as duas outras soluções vizinhas a ela no espaço objetivo. Esse valor indica o quão populosa é a área onde a soluções se encontra.

⁴O mecanismo de Seleção por Roleta utilizado é o mesmo bastante difundido entre os algoritmos evolutivos.

ou seja, soluções localizadas em áreas com menor quantidade de soluções tem maiores chances de serem selecionadas;

- (b) Limite o valor da velocidade $\mathbf{v}$ como:

$$\mathbf{v} = \begin{cases} v_{MAX}, & \text{se } \mathbf{v} > v_{MAX} \\ v_{MIN}, & \text{se } \mathbf{v} < v_{MIN} \\ \mathbf{v}, & \text{caso contrário} \end{cases} \quad (2.6)$$

onde v_{MAX} e v_{MIN} são parâmetros que podem ser definidos pelo usuário.

- (c) Calcule a nova posição $\mathbf{t}$ de cada partícula como:

$$\mathbf{t} = \mathbf{t} + \mathbf{v} \quad (2.7)$$

- (d) Realize a mutação de cada partícula utilizando o operador de mutação proposto por Coello, Pulido e Lechuga (2004);
- (e) Avalie cada partícula utilizando as funções objetivo;
- (f) Armazene as novas soluções não dominadas no EA e remova as soluções do EA que, por ventura, tenham sido dominadas. Caso o EA tenha atingido o limite máximo, são eliminadas as soluções que tenham menor valor de *crowding distance*, ou seja, são eliminadas as soluções que estão em áreas mais populosas;
- (g) Atualize a memória da partícula $\hat{\mathbf{t}}$ usando a equação (2.4) caso $\mathbf{t} \preceq \hat{\mathbf{t}}$. Se $\mathbf{t} \not\preceq \hat{\mathbf{t}}$ nem $\hat{\mathbf{t}} \not\preceq \mathbf{t}$ (i.e., nenhuma domina a outra), a técnica busca no EA as soluções com mínima distância Euclidiana para $\mathbf{t}$ e $\hat{\mathbf{t}}$. Caso a solução mais próxima a $\mathbf{t}$ tenha um valor de *crowding distance* maior que o da solução mais próxima a $\hat{\mathbf{t}}$, então a equação (2.4) é utilizada. Caso contrário $\hat{\mathbf{t}}$ permanece o mesmo;

7. FIM ENQUANTO

8. Retorne o EA como a fronteira de Pareto resultante do processo de busca.

2.2.2 SMPSO

Assim como o MOPSO-CDR, o *Speed-constrained Multi-objective Particle Swarm Optimization* (SMPSO) (NEBRO et al., 2009) também é uma técnica de busca multiobjetivo baseada no PSO. O SMPSO têm sido bastante utilizado pelos pesquisadores pelo fato de apresentar melhor performance do que outras técnicas PSO multiobjetivo mais estabelecidas na literatura.

A seguir são sumarizados os passos da técnica SMPSO e maiores detalhes podem ser obtidos em Nebro et al. (2009).

1. Inicie aleatoriamente a posição $\mathbf{t}$ e velocidade $\mathbf{v}$ de cada partícula;
2. Avalie cada partícula de acordo com as funções objetivo utilizadas;
3. Armazene no EA as soluções consideradas não dominadas;
4. Gere o *crowding distance* de cada solução do EA;
5. Inicie a memória $\hat{\mathbf{t}}$ de cada partícula utilizando a equação (2.4);
6. **ENQUANTO** o critério de parada não for atingido **FAÇA**
 - (a) Calcule a velocidade $\mathbf{v}$ de cada partícula utilizando a equação (2.5). O seguinte procedimento é utilizado de forma a selecionar o guia global $\hat{\mathbf{g}}$ para cada partícula:
 - i. Selecione aleatoriamente duas soluções do EA e escolha a que tiver maior valor de *crowding distance*.
 - (b) Multiplique a velocidade $\mathbf{v}$ pelo fator de restrição χ definido como:

$$\chi = \frac{2}{2 - \varphi - \sqrt{\varphi^2 - 4\varphi}} \quad (2.8)$$

onde

$$\varphi = \begin{cases} C_1 + C_2, & \text{se } C_1 + C_2 > 4 \\ 0, & \text{se } C_1 + C_2 \leq 4 \end{cases} \quad (2.9)$$

- (c) Limite o valor da velocidade $\mathbf{v}$ utilizando a equação (2.6);
- (d) Calcule a nova posição $\mathbf{t}$ de cada partícula utilizando a equação (2.7);
- (e) Realize a mutação (*bitwise mutation*) em 15% das partículas com probabilidade de $1/l$. Onde l é o tamanho do vetor $\mathbf{t}$ (da mesma forma proposta por Deb et al. (2000));
- (f) Avalie cada partícula utilizando as funções objetivo;
- (g) Armazene as novas soluções não dominadas no EA e remova as soluções do EA que, por ventura, tenham sido dominadas. Caso o EA tenha atingido o limite máximo, são eliminadas as soluções que tenham menor valor de *crowding distance*, ou seja, são eliminadas as soluções que estão em áreas mais populosas;
- (h) Atualize a memória da partícula $\hat{\mathbf{t}}$ usando a equação (2.4) caso $\mathbf{t} \preceq \hat{\mathbf{t}}$. Se $\mathbf{t} \not\preceq \hat{\mathbf{t}}$ nem $\hat{\mathbf{t}} \not\preceq \mathbf{t}$ a memória também é atualizada usando a equação (2.4);

7. FIM ENQUANTO

8. Retorne o EA como a fronteira de Pareto resultante do processo de busca.

2.2.3 NSGA-II

O NSGA-II (DEB et al., 2000) é uma técnica de busca multiobjetivo bastante utilizada na literatura. De fato, a mesma pode ser considerada como um *benchmark* pois é muito utilizada como base de comparação em trabalhos que envolvam otimização multiobjetivo.

A seguir são sumarizados os passos do NSGA-II e os detalhes específicos de implementação podem ser obtidos em Deb et al. (2000).

1. Crie uma população inicial aleatória;
2. Ordene a população utilizando o mecanismo conhecido como *fast nondominated sorting*⁵;
3. **ENQUANTO** o critério de parada não for atingido **FAÇA**
 - (a) Realize seleção por torneio binária, *crossover* e mutação⁶ na população para gerar os descendentes;
 - (b) Faça uma união da população atual e a população de descendentes;
 - (c) Ordene essa união utilizando o *fast nondominated sorting*;
 - (d) Selecione as soluções com melhores valores para formar a nova população;
4. **FIM ENQUANTO**
5. Retorne a população como resultado do processo de busca.

2.2.4 SPEA2

A técnica evolucionária multiobjetivo SPEA2 (ZITZLER; LAUMANN; THIELE, 2001) é uma nova versão da técnica SPEA dos mesmos autores. Essa técnica é bastante utilizada na literatura de otimização multiobjetivo.

Os passos a seguir detalham o funcionamento da técnica SPEA2 e maiores detalhes podem ser obtidos em Zitzler, Laumanns e Thiele (2001).

1. Crie uma população inicial aleatória;
2. **ENQUANTO** o critério de parada não for atingido **FAÇA**
 - (a) Calcule a avaliação de cada solução de acordo com os objetivos;

⁵Mecanismo de ordenação que consiste na divisão das soluções da população em diversas fronteiras com diferentes níveis de não dominância. Detalhes específicos desse mecanismo podem ser obtidos em Deb et al. (2000).

⁶Mecanismos padrões encontrados na literatura de algoritmos evolutivos

- (b) Calcule o *fitness* de cada indivíduo da população e do EA;
Cada indivíduo recebe um valor de *fitness* que corresponde à quantidade de soluções que o mesmo domina e a densidade da área onde o mesmo se encontra inserido.
- (c) Armazene todas as soluções não dominada da população no EA;
- (d) Realize seleção por torneio binária, *crossover* e mutação para gerar uma nova população;

3. FIM ENQUANTO

- 4. Retorne o EA como resultado do processo de busca.

2.2.5 TAEA

A técnica TAEA (PRADITWONG; YAO, 2006), diferentemente da maioria das técnicas evolucionárias multiobjetivo, trabalha com dois arquivos externos. Um dos arquivos é chamado de arquivo de convergência (CA) que armazena soluções não dominadas que em algum momento dominaram alguma outra solução não dominada anterior. O segundo arquivo é chamado de arquivo de diversidade onde são armazenadas soluções não dominadas que não dominaram nenhuma outra solução não dominada anterior.

- 1. Crie uma população inicial aleatória;
- 2. **ENQUANTO** o critério de parada não for atingido **FAÇA**
 - (a) Calcule a avaliação de cada solução de acordo com os objetivos;
 - (b) Atualize os arquivos externos CA e DA com as soluções não dominadas;
 - (c) Realize seleção por torneio binária com uma probabilidade p de selecionar de cada um dos arquivos externos, *crossover* e mutação para gerar uma nova população;
onde a probabilidade p é um parâmetro definido pelo usuário.

3. FIM ENQUANTO

- 4. Retorne a união de CA com DA como resultado do processo de busca.

2.3 Trabalhos Relacionados

Nesta seção são abordados os trabalhos relacionados especificamente ao problema de Seleção Multiobjetivo de Casos de Teste, pois esse é o problema foco do presente trabalho.

O trabalho de Yoo e Harman (2007), foi o primeiro a introduzir os conceitos de Pareto dentro do contexto do problema de seleção de casos de teste, além de descrever os benefícios

potenciais da utilização de técnicas multiobjetivo para tal. Os múltiplos objetivos utilizados foram: cobertura de código-fonte, histórico de detecção de falhas e custo de execução. Os estudos empíricos apresentados formularam o problema de seleção com dois objetivos (cobertura de código e custo de execução), assim como também com os três objetivos. Os autores utilizaram três algoritmos: (1) uma reformulação de um algoritmo guloso que combinava os objetivos em um só através da utilização de pesos, (2) o bem difundido Algoritmo Genético NSGA-II (Non Dominating Sorting Genetic Algorithm) de Deb et al. (2000) e, (3) o vNSGA-II que é uma variação do NSGA-II proposta pelos autores. Esses algoritmos foram aplicados no contexto de seleção multiobjetivo de casos de teste estruturais de cinco programas obtidos do repositório SIR (Software-artifact Infrastructure Repository - Do, Elbaum e Rothermel (2005)). O objetivo principal do trabalho foi verificar se a utilização de técnicas de busca multiobjetivo apresentaria melhoras em relação à utilização de um algoritmo guloso. Os resultados apresentados mostraram que as técnicas baseadas em busca, na maioria das vezes, foram melhores que o algoritmo guloso (mas existiram casos onde o algoritmo guloso foi melhor). Devido a isso, os autores propuseram a ideia de fazer um híbrido entre as técnicas e o algoritmo guloso, como um trabalho futuro, na esperança de que os resultados combinados seriam melhor que os apresentados. Além disso, pelos resultados apresentados não era possível concluir qual das técnicas de busca utilizadas era melhor que a outra, pois para pequenos programas o NSGA-II foi melhor e para programas maiores o algoritmo guloso foi melhor.

Maia et al. (2009) utilizaram como objetivos: os riscos associados aos casos de teste, tempo de execução e importância dos requisitos (sob a ótica do cliente). Além disso, três restrições do ambiente de testes foram consideradas: o tempo máximo de execução, o tempo disponível para alocação de recursos (pessoas) para executar os testes e a existência de casos de teste pré-requeridos. Dados de um projeto de software foram coletados e utilizados nos experimentos onde o algoritmo NSGA-II foi comparado com uma abordagem randômica. Por fim, os autores concluíram que era possível otimizar o problema de seleção de casos de teste numa visão multiobjetivo e que o algoritmo NSGA-II retorna melhores soluções do que a abordagem randômica.

Yoo e Harman (2010b), evoluindo o trabalho anterior (YOO; HARMAN, 2007), criaram uma abordagem híbrida para seleção multiobjetivo de casos de teste estruturais. Essa abordagem híbrida, nomeada de HNSGA-II, combinava dois algoritmos utilizados no trabalho anterior: o NSGA-II e o algoritmo guloso. Nos experimentos apresentados, a abordagem híbrida foi comparada com a estratégia gulosa (sozinha) em cinco programas também obtidos do SIR, mas diferentes dos utilizados no trabalho anterior. Os mesmos objetivos do trabalho anterior foram utilizados nessa comparação. Através da análise dos resultados obtidos, os autores concluíram que a abordagem híbrida foi melhor que a abordagem gulosa.

O próximo trabalho de Yoo, Nilsson e Harman (2011) nessa área focou-se, dessa vez, num ambiente industrial maior. Eles reportaram a experiência e resultados iniciais de um projeto que integrava técnicas de busca multiobjetivo dentro do processo de testes da empresa

Google. Nesse trabalho, eles utilizaram um algoritmo evolucionário conhecido como TAEA (Two-Archive Multi-Objective Evolutionary Algorithm) proposto por Praditwong e Yao (2006). Os objetivos utilizados, por sua vez, foram a cobertura de dependências no código-fonte, histórico de detecção de falhas e custo de execução. O objetivo principal desse trabalho foi redução do tempo necessário para detecção prévia de falhas antes da integração do código-fonte (que é feita em etapas). A partir dos resultados dos experimentos os autores relataram que obtiveram uma redução de 33% a 82% no tempo do processo de execução dos testes se comparado à execução de todos os testes.

Em um outro estudo posterior, Yoo, Harman e Ur (2011) estudaram a escalabilidade de três técnicas (NSGA-II, TAEA e SPEA2) aplicadas ao problema de seleção multiobjetivo de casos de teste. Eles demonstraram que a utilização de arquiteturas paralelas (implementadas em hardware) pode aumentar a velocidade dessas técnicas em até 25 vezes. Os objetivos utilizados (cobertura de código e custo de execução) foram formulados de uma maneira que fosse permitido calculá-los de forma paralela através de uma matriz. Por fim, eles concluíram que a utilização de paralelismo pode melhorar a performance das técnicas multiobjetivo quando aplicadas à suítes grandes.

O trabalho de Lucia et al. (2012), por sua vez, propôs mecanismos para melhorar a diversidade do algoritmo vNSGA-II de Yoo e Harman (2007). Para tal, dois novos algoritmos foram propostos. Um dos algoritmos, o FS-vNSGA-II, utilizou-se dos conceitos de *fitness sharing* para penalizar soluções em áreas muito populosa. Já o outro algoritmo, o DF-vNSGA-II, utilizou uma função de densidade procurando forçar uma distribuição mais uniforme das soluções do algoritmo. Os resultados obtidos mostraram que os dois novos algoritmos propostos foram melhores que o algoritmo base vNSGA-II, mas não foi possível afirmar qual dos dois foi melhor comparando-os.

Kumari, Srinivas e Gupta (2012) apresentaram o algoritmo QMDEA (Quantum-inspired Multi-objective Differential Evolution Algorithm) que combinava características de Evolução Diferencial e Computação Quântica esperando obter melhores fronteiras de Pareto. A performance do QMDEA foi verificada em duas aplicações do mundo real e os resultados obtidos foram comparados com os resultados do algoritmo NSGA-II. Através dessa comparação, os autores concluíram que a performance do QMDEA foi superior ao NSGA-II.

Por fim, Bozkurt (2013) formulou o objetivo de custo em termos do custo monetário de invocação de um serviço durante a execução dos testes. Em seu contexto de sistemas centrados em serviços, cada serviço têm um custo monetário associado à sua invocação. Durante a execução dos testes, esses custos de invocação são mais importantes que o tempo que se gasta para execução. Além desse objetivo, ele utilizou um objetivo chamado de confiabilidade que representa uma medida associada a confiabilidade das entradas de teste. Por fim, o último objetivo utilizado foi a cobertura de código. O autor utilizou o algoritmo híbrido proposto por Yoo e Harman (2010b) e o comparou com o NSGA-II. Os resultados obtidos mostraram evidências da efetividade dos objetivos propostos no contexto de sistemas centrados em serviços,

além de confirmar a melhor performance do algoritmo HNSGA-II sobre o NSGA-II.

Como pôde ser observado na literatura relacionada apresentada, ainda existem poucos trabalhos sobre seleção multiobjetivo de casos de teste. Além disso, é possível ver três maiores oportunidades de pesquisa nessa área: (1) investigar a aplicação de outras técnicas de busca no problema de seleção multiobjetivo de casos de teste, (2) investigar o comportamento das técnicas de seleção de casos de teste multiobjetivo já propostas em ambientes de teste diversos (diferentes objetivos e/ou restrições) e (3) encontrar formas de melhorar os resultados das técnicas de seleção já propostas. Os objetivos deste trabalho, como foram apresentados na Seção 1.2, estão relacionados (com diferentes intensidades) a cada uma dessas oportunidades de pesquisa.

A tabela 2.1, a seguir, tem o objetivo de mostrar informações sobre os trabalhos relacionados possibilitando, assim, estabelecer um comparativo entre esses trabalhos e o que foi proposto neste trabalho e apresentado durante este capítulo.

Os pontos fortes foram destacados sob o ponto de vista de inovação apresentada pelo trabalho. Já os pontos fracos foram destacados de forma a mostrar o que esses trabalhos não fizeram e que o presente trabalho abordou.

Tabela 2.1: Comparativo dos trabalhos relacionados

Referência	Técnicas	Objetivos	Resultados	Pontos Fortes	Pontos Fracos
Yoo e Harman (2007)	1. Algoritmo Guloso	1. Cobertura de código	Melhor Técnica: 1. NSGA-II (pequenos programas)	• Primeiro trabalho com formulação multiobjetivo para seleção de casos de teste;	• Comparou as técnicas apenas observando as fronteiras de Pareto, sem abordar a capacidade de detecção de falhas; • Não abordou a existência de restrições;
	2. NSGA-II	2. Custo de execução			
	3. vNSGA-II	3. Histórico de detecção de falhas	2. Algoritmo Guloso (programas maiores)		

Continua na próxima página

Tabela 2.1 – *Continuação da tabela*

Referência	Técnicas	Objetivos	Resultados	Pontos Fortes	Pontos Fracos
Maia et al. (2009)	1. NSGA-II 2. Randômico	1. Riscos	Melhor Técnica: NSGA-II	• Primeiro trabalho que considera restrições no processo de busca; • Primeiro trabalho que considera os riscos e importância dos requisitos;	• Não propôs nenhuma nova técnica; • Comparou as técnicas apenas observando as fronteiras de Pareto, sem abordar a capacidade de detecção de falhas; • Não ficou claro se os resultados foram comparados através de testes estatísticos; • Não fez estudo de impacto das restrições sobre a qualidade das soluções; • Não apresenta dados das suítes utilizadas;
		Além de incorporar restrições: 1. Tempo máximo de execução 2. Tempo disponível para alocação de recursos 3. Testes pré-requeridos			• Comparou as técnicas apenas observando as fronteiras de Pareto, sem abordar a capacidade de detecção de falhas; • Não abordou a existência de restrições;
Yoo e Harman (2010b)	1. Algoritmo Guloso 2. HNSGA-II	1. Cobertura de código	Melhor Técnica: HNSGA-II	• Primeiro trabalho com proposição de um algoritmo híbrido;	• Não comparou com outras técnicas • Não abordou a existência de restrições;
		2. Custo de execução 3. Histórico de detecção de falhas			
Yoo, Nilsson e Harman (2011)	1. TAEA	1. Cobertura de dependência no código 2. Custo de execução 3. Histórico de detecção de falhas	Redução do tempo do processo utilizado pela empresa para detecção prévia de falhas antes da integração do código	• Primeiro trabalho inserido num contexto de uma empresa de grande porte (contexto industrial); • Primeiro trabalho que aborda a capacidade de detecção de falhas;	• Não comparou com outras técnicas • Não abordou a existência de restrições;

Continua na próxima página

Tabela 2.1 – *Continuação da tabela*

Referência	Técnicas	Objetivos	Resultados	Pontos Fortes	Pontos Fracos
Yoo, Harman e Ur (2011)	1. NSGA-II	1. Cobertura de código	Implementações paralelas podem ser até 25x mais rápidas se comparadas às implementações tradicionais;	● Primeiro trabalho que aborda paralelização das técnicas;	● Não fez uma comparação clara de qual técnica apresenta melhores resultados;
	2. SPEA2	2. Custo de execução		● Primeiro trabalho que estuda o tempo de execução das técnicas;	● Não abordou a capacidade de detecção de falhas;
	3. TAEA				● Não abordou a existência de restrições;
Lucia et al. (2012)	1. vNSGA-II	1. Cobertura de código	Tanto o FS-vNSGA-II quanto o DF-vNSGA-II foram melhores que o vNSGA-II, mas nenhum foi melhor que o outro;	● Primeiro trabalho que estuda o impacto de utilização de mecanismos para aumentar a diversidade das soluções;	● Comparou as técnicas apenas observando as fronteiras de Pareto, sem abordar a capacidade de detecção de falhas;
	2. FS-vNSGA-II	2. Custo de execução			● Não abordou a existência de restrições;
	3. DF-vNSGA-II				● Utilizou poucas suítes de pequeno tamanho;
Kumari, Srinivas e Gupta (2012)	1. QMDEA	1. Cobertura de código	Melhor Técnica: QMDEA	● Primeiro trabalho a aplicar o QMDEA ao problema de seleção multiobjetivo de casos de teste;	● Comparou as técnicas apenas observando as fronteiras de Pareto, sem abordar a capacidade de detecção de falhas;
	2. NSGA-II	2. Custo de execução			● Não abordou a existência de restrições;
					● Utilizou poucas suítes de pequeno tamanho;

Continua na próxima página

Tabela 2.1 – *Continuação da tabela*

Referência	Técnicas	Objetivos	Resultados	Pontos Fortes	Pontos Fracos
Bozkurt (2013)	1. Algoritmo Guloso 2. HNSGA-II 3. NSGA-II	1. Cobertura de código	Melhor Técnica: HNSGA-II	• Primeiro trabalho abordar questões de custos monetários;	• Comparou as técnicas apenas observando as fronteiras de Pareto, sem abordar a capacidade de detecção de falhas;
		2. Custo monetário de invocação dos serviços	Redução dos custos monetários de execução dos testes.		• Não abordou a existência de restrições;
		3. Confiabilidade			• Utilizou poucas suítes;

2.4 Considerações Finais

Este capítulo introduziu os conceitos fundamentais para entendimento da tese. Como mencionado, o processo de testes pode ser custoso o que leva a criação de mecanismos para reduzir esses custos. Três áreas de pesquisa relacionadas que tentam reduzir os custos do processo de teste foram apresentadas: minimização, seleção e priorização. Um foco maior foi dado ao problema de seleção de casos de teste por ser este o assunto principal deste trabalho. Em sequência foi mostrada a abordagem de resolução do problema de seleção através da utilização de técnicas de busca. A partir disso, foi mencionado que em determinados ambientes de teste podem existir mais de um critério de seleção e os conceitos relacionados à seleção multiobjetivo de casos de teste foram apresentadas. Após, devido a possibilidade de existência de restrições, os conceitos relacionados à seleção multiobjetivo com restrições foram mostrados. A seguir foram sumarizadas as técnicas de busca que foram utilizadas como base para as técnicas propostas nesta tese. Por fim, os trabalhos relacionados foram mostrados.

No próximo capítulo serão apresentadas as técnicas propostas neste trabalho.

3

Métodos Propostos

Neste capítulo é apresentado todo o trabalho desenvolvido. Inicialmente são apresentadas as técnicas de busca híbridas e não híbridas propostas para a resolução do problema de Seleção Multiobjetivo de Casos de Teste. Após isso, são descritas as técnicas que contêm mecanismos de tratamento de restrições. Por fim, os trabalhos relacionados a este são abordados.

3.1 Técnicas de Busca Propostas para o Problema de Seleção Multiobjetivo de Casos de Teste

3.1.1 Formulação do Problema

Antes de descrever as técnicas propostas é necessário mostrar como o problema foi formulado sob o ponto de vista de um processo de busca. Além disso, os critérios de seleção (objetivos) utilizados também são apresentados.

Uma solução para o problema é um vetor binário representando um subconjunto de casos de teste a ser utilizado no processo de execução dos testes. Seja $T = \{T_1, T_2, \dots, T_{n_t}\}$ uma suíte de testes com n_t casos de teste. Uma solução é definida como $\mathbf{t} = (t_1, t_2, \dots, t_{n_t})$, onde $t_j \in \{0, 1\}$ indica a presença (1), ou ausência (0), do caso de teste T_j dentro do subconjunto selecionado.

Neste trabalho foram considerados os seguintes objetivos: (1) Cobertura de Requisitos (requisitos esses que são ramificações de código fonte) e (2) Custo de Execução (o custo necessário para executar um caso de teste).

Não é o propósito deste trabalho discutir quais objetivos são mais adequados para o problema de seleção multiobjetivo de casos de teste. Dentre os objetivos presentes na literatura (HARMAN, 2011), os aqui utilizados são adequados por representarem situações reais (e comuns) encontradas em ambientes de teste.

O objetivo de Cobertura (a ser maximizado) representa o montante (porcentagem) de requisitos (ramificações de código-fonte) coberto por uma solução $\mathbf{t}$ em comparação com o montante coberto originalmente por T . Formalmente, seja $R = \{R_1, R_2, \dots, R_{n_k}\}$ um conjunto de n_k requisitos da suíte original T . Seja $C(T_j)$ uma função que retorna o subconjunto dos requisitos de R coberto pelo caso de teste T_j . Então, a Cobertura de uma solução $\mathbf{t}$ é dada como:

$$Cobertura(\mathbf{t}) = 100 * \frac{|\bigcup_{t_j=1} \{C(T_j)\}|}{n_k} \quad (3.1)$$

onde $\bigcup_{t_j=1} \{C(T_j)\}$ é a união dos subconjuntos dos requisitos cobertos pelos casos de teste T_j selecionados (onde $t_j = 1$).

A outra função objetivo (a ser minimizada) é o Custo de execução (o custo necessário para executar cada caso de teste). Formalmente, cada caso de teste $T_j \in T$ tem um valor de custo c_j associado. O custo total de uma solução $\mathbf{t}$ é definido como:

$$Custo(\mathbf{t}) = \sum_{t_j=1} c_j \quad (3.2)$$

As técnicas de busca propostas neste trabalho procuram otimizar esses dois objetivos de forma a fornecer um conjunto de soluções ótimas ao testador para que o mesmo possa escolher aquela que mais se adeque aos recursos disponíveis em seu ambiente.

3.1.2 Técnicas Não Híbridas

Como dito anteriormente, o PSO foi utilizado como base para proposição das técnicas não híbridas deste trabalho. Duas técnicas são aqui propostas: (1) *Binary Multi-Objective Particle Swarm Optimization with Crowding Distance and Roulette Wheel* (BMOPSO-CDR) e (2) *Binary Speed-constrained Multi-objective Particle Swarm Optimization* (BSMPSO).

A técnica BMOPSO-CDR (SOUZA et al., 2011) foi uma variante proposta pelos presentes autores através da combinação entre o PSO binário de Kennedy e Eberhart (1997), pois o problema de seleção de testes aqui foi formulado como um problema de busca em espaço binário, e a técnica PSO multiobjetivo MOPSO-CDR proposta por Santana, Pontes e Bastos-Filho (2009), pois o presente trabalho considera mais de um objetivo durante o processo de seleção. A técnica multiobjetivo MOPSO-CDR ainda não havia sido adaptada para trabalhar em problemas binários, portanto uma das contribuições do presente trabalho também foi a criação de uma variante do MOPSO-CDR para problemas com espaço de busca binários.

No BMOPSO-CDR substituímos a equação 2.7 do MOPSO-CDR (apresentado na seção 2.2.1) pelas seguintes equações:

$$\mathbf{t} = \begin{cases} 1, & \text{se } r_3 \leq \text{sig}(\mathbf{v}) \\ 0, & \text{caso contrário} \end{cases} \quad (3.3)$$

onde r_3 é um número aleatório no intervalo entre $[0,1]$ e $\text{sig}(\mathbf{v})$ é a função sigmoideal definida como:

$$\text{sig}(\mathbf{v}) = \frac{1}{1 + e^{-\mathbf{v}}} \quad (3.4)$$

As equações 3.3 e 3.4 foram propostas por Kennedy e Eberhart (1997) de forma a

certificar que as novas posições sejam binárias. O valor da posição t tende a ser 1 quando a velocidade v assume valores altos. Já t tende a ser 0 para valores de velocidade v baixos.

Da mesma forma, a técnica BSMPSO aqui proposta foi uma variante criada a partir da adaptação do PSO binário de Kennedy e Eberhart (1997) combinada com uma adaptação da técnica PSO multiobjetivo SMPPO proposta por Nebro et al. (2009). Embora essa técnica seja bastante utilizada, não foi possível encontrar na literatura nenhum trabalho que propusesse uma variante do SMPPO para problemas binários. Portanto, uma das contribuições deste trabalho foi a proposição da técnica BSMPSO que é uma variante do SMPPO voltada para espaços de busca binários.

Também no BSMPSO, substituímos a equação 2.7 pelas equações 3.3 e 3.4.

Além dessas duas técnicas não híbridas (BMOPSO-CDR e BSMPSO), no capítulo 4 as técnicas (também não híbridas) NSGA-II (DEB et al., 2000), SPEA2 (ZITZLER; LAUMANN; THIELE, 2001) e TAEA (PRADITWONG; YAO, 2006) são utilizadas nos experimentos realizados neste trabalho.

3.1.3 Técnicas Híbridas

Neste trabalho a utilização de mecanismos de busca local para criação de técnicas híbridas é proposta de forma a tentar melhorar as soluções das técnicas mencionadas anteriormente (que tem uma característica de busca mais global). A intenção desse tipo de mecanismo é explorar a vizinhança das soluções no espaço de busca procurando obter novas soluções melhores por perto, ou seja, esses mecanismos objetivam refinar as soluções existentes.

As seguintes técnicas de busca com comportamento local foram utilizadas neste trabalho: (1) *Forward Selection* (FS) e *Backward Elimination* (BE)¹ (KOHAVI; JOHN, 1997; WEBB, 2002), (2) 1-opt (PAPADIMITRIOU; STEIGLITZ, 1998), (3) *Additional Greedy* (AG) (ELBAUM; MALISHEVSKY; ROTHERMEL, 2000; YOO; HARMAN, 2007) e (4) Busca Harmônica - *Harmony Search* (HS) (GEEM; KIM; LOGANATHAN, 2001; WANG et al., 2010).

3.1.3.1 Mecanismo FB

O mecanismo *Forward Selection and Backward Elimination* (FB) é baseado nas técnicas *Forward Selection* e *Backward Elimination*. De acordo com Webb (2002), a técnica *Forward Selection* (ou *Sequential Forward Selection*) é uma técnica de busca que constrói uma solução pela adição de novos nós de forma iterativa até que um critério de parada seja alcançado. Já a técnica *Backward Elimination* (ou *Sequential Backward Selection*) age de forma contrária ao construir soluções através da eliminação de nós da solução corrente. As figuras 3.1 e 3.2 ilustram o processo de busca dessas técnicas.

¹As nomenclaturas dessas técnicas são as utilizadas na área de *feature selection* conforme pode ser verificado em Kohavi e John (1997).




Figura 3.1: Ilustração do processo de busca da técnica *Forward Selection* a partir de um vetor binário (solução).




Figura 3.2: Ilustração do processo de busca da técnica *Backward Elimination* a partir de um vetor binário (solução).

Tomando como base as ideias das técnicas *Forward Selection* e *Backward Elimination*, o mecanismo de busca local FB foi proposto e utilizado para criar as seguintes técnicas híbridas: (1) *Binary Multi-Objective Particle Swarm Optimization with Crowding Distance, Roulette Wheel, Forward Selection and Backward Elimination* (BMOPSO-CDR-FB), (2) *Binary Speed-constrained Multi-objective Particle Swarm Optimization with Forward Selection and Backward Elimination* (BSMPSO-FB), (3) *Non-dominated Sorting Genetic Algorithm with Forward Selection and Backward Elimination* (NSGA-II-FB), (4) *Strength Pareto Evolutionary Algorithm with Forward Selection and Backward Elimination* (SPEA2-FB) e (5) *Two-Archive Evolutionary Algorithm with Forward Selection and Backward Elimination* (TAEA-FB). Esse mecanismo, assim como os outros mecanismos de busca local que serão apresentados nas próximas seções, foi introduzido no final do *loop* principal das técnicas não híbridas.

A seguir os passos do mecanismo FB são sumarizados:

1. Selecione 10% das soluções não dominadas armazenadas no EA (ou equivalente caso a técnica não tenha um arquivo externo) através da Seleção por Roleta. Para utilizar essa seleção primeiro as soluções devem ter seu *crowding distance* calculado.

Algumas técnicas não híbridas já tinham esse valor calculado para as soluções do EA, nos outros casos esse cálculo foi introduzido e utilizado apenas no mecanismo de busca local;

2. Selecione aleatoriamente um objetivo para cada solução $\mathbf{t}$ previamente selecionada.
3. **SE** o objetivo é para ser maximizado, **ENTÃO** utilize o mecanismo FS, **SENÃO** utilize o BE.

O mecanismo FS itera sobre uma solução $\mathbf{t}$ (chamada de solução corrente) de tal forma que para cada caso de teste t_j ainda não presente em $\mathbf{t}$, ou seja para cada $t_j = 0$, uma nova solução candidata $\mathbf{t}'$ é produzida fazendo com que $t_j \leftarrow 1$. Após isso, cada solução $\mathbf{t}'$ é avaliada de acordo com a função objetivo previamente selecionada. A solução $\mathbf{t}'$ que não seja dominada pelo EA e que tenha o melhor valor de avaliação da função objetivo é escolhida como a nova solução corrente e o mecanismo FS é realizado novamente de forma recursiva. Isso é repetido até que todas as $\mathbf{t}'$ criadas sejam dominadas pela EA ou que não haja mais possibilidade de adicionar testes na solução corrente, ou seja $t_j = 1 \forall t_j \in \mathbf{t}$.

O mecanismo BE age de forma contrária ao FS. Ele itera sobre a solução corrente $\mathbf{t}$ de tal forma que para cada teste presente em $\mathbf{t}$ ($t_j = 1$) uma nova solução candidata $\mathbf{t}'$ é produzida fazendo com que $t_j \leftarrow 0$. Em sequência, as soluções candidatas são avaliadas de acordo com a função objetivo previamente escolhida e aquela que represente o melhor valor de avaliação da função e que não seja dominada pela EA é escolhida como a nova solução corrente. A partir daí o processo se repete recursivamente até que todas as soluções $\mathbf{t}'$ sejam dominadas pela EA ou que não seja possível remover mais nenhum teste da solução.

Além disso, todas as soluções candidatas $\mathbf{t}'$ não dominadas pelo EA encontradas durante o processo de busca dos mecanismos são utilizadas para atualizar o EA.

É importante ressaltar que a forma de atualização do EA (ou equivalente) utilizado pelos mecanismos de busca local, propostos nesse trabalho, é a mesma utilizada pelas técnicas nas quais esses mecanismos foram inseridos.

3.1.3.2 Mecanismo 1-opt

A técnica de busca local 1-opt é uma variação da técnica conhecida como k-opt (PAPADIMITRIOU; STEIGLITZ, 1998) e consiste em utilizar uma solução corrente $\mathbf{t}$ para criar novas soluções candidatas $\mathbf{t}'$ mudando um elemento de cada vez. As seguintes técnicas híbridas foram criadas utilizando o mecanismo de busca local 1-opt: (1) *Binary Multi-Objective Particle Swarm Optimization with Crowding Distance, Roulette Wheel and 1-opt* (BMOPSO-CDR-1opt), (2) *Binary Speed-constrained Multi-objective Particle Swarm Optimization with 1-opt* (BSMPSO-1opt), (3) *Non-dominated Sorting Genetic Algorithm with 1-opt* (NSGA-II-1opt), (4) *Strength Pareto Evolutionary Algorithm with 1-opt* (SPEA2-1opt) e (5) *Two-Archive Evolutionary Algorithm with 1-opt* (TAEA-1opt).

Os seguintes passos descrevem o funcionamento do mecanismo 1-opt proposto nesse trabalho:

1. Selecione 10% das soluções não dominadas (da mesma forma apresentada no mecanismo FB);
2. **PARA CADA** solução $\mathbf{t}$ **FAÇA**
 - (a) **PARA CADA** teste $t_j \in \mathbf{t}$ **FAÇA**
 - i. Mude o *bit* de t_j de forma a criar uma nova solução candidata $\mathbf{t}'$. Isto é, se $t_j = 0$ então $t_j \leftarrow 1$, senão o contrário.
 - ii. Avalie $\mathbf{t}'$ através das funções objetivo;
 - (b) Atualize o EA com todas as soluções $\mathbf{t}'$ que não forem dominadas por ele.

3.1.3.3 Mecanismo AG

A técnica conhecida como *Additional Greedy* (ELBAUM; MALISHEVSKY; ROTHERMEL, 2000; YOO; HARMAN, 2007) começa com uma solução vazia e iterativamente adiciona novos testes que tenham o melhor valor de cobertura por custo.

Utilizando os dados presentes na tabela 3.1 é possível exemplificar os passos dessa técnica. Primeiramente seria escolhido T_3 que tem o valor de cobertura por custo de $\frac{0,3}{2} = 0,15$, onde $T_1 = \frac{0,4}{3} \approx 0,13$, $T_2 = \frac{0,4}{5} = 0,08$, $T_4 = \frac{0,5}{6} \approx 0,07$ e $T_5 = \frac{0,3}{3} = 0,1$. No próximo passo a técnica escolheria $T_1 = \frac{0,3}{3} = 1$, onde $T_2 = \frac{0,4}{5} = 0,08$, $T_4 = \frac{0,3}{7} \approx 0,04$ e $T_5 = \frac{0,2}{3} \approx 0,07$. Na sequência seria escolhido $T_5 \approx 0,07$ ($T_2 = 0,06$ e $T_4 \approx 0,03$). Esse processo é repetido enquanto houver testes cujo valor de cobertura por custo seja maior que zero.

Tabela 3.1: Exemplo de uma suíte de testes

	R_1	R_2	R_3	R_4	R_5	R_6	R_7	R_8	R_9	R_{10}	Custo de Execução
T_1	X	X		X			X				3
T_2		X			X			X		X	5
T_3			X			X	X				2
T_4				X		X	X	X		X	7
T_5			X		X				X		3

O mecanismo de busca local AG foi proposto a partir da adaptação da técnica *Additional Greedy* apresentada anteriormente. Esse mecanismo foi utilizado na criação das seguintes técnicas híbridas: (1) *Binary Multi-Objective Particle Swarm Optimization with Crowding Distance, Roulette Wheel and Additional Greedy* (BMOPSO-CDR-AG), (2) *Binary Speed-constrained Multi-objective Particle Swarm Optimization with Additional Greedy* (BSMPSO-AG), (3) *Non-dominated Sorting Genetic Algorithm with Additional Greedy* (NSGA-II-AG), (4) *Strength Pareto Evolutionary Algorithm with Additional Greedy* (SPEA2-AG) e (5) *Two-Archive Evolutionary Algorithm with Additional Greedy* (TAEA-AG). A seguir são mostrados os passos do mecanismo AG:

1. Selecione 10% das soluções não dominadas (da mesma forma apresentada no mecanismo FB);

2. **PARA CADA** solução t **FAÇA**

(a) **REPITA**

i. **PARA CADA** teste $t_j \in t$ onde $t_j = 0$ **FAÇA**

A. Crie uma nova solução candidata t' fazendo com que
 $t_j \leftarrow 1$;

B. Calcule o valor de custo por cobertura de t' ;

ii. Escolha como a nova solução corrente a t' que tenha maior valor de cobertura por custo;

(b) **ATÉ QUE** não seja possível encontrar uma t' com valor de cobertura por custo maior que zero;

(c) Armazene no EA todas as soluções t' que não forem dominadas por ele.

3.1.3.4 Mecanismo HS

A técnica conhecida como Busca Harmônica (HS) (GEEM; KIM; LOGANATHAN, 2001) foi inspirada no processo musical da busca pela harmonia perfeita. Essa técnica imita o processo de busca que um músico realiza para encontrar uma harmonia agradável. As harmonias na música são análogas aos pontos num espaço de busca e as improvisações do músico são análogas aos operadores das técnicas de busca.

Essa técnica tem atraído atenção dos pesquisadores por sua característica de fácil implementação e boa capacidade de otimização. Além disso, a mesma tem sido aplicada com sucesso em diversos problemas com espaço de busca discreto/binário (WANG et al., 2011; WANG et al., 2010; AFKHAMI; MA'ROUZI; SOLEIMANI, 2013). Entretanto, não foi possível encontrar na literatura nenhum outro trabalho que utilize essa técnica no contexto de seleção de testes (além das publicações derivadas deste trabalho).

A técnica HS inicia seu processo de busca criando harmonias (soluções) aleatoriamente e as armazenando num conjunto chamado de memória harmônica (HM). A HM é utilizada durante todo o processo de busca para armazenar as melhores harmonias encontradas. Após a inicialização da HM, o processo de improvisação se inicia. O processo de improvisação (processo de busca) é controlado por 3 operadores²:

1. Operador de consideração da memória harmônica (HMCO): responsável por criar uma nova harmonia através da utilização de harmonias já presentes na HM. O HMCO acontece com uma probabilidade definida pelo parâmetro HMCR.

²Foram utilizadas as mesmas nomenclaturas presentes em Wang et al. (2011).

2. Operador de seleção aleatória (RSO): aleatoriamente modifica uma harmonia criando uma nova. Esse operador também é controlado pelo parâmetro HMCR de tal forma que sua probabilidade é igual a $1 - \text{HMCR}$. Ou seja, ela somente será utilizada caso o operador HMCO não seja utilizado.
3. Operador de ajuste da afinação (PAO): controla quando uma harmonia vai sofrer um ajuste de afinação após o HMCO. O operador PAO sempre acontece depois do HMCO com uma probabilidade definida pelo parâmetro PAR.

Ao final do processo de improvisação se a nova harmonia é melhor do que a pior harmonia do HM então ela vai ser armazenada no HM e a pior harmonia será removida. Esse processo continua até que um critério de parada seja alcançado. Como uma alternativa à atualização sequencial do HM (como mostrado anteriormente), Wang et al. (2010) propuseram uma estratégia de atualização paralela onde um número NGC de harmonias são criadas e improvisadas (através dos operadores apresentados) antes da atualização do HM. Essa estratégia paralela apresentou melhores resultados nos estudos conduzidos por eles.

O mecanismo HS proposto neste trabalho é uma adaptação da variante da técnica HS proposta por Wang et al. (2010) em problemas como um objetivo. Esse mecanismo foi utilizado para criar as técnicas híbridas: (1) *Binary Multi-Objective Particle Swarm Optimization with Crowding Distance, Roulette Wheel and Harmony Search* (BMOPSO-CDR-HS), (2) *Binary Speed-constrained Multi-objective Particle Swarm Optimization with Harmony Search* (BSMPSO-HS), (3) *Non-dominated Sorting Genetic Algorithm with Harmony Search* (NSGA-II-HS), (4) *Strength Pareto Evolutionary Algorithm with Harmony Search* (SPEA2-HS) e (5) *Two-Archive Evolutionary Algorithm with Harmony Search* (TAEA-HS).

A seguir são mostrados os passos do mecanismo HS:

1. Crie NGC soluções $\mathbf{t}$ vazias;
2. **PARA CADA** solução $\mathbf{t}$ **FAÇA**

(a) **SE** $r_1 \leq \text{HMCR}$ **ENTÃO**

i. Aplique o operador HMCO:

$$\mathbf{t} = \mathbf{t}^k \quad (3.5)$$

onde $\mathbf{t}^k$ corresponde a k -ésima solução aleatoriamente escolhida do EA;

ii. **SE** $r_3 \leq \text{PAR}$ **ENTÃO**

A. Aplique o operador PAO:

$$\mathbf{t} = \hat{\mathbf{g}} \quad (3.6)$$

onde $\hat{g}$ é selecionado do EA utilizando a Seleção por Roleta considerando os valores de *crowding distance*. A solução $\hat{g}$ é selecionada previamente e será a mesma utilizada para todas as NGC soluções criadas;

(b) **SENÃO**

i. Aplique o operador RSO:

$$t = \begin{cases} 1, & \text{se } r_2 \leq 0,5 \\ 0, & \text{caso contrário} \end{cases} \quad (3.7)$$

onde r_1 , r_2 e r_3 são valores aleatórios no intervalo $[0,1]$;

3. Atualize o EA com todas as soluções não dominadas criadas nos passos anteriores;
4. Repita o processo acima pelo número de vezes definidas pelo parâmetro NIR (número de repetições do processo de improvisação).

É importante ressaltar que embora a técnica HS não seja considerada uma técnica de busca local, os autores deste trabalho propuseram o mecanismo HS como local devido ao fato que somente o utilizam para melhorar as soluções não dominadas já presentes no EA. Por isso, para todos os efeitos, daqui para a frente o mecanismo HS será sempre referido como busca local no restante deste trabalho.

3.2 Técnicas de Busca Propostas para o Problema de Seleção Multiobjetivo de Casos de Teste com Restrições

Como mencionado no capítulo 2, é comum que em ambientes de teste existam restrições que devem ser atendidas. Na literatura não foi possível identificar nenhum outro trabalho que propusesse técnicas de busca e estudasse a qualidade das fronteiras de Pareto produzidas, a capacidade de detecção de falhas e o impacto que a introdução de restrições pode ter nos resultados dessas técnicas. Portanto, uma das contribuições originais do presente trabalho é de, além de propor novas técnicas para o problema de Seleção Multiobjetivo de Casos de Teste (com e sem restrições), realizar estudos iniciais comparando essas técnicas de busca num ambiente com restrições e verificar qual o impacto que essas restrições podem ter na qualidade das fronteiras de Pareto e na capacidade de detecção de falhas dessas técnicas.

De acordo com os resultados apresentados no capítulo 4, as seguintes técnicas de busca híbridas e com tratamento de restrições propostas foram: (1) *Constrained Binary Speed-constrained Multi-objective Particle Swarm Optimization with Coello's approach* (CBSMPSO-FB-C) e (2) *Constrained Binary Speed-constrained Multi-objective Particle Swarm Optimization with Er-dong's Fitness approach* (CBSMPSO-FB-F).

A técnica CBSMPSO-FB-C foi criada através da combinação da técnica BSMPSO-FB (seção 3.1.3) com o mecanismo de tratamento de restrições proposto por Coello, Pulido e Lechuga (2004). Esse mecanismo utiliza as seguintes regras quando duas soluções são comparadas em relação a dominância:

- Se ambas soluções são viáveis os conceitos de dominância apresentados anteriormente são utilizados;
- Se uma é viável e a outra é inviável, a viável é considerada dominante;
- Se ambas são inviáveis, aquela que violar as restrições em menor quantidade domina a outra.

Esse mecanismo simples é bastante semelhante ao proposto por Deb et al. (2000) e ambos são amplamente utilizados na literatura.

Como dito anteriormente, alguns trabalhos recentes (SINGH; RAY; SARKER, 2013; YU et al., 2014) têm focado no estudo do papel que soluções inviáveis podem ter no processo de busca como um todo. Para eles as soluções inviáveis podem guardar informações importantes que poderiam levar o processo de busca a novas regiões promissoras. Devido a isso, neste trabalho é proposta a técnica CBSMPSO-FB-F que mantém um determinado número de soluções inviáveis na esperança de que as mesmas sejam capazes de conduzir o processo de busca a novas regiões promissoras. Essa técnica é baseada na técnica proposta por Yu et al. (2014) e atribui valores de *fitness* para cada solução inviável de forma a indicar a importância dessa solução para o processo de busca.

Na técnica CBSMPSO-FB-F o EA somente armazena soluções não dominadas que sejam consideradas viáveis. Além disso, um outro arquivo (chamado de L_2) é utilizado para manter um determinado número de soluções não dominadas que sejam inviáveis.

Diferentemente do BSMPSO-FB, no CBSMPSO-FB-F a solução selecionada como guia global $\hat{g}$ (utilizada na equação 2.5) tem uma probabilidade de 50% de ser proveniente do L_2 ao invés do EA. Dessa forma, o enxame "voa" em direção a ambos arquivos durante todo o processo de busca.

A cada iteração, após a atualização do EA (que é o mesmo procedimento herdado do BSMPSO-FB), ocorre a atualização do L_2 . Para cada solução inviável do L_2 é feita uma checagem para verificar se a mesma é não dominada em relação aos membros do EA. Toda solução que seja dominada por algum membro do EA é removida do L_2 . Após isso, são adicionadas no L_2 todas as soluções inviáveis presentes no enxame (população corrente) que não sejam dominadas por nenhum membro do EA.

Para cada solução inviável presente em L_2 é associado um valor de *fitness* $\bar{f}$. Esse valor é formado pela conjunção da quantidade de violações das restrições, pela informação obtida através da atualização da memória $\hat{t}$ das partículas e pela densidade da região onde a solução está localizada. O mesmo é utilizado sempre que o guia global tiver que ser selecionado a partir

do L_2 . Para tal, a técnica seleciona aleatoriamente duas soluções inviáveis e a que tiver maior valor $\bar{f}$ é escolhida como o guia global.

O primeiro componente utilizado no cálculo do valor $\bar{f}$ está relacionado à violação das restrições. Para cada solução $\mathbf{t}$ inviável presente em L_2 é calculado o valor de $\hat{v}_m(\mathbf{t})$ que corresponde à quantidade da violação da restrição m pela solução $\mathbf{t}$. A partir disso $\bar{v}(\mathbf{t})$ é calculado como:

$$\bar{v}(\mathbf{t}) = \frac{1}{n_g + n_h} \sum_{m \in \{m | \hat{v}_m^{max} \neq 0\}} \frac{\hat{v}_m(\mathbf{t})}{\hat{v}_m^{max}} \quad (3.8)$$

onde $\hat{v}_m^{max}$ é o maior valor de violação da restrição m encontrado em L_2 ou no enxame corrente ou em todas as memórias $\hat{\mathbf{t}}$.

Outro componente utilizado no cálculo do valor $\bar{f}$ é a densidade $d(\mathbf{t})$. Esse valor é obtido através do cálculo do *crowding distance* da solução $\mathbf{t}$ e representa o qual populosa (densa) é a região onde essa solução está localizada.

O terceiro componente do cálculo do valor $\bar{f}$ é a quantidade de votos recebida pelas soluções inviáveis presentes em L_2 . Toda nova solução adicionada em L_2 recebe um valor de votos $\tilde{n}(\mathbf{t}) = 0$. Esse valor guarda a quantidade de votos que $\mathbf{t}$ recebeu desde que entrou em L_2 . Toda vez que uma solução $\mathbf{t} \in L_2$ é escolhida para ser o valor $\hat{\mathbf{g}}$ durante a atualização de velocidade, a técnica checa se a partícula que utilizou essa solução atualizou ou não sua memória $\hat{\mathbf{t}}$. Caso positivo $\tilde{n}(\mathbf{t})$ é incrementado, caso contrário é decrementado. O valor de $\tilde{n}(\mathbf{t})$ é limitado por um valor máximo ($\tilde{n}_{max}$) e por um valor mínimo ($\tilde{n}_{min}$) definidos pelo usuário. Além disso, antes de ser utilizado no cálculo do $\bar{f}$ o valor $\tilde{n}(\mathbf{t})$ é normalizado da seguinte forma:

$$\bar{n}(\mathbf{t}) = \frac{\tilde{n}(\mathbf{t}) - \tilde{n}_{min}}{\tilde{n}_{max} - \tilde{n}_{min}} \quad (3.9)$$

Finalmente, o valor $\bar{f}$ é dado como:

$$\bar{f}(\mathbf{t}) = \frac{1 - \bar{v}(\mathbf{t}) + \bar{n}(\mathbf{t})}{d(\mathbf{t})^{-1}} \quad (3.10)$$

Adicionalmente, o tamanho do L_2 é o mesmo tamanho do EA e sempre que o mesmo atinja seu tamanho máximo as soluções com menor valor $\bar{f}$ são eliminadas.

3.3 Considerações Finais

Neste capítulo foram descritas as técnicas de busca não híbridas e híbridas propostas. Em sequência, foram também descritas as técnicas com mecanismos de tratamento de restrições. Por fim, os trabalhos relacionados foram abordados.

No próximo capítulo são mostrados os experimentos realizados de forma a avaliar as técnicas propostas, assim como são discutidos os resultados destes experimentos.

4

Experimentos e Resultados

Este capítulo apresenta os experimentos realizados e as discussões dos resultados das comparações entre as seguintes técnicas propostas neste trabalho: BMOPSO-CDR, BMOPSO-CDR-FB, BMOPSO-CDR-1opt, BMOPSO-CDR-AG, BMOPSO-CDR-HS, BSMPSO, BSMPSO-FB, BSMPSO-1opt, BSMPSO-AG, BSMPSO-HS, NSGA-II-FB, NSGA-II-1opt, NSGA-II-AG, NSGA-II-HS, SPEA2-FB, SPEA2-1opt, SPEA2-AG, SPEA2-HS, TAEA-FB, TAEA-1opt, TAEA-AG, TAEA-HS, CBSMPSO-FB-C e CBSMPSO-FB-F. Detalhes sobre essas técnicas podem ser vistos no capítulo 3.

Além dessas, as técnicas não híbridas TAEA, NSGA-II e SPEA2, que serviram de base para a proposição das técnicas híbridas mencionadas anteriormente, também foram utilizadas nos experimentos.

4.1 Organização dos Experimentos

Nesta seção são mostrados os objetos de estudo utilizados, as questões de estudo consideradas, a preparação dos experimentos considerando essas questões, as métricas utilizadas nas avaliações das técnicas e as configurações de execução dos experimentos e das técnicas.

4.1.1 Objetos de Estudo

Os objetos de estudo utilizados nesse trabalho foram programas obtidos no *Software-Artifact Infrastructure Repository* (SIR) e o programa *Google Guava Core Libraries* (GUAVA).

Os programas obtidos a partir do SIR (DO; ELBAUM; ROTHERMEL, 2005) são extensivamente utilizados em estudos na área de Testes de Software. Estudos esses que os utilizam como *benchmarks* e estão concentrados (em sua maioria) na área específica de Testes de Regressão. Os seguintes programas foram selecionados: (1) *flex* (analisador léxico), (2) *grep* (utilitário de expressão regular), (3) *gzip* (utilitário de compressão), (4) *print tokens* (analisador léxico), (5) *print tokens 2* (analisador léxico), (6) *replace* (ferramenta de busca e substituição), (7) *schedule* (agendador de prioridades), (8) *schedule 2* (agendador de prioridades), (9) *sed* (editor de textos), (10) *space* (interpretador de uma linguagem de definição de matrizes), (11) *tcas* (sistema anti-colisão de aeronaves) e (12) *totinfo* (utilitário de computação de estatísticas). Esses programas

estão disponíveis no SIR de forma padronizada e contendo diversas informações relacionadas.

Além desses programas já extensivamente estudados na literatura, o presente trabalho utilizou também o programa GUAVA (GUAVA..., 2015). O GUAVA é um conjunto de bibliotecas de programação que fornecem funcionalidades extras às oferecidas pela linguagem Java. Dentre essas funcionalidades as mais importantes são: coleções, *caching*, tipos primitivos estendidos, concorrência, *annotations*, processamento de *strings* e operações de entrada e saída.

O objetivo de utilizar o GUAVA é aumentar a diversidade e possibilidade de extrapolação dos resultados aqui obtidos através da utilização de um programa considerado maior, mais complexo e bastante difundido no contexto industrial de desenvolvimento de software. Diferentemente dos programas provenientes do SIR, o código fonte do GUAVA foi obtido diretamente de seu repositório de desenvolvimento na plataforma *GitHub*¹.

Em adição aos motivos supracitados, a escolha do programa GUAVA foi também devida à existência de poucos estudos na área de testes de software que o envolvam. De fato, existem apenas alguns estudos recentes nas áreas de Priorização de Casos de Teste de Regressão (BIAN et al., 2015) e Geração de Casos de Testes (CAMPOS et al., 2015; DAKA et al., 2015). Em relação ao problema de Seleção Multiobjetivo de Casos de Teste não foi possível encontrar nenhum outro estudo que o utilizasse.

Para cada um dos programas do SIR, assim como para o programa GUAVA, uma suíte de testes foi selecionada aleatoriamente dentre as disponíveis. A tabela 4.1 apresenta as informações para cada programa acerca da quantidade de testes (presentes nas suítes selecionadas), número de requisitos cobertos e valor de redundância média (em porcentagem). O valor de redundância média se refere à redundância de cobertura de requisitos entre os testes. É esperado que quanto maior a redundância mais fácil seja para o processo de busca encontrar soluções que cubram uma maior quantidade de requisitos. Para medir essa redundância o Coeficiente de Similaridade de Jaccard (equação 4.1) foi utilizado. Formalmente, dados dois Casos de Teste cobrindo, respectivamente, os conjuntos de requisitos A e B, o Coeficiente de Similaridade de Jaccard é definido como:

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad (4.1)$$

Outro aspecto importante relacionado aos objetos de estudo diz respeito às informações referentes à cobertura de requisitos e custos de execução associados a cada teste. Como os programas SIR utilizados foram escritos em linguagem C, as ferramentas utilizadas para coletar os dados de cobertura de requisitos e custo de execução foram, respectivamente, o *gcov* (presente nativamente no Linux) e o Valgrind (NETHERCOTE; SEWARD, 2003). Para o GUAVA (escrito em Java) foram utilizadas, respectivamente, as ferramentas *Jacoco* e *JUnit*².

¹A versão 19 utilizada neste trabalho está disponível em: <https://github.com/google/guava/tree/v19.0>

²Essas ferramentas são amplamente utilizadas por times de desenvolvimento de software para coletar métricas de código-fonte. As mesmas estão disponíveis gratuitamente na internet.

Tabela 4.1: Detalhes sobre os programas utilizados como objetos de estudo

Programa	# Testes	# Requisitos	Redundância média
flex	567	1757	61%
grep	809	1812	46%
gzip	214	894	68%
print tokens	323	102	62%
print tokens 2	389	156	66%
replace	395	169	48%
schedule	228	62	69%
schedule 2	238	82	81%
sed	370	1551	56%
space	160	850	51%
tcas	84	61	29%
totinfo	205	79	71%
guava	1067	6533	7%

4.1.2 Questões de Estudo e Preparação dos Experimentos

Neste trabalho as questões de estudo (apresentadas a seguir) foram desenvolvidas de forma a guiar a preparação dos experimentos que procuravam responder essas questões. Elas refletem os questionamentos acerca das técnicas de busca propostas para o problema de Seleção Multiobjetivo de Casos de Teste.

Questão de Estudo 1. *As técnicas híbridas propostas neste trabalho produzem melhores fronteiras de Pareto do que as técnicas não híbridas para os programas do SIR?*

O objetivo da questão de estudo 1 foi verificar se, de fato, as introduções de mecanismos de busca local para criação das técnicas híbridas foram capazes de produzir melhores resultados do que as técnicas não híbridas utilizadas como base. Para responder essa questão as técnicas foram divididas em 5 subgrupos conforme apresentado na tabela 4.2.

Tabela 4.2: Divisão dos Subgrupos

Subgrupo 1	Subgrupo 2	Subgrupo 3	Subgrupo 4	Subgrupo 5
BMOPSO-CDR	BSMPSO	NSGA-II	SPEA2	TAEA
BMOPSO-CDR-FB	BSMPSO-FB	NSGA-II-FB	SPEA2-FB	TAEA-FB
BMOPSO-CDR-1opt	BSMPSO-1opt	NSGA-II-1opt	SPEA2-1opt	TAEA-1opt
BMOPSO-CDR-AG	BSMPSO-AG	NSGA-II-AG	SPEA2-AG	TAEA-AG
BMOPSO-CDR-HS	BSMPSO-HS	NSGA-II-HS	SPEA2-HS	TAEA-HS

Questão de Estudo 2. *Qual melhor técnica dentro de cada subgrupo com relação às fronteiras de Pareto para os programas do SIR?*

Através da questão de estudo 2 foi possível selecionar dentro de cada um dos subgrupos a técnica que produziu melhores resultados. Isso possibilitou diminuir a quantidade de técnicas comparadas de forma a permitir a realização de experimentos mais focados para responder as próximas questões de estudo. A partir desse momento as melhores técnicas de cada subgrupo serão referidas apenas como as melhores técnicas.

Questão de Estudo 3. *Qual das melhores técnicas produz fronteira de Pareto superior e apresenta melhor tempo de execução do que as outras para o programa GUAVA?*

Em adição à questão de estudo 2, através da questão de estudo 3 procurou-se verificar qual das melhores técnicas produzia melhor fronteira de Pareto para o GUAVA.

É importante ressaltar que essa comparação de fronteiras de Pareto é bastante comum na literatura (como mostrado na seção 2.3) para verificar a performance de técnicas sob o ponto de vista de otimização.

Questão de Estudo 4. *Qual das melhores técnicas apresenta melhor capacidade de detecção de falhas no GUAVA?*

Como mencionado anteriormente, embora a capacidade de detecção de falhas seja um importante aspecto para Seleção de Casos de Teste (e para o processo de Testes de Software como um todo), poucos trabalhos fazem algum tipo de estudo nessa direção. Levando isso em consideração, o objetivo da questão de estudo 4 foi o de verificar o comportamento das técnicas propostas com relação à capacidade de detecção de falhas. Não foi possível encontrar na literatura relacionada nenhum outro trabalho que estude tanto a capacidade de produção de fronteiras de Pareto (otimização) quanto a capacidade de detecção de falhas no problema de Seleção Multiobjetivo de Casos de Teste. Portanto, essa é uma das contribuições originais deste trabalho.

O ideal seria ter acesso previamente às informações relativas às falhas encontradas associadas a cada teste quando se deseja medir a performance de técnicas de seleção quanto a capacidade de detecção de falhas. De acordo com Mirarab, Esfahani e Tahvildari (2012), falhas reais são difíceis de encontrar em número suficiente para permitir a realização de experimentos controlados (como é o caso dos experimentos deste trabalho). Devido a isso, pesquisadores utilizam falhas artificialmente introduzidas no código fonte dos programas a serem testados. Essas falhas podem ser manualmente introduzidas ou pode-se utilizar a técnica conhecida como Testes de Mutação para produzir essas falhas. De acordo com Andrews, Briand e Labiche (2005), falhas introduzidas através do processo de mutação são melhores do que falhas introduzidas manualmente, pois são capazes de representar melhor as falhas reais no que tange o propósito de detecção de falhas. Devido a isso, esse trabalho utilizou da técnica de Teste de Mutação para permitir que se fosse medida a capacidade de detecção de falhas das técnicas propostas em conformidade com o objetivo da questão de estudo 4.

As próximas questões de estudo procuraram realizar alguns estudos iniciais no que concerne à comparação entre a melhor técnica até o momento (escolhida através das respostas

às perguntas anteriores) e duas técnicas propostas com mecanismos explícitos de tratamento de restrições. Não foi possível encontrar na literatura nenhum outro estudo que comparasse a capacidade de otimização (através das fronteiras de Pareto) e capacidade de detecção de falhas de técnicas com e sem mecanismos de tratamento de restrições no problema de Seleção Multiobjetivo de Casos de Teste, ou seja, que comparasse de alguma forma o impacto da introdução de restrições no ambiente. Portanto, uma das contribuições originais do presente trabalho foi a realização de estudos iniciais acerca desse assunto.

Questão de Estudo 5. *Considerando um ambiente com restrições, a melhor técnica até o momento (sem mecanismo de tratamento de restrições) produz fronteiras de Pareto equivalentes às técnicas com mecanismo explícito de tratamento de restrições no programa GUAVA?*

Como dito anteriormente, é comum que haja restrições presentes no ambiente de testes. Essas restrições podem afetar de forma direta como o processo de seleção será feito. Para responder à questão de estudo 5 foram criados quatro cenários que procuravam simular situações reais de ambientes com restrições: (1) Cobertura de Requisitos $\geq 50\%$, (2) Custo de Execução $\leq 50\%$, (3) Cobertura de Requisitos $\geq 90\%$, (4) Custo de Execução $\leq 10\%$. Os primeiros dois cenários representam situações medianas onde busca-se reduzir o espaço objetivo em 50%, já os dois últimos cenários representam situações consideradas críticas pois reduzem o espaço objetivo em 90% de seu tamanho.

O objetivo da questão de estudo 5 foi verificar se a técnica que não tinha mecanismo explícito de tratamento de restrições era capaz de produzir fronteiras de Pareto equivalente às técnicas que possuíam mecanismos explícitos de tratamento de restrições.

Questão de Estudo 6. *Considerando o mesmo ambiente com restrições, a melhor técnica até o momento (sem mecanismo de tratamento de restrições) tem capacidade de detecção de falhas equivalente às técnicas com mecanismo explícito de tratamento de restrições no programa GUAVA?*

Finalmente, através da resposta à questão de estudo 6 foi possível verificar se a técnica sem mecanismo de restrições era capaz de detectar falhas da mesma forma que as técnicas com mecanismo de tratamento de restrições.

4.1.3 Métricas

Para todos os experimentos as fronteiras de Pareto obtidas (resultados) foram avaliadas de acordo com cinco diferentes métricas de qualidade normalmente adotadas na literatura de otimização multiobjetivo. Cada uma das métricas apresentadas a seguir avalia um aspecto desejado das fronteiras de Pareto:

1. Hypervolume (HV) (DEB; KALYANMOY, 2001): representa o tamanho do espaço de busca objetivo O dominado pela fronteira de Pareto (PF). Também é conhecido

como *área sob a curva*. Quanto maior o valor de HV melhor a fronteira de Pareto PF .

2. Distância Geracional - *Generational Distance* (GD) (COELLO; LAMONT; VELDHUIZEN, 2007): a métrica GD mede o quão distante, em média, uma PF está da fronteira de Pareto ótima (PF^*). Quanto menor o valor de GD melhor a PF .
3. Distância Geracional Inversa - *Inverted Generational Distance* (IGD) (COELLO; LAMONT; VELDHUIZEN, 2007): representa o inverso da métrica GD pois mede a distância média da PF^* com relação à uma PF . A métrica IGD é complementar a métrica GD e objetiva reduzir o problema de quando a PF tem poucas soluções agrupadas o que poderia dar um bom resultado para a métrica GD. Já o resultado da métrica IGD é afetado pela distribuição das soluções da PF em relação à PF^* . Quanto menor o valor de IGD melhor a PF .
4. Cobertura do Pareto de Referência - *Coverage* (CVR): Essa métrica utilizada nesse trabalho é baseada na métrica *coverage* (DEB; KALYANMOY, 2001). A métrica CVR representa a proporção da quantidade de soluções de soluções da PF^* que dominam as soluções presente em uma PF . Quanto menor o valor de CVR melhor a PF .
5. Espalhamento Máximo - *Maximum Spread* (MS) (ZITZLER; DEB; THIELE, 2000): representa a extensão máxima (no espaço objetivo O) coberta pela PF . Quanto maior o valor de MS melhor a PF .

Tanto a métrica GD quanto a métrica IGD necessitam que PF^* seja conhecida. Infelizmente para problemas com grande espaço de busca, como os utilizados neste trabalho, é computacionalmente difícil saber PF^* *a priori*. Nesses casos, ao invés de se utilizar a PF^* no cálculo dessas métricas, é possível construir uma fronteira de Pareto (aqui chamada de $PF_{reference}$) e utilizá-la no lugar da PF^* (como sugerido por Yoo e Harman (2010b)). A $PF_{reference}$ representa todas as soluções não dominadas resultantes da união de todas as fronteiras de Pareto encontradas durante as execuções das técnicas. É importante ressaltar que a métrica CVR também utilizou a $PF_{reference}$ no lugar da PF^* .

4.1.4 Configurações de Execução dos Experimentos e das Técnicas

Todas as técnicas propostas neste trabalho foram executadas 100 vezes (como sugerido por Arcuri e Briand (2014)) devido à natureza aleatória inerente às mesmas. O critério de parada utilizado foi o de 50.000 avaliações das funções objetivo para os programas do SIR e 100.000 para o GUAVA³. Continuando, os dados de cada fronteira de Pareto (resultante das execuções

³Em testes preliminares o programa Guava demonstrou necessitar de uma maior quantidade de avaliações da função objetivo para convergir.

das técnicas) foram normalizados e os dados acerca de cada uma das métricas (apresentadas na seção 4.1.3) foram coletados objetivando responder as questões de estudo formuladas na seção 4.1.2. Além disso, dados sobre a convergência das técnicas para cada métrica também foram coletados.

Todas as comparações entre as técnicas foram inicialmente feitas através do teste estatístico não-paramétrico Kruskal-Wallis, o qual não depende que os dados analisados pertençam a uma distribuição normal⁴. Este teste é indicado para verificar se mais de duas amostras provém da mesma distribuição. Por isso, como todas as comparações apresentadas neste trabalho envolveram inicialmente mais de duas técnicas, o teste Kruskal-Wallis foi utilizado para verificar se havia diferença entre elas. Caso o valor p do teste fosse menor que 0,05 (nível de confiança utilizado em todo este trabalho) a hipótese nula era rejeitada em favor da hipótese alternativa que diz que pelo menos duas das técnicas foram diferentes entre si.

Adicionalmente, o teste estatístico de múltiplas comparações Steel-Dwass foi realizado sempre que o teste de Kruskal-Wallis indicasse a rejeição da hipótese nula. Esse teste foi realizado no intuito de verificar quais pares de técnicas eram consideradas estatisticamente diferentes entre si.

Com relação à configuração das técnicas, todas utilizaram 200 indivíduos (ou 200 partículas no caso das técnicas baseadas em PSO)⁵. Além disso, todas as técnicas que utilizavam arquivo externo tinham como limite 200 soluções não dominadas nesse arquivo. Prosseguindo, a técnica BMOPSO-CDR e suas híbridas utilizaram constantes C_1 e C_2 iguais a 2 e peso de inércia com decrescimento linear de 0,9 até 0,4. Por sua vez, a técnica BSMPSO (e híbridas) utilizaram peso de inércia aleatório entre 0,1 e 0,5 e constantes C_1 e C_2 aleatoriamente no intervalo entre 1,5 e 2,5. Além disso, todas as técnicas baseadas em PSO utilizaram velocidade máxima igual a 4 e velocidade mínima igual a -4. Esses valores utilizados foram os sugeridos pelos criadores das técnicas utilizadas como base no desenvolvimento das técnicas propostas.

Tanto as técnicas NSGA-II, SPEA2 e TAEA (e suas híbridas correspondentes) utilizaram taxa de cruzamento de 0,9. Além disso, as técnicas baseadas em SPEA2 utilizaram taxa de mutação de 0,006. Por sua vez a técnica TAEA e suas híbridas utilizaram uma taxa de probabilidade de 0,5 de selecionar indivíduos do arquivo externo CA ou DA. Por fim, O mecanismo HS das técnicas híbridas utilizou NGC e NIR iguais a 20, HMCR igual 0,9 e PAR igual a 0,03. Todas essas configurações são derivadas dos trabalhos que propuseram essas técnicas.

Por fim, todas as execuções das técnicas foram realizadas na mesma máquina com sistema operacional Windows 7 Home Premium, processador Intel core i7 2.2 GHz e memória RAM de 6 GB.

⁴Os dados coletados foram preliminarmente verificados e não atendiam à uma distribuição normal.

⁵Valor padrão utilizado na literatura de otimização multiobjetivo. Testes preliminares indicaram ser que o valor é adequado.

4.2 Resultados para Cada Subgrupo

Nesta seção são apresentadas as discussões dos resultados em cada subgrupo (conforme definido na seção 4.1.2) objetivando responder as questões de estudo 1 e 2. Tabelas apresentadas no Apêndice A contém os dados das médias, desvios padrão e valores p (referentes ao teste estatístico Kruskal-Wallis) para cada subgrupo e para cada programa do SIR. As médias destacadas em negrito indicam que a técnica correspondente foi considerada estatisticamente a melhor (ou igual à melhor) dentre do conjunto de técnicas comparadas. Já os valores p em negrito indicam quando o teste Kruskal-Wallis rejeitou a hipótese nula para o respectivo conjunto de técnicas, ou seja, indicam quando pelo menos duas das técnicas são estatisticamente diferentes entre si.

Também estão presentes no Apêndice A as tabelas que mostram os dados do teste estatístico de múltiplas comparações Steel-Dwass para os casos onde o valor p do teste Kruskal-Wallis foi menor que 0,05. Os dados dessa tabela se referem às comparações entre cada par de técnicas e quando o valor p é menor que 0,05 a hipótese nula é rejeitada e o respectivo par de técnicas é considerado diferente (nesses casos o valor p está destacado em negrito). Caso contrário, o par de técnicas é considerado estatisticamente igual.

Adicionalmente, as figuras dos boxplots servem como um auxílio para visualizar a distribuição dos dados de cada técnica. Embora essas figuras sejam referenciadas durante o decorrer do capítulo, todas discussões apresentadas basearam-se, quantitativamente, nos resultados dos testes estatísticos. Da mesma forma as figuras dos gráficos de convergência permitem uma visualização macro do comportamento de otimização e convergência das técnicas ao longo das avaliações das funções objetivo.

É importante destacar que ao longo deste trabalho sempre que for afirmado que uma técnica é melhor em uma determinada situação, essa técnica pode estar representando umas das seguintes situações: (1) a técnica apresentou o melhor valor (estatisticamente superior) observado ou (2) apresentou um valor estatisticamente igual ao melhor valor observado. Essas situações foram consideradas equivalentes nas comparações apresentadas neste capítulo.

4.2.1 Subgrupo 1 - BMOPSO-CDR

De acordo com os dados apresentados nas tabelas A.1, A.3, A.5, A.2, A.4 e A.6, assim como as figuras A.1, A.2 e A.3, verifica-se que nas métricas HV, GD e IGD as técnicas híbridas BMOPSO-CDR-FB, BMOPSO-CDR-1opt e BMOPSO-CDR-HS obtiveram melhores fronteiras de Pareto do que a técnica não híbrida BMOPSO-CDR para todos os programas SIR estudados. Em contrapartida, conforme visto nas tabelas A.7 e A.9 e nas figuras A.4 e A.5, nas métricas CVR e MS apenas a técnica híbrida BMOPSO-CDR-FB foi sempre melhor que a técnica não híbrida BMOPSO-CDR.

Na métrica CVR a técnica híbrida BMOPSO-CDR-1opt foi melhor que a não híbrida apenas para os programas *schedule*, *schedule 2*, *tcas* e *totinfo*, e a técnica BMOPSO-CDR-HS

apenas para o programa *tcas*. Para os outros programas tanto a técnica BMOPSO-CDR-1opt quanto a técnica BMOPSO-CDR-HS foram estatisticamente iguais à BMOPSO-CDR além de serem consideradas completamente dominadas pela $PF_{reference}$ ⁶. Já na métrica MS tanto a técnica BMOPSO-CDR-1opt quanto a técnica BMOPSO-CDR-HS foram superiores na maioria dos casos observados.

Com relação à comparação entre a técnica híbrida BMOPSO-CDR-AG e a técnica não híbrida BMOPSO-CDR, a primeira sempre obteve resultados inferiores nas métricas HV e IGD. Considerando a métrica GD a técnica BMOPSO-CDR-AG foi estatisticamente igual ou melhor na maioria dos casos, entretanto, ainda obteve resultados inferiores em 2 casos. Continuando, na métrica CVR ela foi estatisticamente igual para todos os casos e ambas completamente dominadas pela $PF_{reference}$. Por fim, na métrica MS ela foi sempre pior ou estatisticamente igual.

Outro fato observável nas tabelas supracitadas é que a técnica BMOPSO-CDR-FB apresentou resultados superiores a todas as outras para todos os programas do SIR nas métricas HV, IGD, CVR e MS, e na maioria dos programas na métrica GD.

É importante ressaltar que para o programa *grep* na métrica CVR o valor p do teste Kruskal-Wallis foi maior que 0,05 (como pode ser verificado na tabela A.7). Isso indica que todas as técnicas, nesse caso específico, foram consideradas estatisticamente iguais. De fato, todas elas tiveram média igual a 1, valor esse indicativo de que todas as fronteiras de Pareto retornadas pelas técnicas do subgrupo 1 na métrica CVR e programa *grep* foram completamente dominadas pela fronteira $PF_{reference}$.

Através dos gráficos de convergência A.26 até A.30 é observável que a técnica BMOPSO-CDR-FB apresentou um comportamento de convergência e otimização superior às demais técnicas (verificável através das curvas acentuadas de convergência para valores mais ótimos em estágios iniciais das avaliações das funções objetivo). Além disso, é interessante destacar que, para as métricas HV, GD e IGD, a técnica BMOPSO-CDR-HS demonstra uma capacidade de otimização superior às demais nas primeiras avaliações das funções objetivo, mas logo converge prematuramente e é ultrapassada pela técnica BMOPSO-CDR-FB.

Continuando, a técnica BMOPSO-CDR-1opt demonstra um comportamento instável em seu processo de otimização, pois as vezes apresenta uma curva acentuada de otimização em estágios mais tardios do processo de busca e as vezes se mantém com pouca evolução durante todo o processo. Por fim, as técnicas BMOPSO-CDR-AG e BMOPSO-CDR na maioria dos casos demonstram pouca evolução no decorrer das avaliações das funções objetivo, indicando dessa forma uma provável convergência prematura e incapacidade de sair de ótimos locais. Em adição, é importante destacar que, em geral, as técnicas convergiam em torno das 12.500 avaliações da função objetivo (exceto para a técnica BMOPSO-CDR-1opt e para todas as técnicas na métrica CVR).

Levando os dados em consideração, para a questão de estudo 1 a resposta é que apenas a técnica híbrida BMOPSO-CDR-FB foi melhor que a técnica não híbrida BMOPSO-CDR

⁶O conceito relativo ao $PF_{reference}$ foi explicado na seção 4.1.3.

Tabela 4.3: Quantidade de vezes que cada técnica foi considerada melhor (ou estatisticamente igual a melhor) para cada métrica - Subgrupo 1

	BMOPSO-CDR	BMOPSO-CDR-FB	BMOPSO-CDR-1opt	BMOPSO-CDR-AG	BMOPSO-CDR-HS
HV	0	12	1	0	0
GD	0	11	0	0	1
IGD	0	12	3	0	0
CVR	1	12	1	1	1
MS	0	12	1	0	0

em todas as métricas e para todos os programas do SIR. As técnicas BMOPSO-CDR-1opt e BMOPSO-CDR-HS foram melhores na maioria dos casos estudados. Em contrapartida, a técnica BMOPSO-CDR-AG foi pior ou igual na maioria das vezes, demonstrando assim que o mecanismo de busca local AG não trouxe (em geral) uma capacidade de evolução dos resultados para a técnica não híbrida. Entretanto, para as outras técnicas é possível considerar que na maioria dos casos os mecanismos de busca local utilizados para criação das técnicas híbridas de fato melhoraram os resultados.

Por fim, a tabela 4.3 apresenta um resumo da quantidade de vezes que cada técnica foi considerada melhor em cada métrica. Através desses dados, em adição aos resultados discutidos anteriormente para esse subgrupo, é possível afirmar que em resposta à questão de estudo 2 a melhor técnica é a BMOPSO-CDR-FB.

4.2.2 Subgrupo 2 - BSMP SO

As técnicas híbridas BSMP SO-FB, BSMP SO-1opt e BSMP SO-HS foram sempre superiores à técnica não híbrida BSMP SO (de acordo com as tabelas A.11, A.13, A.15, A.12, A.14, A.16 e figuras A.6, A.7, A.8) nas métricas HV, GD, IGD para os programas do SIR.

Com relação às métricas CVR e MS (tabelas A.17, A.19, A.18, A.20 e figuras A.9 e A.10) apenas a técnica híbrida BSMP SO-FB foi melhor que a técnica não híbrida BSMP SO para todos os casos (exceto para o programa *grep* na métrica CVR onde o teste de Kruskal-Wallis indicou que todas as técnicas eram iguais).

Continuando com a observação da métrica CVR, a técnica BSMP SO-1opt foi melhor que a técnica BSMP SO para os programas *schedule 2*, *tcas* e *totinfo* e igual para os outros programas. Por sua vez a técnica BSMP SO-HS somente foi melhor para o programa *tcas* e igual para os demais programas. Além disso, na métrica MS a técnica BSMP SO-1opt foi melhor para a maioria dos programas (igual para o programa *sed* e pior para os programas *gzip* e *replace*). Já a técnica BSMP SO-HS (também na métrica MS) foi pior para os programas *flex*, *gzip* e *sed*; igual para os programas *print tokens 2* e *space*; e melhor para os outros programas.

É importante destacar que, da mesma forma como aconteceu no Subgrupo 1, o teste de Kruskal-Wallis apresentou um valor p maior que 0,05 para o programa *grep* na métrica CVR e todas as fronteiras de Pareto das técnicas foram completamente dominadas pela $PF_{reference}$.

Comparando-se as técnicas BSMP SO-AG e BSMP SO verifica-se que para a métrica HV

a primeira foi pior que a segunda para todos os programas, exceto para o programa *tcas* onde foram consideradas estatisticamente iguais. Em contrapartida, para a métrica GD a primeira apresentou resultados melhores ou iguais para 10 dos 12 programas. Entretanto, para a métrica IGD a segunda obteve resultados superiores para todos os programas (exceto para o programa *tcas* onde foram consideradas estatisticamente iguais). Adicionalmente, ambas as técnicas obtiveram resultados equivalentes para todos os programas para a métrica CVR. Por fim, de acordo com os dados relacionados à métrica MS, a técnica BSMPSO-AG não foi melhor que a técnica BSMPSO para nenhum dos programas, sendo apenas igual em alguns casos.

De todas as técnicas mencionadas anteriormente, a técnica BSMPSO-FB apresentou resultados superiores aos das outras para a maioria dos casos estudados. De fato, ela foi a melhor técnica nas métricas HV, IGD, CVR e MS assim como melhor na maioria dos casos na métrica GD.

Finalmente, os gráficos de convergência A.31 até A.35 mostram a repetição dos mesmos padrões mencionados anteriormente no subgrupo 1 (com as devidas correlações entre os mecanismos de busca local utilizados na criação das técnicas híbridas).

Com relação à questão de estudo 1 a única técnica híbrida que sempre foi melhor (ou comparativamente igual como melhor) à técnica não híbrida BSMPSO foi a BSMPSO-FB. Já as técnicas BSMPSO-1opt e BSMPSO-HS foram melhores na maioria dos casos observados, embora as vezes iguais ou piores. Por fim, a técnica BSMPSO-AG demonstrou ser inferior ou igual para a maioria dos programas estudados.

Para a questão de estudo 2 os resultados mostraram claramente que a melhor técnica do Subgrupo 2 é a BSMPSO-FB. Como pode ser observado na tabela 4.4, apenas 2 vezes (para a métrica GD) ela não foi considerada como a melhor técnica.

Dos dados observados para o Subgrupo 2, o mecanismo de busca local FB de fato trouxe melhorias à técnica BSMPSO. Os mecanismos 1-opt e HS em geral são capazes de introduzir alguma evolução nos resultados da técnica BSMPSO. Por fim, o mecanismo AG não trouxe nenhuma melhoria significativa além de em vários casos deteriorar à capacidade de otimização da BSMPSO.

Tabela 4.4: Quantidade de vezes que cada técnica foi considerada melhor (ou estatisticamente igual a melhor) para cada métrica - Subgrupo 2

	BSMPSO	BSMPSO-FB	BSMPSO-1opt	BSMPSO-AG	BSMPSO-HS
HV	0	12	0	0	0
GD	0	10	1	0	1
IGD	0	12	1	0	0
CVR	1	12	1	1	1
MS	0	12	0	0	0

4.2.3 Subgrupo 3 - NSGA-II

Os resultados do Subgrupo 3 foram um pouco diferentes dos subgrupos anteriores, pois o mecanismo de busca local FB não melhorou em todas as situações estudadas a técnica não híbrida. De acordo com as tabelas A.21 até A.29, as tabelas A.22 até A.30 e as figuras A.11 até A.15, a técnica híbrida NSGA-II-FB foi melhor que a técnica não híbrida NSGA-II na maioria das métricas. Apenas no caso da métrica GD houve um caso em que a técnica NSGA-II-FB obteve um resultado inferior (programa *grep*) e um caso em que o resultado foi equivalente (programa *flex*). Sem contar a mesma situação que ocorreu nos subgrupos anteriores com respeito ao programa *grep* na métrica CVR onde o resultado do teste de Kruskal-Wallis não rejeitou a hipótese nula. Por sua vez, a técnica híbrida NSGA-II-HS foi melhor que a não híbrida para as métricas HV, GD, IGD e MS. No caso da métrica CVR ela foi equivalente para todos os programas (exceto para o *tcas* onde foi melhor).

Em sequência, a técnica híbrida NSGA-II-1opt obteve uma performance inconstante em comparação com a técnica não híbrida NSGA-II. Apenas na métrica MS ela obteve resultados melhores que a última para todos os programas. Além disso, na métrica CVR ela foi melhor, sempre melhor ou igual. Entretanto, nas métricas HV, GD e IGD ela obteve resultados as vezes melhores ou iguais ou piores. Já a técnica NSGA-II-AG obteve resultados em sua maioria iguais ou inferiores à técnica NSGA-II.

É possível destacar novamente que o teste de Kruskal-Wallis apresentou um valor p maior que 0,05 para o programa *grep* na métrica CVR e todas as fronteiras de Pareto das técnicas foram completamente dominadas pela $PF_{reference}$.

Ademais, embora a técnica NSGA-II-1opt tenha sido considerada a melhor em diversas situações, a técnica NSGA-II-FB foi a melhor na maior quantidade de vezes em todas as métricas observadas. Por fim, os gráficos de convergência A.36 até A.40 novamente reproduzem os mesmos padrões observados nos subgrupos 1 e 2.

Em resposta à questão de estudo 1 as técnicas híbridas NSGA-II-FB, NSGA-II-1opt e NSGA-II-HS foram melhores que a técnica não híbrida NSGA-II na grande maioria dos casos observados. Já a técnica híbrida NSGA-II-AG demonstrou ser pior ou igual na maioria das métricas observadas. Devido a isso é possível afirmar que o mecanismo de busca local AG nem sempre foi capaz de melhorar a técnica NSGA-II. Ao invés disso, em muitos casos esse mecanismo deteriorou a performance da técnica não híbrida.

É importante destacar também que nesse subgrupo, diferentemente dos subgrupos anteriores, houve mais casos (poucos) onde os mecanismos de busca local 1opt e HS não melhoraram (ou até mesmo deterioraram) os resultados da técnica não híbrida nas métricas estudadas. Isso indica que a técnica NSGA-II por si só apresenta resultados razoáveis e/ou que esses mecanismos de busca local de certa forma podem introduzir algum tipo de conflito com a capacidade de otimização da técnica NSGA-II. Essa verificação não está no escopo deste trabalho podendo ser considerada como um possível trabalho futuro.

Finalmente, a técnica que obteve melhores fronteiras de Pareto, de forma geral, de acordo com as métricas estudadas foi a técnica NSGA-II-FB (como pode ser visto na tabela 4.5). Portanto a técnica NSGA-II-FB é a resposta da questão de estudo 2 para o Subgrupo 3.

Tabela 4.5: Quantidade de vezes que cada técnica foi considerada melhor (ou estatisticamente igual a melhor) para cada métrica - Subgrupo 3

	NSGA-II	NSGA-II-FB	NSGA-II-1opt	NSGA-II-AG	NSGA-II-HS
HV	0	8	5	0	1
GD	0	8	5	0	3
IGD	0	11	3	0	2
CVR	1	9	4	1	1
MS	0	10	3	0	1

4.2.4 Subgrupo 4 - SPEA2

Os resultados deste subgrupo foram os mais divergentes comparados aos outros subgrupos. Em todas as métricas os resultados apresentados pela técnica não híbrida SPEA2 foram em sua grande maioria melhores que os resultados obtidos pelas técnicas híbridas SPEA2-1opt, SPEA2-HS e SPEA2-AG (segundo os dados das tabelas A.31 até A.39, das tabelas A.32 até A.40 e das figuras A.16 até A.20)

Apenas a técnica híbrida SPEA2-FB teve resultados comparáveis a técnica não híbrida. Na métrica HV a técnica SPEA2-FB foi superior à não híbrida em 4 programas, igual em 3 e pior em 5. Em seguida, na métrica GD, foi melhor em 3, igual em 3 e pior em 6 programas. Na métrica IGD foi melhor em 5, igual em 1 e pior em 6 programas. Continuando, na métrica CVR foi melhor em 6, igual em 3 e pior em 3 programas. Por fim, na métrica MS foi melhor em 8, igual em 2 e pior em 2 programas.

Com uma pequena margem a frente a técnica SPEA2-FB foi considerada como a melhor do subgrupo por aparecer um maior número de vezes como a melhor técnica na observação dos melhores valores obtidos nas métricas estudadas.

Em relação à capacidade de convergência das técnicas deste subgrupo observa-se (nas figuras A.41 até A.45) que nas métricas HV e GD, em geral, todas as técnicas apresentam curvas de otimização com comportamentos semelhantes (apenas com valores diferentes). Nas métricas IGD, CVR e MS a técnica SPEA2-FB destaca-se, em alguns casos, das demais técnicas por apresentar curvas de convergência acentuadas bem antes das outras.

Os resultados dos estudos envolvendo o Subgrupo 4 divergem dos outros subgrupos apresentados até o momento. Na grande maioria dos casos estudados os mecanismos de busca local 1opt, HS e AG deterioraram, ou não trouxeram nenhuma evolução aos resultados da técnica SPEA2. Entretanto, quando comparados os resultados da técnica híbrida SPEA2-FB com os resultados da técnica não híbrida SPEA2 é observável que em alguns casos um se sobressai sobre o outro.

Tabela 4.6: Quantidade de vezes que cada técnica foi considerada melhor (ou estatisticamente igual a melhor) para cada métrica - Subgrupo 4

	SPEA2	SPEA2-FB	SPEA2-1opt	SPEA2-AG	SPEA2-HS
HV	8	7	1	0	0
GD	9	6	1	0	0
IGD	7	6	1	0	0
CVR	6	9	0	0	0
MS	3	9	2	0	2

Como resposta à questão de estudo 1 considera-se que apenas a técnica híbrida SPEA2-FB foi capaz de aperfeiçoar a técnica não híbrida SPEA2. Embora não em todas as situações.

Nas métricas HV, GD, IGD e CVR os resultados das técnicas SPEA2-FB e SPEA2 foram quase similares (um superando o outro por uma pequena margem na quantidade de vezes), mas para a métrica MS verificou-se que a SPEA2-FB foi bem melhor que a SPEA2. Além disso, contando-se o número de vezes que cada técnica foi considerada melhor nas métricas (como pode ser visto na tabela 4.6) a técnica SPEA2-FB foi 37 vezes considerada como a melhor contra 33 vezes da técnica SPEA2. Devido a isso, a resposta da questão de estudo 2 foi considerada a técnica SPEA2-FB.

É importante ressaltar que a técnica SPEA2 demonstrou um comportamento bem estável e com bons resultados. A maioria dos mecanismos de busca local propostos não foram capazes de trazer uma melhoria significativa à esta técnica. De fato, a maioria desses mecanismos acabaram por deteriorar seus resultados. Levando isso em consideração, seria interessante que mais estudos que utilizassem essa técnica no problema de Seleção Multiobjetivo de Casos de Teste fossem realizados, pois além dessa técnica ter demonstrado bons resultados, a mesma é ainda pouco estudada no contexto deste problema. Esses novos estudos podem ser considerados como trabalhos futuros pois não estão no escopo do presente trabalho.

4.2.5 Subgrupo 5 - TAEA

Nos dados apresentados nas tabelas A.41 até A.49, nas tabelas A.42 até A.50 e nas figuras A.21 até A.25 é possível verificar que as técnicas híbridas TAEA-FB, TAEA-1opt e TAEA-HS sempre obtiveram resultados considerados superiores aos resultados da técnica não híbrida TAEA nas métricas HV, GD e IGD. Já na métrica CVR apenas a TAEA-FB foi melhor em todos os casos (exceto para o programa *grep* onde o teste de Kruskal-Wallis indicou que todas as técnicas do subgrupo eram equivalentes).

Continuando com a observação da métrica CVR, as técnicas TAEA-1opt e TAEA-HS foram iguais à técnica não híbrida (exceto para o programa *tcas* onde elas foram superiores). Por fim, com relação à métrica MS é observável que novamente as técnicas híbridas TAEA-FB, TAEA-1opt e TAEA-HS foram melhores em todos os casos, exceto para o programa *gzip* onde a técnica TAEA-1opt foi considerada equivalente. Levando isso em consideração, a técnica

TAEA-FB pode ser considerada a melhor deste subgrupo.

Na comparação entre as técnicas TAEA-AG e TAEA a primeira foi melhor ou igual em todos os casos nas métricas GD e MS e pior ou igual em todos os casos nas métricas HV, IGD e CVR. Esses resultados também foram observados nos outros subgrupos nas técnicas híbridas que utilizaram o mecanismo de busca local AG. Por fim, novamente os gráficos de convergência (figuras A.46 até A.50) mostram os mesmos padrões de comportamento observados nos primeiros subgrupos, onde a técnica híbrida com o mecanismo de busca local FB se destaca das demais em capacidade de convergência e otimização. Além disso, a técnica híbrida com mecanismo AG e a técnica não híbrida demonstram pouca evolução ao longo das avaliações das funções objetivo.

Em resposta à questão de estudo 1 a única técnica híbrida que sempre foi melhor (ou comparativamente igual como melhor) à técnica não híbrida TAEA foi a TAEA-FB. As técnicas TAEA-1opt e TAEA-HS foram melhores na maioria dos casos observados, embora as vezes iguais. Por fim, a técnica TAEA-AG demonstrou ser estatisticamente igual ou pior para a maioria dos programas estudados (em poucos casos melhor).

Com relação à questão de estudo 2 os resultados observados indicaram claramente que em todas as métricas a melhor técnica do Subgrupo 5 é a TAEA-FB. Como pode ser observado na tabela 4.7, apenas nas métricas HV e GD ela não foi a melhor em todos os casos.

Levando isso em consideração é possível afirmar que o mecanismo de busca local FB de fato foi capaz de melhorar a técnica TAEA. Adicionalmente, os resultados dos mecanismos 1-opt e HS na maioria das vezes foram capazes de demonstrar evolução nos resultados da técnica TAEA. Finalmente, o mecanismo AG não introduziu uma melhoria significativa, pois em raras situações o mecanismo obteve um resultado melhor. Em geral, o mecanismo obteve resultados iguais ou deteriorou os resultados em comparação com a técnica não híbrida.

Tabela 4.7: Quantidade de vezes que cada técnica foi considerada melhor (ou estatisticamente igual a melhor) para cada métrica - Subgrupo 5

	TAEA	TAEA-FB	TAEA-1opt	TAEA-AG	TAEA-HS
HV	0	11	1	0	1
GD	0	11	1	1	2
IGD	0	12	1	0	1
CVR	1	12	1	1	1
MS	0	12	1	0	1

4.2.6 Considerações Finais dos subgrupos

Levando em consideração as informações apresentadas anteriormente para cada subgrupo é possível constatar que o mecanismo de busca local FB se sobressaiu sobre os demais. Em uma visão macro esse mecanismo foi capaz de prover fronteiras de Pareto superiores às demais técnicas (principalmente se comparada às versões não híbridas). Além disso, os resultados dos

outros mecanismos de busca local variaram de acordo com a técnica não híbrida a qual foram combinados.

É possível destacar, também, os resultados inferiores obtidos pelo mecanismo de busca local AG nas técnicas híbridas. Na maioria dos casos esse mecanismo não trouxe nenhuma evolução aos resultados das técnicas não híbridas e/ou deteriorou os resultados. Por fim, as melhores técnicas consideradas para cada subgrupo foram: (1) BMOPSO-CDR-FB, (2) BSMPSO-FB, (3) NSGA-II-FB, (4) SPEA2-FB e (5) TAEA-FB. Por isso, essas técnicas serão comparadas no próximo capítulo no programa GUAVA de forma a responder às questões de estudos 3 e 4.

4.3 Resultados das Melhores Técnicas

Nesta seção as discussões referentes às comparações das melhores técnicas (provenientes de cada subgrupo) são apresentadas. As fronteiras de Pareto dessas técnicas foram comparadas (utilizando-se as métricas já apresentadas) no programa GUAVA. Além disso, utilizou-se uma nova métrica que dizia respeito ao tempo de execução (em segundos) que cada técnica levou para retornar o resultado final (fronteira de Pareto). No restante deste trabalho essa métrica foi referida (abreviada) como TP.

4.3.1 Comparação das Fronteiras de Pareto

Conforme pode ser observado nos dados da tabela 4.8, o teste de Kruskal-Wallis não rejeitou a hipótese nula nas métricas HV, GD, IGD e CVR. Isso significa que a performance das técnicas BMOPSO-CDR-FB, BSMPSO-FB, NSGA-II-FB, SPEA2-FB e TAEA-FB foram equivalentes para essas métricas. Já para as métricas MS e TP, o teste indicou que havia pelo menos duas técnicas diferentes entre si. Complementando com os dados da tabela B.1 foi possível verificar que na métrica MS as técnicas BMOPSO-CDR-FB e BSMPSO-FB obtiveram resultados superiores às demais, ou seja, foram capazes de encontrar fronteiras de Pareto com um maior espalhamento no espaço objetivo. Por fim, na métrica TP as técnicas BSMPSO-FB, NSGA-II e TAEA-FB foram melhores, ou seja, levaram menos tempo que as outras para retornar os resultados.

Além disso, com a adição das informações presentes nas figuras B.1 e B.2 verifica-se que as técnicas são muito similares entre si. Como todas utilizam o mecanismo de busca local FB esse comportamento já era esperado. A única exceção é a técnica SPEA2-FB que na métrica TP demonstrou uma performance muito dissimilar às outras levando quase o dobro do tempo para produzir as fronteiras de Pareto. Entretanto, se analisarmos a técnica não híbrida utilizada como base (SPEA2) verificamos que para manutenção do seu arquivo externo ela utiliza mais cálculos que as demais.

Finalmente, em resposta à questão de estudo 3, em conformidade com a tabela 4.9, a técnica BSMPSO-FB foi considerada a melhor, pois em todas as métricas observadas ela apresentou resultados superiores (ou igualmente superiores) às demais técnicas.

Tabela 4.8: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - para todas as métricas no programa GUAVA.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
HV	BMOPSO-CDR-FB	0,804324 (0,074171)	0,0564	GD	BMOPSO-CDR-FB	0,003959 (0,001438)	0,2860
	BSMPSO-FB	0,803500 (0,076044)			BSMPSO-FB	0,004009 (0,001364)	
	NSGA-II-FB	0,818107 (0,069340)			NSGA-II-FB	0,004394 (0,001851)	
	SPEA2-FB	0,828567 (0,063421)			SPEA2-FB	0,004144 (0,001816)	
	TAEA-FB	0,815798 (0,068876)			TAEA-FB	0,004273 (0,002047)	
IGD	BMOPSO-CDR-FB	0,008279 (0,005340)	0,4649	CVR	BMOPSO-CDR-FB	0,998050 (0,011099)	0,2813
	BSMPSO-FB	0,008334 (0,005210)			BSMPSO-FB	0,998324 (0,012150)	
	NSGA-II-FB	0,008504 (0,004451)			NSGA-II-FB	0,996131 (0,028363)	
	SPEA2-FB	0,008052 (0,004360)			SPEA2-FB	0,990963 (0,043829)	
	TAEA-FB	0,008709 (0,004386)			TAEA-FB	0,994515 (0,039244)	
MS	BMOPSO-CDR-FB	0,568851 (0,258288)	<,0001	TP	BMOPSO-CDR-FB	13,4453 (1,31313)	<,0001
	BSMPSO-FB	0,548162 (0,242822)			BSMPSO-FB	12,7815 (1,09954)	
	NSGA-II-FB	0,455931 (0,198138)			NSGA-II-FB	13,1162 (0,88567)	
	SPEA2-FB	0,464235 (0,200923)			SPEA2-FB	21,2920 (1,58368)	
	TAEA-FB	0,454704 (0,185915)			TAEA-FB	12,8760 (1,05489)	

Tabela 4.9: Quantidade de vezes que cada técnica foi considerada melhor (ou estatisticamente igual a melhor) para todas as métricas - Melhores Técnicas

	BMOPSO-CDR-FB	BSMPSO-FB	NSGA-II-FB	SPEA2-FB	TAEA-FB
Todas as métricas	5	6	5	4	5

4.3.2 Comparação da Capacidade de Detecção de Falhas

Como dito anteriormente, na falta de informações sobre as falhas reais, utilizou-se da técnica de Testes de Mutação para possibilitar a comparação das técnicas com relação à capacidade de detecção de falhas. Para tal, a ferramenta PITEST⁷ (COLES, 2015) foi utilizada para introdução dessas falhas. Ao todo o PITEST inseriu 6.449 falhas no código fonte do GUAVA das quais 1.073 foram capazes de serem detectadas pela suíte utilizada neste trabalho. Portanto, somente essas últimas foram consideradas para medir a capacidade de detecção de falhas das técnicas.

Num ambiente real de desenvolvimento de software essas 1.073 falhas provavelmente não ocorreriam todas ao mesmo momento. De acordo com Mirarab, Esfahani e Tahvildari (2012)

⁷Disponível no site <http://pitest.org/>

cada ambiente de desenvolvimento tem uma probabilidade de ocorrência e distribuição de falhas no código fonte. De forma a tentar aproximar os experimentos realizados neste trabalho de um contexto real de desenvolvimento de software, foi assumido um modelo de falhas, similar ao utilizado por Mirarab, Esfahani e Tahvildari (2012), onde no mínimo 1 e no máximo 15 falhas (das 1.073) tinham probabilidade de ocorrer ao mesmo tempo. Foram criados 100 grupos de falhas considerando essa probabilidade e cada um desses grupos foi associado à cada execução das técnicas (100 execuções no total).

Para cada solução presente em cada fronteira de Pareto retornada pelas técnicas calculou-se o percentual de detecção de falhas, ou seja, para cada solução de cada fronteira de Pareto associou-se um valor que representa o percentual de falhas encontradas por aquela solução para o respectivo grupo de falhas associado.

Não faz parte do objetivo deste trabalho a escolha de uma única solução presente nas fronteiras de Pareto. Portanto, como comparar as fronteiras de Pareto com relação a capacidade de detecção de falhas? Neste trabalho foi escolhida a abordagem de criar novas fronteiras de Pareto relacionando a capacidade de detecção de falhas a cada um dos objetivos utilizados. Por exemplo, para cada fronteira de Pareto duas novas fronteiras de Pareto foram criadas: (1) fronteira de Pareto relacionando a Cobertura de Requisitos com o Percentual de Detecção de Falhas, (2) fronteira relacionando o Custo de Execução com o Percentual de Detecção de Falhas. Através dessas duas novas fronteiras foi possível utilizar as mesmas métricas utilizadas anteriormente para comparar as técnicas em relação a capacidade de detecção de falhas.

As tabelas 4.10 e B.3 e a Figura B.3 apresentam os resultados das comparações relacionando a cobertura de requisitos com o percentual de detecção de falhas. Tanto a técnica BMOPSO-CDR-FB quanto a técnica BSMPSO-FB foram superiores às outras em todas as métricas. A técnica NSGA-II-FB foi comparativamente igual a elas nas métricas HV, GD e IGD. Por sua vez a técnica SPEA2-FB foi igualmente a melhor apenas para a métrica MS e, por fim, a técnica TAEA-FB não foi uma das melhores em nenhuma das métricas.

Em adição, as tabelas 4.11 e B.3 e a Figura B.4 apresentam os dados relativos às comparações relacionando os custos de execução e o percentual de falhas detectadas. Como pode ser observado, o teste de Kruskal-Wallis não rejeitou a hipótese nula para as métricas HV, GD e CVR, portanto nessas métricas todas as técnicas foram consideradas equivalentes. Na métrica IGD todas as técnicas (menos a TAEA-FB) foram consideradas como as melhores e na métrica MS apenas as técnicas BMOPSO-CDR-FB e BSMPSO-FB foram consideradas as melhores.

Finalmente, com relação à capacidade de detecção de falhas (questão de estudo 4) é possível ver na tabela 4.12 que ambas as técnicas BMOPSO-CDR-FB e BSMPSO-FB obtiveram os melhores resultados em todos os casos. Isto é, ambas sempre foram consideradas como melhores.

Tabela 4.10: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - para as métricas no programa GUAVA - Dados Cobertura x Falhas.

média (desv. pad.)			Kruskal-Wallis (valor p)	média (desv. pad.)			Kruskal-Wallis (valor p)
HV	BMOPSO-CDR-FB	0,886008 (0,068421)	0,0007	GD	BMOPSO-CDR-FB	0,105310 (0,054154)	0,0006
	BSMPSO-FB	0,892479 (0,066369)			BSMPSO-FB	0,097965 (0,053129)	
	NSGA-II-FB	0,880451 (0,087065)			NSGA-II-FB	0,111735 (0,076962)	
	SPEA2-FB	0,854760 (0,094283)			SPEA2-FB	0,134765 (0,081083)	
	TAEA-FB	0,869565 (0,085912)			TAEA-FB	0,121410 (0,074054)	
IGD	BMOPSO-CDR-FB	0,103988 (0,056817)	0,0008	CVR	BMOPSO-CDR-FB	0,90000 (0,301511)	<,0001
	BSMPSO-FB	0,097091 (0,053891)			BSMPSO-FB	0,90000 (0,301511)	
	NSGA-II-FB	0,110256 (0,077645)			NSGA-II-FB	0,99000 (0,100000)	
	SPEA2-FB	0,133481 (0,084667)			SPEA2-FB	1,00000 (0,000000)	
	TAEA-FB	0,121557 (0,076005)			TAEA-FB	1,00000 (0,000000)	
MS	média (desv. pad.)		Kruskal-Wallis (valor p)				
	BMOPSO-CDR-FB	0,050789 (0,075261)	0,0003				
	BSMPSO-FB	0,039688 (0,066194)					
	NSGA-II-FB	0,018784 (0,056763)					
	SPEA2-FB	0,035809 (0,065655)					
	TAEA-FB	0,025225 (0,062093)					

Tabela 4.11: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - para as métricas no programa GUAVA - Dados Custo x Falhas.

média (desv. pad.)			Kruskal-Wallis (valor p)	média (desv. pad.)			Kruskal-Wallis (valor p)
HV	BMOPSO-CDR-FB	0,755523 (0,095200)	0,5894	GD	BMOPSO-CDR-FB	0,071271 (0,053693)	0,5728
	BSMPSO-FB	0,753321 (0,088172)			BSMPSO-FB	0,075169 (0,051099)	
	NSGA-II-FB	0,751221 (0,085888)			NSGA-II-FB	0,065669 (0,044145)	
	SPEA2-FB	0,740005 (0,086780)			SPEA2-FB	0,068118 (0,047065)	
	TAEA-FB	0,739668 (0,084997)			TAEA-FB	0,074336 (0,048028)	
IGD	BMOPSO-CDR-FB	0,068512 (0,038404)	0,0151	CVR	BMOPSO-CDR-FB	0,99181 (0,045150)	0,2169
	BSMPSO-FB	0,072121 (0,038915)			BSMPSO-FB	1,00000 (0,000000)	
	NSGA-II-FB	0,077536 (0,031001)			NSGA-II-FB	0,99500 (0,037117)	
	SPEA2-FB	0,076371 (0,027748)			SPEA2-FB	0,99750 (0,025000)	
	TAEA-FB	0,079531 (0,029028)			TAEA-FB	0,99500 (0,050000)	
MS	BMOPSO-CDR-FB	0,389791 (0,235557)	<,0001				
	BSMPSO-FB	0,379746 (0,245357)					
	NSGA-II-FB	0,269325 (0,187677)					
	SPEA2-FB	0,263457 (0,162811)					
	TAEA-FB	0,271245 (0,186351)					

Tabela 4.12: Quantidade de vezes que cada técnica foi considerada melhor (ou estatisticamente igual a melhor) para todas as métricas nas comparações relativas à capacidade de detecção de falhas

	BMOPSO-CDR-FB	BSMPSO-FB	NSGA-II-FB	SPEA2-FB	TAEA-FB
Cobertura de Requisitos x Percentual de Detecção de Falhas (todas as métricas)	5	5	3	1	0
Custo de Execução x Percentual de Detecção de Falhas (todas as métricas)	5	5	4	4	3

4.3.3 Considerações Finais das Melhores Técnicas

Nos resultados das comparações relacionadas apenas às fronteiras de Pareto retornadas pelas técnicas foi observado que embora em muitos casos o teste de Kruskal-Wallis indicasse que as técnicas eram equivalentes, a única técnica que sempre esteve como uma das melhores em todas as métricas foi a BSMPSO-FB.

Adicionalmente, para os resultados relativos à capacidade de detecção de falhas os resultados mostraram que ambas as técnicas BSMPSO-FB e BMOPSO-CDR foram melhores em todos os casos observados.

Portanto, como em ambas as comparações houve predominância da técnica BSMPSO-FB, a mesma foi considerada como a melhor técnica dentre as melhores técnicas comparadas nesta seção e foi utilizada como base para o estudo com restrições apresentado na próxima seção.

4.4 Resultados do Estudo com Restrições

Nesta seção são apresentados os resultados dos estudos comparativos entre as técnicas em um ambiente com restrições. Como mencionado na seção 4.1.2, quatro cenários foram propostos para simular situações reais de restrições em ambientes de testes de forma a possibilitar a comparação entre as técnicas. As técnicas comparadas nesta seção foram: BSMPSO-FB (escolhida como a melhor técnica na seção anterior), BSMPSO-FB-C e BSMPSO-FB-F (ambas baseadas na primeira e apresentadas na seção 3.2).

É importante ressaltar que das fronteiras de Pareto resultantes da técnica BSMPSO-FB para o programa GUAVA (na seção anterior) foram retiradas as soluções não dominadas que não atendiam às restrições em cada um dos cenários propostos. Isso foi feito de forma a permitir as comparações entre as técnicas que são apresentadas a seguir.

4.4.1 Comparação das Fronteiras de Pareto

Conforme pode ser visto nas tabelas 4.13 e C.1 e na Figura C.1, a técnica BSMPSO-FB obteve melhores fronteiras de Pareto do que as técnicas CBSMPSO-FB-C e CBSMPSO-FB-F em todas as métricas no cenário de Cobertura de Requisitos $\geq 50\%$. Neste cenário ambas as técnicas com tratamento de restrições foram consideradas estatisticamente iguais nas métricas HV, GD, IGD, CVR e MS. Na métrica TP os resultados indicaram que a técnica CBSMPSO-FB-C era mais rápida do que a CBSMPSO-FB-F para retornar as fronteiras de Pareto finais.

Em relação ao cenário com restrição de Custo de Execução $\leq 50\%$ é observável (através das tabelas 4.14 e C.2 e Figura C.2) que a mesma situação anterior se repetiu. A técnica BSMPSO-FB novamente obteve melhores fronteiras de Pareto que as outras técnicas em todas as métricas. Além disso, as técnicas CBSMPSO-FB-C e CBSMPSO-FB-F foram equivalentes em todas as métricas.

Considerando o cenário crítico de Cobertura de Requisitos $\geq 90\%$ (tabelas 4.15 e C.3 e Figura C.3), na métrica GD o teste de Kruskal-Wallis não foi capaz de rejeitar a hipótese nula e todas as técnicas foram consideradas equivalentes. Nas métricas HV, IGD, CVR e MS ambas técnicas BSMPSO-FB e CBSMPSO-FB-C foram consideradas as melhores. Apenas na métrica TP que a técnica BSMPSO-FB foi considerada a melhor isoladamente. Além disso, com exceção da métrica GD, a técnica CBSMPSO-FB-C foi melhor que a CBSMPSO-FB-F em todas as métricas deste cenário.

Dentre os cenários aqui estudados, unicamente no cenário crítico de Custo de Execução $\leq 10\%$, as técnicas BSMPSO-FB e CBSMPSO-FB-F não foram capazes de encontrar soluções em todas as 100 execuções. A técnica BSMPSO-FB apresentou fronteiras de Pareto com ao menos uma solução em 53 execuções, já a técnica CBSMPSO-F em apenas 23.

As comparações estatísticas apresentadas nas tabelas 4.16 e C.4 utilizaram informações referentes apenas às ocasiões onde as técnicas foram capazes de encontrar soluções, pois ambos testes estatísticos podem ser utilizados em comparações envolvendo amostras com tamanhos diferentes. Através dos dados apresentados nessas tabelas (com adição da Figura C.4) verificou-se que nas métricas HV, GD, IGD, MS e TP a técnica BSMPSO-FB apresentou melhores fronteiras de Pareto que às outras técnicas. Na métrica CVR as técnicas BSMPSO-FB e CBSMPSO-FB-F foram as melhores. Adicionalmente, as técnicas CBSMPSO-FB-C e CBSMPSO-FB-F foram equivalentes na maioria das métricas.

Finalmente, em resposta à questão de estudo 5 e através dos resultados discutidos anteriormente, foi possível afirmar que a técnica BSMPSO-FB era capaz de obter melhores (ou igualmente melhores) fronteiras de Pareto que as demais técnicas mesmo sem ter um mecanismo explícito de tratamento de restrições (conforme pode ser visto na tabela 4.17). Isso demonstrou que a técnica foi sempre capaz de encontrar soluções mais otimizadas no espaço de busca objetivo.

Outro aspecto importante é que, nos cenários aqui simulados, a introdução do mecanismo de tratamento de restrições não foi capaz de produzir resultados melhores que os da técnica sem o mecanismo de tratamento de restrições. Entretanto, no cenário crítico de Custo de Execução $\leq 10\%$ nem sempre a técnica BSMPSO-FB foi capaz de encontrar uma solução que atendesse à restrição, já a técnica CBSMPSO-FB-C sempre foi capaz de encontrar soluções para esse cenário.

Portanto, estudos que procurem aumentar a diversidade de soluções da técnica BSMPSO-FB podem ser realizados em trabalhos futuros. Além disso, as técnicas CBSMPSO-FB-C e CBSMPSO-FB-F foram quase sempre equivalentes, com exceção do cenário de Cobertura de

Tabela 4.13: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - para todas as métricas no programa GUAVA no cenário de Cobertura de Requisitos $\geq 50\%$.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
HV	BSMPSO-FB	0,797997 (0,072208)	<,0001	GD	BSMPSO-FB	0,002436 (0,001422)	<,0001
	CBSMPSO-FB-C	0,772341 (0,064320)			CBSMPSO-FB-C	0,003522 (0,002648)	
	CBSMPSO-FB-F	0,760090 (0,064402)			CBSMPSO-FB-F	0,004014 (0,003817)	
IGD	BSMPSO-FB	0,005743 (0,004731)	<,0001	CVR	BSMPSO-FB	0,986740 (0,045357)	0,0035
	CBSMPSO-FB-C	0,006631 (0,004626)			CBSMPSO-FB-C	0,995063 (0,019088)	
	CBSMPSO-FB-F	0,007680 (0,004792)			CBSMPSO-FB-F	0,995839 (0,026531)	
MS	BSMPSO-FB	0,470091 (0,174710)	0,0005	TP	BSMPSO-FB	12,7815 (1,09954)	<,0001
	CBSMPSO-FB-C	0,396352 (0,137708)			CBSMPSO-FB-C	19,2193 (2,16658)	
	CBSMPSO-FB-F	0,391498 (0,157152)			CBSMPSO-FB-F	20,1738 (1,94259)	

Tabela 4.14: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - para todas as métricas no programa GUAVA no cenário de Custo de Execução $\leq 50\%$.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
HV	BSMPSO-FB	0,802633 (0,075780)	<,0001	GD	BSMPSO-FB	0,001976 (0,000643)	<,0001
	CBSMPSO-FB-C	0,765508 (0,064843)			CBSMPSO-FB-C	0,002732 (0,001026)	
	CBSMPSO-FB-F	0,754054 (0,076538)			CBSMPSO-FB-F	0,005949 (0,008575)	
IGD	BSMPSO-FB	0,007898 (0,006452)	<,0001	CVR	BSMPSO-FB	0,985398 (0,054656)	0,0009
	CBSMPSO-FB-C	0,011306 (0,004698)			CBSMPSO-FB-C	0,994837 (0,021099)	
	CBSMPSO-FB-F	0,011642 (0,004690)			CBSMPSO-FB-F	0,995292 (0,023715)	
MS	BSMPSO-FB	0,515428 (0,232410)	<,0001	TP	BSMPSO-FB	12,7815 (1,09954)	<,0001
	CBSMPSO-FB-C	0,340009 (0,119005)			CBSMPSO-FB-C	19,3283 (2,24656)	
	CBSMPSO-FB-F	0,317250 (0,128689)			CBSMPSO-FB-F	20,6959 (3,78729)	

Tabela 4.15: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - para todas as métricas no programa GUAVA no cenário de Cobertura de Requisitos $\geq 90\%$.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
HV	BSMPSO-FB	0,710386 (0,043232)	<,0001	GD	BSMPSO-FB	0,009607 (0,009889)	0,0670
	CBSMPSO-FB-C	0,737282 (0,072386)			CBSMPSO-FB-C	0,006619 (0,005105)	
	CBSMPSO-FB-F	0,682903 (0,037212)			CBSMPSO-FB-F	0,012666 (0,012687)	
IGD	BSMPSO-FB	0,005704 (0,002114)	<,0001	CVR	BSMPSO-FB	0,99000 (0,044465)	0,0071
	CBSMPSO-FB-C	0,006265 (0,002281)			CBSMPSO-FB-C	0,98888 (0,040930)	
	CBSMPSO-FB-F	0,007070 (0,001806)			CBSMPSO-FB-F	1,00000 (0,000000)	
MS	BSMPSO-FB	0,245536 (0,093292)	0,0008	TP	BSMPSO-FB	12,7815 (1,09954)	<,0001
	CBSMPSO-FB-C	0,281534 (0,117844)			CBSMPSO-FB-C	20,6690 (0,82157)	
	CBSMPSO-FB-F	0,228023 (0,095247)			CBSMPSO-FB-F	23,6096 (2,90414)	

Tabela 4.16: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - para todas as métricas no programa GUAVA no cenário de Custo de Execução $\leq 10\%$.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
HV	BSMPSO-FB	0,607283 (0,021237)	<,0001	GD	BSMPSO-FB	0,001563 (0,001229)	<,0001
	CBSMPSO-FB-C	0,581829 (0,021025)			CBSMPSO-FB-C	0,007392 (0,006935)	
	CBSMPSO-FB-F	0,576679 (0,022918)			CBSMPSO-FB-F	0,004779 (0,004473)	
IGD	BSMPSO-FB	0,003879 (0,004372)	<,0001	CVR	BSMPSO-FB	0,97802 (0,123939)	0,0064
	CBSMPSO-FB-C	0,016160 (0,001651)			CBSMPSO-FB-C	0,98424 (0,103564)	
	CBSMPSO-FB-F	0,015098 (0,001542)			CBSMPSO-FB-F	1,00000 (0,000000)	
MS	BSMPSO-FB	0,296375 (0,104707)	<,0001	TP	BSMPSO-FB	12,7815 (1,09954)	<,0001
	CBSMPSO-FB-C	0,025617 (0,025810)			CBSMPSO-FB-C	18,6254 (2,28207)	
	CBSMPSO-FB-F	0,035859 (0,021938)			CBSMPSO-FB-F	24,3182 (2,62755)	

Tabela 4.17: Quantidade de vezes que cada técnica foi considerada melhor (ou estatisticamente igual a melhor) para todas as métricas - Estudo com Restrições

	BSMPSO-FB	CBSMPSO-FB-C	CBSMPSO-FB-F
Todas as métricas em todos os cenários	24	5	2

Requisitos $\geq 90\%$ onde a primeira foi em geral melhor que a segunda.

4.4.2 Comparação da Capacidade de Detecção de Falhas

A capacidade de detecção de falhas das técnicas no estudo de restrições foi feita através da criação de fronteiras de Pareto de forma similar à feita na comparação entre as melhores técnicas (seção 4.3).

Conforme pode ser visto nas tabelas 4.18 e C.5, para o cenário de Cobertura de Requisitos $\geq 50\%$ na relação entre Cobertura de Requisitos e Percentual de Detecção de Falhas, o teste de Kruskal-Wallis não rejeitou a hipótese nula nas métricas CVR e MS, portanto as técnicas BSMPSO-FB, CBSMPSO-FB-C e CBSMPSO-FB-F foram consideradas equivalentes nessas métricas. Já nas métricas HV, GD e IGD as técnicas BSMPSO-FB e CBSMPSO-FB-F foram consideradas as melhores. Já para o cenário de Custo de Execução $\leq 50\%$ o teste de Kruskal-Wallis indicou que as técnicas eram equivalentes em todas as métricas (tabela 4.19).

Nos cenários críticos de Cobertura de Requisitos $\geq 90\%$ e Custo de Execução $\leq 10\%$ (tabelas 4.20, 4.21 e C.6), na relação entre Cobertura de Requisitos e Percentual de Detecção de Falhas, o teste de Kruskal-Wallis somente rejeitou a hipótese nula na métrica GD do primeiro cenário, onde as técnicas BSMPSO-FB e CBSMPSO-FB-F foram consideradas as melhores.

É importante ressaltar que nos, casos supracitados, as técnicas BSMPSO-FB e CBSMPSO-FB-F foram sempre equivalentes e consideradas como melhores para todos os cenários e métricas. Além disso, comparando-se apenas as técnicas CBSMPSO-FB-C e CBSMPSO-FB-F a segunda predominou sobre a primeira pois foi melhor ou igual em todos os casos.

Os dados referentes à relação entre Custo de Execução e Percentual de Detecção de Falhas (tabelas 4.22 até 4.25 e tabelas C.7 até C.10) mostram que nenhuma técnica foi a melhor em todos os cenários e métricas. Apenas na métrica MS no cenário de Custo de Execução $\leq 50\%$ a técnica BSMPSO-FB não foi considerada como uma das melhores. Em todos os outros casos ela foi a melhor ou uma das melhores.

Já comparando-se as técnicas CBSMPSO-FB-C e CBSMPSO-FB-F é observável que, diferentemente do constatado anteriormente, houve um caso onde a técnica CBSMPSO-FB-C foi melhor que a outra (métrica MS cenário de Cobertura de Requisitos $\geq 90\%$) e um caso onde a técnica CBSMPSO-FB-F foi melhor que a outra (métrica IGD e cenário de Custo de Execução $\leq 10\%$)

Embora através das discussões apresentadas anteriormente seja possível ver que, nos cenários de restrições aqui propostos, a capacidade de detecção de falhas das técnicas foram muitas vezes equivalentes, a técnica BSMPSO-FB foi capaz de superior às outras (conforme

Tabela 4.18: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - para as métricas no programa GUAVA - Dados Cobertura x Falhas no cenário de Cobertura de Requisitos $\geq 50\%$.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
HV	BSMPSO-FB	0,892479 (0,066369)	0,0063	GD	BSMPSO-FB	0,097965 (0,053129)	0,0093
	CBSMPSO-FB-C	0,866224 (0,078231)			CBSMPSO-FB-C	0,116953 (0,065582)	
	CBSMPSO-FB-F	0,880518 (0,083042)			CBSMPSO-FB-F	0,111536 (0,073659)	
IGD	BSMPSO-FB	0,097091 (0,053891)	0,0048	CVR	BSMPSO-FB	0,900000 (0,301511)	0,4100
	CBSMPSO-FB-C	0,117459 (0,064791)			CBSMPSO-FB-C	0,920000 (0,272660)	
	CBSMPSO-FB-F	0,109099 (0,072856)			CBSMPSO-FB-F	0,950000 (0,219043)	
		média (desv. pad.)		Kruskal-Wallis (valor p)			
MS	BSMPSO-FB	0,039688 (0,066194)	0,9015				
	CBSMPSO-FB-C	0,039749 (0,065911)					
	CBSMPSO-FB-F	0,048463 (0,083114)					

pode ser visto na tabela 4.26). Então, a resposta para a questão de estudo 6 seria que a técnica BSMPSO-FB apresenta comportamento de detecção de falhas equivalente na maioria dos casos e superior em outros.

4.4.3 Considerações Finais Estudo com Restrições

Nos resultados das comparações relacionadas apenas às fronteiras de Pareto retornadas pelas técnicas foi observado que a técnica BSMOPSO-FB foi a única que sempre esteve como uma das melhores em todas as métricas.

Adicionalmente, para os resultados relativos à capacidade de detecção de falhas das técnicas, os resultados mostraram que embora em muitos casos o teste de Kruskal-Wallis indicasse que as técnicas fossem equivalentes, a técnica que sempre esteve como uma das melhores em todas as métricas (menos em um caso) foi a BSMPSO-FB.

Como em ambas as comparações houve predominância da técnica BSMPSO-FB, a mesma foi considerada como a melhor técnica. Além disso a técnica demonstrou que, embora não tenha um mecanismo explícito de tratamento de restrições, era capaz de produzir fronteiras de Pareto com diversas soluções que poderiam atender às restrições do ambiente de teste. Além disso, nos cenários aqui simulados, a introdução do mecanismo de tratamento de restrições não foi capaz de produzir resultados melhores que os da técnica sem esse mecanismo.

É importante ressaltar que apenas no cenário crítico proposto de Custo de Execução $\leq 10\%$ a técnica BSMPSO-FB não foi capaz de encontrar soluções em aproximadamente 50% das execuções. Portanto, essa é uma falha evidente da técnica e futuros trabalhos podem ser realizados de forma a propor melhorias em ambientes com restrições.

Tabela 4.19: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - para as métricas no programa GUAVA - Dados Cobertura x Falhas no cenário de Custo de Execução <= 50%.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
HV	BSMPSO-FB	0,881567 (0,074528)	0,3936	GD	BSMPSO-FB	0,107586 (0,060944)	0,1556
	CBSMPSO-FB-C	0,874343 (0,080787)			CBSMPSO-FB-C	0,110888 (0,063782)	
	CBSMPSO-FB-F	0,871585 (0,074983)			CBSMPSO-FB-F	0,116209 (0,055282)	
IGD	BSMPSO-FB	0,106347 (0,062178)	0,2976	CVR	BSMPSO-FB	0,96000 (0,196946)	0,1308
	CBSMPSO-FB-C	0,112275 (0,065270)			CBSMPSO-FB-C	0,98000 (0,140705)	
	CBSMPSO-FB-F	0,113626 (0,058486)			CBSMPSO-FB-F	1,00000 (0,000000)	
		média (desv. pad.)		Kruskal-Wallis (valor p)			
MS	BSMPSO-FB	0,041928 (0,068704)	0,1349				
	CBSMPSO-FB-C	0,044674 (0,071974)					
	CBSMPSO-FB-F	0,065303 (0,086669)					

Tabela 4.20: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - para as métricas no programa GUAVA - Dados Cobertura x Falhas no cenário de Cobertura de Requisitos >= 90%.

			média (desv. pad.)	Kruskal-Wallis (valor p)				média (desv. pad.)	Kruskal-Wallis (valor p)
HV	BSMPSO-FB		0,891806 (0,065703)	0,0963	GD	BSMPSO-FB		0,098004 (0,053112)	0,0306
	CBSMPSO-FB-C		0,870394 (0,089349)			CBSMPSO-FB-C		0,121310 (0,076509)	
	CBSMPSO-FB-F		0,890430 (0,072899)			CBSMPSO-FB-F		0,105379 (0,060673)	
IGD	BSMPSO-FB		0,097091 (0,053891)	0,0831	CVR	BSMPSO-FB		0,900000 (0,301511)	0,0691
	CBSMPSO-FB-C		0,118560 (0,077855)			CBSMPSO-FB-C		0,960000 (0,196946)	
	CBSMPSO-FB-F		0,103032 (0,059038)			CBSMPSO-FB-F		0,970000 (0,171447)	
		média (desv. pad.)		Kruskal-Wallis (valor p)					
MS	BSMPSO-FB		0,038228 (0,065430)	0,1026					
	CBSMPSO-FB-C		0,043132 (0,075907)						
	CBSMPSO-FB-F		0,058988 (0,080033)						

Tabela 4.21: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - para as métricas no programa GUAVA - Dados Cobertura x Falhas no cenário de Custo de Execução <= 10%.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
HV	BSMPSO-FB	0,417304 (0,056528)	0,1289	GD	BSMPSO-FB	0,135434 (0,069687)	0,1356
	CBSMPSO-FB-C	0,434402 (0,076443)			CBSMPSO-FB-C	0,119843 (0,089741)	
	CBSMPSO-FB-F	0,404037 (0,070388)			CBSMPSO-FB-F	0,153393 (0,083021)	
IGD	BSMPSO-FB	0,122280 (0,050633)	0,1341	CVR	BSMPSO-FB	1,00000 (0,000000)	0,4656
	CBSMPSO-FB-C	0,110293 (0,064976)			CBSMPSO-FB-C	0,98000 (0,140705)	
	CBSMPSO-FB-F	0,134710 (0,060005)			CBSMPSO-FB-F	1,00000 (0,000000)	
		média (desv. pad.)		Kruskal-Wallis (valor p)			
MS	BSMPSO-FB	0 (0)	1,0000				
	CBSMPSO-FB-C	0 (0)					
	CBSMPSO-FB-F	0 (0)					

Tabela 4.22: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - para as métricas no programa GUAVA - Dados Custo x Falhas no cenário de Cobertura de Requisitos >= 50%.

				média (desv. pad.)		Kruskal-Wallis (valor p)	
HV	BSMPSO-FB	0,746317 (0,082981)	0,0065	GD	BSMPSO-FB	0,074015 (0,046456)	0,0144
	CBSMPSO-FB-C	0,716458 (0,079748)			CBSMPSO-FB-C	0,087672 (0,048287)	
	CBSMPSO-FB-F	0,709494 (0,088556)			CBSMPSO-FB-F	0,093659 (0,052363)	
IGD	BSMPSO-FB	0,062471 (0,030652)	0,0029	CVR	BSMPSO-FB	0,989667 (0,062799)	0,6014
	CBSMPSO-FB-C	0,068537 (0,026054)			CBSMPSO-FB-C	0,994167 (0,041464)	
	CBSMPSO-FB-F	0,076152 (0,028445)			CBSMPSO-FB-F	0,996667 (0,033333)	
				média (desv. pad.)		Kruskal-Wallis (valor p)	
MS	BSMPSO-FB	0,321418 (0,197484)	0,0003				
	CBSMPSO-FB-C	0,248914 (0,150058)					
	CBSMPSO-FB-F	0,212069 (0,165469)					

Tabela 4.23: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - para as métricas no programa GUAVA - Dados Custo x Falhas no cenário de Custo de Execução $\leq 50\%$.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
HV	BSMPSO-FB	0,750143 (0,090741)	0,0028	GD	BSMPSO-FB	0,068104 (0,047534)	0,0011
	CBSMPSO-FB-C	0,714877 (0,080006)			CBSMPSO-FB-C	0,088914 (0,046484)	
	CBSMPSO-FB-F	0,711611 (0,088255)			CBSMPSO-FB-F	0,091373 (0,049819)	
IGD	BSMPSO-FB	0,072020 (0,039942)	<,0001	CVR	BSMPSO-FB	0,987698 (0,051599)	0,0178
	CBSMPSO-FB-C	0,094564 (0,026349)			CBSMPSO-FB-C	0,995000 (0,050000)	
	CBSMPSO-FB-F	0,095403 (0,025592)			CBSMPSO-FB-F	0,997500 (0,025000)	
		média (desv. pad.)		Kruskal-Wallis (valor p)			
MS	BSMPSO-FB	0,072020 (0,039942)	<,0001				
	CBSMPSO-FB-C	0,094564 (0,026349)					
	CBSMPSO-FB-F	0,095403 (0,025592)					

Tabela 4.24: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - para as métricas no programa GUAVA - Dados Custo x Falhas no cenário de Cobertura de Requisitos $\geq 90\%$.

			média (desv. pad.)	Kruskal-Wallis (valor p)				média (desv. pad.)	Kruskal-Wallis (valor p)
HV	BSMPSO-FB	0,660480 (0,046008)	0,0201	GD	BSMPSO-FB	0,102922 (0,032620)	0,0761	CBSMPSO-FB-C	0,095016 (0,048564)
	CBSMPSO-FB-C	0,669227 (0,083615)			CBSMPSO-FB-F	0,109955 (0,025704)			
	CBSMPSO-FB-F	0,639925 (0,046431)							
IGD	BSMPSO-FB	0,084603 (0,013829)	0,0009	CVR	BSMPSO-FB	0,99000 (0,100000)	0,1725	CBSMPSO-FB-C	0,98250 (0,113790)
	CBSMPSO-FB-C	0,082017 (0,024452)			CBSMPSO-FB-F	1,00000 (0,000000)			
	CBSMPSO-FB-F	0,092964 (0,013785)							
		média (desv. pad.)		Kruskal-Wallis (valor p)					
MS	BSMPSO-FB	0,158207 (0,143083)	0,0212						
	CBSMPSO-FB-C	0,198515 (0,156333)							
	CBSMPSO-FB-F	0,137394 (0,112392)							

4.5 Considerações Finais

Este capítulo apresentou inicialmente como os experimentos foram organizados, quais objetos e questões de estudo foram utilizados e como as técnicas e experimentos foram configurados. Após isso, as técnicas propostas neste trabalho (divididas em subgrupos) foram comparadas de forma a definir qual a melhor técnica em cada subgrupo. Por fim, as melhores técnicas de cada subgrupo foram comparadas em relação às suas fronteiras de Pareto e em relação à capacidade de detecção de falhas.

Os resultados finais destes experimentos indicaram que a técnica BSMPSO-FB foi considerada a melhor das técnicas e, portanto, a mesma foi utilizada na parte dos experimentos que envolvia ambientes com restrições. Adicionalmente, nos estudos considerando restrições também foi verificada uma predominância da técnica BSMPSO-FB.

Finalmente, das técnicas propostas nesse trabalho, a técnica BSMPSO-FB (híbrida e sem mecanismo de tratamento de restrições) foi considerada superior as demais nos experimentos apresentados neste capítulo.

5

Conclusão

O presente trabalho propôs técnicas de busca híbridas e não híbridas aplicadas na resolução do problemas de seleção multiobjetivo de casos de teste. Foram propostas duas técnicas não híbridas baseadas no PSO: (1) BMOPSO-CDR e (2) BSMOPSO. Além disso, foram propostos quatro mecanismos de busca local: (1) FB, (2) 1-opt, (3) AG e (4) HS. Esses mecanismos foram combinados com as técnicas não híbridas propostas e com técnicas não híbridas difundidas na literatura para criação de novas técnicas híbridas que foram propostas nesse trabalho. Por fim foram propostas técnicas híbridas que utilizassem mecanismos de tratamento de restrições.

Inicialmente (durante os experimentos realizados) as técnicas foram divididas em subgrupos, relacionando as técnicas não híbridas com suas híbridas correspondentes, e comparadas em relação às suas fronteiras de Pareto nos programas provenientes do SIR. Como resultados dessas comparações foi possível verificar que o mecanismo de busca local FB foi que apresentou melhores resultados, além de que em geral os mecanismos 1opt e HS também foram capazes de introduzir melhoras nas técnicas não híbridas nas quais foram inseridos. Apenas o mecanismo de busca local AG apresentou um comportamento que era equivalente ou capaz de deteriorar os resultados das técnicas não híbridas nas quais foi inserido. Além disso, foi observado que as técnicas BMOPSO-CDR-FB, BSMPSO-FB, NSGA-II-FB, SPEA2-FB e TAEA-FB foram as melhores em seus respectivos subgrupos.

A próxima etapa dos experimentos comparou essas melhores técnicas de cada subgrupo no programa GUAVA. Essas comparações consideraram dois aspectos (1) qualidade das fronteiras de Pareto e (2) capacidade de detecção de falhas. No primeiro aspecto a técnica BSMPSO-FB foi considerada a melhor e no segundo aspecto ambas técnicas BMOPSO-CDR-FB e BSMPSO-FB foram consideradas as melhores. Portanto, no fim a técnica BSMPSO-FB foi a escolhida como melhor das melhores técnicas e foi utilizada como base para proposição das técnicas híbridas com mecanismos de tratamento de restrições.

A parte final dos experimentos comparou a técnica BSMPSO-FB com as técnicas com tratamento de restrições CBSMPSO-FB-C e CBSMPSO-FB-F em relação aos mesmos aspectos anteriores (qualidade das fronteiras de Pareto e capacidade de detecção de falhas). Nesses experimentos foram propostos quatro cenários de restrições: dois considerados médios e dois

considerados críticos. Os resultados mostraram que os resultados da técnica BSMPSO-FB foram sempre superiores ou equivalentes aos das outras duas técnicas nos aspectos comparados. A única ressalva ocorrendo num dos cenários críticos onde a técnica BSMPSO-FB não foi capaz de encontrar soluções viáveis para aproximadamente 50% das execuções.

É importante ressaltar que todas as técnicas propostas neste trabalho podem utilizar outros objetivos além dos aqui mostrados. Além disso, essas técnicas podem facilmente serem adaptadas para resolução de problemas similares a este.

5.1 Principais Contribuições

As contribuições maiores desse trabalho foram:

- Proposição de novas técnicas de busca (não híbridas) aplicadas ao problema de Seleção Multiobjetivo de Casos de Teste: BMOPSO-CDR e BSMPSO;
- Proposição de novas técnicas de busca híbridas aplicadas ao problema de Seleção Multiobjetivo de Casos de Teste: BMOPSO-CDR-FB, BMOPSO-CDR-1opt, BMOPSO-CDR-AG, BMOPSO-CDR-HS, BSMPSO-FB, BSMPSO-1opt, BSMPSO-AG, BSMPSO-HS, NSGA-II-FB, NSGA-II-FB-1opt, NSGA-II-FB-AG, NSGA-II-FB-HS, SPEA2-FB, SPEA2-1opt, SPEA2-AG, SPEA2-HS, TAEA-FB, TAEA-1opt, TAEA-AG, TAEA-HS;
- Proposição de novas técnicas de busca híbridas e com tratamento de restrições aplicadas ao problema de Seleção Multiobjetivo de Casos de Teste: CBSMPSO-FB-C e CBSMPSO-FB-F;
- Primeiro trabalho que compara as técnicas em relação às fronteiras de Pareto, em relação à capacidade de detecção e falhas e em relação à existência de restrições no ambiente de testes;
- Primeiro trabalho a estudar técnicas baseadas Otimização por Enxame de Partículas (PSO) no problema de Seleção Multiobjetivo de Casos de Teste;
- Primeiro trabalho a estudar a técnica conhecida como Busca Harmônica (*Harmony Search*) no problema de Seleção Multiobjetivo de Casos de Teste.

Além disso, as seguintes publicações foram frutos do presente trabalho até o momento:

- *A Multi-Objective Particle Swarm Optimization for Test Case Selection Based on Functional Requirements Coverage and Execution Effort*: publicado na *23rd IEEE International Conference on Tools with Artificial Intelligence (2011)*;
- *Search based constrained test case selection using execution effort*: publicado no periódico *Expert Systems with Applications An International Journal (2013)*

- *A Comparison Study of Binary Multi-Objective Particle Swarm Optimization Approaches for Test Case Selection*: publicado no 2014 IEEE Congress on Evolutionary Computation (CEC)
- *Multi-Objective Test Case Selection: A study of the influence of the Catfish effect on PSO based strategies*: publicado no XV Workshop de Testes e Tolerância a Falhas (WTF 2014)
- *Multi-Objective Test Case Selection: A Hybrid Particle Swarm Optimization and Harmony Search Algorithm*: publicado no V Workshop de Engenharia de Software Baseada em Busca (WESB 2014). Premiado como melhor artigo.
- *An Hybrid Binary Multi-Objective Particle Swarm Optimization with Local Search for Test Case Selection*: publicado no Brazilian Conference on Intelligent Systems (BRACIS 2014)
- *A hybrid particle swarm optimization and harmony search algorithm approach for multi-objective test case selection*: publicado no Journal of the Brazilian Computer Society (2015) 21:19

5.2 Trabalhos Futuros

Como trabalhos futuros é possível vislumbrar o estudo das técnicas propostas num contexto que envolva mais objetivos de forma a verificar se o desempenho apresentado se mantém quando há um aumento no número de objetivos estudados. Também é possível estender o presente trabalho a partir da utilização e/ou desenvolvimento de outros mecanismos de busca local de forma a propor novas técnicas híbridas de seleção multiobjetivo.

Outro aspecto que pode vir a ser estudado em um trabalho futuro é de utilização de outros programas, diferentes dos aqui utilizados, de forma a verificar se os resultados aqui apresentados podem ser extrapolados para outras situações.

Além disso, é possível realizar um estudo das técnicas propostas em outros problemas de otimização multiobjetivo com espaços de busca binários para verificar se o desempenho das técnicas aqui propostas se mantém equivalente em outros domínios que não o de seleção de testes de software.

Por fim, novos trabalhos futuros podem aprofundar no estudo das técnicas em ambientes com cenários de restrições diversos aos aqui apresentados.

Referências

- AFKHAMI, S.; MA'ROUZI, O. R.; SOLEIMANI, A. A binary harmony search algorithm for solving the maximum clique problem. *International Journal of Computer Applications*, v. 69, 2013.
- AGRAWAL, H. et al. Incremental regression testing. In: *Proceedings of the Conference on Software Maintenance*. Washington, DC, USA: IEEE Computer Society, 1993. (ICSM '93), p. 348–357. ISBN 0-8186-4600-4.
- AHMED, B. S.; ZAMLI, K. Z. A variable strength interaction test suites generation strategy using particle swarm optimization. *Journal of Systems and Software*, v. 84, n. 12, p. 2171 – 2185, 2011. ISSN 0164-1212. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0164121211001464>>.
- ALI, S. et al. A systematic review of the application and empirical investigation of search-based test case generation. *Software Engineering, IEEE Transactions on*, v. 36, n. 6, p. 742–762, Nov 2010. ISSN 0098-5589.
- ANDREWS, J.; BRIAND, L.; LABICHE, Y. Is mutation an appropriate tool for testing experiments? [software testing]. In: *Software Engineering, 2005. ICSE 2005. Proceedings. 27th International Conference on*. [S.l.: s.n.], 2005. p. 402–411.
- ARCURI, A.; BRIAND, L. A hitchhiker's guide to statistical tests for assessing randomized algorithms in software engineering. *Software Testing, Verification and Reliability*, v. 24, n. 3, p. 219–250, 2014. ISSN 1099-1689. Disponível em: <<http://dx.doi.org/10.1002/stvr.1486>>.
- BIAN, Y. et al. Search-based software engineering: 7th international symposium, ssbse 2015, bergamo, italy, september 5-7, 2015, proceedings. In: _____. Cham: Springer International Publishing, 2015. cap. Regression Test Case Prioritisation for Guava, p. 221–227. ISBN 978-3-319-22183-0. Disponível em: <http://dx.doi.org/10.1007/978-3-319-22183-0_15>.
- BLACK, J.; MELACHRINOUDIS, E.; KAEI, D. Bi-criteria models for all-uses test suite reduction. In: *Software Engineering, 2004. ICSE 2004. Proceedings. 26th International Conference on*. [S.l.: s.n.], 2004. p. 106–115. ISSN 0270-5257.
- BORBA, P. et al. (Ed.). *Testing Techniques in Software Engineering, Second Pernambuco Summer School on Software Engineering, PSSE 2007, Recife, Brazil, December 3-7, 2007, Revised Lectures*, v. 6153 de *Lecture Notes in Computer Science*, (Lecture Notes in Computer Science, v. 6153). [S.l.]: Springer, 2010. ISBN 978-3-642-14334-2.
- BOZKURT, M. Cost-aware pareto optimal test suite minimisation for service-centric systems. In: *Proceeding of the fifteenth annual conference on Genetic and evolutionary computation conference*. New York, NY, USA: ACM, 2013. (GECCO '13), p. 1429–1436. ISBN 978-1-4503-1963-8.
- BRIAND, L.; LABICHE, Y.; SOCCAR, G. Automating impact analysis and regression test selection based on uml designs. In: *Software Maintenance, 2002. Proceedings. International Conference on*. [S.l.: s.n.], 2002. p. 252–261. ISSN 1063-6773.

- CAMPOS, J. et al. Search-based software engineering: 7th international symposium, ssbse 2015, bergamo, italy, september 5-7, 2015, proceedings. In: _____. Cham: Springer International Publishing, 2015. cap. Continuous Test Generation on Guava, p. 228–234. ISBN 978-3-319-22183-0. Disponível em: <http://dx.doi.org/10.1007/978-3-319-22183-0_16>.
- CARTAXO, G. E. et al. Ltsbt: A tool to generate and select functional test cases for embedded systems. In: *23rd Annual ACM Symposium on Applied Computing (SAC'2008)*. Fortaleza, CE, Brasil: [s.n.], 2008.
- CARTAXO, G. E.; MACHADO, D. L. P.; NETO, G. F. O. On the use of a similarity function for test case selection in the context of model-based testing. *Software Testing, Verification and Reliability*, v. 21, n. 2, 2009.
- CARVALHO, A. de et al. Predicting fault proneness of classes through a multiobjective particle swarm optimization algorithm. In: *Tools with Artificial Intelligence, 2008. ICTAI '08. 20th IEEE International Conference on*. [S.l.: s.n.], 2008. v. 2, p. 387–394. ISSN 1082-3409.
- CHEN, T. Y.; LAU, M. F. A new heuristic for test suite reduction. *Information & Software Technology*, v. 40, n. 5-6, p. 347–354, 1998.
- CLOW, B.; WHITE, T. An evolutionary race: a comparison of genetic algorithms and particle swarm optimization used for training neural networks. In: *Proc. of the Int. Conf. on Artificial Intelligence, IC-AI O*. [S.l.: s.n.], 2004. v. 4, p. 2.
- COELLO, C.; PULIDO, G.; LECHUGA, M. Handling multiple objectives with particle swarm optimization. *IEEE Transactions on Evolutionary Computation*, v. 8, n. 3, p. 256–279, 2004.
- COELLO, C. A. C.; CHRISTIANSEN, A. D. Moses: A multiobjective optimization tool for engineering design. *Engineering Optimization*, Taylor & Francis, v. 31, n. 3, p. 337–368, 1999.
- COELLO, C. A. C.; LAMONT, G. B.; VELDHUIZEN, D. A. van. *Evolutionary Algorithms for Solving Multi-Objective Problems*. [S.l.]: Springer, 2007. v. 5.
- COLES, H. *Pitest Web Site*. 2015. Disponível em: <<http://pitest.org/>>.
- DAKA, E. et al. Search-based software engineering: 7th international symposium, ssbse 2015, bergamo, italy, september 5-7, 2015, proceedings. In: _____. Cham: Springer International Publishing, 2015. cap. Generating Readable Unit Tests for Guava, p. 235–241. ISBN 978-3-319-22183-0. Disponível em: <http://dx.doi.org/10.1007/978-3-319-22183-0_17>.
- DEB, K. et al. A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: Nsga-ii. In: *Parallel Problem Solving from Nature PPSN VI*. [S.l.]: Springer Berlin Heidelberg, 2000, (Lecture Notes in Computer Science, v. 1917). p. 849–858. ISBN 978-3-540-41056-0.
- DEB, K.; KALYANMOY, D. *Multi-Objective Optimization Using Evolutionary Algorithms*. 1. ed. [S.l.]: Wiley, 2001. Hardcover.
- DESIKAN, S.; RAMESH, G. *Software Testing: Principles and Practices*. [S.l.]: Prentice Hall, 2007.

DO, H.; ELBAUM, S.; ROTHERMEL, G. Supporting controlled experimentation with testing techniques: An infrastructure and its potential impact. *Empirical Softw. Engg.*, Kluwer Academic Publishers, Hingham, MA, USA, v. 10, n. 4, p. 405–435, out. 2005. ISSN 1382-3256. Disponível em: <<http://dx.doi.org/10.1007/s10664-005-3861-2>>.

EBERHART, R. C.; SHI, Y. Comparison between genetic algorithms and particle swarm optimization. *LNCs*, v. 1447, p. 611–616, 1998.

ELBAUM, S.; MALISHEVSKY, A. G.; ROTHERMEL, G. Prioritizing test cases for regression testing. *SIGSOFT Softw. Eng. Notes*, ACM, New York, NY, USA, v. 25, n. 5, p. 102–112, ago. 2000. ISSN 0163-5948.

ENGELBRECHT, A. *Fundamentals of Computational Swarm Intelligence*. [S.l.]: Wiley, 2005. ISBN 9780470091913.

ENGELBRECHT, A. P. *Computational Intelligence: An Introduction*. [S.l.]: Wiley Publishing, 2007. ISBN 0470035617.

FEIJS, L. M. G. et al. Test selection, trace distance and heuristics. In: *Proceedings of the IFIP 14th International Conference on Testing Communicating Systems*. [S.l.: s.n.], 2002. p. 267–282.

GAREY, M. R.; JOHNSON, D. S. *Computers and Intractability: A Guide to the Theory of NP-Completeness*. [S.l.]: W. H. Freeman, 1979. ISBN 0-7167-1044-7.

GEEM, Z. W.; KIM, J. H.; LOGANATHAN, G. A new heuristic optimization algorithm: harmony search. *Simulation*, SAGE Publications, v. 76, n. 2, p. 60–68, 2001.

GUAVA Project Web Site. 2015. [Online; accessed 1-Outubro-2015]. Disponível em: <<https://github.com/google/guava>>.

GUPTA, R.; HARROLD, M.; SOFFA, M. An approach to regression testing using slicing. In: *Software Maintenance, 1992. Proceedings., Conference on*. [S.l.: s.n.], 1992. p. 299–308.

HARMAN, M. Making the case for morto: Multi objective regression test optimization. In: *Fourth International IEEE Conference on Software Testing, Verification and Validation*. [S.l.]: IEEE Computer Society, 2011. p. 111–114.

HARMAN, M.; JONES, B. F. Search-based software engineering. *Information and Software Technology*, v. 43, n. 14, p. 833 – 839, 2001. ISSN 0950-5849. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0950584901001896>>.

HAROLD, M. J.; GUPTA, R.; SOFFA, M. L. A methodology for controlling the size of a test suite. *ACM Trans. Softw. Eng. Methodol.*, ACM, v. 2, n. 3, p. 270–285, 1993. ISSN 1049-331X.

HARROLD, M.; SOFFA, M. An incremental approach to unit testing during maintenance. In: *Software Maintenance, 1988., Proceedings of the Conference on*. [S.l.: s.n.], 1988. p. 362–367.

HARROLD, M. J.; SOFFA, M. L. Interprocedural data flow testing. *SIGSOFT Softw. Eng. Notes*, ACM, New York, NY, USA, v. 14, n. 8, p. 158–167, nov. 1989. ISSN 0163-5948.

HASSAN, R. et al. A comparison of particle swarm optimization and the genetic algorithm. In: *Proceedings of the 1st AIAA multidisciplinary design optimization specialist conference*. [S.l.: s.n.], 2005. p. 18–21.

HEMMATI, H.; ARCURI, A.; BRIAND, L. Achieving scalable model-based testing through test case diversity. *ACM Trans. Softw. Eng. Methodol.*, ACM, New York, NY, USA, v. 22, n. 1, p. 6:1–6:42, mar. 2013. ISSN 1049-331X. Disponível em: <<http://doi.acm.org/10.1145/2430536.2430540>>.

HEMMATI, H. et al. An enhanced test case selection approach for model-based testing: an industrial case study. In: *Proceedings of the eighteenth ACM SIGSOFT international symposium on Foundations of software engineering*. New York, NY, USA: ACM, 2010. (FSE '10), p. 267–276. ISBN 978-1-60558-791-2. Disponível em: <<http://doi.acm.org/10.1145/1882291.1882331>>.

HODGSON, R. J. W. Partial swarm optimization applied to the atomic cluster optimization problem. In: *Proceedings of the Genetic and Evolutionary Computation Conference*. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 2002. (GECCO '02), p. 68–73.

JONES, K. O. Comparison of genetic algorithm and particle swarm optimization. In: *Proc. Int. Conf. Computer Systems and Technologies*. [S.l.: s.n.], 2005. p. 1–6.

JORGENSEN, P. *Software Testing: A Craftsman's Approach*. [S.l.]: Auerbach Publications, 2008.

KAUR, A.; BHATT, D. Hybrid particle swarm optimization for regression testing. *International Journal on Computer Science and Engineering*, v. 3 (5), p. 1815–1824, 2011.

KENNEDY, J.; EBERHART, R. C. Particle swarm optimization. In: *Proceedings of the IEEE International Joint Conference on Neural Networks*. [S.l.: s.n.], 1995. p. 1942–1948.

KENNEDY, J.; EBERHART, R. C. A discrete binary version of the particle swarm algorithm. In: *Proceedings of the World Multiconference on Systemics, Cybernetics and Informatics*. [S.l.: s.n.], 1997. p. 4104–4109.

KOHAVI, R.; JOHN, G. Wrappers for feature subset selection. *Artificial Intelligence*, v. 97, n. 1-2, p. 273–324, 1997.

KUMARI, A.; SRINIVAS, K.; GUPTA, M. Multi-objective test suite minimisation using quantum-inspired multi-objective differential evolution algorithm. In: *Computational Intelligence Computing Research (ICCIC), 2012 IEEE International Conference on*. [S.l.: s.n.], 2012. p. 1–7.

LEFTICARU, R.; IPATE, F. Functional search-based testing from state machines. In: *Software Testing, Verification, and Validation, 2008 1st International Conference on*. [S.l.: s.n.], 2008. p. 525–528.

LEUNG, H. K. N.; WHITE, L. Insights into testing and regression testing global variables. *Journal of Software Maintenance*, John Wiley & Sons, Inc., New York, NY, USA, v. 2, n. 4, p. 209–222, dez. 1990. ISSN 1040-550X.

LI, Z.; HIERONS, R. M.; HARMAN, M. Search algorithms for regression test case prioritization. *IEEE Transactions on Software Engineering*, IEEE, v. 33, n. 4, p. 225–237, 2007.

LIN, J.-W.; HUANG, C.-Y. Analysis of test suite reduction with enhanced tie-breaking techniques. *Inf. Softw. Technol.*, v. 51, n. 4, p. 679–690, 2009.

- LUCIA, A. D. et al. On the role of diversity measures for multi-objective test case selection. In: *Automation of Software Test (AST), 2012 7th International Workshop on*. [S.l.: s.n.], 2012. p. 145–151.
- MA, X.-Y.; SHENG, B.-K.; YE, C.-Q. Test-suite reduction using genetic algorithm. *Lecture Notes in Computer Science*, v. 3756, p. 253–262, 2005.
- MAIA, C. L. B. et al. A multi-objective approach for the regression test case selection problem. In: *Proceedings of Anais do XLI Simposio Brasileiro de Pesquisa Operacional (SBPO 2009)*. [S.l.: s.n.], 2009. p. 1824–1835.
- MANSOUR, N.; EL-FAKIH, K. Simulated annealing and genetic algorithms for optimal regression testing. *Journal of Software Maintenance*, John Wiley & Sons, Inc., New York, NY, USA, v. 11, n. 1, p. 19–34, January 1999.
- MARRE, M.; BERTOLINO, A. Using spanning sets for coverage testing. *Software Engineering, IEEE Transactions on*, v. 29, n. 11, p. 974–984, 2003.
- MIRARAB, S.; ESFAHANI, S. A.; TAHVILDARI, L. Size-constrained regression test case selection using multicriteria optimization. *IEEE Trans. Softw. Eng.*, IEEE Press, Piscataway, NJ, USA, v. 38, n. 4, p. 936–956, jul. 2012. ISSN 0098-5589.
- MYERS, G. J.; SANDLER, C. *The Art of Software Testing*. [S.l.]: John Wiley & Sons, 2004. ISBN 0471469122.
- NEBRO, A. et al. Smpso: A new pso-based metaheuristic for multi-objective optimization. In: *Computational intelligence in multi-criteria decision-making, 2009. mcdm '09. iee symposium on*. [S.l.: s.n.], 2009. p. 66–73.
- NETHERCOTE, N.; SEWARD, J. Valgrind: A program supervision framework. In: *In Third Workshop on Runtime Verification*. [S.l.: s.n.], 2003.
- NOGUEIRA, S. et al. Model based test generation: An industrial experience. *First Brazilian Workshop on Systematic and Automated Software Testing*, João Pessoa, PB, Brasil, Outubro 2007.
- OFFUTT, J.; PAN, J.; VOAS, J. Procedures for reducing the size of coverage-based test sets. In: *Proceedings of the Twelfth International Conference on Testing Computer Software*. [S.l.]: AMC Press, 1995. p. 111–123.
- PAPADIMITRIOU, C.; STEIGLITZ, K. *Combinatorial optimization: algorithms and complexity*. [S.l.]: Dover Publications, 1998. (Dover books on mathematics). ISBN 9780486402581.
- PRADITWONG, K.; YAO, X. A new multi-objective evolutionary optimisation algorithm: the two-archive algorithm. In: *IEEE. Computational Intelligence and Security, 2006 International Conference on*. [S.l.], 2006. v. 1, p. 286–291.
- RAMLER, R.; WOLFMAIER, K. Economic perspectives in test automation - balancing automated and manual testing with opportunity cost. In: *Workshop on Automation of Software Test, ICSE 2006*. [S.l.: s.n.], 2006.
- REYES-SIERRA, M.; COELLO, C. C. Multi-objective particle swarm optimizers: A survey of the state-of-the-art. *International journal of computational intelligence research*, v. 2, n. 3, p. 287–308, 2006.

- ROGSTAD, E.; BRIAND, L.; TORKAR, R. Test case selection for black-box regression testing of database applications. *Inf. Softw. Technol.*, Butterworth-Heinemann, Newton, MA, USA, v. 55, n. 10, p. 1781–1795, out. 2013. ISSN 0950-5849. Disponível em: <<http://dx.doi.org/10.1016/j.infsof.2013.04.004>>.
- ROTHERMEL, G. *Efficient, effective regression testing using safe test selection techniques*. Tese (Doutorado), Clemson, SC, USA, 1996.
- ROTHERMEL, G.; HARROLD, M. J. A safe, efficient regression test selection technique. *ACM Trans. Softw. Eng. Methodol.*, ACM, New York, NY, USA, v. 6, n. 2, p. 173–210, 1997.
- SANTANA, R. A.; PONTES, M. R.; BASTOS-FILHO, C. J. A. A multiple objective particle swarm optimization approach using crowding distance and roulette wheel. In: *Proceedings of the 2009 Ninth International Conference on Intelligent Systems Design and Applications*. Washington, DC, USA: IEEE Computer Society, 2009. (ISDA '09), p. 237–242. ISBN 978-0-7695-3872-3.
- SHI, Y.; EBERHART, R. C. Parameter selection in particle swarm optimization. In: *Proceedings of the 7th International Conference on Evolutionary Programming*. [S.l.: s.n.], 1998. p. 591–600.
- SINGH, H. K.; RAY, T.; SARKER, R. Optimum oil production planning using infeasibility driven evolutionary algorithm. *Evol. Comput.*, MIT Press, Cambridge, MA, USA, v. 21, n. 1, p. 65–82, mar. 2013. ISSN 1063-6560. Disponível em: <http://dx.doi.org/10.1162/EVCO_a_00064>.
- SOUZA, L. S. de et al. A multi-objective particle swarm optimization for test case selection based on functional requirements coverage and execution effort. In: *In Proceedings of the 23rd International Conference on Tools with Artificial Intelligence (ICTAI 2011)*. Boca Raton, FL, USA: [s.n.], 2011.
- SUN, J. ze; WANG, S. yan. A novel chaos discrete particle swarm optimization algorithm for test suite reduction. In: *Information Science and Engineering (ICISE), 2010 2nd International Conference on*. [S.l.: s.n.], 2010. p. 1–4.
- TALLAM, S.; GUPTA, N. A concept analysis inspired greedy algorithm for test suite minimization. *SIGSOFT Softw. Eng. Notes*, ACM, New York, NY, USA, v. 31, n. 1, p. 35–42, set. 2006. ISSN 0163-5948.
- TAŞGETIREN, M. F.; LIANG, Y.-C. A binary particle swarm optimization algorithm for lot sizing problem. *Journal of Economic and Social Research*, v. 5, n. 2, p. 1–20, 2003.
- VOKOLOS, F.; FRANKL, P. Pythia: A regression test selection tool based on textual differencing. In: GRITZALIS, D. (Ed.). *Reliability, Quality and Safety of Software-Intensive Systems*. [S.l.]: Springer US, 1997, (IFIP The International Federation for Information Processing). p. 3–21. ISBN 978-1-4757-6399-7.
- VOKOLOS, F.; FRANKL, P. Empirical evaluation of the textual differencing regression testing technique. In: *Software Maintenance, 1998. Proceedings., International Conference on*. [S.l.: s.n.], 1998. p. 44–53. ISSN 1063-6773.
- WALCOTT, K. R. et al. Timeaware test suite prioritization. In: *Proceedings of the 2006 International Symposium on Software Testing and Analysis*. [S.l.: s.n.], 2006. p. 1–12.

- WANG, L. et al. A discrete harmony search algorithm. In: *Life System Modeling and Intelligent Computing*. [S.l.]: Springer, 2010. p. 37–43.
- WANG, L. et al. A modified multi-objective binary particle swarm optimization algorithm. In: *Proceedings of the Second international conference on Advances in swarm intelligence - Volume Part II*. Berlin, Heidelberg: Springer-Verlag, 2011. (ICSI'11), p. 41–48. ISBN 978-3-642-21523-0. Disponível em: <<http://dl.acm.org/citation.cfm?id=2026369.2026376>>.
- WANG, S.; ALI, S.; GOTLIEB, A. Minimizing test suites in software product lines using weight-based genetic algorithms. In: *Proceedings of the 15th Annual Conference on Genetic and Evolutionary Computation*. New York, NY, USA: ACM, 2013. (GECCO '13), p. 1493–1500. ISBN 978-1-4503-1963-8. Disponível em: <<http://doi.acm.org/10.1145/2463372.2463545>>.
- WEBB, A. R. *Statistical Pattern Recognition, 2nd Edition*. [S.l.]: John Wiley & Sons, 2002. Paperback.
- WEI, Y.; QIQIANG, L. Survey on particle swarm optimization algorithm [j]. *Engineering Science*, v. 5, n. 5, p. 87–94, 2004.
- WHITE, L.; LEUNG, H. A firewall concept for both control-flow and data-flow in regression integration testing. In: *Software Maintenance, 1992. Proceedings., Conference on*. [S.l.: s.n.], 1992. p. 262–271.
- WINDISCH, A.; WAPPLER, S.; WEGENER, J. Applying particle swarm optimization to software testing. In: *Proceedings of the 9th annual conference on Genetic and evolutionary computation*. New York, NY, USA: ACM, 2007. (GECCO '07), p. 1121–1128.
- YAU, S. S.; KISHIMOTO, Z. A Method for Revalidating Modified Programs in the Maintenance Phase. In: *Proceedings of International Computer Software and Applications Conference*. [S.l.: s.n.], 1987.
- YEN, G. G.; LEONG, W. F. Constraint handling procedure for multiobjective particle swarm optimization. In: *IEEE. Evolutionary Computation (CEC), 2010 IEEE Congress on*. [S.l.], 2010. p. 1–8.
- YOO, S.; HARMAN, M. Pareto efficient multi-objective test case selection. In: *Proceedings of the 2007 International Symposium on Software Testing and Analysis*. [S.l.: s.n.], 2007. p. 140–150.
- YOO, S.; HARMAN, M. Regression testing minimization, selection and prioritization: a survey. *Software Testing, Verification and Reliability*, John Wiley & Sons, Ltd., v. 22, n. 2, p. 67–120, 2010.
- YOO, S.; HARMAN, M. Using hybrid algorithm for pareto efficient multi-objective test suite minimisation. *J. Syst. Softw.*, Elsevier Science Inc., New York, NY, USA, v. 83, p. 689–701, April 2010.
- YOO, S.; HARMAN, M.; UR, S. Highly scalable multi objective test suite minimisation using graphics cards. In: *Proceedings of the Third international conference on Search based software engineering*. Berlin, Heidelberg: Springer-Verlag, 2011. (SSBSE'11), p. 219–236. ISBN 978-3-642-23715-7.

YOO, S.; NILSSON, R.; HARMAN, M. Faster fault finding at google using multi objective regression test optimisation. In: *8th European Software Engineering Conference and the ACM SIGSOFT Symposium on the Foundations of Software Engineering (ESEC/FSE 11)*, Szeged, Hungary. [S.l.: s.n.], 2011.

YU, E. et al. Improving constraint handling for multiobjective particle swarm optimization. In: *Control Conference (CCC), 2014 33rd Chinese*. [S.l.: s.n.], 2014. p. 8622–8627.

ZITZLER, E.; DEB, K.; THIELE, L. Comparison of multiobjective evolutionary algorithms: Empirical results. *Evolutionary Computation Journal*, v. 8, n. 2, p. 125–148, 2000.

ZITZLER, E.; LAUMANN, M.; THIELE, L. Spea2: improving the strength pareto evolutionary algorithm for multiobjective optimization. In: *Evolutionary Methods for Design, Optimization and Control with Application to Industrial Problems (EUROGEN 2001)*. [S.l.: s.n.], 2001. p. 95–100.

Apêndice



Dados Adicionais para Cada Subgrupo

Neste apêndice são apresentadas as tabelas com os resultados dos testes estatísticos de Kruskal-Wallis e Steel-Dwass, os Boxplots e os gráficos de convergência para cada subgrupo.

Tabela A.1: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica HV - Subgrupo 1.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	BMOPSO-CDR	0,714385 (0,005470)	<,0001	grep	BMOPSO-CDR	0,631716 (0,006700)	<,0001	gzip	BMOPSO-CDR	0,782575 (0,009836)	<,0001
	BMOPSO-CDR-FB	0,933262 (0,044615)			BMOPSO-CDR-FB	0,791170 (0,063820)			BMOPSO-CDR-FB	0,993333 (0,001147)	
	BMOPSO-CDR-1opt	0,729248 (0,008053)			BMOPSO-CDR-1opt	0,644503 (0,010849)			BMOPSO-CDR-1opt	0,906579 (0,015461)	
	BMOPSO-CDR-AG	0,685427 (0,008518)			BMOPSO-CDR-AG	0,583897 (0,008511)			BMOPSO-CDR-AG	0,762597 (0,009380)	
	BMOPSO-CDR-HS	0,813271 (0,004635)			BMOPSO-CDR-HS	0,744853 (0,006805)			BMOPSO-CDR-HS	0,932502 (0,005708)	
print tokens	BMOPSO-CDR	0,670036 (0,011975)	<,0001	print tokens 2	BMOPSO-CDR	0,646320 (0,008844)	<,0001	replace	BMOPSO-CDR	0,655794 (0,010055)	<,0001
	BMOPSO-CDR-FB	0,995761 (0,000130)			BMOPSO-CDR-FB	0,997015 (0,000111)			BMOPSO-CDR-FB	0,995288 (0,000511)	
	BMOPSO-CDR-1opt	0,812338 (0,017657)			BMOPSO-CDR-1opt	0,811651 (0,013051)			BMOPSO-CDR-1opt	0,806823 (0,013738)	
	BMOPSO-CDR-AG	0,654847 (0,010139)			BMOPSO-CDR-AG	0,636360 (0,008522)			BMOPSO-CDR-AG	0,638401 (0,008075)	
	BMOPSO-CDR-HS	0,871550 (0,006999)			BMOPSO-CDR-HS	0,850557 (0,007389)			BMOPSO-CDR-HS	0,839924 (0,006668)	
schedule	BMOPSO-CDR	0,708563 (0,012021)	<,0001	schedule 2	BMOPSO-CDR	0,700117 (0,013140)	<,0001	sed	BMOPSO-CDR	0,664541 (0,007849)	<,0001
	BMOPSO-CDR-FB	0,994714 (0,000153)			BMOPSO-CDR-FB	0,995695 (0,000112)			BMOPSO-CDR-FB	0,971225 (0,025977)	
	BMOPSO-CDR-1opt	0,987667 (0,007992)			BMOPSO-CDR-1opt	0,992929 (0,004113)			BMOPSO-CDR-1opt	0,719522 (0,011776)	
	BMOPSO-CDR-AG	0,690191 (0,010505)			BMOPSO-CDR-AG	0,685881 (0,011064)			BMOPSO-CDR-AG	0,627179 (0,008381)	
	BMOPSO-CDR-HS	0,922721 (0,006773)			BMOPSO-CDR-HS	0,921686 (0,008224)			BMOPSO-CDR-HS	0,818154 (0,007155)	
space	BMOPSO-CDR	0,776467 (0,009545)	<,0001	tcas	BMOPSO-CDR	0,830048 (0,015811)	<,0001	totinfo	BMOPSO-CDR	0,705871 (0,010472)	<,0001
	BMOPSO-CDR-FB	0,975914 (0,001030)			BMOPSO-CDR-FB	0,967424 (7,754e-7)			BMOPSO-CDR-FB	0,995921 (0,000108)	
	BMOPSO-CDR-1opt	0,907320 (0,010724)			BMOPSO-CDR-1opt	0,967418 (0,000032)			BMOPSO-CDR-1opt	0,995597 (0,000310)	
	BMOPSO-CDR-AG	0,737481 (0,013366)			BMOPSO-CDR-AG	0,809033 (0,017263)			BMOPSO-CDR-AG	0,700172 (0,010840)	
	BMOPSO-CDR-HS	0,915629 (0,005608)			BMOPSO-CDR-HS	0,967225 (0,000196)			BMOPSO-CDR-HS	0,952917 (0,006230)	

105

[illegible]

Tabela A.3: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica GD - Subgrupo 1.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	BMOPSO-CDR	0,041253 (0,006138)	<,0001	grep	BMOPSO-CDR	0,066246 (0,008640)	<,0001	gzip	BMOPSO-CDR	0,040910 (0,004991)	<,0001
	BMOPSO-CDR-FB	0,012593 (0,008294)			BMOPSO-CDR-FB	0,030997 (0,009501)			BMOPSO-CDR-FB	0,000190 (0,000257)	
	BMOPSO-CDR-1opt	0,026564 (0,004272)			BMOPSO-CDR-1opt	0,042946 (0,004138)			BMOPSO-CDR-1opt	0,014280 (0,002655)	
	BMOPSO-CDR-AG	0,018044 (0,005092)			BMOPSO-CDR-AG	0,048434 (0,003320)			BMOPSO-CDR-AG	0,034994 (0,005036)	
	BMOPSO-CDR-HS	0,022831 (0,002688)			BMOPSO-CDR-HS	0,027120 (0,002485)			BMOPSO-CDR-HS	0,011783 (0,001258)	
print tokens	BMOPSO-CDR	0,248819 (0,053466)	<,0001	print tokens 2	BMOPSO-CDR	0,314219 (0,045258)	<,0001	replace	BMOPSO-CDR	0,252218 (0,047761)	<,0001
	BMOPSO-CDR-FB	0,001189 (0,000418)			BMOPSO-CDR-FB	0,000827 (0,001009)			BMOPSO-CDR-FB	0,000762 (0,000743)	
	BMOPSO-CDR-1opt	0,090524 (0,016303)			BMOPSO-CDR-1opt	0,131844 (0,031666)			BMOPSO-CDR-1opt	0,129711 (0,031462)	
	BMOPSO-CDR-AG	0,258011 (0,055221)			BMOPSO-CDR-AG	0,320860 (0,049069)			BMOPSO-CDR-AG	0,245210 (0,052379)	
	BMOPSO-CDR-HS	0,070970 (0,016271)			BMOPSO-CDR-HS	0,121249 (0,021821)			BMOPSO-CDR-HS	0,083126 (0,016491)	
schedule	BMOPSO-CDR	0,201769 (0,040363)	<,0001	schedule 2	BMOPSO-CDR	0,228233 (0,044766)	<,0001	sed	BMOPSO-CDR	0,082383 (0,009392)	<,0001
	BMOPSO-CDR-FB	0,000833 (0,000553)			BMOPSO-CDR-FB	0,000721 (0,000570)			BMOPSO-CDR-FB	0,005444 (0,005755)	
	BMOPSO-CDR-1opt	0,003755 (0,002446)			BMOPSO-CDR-1opt	0,002226 (0,001124)			BMOPSO-CDR-1opt	0,043954 (0,003978)	
	BMOPSO-CDR-AG	0,205561 (0,045550)			BMOPSO-CDR-AG	0,228051 (0,050819)			BMOPSO-CDR-AG	0,078029 (0,006742)	
	BMOPSO-CDR-HS	0,036546 (0,006131)			BMOPSO-CDR-HS	0,043139 (0,010398)			BMOPSO-CDR-HS	0,028569 (0,003052)	
space	BMOPSO-CDR	0,032478 (0,005883)	<,0001	tcas	BMOPSO-CDR	0,037480 (0,007134)	<,0001	totinfo	BMOPSO-CDR	0,269319 (0,027343)	<,0001
	BMOPSO-CDR-FB	0,000276 (0,000150)			BMOPSO-CDR-FB	0,000101 (0,000187)			BMOPSO-CDR-FB	0,001086 (0,000483)	
	BMOPSO-CDR-1opt	0,006015 (0,000830)			BMOPSO-CDR-1opt	0,000136 (0,000197)			BMOPSO-CDR-1opt	0,001469 (0,000548)	
	BMOPSO-CDR-AG	0,019434 (0,002182)			BMOPSO-CDR-AG	0,046611 (0,011879)			BMOPSO-CDR-AG	0,272856 (0,030397)	
	BMOPSO-CDR-HS	0,004682 (0,000601)			BMOPSO-CDR-HS	0,000634 (0,000212)			BMOPSO-CDR-HS	0,024974 (0,006289)	

107

[illegible]

Tabela A.5: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica IGD - Subgrupo 1.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	BMOPSO-CDR	0,023438 (0,000531)	<,0001	grep	BMOPSO-CDR	0,033079 (0,000828)	<,0001	gzip	BMOPSO-CDR	0,018851 (0,000945)	<,0001
	BMOPSO-CDR-FB	0,006814 (0,004908)			BMOPSO-CDR-FB	0,015956 (0,006760)			BMOPSO-CDR-FB	0,000433 (0,000223)	
	BMOPSO-CDR-1opt	0,022773 (0,000569)			BMOPSO-CDR-1opt	0,031761 (0,001301)			BMOPSO-CDR-1opt	0,013884 (0,001291)	
	BMOPSO-CDR-AG	0,024612 (0,000560)			BMOPSO-CDR-AG	0,039342 (0,001020)			BMOPSO-CDR-AG	0,019451 (0,000900)	
	BMOPSO-CDR-HS	0,020404 (0,000623)			BMOPSO-CDR-HS	0,021010 (0,000928)			BMOPSO-CDR-HS	0,014532 (0,001452)	
print tokens	BMOPSO-CDR	0,087677 (0,001787)	<,0001	print tokens 2	BMOPSO-CDR	0,084670 (0,000948)	<,0001	replace	BMOPSO-CDR	0,066870 (0,000995)	<,0001
	BMOPSO-CDR-FB	0,010359 (0,003983)			BMOPSO-CDR-FB	0,011718 (0,005146)			BMOPSO-CDR-FB	0,005291 (0,002351)	
	BMOPSO-CDR-1opt	0,071966 (0,002590)			BMOPSO-CDR-1opt	0,069168 (0,001551)			BMOPSO-CDR-1opt	0,055473 (0,001134)	
	BMOPSO-CDR-AG	0,089153 (0,001521)			BMOPSO-CDR-AG	0,085672 (0,000918)			BMOPSO-CDR-AG	0,068325 (0,000808)	
	BMOPSO-CDR-HS	0,069846 (0,002387)			BMOPSO-CDR-HS	0,068407 (0,000626)			BMOPSO-CDR-HS	0,052963 (0,000841)	
schedule	BMOPSO-CDR	0,098689 (0,002659)	<,0001	schedule 2	BMOPSO-CDR	0,094788 (0,002127)	<,0001	sed	BMOPSO-CDR	0,024099 (0,000859)	<,0001
	BMOPSO-CDR-FB	0,016260 (0,006484)			BMOPSO-CDR-FB	0,011616 (0,006363)			BMOPSO-CDR-FB	0,003207 (0,003767)	
	BMOPSO-CDR-1opt	0,014712 (0,010593)			BMOPSO-CDR-1opt	0,013356 (0,011422)			BMOPSO-CDR-1opt	0,020224 (0,001289)	
	BMOPSO-CDR-AG	0,100747 (0,002154)			BMOPSO-CDR-AG	0,096239 (0,001958)			BMOPSO-CDR-AG	0,026136 (0,000780)	
	BMOPSO-CDR-HS	0,079475 (0,002960)			BMOPSO-CDR-HS	0,074068 (0,003494)			BMOPSO-CDR-HS	0,016942 (0,001113)	
space	BMOPSO-CDR	0,017009 (0,001088)	<,0001	tcas	BMOPSO-CDR	0,064790 (0,005451)	<,0001	totinfo	BMOPSO-CDR	0,094914 (0,001401)	<,0001
	BMOPSO-CDR-FB	0,000470 (0,000178)			BMOPSO-CDR-FB	0,001577 (0,000889)			BMOPSO-CDR-FB	0,010127 (0,004280)	
	BMOPSO-CDR-1opt	0,007170 (0,001411)			BMOPSO-CDR-1opt	0,001327 (0,000716)			BMOPSO-CDR-1opt	0,013148 (0,006208)	
	BMOPSO-CDR-AG	0,018920 (0,001060)			BMOPSO-CDR-AG	0,067638 (0,005320)			BMOPSO-CDR-AG	0,095614 (0,001465)	
	BMOPSO-CDR-HS	0,010760 (0,001287)			BMOPSO-CDR-HS	0,001979 (0,001074)			BMOPSO-CDR-HS	0,071506 (0,003599)	

109

[illegible]

Tabela A.7: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica CVR - Subgrupo 1.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	BMOPSO-CDR	1,00000 (0,000000)	<,0001	grep	BMOPSO-CDR	1,00000 (0)	1,0000	gzip	BMOPSO-CDR	1,00000 (0,000000)	<,0001
	BMOPSO-CDR-FB	0,97865 (0,043397)			BMOPSO-CDR-FB	1,00000 (0)			BMOPSO-CDR-FB	0,83484 (0,083993)	
	BMOPSO-CDR-1opt	1,00000 (0,000000)			BMOPSO-CDR-1opt	1,00000 (0)			BMOPSO-CDR-1opt	1,00000 (0,000000)	
	BMOPSO-CDR-AG	1,00000 (0,000000)			BMOPSO-CDR-AG	1,00000 (0)			BMOPSO-CDR-AG	1,00000 (0,000000)	
	BMOPSO-CDR-HS	1,00000 (0,000000)			BMOPSO-CDR-HS	1,00000 (0)			BMOPSO-CDR-HS	1,00000 (0,000000)	
print tokens	BMOPSO-CDR	1,00000 (0,000000)	<,0001	print tokens 2	BMOPSO-CDR	1,00000 (0,000000)	<,0001	replace	BMOPSO-CDR	1,00000 (0,000000)	<,0001
	BMOPSO-CDR-FB	0,63579 (0,145179)			BMOPSO-CDR-FB	0,45402 (0,166541)			BMOPSO-CDR-FB	0,80656 (0,094262)	
	BMOPSO-CDR-1opt	1,00000 (0,000000)			BMOPSO-CDR-1opt	1,00000 (0,000000)			BMOPSO-CDR-1opt	1,00000 (0,000000)	
	BMOPSO-CDR-AG	1,00000 (0,000000)			BMOPSO-CDR-AG	1,00000 (0,000000)			BMOPSO-CDR-AG	1,00000 (0,000000)	
	BMOPSO-CDR-HS	1,00000 (0,000000)			BMOPSO-CDR-HS	1,00000 (0,000000)			BMOPSO-CDR-HS	1,00000 (0,000000)	
schedule	BMOPSO-CDR	1,00000 (0,000000)	<,0001	schedule 2	BMOPSO-CDR	1,00000 (0,000000)	<,0001	sed	BMOPSO-CDR	1,00000 (0,000000)	<,0001
	BMOPSO-CDR-FB	0,57493 (0,109882)			BMOPSO-CDR-FB	0,34991 (0,114846)			BMOPSO-CDR-FB	0,97227 (0,022870)	
	BMOPSO-CDR-1opt	0,90823 (0,133296)			BMOPSO-CDR-1opt	0,86002 (0,130694)			BMOPSO-CDR-1opt	1,00000 (0,000000)	
	BMOPSO-CDR-AG	1,00000 (0,000000)			BMOPSO-CDR-AG	1,00000 (0,000000)			BMOPSO-CDR-AG	1,00000 (0,000000)	
	BMOPSO-CDR-HS	1,00000 (0,000000)			BMOPSO-CDR-HS	1,00000 (0,000000)			BMOPSO-CDR-HS	1,00000 (0,000000)	
space	BMOPSO-CDR	1,00000 (0,000000)	<,0001	tcas	BMOPSO-CDR	1,00000 (0,000000)	<,0001	totinfo	BMOPSO-CDR	1,00000 (0,000000)	<,0001
	BMOPSO-CDR-FB	0,93441 (0,043376)			BMOPSO-CDR-FB	0,21871 (0,076090)			BMOPSO-CDR-FB	0,34346 (0,112185)	
	BMOPSO-CDR-1opt	1,00000 (0,000000)			BMOPSO-CDR-1opt	0,32405 (0,096074)			BMOPSO-CDR-1opt	0,61384 (0,170556)	
	BMOPSO-CDR-AG	1,00000 (0,000000)			BMOPSO-CDR-AG	1,00000 (0,000000)			BMOPSO-CDR-AG	1,00000 (0,000000)	
	BMOPSO-CDR-HS	1,00000 (0,000000)			BMOPSO-CDR-HS	0,75616 (0,100779)			BMOPSO-CDR-HS	1,00000 (0,000000)	

111[illegible]

Tabela A.9: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica MS - Subgrupo 1.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	BMOPSO-CDR	0,32900 (0,019627)	<,0001	grep	BMOPSO-CDR	0,136454 (0,024221)	<,0001	gzip	BMOPSO-CDR	0,234228 (0,026095)	<,0001
	BMOPSO-CDR-FB	1,02008 (0,270286)			BMOPSO-CDR-FB	0,310735 (0,097828)			BMOPSO-CDR-FB	0,992121 (0,003387)	
	BMOPSO-CDR-1opt	0,34462 (0,022149)			BMOPSO-CDR-1opt	0,164965 (0,026438)			BMOPSO-CDR-1opt	0,236817 (0,039734)	
	BMOPSO-CDR-AG	0,26564 (0,007903)			BMOPSO-CDR-AG	0,070257 (0,010846)			BMOPSO-CDR-AG	0,189005 (0,027689)	
	BMOPSO-CDR-HS	0,29879 (0,011508)			BMOPSO-CDR-HS	0,155288 (0,016567)			BMOPSO-CDR-HS	0,191868 (0,027845)	
print tokens	BMOPSO-CDR	0,013324 (0,012787)	<,0001	print tokens 2	BMOPSO-CDR	0,002847 (0,004988)	<,0001	replace	BMOPSO-CDR	0,008862 (0,008190)	<,0001
	BMOPSO-CDR-FB	0,989756 (0,003364)			BMOPSO-CDR-FB	0,984230 (0,028251)			BMOPSO-CDR-FB	0,994538 (0,000808)	
	BMOPSO-CDR-1opt	0,041785 (0,017361)			BMOPSO-CDR-1opt	0,016845 (0,012244)			BMOPSO-CDR-1opt	0,007589 (0,006864)	
	BMOPSO-CDR-AG	0,012392 (0,012550)			BMOPSO-CDR-AG	0,002073 (0,003389)			BMOPSO-CDR-AG	0,007660 (0,006047)	
	BMOPSO-CDR-HS	0,029958 (0,018950)			BMOPSO-CDR-HS	0,003731 (0,005162)			BMOPSO-CDR-HS	0,017929 (0,009794)	
schedule	BMOPSO-CDR	0,025068 (0,018555)	<,0001	schedule 2	BMOPSO-CDR	0,014345 (0,013761)	<,0001	sed	BMOPSO-CDR	0,14591 (0,039415)	<,0001
	BMOPSO-CDR-FB	0,982852 (0,012901)			BMOPSO-CDR-FB	0,987191 (0,004181)			BMOPSO-CDR-FB	1,03863 (0,045438)	
	BMOPSO-CDR-1opt	0,841763 (0,200651)			BMOPSO-CDR-1opt	0,887075 (0,211365)			BMOPSO-CDR-1opt	0,17615 (0,065173)	
	BMOPSO-CDR-AG	0,022539 (0,016236)			BMOPSO-CDR-AG	0,014140 (0,013246)			BMOPSO-CDR-AG	0,07068 (0,046421)	
	BMOPSO-CDR-HS	0,045419 (0,021053)			BMOPSO-CDR-HS	0,030894 (0,026068)			BMOPSO-CDR-HS	0,10497 (0,039922)	
space	BMOPSO-CDR	0,292847 (0,057452)	<,0001	tcas	BMOPSO-CDR	0,093830 (0,045639)	<,0001	totinfo	BMOPSO-CDR	0,002062 (0,005934)	<,0001
	BMOPSO-CDR-FB	0,990246 (0,038215)			BMOPSO-CDR-FB	0,990810 (6,274e-8)			BMOPSO-CDR-FB	0,897185 (0,016454)	
	BMOPSO-CDR-1opt	0,438298 (0,070675)			BMOPSO-CDR-1opt	0,989996 (0,008138)			BMOPSO-CDR-1opt	0,893952 (0,028216)	
	BMOPSO-CDR-AG	0,143001 (0,028224)			BMOPSO-CDR-AG	0,070038 (0,045381)			BMOPSO-CDR-AG	0,001824 (0,004544)	
	BMOPSO-CDR-HS	0,326071 (0,038251)			BMOPSO-CDR-HS	0,974535 (0,032712)			BMOPSO-CDR-HS	0,025736 (0,026466)	

Tabela A.10: Resultados do teste Steel-Dwass - Métrica MS - Subgrupo 1

[illegible]

Tabela A.11: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica HV - Subgrupo 2.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	BSMPSO	0,684828 (0,004771)	<,0001	grep	BSMPSO	0,590990 (0,006533)	<,0001	gzip	BSMPSO	0,728726 (0,006533)	<,0001
	BSMPSO-FB	0,931934 (0,044860)			BSMPSO-FB	0,791560 (0,051847)			BSMPSO-FB	0,992959 (0,002088)	
	BSMPSO-1opt	0,715609 (0,008082)			BSMPSO-1opt	0,630829 (0,011313)			BSMPSO-1opt	0,884618 (0,015580)	
	BSMPSO-AG	0,673657 (0,006526)			BSMPSO-AG	0,574234 (0,007545)			BSMPSO-AG	0,720772 (0,008886)	
	BSMPSO-HS	0,812810 (0,005489)			BSMPSO-HS	0,744863 (0,006647)			BSMPSO-HS	0,932100 (0,005314)	
print tokens	BSMPSO	0,619802 (0,007141)	<,0001	print tokens 2	BSMPSO	0,609984 (0,006173)	<,0001	replace	BSMPSO	0,610956 (0,007107)	<,0001
	BSMPSO-FB	0,995727 (0,000145)			BSMPSO-FB	0,997000 (0,000124)			BSMPSO-FB	0,994967 (0,002375)	
	BSMPSO-1opt	0,788545 (0,017175)			BSMPSO-1opt	0,788436 (0,012067)			BSMPSO-1opt	0,780210 (0,015958)	
	BSMPSO-AG	0,612918 (0,006689)			BSMPSO-AG	0,604860 (0,007039)			BSMPSO-AG	0,602925 (0,007790)	
	BSMPSO-HS	0,872618 (0,007292)			BSMPSO-HS	0,850114 (0,006981)			BSMPSO-HS	0,840910 (0,007166)	
schedule	BSMPSO	0,643634 (0,009473)	<,0001	schedule 2	BSMPSO	0,640882 (0,008327)	<,0001	sed	BSMPSO	0,614780 (0,007353)	<,0001
	BSMPSO-FB	0,994715 (0,000158)			BSMPSO-FB	0,995712 (0,000108)			BSMPSO-FB	0,971650 (0,028432)	
	BSMPSO-1opt	0,972736 (0,012915)			BSMPSO-1opt	0,987955 (0,007065)			BSMPSO-1opt	0,692055 (0,012828)	
	BSMPSO-AG	0,637392 (0,010938)			BSMPSO-AG	0,636665 (0,009763)			BSMPSO-AG	0,597720 (0,009621)	
	BSMPSO-HS	0,924104 (0,008048)			BSMPSO-HS	0,922348 (0,008205)			BSMPSO-HS	0,818320 (0,006170)	
space	BSMPSO	0,720974 (0,010753)	<,0001	tcas	BSMPSO	0,732493 (0,012612)	<,0001	totinfo	BSMPSO	0,665341 (0,011761)	<,0001
	BSMPSO-FB	0,976071 (0,001040)			BSMPSO-FB	0,967424 (7,421e-7)			BSMPSO-FB	0,995944 (0,000102)	
	BSMPSO-1opt	0,898990 (0,011499)			BSMPSO-1opt	0,967412 (0,000045)			BSMPSO-1opt	0,995322 (0,001401)	
	BSMPSO-AG	0,702506 (0,013506)			BSMPSO-AG	0,727763 (0,015179)			BSMPSO-AG	0,661254 (0,011126)	
	BSMPSO-HS	0,915943 (0,006184)			BSMPSO-HS	0,967198 (0,000204)			BSMPSO-HS	0,952268 (0,006813)	

115

[illegible]

Tabela A.13: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica GD - Subgrupo 2.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	BSMPSO	0,046335 (0,007475)	<,0001	grep	BSMPSO	0,079154 (0,010118)	<,0001	gzip	BSMPSO	0,057194 (0,007222)	<,0001
	BSMPSO-FB	0,012893 (0,007409)			BSMPSO-FB	0,029929 (0,003420)			BSMPSO-FB	0,000263 (0,000341)	
	BSMPSO-1opt	0,026727 (0,004540)			BSMPSO-1opt	0,046054 (0,004335)			BSMPSO-1opt	0,017279 (0,002741)	
	BSMPSO-AG	0,017345 (0,004361)			BSMPSO-AG	0,048689 (0,003351)			BSMPSO-AG	0,043723 (0,004282)	
	BSMPSO-HS	0,023137 (0,002827)			BSMPSO-HS	0,027467 (0,002559)			BSMPSO-HS	0,011792 (0,001192)	
print tokens	BSMPSO	0,289718 (0,059427)	<,0001	print tokens 2	BSMPSO	0,331309 (0,055268)	<,0001	replace	BSMPSO	0,274564 (0,055568)	<,0001
	BSMPSO-FB	0,001193 (0,000417)			BSMPSO-FB	0,000791 (0,001007)			BSMPSO-FB	0,000965 (0,001753)	
	BSMPSO-1opt	0,107443 (0,022739)			BSMPSO-1opt	0,164573 (0,036276)			BSMPSO-1opt	0,152143 (0,035958)	
	BSMPSO-AG	0,296191 (0,066349)			BSMPSO-AG	0,340111 (0,056275)			BSMPSO-AG	0,288872 (0,062935)	
	BSMPSO-HS	0,069278 (0,013460)			BSMPSO-HS	0,120605 (0,021280)			BSMPSO-HS	0,083583 (0,022256)	
schedule	BSMPSO	0,231762 (0,041958)	<,0001	schedule 2	BSMPSO	0,253667 (0,047595)	<,0001	sed	BSMPSO	0,098939 (0,011224)	<,0001
	BSMPSO-FB	0,000861 (0,000502)			BSMPSO-FB	0,000600 (0,000550)			BSMPSO-FB	0,005292 (0,006183)	
	BSMPSO-1opt	0,008248 (0,004169)			BSMPSO-1opt	0,003689 (0,002410)			BSMPSO-1opt	0,049714 (0,004989)	
	BSMPSO-AG	0,230963 (0,049790)			BSMPSO-AG	0,266155 (0,055801)			BSMPSO-AG	0,084786 (0,008368)	
	BSMPSO-HS	0,035931 (0,006673)			BSMPSO-HS	0,041846 (0,009997)			BSMPSO-HS	0,029152 (0,003211)	
space	BSMPSO	0,050001 (0,007383)	<,0001	tcas	BSMPSO	0,101553 (0,020509)	<,0001	totinfo	BSMPSO	0,304640 (0,034406)	<,0001
	BSMPSO-FB	0,000270 (0,000189)			BSMPSO-FB	0,000179 (0,000224)			BSMPSO-FB	0,001080 (0,000354)	
	BSMPSO-1opt	0,006805 (0,000970)			BSMPSO-1opt	0,000130 (0,000199)			BSMPSO-1opt	0,001698 (0,000920)	
	BSMPSO-AG	0,025874 (0,002524)			BSMPSO-AG	0,103577 (0,023110)			BSMPSO-AG	0,310286 (0,034950)	
	BSMPSO-HS	0,004533 (0,000580)			BSMPSO-HS	0,000603 (0,000226)			BSMPSO-HS	0,025159 (0,006207)	

117

[illegible]

Tabela A.15: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica IGD - Subgrupo 2.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	BSMPSO	0,024282 (0,000494)	<,0001	grep	BSMPSO	0,037376 (0,000826)	<,0001	gzip	BSMPSO	0,020468 (0,000866)	<,0001
	BSMPSO-FB	0,006931 (0,004818)			BSMPSO-FB	0,015700 (0,005304)			BSMPSO-FB	0,000461 (0,000218)	
	BSMPSO-1opt	0,023106 (0,000624)			BSMPSO-1opt	0,033208 (0,001372)			BSMPSO-1opt	0,014007 (0,001161)	
	BSMPSO-AG	0,024955 (0,000517)			BSMPSO-AG	0,040449 (0,000889)			BSMPSO-AG	0,020898 (0,000943)	
	BSMPSO-HS	0,020497 (0,000559)			BSMPSO-HS	0,021027 (0,000831)			BSMPSO-HS	0,014695 (0,001203)	
print tokens	BSMPSO	0,093082 (0,001306)	<,0001	print tokens 2	BSMPSO	0,088328 (0,000726)	<,0001	replace	BSMPSO	0,070818 (0,000916)	<,0001
	BSMPSO-FB	0,011155 (0,004345)			BSMPSO-FB	0,012813 (0,006320)			BSMPSO-FB	0,005592 (0,001903)	
	BSMPSO-1opt	0,074362 (0,001949)			BSMPSO-1opt	0,071385 (0,001592)			BSMPSO-1opt	0,057186 (0,001284)	
	BSMPSO-AG	0,093937 (0,001257)			BSMPSO-AG	0,088925 (0,000793)			BSMPSO-AG	0,071702 (0,000828)	
	BSMPSO-HS	0,069748 (0,002395)			BSMPSO-HS	0,068414 (0,000599)			BSMPSO-HS	0,052890 (0,000992)	
schedule	BSMPSO	0,105884 (0,001973)	<,0001	schedule 2	BSMPSO	0,101888 (0,001545)	<,0001	sed	BSMPSO	0,026551 (0,000805)	<,0001
	BSMPSO-FB	0,015880 (0,005683)			BSMPSO-FB	0,011647 (0,005629)			BSMPSO-FB	0,003164 (0,003958)	
	BSMPSO-1opt	0,027225 (0,016886)			BSMPSO-1opt	0,021931 (0,014693)			BSMPSO-1opt	0,021862 (0,001278)	
	BSMPSO-AG	0,106744 (0,002165)			BSMPSO-AG	0,102777 (0,001612)			BSMPSO-AG	0,027573 (0,000948)	
	BSMPSO-HS	0,079435 (0,003170)			BSMPSO-HS	0,073329 (0,003712)			BSMPSO-HS	0,017094 (0,001036)	
space	BSMPSO	0,018723 (0,000905)	<,0001	tcas	BSMPSO	0,075502 (0,002901)	<,0001	totinfo	BSMPSO	0,100208 (0,001645)	<,0001
	BSMPSO-FB	0,000471 (0,000166)			BSMPSO-FB	0,001560 (0,000745)			BSMPSO-FB	0,010127 (0,004198)	
	BSMPSO-1opt	0,007835 (0,001413)			BSMPSO-1opt	0,001343 (0,000716)			BSMPSO-1opt	0,013639 (0,005588)	
	BSMPSO-AG	0,020097 (0,000940)			BSMPSO-AG	0,076218 (0,003009)			BSMPSO-AG	0,100796 (0,001610)	
	BSMPSO-HS	0,010657 (0,001333)			BSMPSO-HS	0,001951 (0,001204)			BSMPSO-HS	0,071393 (0,003543)	

119

[illegible]

Tabela A.17: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica CVR - Subgrupo 2.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	BSMPSO	1,00000 (0,000000)	<,0001	grep	BSMPSO	1,00000 (0)	1,0000	gzip	BSMPSO	1,00000 (0,000000)	<,0001
	BSMPSO-FB	0,97171 (0,065427)			BSMPSO-FB	1,00000 (0)			BSMPSO-FB	0,83642 (0,083734)	
	BSMPSO-1opt	1,00000 (0,000000)			BSMPSO-1opt	1,00000 (0)			BSMPSO-1opt	1,00000 (0,000000)	
	BSMPSO-AG	1,00000 (0,000000)			BSMPSO-AG	1,00000 (0)			BSMPSO-AG	1,00000 (0,000000)	
	BSMPSO-HS	1,00000 (0,000000)			BSMPSO-HS	1,00000 (0)			BSMPSO-HS	1,00000 (0,000000)	
print tokens	BSMPSO	1,00000 (0,000000)	<,0001	print tokens 2	BSMPSO	1,00000 (0,000000)	<,0001	replace	BSMPSO	1,00000 (0,000000)	<,0001
	BSMPSO-FB	0,66307 (0,157174)			BSMPSO-FB	0,45473 (0,171951)			BSMPSO-FB	0,80381 (0,091510)	
	BSMPSO-1opt	1,00000 (0,000000)			BSMPSO-1opt	1,00000 (0,000000)			BSMPSO-1opt	1,00000 (0,000000)	
	BSMPSO-AG	1,00000 (0,000000)			BSMPSO-AG	1,00000 (0,000000)			BSMPSO-AG	1,00000 (0,000000)	
	BSMPSO-HS	1,00000 (0,000000)			BSMPSO-HS	1,00000 (0,000000)			BSMPSO-HS	1,00000 (0,000000)	
schedule	BSMPSO	1,00000 (0,000000)	<,0001	schedule 2	BSMPSO	1,00000 (0,000000)	<,0001	sed	BSMPSO	1,00000 (0,000000)	<,0001
	BSMPSO-FB	0,57429 (0,085260)			BSMPSO-FB	0,33012 (0,105064)			BSMPSO-FB	0,96837 (0,048505)	
	BSMPSO-1opt	0,99497 (0,026628)			BSMPSO-1opt	0,94782 (0,103552)			BSMPSO-1opt	1,00000 (0,000000)	
	BSMPSO-AG	1,00000 (0,000000)			BSMPSO-AG	1,00000 (0,000000)			BSMPSO-AG	1,00000 (0,000000)	
	BSMPSO-HS	1,00000 (0,000000)			BSMPSO-HS	1,00000 (0,000000)			BSMPSO-HS	1,00000 (0,000000)	
space	BSMPSO	1,00000 (0,000000)	<,0001	tcas	BSMPSO	1,00000 (0,000000)	<,0001	totinfo	BSMPSO	1,00000 (0,000000)	<,0001
	BSMPSO-FB	0,91959 (0,049377)			BSMPSO-FB	0,22783 (0,052537)			BSMPSO-FB	0,34223 (0,096507)	
	BSMPSO-1opt	1,00000 (0,000000)			BSMPSO-1opt	0,33968 (0,093262)			BSMPSO-1opt	0,67764 (0,150891)	
	BSMPSO-AG	1,00000 (0,000000)			BSMPSO-AG	1,00000 (0,000000)			BSMPSO-AG	1,00000 (0,000000)	
	BSMPSO-HS	1,00000 (0,000000)			BSMPSO-HS	0,76054 (0,087684)			BSMPSO-HS	1,00000 (0,000000)	

Tabela A.18: Resultados do teste Steel-Dwass - Métrica CVR - Subgrupo 2.

Steel-Dwass (valor p)				Steel-Dwass (valor p)				Steel-Dwass (valor p)			
flex	BSMPSO	BSMPSO-FB	<,0001	gzip	BSMPSO	BSMPSO-FB	<,0001	print tokens	BSMPSO	BSMPSO-FB	<,0001
	BSMPSO	BSMPSO-1opt	1,0000		BSMPSO	BSMPSO-1opt	1,0000		BSMPSO	BSMPSO-1opt	1,0000
	BSMPSO	BSMPSO-AG	1,0000		BSMPSO	BSMPSO-AG	1,0000		BSMPSO	BSMPSO-AG	1,0000
	BSMPSO	BSMPSO-HS	1,0000		BSMPSO	BSMPSO-HS	1,0000		BSMPSO	BSMPSO-HS	1,0000
	BSMPSO-FB	BSMPSO-1opt	<,0001		BSMPSO-FB	BSMPSO-1opt	<,0001		BSMPSO-FB	BSMPSO-1opt	<,0001
	BSMPSO-FB	BSMPSO-AG	<,0001		BSMPSO-FB	BSMPSO-AG	<,0001		BSMPSO-FB	BSMPSO-AG	<,0001
	BSMPSO-FB	BSMPSO-HS	<,0001		BSMPSO-FB	BSMPSO-HS	<,0001		BSMPSO-FB	BSMPSO-HS	<,0001
	BSMPSO-1opt	BSMPSO-AG	1,0000		BSMPSO-1opt	BSMPSO-AG	1,0000		BSMPSO-1opt	BSMPSO-AG	1,0000
	BSMPSO-1opt	BSMPSO-HS	1,0000		BSMPSO-1opt	BSMPSO-HS	1,0000		BSMPSO-1opt	BSMPSO-HS	1,0000
	BSMPSO-AG	BSMPSO-HS	1,0000		BSMPSO-AG	BSMPSO-HS	1,0000		BSMPSO-AG	BSMPSO-HS	1,0000
print tokens 2	BSMPSO	BSMPSO-FB	<,0001	replace	BSMPSO	BSMPSO-FB	<,0001	schedule	BSMPSO	BSMPSO-FB	<,0001
	BSMPSO	BSMPSO-1opt	1,0000		BSMPSO	BSMPSO-1opt	1,0000		BSMPSO	BSMPSO-1opt	0,1601
	BSMPSO	BSMPSO-AG	1,0000		BSMPSO	BSMPSO-AG	1,0000		BSMPSO	BSMPSO-AG	1,0000
	BSMPSO	BSMPSO-HS	1,0000		BSMPSO	BSMPSO-HS	1,0000		BSMPSO	BSMPSO-HS	1,0000
	BSMPSO-FB	BSMPSO-1opt	<,0001		BSMPSO-FB	BSMPSO-1opt	<,0001		BSMPSO-FB	BSMPSO-1opt	<,0001
	BSMPSO-FB	BSMPSO-AG	<,0001		BSMPSO-FB	BSMPSO-AG	<,0001		BSMPSO-FB	BSMPSO-AG	<,0001
	BSMPSO-FB	BSMPSO-HS	<,0001		BSMPSO-FB	BSMPSO-HS	<,0001		BSMPSO-FB	BSMPSO-HS	<,0001
	BSMPSO-1opt	BSMPSO-AG	1,0000		BSMPSO-1opt	BSMPSO-AG	1,0000		BSMPSO-1opt	BSMPSO-AG	0,1601
	BSMPSO-1opt	BSMPSO-HS	1,0000		BSMPSO-1opt	BSMPSO-HS	1,0000		BSMPSO-1opt	BSMPSO-HS	0,1601
	BSMPSO-AG	BSMPSO-HS	1,0000		BSMPSO-AG	BSMPSO-HS	1,0000		BSMPSO-AG	BSMPSO-HS	1,0000
schedule 2	BSMPSO	BSMPSO-FB	<,0001	sed	BSMPSO	BSMPSO-FB	<,0001	space	BSMPSO	BSMPSO-FB	<,0001
	BSMPSO	BSMPSO-1opt	<,0001		BSMPSO	BSMPSO-1opt	1,0000		BSMPSO	BSMPSO-1opt	1,0000
	BSMPSO	BSMPSO-AG	1,0000		BSMPSO	BSMPSO-AG	1,0000		BSMPSO	BSMPSO-AG	1,0000
	BSMPSO	BSMPSO-HS	1,0000		BSMPSO	BSMPSO-HS	1,0000		BSMPSO	BSMPSO-HS	1,0000
	BSMPSO-FB	BSMPSO-1opt	<,0001		BSMPSO-FB	BSMPSO-1opt	<,0001		BSMPSO-FB	BSMPSO-1opt	<,0001
	BSMPSO-FB	BSMPSO-AG	<,0001		BSMPSO-FB	BSMPSO-AG	<,0001		BSMPSO-FB	BSMPSO-AG	<,0001
	BSMPSO-FB	BSMPSO-HS	<,0001		BSMPSO-FB	BSMPSO-HS	<,0001		BSMPSO-FB	BSMPSO-HS	<,0001
	BSMPSO-1opt	BSMPSO-AG	<,0001		BSMPSO-1opt	BSMPSO-AG	1,0000		BSMPSO-1opt	BSMPSO-AG	1,0000
	BSMPSO-1opt	BSMPSO-HS	<,0001		BSMPSO-1opt	BSMPSO-HS	1,0000		BSMPSO-1opt	BSMPSO-HS	1,0000
	BSMPSO-AG	BSMPSO-HS	1,0000		BSMPSO-AG	BSMPSO-HS	1,0000		BSMPSO-AG	BSMPSO-HS	1,0000
tcas	BSMPSO	BSMPSO-FB	<,0001	totinfo	BSMPSO	BSMPSO-FB	<,0001				
	BSMPSO	BSMPSO-1opt	<,0001		BSMPSO	BSMPSO-1opt	<,0001				
	BSMPSO	BSMPSO-AG	1,0000		BSMPSO	BSMPSO-AG	1,0000				
	BSMPSO	BSMPSO-HS	<,0001		BSMPSO	BSMPSO-HS	1,0000				
	BSMPSO-FB	BSMPSO-1opt	<,0001		BSMPSO-FB	BSMPSO-1opt	<,0001				
	BSMPSO-FB	BSMPSO-AG	<,0001		BSMPSO-FB	BSMPSO-AG	<,0001				
	BSMPSO-FB	BSMPSO-HS	<,0001		BSMPSO-FB	BSMPSO-HS	<,0001				
	BSMPSO-1opt	BSMPSO-AG	<,0001		BSMPSO-1opt	BSMPSO-AG	<,0001				
	BSMPSO-1opt	BSMPSO-HS	<,0001		BSMPSO-1opt	BSMPSO-HS	<,0001				
	BSMPSO-AG	BSMPSO-HS	<,0001		BSMPSO-AG	BSMPSO-HS	1,0000				

Tabela A.19: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica MS - Subgrupo 2.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	BSMPSO	0,32795 (0,018319)	<,0001	grep	BSMPSO	0,128869 (0,025745)	<,0001	gzip	BSMPSO	0,311720 (0,064398)	<,0001
	BSMPSO-FB	1,02119 (0,271736)			BSMPSO-FB	0,315080 (0,080544)			BSMPSO-FB	0,992801 (0,004758)	
	BSMPSO-1opt	0,34553 (0,020405)			BSMPSO-1opt	0,164971 (0,031367)			BSMPSO-1opt	0,255434 (0,041166)	
	BSMPSO-AG	0,26767 (0,007145)			BSMPSO-AG	0,072745 (0,011570)			BSMPSO-AG	0,211746 (0,033460)	
	BSMPSO-HS	0,29676 (0,010885)			BSMPSO-HS	0,157079 (0,022347)			BSMPSO-HS	0,187590 (0,022328)	
print tokens	BSMPSO	0,012988 (0,012511)	<,0001	print tokens 2	BSMPSO	0,004552 (0,005960)	<,0001	replace	BSMPSO	0,013065 (0,010721)	<,0001
	BSMPSO-FB	0,989953 (0,002762)			BSMPSO-FB	0,986666 (0,003299)			BSMPSO-FB	0,993491 (0,015181)	
	BSMPSO-1opt	0,036032 (0,013075)			BSMPSO-1opt	0,011020 (0,011606)			BSMPSO-1opt	0,007011 (0,007209)	
	BSMPSO-AG	0,010334 (0,011215)			BSMPSO-AG	0,002720 (0,003755)			BSMPSO-AG	0,006404 (0,006332)	
	BSMPSO-HS	0,030697 (0,018994)			BSMPSO-HS	0,004049 (0,005307)			BSMPSO-HS	0,018940 (0,011669)	
schedule	BSMPSO	0,031444 (0,015349)	<,0001	schedule 2	BSMPSO	0,019534 (0,012943)	<,0001	sed	BSMPSO	0,15789 (0,040706)	<,0001
	BSMPSO-FB	0,984142 (0,000042)			BSMPSO-FB	0,987923 (5,216e-6)			BSMPSO-FB	1,03942 (0,047619)	
	BSMPSO-1opt	0,560602 (0,234649)			BSMPSO-1opt	0,684424 (0,286025)			BSMPSO-1opt	0,16425 (0,063183)	
	BSMPSO-AG	0,026618 (0,017290)			BSMPSO-AG	0,012384 (0,010298)			BSMPSO-AG	0,08512 (0,058965)	
	BSMPSO-HS	0,045603 (0,022477)			BSMPSO-HS	0,036828 (0,028131)			BSMPSO-HS	0,09985 (0,036905)	
space	BSMPSO	0,311659 (0,057718)	<,0001	tcas	BSMPSO	0,046463 (0,027329)	<,0001	totinfo	BSMPSO	0,002588 (0,006253)	<,0001
	BSMPSO-FB	0,991693 (0,037234)			BSMPSO-FB	0,990810 (6,596e-8)			BSMPSO-FB	0,898830 (1,565e-6)	
	BSMPSO-1opt	0,413299 (0,069439)			BSMPSO-1opt	0,989183 (0,011450)			BSMPSO-1opt	0,893451 (0,031379)	
	BSMPSO-AG	0,155759 (0,027859)			BSMPSO-AG	0,036042 (0,025974)			BSMPSO-AG	0,001826 (0,004549)	
	BSMPSO-HS	0,324180 (0,042176)			BSMPSO-HS	0,976495 (0,039286)			BSMPSO-HS	0,026697 (0,025367)	

Tabela A.20: Resultados do teste Steel-Dwass - Métrica MS - Subgrupo 2.

Steel-Dwass (valor p)				Steel-Dwass (valor p)				Steel-Dwass (valor p)			
flex	BSMPSO	BSMPSO-FB	<,0001	grep	BSMPSO	BSMPSO-FB	<,0001	gzip	BSMPSO	BSMPSO-FB	<,0001
	BSMPSO	BSMPSO-1opt	<,0001		BSMPSO	BSMPSO-1opt	<,0001		BSMPSO	BSMPSO-1opt	<,0001
	BSMPSO	BSMPSO-AG	<,0001		BSMPSO	BSMPSO-AG	<,0001		BSMPSO	BSMPSO-AG	<,0001
	BSMPSO	BSMPSO-HS	<,0001		BSMPSO	BSMPSO-HS	<,0001		BSMPSO	BSMPSO-HS	<,0001
	BSMPSO-FB	BSMPSO-1opt	<,0001		BSMPSO-FB	BSMPSO-1opt	<,0001		BSMPSO-FB	BSMPSO-1opt	<,0001
	BSMPSO-FB	BSMPSO-AG	<,0001		BSMPSO-FB	BSMPSO-AG	<,0001		BSMPSO-FB	BSMPSO-AG	<,0001
	BSMPSO-FB	BSMPSO-HS	<,0001		BSMPSO-FB	BSMPSO-HS	<,0001		BSMPSO-FB	BSMPSO-HS	<,0001
	BSMPSO-1opt	BSMPSO-AG	<,0001		BSMPSO-1opt	BSMPSO-AG	<,0001		BSMPSO-1opt	BSMPSO-AG	<,0001
	BSMPSO-1opt	BSMPSO-HS	<,0001		BSMPSO-1opt	BSMPSO-HS	0,2600		BSMPSO-1opt	BSMPSO-HS	<,0001
BSMPSO-AG	BSMPSO-HS	<,0001	BSMPSO-AG	BSMPSO-HS	<,0001	BSMPSO-AG	BSMPSO-HS	<,0001			
print tokens	BSMPSO	BSMPSO-FB	<,0001	print tokens 2	BSMPSO	BSMPSO-FB	<,0001	replace	BSMPSO	BSMPSO-FB	<,0001
	BSMPSO	BSMPSO-1opt	<,0001		BSMPSO	BSMPSO-1opt	0,0015		BSMPSO	BSMPSO-1opt	0,0001
	BSMPSO	BSMPSO-AG	0,4895		BSMPSO	BSMPSO-AG	0,3725		BSMPSO	BSMPSO-AG	<,0001
	BSMPSO	BSMPSO-HS	<,0001		BSMPSO	BSMPSO-HS	0,9919		BSMPSO	BSMPSO-HS	0,0025
	BSMPSO-FB	BSMPSO-1opt	<,0001		BSMPSO-FB	BSMPSO-1opt	<,0001		BSMPSO-FB	BSMPSO-1opt	<,0001
	BSMPSO-FB	BSMPSO-AG	<,0001		BSMPSO-FB	BSMPSO-AG	<,0001		BSMPSO-FB	BSMPSO-AG	<,0001
	BSMPSO-FB	BSMPSO-HS	<,0001		BSMPSO-FB	BSMPSO-HS	<,0001		BSMPSO-FB	BSMPSO-HS	<,0001
	BSMPSO-1opt	BSMPSO-AG	<,0001		BSMPSO-1opt	BSMPSO-AG	<,0001		BSMPSO-1opt	BSMPSO-AG	0,9243
	BSMPSO-1opt	BSMPSO-HS	0,0491		BSMPSO-1opt	BSMPSO-HS	0,0008		BSMPSO-1opt	BSMPSO-HS	<,0001
BSMPSO-AG	BSMPSO-HS	<,0001	BSMPSO-AG	BSMPSO-HS	0,5843	BSMPSO-AG	BSMPSO-HS	<,0001			
schedule	BSMPSO	BSMPSO-FB	<,0001	schedule 2	BSMPSO	BSMPSO-FB	<,0001	sed	BSMPSO	BSMPSO-FB	<,0001
	BSMPSO	BSMPSO-1opt	<,0001		BSMPSO	BSMPSO-1opt	<,0001		BSMPSO	BSMPSO-1opt	0,9803
	BSMPSO	BSMPSO-AG	0,0099		BSMPSO	BSMPSO-AG	<,0001		BSMPSO	BSMPSO-AG	<,0001
	BSMPSO	BSMPSO-HS	0,0004		BSMPSO	BSMPSO-HS	<,0001		BSMPSO	BSMPSO-HS	<,0001
	BSMPSO-FB	BSMPSO-1opt	<,0001		BSMPSO-FB	BSMPSO-1opt	0,0004		BSMPSO-FB	BSMPSO-1opt	<,0001
	BSMPSO-FB	BSMPSO-AG	<,0001		BSMPSO-FB	BSMPSO-AG	<,0001		BSMPSO-FB	BSMPSO-AG	<,0001
	BSMPSO-FB	BSMPSO-HS	<,0001		BSMPSO-FB	BSMPSO-HS	<,0001		BSMPSO-FB	BSMPSO-HS	<,0001
	BSMPSO-1opt	BSMPSO-AG	<,0001		BSMPSO-1opt	BSMPSO-AG	<,0001		BSMPSO-1opt	BSMPSO-AG	<,0001
	BSMPSO-1opt	BSMPSO-HS	<,0001		BSMPSO-1opt	BSMPSO-HS	<,0001		BSMPSO-1opt	BSMPSO-HS	<,0001
BSMPSO-AG	BSMPSO-HS	<,0001	BSMPSO-AG	BSMPSO-HS	<,0001	BSMPSO-AG	BSMPSO-HS	<,0001			
space	BSMPSO	BSMPSO-FB	<,0001	tcas	BSMPSO	BSMPSO-FB	<,0001	totinfo	BSMPSO	BSMPSO-FB	<,0001
	BSMPSO	BSMPSO-1opt	<,0001		BSMPSO	BSMPSO-1opt	<,0001		BSMPSO	BSMPSO-1opt	<,0001
	BSMPSO	BSMPSO-AG	<,0001		BSMPSO	BSMPSO-AG	0,0226		BSMPSO	BSMPSO-AG	0,9807
	BSMPSO	BSMPSO-HS	0,4373		BSMPSO	BSMPSO-HS	<,0001		BSMPSO	BSMPSO-HS	<,0001
	BSMPSO-FB	BSMPSO-1opt	<,0001		BSMPSO-FB	BSMPSO-1opt	<,0001		BSMPSO-FB	BSMPSO-1opt	<,0001
	BSMPSO-FB	BSMPSO-AG	<,0001		BSMPSO-FB	BSMPSO-AG	<,0001		BSMPSO-FB	BSMPSO-AG	<,0001
	BSMPSO-FB	BSMPSO-HS	<,0001		BSMPSO-FB	BSMPSO-HS	<,0001		BSMPSO-FB	BSMPSO-HS	<,0001
	BSMPSO-1opt	BSMPSO-AG	<,0001		BSMPSO-1opt	BSMPSO-AG	<,0001		BSMPSO-1opt	BSMPSO-AG	<,0001
	BSMPSO-1opt	BSMPSO-HS	<,0001		BSMPSO-1opt	BSMPSO-HS	0,0002		BSMPSO-1opt	BSMPSO-HS	<,0001
BSMPSO-AG	BSMPSO-HS	<,0001	BSMPSO-AG	BSMPSO-HS	<,0001	BSMPSO-AG	BSMPSO-HS	<,0001			

Tabela A.21: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica HV - Subgrupo 3.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	NSGA-II	0,793056 (0,012883)	<,0001	grep	NSGA-II	0,707444 (0,013348)	<,0001	gzip	NSGA-II	0,891757 (0,015843)	<,0001
	NSGA-II-FB	0,909780 (0,064692)			NSGA-II-FB	0,769475 (0,072019)			NSGA-II-FB	0,993719 (0,000150)	
	NSGA-II-1opt	0,763116 (0,011139)			NSGA-II-1opt	0,672076 (0,012670)			NSGA-II-1opt	0,982481 (0,008097)	
	NSGA-II-AG	0,697424 (0,012584)			NSGA-II-AG	0,592509 (0,011512)			NSGA-II-AG	0,821230 (0,026374)	
	NSGA-II-HS	0,885967 (0,008287)			NSGA-II-HS	0,811667 (0,010073)			NSGA-II-HS	0,979649 (0,004200)	
print tokens	NSGA-II	0,808281 (0,017446)	<,0001	print tokens 2	NSGA-II	0,778820 (0,019046)	<,0001	replace	NSGA-II	0,779125 (0,019750)	<,0001
	NSGA-II-FB	0,984248 (0,041957)			NSGA-II-FB	0,988793 (0,020844)			NSGA-II-FB	0,986274 (0,029474)	
	NSGA-II-1opt	0,992380 (0,005227)			NSGA-II-1opt	0,970745 (0,009923)			NSGA-II-1opt	0,944516 (0,015764)	
	NSGA-II-AG	0,791193 (0,023191)			NSGA-II-AG	0,775012 (0,017018)			NSGA-II-AG	0,762299 (0,019439)	
	NSGA-II-HS	0,937641 (0,010911)			NSGA-II-HS	0,907261 (0,013267)			NSGA-II-HS	0,907447 (0,011041)	
schedule	NSGA-II	0,860073 (0,022286)	<,0001	schedule 2	NSGA-II	0,844775 (0,023838)	<,0001	sed	NSGA-II	0,776256 (0,021504)	<,0001
	NSGA-II-FB	0,986119 (0,015777)			NSGA-II-FB	0,995792 (0,000084)			NSGA-II-FB	0,940371 (0,085567)	
	NSGA-II-1opt	0,994872 (0,000115)			NSGA-II-1opt	0,995764 (0,000085)			NSGA-II-1opt	0,788525 (0,021083)	
	NSGA-II-AG	0,832110 (0,024866)			NSGA-II-AG	0,835084 (0,024418)			NSGA-II-AG	0,670453 (0,020484)	
	NSGA-II-HS	0,974099 (0,008791)			NSGA-II-HS	0,969272 (0,009077)			NSGA-II-HS	0,895499 (0,008955)	
space	NSGA-II	0,852741 (0,017167)	<,0001	tcas	NSGA-II	0,946595 (0,013459)	<,0001	totinfo	NSGA-II	0,873352 (0,021154)	<,0001
	NSGA-II-FB	0,976232 (0,000817)			NSGA-II-FB	0,965271 (0,015681)			NSGA-II-FB	0,964907 (0,065849)	
	NSGA-II-1opt	0,920078 (0,009330)			NSGA-II-1opt	0,967425 (1,129e-6)			NSGA-II-1opt	0,996076 (0,000033)	
	NSGA-II-AG	0,746189 (0,024539)			NSGA-II-AG	0,936375 (0,015912)			NSGA-II-AG	0,869034 (0,021947)	
	NSGA-II-HS	0,949054 (0,006916)			NSGA-II-HS	0,967411 (0,000050)			NSGA-II-HS	0,985176 (0,005413)	

Tabela A.22: Resultados do teste Steel-Dwass - Métrica HV - Subgrupo 3.

[illegible]

Tabela A.23: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica GD - Subgrupo 3.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	NSGA-II	0,018868 (0,004510)	<,0001	grep	NSGA-II	0,025310 (0,005916)	<,0001	gzip	NSGA-II	0,009948 (0,002661)	<,0001
	NSGA-II-FB	0,018067 (0,011891)			NSGA-II-FB	0,033786 (0,013047)			NSGA-II-FB	0,000122 (0,000078)	
	NSGA-II-1opt	0,024012 (0,003612)			NSGA-II-1opt	0,037692 (0,005016)			NSGA-II-1opt	0,001148 (0,001191)	
	NSGA-II-AG	0,027769 (0,009034)			NSGA-II-AG	0,054541 (0,010076)			NSGA-II-AG	0,026289 (0,006536)	
	NSGA-II-HS	0,013247 (0,002430)			NSGA-II-HS	0,008636 (0,001802)			NSGA-II-HS	0,000745 (0,000379)	
print tokens	NSGA-II	0,108887 (0,028284)	<,0001	print tokens 2	NSGA-II	0,167845 (0,039791)	<,0001	replace	NSGA-II	0,130183 (0,037121)	<,0001
	NSGA-II-FB	0,005242 (0,015920)			NSGA-II-FB	0,003146 (0,006693)			NSGA-II-FB	0,002524 (0,006818)	
	NSGA-II-1opt	0,002206 (0,001343)			NSGA-II-1opt	0,009894 (0,004677)			NSGA-II-1opt	0,012816 (0,004631)	
	NSGA-II-AG	0,116482 (0,029363)			NSGA-II-AG	0,172912 (0,036996)			NSGA-II-AG	0,140303 (0,037116)	
	NSGA-II-HS	0,024619 (0,007884)			NSGA-II-HS	0,059540 (0,019643)			NSGA-II-HS	0,035079 (0,009232)	
schedule	NSGA-II	0,065434 (0,015920)	<,0001	schedule 2	NSGA-II	0,091661 (0,028742)	<,0001	sed	NSGA-II	0,030028 (0,008938)	<,0001
	NSGA-II-FB	0,003137 (0,003881)			NSGA-II-FB	0,000453 (0,000481)			NSGA-II-FB	0,008296 (0,009277)	
	NSGA-II-1opt	0,000853 (0,000709)			NSGA-II-1opt	0,000665 (0,000667)			NSGA-II-1opt	0,027926 (0,005036)	
	NSGA-II-AG	0,082583 (0,020218)			NSGA-II-AG	0,100516 (0,030688)			NSGA-II-AG	0,069567 (0,010929)	
	NSGA-II-HS	0,007751 (0,003757)			NSGA-II-HS	0,011457 (0,004801)			NSGA-II-HS	0,006383 (0,001547)	
space	NSGA-II	0,003779 (0,000891)	<,0001	tcas	NSGA-II	0,003030 (0,001656)	<,0001	totinfo	NSGA-II	0,096413 (0,027391)	<,0001
	NSGA-II-FB	0,000250 (0,000130)			NSGA-II-FB	0,000558 (0,003193)			NSGA-II-FB	0,027498 (0,060336)	
	NSGA-II-1opt	0,004129 (0,000700)			NSGA-II-1opt	0,000049 (0,000128)			NSGA-II-1opt	0,000778 (0,000682)	
	NSGA-II-AG	0,015999 (0,004476)			NSGA-II-AG	0,004250 (0,002102)			NSGA-II-AG	0,099810 (0,027989)	
	NSGA-II-HS	0,001018 (0,000301)			NSGA-II-HS	0,000162 (0,000210)			NSGA-II-HS	0,004878 (0,002265)	

Tabela A.24: Resultados do teste Steel-Dwass - Métrica GD - Subgrupo 3.

Steel-Dwass (valor p)				Steel-Dwass (valor p)				Steel-Dwass (valor p)			
flex	NSGA-II	NSGA-II-FB	0,1813	grep	NSGA-II	NSGA-II-FB	<,0001	gzip	NSGA-II	NSGA-II-FB	<,0001
	NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001
	NSGA-II	NSGA-II-AG	<,0001		NSGA-II	NSGA-II-AG	<,0001		NSGA-II	NSGA-II-AG	<,0001
	NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001
	NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001
	NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001
	NSGA-II-FB	NSGA-II-HS	0,7205		NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001
	NSGA-II-1opt	NSGA-II-AG	0,0254		NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001
	NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	1,0000
	NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001
print tokens	NSGA-II	NSGA-II-FB	<,0001	print tokens 2	NSGA-II	NSGA-II-FB	<,0001	replace	NSGA-II	NSGA-II-FB	<,0001
	NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001
	NSGA-II	NSGA-II-AG	0,4419		NSGA-II	NSGA-II-AG	0,7649		NSGA-II	NSGA-II-AG	0,1551
	NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001
	NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001
	NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001
	NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001
	NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001
	NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001
	NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001
schedule	NSGA-II	NSGA-II-FB	<,0001	schedule 2	NSGA-II	NSGA-II-FB	<,0001	sed	NSGA-II	NSGA-II-FB	<,0001
	NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	0,8987
	NSGA-II	NSGA-II-AG	<,0001		NSGA-II	NSGA-II-AG	0,1211		NSGA-II	NSGA-II-AG	<,0001
	NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001
	NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	0,0703		NSGA-II-FB	NSGA-II-1opt	<,0001
	NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001
	NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	0,8552
	NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001
	NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001
	NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001
space	NSGA-II	NSGA-II-FB	<,0001	tcas	NSGA-II	NSGA-II-FB	<,0001	totinfo	NSGA-II	NSGA-II-FB	<,0001
	NSGA-II	NSGA-II-1opt	0,0175		NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001
	NSGA-II	NSGA-II-AG	<,0001		NSGA-II	NSGA-II-AG	0,0001		NSGA-II	NSGA-II-AG	0,9356
	NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001
	NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	0,8334		NSGA-II-FB	NSGA-II-1opt	<,0001
	NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001
	NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001
	NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001
	NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001
	NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001

Tabela A.25: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica IGD - Subgrupo 3.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	NSGA-II	0,021284 (0,000716)	<,0001	grep	NSGA-II	0,025194 (0,001510)	<,0001	gzip	NSGA-II	0,016304 (0,001046)	<,0001
	NSGA-II-FB	0,009983 (0,006608)			NSGA-II-FB	0,018132 (0,007927)			NSGA-II-FB	0,000386 (0,000212)	
	NSGA-II-1opt	0,021873 (0,000792)			NSGA-II-1opt	0,029079 (0,001500)			NSGA-II-1opt	0,010582 (0,003112)	
	NSGA-II-AG	0,024543 (0,000601)			NSGA-II-AG	0,038442 (0,001361)			NSGA-II-AG	0,018970 (0,000948)	
	NSGA-II-HS	0,019238 (0,000593)			NSGA-II-HS	0,015521 (0,001097)			NSGA-II-HS	0,013897 (0,001587)	
print tokens	NSGA-II	0,074100 (0,002423)	<,0001	print tokens 2	NSGA-II	0,072716 (0,001540)	<,0001	replace	NSGA-II	0,056989 (0,001582)	<,0001
	NSGA-II-FB	0,010086 (0,015256)			NSGA-II-FB	0,012064 (0,012904)			NSGA-II-FB	0,006504 (0,010346)	
	NSGA-II-1opt	0,010950 (0,005647)			NSGA-II-1opt	0,040449 (0,010338)			NSGA-II-1opt	0,036270 (0,006955)	
	NSGA-II-AG	0,075477 (0,002458)			NSGA-II-AG	0,073050 (0,001333)			NSGA-II-AG	0,058082 (0,001584)	
	NSGA-II-HS	0,063639 (0,004453)			NSGA-II-HS	0,065205 (0,001409)			NSGA-II-HS	0,049428 (0,001283)	
schedule	NSGA-II	0,081981 (0,003039)	<,0001	schedule 2	NSGA-II	0,079113 (0,003256)	<,0001	sed	NSGA-II	0,019237 (0,001280)	<,0001
	NSGA-II-FB	0,015536 (0,012496)			NSGA-II-FB	0,008292 (0,004277)			NSGA-II-FB	0,004657 (0,006364)	
	NSGA-II-1opt	0,010883 (0,006011)			NSGA-II-1opt	0,009890 (0,004915)			NSGA-II-1opt	0,016039 (0,001885)	
	NSGA-II-AG	0,084260 (0,003228)			NSGA-II-AG	0,079924 (0,003125)			NSGA-II-AG	0,024352 (0,001207)	
	NSGA-II-HS	0,070687 (0,010025)			NSGA-II-HS	0,067964 (0,005810)			NSGA-II-HS	0,015357 (0,000666)	
space	NSGA-II	0,016227 (0,001121)	<,0001	tcas	NSGA-II	0,028961 (0,015137)	<,0001	totinfo	NSGA-II	0,077530 (0,002341)	<,0001
	NSGA-II-FB	0,000483 (0,000199)			NSGA-II-FB	0,001756 (0,007462)			NSGA-II-FB	0,017289 (0,028868)	
	NSGA-II-1opt	0,006835 (0,001105)			NSGA-II-1opt	0,000714 (0,000532)			NSGA-II-1opt	0,005381 (0,002015)	
	NSGA-II-AG	0,019870 (0,001070)			NSGA-II-AG	0,034956 (0,012379)			NSGA-II-AG	0,077910 (0,002208)	
	NSGA-II-HS	0,009183 (0,001840)			NSGA-II-HS	0,000634 (0,000234)			NSGA-II-HS	0,053883 (0,013625)	

Tabela A.26: Resultados do teste Steel-Dwass - Métrica IGD - Subgrupo 3.

Steel-Dwass (valor p)				Steel-Dwass (valor p)				Steel-Dwass (valor p)			
flex	NSGA-II	NSGA-II-FB	<,0001	grep	NSGA-II	NSGA-II-FB	<,0001	gzip	NSGA-II	NSGA-II-FB	<,0001
	NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001
	NSGA-II	NSGA-II-AG	<,0001		NSGA-II	NSGA-II-AG	<,0001		NSGA-II	NSGA-II-AG	<,0001
	NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001
	NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001
	NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001
	NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	0,8968		NSGA-II-FB	NSGA-II-HS	<,0001
	NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001
	NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001
	NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001
print tokens	NSGA-II	NSGA-II-FB	<,0001	print tokens 2	NSGA-II	NSGA-II-FB	<,0001	replace	NSGA-II	NSGA-II-FB	<,0001
	NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001
	NSGA-II	NSGA-II-AG	0,0041		NSGA-II	NSGA-II-AG	0,2372		NSGA-II	NSGA-II-AG	<,0001
	NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001
	NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001
	NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001
	NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001
	NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001
	NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001
	NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001
schedule	NSGA-II	NSGA-II-FB	<,0001	schedule 2	NSGA-II	NSGA-II-FB	<,0001	sed	NSGA-II	NSGA-II-FB	<,0001
	NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001
	NSGA-II	NSGA-II-AG	<,0001		NSGA-II	NSGA-II-AG	0,2394		NSGA-II	NSGA-II-AG	<,0001
	NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001
	NSGA-II-FB	NSGA-II-1opt	0,3457		NSGA-II-FB	NSGA-II-1opt	0,1089		NSGA-II-FB	NSGA-II-1opt	<,0001
	NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001
	NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001
	NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001
	NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	0,5583
	NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001
space	NSGA-II	NSGA-II-FB	<,0001	tcas	NSGA-II	NSGA-II-FB	<,0001	totinfo	NSGA-II	NSGA-II-FB	<,0001
	NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001
	NSGA-II	NSGA-II-AG	<,0001		NSGA-II	NSGA-II-AG	0,0178		NSGA-II	NSGA-II-AG	0,8346
	NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001
	NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	0,8157		NSGA-II-FB	NSGA-II-1opt	0,9839
	NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001
	NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	0,0044		NSGA-II-FB	NSGA-II-HS	<,0001
	NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001
	NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	0,0028		NSGA-II-1opt	NSGA-II-HS	<,0001
	NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001

Tabela A.27: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica CVR - Subgrupo 3.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	NSGA-II	1,00000 (0,000000)	<,0001	grep	NSGA-II	1,00000 (0,000000)	0,4060	gzip	NSGA-II	1,00000 (0,000000)	<,0001
	NSGA-II-FB	0,97066 (0,078749)			NSGA-II-FB	0,99979 (0,002083)			NSGA-II-FB	0,80144 (0,097555)	
	NSGA-II-1opt	1,00000 (0,000000)			NSGA-II-1opt	1,00000 (0,000000)			NSGA-II-1opt	1,00000 (0,000000)	
	NSGA-II-AG	1,00000 (0,000000)			NSGA-II-AG	1,00000 (0,000000)			NSGA-II-AG	1,00000 (0,000000)	
	NSGA-II-HS	1,00000 (0,000000)			NSGA-II-HS	1,00000 (0,000000)			NSGA-II-HS	1,00000 (0,000000)	
print tokens	NSGA-II	1,00000 (0,000000)	<,0001	print tokens 2	NSGA-II	1,00000 (0,000000)	<,0001	replace	NSGA-II	1,00000 (0,000000)	<,0001
	NSGA-II-FB	0,57928 (0,253943)			NSGA-II-FB	0,39577 (0,271419)			NSGA-II-FB	0,82885 (0,125364)	
	NSGA-II-1opt	0,89045 (0,137673)			NSGA-II-1opt	0,99970 (0,003030)			NSGA-II-1opt	1,00000 (0,000000)	
	NSGA-II-AG	1,00000 (0,000000)			NSGA-II-AG	1,00000 (0,000000)			NSGA-II-AG	1,00000 (0,000000)	
	NSGA-II-HS	1,00000 (0,000000)			NSGA-II-HS	1,00000 (0,000000)			NSGA-II-HS	1,00000 (0,000000)	
schedule	NSGA-II	1,00000 (0,000000)	<,0001	schedule 2	NSGA-II	1,00000 (0,000000)	<,0001	sed	NSGA-II	1,00000 (0,000000)	<,0001
	NSGA-II-FB	0,64149 (0,268864)			NSGA-II-FB	0,27135 (0,053696)			NSGA-II-FB	0,97428 (0,033528)	
	NSGA-II-1opt	0,43975 (0,129985)			NSGA-II-1opt	0,32736 (0,118514)			NSGA-II-1opt	1,00000 (0,000000)	
	NSGA-II-AG	1,00000 (0,000000)			NSGA-II-AG	1,00000 (0,000000)			NSGA-II-AG	1,00000 (0,000000)	
	NSGA-II-HS	0,99909 (0,009091)			NSGA-II-HS	1,00000 (0,000000)			NSGA-II-HS	1,00000 (0,000000)	
space	NSGA-II	1,00000 (0,000000)	<,0001	tcas	NSGA-II	0,997087 (0,016534)	<,0001	totinfo	NSGA-II	1,00000 (0,000000)	<,0001
	NSGA-II-FB	0,90724 (0,055296)			NSGA-II-FB	0,303327 (0,130545)			NSGA-II-FB	0,62161 (0,397180)	
	NSGA-II-1opt	1,00000 (0,000000)			NSGA-II-1opt	0,241042 (0,071916)			NSGA-II-1opt	0,23356 (0,109142)	
	NSGA-II-AG	1,00000 (0,000000)			NSGA-II-AG	0,997600 (0,024000)			NSGA-II-AG	1,00000 (0,000000)	
	NSGA-II-HS	1,00000 (0,000000)			NSGA-II-HS	0,416011 (0,093821)			NSGA-II-HS	0,99900 (0,010000)	

Tabela A.28: Resultados do teste Steel-Dwass - Métrica CVR - Subgrupo 3.

Steel-Dwass (valor p)				Steel-Dwass (valor p)				Steel-Dwass (valor p)			
flex	NSGA-II	NSGA-II-FB	<,0001	gzip	NSGA-II	NSGA-II-FB	<,0001	print tokens	NSGA-II	NSGA-II-FB	<,0001
	NSGA-II	NSGA-II-1opt	1,0000		NSGA-II	NSGA-II-1opt	1,0000		NSGA-II	NSGA-II-1opt	<,0001
	NSGA-II	NSGA-II-AG	1,0000		NSGA-II	NSGA-II-AG	1,0000		NSGA-II	NSGA-II-AG	1,0000
	NSGA-II	NSGA-II-HS	1,0000		NSGA-II	NSGA-II-HS	1,0000		NSGA-II	NSGA-II-HS	1,0000
	NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001
	NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001
	NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001
	NSGA-II-1opt	NSGA-II-AG	1,0000		NSGA-II-1opt	NSGA-II-AG	1,0000		NSGA-II-1opt	NSGA-II-AG	<,0001
	NSGA-II-1opt	NSGA-II-HS	1,0000		NSGA-II-1opt	NSGA-II-HS	1,0000		NSGA-II-1opt	NSGA-II-HS	<,0001
	NSGA-II-AG	NSGA-II-HS	1,0000		NSGA-II-AG	NSGA-II-HS	1,0000		NSGA-II-AG	NSGA-II-HS	1,0000
print tokens 2	NSGA-II	NSGA-II-FB	<,0001	replace	NSGA-II	NSGA-II-FB	<,0001	schedule	NSGA-II	NSGA-II-FB	<,0001
	NSGA-II	NSGA-II-1opt	0,8600		NSGA-II	NSGA-II-1opt	1,0000		NSGA-II	NSGA-II-1opt	<,0001
	NSGA-II	NSGA-II-AG	1,0000		NSGA-II	NSGA-II-AG	1,0000		NSGA-II	NSGA-II-AG	1,0000
	NSGA-II	NSGA-II-HS	1,0000		NSGA-II	NSGA-II-HS	1,0000		NSGA-II	NSGA-II-HS	0,8600
	NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001
	NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001
	NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001
	NSGA-II-1opt	NSGA-II-AG	0,8600		NSGA-II-1opt	NSGA-II-AG	1,0000		NSGA-II-1opt	NSGA-II-AG	<,0001
	NSGA-II-1opt	NSGA-II-HS	0,8600		NSGA-II-1opt	NSGA-II-HS	1,0000		NSGA-II-1opt	NSGA-II-HS	<,0001
	NSGA-II-AG	NSGA-II-HS	1,0000		NSGA-II-AG	NSGA-II-HS	1,0000		NSGA-II-AG	NSGA-II-HS	0,8600
schedule 2	NSGA-II	NSGA-II-FB	<,0001	sed	NSGA-II	NSGA-II-FB	<,0001	space	NSGA-II	NSGA-II-FB	<,0001
	NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	1,0000		NSGA-II	NSGA-II-1opt	1,0000
	NSGA-II	NSGA-II-AG	1,0000		NSGA-II	NSGA-II-AG	1,0000		NSGA-II	NSGA-II-AG	1,0000
	NSGA-II	NSGA-II-HS	1,0000		NSGA-II	NSGA-II-HS	1,0000		NSGA-II	NSGA-II-HS	1,0000
	NSGA-II-FB	NSGA-II-1opt	0,0088		NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001
	NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001
	NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001
	NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	1,0000		NSGA-II-1opt	NSGA-II-AG	1,0000
	NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	1,0000		NSGA-II-1opt	NSGA-II-HS	1,0000
	NSGA-II-AG	NSGA-II-HS	1,0000		NSGA-II-AG	NSGA-II-HS	1,0000		NSGA-II-AG	NSGA-II-HS	1,0000
tcas	NSGA-II	NSGA-II-FB	<,0001	totinfo	NSGA-II	NSGA-II-FB	<,0001				
	NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001				
	NSGA-II	NSGA-II-AG	0,4788		NSGA-II	NSGA-II-AG	1,0000				
	NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	0,8600				
	NSGA-II-FB	NSGA-II-1opt	0,0010		NSGA-II-FB	NSGA-II-1opt	<,0001				
	NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001				
	NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001				
	NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001				
	NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001				
	NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	0,8600				

Tabela A.29: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica MS - Subgrupo 3.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	NSGA-II	0,255980 (0,006043)	<,0001	grep	NSGA-II	0,038259 (0,012962)	<,0001	gzip	NSGA-II	0,157557 (0,018499)	<,0001
	NSGA-II-FB	0,789038 (0,338155)			NSGA-II-FB	0,279864 (0,113766)			NSGA-II-FB	0,991799 (0,000355)	
	NSGA-II-1opt	0,278936 (0,014312)			NSGA-II-1opt	0,109844 (0,029133)			NSGA-II-1opt	0,281677 (0,098401)	
	NSGA-II-AG	0,259630 (0,006958)			NSGA-II-AG	0,063558 (0,016071)			NSGA-II-AG	0,148301 (0,009321)	
	NSGA-II-HS	0,259433 (0,006490)			NSGA-II-HS	0,069662 (0,020368)			NSGA-II-HS	0,188344 (0,034950)	
print tokens	NSGA-II	0,025273 (0,015443)	<,0001	print tokens 2	NSGA-II	0,005390 (0,005146)	<,0001	replace	NSGA-II	0,010815 (0,007391)	<,0001
	NSGA-II-FB	0,922269 (0,222719)			NSGA-II-FB	0,878398 (0,271443)			NSGA-II-FB	0,927848 (0,225579)	
	NSGA-II-1opt	0,840779 (0,190655)			NSGA-II-1opt	0,228430 (0,110807)			NSGA-II-1opt	0,190341 (0,104277)	
	NSGA-II-AG	0,024176 (0,014373)			NSGA-II-AG	0,004791 (0,004430)			NSGA-II-AG	0,011111 (0,007788)	
	NSGA-II-HS	0,060316 (0,035830)			NSGA-II-HS	0,010238 (0,009820)			NSGA-II-HS	0,026221 (0,013128)	
schedule	NSGA-II	0,048915 (0,018169)	<,0001	schedule 2	NSGA-II	0,024871 (0,018284)	<,0001	sed	NSGA-II	0,055151 (0,039157)	<,0001
	NSGA-II-FB	0,863519 (0,238015)			NSGA-II-FB	0,987679 (0,002439)			NSGA-II-FB	0,855605 (0,344379)	
	NSGA-II-1opt	0,980727 (0,024512)			NSGA-II-1opt	0,983780 (0,034325)			NSGA-II-1opt	0,192296 (0,070707)	
	NSGA-II-AG	0,046080 (0,019309)			NSGA-II-AG	0,024022 (0,017376)			NSGA-II-AG	0,044569 (0,027594)	
	NSGA-II-HS	0,106950 (0,114176)			NSGA-II-HS	0,067753 (0,046547)			NSGA-II-HS	0,062501 (0,017307)	
space	NSGA-II	0,132879 (0,031139)	<,0001	tcas	NSGA-II	0,456029 (0,216349)	<,0001	totinfo	NSGA-II	0,008628 (0,011054)	<,0001
	NSGA-II-FB	0,992525 (0,037606)			NSGA-II-FB	0,974700 (0,113711)			NSGA-II-FB	0,755281 (0,330576)	
	NSGA-II-1opt	0,433743 (0,050871)			NSGA-II-1opt	0,989182 (0,011450)			NSGA-II-1opt	0,893899 (0,028209)	
	NSGA-II-AG	0,105170 (0,022444)			NSGA-II-AG	0,366316 (0,154235)			NSGA-II-AG	0,007939 (0,009522)	
	NSGA-II-HS	0,347356 (0,064442)			NSGA-II-HS	0,990811 (5,35e-7)			NSGA-II-HS	0,169987 (0,143287)	

Tabela A.30: Resultados do teste Steel-Dwass - Métrica MS - Subgrupo 3.

Steel-Dwass (valor p)				Steel-Dwass (valor p)				Steel-Dwass (valor p)			
flex	NSGA-II	NSGA-II-FB	<,0001	grep	NSGA-II	NSGA-II-FB	<,0001	gzip	NSGA-II	NSGA-II-FB	<,0001
	NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001
	NSGA-II	NSGA-II-AG	0,0009		NSGA-II	NSGA-II-AG	<,0001		NSGA-II	NSGA-II-AG	0,0004
	NSGA-II	NSGA-II-HS	0,0004		NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001
	NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001
	NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001
	NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001
	NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001
	NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001
	NSGA-II-AG	NSGA-II-HS	1,0000		NSGA-II-AG	NSGA-II-HS	0,3512		NSGA-II-AG	NSGA-II-HS	<,0001
print tokens	NSGA-II	NSGA-II-FB	<,0001	print tokens 2	NSGA-II	NSGA-II-FB	<,0001	replace	NSGA-II	NSGA-II-FB	<,0001
	NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001
	NSGA-II	NSGA-II-AG	0,9134		NSGA-II	NSGA-II-AG	0,4266		NSGA-II	NSGA-II-AG	0,8612
	NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	0,0001		NSGA-II	NSGA-II-HS	<,0001
	NSGA-II-FB	NSGA-II-1opt	0,0004		NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001
	NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001
	NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001
	NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001
	NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001
	NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001
schedule	NSGA-II	NSGA-II-FB	<,0001	schedule 2	NSGA-II	NSGA-II-FB	<,0001	sed	NSGA-II	NSGA-II-FB	<,0001
	NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001
	NSGA-II	NSGA-II-AG	0,1682		NSGA-II	NSGA-II-AG	0,8138		NSGA-II	NSGA-II-AG	0,0464
	NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001
	NSGA-II-FB	NSGA-II-1opt	0,9983		NSGA-II-FB	NSGA-II-1opt	0,7015		NSGA-II-FB	NSGA-II-1opt	<,0001
	NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001
	NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001
	NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001
	NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001
	NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001
space	NSGA-II	NSGA-II-FB	<,0001	tcas	NSGA-II	NSGA-II-FB	<,0001	totinfo	NSGA-II	NSGA-II-FB	<,0001
	NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001		NSGA-II	NSGA-II-1opt	<,0001
	NSGA-II	NSGA-II-AG	<,0001		NSGA-II	NSGA-II-AG	0,0182		NSGA-II	NSGA-II-AG	0,9319
	NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001		NSGA-II	NSGA-II-HS	<,0001
	NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001		NSGA-II-FB	NSGA-II-1opt	<,0001
	NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001		NSGA-II-FB	NSGA-II-AG	<,0001
	NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001		NSGA-II-FB	NSGA-II-HS	<,0001
	NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001		NSGA-II-1opt	NSGA-II-AG	<,0001
	NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001		NSGA-II-1opt	NSGA-II-HS	<,0001
	NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001		NSGA-II-AG	NSGA-II-HS	<,0001

Tabela A.31: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica HV - Subgrupo 4.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	SPEA2	0,962566 (0,003697)	<,0001	grep	SPEA2	0,894207 (0,004904)	<,0001	gzip	SPEA2	0,993178 (0,000403)	<,0001
	SPEA2-FB	0,907188 (0,063678)			SPEA2-FB	0,783133 (0,060009)			SPEA2-FB	0,993715 (0,000125)	
	SPEA2-1opt	0,789432 (0,009815)			SPEA2-1opt	0,691728 (0,009227)			SPEA2-1opt	0,987581 (0,002473)	
	SPEA2-AG	0,706496 (0,013544)			SPEA2-AG	0,595073 (0,012004)			SPEA2-AG	0,933720 (0,015728)	
	SPEA2-HS	0,905093 (0,005222)			SPEA2-HS	0,827222 (0,006358)			SPEA2-HS	0,987880 (0,001564)	
print tokens	SPEA2	0,995996 (0,000042)	<,0001	print tokens 2	SPEA2	0,997167 (0,000017)	<,0001	replace	SPEA2	0,994964 (0,000510)	<,0001
	SPEA2-FB	0,996005 (0,000034)			SPEA2-FB	0,997164 (0,000042)			SPEA2-FB	0,995030 (0,001162)	
	SPEA2-1opt	0,982513 (0,006081)			SPEA2-1opt	0,950832 (0,007240)			SPEA2-1opt	0,931837 (0,006572)	
	SPEA2-AG	0,939282 (0,012473)			SPEA2-AG	0,930596 (0,010293)			SPEA2-AG	0,890168 (0,014363)	
	SPEA2-HS	0,986602 (0,003389)			SPEA2-HS	0,972536 (0,004268)			SPEA2-HS	0,960482 (0,005359)	
schedule	SPEA2	0,995033 (0,000027)	<,0001	schedule 2	SPEA2	0,995929 (0,000012)	<,0001	sed	SPEA2	0,970973 (0,004415)	<,0001
	SPEA2-FB	0,995024 (0,000064)			SPEA2-FB	0,995925 (9,476e-6)			SPEA2-FB	0,956601 (0,067041)	
	SPEA2-1opt	0,994981 (0,000075)			SPEA2-1opt	0,995864 (0,000035)			SPEA2-1opt	0,846091 (0,014935)	
	SPEA2-AG	0,986887 (0,005894)			SPEA2-AG	0,989425 (0,004124)			SPEA2-AG	0,712264 (0,023527)	
	SPEA2-HS	0,994884 (0,000151)			SPEA2-HS	0,995667 (0,000185)			SPEA2-HS	0,923028 (0,006228)	
space	SPEA2	0,974034 (0,002067)	<,0001	tcas	SPEA2	0,967425 (9,473e-8)	<,0001	totinfo	SPEA2	0,996137 (5,847e-6)	<,0001
	SPEA2-FB	0,976385 (0,000625)			SPEA2-FB	0,967425 (5,422e-8)			SPEA2-FB	0,996139 (3,273e-6)	
	SPEA2-1opt	0,935977 (0,006822)			SPEA2-1opt	0,967425 (1,048e-7)			SPEA2-1opt	0,996122 (0,000015)	
	SPEA2-AG	0,799191 (0,014068)			SPEA2-AG	0,967371 (0,000119)			SPEA2-AG	0,995515 (0,000572)	
	SPEA2-HS	0,955644 (0,006180)			SPEA2-HS	0,967421 (0,000027)			SPEA2-HS	0,996063 (0,000064)	

Tabela A.32: Resultados do teste Steel-Dwass - Métrica HV - Subgrupo 4.

Steel-Dwass (valor p)				Steel-Dwass (valor p)				Steel-Dwass (valor p)			
flex	SPEA2	SPEA2-FB	<,0001	grep	SPEA2	SPEA2-FB	<,0001	gzip	SPEA2	SPEA2-FB	<,0001
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	0,0582		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	0,9997
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001
print tokens	SPEA2	SPEA2-FB	0,7635	print tokens 2	SPEA2	SPEA2-FB	0,9959	replace	SPEA2	SPEA2-FB	<,0001
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001
schedule	SPEA2	SPEA2-FB	0,0005	schedule 2	SPEA2	SPEA2-FB	<,0001	sed	SPEA2	SPEA2-FB	<,0001
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001
space	SPEA2	SPEA2-FB	<,0001	tcas	SPEA2	SPEA2-FB	<,0001	totinfo	SPEA2	SPEA2-FB	0,0006
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	0,9546		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001

Tabela A.33: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica GD - Subgrupo 4.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	SPEA2	0,001406 (0,000405)	<,0001	grep	SPEA2	0,001104 (0,000380)	<,0001	gzip	SPEA2	0,000148 (0,000085)	<,0001
	SPEA2-FB	0,018338 (0,011223)			SPEA2-FB	0,032394 (0,008001)			SPEA2-FB	0,000112 (0,000077)	
	SPEA2-1opt	0,026656 (0,004502)			SPEA2-1opt	0,038518 (0,005031)			SPEA2-1opt	0,000480 (0,000274)	
	SPEA2-AG	0,034438 (0,010543)			SPEA2-AG	0,055536 (0,009762)			SPEA2-AG	0,010871 (0,003482)	
	SPEA2-HS	0,012628 (0,001590)			SPEA2-HS	0,009208 (0,001369)			SPEA2-HS	0,000274 (0,000074)	
print tokens	SPEA2	0,000661 (0,000265)	<,0001	print tokens 2	SPEA2	0,001108 (0,000668)	<,0001	replace	SPEA2	0,001603 (0,000560)	<,0001
	SPEA2-FB	0,000970 (0,000271)			SPEA2-FB	0,001137 (0,000605)			SPEA2-FB	0,000795 (0,000447)	
	SPEA2-1opt	0,004729 (0,001674)			SPEA2-1opt	0,020693 (0,006500)			SPEA2-1opt	0,021542 (0,005035)	
	SPEA2-AG	0,025414 (0,007510)			SPEA2-AG	0,039757 (0,009451)			SPEA2-AG	0,047025 (0,010470)	
	SPEA2-HS	0,004127 (0,001085)			SPEA2-HS	0,010562 (0,002165)			SPEA2-HS	0,009876 (0,002026)	
schedule	SPEA2	0,000050 (0,000108)	<,0001	schedule 2	SPEA2	0,000055 (0,000126)	<,0001	sed	SPEA2	0,000869 (0,000166)	<,0001
	SPEA2-FB	0,000452 (0,000551)			SPEA2-FB	0,000227 (0,000293)			SPEA2-FB	0,007325 (0,009492)	
	SPEA2-1opt	0,001254 (0,000688)			SPEA2-1opt	0,000886 (0,000523)			SPEA2-1opt	0,019658 (0,003703)	
	SPEA2-AG	0,003478 (0,001958)			SPEA2-AG	0,003353 (0,001302)			SPEA2-AG	0,062799 (0,009007)	
	SPEA2-HS	0,001677 (0,000751)			SPEA2-HS	0,001398 (0,000472)			SPEA2-HS	0,005061 (0,000952)	
space	SPEA2	0,000288 (0,000076)	<,0001	tcas	SPEA2	9,817e-8 (4,282e-8)	<,0001	totinfo	SPEA2	0,000046 (0,000135)	<,0001
	SPEA2-FB	0,000211 (0,000079)			SPEA2-FB	7,522e-6 (0,000052)			SPEA2-FB	0,000143 (0,000301)	
	SPEA2-1opt	0,002595 (0,000524)			SPEA2-1opt	7,54e-6 (0,000052)			SPEA2-1opt	0,000633 (0,000516)	
	SPEA2-AG	0,009447 (0,002811)			SPEA2-AG	0,000540 (0,000288)			SPEA2-AG	0,002020 (0,001164)	
	SPEA2-HS	0,000938 (0,000211)			SPEA2-HS	0,000064 (0,000143)			SPEA2-HS	0,001122 (0,000641)	

Tabela A.34: Resultados do teste Steel-Dwass - Métrica GD - Subgrupo 4.

Steel-Dwass (valor p)				Steel-Dwass (valor p)				Steel-Dwass (valor p)			
flex	SPEA2	SPEA2-FB	<,0001	grep	SPEA2	SPEA2-FB	<,0001	gzip	SPEA2	SPEA2-FB	0,0002
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	0,0442		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001
print tokens	SPEA2	SPEA2-FB	<,0001	print tokens 2	SPEA2	SPEA2-FB	0,7509	replace	SPEA2	SPEA2-FB	<,0001
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	0,1288		SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001
schedule	SPEA2	SPEA2-FB	0,6836	schedule 2	SPEA2	SPEA2-FB	<,0001	sed	SPEA2	SPEA2-FB	0,9984
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	0,6737
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	0,0003		SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001
space	SPEA2	SPEA2-FB	<,0001	tcas	SPEA2	SPEA2-FB	<,0001	totinfo	SPEA2	SPEA2-FB	0,0008
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	0,7100		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	0,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001

Tabela A.35: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica IGD - Subgrupo 4.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	SPEA2	0,016753 (0,001140)	<,0001	grep	SPEA2	0,009748 (0,000914)	<,0001	gzip	SPEA2	0,003464 (0,001724)	<,0001
	SPEA2-FB	0,010379 (0,006921)			SPEA2-FB	0,016607 (0,006548)			SPEA2-FB	0,000427 (0,000219)	
	SPEA2-1opt	0,021446 (0,000627)			SPEA2-1opt	0,026876 (0,001107)			SPEA2-1opt	0,009010 (0,002323)	
	SPEA2-AG	0,024221 (0,000648)			SPEA2-AG	0,038061 (0,001359)			SPEA2-AG	0,015387 (0,001007)	
	SPEA2-HS	0,018395 (0,000756)			SPEA2-HS	0,013741 (0,000783)			SPEA2-HS	0,009532 (0,002120)	
print tokens	SPEA2	0,001443 (0,001199)	<,0001	print tokens 2	SPEA2	0,001186 (0,001290)	<,0001	replace	SPEA2	0,007094 (0,005082)	<,0001
	SPEA2-FB	0,002430 (0,001145)			SPEA2-FB	0,002952 (0,002077)			SPEA2-FB	0,005114 (0,003170)	
	SPEA2-1opt	0,027438 (0,008891)			SPEA2-1opt	0,058016 (0,004259)			SPEA2-1opt	0,046745 (0,001893)	
	SPEA2-AG	0,063535 (0,004066)			SPEA2-AG	0,064099 (0,001436)			SPEA2-AG	0,049879 (0,001311)	
	SPEA2-HS	0,041995 (0,012372)			SPEA2-HS	0,057500 (0,004417)			SPEA2-HS	0,043911 (0,002741)	
schedule	SPEA2	0,000153 (0,000481)	<,0001	schedule 2	SPEA2	0,000167 (0,000336)	<,0001	sed	SPEA2	0,009961 (0,002076)	<,0001
	SPEA2-FB	0,001144 (0,000977)			SPEA2-FB	0,000842 (0,000783)			SPEA2-FB	0,003561 (0,005341)	
	SPEA2-1opt	0,004114 (0,002115)			SPEA2-1opt	0,005215 (0,003739)			SPEA2-1opt	0,014270 (0,002023)	
	SPEA2-AG	0,053203 (0,017476)			SPEA2-AG	0,047501 (0,013460)			SPEA2-AG	0,022051 (0,001322)	
	SPEA2-HS	0,006303 (0,003941)			SPEA2-HS	0,008214 (0,006064)			SPEA2-HS	0,013673 (0,001234)	
space	SPEA2	0,002715 (0,001567)	<,0001	tcas	SPEA2	0,000042 (0,000120)	<,0001	totinfo	SPEA2	0,000068 (0,000201)	<,0001
	SPEA2-FB	0,000446 (0,000167)			SPEA2-FB	0,000061 (0,000140)			SPEA2-FB	0,000319 (0,000706)	
	SPEA2-1opt	0,007878 (0,001279)			SPEA2-1opt	0,000156 (0,000204)			SPEA2-1opt	0,001862 (0,001181)	
	SPEA2-AG	0,017710 (0,001090)			SPEA2-AG	0,002446 (0,002492)			SPEA2-AG	0,010871 (0,006396)	
	SPEA2-HS	0,007807 (0,001876)			SPEA2-HS	0,000293 (0,000229)			SPEA2-HS	0,003115 (0,001697)	

Tabela A.36: Resultados do teste Steel-Dwass - Métrica IGD - Subgrupo 4.

Steel-Dwass (valor p)				Steel-Dwass (valor p)				Steel-Dwass (valor p)			
flex	SPEA2	SPEA2-FB	<,0001	grep	SPEA2	SPEA2-FB	<,0001	gzip	SPEA2	SPEA2-FB	<,0001
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	0,1732		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	0,1510
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001
print tokens	SPEA2	SPEA2-FB	<,0001	print tokens 2	SPEA2	SPEA2-FB	<,0001	replace	SPEA2	SPEA2-FB	0,0041
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	0,9995		SPEA2-1opt	SPEA2-HS	<,0001
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001
schedule	SPEA2	SPEA2-FB	<,0001	schedule 2	SPEA2	SPEA2-FB	<,0001	sed	SPEA2	SPEA2-FB	<,0001
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	0,9101
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001
space	SPEA2	SPEA2-FB	<,0001	tcas	SPEA2	SPEA2-FB	0,0057	totinfo	SPEA2	SPEA2-FB	0,1366
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	0,0723		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	0,9987		SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001

Tabela A.37: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica CVR - Subgrupo 4.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	SPEA2	0,99168 (0,039794)	<,0001	grep	SPEA2	0,98648 (0,063486)	<,0001	gzip	SPEA2	0,97816 (0,044657)	<,0001
	SPEA2-FB	0,97499 (0,063727)			SPEA2-FB	1,00000 (0,000000)			SPEA2-FB	0,80427 (0,101666)	
	SPEA2-1opt	1,00000 (0,000000)			SPEA2-1opt	1,00000 (0,000000)			SPEA2-1opt	1,00000 (0,000000)	
	SPEA2-AG	1,00000 (0,000000)			SPEA2-AG	1,00000 (0,000000)			SPEA2-AG	1,00000 (0,000000)	
	SPEA2-HS	1,00000 (0,000000)			SPEA2-HS	1,00000 (0,000000)			SPEA2-HS	1,00000 (0,000000)	
print tokens	SPEA2	0,32918 (0,084032)	<,0001	print tokens 2	SPEA2	0,41018 (0,103877)	<,0001	replace	SPEA2	0,96260 (0,043161)	<,0001
	SPEA2-FB	0,44039 (0,118155)			SPEA2-FB	0,44178 (0,121831)			SPEA2-FB	0,81857 (0,108704)	
	SPEA2-1opt	1,00000 (0,000000)			SPEA2-1opt	1,00000 (0,000000)			SPEA2-1opt	1,00000 (0,000000)	
	SPEA2-AG	1,00000 (0,000000)			SPEA2-AG	1,00000 (0,000000)			SPEA2-AG	1,00000 (0,000000)	
	SPEA2-HS	1,00000 (0,000000)			SPEA2-HS	1,00000 (0,000000)			SPEA2-HS	1,00000 (0,000000)	
schedule	SPEA2	0,162416 (0,048206)	<,0001	schedule 2	SPEA2	0,093634 (0,044865)	<,0001	sed	SPEA2	0,99887 (0,011321)	<,0001
	SPEA2-FB	0,166933 (0,099127)			SPEA2-FB	0,119536 (0,046236)			SPEA2-FB	0,97434 (0,035872)	
	SPEA2-1opt	0,398088 (0,122486)			SPEA2-1opt	0,321802 (0,117140)			SPEA2-1opt	1,00000 (0,000000)	
	SPEA2-AG	0,992008 (0,038853)			SPEA2-AG	0,989452 (0,032010)			SPEA2-AG	1,00000 (0,000000)	
	SPEA2-HS	0,631718 (0,149727)			SPEA2-HS	0,660117 (0,155342)			SPEA2-HS	1,00000 (0,000000)	
space	SPEA2	0,98313 (0,019772)	<,0001	tcas	SPEA2	0,195221 (0,074951)	<,0001	totinfo	SPEA2	0,088478 (0,032907)	<,0001
	SPEA2-FB	0,91040 (0,057335)			SPEA2-FB	0,161394 (0,056398)			SPEA2-FB	0,050378 (0,057343)	
	SPEA2-1opt	1,00000 (0,000000)			SPEA2-1opt	0,186989 (0,075204)			SPEA2-1opt	0,223998 (0,092889)	
	SPEA2-AG	1,00000 (0,000000)			SPEA2-AG	0,711431 (0,138561)			SPEA2-AG	0,714219 (0,215907)	
	SPEA2-HS	0,99991 (0,000917)			SPEA2-HS	0,300178 (0,093159)			SPEA2-HS	0,479282 (0,139435)	

Tabela A.38: Resultados do teste Steel-Dwass - Métrica CVR - Subgrupo 4.

Steel-Dwass (valor p)				Steel-Dwass (valor p)				Steel-Dwass (valor p)			
flex	SPEA2	SPEA2-FB	<,0001	grep	SPEA2	SPEA2-FB	0,0011	gzip	SPEA2	SPEA2-FB	<,0001
	SPEA2	SPEA2-1opt	0,0108		SPEA2	SPEA2-1opt	0,0011		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	0,0108		SPEA2	SPEA2-AG	0,0011		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	0,0108		SPEA2	SPEA2-HS	0,0011		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	1,0000		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	1,0000		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	1,0000		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	1,0000		SPEA2-1opt	SPEA2-AG	1,0000		SPEA2-1opt	SPEA2-AG	1,0000
	SPEA2-1opt	SPEA2-HS	1,0000		SPEA2-1opt	SPEA2-HS	1,0000		SPEA2-1opt	SPEA2-HS	1,0000
	SPEA2-AG	SPEA2-HS	1,0000		SPEA2-AG	SPEA2-HS	1,0000		SPEA2-AG	SPEA2-HS	1,0000
print tokens	SPEA2	SPEA2-FB	<,0001	print tokens 2	SPEA2	SPEA2-FB	0,2552	replace	SPEA2	SPEA2-FB	<,0001
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	1,0000		SPEA2-1opt	SPEA2-AG	1,0000		SPEA2-1opt	SPEA2-AG	1,0000
	SPEA2-1opt	SPEA2-HS	1,0000		SPEA2-1opt	SPEA2-HS	1,0000		SPEA2-1opt	SPEA2-HS	1,0000
	SPEA2-AG	SPEA2-HS	1,0000		SPEA2-AG	SPEA2-HS	1,0000		SPEA2-AG	SPEA2-HS	1,0000
schedule	SPEA2	SPEA2-FB	0,9977	schedule 2	SPEA2	SPEA2-FB	<,0001	sed	SPEA2	SPEA2-FB	<,0001
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	0,8600
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	0,8600
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	0,8600
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	1,0000
	SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	1,0000
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	1,0000
space	SPEA2	SPEA2-FB	<,0001	tcas	SPEA2	SPEA2-FB	0,0570	totinfo	SPEA2	SPEA2-FB	<,0001
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	0,9995		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	0,0032		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	1,0000		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	0,8600		SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001
	SPEA2-AG	SPEA2-HS	0,8600		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001

Tabela A.39: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica MS - Subgrupo 4.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	SPEA2	0,277026 (0,011529)	<,0001	grep	SPEA2	0,093106 (0,012117)	<,0001	gzip	SPEA2	0,629716 (0,136372)	<,0001
	SPEA2-FB	0,752213 (0,351948)			SPEA2-FB	0,303561 (0,098213)			SPEA2-FB	0,991603 (0,001797)	
	SPEA2-1opt	0,274610 (0,013978)			SPEA2-1opt	0,140786 (0,032115)			SPEA2-1opt	0,325561 (0,083061)	
	SPEA2-AG	0,260004 (0,007765)			SPEA2-AG	0,072317 (0,020798)			SPEA2-AG	0,164155 (0,018608)	
	SPEA2-HS	0,267100 (0,007527)			SPEA2-HS	0,085239 (0,014811)			SPEA2-HS	0,305886 (0,080908)	
print tokens	SPEA2	0,990148 (0,001958)	<,0001	print tokens 2	SPEA2	0,983784 (0,028975)	<,0001	replace	SPEA2	0,759307 (0,150763)	<,0001
	SPEA2-FB	0,990344 (0,000016)			SPEA2-FB	0,987242 (1,699e-6)			SPEA2-FB	0,989363 (0,029327)	
	SPEA2-1opt	0,410182 (0,115749)			SPEA2-1opt	0,061527 (0,036182)			SPEA2-1opt	0,050004 (0,022068)	
	SPEA2-AG	0,060404 (0,032313)			SPEA2-AG	0,013843 (0,011802)			SPEA2-AG	0,027739 (0,014519)	
	SPEA2-HS	0,253537 (0,130004)			SPEA2-HS	0,063619 (0,038197)			SPEA2-HS	0,078762 (0,034415)	
schedule	SPEA2	0,984084 (0,000018)	<,0001	schedule 2	SPEA2	0,987925 (7,931e-6)	<,0001	sed	SPEA2	0,228570 (0,097826)	<,0001
	SPEA2-FB	0,984085 (0,000026)			SPEA2-FB	0,987922 (5,364e-7)			SPEA2-FB	0,904552 (0,303836)	
	SPEA2-1opt	0,984094 (0,000032)			SPEA2-1opt	0,987193 (0,004179)			SPEA2-1opt	0,159145 (0,078459)	
	SPEA2-AG	0,283122 (0,228451)			SPEA2-AG	0,298747 (0,234523)			SPEA2-AG	0,057199 (0,042212)	
	SPEA2-HS	0,975561 (0,048543)			SPEA2-HS	0,970637 (0,086165)			SPEA2-HS	0,100155 (0,041353)	
space	SPEA2	0,667901 (0,133581)	<,0001	tcas	SPEA2	0,990808 (1,347e-7)	<,0001	totinfo	SPEA2	0,898832 (4,07e-6)	<,0001
	SPEA2-FB	0,981424 (0,044781)			SPEA2-FB	0,990807 (4,573e-8)			SPEA2-FB	0,898830 (2,281e-6)	
	SPEA2-1opt	0,387302 (0,047561)			SPEA2-1opt	0,990807 (1,062e-7)			SPEA2-1opt	0,898833 (5,021e-6)	
	SPEA2-AG	0,119647 (0,029305)			SPEA2-AG	0,973118 (0,066828)			SPEA2-AG	0,813527 (0,140397)	
	SPEA2-HS	0,391861 (0,072412)			SPEA2-HS	0,990810 (2,198e-7)			SPEA2-HS	0,898841 (6,864e-6)	

Tabela A.40: Resultados do teste Steel-Dwass - Métrica MS - Subgrupo 4.

Steel-Dwass (valor p)				Steel-Dwass (valor p)				Steel-Dwass (valor p)			
flex	SPEA2	SPEA2-FB	<,0001	grep	SPEA2	SPEA2-FB	<,0001	gzip	SPEA2	SPEA2-FB	<,0001
	SPEA2	SPEA2-1opt	0,4526		SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	0,0015		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	0,1635
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001
print tokens	SPEA2	SPEA2-FB	0,8769	print tokens 2	SPEA2	SPEA2-FB	0,0101	replace	SPEA2	SPEA2-FB	<,0001
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	1,0000		SPEA2-1opt	SPEA2-HS	<,0001
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001
schedule	SPEA2	SPEA2-FB	<,0001	schedule 2	SPEA2	SPEA2-FB	0,5143	sed	SPEA2	SPEA2-FB	<,0001
	SPEA2	SPEA2-1opt	1,0000		SPEA2	SPEA2-1opt	0,1098		SPEA2	SPEA2-1opt	0,0002
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	0,6415		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	0,0010
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001
space	SPEA2	SPEA2-FB	<,0001	tcas	SPEA2	SPEA2-FB	<,0001	totinfo	SPEA2	SPEA2-FB	<,0001
	SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	<,0001		SPEA2	SPEA2-1opt	0,9959
	SPEA2	SPEA2-AG	<,0001		SPEA2	SPEA2-AG	1,0000		SPEA2	SPEA2-AG	<,0001
	SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001		SPEA2	SPEA2-HS	<,0001
	SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001		SPEA2-FB	SPEA2-1opt	<,0001
	SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001		SPEA2-FB	SPEA2-AG	<,0001
	SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001		SPEA2-FB	SPEA2-HS	<,0001
	SPEA2-1opt	SPEA2-AG	<,0001		SPEA2-1opt	SPEA2-AG	0,0014		SPEA2-1opt	SPEA2-AG	<,0001
	SPEA2-1opt	SPEA2-HS	1,0000		SPEA2-1opt	SPEA2-HS	<,0001		SPEA2-1opt	SPEA2-HS	<,0001
	SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001		SPEA2-AG	SPEA2-HS	<,0001

Tabela A.41: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica HV - Subgrupo 5.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	TAEA	0,710133 (0,014161)	<,0001	grep	TAEA	0,618583 (0,016166)	<,0001	gzip	TAEA	0,768389 (0,021932)	<,0001
	TAEA-FB	0,894228 (0,066643)			TAEA-FB	0,782386 (0,055926)			TAEA-FB	0,993389 (0,000883)	
	TAEA-1opt	0,726931 (0,017900)			TAEA-1opt	0,639119 (0,016526)			TAEA-1opt	0,807487 (0,033731)	
	TAEA-AG	0,666933 (0,011992)			TAEA-AG	0,573487 (0,012421)			TAEA-AG	0,715118 (0,024911)	
	TAEA-HS	0,828928 (0,007598)			TAEA-HS	0,752254 (0,010931)			TAEA-HS	0,946229 (0,007008)	
print tokens	TAEA	0,600816 (0,026421)	<,0001	print tokens 2	TAEA	0,573404 (0,016393)	<,0001	replace	TAEA	0,594455 (0,025480)	<,0001
	TAEA-FB	0,949157 (0,081637)			TAEA-FB	0,987065 (0,022203)			TAEA-FB	0,976830 (0,040959)	
	TAEA-1opt	0,736135 (0,034074)			TAEA-1opt	0,782223 (0,020027)			TAEA-1opt	0,779177 (0,022038)	
	TAEA-AG	0,594240 (0,023259)			TAEA-AG	0,575096 (0,014148)			TAEA-AG	0,588540 (0,021815)	
	TAEA-HS	0,892175 (0,011629)			TAEA-HS	0,857876 (0,011149)			TAEA-HS	0,860610 (0,008958)	
schedule	TAEA	0,630590 (0,032352)	<,0001	schedule 2	TAEA	0,626088 (0,029210)	<,0001	sed	TAEA	0,642354 (0,023877)	<,0001
	TAEA-FB	0,986017 (0,015716)			TAEA-FB	0,995714 (0,000091)			TAEA-FB	0,912109 (0,104670)	
	TAEA-1opt	0,968097 (0,026984)			TAEA-1opt	0,970900 (0,018078)			TAEA-1opt	0,688561 (0,026861)	
	TAEA-AG	0,621230 (0,030329)			TAEA-AG	0,616416 (0,028903)			TAEA-AG	0,589921 (0,015563)	
	TAEA-HS	0,942537 (0,010064)			TAEA-HS	0,937381 (0,010896)			TAEA-HS	0,833904 (0,009333)	
space	TAEA	0,743083 (0,028608)	<,0001	tcas	TAEA	0,692702 (0,049205)	<,0001	totinfo	TAEA	0,614187 (0,025702)	<,0001
	TAEA-FB	0,975729 (0,001968)			TAEA-FB	0,872435 (0,114429)			TAEA-FB	0,949794 (0,088365)	
	TAEA-1opt	0,833779 (0,020307)			TAEA-1opt	0,927897 (0,059305)			TAEA-1opt	0,972151 (0,015751)	
	TAEA-AG	0,680559 (0,027349)			TAEA-AG	0,691065 (0,046267)			TAEA-AG	0,610634 (0,020146)	
	TAEA-HS	0,883208 (0,008243)			TAEA-HS	0,965021 (0,003093)			TAEA-HS	0,960026 (0,009286)	

Tabela A.42: Resultados do teste Steel-Dwass - Métrica HV - Subgrupo 5.

Steel-Dwass (valor p)				Steel-Dwass (valor p)				Steel-Dwass (valor p)			
flex	TAEA	TAEA-FB	<,0001	grep	TAEA	TAEA-FB	<,0001	gzip	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001
	TAEA	TAEA-AG	<,0001		TAEA	TAEA-AG	<,0001		TAEA	TAEA-AG	<,0001
	TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001
	TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001
print tokens	TAEA	TAEA-FB	<,0001	print tokens 2	TAEA	TAEA-FB	<,0001	replace	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001
	TAEA	TAEA-AG	0,5026		TAEA	TAEA-AG	0,6660		TAEA	TAEA-AG	0,5487
	TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001
	TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001
schedule	TAEA	TAEA-FB	<,0001	schedule 2	TAEA	TAEA-FB	<,0001	sed	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001
	TAEA	TAEA-AG	0,1936		TAEA	TAEA-AG	0,0790		TAEA	TAEA-AG	<,0001
	TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001
	TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001
space	TAEA	TAEA-FB	<,0001	tcas	TAEA	TAEA-FB	<,0001	totinfo	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001
	TAEA	TAEA-AG	<,0001		TAEA	TAEA-AG	0,9996		TAEA	TAEA-AG	0,9783
	TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	0,7565		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	0,9985		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001
	TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001

Tabela A.43: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica GD - Subgrupo 5.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	TAEA	0,051424 (0,015586)	<,0001	grep	TAEA	0,077136 (0,024777)	<,0001	gzip	TAEA	0,050068 (0,017056)	<,0001
	TAEA-FB	0,020065 (0,013057)			TAEA-FB	0,030371 (0,003515)			TAEA-FB	0,000209 (0,000327)	
	TAEA-1opt	0,037247 (0,007442)			TAEA-1opt	0,053030 (0,008527)			TAEA-1opt	0,036224 (0,013795)	
	TAEA-AG	0,021088 (0,008017)			TAEA-AG	0,050160 (0,004530)			TAEA-AG	0,057671 (0,026365)	
	TAEA-HS	0,036323 (0,005092)			TAEA-HS	0,029710 (0,005027)			TAEA-HS	0,008663 (0,002014)	
print tokens	TAEA	0,359137 (0,063592)	<,0001	print tokens 2	TAEA	0,412235 (0,026254)	<,0001	replace	TAEA	0,359570 (0,058201)	<,0001
	TAEA-FB	0,019132 (0,032563)			TAEA-FB	0,003470 (0,005268)			TAEA-FB	0,005055 (0,009965)	
	TAEA-1opt	0,146913 (0,037330)			TAEA-1opt	0,172469 (0,037131)			TAEA-1opt	0,156427 (0,037646)	
	TAEA-AG	0,365433 (0,061085)			TAEA-AG	0,409323 (0,027353)			TAEA-AG	0,351637 (0,066440)	
	TAEA-HS	0,070402 (0,020443)			TAEA-HS	0,125163 (0,019005)			TAEA-HS	0,090435 (0,022518)	
schedule	TAEA	0,310578 (0,073677)	<,0001	schedule 2	TAEA	0,330255 (0,064174)	<,0001	sed	TAEA	0,114290 (0,044418)	<,0001
	TAEA-FB	0,003160 (0,003861)			TAEA-FB	0,000639 (0,000569)			TAEA-FB	0,010012 (0,011529)	
	TAEA-1opt	0,011815 (0,014158)			TAEA-1opt	0,010728 (0,011264)			TAEA-1opt	0,067415 (0,014546)	
	TAEA-AG	0,320511 (0,079971)			TAEA-AG	0,337097 (0,067855)			TAEA-AG	0,089783 (0,013701)	
	TAEA-HS	0,029341 (0,009550)			TAEA-HS	0,038406 (0,012914)			TAEA-HS	0,029879 (0,004948)	
space	TAEA	0,022196 (0,008158)	<,0001	tcas	TAEA	0,163625 (0,061068)	<,0001	totinfo	TAEA	0,364941 (0,041314)	<,0001
	TAEA-FB	0,000316 (0,000313)			TAEA-FB	0,044023 (0,060650)			TAEA-FB	0,042815 (0,083098)	
	TAEA-1opt	0,011643 (0,002637)			TAEA-1opt	0,010925 (0,021376)			TAEA-1opt	0,011509 (0,008385)	
	TAEA-AG	0,029921 (0,005905)			TAEA-AG	0,160373 (0,058926)			TAEA-AG	0,369205 (0,035694)	
	TAEA-HS	0,006477 (0,001675)			TAEA-HS	0,001097 (0,000400)			TAEA-HS	0,022492 (0,009356)	

Tabela A.44: Resultados do teste Steel-Dwass - Métrica GD - Subgrupo 5.

Steel-Dwass (valor p)				Steel-Dwass (valor p)				Steel-Dwass (valor p)			
flex	TAEA	TAEA-FB	<,0001	grep	TAEA	TAEA-FB	<,0001	gzip	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001
	TAEA	TAEA-AG	<,0001		TAEA	TAEA-AG	<,0001		TAEA	TAEA-AG	0,6489
	TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	0,0790		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	0,5583		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	0,1260		TAEA-1opt	TAEA-AG	<,0001
	TAEA-1opt	TAEA-HS	0,9587		TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001
print tokens	TAEA	TAEA-FB	<,0001	print tokens 2	TAEA	TAEA-FB	<,0001	replace	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001
	TAEA	TAEA-AG	0,8765		TAEA	TAEA-AG	0,6379		TAEA	TAEA-AG	1,0000
	TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001
	TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001
schedule	TAEA	TAEA-FB	<,0001	schedule 2	TAEA	TAEA-FB	<,0001	sed	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001
	TAEA	TAEA-AG	0,7366		TAEA	TAEA-AG	0,5951		TAEA	TAEA-AG	<,0001
	TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001
	TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001
space	TAEA	TAEA-FB	<,0001	tcas	TAEA	TAEA-FB	<,0001	totinfo	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001
	TAEA	TAEA-AG	<,0001		TAEA	TAEA-AG	0,9927		TAEA	TAEA-AG	0,9806
	TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	0,7867		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	1,0000		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001
	TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001

Tabela A.45: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica IGD - Subgrupo 5.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	TAEA	0,024179 (0,000638)	<,0001	grep	TAEA	0,034679 (0,001905)	<,0001	gzip	TAEA	0,020894 (0,001212)	<,0001
	TAEA-FB	0,011336 (0,006553)			TAEA-FB	0,016532 (0,005837)			TAEA-FB	0,000458 (0,000233)	
	TAEA-1opt	0,023631 (0,000722)			TAEA-1opt	0,032746 (0,002006)			TAEA-1opt	0,019641 (0,001523)	
	TAEA-AG	0,025525 (0,000646)			TAEA-AG	0,040595 (0,001486)			TAEA-AG	0,022578 (0,001453)	
	TAEA-HS	0,020837 (0,000434)			TAEA-HS	0,021151 (0,001256)			TAEA-HS	0,016059 (0,000866)	
print tokens	TAEA	0,096004 (0,003457)	<,0001	print tokens 2	TAEA	0,092597 (0,001834)	<,0001	replace	TAEA	0,072854 (0,002530)	<,0001
	TAEA-FB	0,022625 (0,026325)			TAEA-FB	0,017019 (0,013790)			TAEA-FB	0,010949 (0,014043)	
	TAEA-1opt	0,079422 (0,003653)			TAEA-1opt	0,071917 (0,001835)			TAEA-1opt	0,057364 (0,001635)	
	TAEA-AG	0,096804 (0,002959)			TAEA-AG	0,092399 (0,001598)			TAEA-AG	0,073348 (0,002204)	
	TAEA-HS	0,070531 (0,002225)			TAEA-HS	0,068286 (0,000718)			TAEA-HS	0,052812 (0,000827)	
schedule	TAEA	0,109682 (0,005076)	<,0001	schedule 2	TAEA	0,105094 (0,004331)	<,0001	sed	TAEA	0,025941 (0,001466)	<,0001
	TAEA-FB	0,018926 (0,011026)			TAEA-FB	0,010572 (0,004721)			TAEA-FB	0,006809 (0,007449)	
	TAEA-1opt	0,047028 (0,021153)			TAEA-1opt	0,057916 (0,010673)			TAEA-1opt	0,023086 (0,001721)	
	TAEA-AG	0,110749 (0,005271)			TAEA-AG	0,106331 (0,004373)			TAEA-AG	0,028599 (0,000864)	
	TAEA-HS	0,081418 (0,003117)			TAEA-HS	0,075585 (0,002282)			TAEA-HS	0,017499 (0,000646)	
space	TAEA	0,020047 (0,001331)	<,0001	tcas	TAEA	0,081301 (0,005546)	<,0001	totinfo	TAEA	0,107665 (0,003884)	<,0001
	TAEA-FB	0,000515 (0,000272)			TAEA-FB	0,030538 (0,035338)			TAEA-FB	0,022262 (0,032691)	
	TAEA-1opt	0,014375 (0,001638)			TAEA-1opt	0,023528 (0,025174)			TAEA-1opt	0,044066 (0,017796)	
	TAEA-AG	0,021883 (0,001540)			TAEA-AG	0,081174 (0,005054)			TAEA-AG	0,108178 (0,003101)	
	TAEA-HS	0,014051 (0,001327)			TAEA-HS	0,011064 (0,007222)			TAEA-HS	0,071539 (0,005272)	

Tabela A.46: Resultados do teste Steel-Dwass - Métrica IGD - Subgrupo 5.

Steel-Dwass (valor p)				Steel-Dwass (valor p)				Steel-Dwass (valor p)			
flex	TAEA	TAEA-FB	<,0001	grep	TAEA	TAEA-FB	<,0001	gzip	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001
	TAEA	TAEA-AG	<,0001		TAEA	TAEA-AG	<,0001		TAEA	TAEA-AG	<,0001
	TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001
	TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001
print tokens	TAEA	TAEA-FB	<,0001	print tokens 2	TAEA	TAEA-FB	<,0001	replace	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001
	TAEA	TAEA-AG	0,6237		TAEA	TAEA-AG	0,6582		TAEA	TAEA-AG	0,7234
	TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001
	TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001
schedule	TAEA	TAEA-FB	<,0001	schedule 2	TAEA	TAEA-FB	<,0001	sed	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001
	TAEA	TAEA-AG	0,4192		TAEA	TAEA-AG	0,1965		TAEA	TAEA-AG	<,0001
	TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001
	TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001
space	TAEA	TAEA-FB	<,0001	tcas	TAEA	TAEA-FB	<,0001	totinfo	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001
	TAEA	TAEA-AG	<,0001		TAEA	TAEA-AG	0,9976		TAEA	TAEA-AG	0,9777
	TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	0,1936		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	0,2829		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001
	TAEA-1opt	TAEA-HS	0,7366		TAEA-1opt	TAEA-HS	0,8996		TAEA-1opt	TAEA-HS	<,0001
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001

Tabela A.47: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica CVR - Subgrupo 5.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	TAEA	1,00000 (0,000000)	<,0001	grep	TAEA	1,00000 (0,000000)	0,4060	gzip	TAEA	1,00000 (0,000000)	<,0001
	TAEA-FB	0,97924 (0,063555)			TAEA-FB	0,99661 (0,033898)			TAEA-FB	0,84943 (0,088994)	
	TAEA-1opt	1,00000 (0,000000)			TAEA-1opt	1,00000 (0,000000)			TAEA-1opt	1,00000 (0,000000)	
	TAEA-AG	1,00000 (0,000000)			TAEA-AG	1,00000 (0,000000)			TAEA-AG	1,00000 (0,000000)	
	TAEA-HS	1,00000 (0,000000)			TAEA-HS	1,00000 (0,000000)			TAEA-HS	1,00000 (0,000000)	
print tokens	TAEA	1,00000 (0,000000)	<,0001	print tokens 2	TAEA	1,00000 (0,000000)	<,0001	replace	TAEA	1,00000 (0,000000)	<,0001
	TAEA-FB	0,81280 (0,193663)			TAEA-FB	0,53522 (0,246400)			TAEA-FB	0,86419 (0,120549)	
	TAEA-1opt	1,00000 (0,000000)			TAEA-1opt	1,00000 (0,000000)			TAEA-1opt	1,00000 (0,000000)	
	TAEA-AG	1,00000 (0,000000)			TAEA-AG	1,00000 (0,000000)			TAEA-AG	1,00000 (0,000000)	
	TAEA-HS	1,00000 (0,000000)			TAEA-HS	1,00000 (0,000000)			TAEA-HS	1,00000 (0,000000)	
schedule	TAEA	1,00000 (0,000000)	<,0001	schedule 2	TAEA	1,00000 (0,000000)	<,0001	sed	TAEA	1,00000 (0,000000)	<,0001
	TAEA-FB	0,69326 (0,225557)			TAEA-FB	0,29309 (0,066457)			TAEA-FB	0,98471 (0,020050)	
	TAEA-1opt	0,99262 (0,059362)			TAEA-1opt	1,00000 (0,000000)			TAEA-1opt	1,00000 (0,000000)	
	TAEA-AG	1,00000 (0,000000)			TAEA-AG	1,00000 (0,000000)			TAEA-AG	1,00000 (0,000000)	
	TAEA-HS	1,00000 (0,000000)			TAEA-HS	1,00000 (0,000000)			TAEA-HS	1,00000 (0,000000)	
space	TAEA	1,00000 (0,000000)	<,0001	tcas	TAEA	1,00000 (0,000000)	<,0001	totinfo	TAEA	1,00000 (0,000000)	<,0001
	TAEA-FB	0,92983 (0,046287)			TAEA-FB	0,69035 (0,307330)			TAEA-FB	0,62125 (0,375718)	
	TAEA-1opt	1,00000 (0,000000)			TAEA-1opt	0,94265 (0,095168)			TAEA-1opt	0,99700 (0,025446)	
	TAEA-AG	1,00000 (0,000000)			TAEA-AG	1,00000 (0,000000)			TAEA-AG	1,00000 (0,000000)	
	TAEA-HS	1,00000 (0,000000)			TAEA-HS	0,96508 (0,042319)			TAEA-HS	1,00000 (0,000000)	

Tabela A.48: Resultados do teste Steel-Dwass - Métrica CVR - Subgrupo 5.


Steel-Dwass (valor p)				Steel-Dwass (valor p)				Steel-Dwass (valor p)			
flex	TAEA	TAEA-FB	<,0001	gzip	TAEA	TAEA-FB	<,0001	print tokens	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	1,0000		TAEA	TAEA-1opt	1,0000		TAEA	TAEA-1opt	1,0000
	TAEA	TAEA-AG	1,0000		TAEA	TAEA-AG	1,0000		TAEA	TAEA-AG	1,0000
	TAEA	TAEA-HS	1,0000		TAEA	TAEA-HS	1,0000		TAEA	TAEA-HS	1,0000
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	1,0000		TAEA-1opt	TAEA-AG	1,0000		TAEA-1opt	TAEA-AG	1,0000
	TAEA-1opt	TAEA-HS	1,0000		TAEA-1opt	TAEA-HS	1,0000		TAEA-1opt	TAEA-HS	1,0000
	TAEA-AG	TAEA-HS	1,0000		TAEA-AG	TAEA-HS	1,0000		TAEA-AG	TAEA-HS	1,0000
print tokens 2	TAEA	TAEA-FB	<,0001	replace	TAEA	TAEA-FB	<,0001	schedule	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	1,0000		TAEA	TAEA-1opt	1,0000		TAEA	TAEA-1opt	0,6207
	TAEA	TAEA-AG	1,0000		TAEA	TAEA-AG	1,0000		TAEA	TAEA-AG	1,0000
	TAEA	TAEA-HS	1,0000		TAEA	TAEA-HS	1,0000		TAEA	TAEA-HS	1,0000
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	1,0000		TAEA-1opt	TAEA-AG	1,0000		TAEA-1opt	TAEA-AG	0,6207
	TAEA-1opt	TAEA-HS	1,0000		TAEA-1opt	TAEA-HS	1,0000		TAEA-1opt	TAEA-HS	0,6207
	TAEA-AG	TAEA-HS	1,0000		TAEA-AG	TAEA-HS	1,0000		TAEA-AG	TAEA-HS	1,0000
schedule 2	TAEA	TAEA-FB	<,0001	sed	TAEA	TAEA-FB	<,0001	space	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	1,0000		TAEA	TAEA-1opt	1,0000		TAEA	TAEA-1opt	1,0000
	TAEA	TAEA-AG	1,0000		TAEA	TAEA-AG	1,0000		TAEA	TAEA-AG	1,0000
	TAEA	TAEA-HS	1,0000		TAEA	TAEA-HS	1,0000		TAEA	TAEA-HS	1,0000
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	1,0000		TAEA-1opt	TAEA-AG	1,0000		TAEA-1opt	TAEA-AG	1,0000
	TAEA-1opt	TAEA-HS	1,0000		TAEA-1opt	TAEA-HS	1,0000		TAEA-1opt	TAEA-HS	1,0000
	TAEA-AG	TAEA-HS	1,0000		TAEA-AG	TAEA-HS	1,0000		TAEA-AG	TAEA-HS	1,0000
tcas	TAEA	TAEA-FB	<,0001	totinfo	TAEA	TAEA-FB	<,0001				
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	0,6207				
	TAEA	TAEA-AG	1,0000		TAEA	TAEA-AG	1,0000				
	TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	1,0000				
	TAEA-FB	TAEA-1opt	0,0002		TAEA-FB	TAEA-1opt	<,0001				
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001				
	TAEA-FB	TAEA-HS	0,0033		TAEA-FB	TAEA-HS	<,0001				
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	0,6207				
	TAEA-1opt	TAEA-HS	1,0000		TAEA-1opt	TAEA-HS	0,6207				
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	1,0000				

Tabela A.49: Valores da média, desvio padrão e Kruskal-Wallis (valor p) - Métrica MS - Subgrupo 5.

		média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)			média (desv. pad.)	Kruskal-Wallis (valor p)
flex	TAEA	0,251026 (0,006846)	<,0001	grep	TAEA	0,028976 (0,016767)	<,0001	gzip	TAEA	0,143741 (0,023516)	<,0001
	TAEA-FB	0,764053 (0,347235)			TAEA-FB	0,301680 (0,083850)			TAEA-FB	0,992386 (0,005121)	
	TAEA-1opt	0,286941 (0,025504)			TAEA-1opt	0,106847 (0,036638)			TAEA-1opt	0,149340 (0,018242)	
	TAEA-AG	0,263407 (0,009333)			TAEA-AG	0,067017 (0,015493)			TAEA-AG	0,168556 (0,033352)	
	TAEA-HS	0,254812 (0,007736)			TAEA-HS	0,064583 (0,024992)			TAEA-HS	0,151385 (0,014149)	
print tokens	TAEA	0,003443 (0,008199)	<,0001	print tokens 2	TAEA	0,000137 (0,000964)	<,0001	replace	TAEA	0,001657 (0,003789)	<,0001
	TAEA-FB	0,761639 (0,385111)			TAEA-FB	0,853848 (0,296625)			TAEA-FB	0,861214 (0,316256)	
	TAEA-1opt	0,030814 (0,012398)			TAEA-1opt	0,010616 (0,011436)			TAEA-1opt	0,005804 (0,005810)	
	TAEA-AG	0,002725 (0,006351)			TAEA-AG	0,000206 (0,001175)			TAEA-AG	0,002447 (0,005039)	
	TAEA-HS	0,016050 (0,016289)			TAEA-HS	0,001033 (0,002655)			TAEA-HS	0,006750 (0,007262)	
schedule	TAEA	0,008464 (0,013020)	<,0001	schedule 2	TAEA	0,004397 (0,008317)	<,0001	sed	TAEA	0,031372 (0,026246)	<,0001
	TAEA-FB	0,861753 (0,234746)			TAEA-FB	0,987679 (0,002439)			TAEA-FB	0,789952 (0,373564)	
	TAEA-1opt	0,341842 (0,240348)			TAEA-1opt	0,154617 (0,093601)			TAEA-1opt	0,074902 (0,053077)	
	TAEA-AG	0,009411 (0,017420)			TAEA-AG	0,004719 (0,008596)			TAEA-AG	0,046194 (0,034629)	
	TAEA-HS	0,026537 (0,021179)			TAEA-HS	0,014902 (0,015633)			TAEA-HS	0,040085 (0,015676)	
space	TAEA	0,099756 (0,047361)	<,0001	tcas	TAEA	0,013227 (0,026109)	<,0001	totinfo	TAEA	0,000829 (0,003306)	<,0001
	TAEA-FB	0,988502 (0,040613)			TAEA-FB	0,613604 (0,458511)			TAEA-FB	0,719198 (0,361082)	
	TAEA-1opt	0,226530 (0,055617)			TAEA-1opt	0,644161 (0,376362)			TAEA-1opt	0,297118 (0,237588)	
	TAEA-AG	0,124650 (0,029694)			TAEA-AG	0,015156 (0,023881)			TAEA-AG	0,000653 (0,002863)	
	TAEA-HS	0,240307 (0,040676)			TAEA-HS	0,758500 (0,181804)			TAEA-HS	0,024669 (0,038813)	


Tabela A.50: Resultados do teste Steel-Dwass - Métrica MS - Subgrupo 5.

Steel-Dwass (valor p)				Steel-Dwass (valor p)				Steel-Dwass (valor p)			
flex	TAEA	TAEA-FB	<,0001	grep	TAEA	TAEA-FB	<,0001	gzip	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	0,5902
	TAEA	TAEA-AG	<,0001		TAEA	TAEA-AG	<,0001		TAEA	TAEA-AG	<,0001
	TAEA	TAEA-HS	0,0052		TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	0,0112
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	0,0003
	TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	0,2167
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	0,3824		TAEA-AG	TAEA-HS	0,0080
print tokens	TAEA	TAEA-FB	<,0001	print tokens 2	TAEA	TAEA-FB	<,0001	replace	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001
	TAEA	TAEA-AG	0,9973		TAEA	TAEA-AG	0,9927		TAEA	TAEA-AG	0,7029
	TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	0,0155		TAEA	TAEA-HS	<,0001
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001
	TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	0,6881
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	0,0419		TAEA-AG	TAEA-HS	<,0001
schedule	TAEA	TAEA-FB	<,0001	schedule 2	TAEA	TAEA-FB	<,0001	sed	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001
	TAEA	TAEA-AG	0,9181		TAEA	TAEA-AG	0,9999		TAEA	TAEA-AG	<,0001
	TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001
	TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001		TAEA-1opt	TAEA-HS	<,0001
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	0,9998
space	TAEA	TAEA-FB	<,0001	tcas	TAEA	TAEA-FB	<,0001	totinfo	TAEA	TAEA-FB	<,0001
	TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001		TAEA	TAEA-1opt	<,0001
	TAEA	TAEA-AG	<,0001		TAEA	TAEA-AG	0,9680		TAEA	TAEA-AG	0,9947
	TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001		TAEA	TAEA-HS	<,0001
	TAEA-FB	TAEA-1opt	<,0001		TAEA-FB	TAEA-1opt	0,1392		TAEA-FB	TAEA-1opt	<,0001
	TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001		TAEA-FB	TAEA-AG	<,0001
	TAEA-FB	TAEA-HS	<,0001		TAEA-FB	TAEA-HS	0,9030		TAEA-FB	TAEA-HS	<,0001
	TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001		TAEA-1opt	TAEA-AG	<,0001
	TAEA-1opt	TAEA-HS	0,2659		TAEA-1opt	TAEA-HS	0,6783		TAEA-1opt	TAEA-HS	<,0001
	TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001		TAEA-AG	TAEA-HS	<,0001




1 – BMOPSO-CDR 2 – BMOPSO-CDR-FB 3 – BMOPSO-CDR-1opt 4 – BMOPSO-CDR-AG 5 – BMOPSO-CDR-HS

Figura A.1: Boxplots dos valores da métrica HV para cada programa SIR - Subgrupo 1.




1 – BMOPSO-CDR 2 – BMOPSO-CDR-FB 3 – BMOPSO-CDR-1opt 4 – BMOPSO-CDR-AG 5 – BMOPSO-CDR-HS

Figura A.2: Boxplots dos valores da métrica GD para cada programa SIR - Subgrupo 1.




1 – BMOPSO-CDR 2 – BMOPSO-CDR-FB 3 – BMOPSO-CDR-1opt 4 – BMOPSO-CDR-AG 5 – BMOPSO-CDR-HS

Figura A.3: Boxplots dos valores da métrica IGD para cada programa SIR - Subgrupo 1.




1 – BMOPSO-CDR 2 – BMOPSO-CDR-FB 3 – BMOPSO-CDR-1opt 4 – BMOPSO-CDR-AG 5 – BMOPSO-CDR-HS

Figura A.4: Boxplots dos valores da métrica CVR para cada programa SIR - Subgrupo 1.




1 – BMOPSO-CDR 2 – BMOPSO-CDR-FB 3 – BMOPSO-CDR-1opt 4 – BMOPSO-CDR-AG 5 – BMOPSO-CDR-HS

Figura A.5: Boxplots dos valores da métrica MS para cada programa SIR - Subgrupo 1.




1 – BSMPSO 2 – BSMPSO-FB 3 – BSMPSO-1opt 4 – BSMPSO-AG 5 – BSMPSO-HS

Figura A.6: Boxplots dos valores da métrica HV para cada programa SIR - Subgrupo 2.




1 – BSMPSO 2 – BSMPSO-FB 3 – BSMPSO-1opt 4 – BSMPSO-AG 5 – BSMPSO-HS

Figura A.7: Boxplots dos valores da métrica GD para cada programa SIR - Subgrupo 2.




1 – BSMP SO 2 – BSMP SO-FB 3 – BSMP SO-1opt 4 – BSMP SO-AG 5 – BSMP SO-HS

Figura A.8: Boxplots dos valores da métrica IGD para cada programa SIR - Subgrupo 2.




1 – BSMPSO 2 – BSMPSO-FB 3 – BSMPSO-1opt 4 – BSMPSO-AG 5 – BSMPSO-HS

Figura A.9: Boxplots dos valores da métrica CVR para cada programa SIR - Subgrupo 2.




1 – BSMP SO 2 – BSMP SO-FB 3 – BSMP SO-1opt 4 – BSMP SO-AG 5 – BSMP SO-HS

Figura A.10: Boxplots dos valores da métrica MS para cada programa SIR - Subgrupo 2.




1 - NSGA-II 2 - NSGA-II-FB 3 - NSGA-II-1opt 4 - NSGA-II-AG 5 - NSGA-II-HS

Figura A.11: Boxplots dos valores da métrica HV para cada programa SIR - Subgrupo 3.



1 – NSGA-II 2 – NSGA-II-FB 3 – NSGA-II-1opt 4 – NSGA-II-AG 5 – NSGA-II-HS

Figura A.12: Boxplots dos valores da métrica GD para cada programa SIR - Subgrupo 3.



1 – NSGA-II 2 – NSGA-II-FB 3 – NSGA-II-1opt 4 – NSGA-II-AG 5 – NSGA-II-HS

Figura A.13: Boxplots dos valores da métrica IGD para cada programa SIR - Subgrupo 3.






Figura A.14: Boxplots dos valores da métrica CVR para cada programa SIR - Subgrupo 3.




1 - NSGA-II 2 - NSGA-II-FB 3 - NSGA-II-1opt 4 - NSGA-II-AG 5 - NSGA-II-HS

Figura A.15: Boxplots dos valores da métrica MS para cada programa SIR - Subgrupo 3.




1 – SPEA2 2 – SPEA2-FB 3 – SPEA2-1opt 4 – SPEA2-AG 5 – SPEA2-HS

Figura A.16: Boxplots dos valores da métrica HV para cada programa SIR - Subgrupo 4.




1 – SPEA2 2 – SPEA2-FB 3 – SPEA2-1opt 4 – SPEA2-AG 5 – SPEA2-HS

Figura A.17: Boxplots dos valores da métrica GD para cada programa SIR - Subgrupo 4.




1 - SPEA2 2 - SPEA2-FB 3 - SPEA2-1opt 4 - SPEA2-AG 5 - SPEA2-HS

Figura A.18: Boxplots dos valores da métrica IGD para cada programa SIR - Subgrupo 4.




1 – SPEA2 2 – SPEA2-FB 3 – SPEA2-1opt 4 – SPEA2-AG 5 – SPEA2-HS

Figura A.19: Boxplots dos valores da métrica CVR para cada programa SIR - Subgrupo 4.




1 – SPEA2 2 – SPEA2-FB 3 – SPEA2-1opt 4 – SPEA2-AG 5 – SPEA2-HS

Figura A.20: Boxplots dos valores da métrica MS para cada programa SIR - Subgrupo 4.




1 – TAEA 2 – TAEA-FB 3 – TAEA-1opt 4 – TAEA-AG 5 – TAEA-HS

Figura A.21: Boxplots dos valores da métrica HV para cada programa SIR - Subgrupo 5.




1 – TAEA 2 – TAEA-FB 3 – TAEA-1opt 4 – TAEA-AG 5 – TAEA-HS

Figura A.22: Boxplots dos valores da métrica GD para cada programa SIR - Subgrupo 5.




1 – TAEA 2 – TAEA-FB 3 – TAEA-1opt 4 – TAEA-AG 5 – TAEA-HS

Figura A.23: Boxplots dos valores da métrica IGD para cada programa SIR - Subgrupo 5.



1 – TAEA 2 – TAEA-FB 3 – TAEA-1opt 4 – TAEA-AG 5 – TAEA-HS

Figura A.24: Boxplots dos valores da métrica CVR para cada programa SIR - Subgrupo 5.



1 – TAEA 2 – TAEA-FB 3 – TAEA-1opt 4 – TAEA-AG 5 – TAEA-HS

Figura A.25: Boxplots dos valores da métrica MS para cada programa SIR - Subgrupo 5.




Figura A.26: Convergência da métrica HV ao longo das avaliações de função para cada programa SIR - Subgrupo 1.




Figura A.27: Convergência da métrica GD ao longo das avaliações de função para cada programa SIR - Subgrupo 1.




Figura A.28: Convergência da métrica IGD ao longo das avaliações de função para cada programa SIR - Subgrupo 1.




Figura A.29: Convergência da métrica CVR ao longo das avaliações de função para cada programa SIR - Subgrupo 1.




Figura A.30: Convergência da métrica MS ao longo das avaliações de função para cada programa SIR - Subgrupo 1.




Figura A.31: Convergência da métrica HV ao longo das avaliações de função para cada programa SIR - Subgrupo 2.




Figura A.32: Convergência da métrica GD ao longo das avaliações de função para cada programa SIR - Subgrupo 2.




Figura A.33: Convergência da métrica IGD ao longo das avaliações de função para cada programa SIR - Subgrupo 2.




Figura A.34: Convergência da métrica CVR ao longo das avaliações de função para cada programa SIR - Subgrupo 2.




Figura A.35: Convergência da métrica MS ao longo das avaliações de função para cada programa SIR - Subgrupo 2.




Figura A.36: Convergência da métrica HV ao longo das avaliações de função para cada programa SIR - Subgrupo 3.




Figura A.37: Convergência da métrica GD ao longo das avaliações de função para cada programa SIR - Subgrupo 3.




Figura A.38: Convergência da métrica IGD ao longo das avaliações de função para cada programa SIR - Subgrupo 3.




Figura A.39: Convergência da métrica CVR ao longo das avaliações de função para cada programa SIR - Subgrupo 3.




Figura A.40: Convergência da métrica MS ao longo das avaliações de função para cada programa SIR - Subgrupo 3.




Figura A.41: Convergência da métrica HV ao longo das avaliações de função para cada programa SIR - Subgrupo 4.




Figura A.42: Convergência da métrica GD ao longo das avaliações de função para cada programa SIR - Subgrupo 4.




Figura A.43: Convergência da métrica IGD ao longo das avaliações de função para cada programa SIR - Subgrupo 4.




Figura A.44: Convergência da métrica CVR ao longo das avaliações de função para cada programa SIR - Subgrupo 4.




Figura A.45: Convergência da métrica MS ao longo das avaliações de função para cada programa SIR - Subgrupo 4.




Figura A.46: Convergência da métrica HV ao longo das avaliações de função para cada programa SIR - Subgrupo 5.




Figura A.47: Convergência da métrica GD ao longo das avaliações de função para cada programa SIR - Subgrupo 5.




Figura A.48: Convergência da métrica IGD ao longo das avaliações de função para cada programa SIR - Subgrupo 5.




Figura A.49: Convergência da métrica CVR ao longo das avaliações de função para cada programa SIR - Subgrupo 5.




Figura A.50: Convergência da métrica MS ao longo das avaliações de função para cada programa SIR - Subgrupo 5.

B

Dados Adicionais para as Melhores Técnicas

Neste apêndice são apresentadas as tabelas com os resultados estatísticos do teste de múltiplas comparações Steel-Dwass, os Boxplots e os gráficos de convergência para as melhores técnicas.

Tabela B.1: Resultados do teste Steel-Dwass - GUAVA.


Steel-Dwass (valor p)				Steel-Dwass (valor p)			
MS	BMOPSO-CDR-FB	BSMPSO-FB	0,9491	TP	BMOPSO-CDR-FB	BSMPSO-FB	0,0035
	BMOPSO-CDR-FB	NSGA-II-FB	0,0059		BMOPSO-CDR-FB	NSGA-II-FB	0,3645
	BMOPSO-CDR-FB	SPEA2-FB	0,0099		BMOPSO-CDR-FB	SPEA2-FB	<,0001
	BMOPSO-CDR-FB	TAEA-FB	0,0032		BMOPSO-CDR-FB	TAEA-FB	0,0186
	BSMPSO-FB	NSGA-II-FB	0,0234		BSMPSO-FB	NSGA-II-FB	0,1325
	BSMPSO-FB	SPEA2-FB	0,0448		BSMPSO-FB	SPEA2-FB	<,0001
	BSMPSO-FB	TAEA-FB	0,0156		BSMPSO-FB	TAEA-FB	0,9771
	NSGA-II-FB	SPEA2-FB	0,9993		NSGA-II-FB	SPEA2-FB	<,0001
	NSGA-II-FB	TAEA-FB	1,0000		NSGA-II-FB	TAEA-FB	0,2372
	SPEA2-FB	TAEA-FB	0,9999		SPEA2-FB	TAEA-FB	<,0001

Tabela B.2: Resultados do teste Steel-Dwass - Cobertura x Falhas - GUAVA.

Steel-Dwass (valor p)				Steel-Dwass (valor p)			
HV	BMOPSO-CDR-FB	BSMPSO-FB	0,7940	GD	BMOPSO-CDR-FB	BSMPSO-FB	0,4951
	BMOPSO-CDR-FB	NSGA-II-FB	0,9358		BMOPSO-CDR-FB	NSGA-II-FB	0,9682
	BMOPSO-CDR-FB	SPEA2-FB	0,0489		BMOPSO-CDR-FB	SPEA2-FB	0,0811
	BMOPSO-CDR-FB	TAEA-FB	0,2520		BMOPSO-CDR-FB	TAEA-FB	0,3465
	BSMPSO-FB	NSGA-II-FB	0,4157		BSMPSO-FB	NSGA-II-FB	0,2999
	BSMPSO-FB	SPEA2-FB	0,0012		BSMPSO-FB	SPEA2-FB	0,0007
	BSMPSO-FB	TAEA-FB	0,0226		BSMPSO-FB	TAEA-FB	0,0160
	NSGA-II-FB	SPEA2-FB	0,1754		NSGA-II-FB	SPEA2-FB	0,2422
	NSGA-II-FB	TAEA-FB	0,7049		NSGA-II-FB	TAEA-FB	0,6898
	SPEA2-FB	TAEA-FB	0,8213		SPEA2-FB	TAEA-FB	0,8874
IGD	BMOPSO-CDR-FB	BSMPSO-FB	0,6928	CVR	BMOPSO-CDR-FB	BSMPSO-FB	1,0000
	BMOPSO-CDR-FB	NSGA-II-FB	0,9531		BMOPSO-CDR-FB	NSGA-II-FB	0,0431
	BMOPSO-CDR-FB	SPEA2-FB	0,0516		BMOPSO-CDR-FB	SPEA2-FB	0,0107
	BMOPSO-CDR-FB	TAEA-FB	0,3096		BMOPSO-CDR-FB	TAEA-FB	0,0107
	BSMPSO-FB	NSGA-II-FB	0,4161		BSMPSO-FB	NSGA-II-FB	0,0431
	BSMPSO-FB	SPEA2-FB	0,0011		BSMPSO-FB	SPEA2-FB	0,0107
	BSMPSO-FB	TAEA-FB	0,0249		BSMPSO-FB	TAEA-FB	0,0107
	NSGA-II-FB	SPEA2-FB	0,1781		NSGA-II-FB	SPEA2-FB	0,8600
	NSGA-II-FB	TAEA-FB	0,6652		NSGA-II-FB	TAEA-FB	0,8600
	SPEA2-FB	TAEA-FB	0,8280		SPEA2-FB	TAEA-FB	1,0000
MS	BMOPSO-CDR-FB	BSMPSO-FB	0,8017				
	BMOPSO-CDR-FB	NSGA-II-FB	0,0004				
	BMOPSO-CDR-FB	SPEA2-FB	0,4922				
	BMOPSO-CDR-FB	TAEA-FB	0,0154				
	BSMPSO-FB	NSGA-II-FB	0,0194				
	BSMPSO-FB	SPEA2-FB	0,9849				
	BSMPSO-FB	TAEA-FB	0,2634				
	NSGA-II-FB	SPEA2-FB	0,0862				
	NSGA-II-FB	TAEA-FB	0,8171				
	SPEA2-FB	TAEA-FB	0,5705				

Tabela B.3: Resultados do teste Steel-Dwass - Custo x Falhas - GUAVA.

Steel-Dwass (valor p)				Steel-Dwass (valor p)			
IGD	BMOPSO-CDR-FB	BSMPSO-FB	0,9284	MS	BMOPSO-CDR-FB	BSMPSO-FB	0,9933
	BMOPSO-CDR-FB	NSGA-II-FB	0,0605		BMOPSO-CDR-FB	NSGA-II-FB	0,0030
	BMOPSO-CDR-FB	SPEA2-FB	0,1037		BMOPSO-CDR-FB	SPEA2-FB	0,0020
	BMOPSO-CDR-FB	TAEA-FB	0,0364		BMOPSO-CDR-FB	TAEA-FB	0,0029
	BSMPSO-FB	NSGA-II-FB	0,4681		BSMPSO-FB	NSGA-II-FB	0,0110
	BSMPSO-FB	SPEA2-FB	0,6157		BSMPSO-FB	SPEA2-FB	0,0136
	BSMPSO-FB	TAEA-FB	0,3526		BSMPSO-FB	TAEA-FB	0,0235
	NSGA-II-FB	SPEA2-FB	1,0000		NSGA-II-FB	SPEA2-FB	0,9998
	NSGA-II-FB	TAEA-FB	0,9740		NSGA-II-FB	TAEA-FB	0,9999
	SPEA2-FB	TAEA-FB	0,9383		SPEA2-FB	TAEA-FB	1,0000



1 – BMOPSO-CDR-FB 2 – BSMPPO-FB 3 – NSGA-II-FB 4 – SPEA2-FB 5 – TAEA-FB

Figura B.1: Boxplots dos valores das métricas para o programa GUAVA.






Figura B.2: Convergência das métricas ao longo das avaliações das funções objetivo - GUAVA.



1 – BMOPSO-CDR-FB 2 – BSMP2SO-FB 3 – NSGA-II-FB 4 – SPEA2-FB 5 – TAEA-FB

Figura B.3: Boxplots dos valores das métricas para o programa GUAVA - Cobertura x Falhas.



1 – BMOPSO-CDR-FB 2 – BSMP SO-FB 3 – NSGA-II-FB 4 – SPEA2-FB 5 – TAEA-FB

Figura B.4: Boxplots dos valores das métricas para o programa GUAVA - Custo x Falhas.



Dados Adicionais para o Estudo com Restrições

Neste apêndice são apresentadas as tabelas com os resultados estatísticos do teste de múltiplas comparações Steel-Dwass, assim como os Boxplots com os valores das métricas.

Tabela C.1: Resultados do teste Steel-Dwass no programa GUAVA no cenário de Cobertura de Requisitos $\geq 50\%$

			Steel-Dwass (valor p)				Steel-Dwass (valor p)
HV	BSMPSO-FB	CBSMPSO-FB-C	<,0001	GD	BSMPSO-FB	CBSMPSO-FB-C	<,0001
	BSMPSO-FB	CBSMPSO-FB-F	<,0001		BSMPSO-FB	CBSMPSO-FB-F	<,0001
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,5997		CBSMPSO-FB-C	CBSMPSO-FB-F	0,9916
IGD	BSMPSO-FB	CBSMPSO-FB-C	0,0001	CVR	BSMPSO-FB	CBSMPSO-FB-C	0,0476
	BSMPSO-FB	CBSMPSO-FB-F	<,0001		BSMPSO-FB	CBSMPSO-FB-F	0,0082
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,6908		CBSMPSO-FB-C	CBSMPSO-FB-F	0,8234
MS	BSMPSO-FB	CBSMPSO-FB-C	0,0014	TP	BSMPSO-FB	CBSMPSO-FB-C	<,0001
	BSMPSO-FB	CBSMPSO-FB-F	0,0036		BSMPSO-FB	CBSMPSO-FB-F	<,0001
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,9455		CBSMPSO-FB-C	CBSMPSO-FB-F	0,0022

Tabela C.2: Resultados do teste Steel-Dwass no programa GUAVA no cenário de Custo de Execução $\leq 50\%$

			Steel-Dwass (valor p)				Steel-Dwass (valor p)
HV	BSMPSO-FB	CBSMPSO-FB-C	<,0001	GD	BSMPSO-FB	CBSMPSO-FB-C	<,0001
	BSMPSO-FB	CBSMPSO-FB-F	<,0001		BSMPSO-FB	CBSMPSO-FB-F	<,0001
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,5796		CBSMPSO-FB-C	CBSMPSO-FB-F	0,5426
IGD	BSMPSO-FB	CBSMPSO-FB-C	<,0001	CVR	BSMPSO-FB	CBSMPSO-FB-C	0,0368
	BSMPSO-FB	CBSMPSO-FB-F	<,0001		BSMPSO-FB	CBSMPSO-FB-F	0,0020
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,4238		CBSMPSO-FB-C	CBSMPSO-FB-F	0,5421
MS	BSMPSO-FB	CBSMPSO-FB-C	<,0001	TP	BSMPSO-FB	CBSMPSO-FB-C	<,0001
	BSMPSO-FB	CBSMPSO-FB-F	<,0001		BSMPSO-FB	CBSMPSO-FB-F	<,0001
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,2620		CBSMPSO-FB-C	CBSMPSO-FB-F	0,1189

Tabela C.3: Resultados do teste Steel-Dwass no programa GUAVA no cenário de Cobertura de Requisitos $\geq 90\%$

Steel-Dwass (valor p)				Steel-Dwass (valor p)			
HV	BSMPSO-FB	CBSMPSO-FB-C	0,0908	IGD	BSMPSO-FB	CBSMPSO-FB-C	0,2336
	BSMPSO-FB	CBSMPSO-FB-F	<,0001		BSMPSO-FB	CBSMPSO-FB-F	<,0001
	CBSMPSO-FB-C	CBSMPSO-FB-F	<,0001		CBSMPSO-FB-C	CBSMPSO-FB-F	0,0273
CVR	BSMPSO-FB	CBSMPSO-FB-C	0,8739	MS	BSMPSO-FB	CBSMPSO-FB-C	0,2439
	BSMPSO-FB	CBSMPSO-FB-F	0,0113		BSMPSO-FB	CBSMPSO-FB-F	0,0259
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,0035		CBSMPSO-FB-C	CBSMPSO-FB-F	0,0013
TP	BSMPSO-FB	CBSMPSO-FB-C	<,0001				
	BSMPSO-FB	CBSMPSO-FB-F	<,0001				
	CBSMPSO-FB-C	CBSMPSO-FB-F	<,0001				

Tabela C.4: Resultados do teste Steel-Dwass no programa GUAVA no cenário de Custo de Execução $\leq 10\%$

Steel-Dwass (valor p)				Steel-Dwass (valor p)			
HV	BSMPSO-FB	CBSMPSO-FB-C	<,0001	GD	BSMPSO-FB	CBSMPSO-FB-C	<,0001
	BSMPSO-FB	CBSMPSO-FB-F	<,0001		BSMPSO-FB	CBSMPSO-FB-F	<,0001
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,5509		CBSMPSO-FB-C	CBSMPSO-FB-F	0,4825
IGD	BSMPSO-FB	CBSMPSO-FB-C	<,0001	CVR	BSMPSO-FB	CBSMPSO-FB-C	0,0274
	BSMPSO-FB	CBSMPSO-FB-F	<,0001		BSMPSO-FB	CBSMPSO-FB-F	0,0705
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,0332		CBSMPSO-FB-C	CBSMPSO-FB-F	0,5261
MS	BSMPSO-FB	CBSMPSO-FB-C	<,0001	TP	BSMPSO-FB	CBSMPSO-FB-C	<,0001
	BSMPSO-FB	CBSMPSO-FB-F	<,0001		BSMPSO-FB	CBSMPSO-FB-F	<,0001
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,0600		CBSMPSO-FB-C	CBSMPSO-FB-F	<,0001

Tabela C.5: Resultados do teste Steel-Dwass para as métricas no programa GUAVA - Dados Cobertura x Falhas no cenário de Cobertura de Requisitos $\geq 50\%$.

Steel-Dwass (valor p)				Steel-Dwass (valor p)			
HV	BSMPSO-FB	CBSMPSO-FB-C	0,0053	GD	BSMPSO-FB	CBSMPSO-FB-C	0,0072
	BSMPSO-FB	CBSMPSO-FB-F	0,2950		BSMPSO-FB	CBSMPSO-FB-F	0,1529
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,1671		CBSMPSO-FB-C	CBSMPSO-FB-F	0,4393
IGD	BSMPSO-FB	CBSMPSO-FB-C	0,0036				
	BSMPSO-FB	CBSMPSO-FB-F	0,2126				
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,2136				

Tabela C.6: Resultados do teste Steel-Dwass para as métricas no programa GUAVA - Dados Cobertura x Falhas no cenário de Cobertura de Requisitos $\geq 90\%$.

Steel-Dwass (valor p)				Steel-Dwass (valor p)			
GD	BSMPSO-FB	CBSMPSO-FB-C	0,0237				
	BSMPSO-FB	CBSMPSO-FB-F	0,1962				
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,7088				

Tabela C.7: Resultados do teste Steel-Dwass para as métricas no programa GUAVA - Dados Custo x Falhas no cenário de Cobertura de Requisitos $\geq 50\%$.

			Steel-Dwass (valor p)				Steel-Dwass (valor p)
HV	BSMPSO-FB	CBSMPSO-FB-C	0,0202	GD	BSMPSO-FB	CBSMPSO-FB-C	0,1019
	BSMPSO-FB	CBSMPSO-FB-F	0,0152		BSMPSO-FB	CBSMPSO-FB-F	0,0141
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,8897		CBSMPSO-FB-C	CBSMPSO-FB-F	0,6968
IGD	BSMPSO-FB	CBSMPSO-FB-C	0,1673	MS	BSMPSO-FB	CBSMPSO-FB-C	0,0277
	BSMPSO-FB	CBSMPSO-FB-F	0,0031		BSMPSO-FB	CBSMPSO-FB-F	0,0004
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,1408		CBSMPSO-FB-C	CBSMPSO-FB-F	0,1559

Tabela C.8: Resultados do teste Steel-Dwass para as métricas no programa GUAVA - Dados Custo x Falhas no cenário de Custo de Execução $\leq 50\%$.


			Steel-Dwass (valor p)				Steel-Dwass (valor p)
HV	BSMPSO-FB	CBSMPSO-FB-C	0,0086	GD	BSMPSO-FB	CBSMPSO-FB-C	0,0036
	BSMPSO-FB	CBSMPSO-FB-F	0,0088		BSMPSO-FB	CBSMPSO-FB-F	0,0047
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,8984		CBSMPSO-FB-C	CBSMPSO-FB-F	0,9985
IGD	BSMPSO-FB	CBSMPSO-FB-C	0,0001	CVR	BSMPSO-FB	CBSMPSO-FB-C	0,0838
	BSMPSO-FB	CBSMPSO-FB-F	<,0001		BSMPSO-FB	CBSMPSO-FB-F	0,0824
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,9722		CBSMPSO-FB-C	CBSMPSO-FB-F	1,0000
MS	BSMPSO-FB	CBSMPSO-FB-C	0,0001				
	BSMPSO-FB	CBSMPSO-FB-F	<,0001				
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,9722				

Tabela C.9: Resultados do teste Steel-Dwass para as métricas no programa GUAVA - Dados Custo x Falhas no cenário de Cobertura de Requisitos $\geq 90\%$.

			Steel-Dwass (valor p)				Steel-Dwass (valor p)
HV	BSMPSO-FB	CBSMPSO-FB-C	0,9814	IGD	BSMPSO-FB	CBSMPSO-FB-C	0,9888
	BSMPSO-FB	CBSMPSO-FB-F	0,0111		BSMPSO-FB	CBSMPSO-FB-F	0,0002
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,1259		CBSMPSO-FB-C	CBSMPSO-FB-F	0,0554
MS	BSMPSO-FB	CBSMPSO-FB-C	0,1387				
	BSMPSO-FB	CBSMPSO-FB-F	0,8006				
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,0170				

Tabela C.10: Resultados do teste Steel-Dwass para as métricas no programa GUAVA - Dados Custo x Falhas no cenário de Custo de Execução $\leq 10\%$.

			Steel-Dwass (valor p)				Steel-Dwass (valor p)
GD	BSMPSO-FB	CBSMPSO-FB-C	<,0001	IGD	BSMPSO-FB	CBSMPSO-FB-C	<,0001
	BSMPSO-FB	CBSMPSO-FB-F	<,0001		BSMPSO-FB	CBSMPSO-FB-F	<,0001
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,9608		CBSMPSO-FB-C	CBSMPSO-FB-F	0,0071
CVR	BSMPSO-FB	CBSMPSO-FB-C	0,0041	MS	BSMPSO-FB	CBSMPSO-FB-C	<,0001
	BSMPSO-FB	CBSMPSO-FB-F	0,1685		BSMPSO-FB	CBSMPSO-FB-F	<,0001
	CBSMPSO-FB-C	CBSMPSO-FB-F	0,8905		CBSMPSO-FB-C	CBSMPSO-FB-F	0,1437



1 - BSMPPO-FB 2 - CBSMPPO-FB-C 3 - CBSMPPO-FB-F

Figura C.1: Boxplots dos valores das métricas para o programa GUAVA no cenário de Cobertura de Requisitos $\geq 50\%$




Figura C.2: Boxplots dos valores das métricas para o programa GUAVA no cenário de Custo de Execução $\leq 50\%$




Figura C.3: Boxplots dos valores das métricas para o programa GUAVA no cenário de Cobertura de Requisitos $\geq 90\%$




Figura C.4: Boxplots dos valores das métricas para o programa GUAVA no cenário de Custo de Execução $\leq 10\%$