

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

***FRAMEWORK PARA INVESTIGAÇÃO DE
MAPEAMENTOS DE APLICAÇÕES EM
ARQUITETURAS *MANYCORE****

DENIS PEREIRA DE LIMA

ORIENTADOR: PROF. DR. EMERSON CARLOS PEDRINO

São Carlos – SP

Dezembro/2022

UNIVERSIDADE FEDERAL DE SÃO CARLOS

CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

***FRAMEWORK PARA INVESTIGAÇÃO DE
MAPEAMENTOS DE APLICAÇÕES EM
ARQUITETURAS *MANYCORE****

DENIS PEREIRA DE LIMA

Tese apresentada ao Programa de Pós-Graduação em
Ciência da Computação da Universidade Federal de
São Carlos, como parte dos requisitos para a obten-
ção do título de Doutor em Ciência da Computação,
área de concentração: Arquitetura de Computadores.
Orientador: Prof. Dr. Emerson Carlos Pedrino

São Carlos – SP

Dezembro/2022



UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Ciência da Computação

Folha de Aprovação

Defesa de Tese de Doutorado do candidato Denis Pereira de Lima, realizada em 07/12/2022.

Comissão Julgadora:

Prof. Dr. Emerson Carlos Pedrino (UFSCar)

Prof. Dr. Márcio Merino Fernandes (UFSCar)

Prof. Dr. José Hiroki Saito (UFSCar)

Prof. Dr. Mário Luiz Tronco (USP)

Prof. Dr. Ivan Nunes da Silva (USP)

AGRADECIMENTOS

Sou grato a minha esposa, Maria Cristina, e a minha filha, Sophia, que nunca me recusaram amor, apoio e incentivo. Obrigado, de todo o meu coração, por compartilhar os inúmeros momentos de ansiedade e estresse neste período. Sem vocês ao meu lado, o trabalho não seria concluído.

Agradeço a meus pais, Domingos (*in memoriam*) e Roseli, pela educação, respeito e suporte que puderam me prover.

Agradeço a meu amigo e orientador, Prof. Dr. Emerson Carlos Pedrino, pela excelente formação, ajuda e suporte em toda a minha formação, além das incontáveis horas de discussão acerca dos temas presentes nesta tese.

Agradeço ao Chefe do Departamento de Física, da UFSCar, pelo afastamento concedido a mim para o desenvolvimento desta pesquisa.

Aos amigos, que estiveram sempre ao meu lado, pela amizade incondicional e pelo apoio demonstrado, ao longo de todo o período, em que me dediquei a este trabalho.

Agradeço a todos os servidores do Departamento de Computação pelo acolhimento e apoio ao longo desta pesquisa, e durante as disciplinas cursadas.

Agradeço a todos os meus professores por terem me proporcionado reter o conhecimento, não apenas racional, mas a manifestação do caráter e afetividade da educação no processo de formação profissional.

A todos que participaram, direta ou indiretamente, do desenvolvimento deste trabalho de pesquisa, enriquecendo o meu processo de aprendizado.

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) – Código de Financiamento 001.

“A ciência nunca resolve um problema sem criar pelo menos outros dez”.

George Bernard Shaw

RESUMO

Nesta tese, propõe-se a implementação de um *framework* para mapeamento - com otimização de métricas multiobjetivo - de grafos de aplicações em arquiteturas *manycore*, com elementos de processamento homogêneos, visando-se propor uma nova abordagem em relação aos trabalhos encontrados na literatura relacionada. Para a validação desta proposta de tese, propõem-se: uma nova metodologia de calibração e mapeamento multiobjetivo de tarefas relacionadas à detecção de padrões em imagens de alta resolução (binária e escala de cinza); uma nova proposta de metodologia autoadaptativa a ser usada em algoritmos multiobjetivos para mapeamento de aplicações em arquiteturas *manycore*. Os resultados obtidos por meio da metodologia de detecção de padrões e mapeamento de tarefas, em arquiteturas *manycore*, demonstraram uma alta taxa de generalização e acurácia, trazendo uma nova contribuição em relação ao uso dos algoritmos multiobjetivos avaliados. O melhor desempenho, durante os experimentos, foi obtido pelo algoritmo PESAI, algo anteriormente não relatado na literatura. A metodologia relacionada ao mapeamento e uso de estratégia autoadaptativa representou um estudo completo no que tange os indicadores de desempenho *Hypervolume* e IGD, novamente comprovando a maior efetividade do PESAI para a métrica *Hypervolume*, novamente, trazendo uma nova contribuição acerca do uso dos algoritmos NSGAI e SPEA2, quanto à métrica IGD.

Palavras-chave: Mapeamento de tarefas, Arquiteturas *manycore*, Otimização multiobjetivo autoadaptativa, Tolerância a falhas, Eficiência energética e Balanceamento de carga.

ABSTRACT

This thesis proposes an implementation of a framework for mapping graphs onto many-core architectures with multi-objective metrics optimization. The aim is to propose a new approach in relation to the works found in the related literature. To validate this proposal, the following are presented: a calibration methodology and multi-objective mapping of tasks related to pattern detection in high-resolution images (binary and grayscale), and a proposal for a new self-adaptive methodology to be used in multi-objective algorithms for mapping applications for manycore architectures. The results obtained through the pattern detection and task mapping methodology on manycore architectures demonstrate a high rate of generalization and accuracy. This brings a new contribution regarding the use of the evaluated multi-objective algorithms, with the best performance obtained by the PESAI algorithm, which was not previously reported in the literature. The methodology related to the mapping and use of the self-adaptive strategy represents a complete study with the Hypervolume and IGD performance indicators, proving the greater effectiveness of PESAI for the Hypervolume metric. This also makes a new contribution regarding the NSGAI and SPEA2 algorithms regarding the metric IGD, demonstrating the improvement of the obtained results in the use of the proposed self-adaptive strategy.

Keywords: Task mapping, Manycore architectures, Self-adaptive multi-objective optimization, Fault Tolerance, Energy Efficiency and Load Balancing.

LISTA DE FIGURAS

1.1	Taxonomia básica e classificação das técnicas de mapeamento de aplicações em arquiteturas <i>manycore</i> , com destaque para as técnicas baseadas em MOEAs. Adaptado de (AMIN et al., 2020).	22
2.1	Elementos fundamentais de uma arquitetura <i>NoC</i> , baseados em uma estrutura de 4x4 elementos (SALMINEN; KULMALA; HAMALAINEN, 2008).	33
2.2	Estrutura básica de um roteador para arquiteturas <i>manycore</i> . Adaptado de (RETTKOWSKI; GÖHRINGER, 2018).	34
2.3	Exemplos de estruturas de comunicação em arquiteturas SoC. a) Comunicação tradicional baseada em <i>bus</i> ; b) Comunicação dedicada ponto a ponto; c) Comunicação baseada em rede. Adaptado de (BJERREGAARD; MAHADEVAN, 2006).	35
2.4	Formas regulares de topologia: (a) - Topologia em malha 4x4 com aridade 2; (b) - Topologia Toroidal 4 x 4 com aridade 2; (c) - Topologia de Árvore binária com aridade 2. Formas Irregulares: (d) - Topologia Em Malha com conexões irregulares; (e) - Topologia Mista com conexões irregulares. Adaptado de (BJERREGAARD; MAHADEVAN, 2006).	36
2.5	(a) - <i>Scalable, Programmable, Integrated Network (SPIN)</i> ; (b) - <i>Chip-Level Integration of Communicating Heterogeneous Elements (CLICHÉ)</i> ; (c) - Toroidal; (d) - Toroidal Dobrada; (e) - Octagonal; <i>Butterfly Fat-Tree (BFT)</i> . Adaptado de (PANDE et al., 2005).	37
2.6	Representação de pontos de interesse e delimitação da primeira fronteira de Pareto não dominada (DEB, 2011).	46
2.7	Exemplo do procedimento utilizado para a execução do algoritmo NSGAI proposto por Deb (2011).	48
4.1	Diagrama de blocos do <i>framework</i> proposto.	67

4.2	Detalhes de implementação do Procedimento_1D descrito no texto.	69
4.3	Pseudo código que representa o procedimento MOEA-A	72
4.4	Procedimento utilizado para criação da população.	73
4.5	<i>Framework</i> autoadaptativo proposto.	76
4.6	Exemplo de um arquivo de configuração utilizado no TGFF.	77
4.7	Exemplo de um arquivo de saída resultante do procedimento realizado no TGFF, representando um dos três grafos configurados para serem gerados, onde: <i>Task</i> representa as tarefas e seus respectivos pesos de computação contida no grafo em tela e <i>Arc</i> representa as ligações entre as tarefas e seus respectivos custos de comunicação.	78
4.8	Representação gráfica de um arquivo de saída resultante do procedimento realizado no TGFF, representando um dos três grafos configurados para serem gerados.	78
4.9	Representação da criação da população inicial com base nos cromossomos gerados e tamanho da população.	80
4.10	Exemplo prático do cálculo efetuado pela métrica de tolerância a falhas, conforme apresentado na Equação 4.5.	82
4.11	Exemplo prático do cálculo efetuado pela métrica de energia, conforme apresentado na Equação 4.6.	84
4.12	Exemplo prático do cálculo efetuado pela métrica de comunicação, conforme apresentado na Equação 4.7.	86
4.13	Exemplo prático do cálculo simplificado efetuado para obtenção do <i>Hypervolume</i> para avaliação da qualidade apresentada pelas novas soluções durante o procedimento de cruzamento.	88
5.1	Imagem da (PCB) usada para os experimentos. A área destacada mostra os três tipos de padrões (ilha quadrada, ilha circular e trilha) a serem detectados pelo filtro.	96
5.2	Exemplo de sub-imagens usadas no conjunto de teste e treinamento para a aplicação de detecção de padrões em imagens de PCB de alta resolução.	96

5.3	A planta de refino de petróleo foi capturada pelo satélite Ikonos RGB com resolução de 1 m (Imagem disponível em: https://effgis.com/en/solutions/satellite-images/satellite-image-samples/).	97
5.4	Exemplos de sub-imagens em tons de cinza usadas para o treinamento e teste da aplicação 2.	98
5.5	As imagens obtidas ao final dos procedimentos de treinamento e teste demonstram a eficácia do método em detectar os padrões previamente estabelecidos. Para a aplicação 1, os padrões detectados incluem círculo, quadrado e pista, conforme mostrado nas imagens. Já para a aplicação 2, os resultados também evidenciam o sucesso do método na detecção dos padrões específicos dessa aplicação.	99
5.6	Os grafos de aplicação e seus respectivos programas obtidos para a aplicação 1, que mostram os padrões (círculo, quadrado e trilha), e para a aplicação 2 são apresentados, respectivamente. Esses grafos ilustram as soluções encontradas pelo método para detectar os padrões específicos de cada aplicação.	102
5.7	Descrição do procedimento de calibração para obtenção do melhor MOEA para o <i>framework</i> proposto quanto à aplicação de filtros de detecção de padrões.	103
5.8	Procedimento para conversão de grafo para texto.	104
5.9	O histograma apresenta o número de acertos obtidos por cada um dos algoritmos avaliados em relação às três métricas descritas anteriormente: Energia, Tolerância a Falhas e Comunicação. O histograma inclui um total de 16 grafos de aplicação utilizados no procedimento de mapeamento.	107
5.10	<i>Boxplot</i> dos resultados de Comunicação, Energia e Tolerância a Falhas do procedimento de mapeamento da Tabela 5.6, usando tamanho de <i>grid</i> 9 (3 x 3), taxa de mutação 0,05 e 50000 avaliações.	109
5.11	<i>Boxplot</i> dos resultados de comunicação, energia e tolerância a falhas do procedimento de mapeamento da Tabela 5.6, usando tamanho de <i>grid</i> 12 (4 x 3), taxa de mutação 0,05 e 50000 avaliações.	109
5.12	<i>Boxplot</i> dos resultados de Comunicação, Energia e Tolerância a Falhas do procedimento de mapeamento da Tabela 5.6, usando tamanho de <i>grid</i> 16 (4 x 4), taxa de mutação 0,05 e 50000 avaliações.	110

5.13 Os nós em verde representam quais tarefas foram alocadas; nós em laranja re-
presentam quais nós não possuem tarefas alocadas. 111

LISTA DE TABELAS

3.1	Sumário dos trabalhos relacionados ao mapeamento em arquiteturas <i>manycore</i> .	63
4.1	Instruções Morfológicas, Aritméticas e Lógicas	66
4.2	Parâmetros e variáveis usados nos algoritmos (Treinamento e Teste)	66
4.3	Parâmetros utilizados no procedimento de mapeamento autoadaptativo.	79
4.4	Algoritmos utilizados no procedimento de mapeamento auto adaptativo.	79
4.5	Exemplo teórico de cálculo efetuado para obtenção e normalização das probabilidades referentes a cada um das estratégias de cruzamento	90
5.1	Parâmetros utilizados para os procedimentos de treinamento e teste	98
5.2	Resultados relacionados com o treinamento.	100
5.3	Resultados relacionados com o teste.	101
5.4	Lista de aplicações utilizadas no experimento de mapeamento de tarefas em arquiteturas <i>manycore</i>	105
5.5	Parâmetros e Algoritmos utilizados no procedimento de mapeamento.	105
5.6	Exemplo de resultados do procedimento de mapeamento aplicado para o gráfico número 3 na Tabela 5.4 (MWD (Multi Window Display)), onde foram avaliadas diferentes taxas de mutação, número de avaliações, tamanhos de <i>grid</i> e cinco algoritmos estado da arte.	106
5.7	Parâmetros adicionais utilizados no procedimento de mapeamento	110
5.8	Resumo dos resultados do procedimento de mapeamento <i>manycore</i> para o aplicativo 1	110
5.9	Resumo dos resultados do procedimento de mapeamento <i>manycore</i> para o aplicativo 2	110

5.10	Pontos de referência utilizados para cálculo do <i>Hypervolume</i>	112
5.11	Tamanho de cada um dos 10 grafos utilizados durante o procedimento de avaliação de resultados, organizados em relação ao tamanho do <i>grid</i> onde os conjuntos de grafos foram mapeados	113
A.1	Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Energia e Balanceamento de Carga em relação ao <i>grid</i> de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.	137
A.2	Resultados para o cálculo do IGD para as métricas de Energia e Balanceamento de Carga em relação ao <i>grid</i> de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.	137
A.3	Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Tolerância a Falhas e Energia em relação ao <i>grid</i> de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.	138
A.4	Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Energia em relação ao <i>grid</i> de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.	138
A.5	Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Tolerância a Falhas e Comunicação em relação ao <i>grid</i> de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.	139
A.6	Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Comunicação em relação ao <i>grid</i> de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.	139
A.7	Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Comunicação e Energia em relação ao <i>grid</i> de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.	140
A.8	Resultados para o cálculo do IGD para as métricas de Comunicação e Energia em relação ao <i>grid</i> de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.	140
A.9	Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Energia e Balanceamento de Carga em relação ao <i>grid</i> de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.	141

A.10 Resultados para o cálculo do IGD para as métricas de Energia e Balanceamento de Carga em relação ao <i>grid</i> de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.	141
A.11 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Tolerância a Falhas e Energia em relação ao <i>grid</i> de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.	142
A.12 Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Energia em relação ao <i>grid</i> de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.	142
A.13 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Tolerância a Falhas e Comunicação em relação ao <i>grid</i> de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.	143
A.14 Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Comunicação em relação ao <i>grid</i> de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.	143
A.15 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Comunicação e Energia em relação ao <i>grid</i> de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.	144
A.16 Resultados para o cálculo do IGD para as métricas de Comunicação e Energia em relação ao <i>grid</i> de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.	144
A.17 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Energia e Balanceamento de Carga em relação ao <i>grid</i> de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.	145
A.18 Resultados para o cálculo do IGD para as métricas de Energia e Balanceamento de Carga em relação ao <i>grid</i> de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.	145
A.19 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Tolerância a Falhas e Energia em relação ao <i>grid</i> de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.	146

A.20 Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Energia em relação ao <i>grid</i> de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.	146
A.21 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Tolerância a Falhas e Comunicação em relação ao <i>grid</i> de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.	147
A.22 Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Comunicação em relação ao <i>grid</i> de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.	147
A.23 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Comunicação e Energia em relação ao <i>grid</i> de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.	148
A.24 Resultados para o cálculo do IGD para as métricas de Comunicação e Energia em relação ao <i>grid</i> de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.	148
A.25 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Energia e Balanceamento de Carga em relação ao <i>grid</i> de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.	149
A.26 Resultados para o cálculo do IGD para as métricas de Energia e Balanceamento de Carga em relação ao <i>grid</i> de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.	150
A.27 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Tolerância a Falhas e Energia em relação ao <i>grid</i> de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.	150
A.28 Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Energia em relação ao <i>grid</i> de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.	151
A.29 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Tolerância a Falhas e Comunicação em relação ao <i>grid</i> de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.	151

A.30 Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Comunicação em relação ao <i>grid</i> de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.	152
A.31 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Comunicação e Energia em relação ao <i>grid</i> de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.	152
A.32 Resultados para o cálculo do IGD para as métricas de Comunicação e Energia em relação ao <i>grid</i> de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.	153
A.33 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Energia e Balanceamento de Carga em relação ao <i>grid</i> de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.	153
A.34 Resultados para o cálculo do IGD para as métricas de Energia e Balanceamento de Carga em relação ao <i>grid</i> de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.	154
A.35 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Tolerância a Falhas e Energia em relação ao <i>grid</i> de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.	154
A.36 Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Energia em relação ao <i>grid</i> de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.	155
A.37 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Tolerância a Falhas e Comunicação em relação ao <i>grid</i> de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.	155
A.38 Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Comunicação em relação ao <i>grid</i> de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.	156
A.39 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Comunicação e Energia em relação ao <i>grid</i> de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.	156

A.40 Resultados para o cálculo do IGD para as métricas de Comunicação e Energia em relação ao <i>grid</i> de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.	157
A.41 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Energia e Balanceamento de Carga em relação ao <i>grid</i> de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.	157
A.42 Resultados para o cálculo do IGD para as métricas de Energia e Balanceamento de Carga em relação ao <i>grid</i> de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.	158
A.43 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Tolerância a Falhas e Energia em relação ao <i>grid</i> de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.	158
A.44 Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Energia em relação ao <i>grid</i> de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.	159
A.45 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Tolerância a Falhas e Comunicação em relação ao <i>grid</i> de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.	159
A.46 Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Comunicação em relação ao <i>grid</i> de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.	160
A.47 Resultados para o cálculo do <i>Hypervolume</i> para as métricas de Comunicação e Energia em relação ao <i>grid</i> de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.	160
A.48 Resultados para o cálculo do IGD para as métricas de Comunicação e Energia em relação ao <i>grid</i> de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.	161

SUMÁRIO

CAPÍTULO 1 – INTRODUÇÃO	20
1.1 Contexto	20
1.2 Motivação e Objetivo	22
1.3 Hipóteses	23
1.4 Contribuições da Tese	24
1.5 Delimitação de Escopo da Pesquisa	26
1.6 Organização	27
CAPÍTULO 2 – FUNDAMENTAÇÃO TEÓRICA DE SISTEMAS <i>MANYCORE</i>	28
2.1 Arquiteturas <i>manycore</i>	28
2.2 Motivações sobre Arquiteturas <i>Manycore</i>	29
2.3 <i>NoC</i> - (<i>Network on Chip</i>)	31
2.3.1 Fundamentos Básicos	33
2.3.2 Tipos de Redes	34
2.3.3 Protocolo	36
2.3.4 Controle de Fluxo	38
2.3.5 QoS	39
2.3.6 Link de Comunicação	40
2.4 Mapeamento de Aplicações em Sistemas Homogêneos e Heterogêneos	41
2.4.1 Mapeamento em Tempo de Desenvolvimento	42

2.4.2	Mapeamento em Tempo de Execução	42
2.4.3	Mapeamento Híbrido	44
2.5	MOEAs - <i>Multiobjective evolutionary algorithms</i>	44
2.6	Abordagens Autoadaptativas	50
CAPÍTULO 3 – TRABALHOS RELACIONADOS		53
3.1	Mapeamento de aplicações em arquiteturas <i>manycore</i>	53
3.1.1	Mapeamentos baseados em eficiência energética	54
3.1.2	Mapeamentos baseados em sistemas tolerantes a falha	56
3.1.3	Mapeamentos baseados em controle termal	58
3.2	Abordagens multiobjetivo autoadaptativas	60
3.3	Limitações dos Trabalhos Relacionados e Sumário dos trabalhos relacionados. .	62
CAPÍTULO 4 – METODOLOGIAS DE MAPEAMENTO DE TAREFAS EM ARQUITETURAS MANYCORE		64
4.1	<i>Framework</i> proposto para mapeamento de aplicações de MM em arquiteturas <i>manycore</i>	64
4.1.1	Módulo <i>Folds</i>	65
4.1.2	Módulo de Treinamento	65
4.1.3	Procedimento 1D	68
4.1.4	Módulo de Testes	71
4.1.5	Módulo de Mapeamento	71
4.2	<i>Framework</i> autoadaptativo para mapeamento de aplicações em arquiteturas <i>manycore</i>	75
4.2.1	Módulo de Entradas	75
4.2.2	Módulo de Mapeamento Mutiobjetivo.	79
4.2.3	Módulo Autoadaptativo	86
4.2.4	Módulo de Resultados	92

CAPÍTULO 5 – RESULTADOS	95
5.1 Resultados - <i>Framework</i> proposto para mapeamento de grafos de aplicações em arquiteturas <i>manycore</i>	95
5.1.1 Resultados do treinamento e teste	97
5.1.2 Resultados do Mapeamento	99
5.2 Resultados - <i>Framework</i> autoadaptativo para mapeamento de aplicações em arquiteturas <i>manycore</i>	112
5.3 Resultados numéricos sem o uso do procedimento autoadaptativo	113
5.3.1 Energia x Balanceamento de Carga	113
5.3.2 Tolerância a falhas x Energia	115
5.3.3 Tolerância a falhas x Comunicação	117
5.3.4 Comunicação x Energia	118
5.4 Resultados numéricos com o uso do procedimento autoadaptativo	120
5.4.1 Energia x Balanceamento de Carga	120
5.4.2 Tolerância a falhas x Energia	121
5.4.3 Tolerância a falhas x Comunicação	123
5.4.4 Comunicação x Energia	124
CAPÍTULO 6 – CONCLUSÃO, LIMITAÇÕES E TRABALHOS FUTUROS	126
REFERÊNCIAS	128
GLOSSÁRIO	135
CAPÍTULO A –TABELAS - RESULTADOS B	136
A.1 Sem uso do procedimento autoadaptativo	136
A.2 Com uso do procedimento autoadaptativo	149

Capítulo 1

INTRODUÇÃO

1.1 Contexto

Inicialmente, a fim de melhor contextualizar o projeto contido na presente tese, o Prof. Dr. Emerson Carlos Pedrino, líder de nosso grupo de pesquisa, submeteu à agência de fomento FAPESP (Fundação de Amparo à Pesquisa do Estado de São Paulo) um projeto de pós-doutorado intitulado "Bolsa de Pesquisa no Exterior - 2017/26421-3: Investigação do Uso de Sistemas Inteligentes para Mapeamento Eficiente de Aplicações em Arquiteturas ManyCore", a ser realizado junto ao grupo de pesquisa do Prof. Dr. Gianluca Tempesti, na Universidade de York, no Reino Unido. Parte desta tese se baseia nessa colaboração, em que se propôs a união das expertises de cada um dos grupos para construir e desenvolver um sistema para o mapeamento de aplicações em arquiteturas *manycore*.

A interação entre os grupos foi profícua e resultou em dois trabalhos, sendo um deles publicado na prestigiada revista ICAE (*Integrated Computer Aided Engineering* — JCR 6.137 2022) e o segundo trabalho encontra-se em fase final de revisão para submissão até a data de revisão deste texto, onde pude ser colaborador e trabalhar integralmente e constantemente, juntamente aos dois líderes do grupo para a proposição de novas metodologias de mapeamento em arquiteturas *manycore*, sendo esses dois trabalhos iniciais os balizadores para concepção e construção das metodologias apresentadas nesta tese.

Pôde-se perceber que nos últimos anos houve um aumento na demanda por sistemas computacionais embarcados de alto desempenho, energeticamente eficientes e resilientes, sendo assim, as arquiteturas *manycore* têm emergido como uma grande promessa para solucionar tais

demandas, todavia ocorre a necessidade do uso de estratégias que possam garantir que tais requisitos sejam alcançados. Tais abordagens têm como contrapartida o aumento da complexidade relacionada ao desenvolvimento e mapeamento de tarefas nas referidas arquiteturas.

As arquiteturas *manycores* são baseadas em *Networks-on-Chip* (NoCs). Nessas redes, os pacotes (dados) são transferidos entre os núcleos ou para a memória principal do elemento de processamento (PE) por meio de interfaces de rede, representadas por um arranjo de componentes que representam roteadores simples. Apesar disso, esses recursos aprimorados aumentam a complexidade, pois é preciso lidar com outras tarefas, tais como roteamento, protocolos de comutação, sincronização, tratamento de congestionamento e problemas relacionados ao acesso de dados na memória principal. Contudo, essas redes são propostas para resolver o problema relacionado à alta dependência de sistemas computacionais de alto desempenho pelo uso do barramento. Dessa forma, tais arquiteturas podem fornecer uma alta largura de banda, permitindo que sistemas embarcados de alto desempenho sejam escalados de forma fácil e eficiente.

O mapeamento de tarefas em arquiteturas *manycores* consiste em segmentar e/ou clusterizar tarefas eficientemente, favorecendo assim o uso inteligente dos recursos disponíveis (CENG et al., 2008), levando-se em conta restrições relacionadas ao consumo energético, tolerância a falhas, comunicação, controle térmico, entre outros. A adição de sincronismo, temporização e largura de banda também pode ser considerada durante a tarefa de mapeamento. Tais tarefas de mapeamento podem ser executadas em tempo de desenvolvimento, tempo de execução e de forma híbrida. As otimizações devem obedecer às restrições impostas pela tarefa que deve ser executada na arquitetura *manycore*. Neste cenário, ainda deve-se considerar a arquitetura de elemento de processamento utilizado, os diferentes núcleos (*cores*) e qual a estrutura de roteamento e interligação serão utilizados por uma dada aplicação.

Conforme demonstrado na Figura 1.1, pode-se notar que existem diversas formas e abordagens para a realização de tarefas de mapeamento de aplicações em arquiteturas *manycore*. O presente trabalho tem foco nas abordagens que se utilizam de estratégias evolutivas, com destaque para a utilização em problemas multiobjetivos por meio de MOEA's (Algoritmos Evolutivos Multiobjetivos). Vale ainda destacar a integração das metodologias propostas em uma plataforma de otimização chamada PlatEMO (*Evolutionary Multi-Objective Optimization Platform*) (TIAN et al., 2017), especialmente desenvolvida para a avaliação e validação de algoritmos de estado da arte em otimização. Tal otimização pode ser realizada em relação a um ou mais objetivos. A tarefa de integração e codificação de problemas multiobjetivo em tal plataforma será demonstrada ao longo de toda a presente tese.

Além das estratégias baseadas em otimizações multiobjetivos, o presente trabalho tem ainda

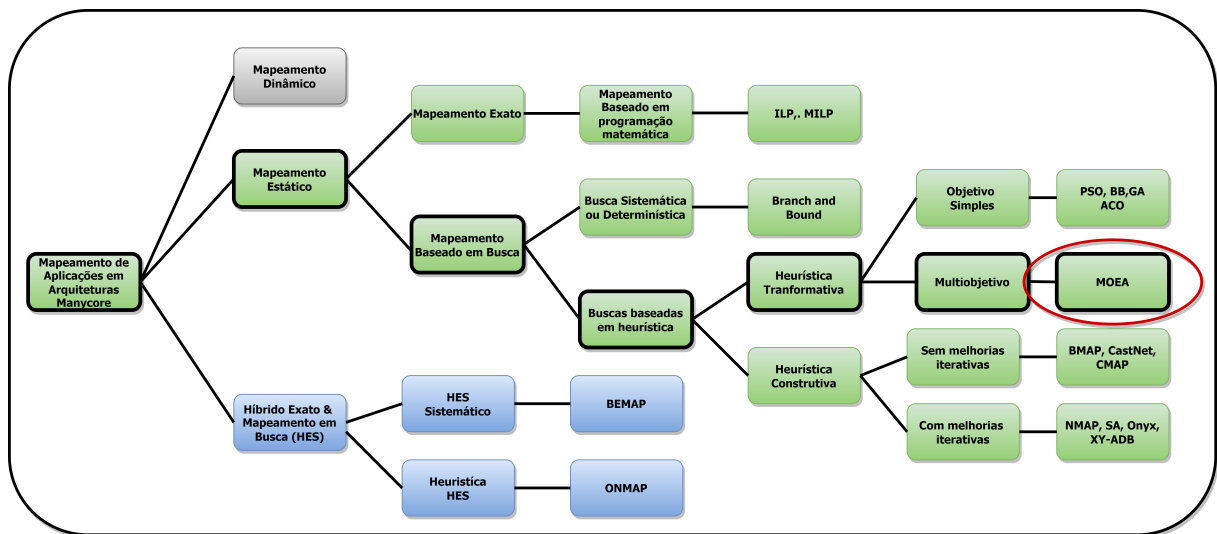


Figura 1.1: Taxonomia básica e classificação das técnicas de mapeamento de aplicações em arquiteturas *manycore*, com destaque para as técnicas baseadas em MOEAs. Adaptado de (AMIN et al., 2020).

como abordagem prevista a utilização de procedimentos de evolução autoadaptativas. Tal abordagem é descrita por diversos pesquisadores como uma solução viável para a melhoria de desempenho em algoritmos evolutivos, aumento na velocidade de convergência e de menor consumo energético, haja vista que os recursos computacionais serão utilizados reduzidamente durante a tarefa de mapeamento.

Por fim, além do problema de mapeamento já mencionado, outro em aberto, e que ainda é desafiador, é o de geração de mapas de alocação de tarefas utilizando-se várias aplicações rodando em sistemas múltiplos/muitos núcleos visando-se otimizar vários objetivos simultaneamente.

1.2 Motivação e Objetivo

Na presente tese é planejado investigar metodologias de mapeamento para arquiteturas *manycore* com elementos de processamento homogêneos que sejam energeticamente eficientes, tolerantes à falha e que obtenham desempenho aprimorado.

As aplicações que serão investigadas aqui são obtidas por meio de aplicações reais e simuladas, representadas por grafos, utilizando para tal simulação a ferramenta TGFF (DICK; RHODES; WOLF, 1998). Será descrito que cada um dos PEs da referida arquitetura é um elemento de processamento que pode realizar uma ou mais tarefas.

Todas as abordagens propostas utilizaram algoritmos multiobjetivos para a obtenção dos

mapas, avaliação das métricas utilizadas e coleta de resultados. O arranjo de ligações utilizado foi uma estrutura baseada em NoC, em formato MESH com roteamento XY, tal organização será melhor detalhada ao longo do texto.

As propriedades relacionadas à eficiência energética e desempenho estão diretamente baseadas na proximidade entre as tarefas a serem executadas e uma menor utilização dos *links* de comunicação da referida arquitetura. Em contrapartida, a propriedade relacionada à tolerância a falha se refere diretamente a capacidade da arquitetura poder migrar tarefas de processadores com falha para processadores que estejam ociosos. Portanto, durante a execução do mapeamento, devem-se prover formas para que tal migração aconteça. Ou seja, que sejam inseridos de forma inteligente e aprimorada, processadores ociosos ao longo da arquitetura. Assim, o mapeamento de tarefas se torna uma tarefa complexa e custosa computacionalmente, resultando em um problema NP (*nondeterministic polynomial time*) Completo (SINGH et al., 2017).

Por fim, o processo de mapeamento multiobjetivo resulta em uma fronteira de Pareto, onde cada um dos eixos representa um dos objetivos previamente selecionados, e cada um dos pontos representa um cromossomo que corresponde a um mapa. Tais objetivos podem estar relacionados a diversos fatores inerentes à arquitetura estudada, por exemplo, energia, resiliência, temperatura etc.

Ainda, serão investigados procedimentos autoadaptativos no mapeamento que se utilizará de abordagens multiobjetivas.

1.3 Hipóteses

A fim de buscar maneiras eficientes e inteligentes para o mapeamento de tarefas em arquiteturas *manycore*, é necessária uma análise profunda dos melhores algoritmos para essa tarefa e sua correlação com as métricas utilizadas na presente tese. Tal estudo requer:

- A proposição de *frameworks* que forneçam o arcabouço de soluções para que esses estudos possam ser realizados;
- Proposição de maneiras eficientes para a segmentação dos experimentos e a realização de testes;
- Apresentação de uma nova metodologia autoadaptativa para algoritmos multiobjetivos utilizados no mapeamento de arquiteturas *manycore*;

- Determinação e avaliação dos melhores algoritmos a serem utilizados nesse tipo de cenário.

Para realizar esse estudo, foi necessário utilizar ambientes de desenvolvimento e ferramentas que possibilitassem a realização de testes, análises e coleta de resultados de forma segura e eficiente, tentando obter respostas as mais próximas possíveis de um ambiente real e observando as relações e correspondências entre os resultados obtidos. Dessa forma, espera-se que essas análises forneçam resultados que permitam aos pesquisadores da área terem uma nova abordagem em relação à seleção e uso de MOEAs para mapeamento de tarefas em arquiteturas *manycore*.

1.4 Contribuições da Tese

Nesta tese é abordado o mapeamento de tarefas em arquiteturas *manycore* com elementos de processamento homogêneos.

Em relação aos trabalhos previamente publicados na literatura, apresenta-se um estudo detalhado de correlações entre as métricas (Energia, Tolerância a falhas, Comunicação e Balanceamento de Carga) e uso de algoritmos multiobjetivos, que nesse estudo são direcionados a executar tais tarefas.

Também, apresenta-se uma metodologia para a detecção de padrões em imagens de alta resolução, geração dos respectivos grafos de tarefas, procedimento de calibração baseado em MOEAs e, por fim, é realizado o mapeamento com base nos grafos de tarefa gerados e o algoritmo mais eficiente é encontrado durante o procedimento de calibração.

Outra abordagem distinta é a determinação de uma metodologia autoadaptativa para o mapeamento de tarefas multiobjetivo.

Portanto, as novas contribuições são:

- O desenvolvimento de um framework direcionado ao mapeamento de tarefas em arquiteturas *manycore*;
- A formalização dos objetivos e métricas utilizadas nos procedimentos de mapeamento de tarefas em arquiteturas *manycore*;
- A proposição de uma metodologia de mapeamento de tarefas de detecção de padrões em imagens de alta resolução;

- A proposição de um metodologia autoadaptativa para MOEAs utilizados em tarefas de mapeamento de tarefas em arquiteturas *manycore*;

Por fim, foram publicados diversos trabalhos durante o período de desenvolvimento da presente tese, em que destacam-se:

Trabalhos diretamente relacionados:

- CARLOS PEDRINO, EMERSON ; DE LIMA, DENIS PEREIRA ; TEMPESTI, GIANLUCA . *A multiobjective metaheuristic approach for morphological filters on many-core architectures*. INTEGRATED COMPUTER-AIDED ENGINEERING , p. 1-15, 2019.
- Bruno PADUA ; LIMA, D. P. ; FERNANDES, M. M. ; ABUASSAL, A. ; TEMPESTI, GIANLUCA ; CARLOS PEDRINO, EMERSON . *Hybrid Implementation of Evolutionary Algorithms in FPGAs for Automatic Generation of Morphological Image Filters*. PRZEGLAD ELEKTROTECHNICZNY , 2020.

Trabalhos indiretamente relacionados:

- PEDRINO, EMERSON CARLOS ; PARIS, PAULO CESAR DONIZETI ; DE LIMA, DENIS PEREIRA ; RODA, VALENTIN OBAC . *Software review: CGP-Library. Genetic Programming and Evolvable Machines* , v. 18, p. 1-4, 2017.
- LIMA, D. P. ; Rafael F V S ; PEDRINO, EMERSON CARLOS . *Neural Network Training Using Unscented and Extended Kalman Filter. Robotics & Automation Engineering Journal (RAEJ)*, v. 1, p. 1-6, 2017.
- I. F. Gallon ; LIMA, D. P. ; PEDRINO, EMERSON CARLOS . *ASCGP - Automatic System for Construction of Logical Circuits in FPGA using CGP. IEEE Latin America Transactions* , v. 16, p. 1843-1848, 2018.
- Rafael GIVANILDO ; Denis LIMA ; PARIS, PAULO CESAR DONIZETI ; PEDRINO, EMERSON CARLOS . *Low-Cost and Accuracy Smart Meter Prototype for Smart Grids*. PRZEGLAD ELEKTROTECHNICZNY, v. 97, p. 72-77, 2021.
- AKAMATU, SAULO ; DE LIMA, DENIS PEREIRA ; PEDRINO, EMERSON CARLOS . *Hybrid parallelization of the black hole algorithm for systems on chip*. INTEGRATED COMPUTER-AIDED ENGINEERING, v. 29, p. 1-15, 2022.

1.5 Delimitação de Escopo da Pesquisa

O presente trabalho apresenta um estudo e avaliação de metodologias conhecidas para mapeamento de aplicações em arquiteturas *manycore*. Para isso, são realizados experimentos, validações e testes, de modo a determinar um algoritmo que possua a melhor resposta em relação à precisão e acurácia.

Durante toda a presente pesquisa, apenas serão consideradas as métricas e restrições previamente discutidas no Capítulo 4, desconsiderando outros problemas comuns no mapeamento de tarefas em arquiteturas *manycore* e outras abordagens adicionais, tais como:

- Métodos de Roteamento;
- Métodos de Arbitração;
- Métodos relacionados ao controle de frequência;
- Métodos relacionados ao controle de tensão;
- Métodos de controle centralizado e descentralizado;
- Elementos de processamento não homogêneos;
- Mapeamento em tempo de execução ou híbrido;
- Detalhes sobre algoritmos adicionais utilizados ou que podem ser encontrados em outros trabalhos;
- Outros problemas que fazem parte do estudo de mapeamento de tarefas em arquiteturas *manycore*.

O único evento inesperado considerado neste trabalho é a relação entre as métricas relacionadas à energia, tolerância a falhas, comunicação e balanceamento de carga para o mapeamento multiobjetivo de tarefas em arquiteturas *manycore*. Demais eventos inesperados são desconsiderados e uma revisão sobre os demais tópicos pode ser encontrada em (SINGH et al., 2013, 2017; SAHU; CHATTOPADHYAY, 2013; ZHANG et al., 2018; QU et al., 2018; WU; LU; CHEN, 2016) e nos artigos relacionados no Capítulo 3.

1.6 Organização

O restante deste documento está organizado da seguinte forma:

- *Capítulo 2*: Neste capítulo, são apresentados os conceitos fundamentais e as tecnologias relevantes ao desenvolvimento deste trabalho. Serão discutidos tópicos importantes para a compreensão e aplicação dos métodos propostos.
- *Capítulo 3*: Neste capítulo, são apresentados outros trabalhos que tratam de problemas relacionados ao tema deste estudo. Serão discutidas as limitações dessas soluções e como elas diferem da proposta apresentada neste trabalho. Além disso, serão destacados os principais avanços e desafios em relação a esses trabalhos.
- *Capítulo 4*: Neste capítulo, são apresentadas as metodologias referentes à criação de *frameworks* para mapeamento de tarefas em arquiteturas *manycore*. Serão discutidos os principais conceitos e técnicas envolvidos na criação desses *frameworks*, bem como as vantagens e desvantagens de diferentes abordagens.
- *Capítulo 5*: Neste capítulo, são apresentados os resultados da avaliação das metodologias apresentadas no Capítulo 4. Serão discutidos os principais resultados obtidos.
- *Capítulo 6*: Neste capítulo, são apresentadas as conclusões relacionadas à presente tese. Serão destacados os principais resultados obtidos, bem como as principais contribuições para o avanço do conhecimento na área. Além disso, serão discutidas as limitações encontradas e possíveis trabalhos futuros que podem ser realizados com base nesta pesquisa.

Capítulo 2

FUNDAMENTAÇÃO TEÓRICA DE SISTEMAS

manycore

Neste capítulo, serão apresentados conceitos fundamentais e tecnologias relevantes para o desenvolvimento desta tese. Na Seção 2.1, serão detalhados aspectos fundamentais para o entendimento sobre as redes em chip (NoCs). Na Seção 2.2 são apresentadas algumas motivações para a utilização de metodologias *manycore*, contextualizando o ponto de vista histórico e funcional da abordagem. Na Seção 2.3 são apresentados os principais elementos que fazem parte da concepção de uma NoC, detalhando sucintamente cada um dos seus componentes. A Seção 2.4 apresentará informações iniciais sobre o mapeamento de aplicações em sistemas baseados em arquiteturas *manycore*. Na Seção 2.5, são apresentadas uma definição da forma de utilização de algoritmos evolutivos multiobjetivos e uma breve exemplificação de seu uso, tomando como base o algoritmo NSGA II. Por fim, na Seção 2.6, será apresentada uma definição do uso de estratégias autoadaptativas.

2.1 Arquiteturas *manycore*

Uma arquitetura *manycore* pode ser definida como um sistema que apresenta centenas ou milhares de núcleos de processamento físicos, com o objetivo principal de atingir um alto grau de paralelismo explícito e uma alta largura de banda. Mesmo utilizando núcleos de processamento mais simples e com menor desempenho em comparação com sistemas *multicore*, as arquiteturas *manycore* conseguem manter uma alta largura de banda. Tais arquiteturas podem conter estruturas homogêneas e heterogêneas, ou seja, os núcleos de processamento podem ser idênticos ou diferentes (PARHAMI, 2006; SHAH et al., 2021).

Nos últimos anos, as demandas de desempenho para aplicações embarcadas aumentaram

substancialmente. Além disso, apenas aumentar a frequência dos processadores de núcleo único não é suficiente para atender aos requisitos desses sistemas. Logo, é necessário pensar em meios de comunicação mais eficientes, sistemas resilientes, tolerantes a falhas, com alto desempenho e baixo consumo de energia. Tratar esses sistemas como um agrupamento de vários processadores que podem executar diferentes tipos de tarefas em paralelo é uma solução mais eficiente e escalável para atender às novas demandas (SINGH et al., 2013).

De maneira conceitual, é possível classificar sistemas *manycore* e *multicore* utilizando como balizadoras as seguintes métricas: número, complexidade e nível de independência dos elementos de processamento. Sistemas *multicore* avançados geralmente possuem de 2 a 64 elementos de processamento, enquanto sistemas *manycore* podem possuir centenas ou milhares de elementos de processamento. A complexidade dos elementos de processamento dos sistemas *manycore* é menor em relação aos elementos de processamento contidos nos sistemas *multicore*, portanto, a complexidade é sacrificada em detrimento da existência de um grande número de elementos de processamento. Sistemas *manycore* permitem o aumento de processamento, dividindo um problema em centenas/milhares de elementos de processamento simples. Entretanto, eles apresentam um grande desafio no desenvolvimento de soluções escaláveis em hardware e software, pois tais soluções devem ser mapeadas de maneira a obter o melhor desempenho, menor consumo energético e maior resiliência (BONNEY et al., 2016).

2.2 **Motivações sobre Arquiteturas *Manycore***

Nesta seção, serão apresentadas algumas considerações acerca da motivação de uso de arquiteturas *manycore* em pesquisas relacionadas a sistemas distribuídos. Em relação a arquiteturas *single core*, pode-se enumerar as seguintes limitações (MANFERDELLI; GOVINDARAJU; CRALL, 2008; PATTERSON, 2010):

- *The Power Wall* – a limitação relativa ao aumento da frequência de trabalho dos processadores;
- *The Memory Wall* – refere-se à necessidade do uso de *caches* cada vez maiores, pois os tempos de acesso de memória ainda estão muito aquém de se equiparar as velocidades praticadas no processador, tornando custoso computacionalmente os acessos à memória, sendo ainda necessário agregar um número maior de recursos (coerência, controle, gerenciamento, predição, entre outros) para compatibilização de velocidades e acesso;
- *The ILP (Instruction Level Parallelism) Wall* – as arquiteturas paralelas, comparadas com

as arquiteturas escalares, são logicamente mais complexas, exigem a utilização de uma grande quantidade de transistores, conseqüentemente, dissipam mais calor e são mais difíceis de programar para obter o seu aproveitamento de forma eficiente.

Devido às limitações expostas acima, diversos pesquisadores buscaram uma solução efetiva que pudesse ser viabilizada em escala industrial. A solução encontrada foi a utilização de sistemas com mais de um elemento de processamento, denominados sistemas *Multicore*. Porém, os elementos de processamento necessitam de um barramento para se comunicarem (BUS), surgindo assim um novo problema: a união dos três problemas que ocorriam nos sistemas com único elemento de processamento. Esse problema é denominado: *Power Wall + Memory Wall + ILP Wall = Brick Wall for Serial Computing*, ou seja, o problema anterior relacionado a um único elemento de processamento foi escalado conforme o número de elementos contidos no sistema com vários elementos de processamento.

Portanto, podem-se enumerar alguns problemas que surgiram com o advento de novos sistemas que contêm um número maior de elementos de processamento:

- O *desempenho* de todo o sistema computacional tem dependência do código serial a ser executado; ou seja, quanto maior a necessidade de processar código serialmente, menores são as chances de acelerar o processamento usando paralelismo, por exemplo;
- Dificuldade na otimização do software. Nota-se que existe uma "facilidade" em adicionar novos elementos de processamento, mas há uma grande complexidade do *software* em obter vantagem de todos os elementos de processamento de forma eficiente e equânime;
- Manter a simultaneidade em diversos elementos de processamento;
- Todos os elementos de processamento precisam acessar o mesmo barramento de comunicação. Portanto, todo acesso ao barramento é demasiadamente custoso, haja vista a incompatibilidade de velocidade entre os elementos de processamento, barramento de suporte à comunicação e às memórias;
- A coerência de cache é um problema que limita o dimensionamento de processadores *multicore*, além de adicionar circuitos que podem limitar a velocidade do processamento e gerar aquecimento adicional ao chip;
- Um dos grandes problemas que podem ser encontrados é a dificuldade no gerenciamento de uma quantidade abundante de dispositivos.

Ainda no intento de buscar uma alternativa viável e eficiente para tratar dos problemas relacionados a sistemas *multicore*, surgiram os sistemas *manycore*. Tais sistemas podem ter mais em comum, conceitualmente, com tecnologias originadas para a computação de alto desempenho, tais como *clusters* e processadores vetoriais.

As GPUs (*Graphics Processing Units*) podem ser consideradas uma forma de processador de vários núcleos com várias unidades de processamento, adequadas apenas para código altamente paralelo (alta taxa de transferência, mas com desempenho de *thread* único extremamente ruim) (BRODTKORB et al., 2013).

Por fim, deve-se pontuar que ao longo dos anos, desde a inovação tecnológica proporcionada pelos computadores, existe uma intensa busca por sistemas eficientes, resilientes e com baixo consumo, que supram as lacunas e limitações trazidas pelos sistemas anteriormente utilizados, sejam eles com um único elemento de processamento ou vários. Tal busca resultou em sistemas com muitos/milhares de elementos de processamento que não dependem somente de um barramento de comunicações (BUS), favorecendo a criação de soluções flexíveis e altamente eficientes.

2.3 NoC - (Network on Chip)

As redes em chip (NoCs) são geralmente preferíveis em relação aos *BUS* de comunicação, devido à maior largura de banda e ao suporte nativo à várias comunicações simultâneas. Ao recorrer a uma rede para substituir a fiação global, há vantagens em termos de estrutura, desempenho e modularidade. A rede no chip estrutura os fios globais para que suas propriedades elétricas sejam otimizadas e bem controladas. Tais parâmetros elétricos devem ser controlados de maneira adequada, especialmente a diafonia baixa e previsível. O compartilhamento de recursos de fiação entre muitos fluxos de comunicação proporciona um uso mais eficiente dos fios, ou seja, quando um cliente está ocioso, outros clientes continuam a usar os recursos de rede (DALLY; TOWLES, 2001).

Com a necessidade de maior poder de processamento em relação à grande quantidade de dados obtidos, o desafio em relação à comunicação interna e externa desses dispositivos tem crescido nos últimos anos, tornando-se objeto de intensa pesquisa no campo denominado Redes em Chips (*NoC*) (BJERREGAARD; MAHADEVAN, 2006), (TSAI et al., 2012), (ALEXOUDI et al., 2019), (PANDE et al., 2005).

Nesta seção, serão discutidos os aspectos fundamentais sobre *NoCs*, fornecendo ao leitor informações importantes para o entendimento de conceitos que serão utilizados ao longo desta

proposta.

Toda a área de pesquisa está baseada em problemas que podem ocorrer durante o desenvolvimento e/ou operação de tais sistemas, podendo ser categorizada conforme a taxonomia apresentada por Bjerregaard e Mahadevan (2006):

- **Sistema**

- Metodologias de Desenvolvimento e Abstração: co-exploração e modelamento;
- Arquitetura: composição do sistema, clusterização e estrutura reconfigurável;
- Tráfego: latência crítica, fluxo de dados e *best-effort*.

- **Adaptadores de Rede**

- Funcionalidades: encapsulamento e gerenciamento de serviços;
- *Sockets: plug and play* e reuso de *Intellectual Property* (IP).

- **Rede**

- Topologia: topologias regulares x topologias irregulares e estrutura de chaveamento;
- Protocolo: roteamento, chaveamento e esquemas de controle;
- Controle de Fluxo: evitar *deadlocks*, canais virtuais e bufferização;
- QoS: classificação do serviço e da negociação;
- Características: correção de erro, *broadcast/multicast/narrowcast* e *wireless*;

- **Link**

- Sincronização, confiabilidade, codificação.

As metodologias de desenvolvimento e abstração, arquitetura e tráfego do sistema estão relacionadas à forma como o sistema é projetado e como ele se comporta em termos de comunicação de dados. Os adaptadores de rede referem-se às funcionalidades que envolvem o encapsulamento e o gerenciamento de serviços, bem como ao reuso de *Intellectual Property* (IP) em diferentes contextos. A rede em si envolve topologia, protocolo, controle de fluxo, qualidade de serviço (QoS) e características de transmissão, como correção de erro, *broadcast/multicast/narrowcast* e tecnologia *wireless*. Por fim, os aspectos relacionados ao *link* incluem sincronização, confiabilidade e codificação.

Em resumo, as redes em chip (NoCs) são uma solução preferível em relação aos *BUS* de comunicação, proporcionando maior largura de banda e suporte a várias comunicações simultâneas. A área de pesquisa de NoCs aborda problemas relacionados ao desenvolvimento e

operação de sistemas, categorizados em metodologias de desenvolvimento e abstração, arquitetura, tráfego do sistema, adaptadores de rede, rede e aspectos do *link*. O entendimento desses conceitos é fundamental para a proposição de soluções eficientes de comunicação de dados em sistemas de alto desempenho.

2.3.1 Fundamentos Básicos

A Figura 2.1 mostra uma estrutura 2D com distribuição de 4x4 elementos de processamento no *grid* cartesiano, totalizando 16 módulos (processador, roteador e interface de rede), em que essa estrutura possui comunicação global entre todos os componentes associados.

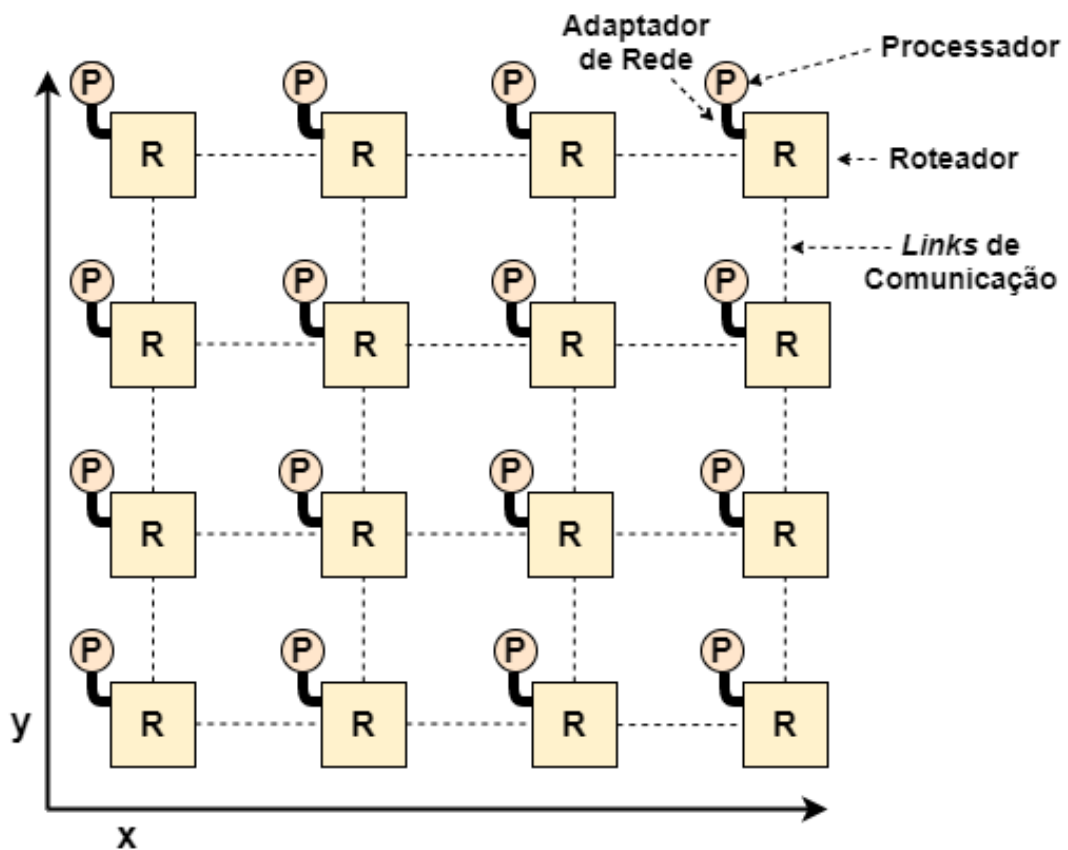


Figura 2.1: Elementos fundamentais de uma arquitetura NoC, baseados em uma estrutura de 4x4 elementos (SALMINEN; KULMALA; HAMALAINEN, 2008).

Os componentes básicos de uma rede em chip (NoC) são:

- Adaptadores de Rede - Os adaptadores de rede gerenciam e implementam uma interface de comunicação com o *core* adjacente, e sua função principal é o desacoplamento/dissociação entre a computação realizada pelos *cores* e a comunicação realizada pela rede (NoC).

- Roteadores - Os roteadores gerenciam rotas e implementam estratégias de roteamento de acordo com o protocolo armazenado, podendo utilizar estratégias pré-determinadas ou adaptativas, como demonstrado na Figura 2.2, que apresenta a estrutura básica de um roteador para arquiteturas *manycore*.
- *Links* de Comunicação - Os *links* de comunicação são compostos por um ou mais canais, lógicos e/ou físicos (como fios, tecnologia *wireless* e ótica), fornecendo ao sistema largura de banda para executar determinada tarefa.

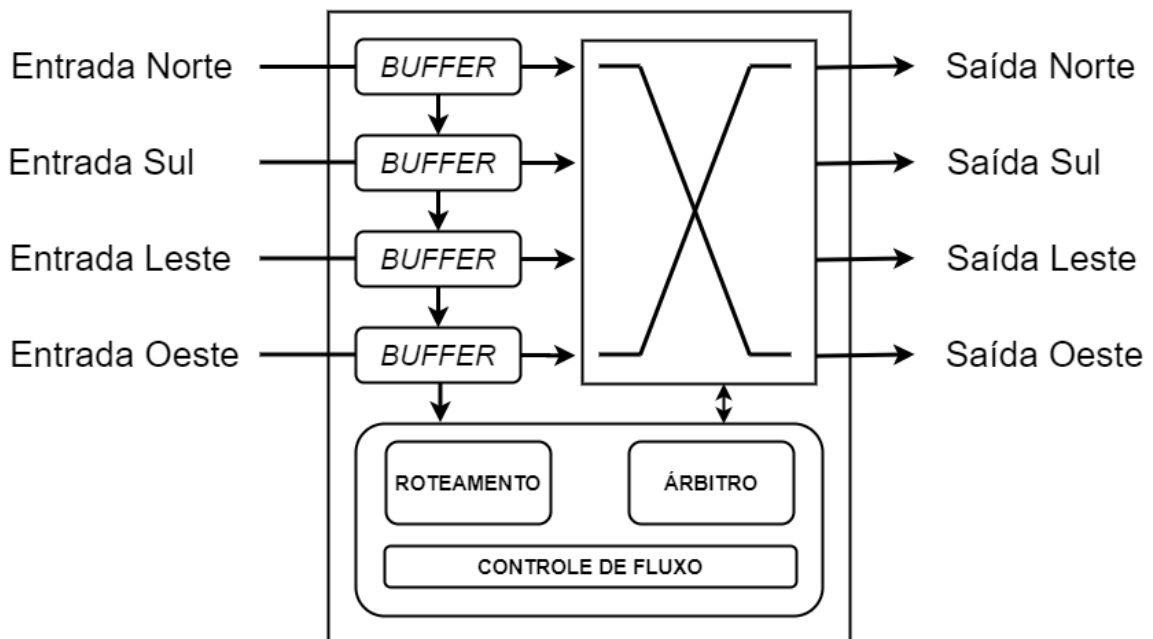


Figura 2.2: Estrutura básica de um roteador para arquiteturas *manycore*. Adaptado de (RETTKOWSKI; GÖHRINGER, 2018).

Dessa forma, é possível descrever as principais características dos componentes básicos de uma rede em chip (NoC) e como eles se relacionam entre si para possibilitar a comunicação e o desempenho em sistemas de alto desempenho.

2.3.2 Tipos de Redes

Segundo Bjerregaard e Mahadevan (2006), as redes em chip (NoC) são consideradas um novo conceito unificador em relação à comunicação de arquiteturas *manycore*. As especificidades atribuídas ao NoC são o que o tornam capaz de dar o suporte necessário para a operação de tais sistemas. Para grande parte dos pesquisadores da área, existem duas percepções aceitáveis para a descrição do NoC, que podem ser classificadas da seguinte forma:

- O NoC sendo classificado como um subconjunto ou subgrupo dos *System-on-a-Chip* (SoC);
- O NoC sendo classificado como uma extensão dos SoCs.

A primeira classificação é baseada no NoC estritamente como um método para distribuição de dados, em que toda sua sistemática de funcionamento está fundamentada no uso da rede para prover tal comunicação. Já a segunda classificação define o NoC de modo mais amplo e sistemático, abrangendo as questões relacionadas à arquitetura do sistema, à aplicação utilizada e ao modo que essas interações podem interferir e impactar na comunicação.

Basicamente, o trabalho das redes é transportar mensagens/pacotes de uma origem para um destino estabelecido. Sendo parte importante para tal tarefa o meio que será utilizado para propagar os dados na rede. Os meios de transmissão física podem variar desde fios até sistemas óticos de alta velocidade (AGARWAL; ISKANDER; SHANKAR, 2009), (BJERREGAARD; MAHADEVAN, 2006).

Assim sendo, alguns exemplos de arranjos utilizados em arquiteturas SoC são apresentados na Figura 2.3, destacando as topologias dessas redes, que têm grande influência no modo como serão transmitidos os pacotes e em estratégias utilizadas para otimizar o fluxo de dados (CULLER; SINGH; GUPTA, 1999).

Na Figura 2.4 e na Figura 2.5 são apresentadas algumas das possíveis topologias de comunicação encontradas na literatura em relação às redes em chip (NoCs).

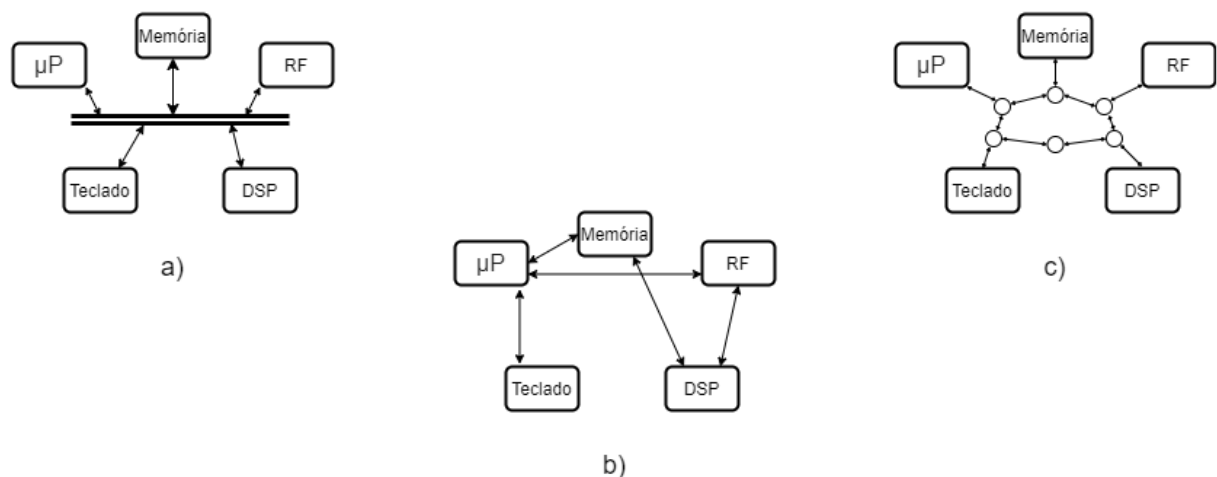



Figura 2.3: Exemplos de estruturas de comunicação em arquiteturas SoC. a) Comunicação tradicional baseada em bus; b) Comunicação dedicada ponto a ponto; c) Comunicação baseada em rede. Adaptado de (BJERREGAARD; MAHADEVAN, 2006).

As topologias dessas redes têm grande influência no modo como serão transmitidos os pacotes e em estratégias utilizadas para otimizar o fluxo de dados (CULLER; SINGH; GUPTA,

1999). A topologia visa demonstrar a disposição espacial dos *cores* em relação aos roteadores e *links*. Na Figura 2.4 e na Figura 2.5 são apresentadas algumas das possíveis topologias de comunicação encontradas na literatura em relação a *NoCs*.

Topologias com conexões regulares



Topologias com conexões irregulares

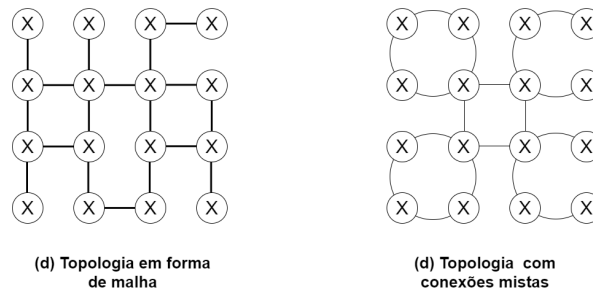


Figura 2.4: Formas regulares de topologia: (a) - Topologia em malha 4x4 com aridade 2; (b) - Topologia Toroidal 4 x 4 com aridade 2; (c) - Topologia de Árvore binária com aridade 2. Formas Irregulares: (d) - Topologia Em Malha com conexões irregulares; (e) - Topologia Mista com conexões irregulares. Adaptado de (BJERREGAARD; MAHADEVAN, 2006).

As características de tais topologias podem ser melhor interpretadas em (Dally e Towles (2004), Pande et al. (2005)). Outras classificações em relação às topologias podem ser encontradas em (Jantsch (2003), Aggarwal e Franklin (2001)), e em relação aos meios de transmissão podem ser encontrados em (Karkar et al. (2016), Wang e Jin (2014) e Werner, Navaridas e Luján (2017)).

2.3.3 Protocolo

O protocolo visa principalmente determinar de que modo os dados serão transmitidos através do *NoC*, e em vista disso, são definidas estratégias para chaveamento do caminho de dados, podendo as tarefas serem realizadas de forma estática, dinâmica e/ou adaptativa, utilizando para tal, inteligência computacional e/ou algoritmos determinísticos, de modo a determinar uma possível trajetória ótima para o caminho de dados a ser percorrido. Nas aproximações modernas,




Figura 2.5: (a) - *Scalabre, Programmable, Integrated Network (SPIN)*; (b) - *Chip-Level Integration of Communicating Heterogeneous Elements (CLICHÉ)*; (c) - *Toroidal*; (d) - *Toroidal Dobrada*; (e) - *Octagonal; Butterfly Fat-Tree (BFT)*. Adaptado de (PANDE et al., 2005).

tem-se procurado tratar concorrentemente e/ou cooperativamente a integração de diversos recursos, dentre eles, destacam-se: energia, comunicação, temperatura, tolerância a falhas etc.

Segundo Bjerregaard e Mahadevan (2006), pode-se discutir os aspectos relacionados aos protocolos da seguinte forma:

- Comutação de circuitos x Comutação de pacotes;

Na comutação de circuitos, cada unidade de dados conhece todo o endereço do caminho que é fornecido pela fonte.

Na comutação de pacotes, cada unidade de dados apenas conhece o caminho intermediário e o endereço de destino é decidido pelos roteadores.

- Serviço orientado à conexão x Serviço não orientado à conexão;

No serviço orientado à conexão, estabelece-se uma conexão antes de iniciar a comunicação entre o remetente e o destinatário. Quando a conexão é estabelecida, a mensagem é enviada e depois a conexão é liberada.

No serviço não orientado à conexão, não há configuração inicial da conexão entre o remetente e o destinatário para a transferência de dados. Isso significa que não se pode garantir a entrega e o (QoS - *Quality of Service*) dos pacotes trafegando através do NoC.

- Roteamento determinístico x Roteamento adaptativo;

No roteamento determinístico, é gerada uma única rota para um determinado par de endereços de origem e destino, não levando em consideração qualquer informação sobre o tráfego da rede.

No roteamento adaptativo, são utilizadas informações sobre o tráfego de rede e/ou status do canal para evitar congestionamentos, provendo novas rotas entre a origem e destino, mitigando possíveis quedas de desempenho.

- Roteamento mínimo x Roteamento não mínimo;
- Modelo baseado em atraso e Modelo baseado em perda;
- Controle central x Controle distribuído.

2.3.4 Controle de Fluxo

O Controle de Fluxo é uma técnica que determina como os recursos de uma rede, como a largura de banda do canal e a capacidade do *buffer*, devem ser alocados para os pacotes que atravessam a rede. O objetivo é utilizar os recursos da forma mais eficiente possível para permitir um alto rendimento da rede, evitando colisões e perda de pacotes. As estratégias mais comuns de controle de fluxo baseadas em arquiteturas *manycore* são: *store-and-forward*, *wormhole* e *virtual cut-through* (PANDE et al., 2005; BJERREGAARD; MAHADEVAN, 2006; WU; LU; CHEN, 2016).

O *Packet-Buffer Flow Control* é uma abordagem que visa determinar como os recursos da rede, como a largura de banda do canal e a capacidade do *buffer*, devem ser alocados para os pacotes que atravessam um NoC, de modo a prover a gestão eficiente dos recursos e alto desempenho, minimizando colisões e perda de pacotes.

O protocolo *Store-and-forward* é um método de comutação de pacotes em que o nó armazena o pacote completo e o encaminha com base nas informações dentro do seu cabeçalho. Assim, o pacote pode ser parado se o roteador de encaminhamento existente no percurso não tiver espaço suficiente em seu *buffer*.

O roteamento *Wormhole routing* é um caso especial de *cut-through*. Em vez de armazenar um pacote completamente em um nó e, em seguida, transmiti-lo para o próximo nó, o roteamento *Wormhole routing* opera distribuindo o *header* de um pacote diretamente dos canais de entrada e saída do módulo de roteamento. Um pacote é dividido em um número de *flits* (dígitos de controle de fluxo) para transmissão. O tamanho de um *flit* depende dos parâmetros do

sistema, em particular da largura do canal. O cabeçalho do *flit* (ou *flits*) governa o percurso. Assim que um nó examina o fluxo do cabeçalho de uma mensagem, ele seleciona o próximo canal na rota e começa a distribuir *flits* por esse canal. À medida que o *header* percorre a rota especificada, os *flits* restantes seguem em forma de *pipeline* (SEYDIM, 1998).

O *Virtual cut-through* é uma técnica que tem semelhanças com o comutador de mensagens. A diferença é que, quando uma mensagem chega em um nó intermediário e seu canal de saída selecionado fica livre (logo após a recepção do cabeçalho), a mensagem é enviada para o nó adjacente em direção ao seu destino antes de ser recebida completamente no nó. Somente se a mensagem estiver bloqueada, devido a um canal de saída ocupado, tal mensagem é *bufferizada* em um nó intermediário. Portanto, o atraso devido à utilização de um *buffer* de forma desnecessária em um canal inativo é evitado (KERMANI; KLEINROCK, 1979).

A escolha da técnica de controle de fluxo a ser utilizada em uma arquitetura *manycore* depende das características específicas da rede e dos requisitos de desempenho do sistema. Cada técnica tem suas vantagens e desvantagens e, portanto, deve ser cuidadosamente avaliada em relação aos objetivos do projeto. A literatura apresenta uma variedade de estudos que comparam as diferentes técnicas de controle de fluxo em relação ao desempenho de rede, consumo de energia, latência, escalabilidade, entre outros fatores relevantes.

Em resumo, o controle de fluxo é um aspecto importante a ser considerado em arquiteturas *manycore* para garantir um alto desempenho da rede e evitar a perda de pacotes. A escolha da técnica de controle de fluxo adequada deve ser baseada nas características da rede e nos requisitos de desempenho do sistema. A literatura apresenta uma variedade de estudos que comparam as diferentes técnicas de controle de fluxo, fornecendo informações valiosas para a escolha da técnica adequada para um determinado projeto.

2.3.5 QoS

A Qualidade de Serviço (*QoS*) pode ser definida como a qualidade dos serviços oferecidos pela rede de comunicação, ou seja, um conjunto de mecanismos que visam principalmente oferecer suporte às aplicações críticas. Alguns dos mecanismos básicos que podem ser considerados incluem grande largura de banda, baixo consumo de energia, redução do *jitter*, baixa latência, controle de perda de pacotes, entre outros. Esses serviços devem ser balanceados e trabalhar de forma integrada na rede, a fim de prover o suporte necessário para o desempenho requerido de uma determinada aplicação.

A QoS é essencial para a entrega confiável e eficiente de dados em redes, particularmente

em redes de alta velocidade, onde a carga de tráfego pode ser muito alta. Com o aumento da demanda por aplicações críticas, como aplicações em tempo real, a QoS tornou-se um elemento importante em redes de computadores. A QoS oferece a possibilidade de garantir o desempenho de uma aplicação ou serviço específico, que pode ser mais importante do que outros serviços oferecidos pela rede.

Alguns dos principais fatores que influenciam a QoS incluem largura de banda, latência, jitter, perda de pacotes e segurança. A largura de banda refere-se à quantidade de dados que podem ser transmitidos em uma unidade de tempo. A latência refere-se ao tempo de atraso que ocorre durante a transmissão de dados. O *jitter* é a variação do atraso da transmissão de dados e pode afetar a qualidade do áudio e do vídeo em tempo real. A perda de pacotes ocorre quando os pacotes de dados são descartados durante a transmissão. A segurança refere-se à proteção dos dados transmitidos contra acesso não autorizado.

Sendo assim, a QoS é um conjunto de mecanismos que visam oferecer suporte a aplicações críticas, garantindo que elas recebam o desempenho necessário da rede. A largura de banda, latência, *jitter*, perda de pacotes e segurança são alguns dos fatores que afetam a QoS. A QoS é uma área ativa de pesquisa e desenvolvimento, e várias técnicas e algoritmos têm sido propostos para melhorar a qualidade de serviços oferecidos por redes de computadores.

2.3.6 Link de Comunicação

Os links de comunicação se referem basicamente aos enlaces de interligação entre os roteadores de comunicação em uma arquitetura de rede em chip (*NoC*). Eles podem ter um ou mais canais (virtuais e/ou físicos) e são classificados em relação a vários aspectos, incluindo sincronização, implementação, codificação, confiabilidade, consumo de energia e meio físico de transmissão.

A sincronização se refere à forma como os dados são transmitidos no link de comunicação. Os dados podem ser transmitidos de forma síncrona ou assíncrona, dependendo das características da rede e dos requisitos de desempenho. Na transmissão síncrona, o relógio do transmissor e do receptor estão sincronizados, enquanto na transmissão assíncrona, não há um relógio compartilhado.

A implementação do link de comunicação refere-se à forma como ele é construído e projetado. O link pode ser implementado de várias maneiras, incluindo comutação de circuitos e comutação de pacotes. A comutação de circuitos envolve a reserva antecipada de um caminho exclusivo para a transmissão dos dados, enquanto a comutação de pacotes envolve a divisão dos

dados em pacotes e a transmissão de cada pacote individualmente.

A codificação se refere ao método usado para codificar os dados para transmissão. Vários métodos de codificação podem ser usados, incluindo codificação binária e codificação de canal. A codificação binária é usada para transmitir dados digitais, enquanto a codificação de canal é usada para transmitir dados analógicos.

A confiabilidade se refere à capacidade do link de comunicação em entregar dados sem erros. Vários mecanismos podem ser usados para garantir a confiabilidade do link, como códigos de detecção e correção de erros e técnicas de retransmissão.

O consumo de energia é um aspecto importante do link de comunicação, especialmente em sistemas embarcados com recursos limitados. Vários métodos podem ser usados para reduzir o consumo de energia do link, incluindo a redução da taxa de transmissão de dados e o uso de técnicas de gerenciamento de energia.

O meio físico de transmissão refere-se ao tipo de meio usado para transmitir os dados pelo link de comunicação. Vários tipos de meio podem ser usados, como fios de cobre, fibras ópticas e transmissão sem fio.

Por fim, os links de comunicação em uma arquitetura de rede em chip são os enlaces de interligação entre os roteadores de comunicação e podem ter um ou mais canais. Eles são classificados em relação a vários aspectos, incluindo sincronização, implementação, codificação, confiabilidade, consumo de energia e meio físico de transmissão.

2.4 Mapeamento de Aplicações em Sistemas Homogêneos e Heterogêneos

Uma grande parte das metodologias utilizadas para o mapeamento de aplicações em sistemas homogêneos ou heterogêneos é baseada na carga de trabalho a ser processada. Essa carga de trabalho pode ser analisada e distribuída de forma estática, dinâmica ou híbrida, a fim de atingir diversos objetivos, tais como consumo de energia, tolerância a falhas e comunicação. Para otimizar o processo, algoritmos *Multi-Objective Evolutionary Algorithm* (MOEA) podem ser utilizados (WEICHS LGARTNER et al., 2018a).

As discussões, acerca das metodologias de mapeamento em arquiteturas *manycore* foram baseadas no trabalho publicado por Singh et al. (SINGH et al., 2013).

2.4.1 Mapeamento em Tempo de Desenvolvimento

O mapeamento em tempo de desenvolvimento requer uma visão global da aplicação que se deseja otimizar. A maioria das metodologias adotadas para o mapeamento de aplicações em arquiteturas *manycore* é realizada com o objetivo de obter mapas com alta precisão para tarefas específicas. Porém, a variação na carga de trabalho, ou seja, aplicações dinâmicas, não é contemplada por essa abordagem. Além disso, o tempo para obter os mapas é geralmente longo. Portanto, essa abordagem utiliza algoritmos de otimização bem estabelecidos na literatura, como Busca Tabu, Algoritmos Genéticos, Programação Linear, entre outros.

Durante o mapeamento em tempo de desenvolvimento, são impostas restrições para obter mapas ótimos para tarefas e abordagens específicas, dentre as quais destacam-se:

- Desempenho: o desempenho é otimizado de modo a obter mapas que apresentem características de sincronia ou minimizem o tempo de execução das operações. O cálculo do desempenho refere-se a diversos parâmetros da arquitetura *manycore*, incluindo o tempo total de execução, a latência, o atraso, o período e a taxa de transferência;
- Consumo de energia: com o advento de sistemas embarcados que necessitam de alto desempenho de processamento, mas com consumo limitado de energia, de modo a oferecer um longo tempo de uso, a maioria desses sistemas utiliza baterias para sua operação. Nesse contexto, a otimização visa obter um aumento no tempo operacional do sistema;
- Confiabilidade: a metodologia de mapeamento em tempo de desenvolvimento tem como objetivo aumentar significativamente a vida útil da aplicação/sistema em uso. Para alcançar essa finalidade, são propostas abordagens que se utilizam de alocação eficiente de recursos, controle térmico da arquitetura, tolerância a falhas/redundância de recursos, entre outros.

Ao utilizar *MOEAs*, pode-se obter a interação entre os parâmetros e as abordagens mencionados anteriormente, tornando essa interação uma ferramenta poderosa para a obtenção de mapas multiobjetivos gerados em tempo de execução para arquiteturas *manycore*.

2.4.2 Mapeamento em Tempo de Execução

O mapeamento em tempo de execução envolve a observação geral do sistema em tempo de execução, com o objetivo de obter uma visão pontual da carga de trabalho dinâmica e criar estratégias adaptativas para gerenciar essas mudanças. No entanto, essa abordagem não pode

garantir a execução previsível de aplicativos dentro de um grande espaço de busca, ao contrário do mapeamento em tempo de desenvolvimento. Além disso, o mapeamento em tempo de execução tem pouco tempo disponível para execução do mapeamento, devido às cargas dinâmicas de trabalho envolvidas no processo.

Vantagens:

- Capacidade de adaptação a diversos cenários e cargas de trabalho em tempo de execução;
- Capacidade de atualização constante, permitindo a atualização do sistema para novos aplicativos ou a alteração de padrões que não eram conhecidos no momento do desenvolvimento, mesmo após a entrega do sistema ao usuário final;
- Tolerância a falhas, já que, se um ou mais núcleos de processamento não estiverem funcionando corretamente após a produção de um *SoC*, os núcleos defeituosos podem ser desativados antes do processo de mapeamento. O tempo de uso do sistema pode levar a núcleos defeituosos, tais defeitos não são previsíveis no momento do desenvolvimento do sistema.

Desvantagens:

- Espaço de busca reduzido para o mapeamento, devido ao tempo de resposta necessário para lidar com cargas de trabalho dinâmicas.

No mapeamento em tempo de execução, existe uma metodologia associada conhecida como mapeamento *on-the-fly*. Para aplicar esse método, são necessárias heurísticas eficientes e rápidas para lidar com a chegada de novas tarefas de aplicações nos recursos da plataforma. No entanto, essas heurísticas não conseguem garantir o correto escalonamento das tarefas devido ao tempo limitado de reação e ao poder de computação necessário para obter mapas otimizados. Essas heurísticas são independentes de plataforma, pois não usam nenhuma informação ou resultado de análises previamente calculados.

Além do mapeamento *on-the-fly*, existe outra metodologia associada ao mapeamento em tempo de execução, denominada mapeamento *Design Space Exploration* (DSE). O objetivo do DSE é utilizar análises previamente realizadas em relação à plataforma e utilizar essas informações para realizar mapeamentos otimizados em tempo reduzido, devido à carga dinâmica que ocorre na plataforma em estudo. Nesse caso, são utilizadas heurísticas computacionalmente simples, de modo a otimizar os recursos computacionais disponíveis, aplicando essas heurísticas sobre o mapeamento e análises previamente realizadas em tempo de desenvolvimento e armazenadas na plataforma.

2.4.3 Mapeamento Híbrido

A metodologia de mapeamento híbrido visa combinar as características e pontos positivos do mapeamento em tempo de desenvolvimento e em tempo de execução, de modo a otimizar o mapeamento para diferentes cenários de carga de trabalho ou modos de execução durante o desenvolvimento e aplicá-lo em tempo de execução posteriormente.

No entanto, considerando todas as possíveis combinações de aplicativos em diferentes cenários, haveria um aumento exponencial no número de mapeamentos que precisariam ser armazenados. Alguns autores propõem a abordagem de manter apenas os mapeamentos mais representativos em relação a um determinado problema, favorecendo o armazenamento e o uso posterior em tempo de execução.

As estratégias baseadas em mapeamento *on-the-fly* oferecem certas limitações na obtenção de mapas ótimos devido ao poder computacional requerido, tempo reduzido e cargas dinâmicas de trabalho recorrentes na plataforma. Uma das possíveis maneiras de superar essas dificuldades é a utilização de técnicas de *DSE* em tempo de desenvolvimento, combinadas com o gerenciamento em tempo de execução, a fim de selecionar as configurações de mapeamento mais adequadas aos aplicativos e cargas de trabalho dinâmicas. Foi utilizado o menor poder computacional possível para o cálculo do mapeamento em tempo de execução, facilitando o desempenho na alocação de novas tarefas na plataforma.

2.5 MOEAs - *Multiobjective evolutionary algorithms*

Diversos problemas práticos do nosso mundo cotidiano, como os campos da matemática, engenharia, política, economia, agricultura e aviação, possuem a necessidade intrínseca de otimizar vários objetivos simultaneamente. Muitas vezes, esses objetivos podem ser conflitantes (DEB, 2011). Por exemplo, uma grande indústria pode precisar maximizar a quantidade produzida de um determinado produto, mas também deve minimizar a quantidade de emissões de gases na atmosfera durante o processo. Antigamente, os pesquisadores supriam essa necessidade combinando diversos objetivos em uma única equação correspondente, tentando dar graus de precedência e importância para cada um dos possíveis objetivos a serem utilizados. No entanto, esse procedimento não conseguia dar sentido de completude a todo o problema a ser resolvido, além de não contemplar características específicas de cada um dos problemas e dos respectivos objetivos a serem otimizados. Dessa forma, diversos pesquisadores concentraram seus esforços em criar abordagens que pudessem lidar com esse problema, resultando no surgimento das estratégias de otimização multiobjetivo (TAMAKI; KITA; KOBAYASHI, 1996).

De acordo com Gunantara (2018), os algoritmos multiobjetivos são baseados em estratégias de otimização estocástica na maioria das vezes. Como outras metodologias já propostas na literatura, a maioria dos MOEAs pode ser utilizada para encontrar soluções baseadas em fronteiras de Pareto, onde cada indivíduo da população é representado em um plano e/ou superfície definida pelos limites impostos pelo problema estudado. Essas abordagens diferem de outras que se utilizam de soluções baseadas em populações somente, pois a maioria dos algoritmos baseados em MOEAs utiliza o conceito de dominância de um indivíduo em relação aos demais contidos na população. Em resumo, os algoritmos multiobjetivos possuem mecanismos muito semelhantes às abordagens que utilizam estratégias evolutivas descritas em toda a literatura, exceto pelo uso de relações de dominância. Assim, pode-se determinar o procedimento, de forma sucinta, da seguinte maneira:

- A função objetivo é calculada com premissas previamente definidas pelo problema a ser otimizado, onde em cada iteração o custo/fitness é utilizado para determinar a dominância de cada um dos indivíduos em relação a toda população, tentando assim determinar uma potencial melhor solução para a determinação de uma população que possa ser evoluída.
- Em seguida, a população obtida durante o processo anterior é combinada/mutada para obter uma nova população a ser avaliada, tal população contém indivíduos da população anterior e novos indivíduos obtidos durante esse processo.

Como descrito por Deb (2011), assim como em um problema de otimização de objetivo único, o problema de otimização multiobjetivo pode conter uma série de restrições que qualquer solução viável (incluindo todas as soluções ótimas) deve satisfazer. Tais objetivos podem ser minimizados ou maximizados, e o problema de otimização multiobjetivo pode ser apresentado em sua forma geral conforme a Equação 2.1:

$$\begin{array}{l}
 \left. \begin{array}{l}
 f_m(\mathbf{x}), \quad m = 1, 2, \dots, M; \\
 g_j(\mathbf{x}) \geq 0, \quad j = 1, 2, \dots, J; \\
 h_k(\mathbf{x}) = 0, \quad k = 1, 2, \dots, K; \\
 x_i^L \leq x_i \leq x_i^U, \quad i = 1, 2, \dots, n.;
 \end{array} \right\} \quad (2.1) \\
 \text{Minimizar/Maximizar}
 \end{array}$$

Pode-se considerar como uma solução $\mathbf{x} \in \mathbb{R}^n$ sendo representado com um vetor de n variáveis de decisão: $\mathbf{x} = (x_1, x_2, \dots, x_n)^T$. Deste modo, as soluções devem satisfazer as restrições e os limites impostos pelas variáveis que constituem uma provável solução viável no espaço variável de decisão $S \subset \mathbb{R}^n$. Uma das principais diferenças marcantes entre otimização baseada em

objetivo único e a otimização multiobjetivo é que na otimização multiobjetivo as funções objetivo constituem um espaço multidimensional, representado em diversos planos, além do espaço variável de decisão usual. Este espaço M-dimensional adicional é chamado de espaço objetivo, denotado por $Z \subset \mathbb{R}^M$. Portanto, para cada solução \mathbf{x} no espaço da variável de decisão, ocorre a existência de um ponto $\mathbf{z} \in \mathbb{R}^M$ no espaço objetivo, denotado por $\mathbf{f}(\mathbf{x}) = \mathbf{z} = (z_1, z_2, \dots, z_M)^T$. De modo a melhor contextualizar o problema a ser otimizado, deve-se referir a uma "solução viável" como uma variável baseada em vetores e um "ponto" como o vetor objetivo correspondente. As soluções ótimas em otimização multiobjetivo podem ser definidas a partir de um conceito matemático de ordenação parcial (GUO; CHO; ZHU, 2004), trazendo tal definição ao contexto de otimização multiobjetivo. O termo dominação (*dominance*) é usado para esse propósito (DEB, 2011).

Sendo assim, pode-se definir o conceito de dominância baseado em Deb e Sinha (2010):

- $\mathbf{x}^{(1)}$ tem forte dominância em $\mathbf{x}^{(2)} \Leftrightarrow \mathbf{f}(\mathbf{x}^{(1)}) > \mathbf{f}(\mathbf{x}^{(2)})$,
- $\mathbf{x}^{(1)}$ tem fraca dominância em $\mathbf{x}^{(2)} \Leftrightarrow \mathbf{f}(\mathbf{x}^{(1)}) \geq \mathbf{f}(\mathbf{x}^{(2)})$,
- $\mathbf{x}^{(1)}$ e $\mathbf{x}^{(2)}$ não são dominados entre si $\Leftrightarrow \mathbf{f}(\mathbf{x}^{(1)}) \not\geq \mathbf{f}(\mathbf{x}^{(2)}) \wedge \mathbf{f}(\mathbf{x}^{(2)}) \not\geq \mathbf{f}(\mathbf{x}^{(1)})$.

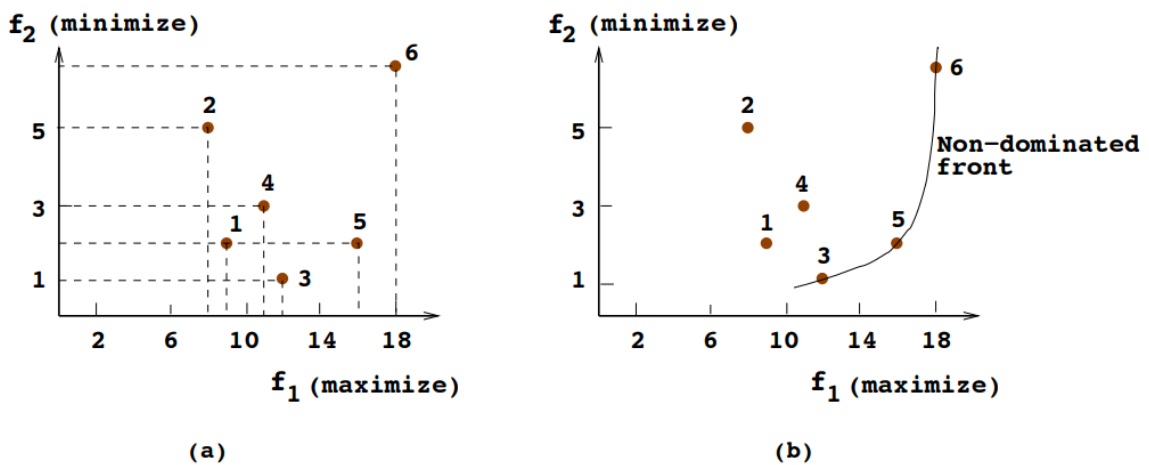


Figura 2.6: Representação de pontos de interesse e delineação da primeira fronteira de Pareto não dominada (DEB, 2011).

Sendo assim, pode-se utilizar a definição supramencionada para estabelecer se um ponto domina ou é dominado por outro estabelecido, realizando uma comparação ponto a ponto. Seguindo a definição, pode-se dizer que os pontos que não são dominados por nenhum outro membro do conjunto são chamados de pontos não dominados da classe, ou simplesmente os pontos não dominados.

Para o conjunto de soluções mostradas na figura 2.6 (a), onde são representados retângulos com as relações de dominância, a fronteira de Pareto é representada pelos pontos 3, 5 e 6 na figura 2.6 (b). Uma propriedade encontrada em relação a quaisquer dois desses pontos é que havendo um ganho em um objetivo de um ponto para o outro ponto, acontece o sacrifício em pelo menos outro objetivo. Sabendo de tal propriedade, os utilizadores do método recorrem a um grande número de iterações antes que seja feita a escolha final. Esses pontos formam uma fronteira quando são vistos juntos no espaço objetivo; todavia, os pontos não dominados são frequentemente utilizados para representar outras fronteiras de não dominação (DEB, 2011).

Portanto, utilizando-se desses conceitos, a definição de soluções Pareto-ótimas são mais fáceis de serem obtidas e selecionadas em problemas relacionados ao uso de otimização multi-objetivo. Se o conjunto de pontos representa uma dada tarefa, significa que ele contém todos os pontos no espaço de busca (assumindo um número contável), os pontos situados na fronteira de Pareto, por definição, não são dominados por qualquer outro ponto no espaço objetivo, portanto, são pontos ótimos de Pareto. No entanto, uma análise mais profunda e definições matematicamente mais elegantes relacionadas a fronteira de Pareto, podem ser encontrados em Tamaki, Kita e Kobayashi (1996).

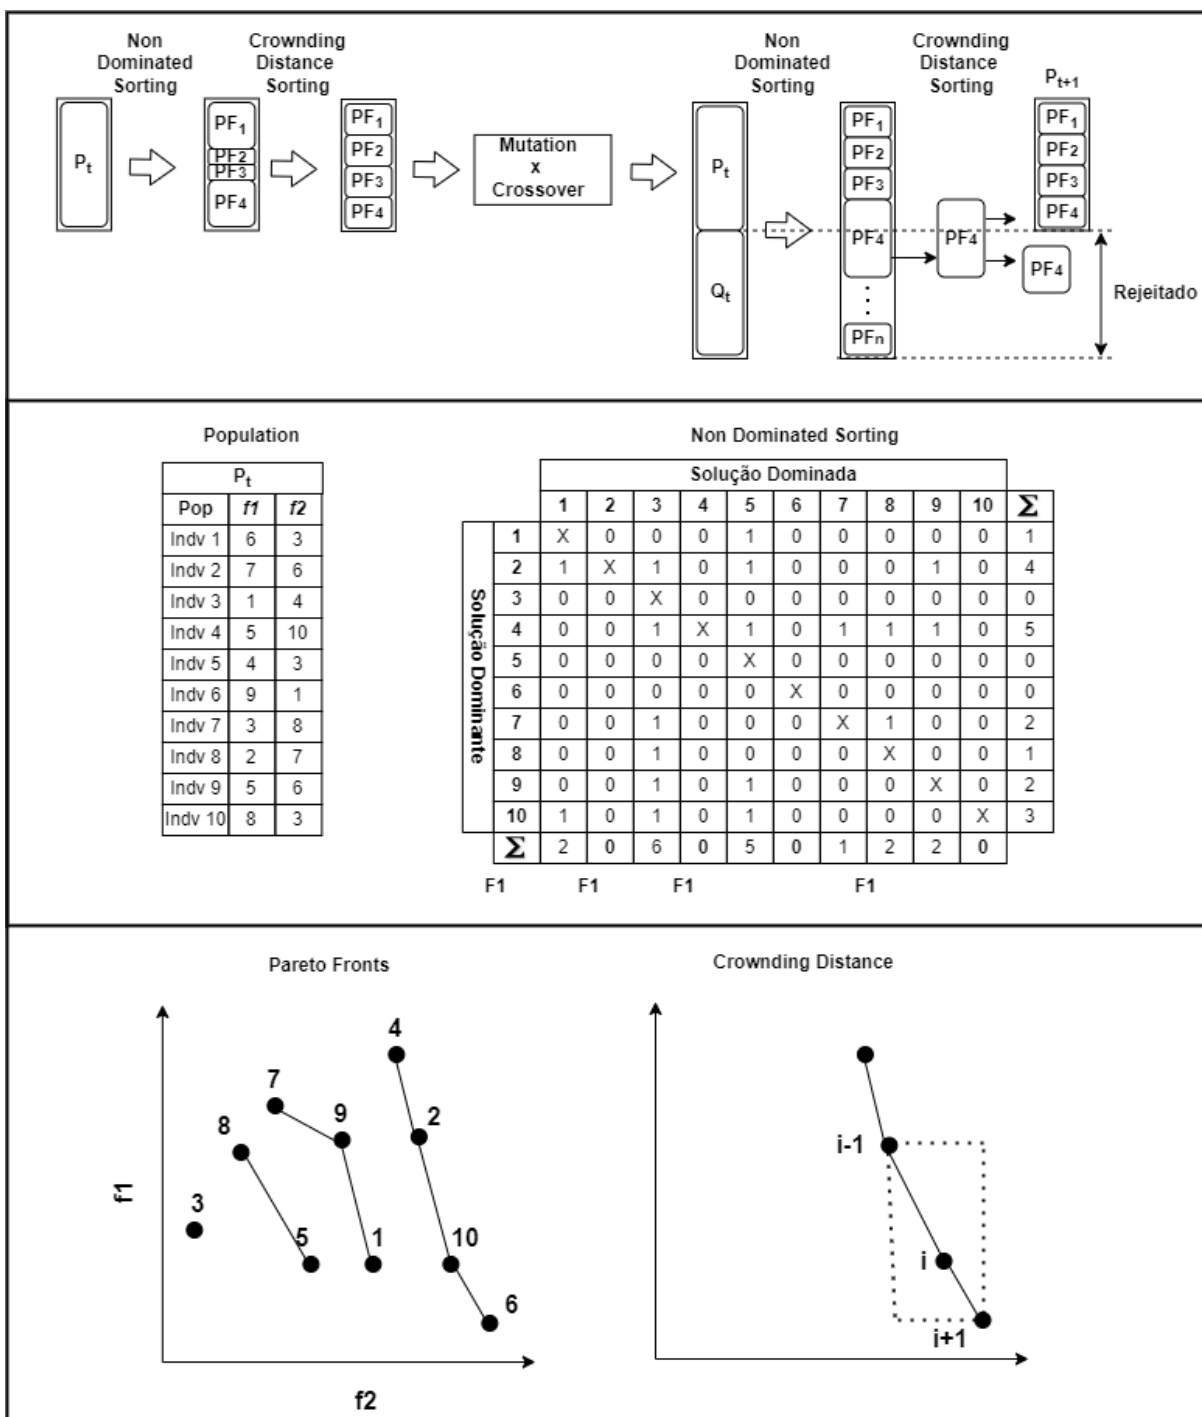


Figura 2.7: Exemplo do procedimento utilizado para a execução do algoritmo NSGAII proposto por Deb (2011).

De modo a melhor contextualizar ao leitor da presente tese o conceito de MOEAs, a seguir será apresentada uma breve exemplificação do algoritmo NSGAII, conforme descrito por Deb em (DEB et al., 2000), sendo que o NSGAII é um algoritmo evolucionário. Os algoritmos evolutivos foram desenvolvidos porque as técnicas clássicas diretas e baseadas em otimização, baseadas em gradiente, têm os seguintes problemas ao lidar com não linearidades e interações

complexas:

- A convergência para uma solução ótima, na maioria das vezes, depende da solução inicial escolhida;
- A maioria dos algoritmos tende a ficar preso em mínimo local, ou seja, em uma solução abaixo do ideal.

O NSGAII é um algoritmo evolucionário que possui os três recursos a seguir:

- Um princípio de elitismo, em outras palavras, as elites de uma população têm a oportunidade de serem levadas para a próxima geração;
- Um mecanismo explícito de preservação da diversidade (*Crowding distance* - Equações 2.2 e 2.3);
- Enfatiza as soluções não dominadas.

Na Figura 2.7, na parte inferior, é demonstrado um exemplo simbólico para o cálculo da *Crowding distance*, onde: cd^i representando o valor resultante de *Crowding distance* de cada uma das soluções contidas em um dado espaço de soluções, obtido pela média aritmética, denotado por $\sum_{m=1}^M cd_m^i$ e relacionado com o número de objetivos (M) do problema a ser otimizado. Sendo assim, para uma solução i , f_m^{i-1} é o valor objetivo obtido para a solução vizinha localizada acima da solução i na fronteira de Pareto e f_m^{i+1} é o valor objetivo obtido para a solução vizinha localizada abaixo da solução i na mesma fronteira de Pareto. Os itens f_m^0 e f_m^L correspondem aos valores dos pontos extremos da fronteira de Pareto em tela para uma dada solução i contida no espaço de soluções. Devido às soluções contidas nos extremos da fronteira serem mantidas para avaliação na próxima geração do procedimento evolutivo, é atribuído um valor alto, ou infinito, como em algumas implementações, para os itens cd^0 e cd^L contidos na Equação 2.3.

$$cd^i = \frac{1}{M} \sum_{m=1}^M cd_m^i \quad (2.2)$$

$$cd_m^i = \frac{f_m^{i+1} - f_m^{i-1}}{f_m^0 - f_m^L} \quad (2.3)$$

Sendo assim, tomando-se o exemplo apresentado na figura 2.7 como base, e o procedimento é descrito a seguir:

- Realize uma ordenação baseada em não dominação, conforme supramencionado, na combinação das populações de pais e descendentes e classifique-os por fronteiras de Pareto, isto é, eles são ordenados de acordo com um nível ascendente de não dominação;
- Realize uma ordenação não dominada na combinação das populações de pais e descendentes, e classifique-os por frentes, ou seja, eles são ordenados de acordo com um nível ascendente de não dominação;
- Preencha a nova população conforme a classificação obtida pelas fronteiras de Pareto;
- Execute *Crowding-sort*, que usa a distância descrita nas Equações 2.2 e 2.3. As soluções que possuem a menor densidade (proximidade entre soluções) são as preferidas e selecionadas pelo procedimento. O *Crowding distance* é a Distância de Manhattan avaliada dentro de um espaço objetivo. No entanto, os pontos extremos devem ser mantidos a cada geração, portanto, recebem uma distância de valor infinito.
- Crie uma população de descendentes dessa nova população usando uma estratégia de seleção, por exemplo, torneio (comparação por ranqueamento das fronteiras de Pareto, se igual, faça por *Crowding distance*). Por fim, faça as operações baseadas em operadores de cruzamento e mutação.

2.6 Abordagens Autoadaptativas

O conceito de adaptação é comum em diversas áreas do conhecimento, sendo uma forma de um agente ou indivíduo se ajustar ao meio ou a um determinado problema de forma autônoma. Ao levar esse conceito para o campo da computação, em particular a área de otimização evolucionária, o termo é melhor definido por Meyer-Nieberg e Beyer (2007) e Kramer (2010) como o controle online evolutivo das chamadas **variáveis de estratégia**. As variáveis de estratégia definem as propriedades de um algoritmo evolucionário, como seus operadores genéticos de mutação e cruzamento, operador de seleção ou tamanho das populações a serem evoluídas.

O maior desafio relacionado a essa otimização não é apenas encontrar ajustes adequados, mas também fazê-los de maneira eficiente. Todo o processo pode se tornar ainda mais complexo e computacionalmente custoso quando é aplicado a um espaço de busca em que o otimizador é submetido a problemas que possuem características dinâmicas. Isso ocorre porque uma configuração de parâmetros que era considerada ótima no início de uma execução pode se tornar inadequada durante o processo evolutivo. Assim, geralmente há a necessidade de uma modificação

constante ou adaptação dos parâmetros de controle durante a execução (MEYER-NIEBERG; BEYER, 2007).

Para contextualizar as estratégias autoadaptativas, pode-se considerar uma população ρ de μ indivíduos $\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_\mu$, onde cada \mathbf{a} corresponde a uma variável objetiva N-dimensional do vetor \mathbf{x} que define uma solução para o problema de otimização de dimensão N . A ideia da autoadaptação é a seguinte: um vetor σ de variáveis de estratégia está ligado a cada cromossomo representado na população ρ . Tanto os objetivos quanto as variáveis de estratégia sofrem variação e seleção conforme cada um dos indivíduos avaliados, representado por $\mathbf{a} = (\mathbf{x}, \sigma)$. Portanto, os indivíduos herdam todo o material genético, ou seja, o cromossomo \mathbf{x} que define a solução e o vetor de variáveis de estratégia σ . As variáveis de estratégia autoadaptativas também são conhecidas como **endógenas**, ou seja, evolutivas, em contraste com os parâmetros **exógenos**, sendo mantidos constantes durante a execução da otimização (KRAMER, 2010).

O uso de abordagens autoadaptativas na otimização evolucionária tem se mostrado uma técnica promissora para resolver problemas complexos e dinâmicos. O controle online das variáveis de estratégia permite que o algoritmo evolucionário ajuste seus parâmetros de forma autônoma, o que pode levar a soluções mais eficientes e robustas.

Essa técnica é particularmente útil em espaços de busca onde as características do problema mudam dinamicamente, dificultando encontrar e manter uma configuração ideal de parâmetros. Com a autoadaptação, os parâmetros são atualizados continuamente durante a execução do algoritmo, permitindo que ele se adapte às mudanças no ambiente de busca.

Além disso, a abordagem autoadaptativa é especialmente eficaz em problemas onde os parâmetros de controle não podem ser definidos *a priori* ou são difíceis de determinar. A autoadaptação permite que o algoritmo encontre automaticamente a melhor combinação de parâmetros para o problema em questão, sem que o usuário precise especificá-los manualmente.

Em resumo, as abordagens autoadaptativas na otimização evolucionária têm o potencial de superar os desafios associados à adaptação de parâmetros em espaços de busca dinâmicos e complexos. Ao permitir que o algoritmo evolua continuamente seus parâmetros de controle, essa técnica pode levar a soluções mais eficientes e robustas, além de ser especialmente útil em problemas onde os parâmetros são difíceis de definir *a priori*.

Por fim, neste capítulo foram apresentados conceitos e tecnologias fundamentais para o desenvolvimento da tese. Foram detalhados aspectos sobre redes em chip, metodologias *many-core* e elementos essenciais para a concepção de uma NoC. Além disso, foram abordados temas como o mapeamento de aplicações em sistemas *manycore*, algoritmos evolutivos multiobjetivos

e estratégias autoadaptativas. Essas informações forneceram ao leitor o embasamento necessário para entender os conceitos e metodologias aplicados na tese apresentada. Compreender esses fundamentos é essencial para que se possa apreciar plenamente os resultados obtidos e a contribuição da pesquisa para o avanço na área.

Capítulo 3

TRABALHOS RELACIONADOS

Neste capítulo são apresentados resumos dos trabalhos relacionados ao tema principal desta tese. A seção 3.1 apresenta uma contextualização acerca de Mapeamentos em Arquiteturas *manycore*; a seção 3.1.1 apresenta trabalhos com enfoque em otimização energética; a seção 3.1.2 apresenta trabalhos com enfoque em tolerância a falhas; a seção 3.1.3 apresenta trabalhos com enfoque em otimização termal; a seção 3.2 apresenta trabalhos que se utilizam de abordagens autoadaptativas para otimização de MOEAs e a seção 3.3 apresenta as limitações e o sumário dos trabalhos relacionados.

3.1 Mapeamento de aplicações em arquiteturas *manycore*

Uma das tendências mais importantes na arquitetura de computadores nos últimos anos é a mudança de paradigma em relação a *multi/manycore*. Assim, a frequência dos processadores atingiu seu limite e ganhos adicionais de desempenho, ao melhorar a arquitetura principal, resultariam em um enorme aumento no consumo de energia. Diante disso, ao explorar o paralelismo, vários núcleos com menor poder computacional podem superar um único núcleo trabalhando em alta frequência, obtendo ainda um melhor uso dos recursos do sistema (WEICHSLGARTNER et al., 2018b).

Além disso, as demandas de desempenho de aplicações embarcadas complexas modernas aumentaram substancialmente, o que não pode ser satisfeito simplesmente aumentando a frequência de um processador de núcleo único ou somente pela personalização do processador. Em vez disso, há a necessidade de vários processadores que possam se comunicar coesamente e fornecer maior paralelismo (SINGH et al., 2013).

Sendo assim, diversos pesquisadores têm concentrado seus esforços em determinar melho-

res métodos para a implementação de tais arquiteturas, por meio de estudos de novas metodologias baseadas em arquiteturas *manycore*.

Cabe destacar que, ao longo dos anos, foram realizados diversos trabalhos de pesquisa relacionados à taxonomia, classificação e principais abordagens em arquiteturas *manycore*. Dentre eles, destacam-se os estudos de Singh et al. (2013), Sahu e Chattopadhyay (2013), Marwedel et al. (2011), (THEOCHARIDES et al., 2009) e Ascia, Catania e Palesi (2004).

Portanto, a seguir serão apresentados alguns trabalhos que possuem abordagens diretamente relacionadas à presente tese.

3.1.1 Mapeamentos baseados em eficiência energética

Otimizar os recursos relacionados ao consumo de energia em sistemas embarcados modernos, por exemplo, telefones celulares e *tablets*, é importante, pois geralmente esses dispositivos são operados por uma fonte de alimentação independente, como, por exemplo, uma bateria (SINGH et al., 2017).

O tempo operacional de tais sistemas deve ser maximizado, de forma que as aplicações que estejam rodando obtenham uma quantidade de recursos computacionais compatível com suas necessidades de desempenho, em contrapartida, tais aplicações devem ser geridas para utilizar os recursos energéticos eficientemente.

Em relação ao uso eficiente de energia nos sistemas baseados em arquiteturas *manycore*, a metodologia proposta por Mohammad (2016), em seu trabalho é proposto um sistema distribuído em tempo de execução, cujo objetivo é maximizar os recursos energéticos do sistema, utilizando para tal, um sistema de comunicação entre elementos de processamento e uma lista de espera que relaciona todas as aplicações com os recursos energéticos disponíveis.

Correlatadamente, em Chatterjee et al. (2017) é proposta uma estratégia de mapeamento e programação de tarefas em tempo real, considerando as limitações de energia em sistemas baseados em arquiteturas *manycore*. Nessa abordagem, é utilizada uma heurística de alocação de tarefas dinâmica para minimizar o consumo de energia, considerando prazo de execução de tarefas. Além disso, a estratégia proposta também considera o balanceamento de carga entre os núcleos de processamento para evitar gargalos e melhorar o desempenho do sistema.

O gerenciamento hierárquico de recursos proposto por Castilhos et al. (2016) é uma abordagem que busca melhorar a escalabilidade de sistemas *manycore*, dividindo o sistema em regiões e alocando um módulo gerencial responsável por cada região. Esses módulos gerenciais são

capazes de controlar a alocação de recursos dentro de sua região, realizando gerenciamento de energia e escalonamento de tarefas de forma independente. Com isso, é possível obter uma melhor utilização dos recursos disponíveis e evitar gargalos de desempenho em áreas específicas do sistema. Além disso, essa abordagem permite que o sistema seja mais facilmente escalável, já que novas regiões podem ser adicionadas conforme a demanda de processamento aumenta.

Outra abordagem interessante é proposta por Ju et al. (2019), que utiliza uma estratégia de otimização de recursos energéticos baseada no ajuste dinâmico da contagem de *threads* durante a execução do programa. Essa técnica permite explorar efetivamente o poder de computação de arquiteturas heterogêneas *manycore*, resultando em um aumento do desempenho computacional e da eficiência energética do sistema como um todo. Em contraste com outras abordagens que elencam hierarquicamente os recursos, essa abordagem é mais flexível e adaptável às necessidades específicas de cada aplicação.

O trabalho desenvolvido por Salehi, Ejlali e Shafique (2017) é também relevante, uma vez que ele se concentra no gerenciamento da confiabilidade de energia em tempo de execução, levando em consideração as variações nos níveis de *hardware* e *software*. O método empregado atualiza o nível energético consumido por cada tarefa em tempo de execução, utilizando seleção adaptável de tensão e frequência, com o objetivo de fornecer confiabilidade à execução dessas tarefas e obter um equilíbrio na relação potência e desempenho durante a execução.

Já, o trabalho de Donyanavard et al. (2016) também é importante no contexto de alocação de recursos em sistemas embarcados com restrições de energia. Esse trabalho propõe uma técnica de previsão de desempenho de tarefas e consumo de energia em tempo de execução, incorporando estratégias de Qualidade de Serviço (QoS) por tarefa em suas decisões de alocação. A ideia é identificar pontos de economia energética sem comprometer o desempenho geral do sistema. Essa abordagem permite que o sistema faça escolhas inteligentes de alocação de recursos, ajustando a frequência de operação e a tensão de alimentação de cada tarefa de acordo com sua importância e prazo de execução, maximizando assim a eficiência energética e a performance geral do sistema.

Abordagens com foco no desempenho energético têm como principal objetivo a obtenção de sistemas computacionais que sejam poderosos do ponto de vista de processamento, ao mesmo tempo em que mantêm um baixo consumo de energia. O objetivo é, portanto, maximizar o desempenho computacional do sistema, mas sem sacrificar a eficiência energética, de modo a alcançar um equilíbrio ideal entre desempenho e consumo de energia. Essa abordagem é particularmente relevante para sistemas embarcados e dispositivos móveis, onde a duração da bateria é uma preocupação importante e limita a quantidade de energia que pode ser consumida

pelo dispositivo.

3.1.2 Mapeamentos baseados em sistemas tolerantes a falha

Muitos trabalhos de pesquisa ao longo da literatura têm se concentrado na utilização eficiente de recursos e otimização de aplicativos, com vistas ao mapeamento tolerante a falhas e à garantia de maior tempo de operação confiável de sistemas que possuam arquiteturas *many-core*. Para isso, são utilizadas novas abordagens, que combinam metodologias inteligentes e/ou determinísticas, com o objetivo de prover soluções otimizadas e de fácil aplicação.

Pode-se destacar o estudo proposto por Shah, Kanniganti e Soumya (2017), que propõe uma topologia tolerante a falhas com uma interface física de rede duplamente conectada. Essa arquitetura garante que o processador principal tenha pelo menos dois links de comunicação, o que pode aumentar a confiabilidade do sistema. Além disso, é desenvolvido um algoritmo de roteamento tolerante a falhas adaptável que pode detectar congestionamentos na rede, atuando reativamente em falhas ocorridas. Este trabalho também demonstra que a latência e o consumo de energia utilizando algoritmos distintos (De Bruijn, *poorest neighbor*) são muito menores em comparação com a distribuição em malha e toroidal, sendo duas arquiteturas comuns em redes em chip (*NoC*) na literatura.

Em Zhou, Liu e Zhu (2017), é proposto o uso de portas de comunicação de backup e uma unidade tolerante a falhas no nível do roteador para manter a confiabilidade do tráfego. O princípio básico do roteamento de detecção é que todos os pacotes que chegam ao roteador devem ser encaminhados imediatamente para os roteadores adjacentes. No entanto, erros podem ocorrer com mais frequência em uma carga de rede mais alta, já que mais pacotes disputam a mesma porta de saída, levando a latência e consumo de energia extra.

De forma correlata, o estudo de Chatterjee, Paul e Chattopadhyay (2017) aborda a tolerância a falhas em sistemas *manycore*, utilizando uma técnica aprimorada baseada em software que elimina a necessidade de qualquer ponto de verificação. Essa técnica permite que nenhuma memória adicional seja necessária para armazenar o mapeamento tolerante a falhas do processador. Além disso, a energia gasta na migração de tarefas para processadores sobressalentes é reduzida, diferentemente de outros estudos baseados na redundância de hardware, que implicam consumo adicional de energia e área.

As possíveis falhas em processadores e seus pontos de migração podem ser previamente calculados durante o desenvolvimento, armazenando-os em memória para serem utilizados posteriormente. No entanto, Azad et al. (2017) apresentam uma abordagem "ground-up" mais

abrangente para a detecção de falhas, utilizando métodos previamente propostos para arquiteturas *SoCs* e adaptando-os para arquiteturas *NoC*. O método proposto inclui estratégias para detecção, localização, classificação e correção de falhas, com o uso de uma unidade global de gerenciamento para melhorar o tempo de reação a falhas e aprimorar o gerenciamento local de falhas do sistema.

É importante ressaltar que a falha em canais de interligação pode prejudicar seriamente o desempenho e confiabilidade de sistemas *manycore*. O trabalho de Bhowmik et al. (2018) é relevante por apresentar um mecanismo de baixo custo computacional capaz de detectar e localizar falhas em canais de interligação em arquiteturas *manycore*. A abordagem proposta consiste em utilizar um scheduler para executar o mecanismo de teste simultaneamente em vários nós, visando a obtenção de escalabilidade. Dessa forma, é possível detectar canais em curto, canais abertos e identificar suas localizações na arquitetura, contribuindo para a melhoria do desempenho e da confiabilidade do sistema *manycore*. É importante destacar que essa abordagem complementa outras técnicas de tolerância a falhas utilizadas em processadores incorporados à arquitetura, fornecendo um mecanismo de detecção de falhas em canais de interligação que pode ser facilmente incorporado em projetos de arquiteturas *manycore*.

Existem aplicações que utilizam modelos baseados em falhas para detecção de erros e determinação da posição sobressalente do núcleo. Em Beechu, Harishchandra e Balachandra (2017), é proposto um mapeamento de alto desempenho com gerenciamento central, que visa alta tolerância a falhas e eficiência energética. O algoritmo de mapeamento fornece uma visão global e local da arquitetura em relação aos processadores, evitando quedas de desempenho e reduzindo o tempo para realocação de processadores defeituosos. Esse método é aplicável a grafos gerados aleatoriamente com grande distribuição de tarefas.

É notável que as soluções propostas para as falhas em arquiteturas *manycore* buscam sempre alcançar um equilíbrio entre eficiência, baixo custo computacional e tolerância a falhas. A implementação de técnicas para a detecção, localização e migração de processadores defeituosos ou links de comunicação com falhas é uma preocupação constante dos pesquisadores. Soluções que apresentam baixo índice de manutenção, vida útil de operação estendida, baixo consumo energético e alto desempenho são altamente desejáveis em aplicações críticas e de grande escala, que fazem uso intensivo de processamento. Portanto, novas abordagens e soluções são necessárias para lidar com as falhas em arquiteturas *manycore*, visando sempre o aumento da confiabilidade e disponibilidade do sistema.

Sendo assim, nesta seção, foram apresentados diversos estudos que propõem soluções para o mapeamento de arquiteturas *manycore* com vistas a sistemas baseados em tolerância a falhas.

Foi possível observar que as soluções propostas apresentam diferentes abordagens e estratégias, mas todas com o objetivo de garantir alta confiabilidade e eficiência energética do sistema.

Dentre as abordagens apresentadas, destaca-se o uso de algoritmos de mapeamento baseados em restrições, que consideram a tolerância a falhas, a comunicação e o consumo de energia. A utilização de tarefas de baixo custo computacional e cálculos rápidos também é comum em diversas soluções apresentadas. Além disso, foram apresentados estudos que propõem soluções de mapeamento em tempo de execução e com restrições em relação ao controle térmico.

Em conjunto, essas soluções apresentam contribuições importantes para a literatura de arquiteturas *manycore*, visto que oferecem soluções eficientes e confiáveis para o mapeamento em sistemas baseados em tolerância a falhas. A escolha da abordagem a ser utilizada dependerá do contexto e das demandas específicas do sistema em questão, bem como das limitações e recursos disponíveis. Em suma, as abordagens propostas para o mapeamento de arquiteturas *manycore* com vistas a sistemas baseados em tolerância a falhas representam um importante avanço na busca por soluções mais eficientes e confiáveis para os desafios enfrentados em ambientes críticos.

3.1.3 Mapeamentos baseados em controle termal

O trabalho de Kim et al. (2017) destaca a importância de modelar a arquitetura baseada em *dark silicon* considerando tanto o modelo de energia quanto o modelo térmico dos processadores. Eles utilizaram a técnica DVFS e um estado do processador baseado em *dark silicon* para alcançar esse objetivo, com uma estratégia do tipo *On/Off*. O estudo revelou que o consumo de energia no sistema tem impactos diferentes, às vezes contraditórios, nos efeitos de confiabilidade do *software* e do *hardware*. Esses resultados são importantes para orientar o projeto de arquiteturas *manycore* que visam alcançar um equilíbrio entre desempenho, consumo de energia e confiabilidade.

Correlatadamente, em Haghbayan et al. (2016), é proposto um mapeamento de tempo de execução vitalício para atender aos requisitos de confiabilidade, considerando o desempenho e a demanda limitada de energia em sistemas com arquiteturas *manycore*. Para isso, são exploradas estratégias de *dark silicon* com o objetivo de maximizar a vida útil operacional do sistema, escolhendo os recursos eficientemente e fornecendo um período hábil de longo prazo para recuperação de núcleos em falha ou sob forte demanda por recursos. É também utilizado um *feedback* de temperatura granular para análises dinâmicas, fornecendo dados para um algoritmo que realizará o mapeamento de tempo de execução. Dessa forma, a abordagem proposta visa garantir uma maior eficiência energética e uma maior durabilidade dos sistemas *manycore*

com uma confiabilidade superior.

A abordagem proposta por Namazi et al. (2017b) é uma solução importante para garantir a confiabilidade e o desempenho de sistemas com arquitetura *manycore* homogênea. Ao utilizar um modelo de programação não linear mista, os autores encontram uma estratégia ideal para o mapeamento de tarefas, minimizando redundâncias e latência na execução de aplicativos, bem como garantindo a largura de banda necessária de cada transmissão. Dessa forma, erros que possam ocorrer nos processadores são mascarados por meio de uma replicação e realocação otimizada. É importante destacar que essa abordagem é fundamental para maximizar a eficiência do sistema e aumentar sua vida útil operacional, além de reduzir o consumo de energia e aquecimento.

Por sua vez, o estudo desenvolvido por Wang et al. (2018) apresenta uma abordagem interessante para o mapeamento em tempo de execução em arquiteturas *manycore*. O algoritmo proposto é baseado em manter uma quantidade de mapas anteriormente gerados para fornecer uma estratégia de reação rápida em caso de falha, resultando em uma melhora significativa na taxa de transferência do sistema. Além disso, é utilizado um esquema de mapeamento baseado em empréstimos, com restrições relacionadas à confiabilidade geral e local do sistema, garantindo um bom desempenho mesmo em casos de falha. A proposta apresentada é uma contribuição importante para a literatura de arquiteturas *manycore*, visto que oferece uma solução eficiente e confiável para o mapeamento em tempo de execução com restrições relacionadas ao controle térmico do sistema.

O trabalho de Liu et al. (2018) apresenta uma abordagem interessante para o mapeamento de tarefas em arquiteturas *manycore* com restrições em relação ao controle térmico e conflitos de comunicação. O algoritmo proposto pode ser realizado em tempo polinomial e considera a dinâmica da topologia de comunicação da arquitetura. O gerenciamento térmico e a alocação de núcleos são considerados durante o processo de mapeamento, permitindo a construção de canais de desvio expresso entre núcleos ativos com latência ultrabaixa. Esses canais podem melhorar o desempenho e garantir a segurança térmica da arquitetura.

Ao longo desta seção, foram apresentados diversos estudos e propostas relacionados ao controle térmico em arquiteturas *manycore*. Foi possível constatar a importância desse fator para o desempenho e a confiabilidade do sistema, bem como a complexidade do problema de gerenciamento térmico em arquiteturas com múltiplos núcleos de processamento.

Entre as abordagens apresentadas, destaca-se a proposta de Jiao et al. (2018), que oferece um algoritmo de gerenciamento termal e roteamento para arquiteturas com topologias 3D, com potencial de generalização para arquiteturas 2D. A utilização de duas camadas, eletrônica e

fotônica, para organização dos núcleos e transmissão de sinais de comunicação, demonstra um esforço para encontrar soluções eficientes e seguras para o controle térmico em arquiteturas *manycore*.

Outros estudos apresentados abordaram a questão do mapeamento de tarefas em arquiteturas *manycore* com restrições em relação ao controle térmico, comunicação e consumo de energia. Foi possível constatar a complexidade do problema e a necessidade de encontrar soluções eficientes e confiáveis para garantir o desempenho e a segurança do sistema.

Em resumo, o controle térmico é um fator crucial para o desempenho e a confiabilidade de sistemas baseados em arquiteturas *manycore*. As propostas apresentadas neste capítulo demonstram a relevância do tema e o esforço contínuo para encontrar soluções eficientes e seguras para o gerenciamento térmico em arquiteturas com múltiplos núcleos de processamento.

3.2 Abordagens multiobjetivo autoadaptativas

A utilização de recursos autoadaptativos em conjunto com MOEAs é algo de grande importância, já que MOEAs estão em constante desenvolvimento e com o advento de estratégias autoadaptativas é possível obter resultados ainda melhores (soluções). No entanto, quando se trata do mapeamento de tarefas em arquiteturas *manycores*, há poucos estudos disponíveis. Esta seção tem por objetivo demonstrar alguns estudos relacionados a essa abordagem.

No trabalho proposto por Martins et al. (2019), denominado *MORM (Multi-Objective Resource Management)*, os autores apresentam um sistema para gerenciamento de recursos energéticos em detrimento de cargas de trabalho dinâmicas. O cerne autoadaptativo do sistema está relacionado às mudanças de carga que podem ocorrer durante a operação do sistema, permitindo que os recursos sejam remapeados e/ou realocados para outros pontos do *grid* em questão, além do uso de técnicas como DVFS (*Dynamic Voltage and Frequency Scaling*). Os recursos são alocados de acordo com algumas métricas em uma abordagem multiobjetivo, como potência, energia, comunicação, computação e escalabilidade. O grande enfoque e motivação do trabalho é prover sistemas energeticamente eficientes com a possibilidade de lidar com cargas de trabalho dinâmicas.

Outro trabalho relevante é o proposto por Xue, Zhu e Neri (2022), que trata do problema de seleção de características com uma abordagem multiobjetivo autoadaptativa, a fim de reduzir a dimensionalidade do problema e aumentar a capacidade de obter melhores resultados quanto à classificação. É importante destacar que esses problemas são normalmente tratados como otimizações com dois objetivos. Os autores afirmam que, quando o problema é relativamente

simples, grande parte das heurísticas da literatura consegue obter resultados satisfatórios em tempo de execução viável. No entanto, com o aumento da dimensionalidade dos problemas de classificação, o desempenho decai drasticamente. A utilização de um algoritmo multiobjetivo autoadaptativo, conforme proposto pelos autores, pode oferecer melhores resultados em tempo de execução viável, utilizando para tal um mecanismo autoadaptativo baseado em recompensa e penalidade com vistas à dominância das soluções, além do uso de uma estratégia que evita a estagnação das soluções ao longo das gerações.

Wan et al. (2018) apresenta um algoritmo autoadaptativo multiobjetivo baseado em busca harmônica com o uso de técnicas de clusterização *fuzzy* para a segmentação de imagens. Normalmente, a segmentação de imagens visa a otimização de apenas um objetivo, o que não considera toda a informação contida nas imagens, além dos possíveis nuances existentes. Com a utilização de mais de uma função objetivo durante a tarefa de segmentação, foi verificado pelos autores um aumento na qualidade e na eficiência da tarefa de segmentação, além de outros resultados que não eram possíveis com técnicas comuns. O cerne da autoadaptação é baseado em dois mecanismos principais, que consistem em equilibrar recursos utilizados para a pesquisa local e global e a redução no custo relacionado ao ajuste de parâmetros.

A otimização de problemas relacionados ao *scheduling de flow shops* ainda é um tema de intensa pesquisa ((LI; GONG; LU, 2022)), devido ao seu uso em vários campos da indústria e outros setores produtivos. No artigo proposto por Liang et al. (2019), é desenvolvido um algoritmo com evolução diferencial autoadaptativa para solução de problemas multiobjetivos relacionados a *Job Shop* com restrição baseada no tamanho dos buffers disponíveis. As métricas otimizadas no referido trabalho são o *makespan* e o valor correspondente à tarefa com maior atraso. A metodologia autoadaptativa é incorporada ao mecanismo de evolução diferencial, resultando em um aumento na velocidade de convergência e na qualidade da solução. Já no artigo proposto por Li et al. (2022), o problema relacionado a *Job Shop* ainda é tema, porém a proposta visa minimizar dois objetivos específicos: o *makespan* e o tempo total de carga de trabalho. A abordagem é baseada em programação linear de inteiros mista e uma autoadaptação baseada em decomposição.

Diante dos trabalhos apresentados, pode-se afirmar que a utilização de recursos autoadaptativos em conjunto com MOEAs é uma área em constante desenvolvimento, com possibilidade de obter melhores resultados (soluções) em diversos problemas. É importante destacar que, para obter soluções eficientes, são necessários estudos que identifiquem os melhores recursos e estratégias que permitam a adaptação a situações específicas, como a variação da carga de trabalho ou a dimensionalidade do problema. As pesquisas em autoadaptação podem trazer

benefícios a diferentes setores, como o aumento da eficiência energética, a redução de custos e a melhoria da qualidade dos serviços prestados. Portanto, esses estudos podem ser vistos como uma importante contribuição para a evolução dos sistemas autoadaptativos em MOEAs.

3.3 Limitações dos Trabalhos Relacionados e Sumário dos trabalhos relacionados.

A tabela 3.1 apresenta uma síntese dos trabalhos sobre mapeamento de aplicações em arquiteturas *manycore* abordados neste capítulo. Embora todos eles tenham contribuído para o desenvolvimento de técnicas de mapeamento, ainda há várias lacunas a serem exploradas nesse campo de estudo.

De maneira geral, os estudos analisados (seções 3.1.1, 3.1.2 e 3.1.3) validaram suas técnicas por meio de simulação e/ou emulação em sistemas baseados em modelos matemáticos. Muitos deles utilizaram apenas um algoritmo multiobjetivo para realizar as validações, sendo o NSGAI o mais comum devido à sua facilidade de implementação e efetividade em problemas relacionados ao mapeamento. No entanto, a utilização de apenas um algoritmo deixa uma grande lacuna, pois outros algoritmos podem fornecer resultados ainda melhores, dependendo do escopo do problema. De fato, estudos anteriores demonstraram que o desempenho do NSGAI pode ser inferior ao de outros algoritmos disponíveis na literatura. Portanto, há espaço para explorar o uso de outras abordagens que possam aprimorar ainda mais as técnicas de mapeamento de aplicações em arquiteturas *manycore*.

Tabela 3.1: Sumário dos trabalhos relacionados ao mapeamento em arquiteturas *manycore*

Autor/Ano	Tipo de Arquitetura	Gerenciamento	Objetivos
(MOHAMMAD, 2016)	Homogênea	Controle Distribuído	Eficiência Energética baseada em DVFS.
(CHATTERJEE et al., 2017)	Homogênea	Controle Centralizado	Controle Temporal (<i>Scheduling</i>), Eficiência Energética.
(CASTILHOS et al., 2016)	Homogênea	Controle Hierárquico	Distribuição de Carga de Trabalho, Gerenciamento da Comunicação.
(JU et al., 2019)	Homogênea	Controle Centralizado	Eficiência Energética, Controle baseado em <i>threads</i>
(SALEHI; EJLALI; SHAFIQUE, 2017)	Homogênea	Controle Centralizado	Eficiência Energética, Tempo de Execução, Contexto baseado em confiabilidade.
(DONYANAVARD et al., 2016)	Heterogênea	Controle Centralizado	Eficiência Energética baseada em sensores
(SHAH; KANNIGANTI; SOUMYA, 2017)	Homogênea	Controle Centralizado	Tolerância a Falhas, Gerenciamento da Comunicação.
(ZHOU; LIU; ZHU, 2017)	Homogênea	Controle Centralizado	Tolerância a Falhas, Gerenciamento da Comunicação.
(CHATTERJEE; PAUL; CHATTOPADHYAY, 2017)	Homogênea	Controle Centralizado	Tolerância a Falhas, Gerenciamento da Comunicação, Eficiência Energética, Tempo de Execução.
(AZAD et al., 2017)	Homogênea	Controle Centralizado	Tolerância a Falhas, Controle de entrega de pacotes.
(BHOWMIK et al., 2018)	Homogênea	Controle Centralizado	Tolerância a Falhas em Canais de Comunicação
(BEECHU; HARISHCHANDRA; BALACHANDRA, 2018)	Homogênea	Controle Distribuído	Gerenciamento de Desempenho, Gerenciamento da Comunicação
(KIM et al., 2017)	Homogênea	Controle Centralizado	Eficiência Energética baseado em DVFS, Metodologia <i>dark silicon</i> .
(HAGHBAYAN et al., 2016)	Homogênea	Controle Centralizado	Tolerância a Falhas, Eficiência Energética, Metodologia <i>dark silicon</i> .
(NAMAZI et al., 2017b)	Homogênea	Controle Centralizado	Tolerância a Falhas, Gerenciamento da Comunicação, Eficiência Energética, Tempo de Execução.
(NAMAZI et al., 2017a)	Homogênea	Controle Centralizado	Tolerância a Falhas, Eficiência Energética.
(BEECHU; HARISHCHANDRA; BALACHANDRA, 2017)	Homogênea	Controle Centralizado	Tolerância a Falhas, Gerenciamento da Comunicação.
(WANG et al., 2018)	Homogênea	Controle Centralizado	Tolerância a Falhas, Gerenciamento da Comunicação.
(LIU et al., 2018)	Homogênea	Controle Centralizado	Controle Térmico, Eficiência Energética
(JIAO et al., 2018)	Homogênea	Controle Centralizado	Controle Térmico, Eficiência Energética

Capítulo 4

METODOLOGIAS DE MAPEAMENTO DE TAREFAS EM ARQUITETURAS MANYCORE

Com o aumento da complexidade e da demanda por desempenho em aplicações, o uso de arquiteturas *manycore* tem se tornado cada vez mais comum para acelerar o processamento. No entanto, o mapeamento dessas aplicações em muitos núcleos é um desafio, devido à necessidade de balanceamento de carga, gerenciamento de comunicação e escalabilidade.

Neste capítulo é apresentado dois *frameworks* propostos para facilitar o mapeamento de grafos de aplicações de morfologia matemática em arquiteturas *manycore*. O primeiro (Seção 4.1) proposto é voltado para o mapeamento de grafos de aplicativos de morfologia matemática em arquiteturas *manycore* e tem como objetivo otimizar o uso dos recursos computacionais disponíveis. Já o segundo *framework* (Seção 4.2) proposto é autoadaptativo e visa adaptar o procedimento evolutivo de mapeamento de aplicações em arquiteturas *manycore*, com destaque para o procedimento autoadaptativo multiobjetivo proposto para o mapeamento de grafos.

Portanto, nesta seção serão discutidos os detalhes de cada *framework*, bem como os resultados obtidos em experimentos realizados para avaliar sua eficácia. Ao final deste capítulo, espera-se fornecer uma visão abrangente dos desafios envolvidos no mapeamento de grafos em arquiteturas *manycore*, bem como soluções propostas para enfrentar esses desafios.

4.1 *Framework* proposto para mapeamento de aplicações de MM em arquiteturas *manycore*

Na seção seguinte, será apresentado o *framework* proposto para o mapeamento de grafos de aplicações MM em arquiteturas *manycore*, que representa uma das metodologias utilizadas

nesta tese. Conforme ilustrado na Figura 4.1, o *framework* é composto por quatro módulos distintos: o Módulo Folds (descrito na Seção 4.1.1), o Módulo de Treinamento (descrito na Seção 4.1.2), o Módulo de Testes (descrito na Seção 4.1.4) e o Módulo de Mapeamento (descrito na Seção 4.1.5). O objetivo deste *framework* é simplificar o mapeamento de grafos de aplicações MM em arquiteturas *manycore*, permitindo uma melhor utilização dos recursos de hardware disponíveis e aprimorando o desempenho geral das aplicações.

4.1.1 Módulo *Folds*

O Módulo *Folds* (Figura 4.1 (Canto superior esquerdo)) é utilizado para gerar, automaticamente, conjuntos de imagens de treinamento e teste para o *framework* proposto nesta tese, que possui como ideia principal obter uma melhor variabilidade estatística e generalização dos dados de entrada nesta etapa, sendo posteriormente tais conjuntos transferidos aos Módulos de Treinamento e Teste.

Assim, neste módulo específico, a ser visto em detalhes também na seção experimental, N ($N= 40$ neste estudo) pares de imagens de entrada (original + alvo (padrões a serem detectados pelo procedimento proposto)) e n *folds* ($n= 10$ neste estudo), foram utilizados para gerar os conjuntos de imagens de treinamento e teste. Portanto, para cada *fold*, N_1 ($N_1= 30$ neste estudo) pares de imagens de treinamento e N_2 ($N_2= 10$), foram usados pares de imagens de teste, geradas aleatoriamente a partir do conjunto de entrada, como pode ser visto na Figura 4.1. Também, foram utilizadas neste contexto, imagens de entrada binárias e em níveis de cinza contendo padrões geométricos, sendo tais padrões mais adequados para a utilização de filtros morfológicos, gerados automaticamente, pela abordagem inteligente proposta. Por fim, todas as conexões (fluxo de dados) e relacionamentos entre este módulo e os demais são representados por setas tracejadas, também apresentados nessa figura. Portanto, é possível inferir que esse módulo fornece dados adequados (ao referido procedimento) e padronizados para o correto funcionamento dos Módulos de Treinamento e Testes, a serem melhor descritos na Seção 4.1.2.

4.1.2 Módulo de Treinamento

O objetivo do Módulo de Treinamento (Figura 4.1 (Lado superior direito)) é gerar automaticamente filtros de imagem utilizando MM, com o auxílio de um algoritmo (Procedimento 1D (Figura 4.2)) baseado em NSGAI (DEB et al., 2000), modificado nesta proposta, conforme detalhado abaixo, utilizando para tal os conjuntos de treinamento gerados anteriormente pelo Módulo *Fold*, conjunto de instruções morfológicas e lógicas (Tabela 4.1) e parâmetros genéti-

Tabela 4.1: Instruções Morfológicas, Aritméticas e Lógicas

ID	Instrução	Descrição
1	Nop	Nenhuma operação. Permite maior flexibilidade para o cromossomo, com Aridade 1.
2	Sub	Subtração aritmética de Aridade 2.
3	And	Operação lógica AND de Aridade 2.
4	Ero_s_3	Erosão (Aridade 1) por um elemento estruturante quadrado de tamanho 3x3.
5	Ero_c_3	Erosão (Aridade 1) por um elemento estruturante em forma de disco de tamanho 3x3.
6	Ero_s_5	Erosão (Aridade 1) por um elemento estruturante quadrado de tamanho 5x5.
7	Ero_c_5	Erosão (Aridade 1) por um elemento estruturante em forma de disco de tamanho 5x5.
8	Ero_s_7	Erosão (Aridade 1) por um elemento estruturante quadrado de tamanho 7x7.
9	Ero_c_7	Erosão (Aridade 1) por um elemento estruturante em forma de disco de tamanho 7x7.
10	Dil_s_3	Dilatação (Aridade 1) por um elemento estruturante quadrado de tamanho 3x3.
11	Dil_c_3	Dilatação (Aridade 1) por um elemento estruturante em forma de disco de tamanho 3x3.
12	Dil_s_5	Dilatação (Aridade 1) por um elemento estruturante quadrado de tamanho 5x5.
13	Dil_c_5	Dilatação (Aridade 1) por um elemento estruturante em forma de disco de tamanho 5x5.
14	Dil_s_7	Dilatação (Aridade 1) por um elemento estruturante quadrado de tamanho 7x7.
15	Dil_c_7	Dilatação (Aridade 1) por um elemento estruturante em forma de disco de tamanho 7x7.
16	Ero/_3	Erosão (Aridade 1) por um elemento estruturante diagonal direita de tamanho 3x3.
17	Ero_3	Erosão (Aridade 1) por um elemento estruturante diagonal esquerda de tamanho 3x3.
18	Ero/_5	Erosão (Aridade 1) por um elemento estruturante diagonal direita de tamanho 5x5.
19	Ero_5	Erosão (Aridade 1) por um elemento estruturante diagonal esquerda de tamanho 5x5.
20	Ero/_7	Erosão (Aridade 1) por um elemento estruturante diagonal direita de tamanho 7x7.
21	Ero_7	Erosão (Aridade 1) por um elemento estruturante diagonal esquerda de tamanho 7x7.
22	Dil/_3	Dilatação (Aridade 1) por um elemento estruturante diagonal direita de tamanho 3x3.
23	Dil_3	Dilatação (Aridade 1) por um elemento estruturante diagonal esquerda de tamanho 3x3.
24	Dil/_5	Dilatação (Aridade 1) por um elemento estruturante diagonal direita de tamanho 5x5.
25	Dil_5	Dilatação (Aridade 1) por um elemento estruturante diagonal esquerda de tamanho 5x5.
26	Dil/_7	Dilatação (Aridade 1) por um elemento estruturante diagonal direita de tamanho 7x7.
27	Dil_7	Dilatação (Aridade 1) por um elemento estruturante diagonal esquerda de tamanho 7x7.
28	Or	Operação lógica OR de Aridade 2.
29	Nor	Operação lógica NOR de Aridade 2.
30	Add	Adição aritmética de Aridade 2.

Tabela 4.2: Parâmetros e variáveis usados nos algoritmos (Treinamento e Teste)

EA Parâmetros	Descrição
N_i	Número de Indivíduos (Tamanho da População)
L	Número de genes no cromossomo
Mt_Rt	Taxa de mutação
Ng	Número de Gerações
$n_training_pairs_set$	{ $img_in_tr, img_in_tg_tr$ }
$n_test_pairs_set$	{ $img_in_tst, img_in_tg_tst$ }

cos adequados ao procedimento proposto (Tabela 4.2). Por fim, os resultados são obtidos, na forma de cromossomos (Figura 4.2), conforme a figura apresentada, representam Grafos Acíclicos Dirigidos (DAG) (SAHNER; TRIVEDI, 1987), relacionados às aplicações de MM (filtros morfológicos) implementados nesta pesquisa.

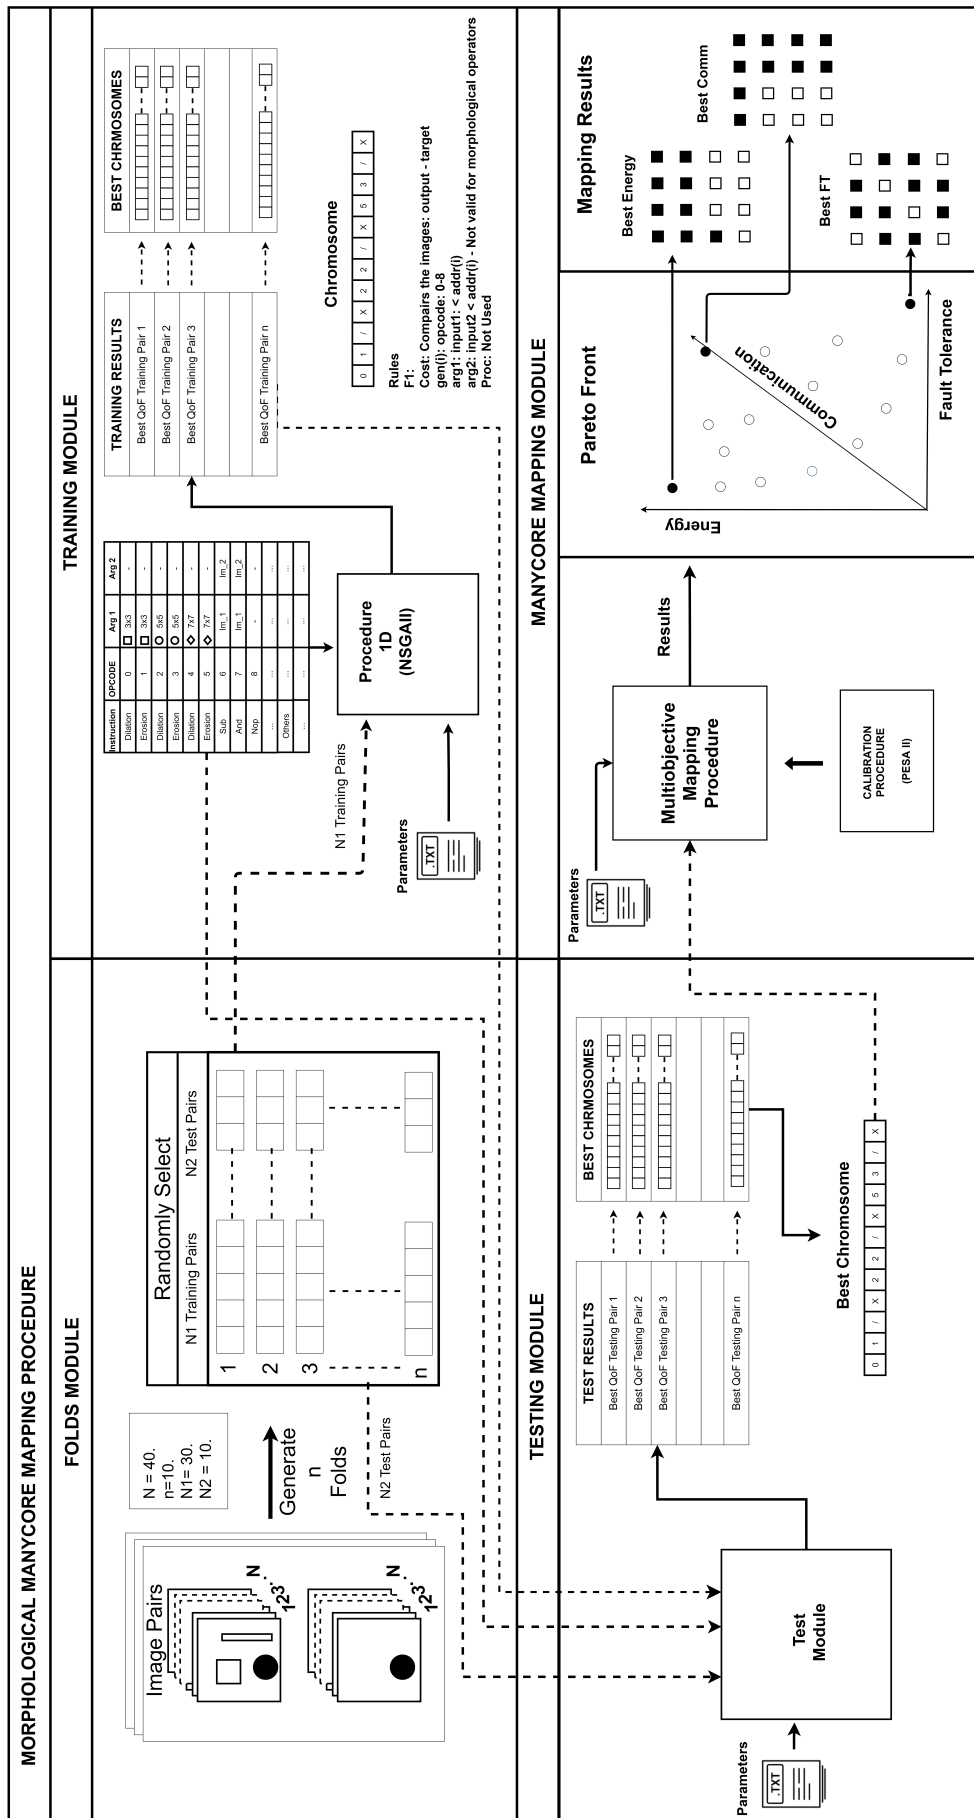


Figura 4.1: Diagrama de blocos do framework proposto.

4.1.3 Procedimento 1D

O Procedimento 1D (Pseudo-Código - Figura 4.3), interno ao Módulo de Treinamento, foi implementado, conforme mencionado anteriormente, por meio de uma modificação (detalhada abaixo) do algoritmo NSGAI, disponível na caixa de ferramentas PlatEMO (TIAN et al., 2017), com o objetivo de otimizar apenas a qualidade dos filtros Morfológicos (Métrica: *QoF*: qualidade do filtro) gerados automaticamente neste trabalho. O objetivo é obter os melhores filtros (melhor qualidade de extração) para o módulo de Mapeamento a ser descrito na seção 4.1.5.

O Procedimento 1D tem como entradas os seguintes conjuntos de dados para seu bom funcionamento: *Parâmetros_Set*, *n_training_pairs_set*, e *instrução_set*; e como saída, os melhores grafos (melhores cromossomos do procedimento proposto acima) apresentados após o processo de evolução desenvolvido nesta pesquisa.

Na Tabela 1 são demonstrados os operadores morfológicos e lógicos utilizados pelo procedimento evolutivo modificado proposto. Os IDs (Identificações na tabela) correspondem aos *Opcodes* (códigos de operação dos nós do gráfico de aplicação a serem explicados abaixo) utilizados pelo procedimento evolutivo modificado. Alguns operadores requerem apenas um argumento, como os morfológicos e o *nop* (Sem Operação). Outros requerem dois argumentos, como os aritméticos. Por exemplo, o operador *nop* (utilizado como *bypass*) tem aridade 1 e apenas faz uma cópia da imagem da entrada para a saída de seu respectivo nó no grafo. Como outro exemplo de operador de aridade 1, podendo-se citar o operador morfológico *dil_c_3* (descrito na tabela 4.1 - 11), que recebe a imagem de entrada de seu respectivo nó e realiza uma dilatação sobre ele por meio de um elemento estruturante de dimensão 3 x 3. E, como último exemplo de operador com aridade 2, pode-se citar o operador *sub* (ver Tabela 4.1 - 2), que realiza uma subtração entre duas imagens de entrada de seus respectivos nós e copia o resultado para sua respectiva saída. As outras operações na Tabela 4.1 são autoexplicativas.

Na Tabela 4.2 são apresentados os parâmetros necessários para o correto funcionamento do referido procedimento para os processos de treinamento e teste. O conjunto *n_training_pairs_set* criado no módulo *Folds*, conforme mencionado acima, contém pares de imagens de treinamento (original (*img_in_tr*) + destino (*img_in_tg_tr*)), onde, a imagem original pode ser uma imagem binária ou em tons de cinza, com resolução de 194 x 174 *pixels* e, a imagem alvo, também uma imagem binária ou em tons de cinza, contendo objetos de interesse como visto na Figura 4.1.5 - Módulo de *Folds* - canto superior direito. O conjunto de parâmetros de trabalho utilizado pelo algoritmo proposto, *Parameters_Set*, contém: *Ni*: tamanho da população; *L*: comprimento do cromossomo (número de genes); *Ng*: número de gerações; *Mt_Rt*: taxa de mutação para

o procedimento genético. Os valores utilizados na Tabela 2 foram fixados após um processo de calibração inicial para extrair os melhores parâmetros em cada cenário para obter o melhor *QoF*, já definido anteriormente.

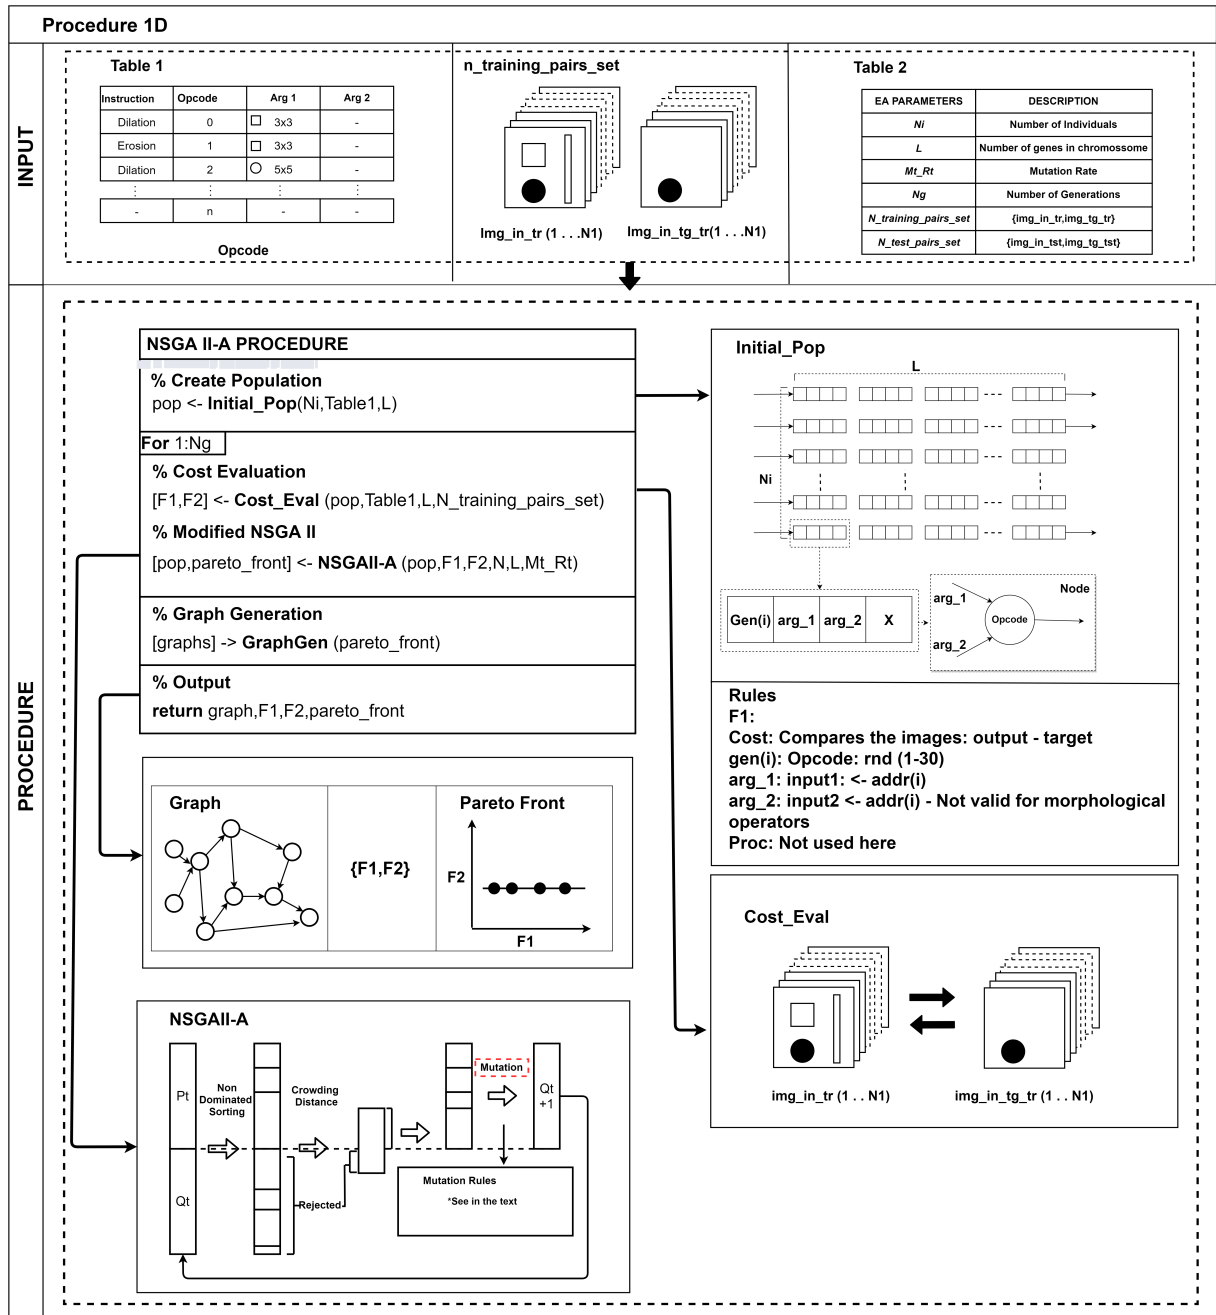


Figura 4.2: Detalhes de implementação do Procedimento_1D descrito no texto.

Na Figura 4.2, há um pseudocódigo detalhado utilizando textos e representações gráficas, contendo todo o fluxo de dados, variáveis e parâmetros do módulo **Procedure_1D**. Assim, ini-

cialmente, uma população inicial de indivíduos (cromossomos contendo as operações de filtro a serem executadas na arquitetura *manycore*), representada por grafos acíclicos direcionados, mencionados acima, é gerada aleatoriamente, dado o número de indivíduos (N_i), os parâmetros, já discutidos acima, na Tabela 4.1, e o comprimento (L) de cada filtro. Nessa Figura, no canto superior direito, é possível visualizar o formato de cada geração e as regras de geração de um determinado indivíduo da população. Cada gene corresponde a um nó do grafo da aplicação, contendo um *Opcode* (instrução a ser executada na arquitetura *manycore*) e dois operandos. O terceiro operando, que corresponde ao processador a ser alocado para o procedimento, não é utilizado nesta primeira parte do código implementado, apenas na segunda, a ser explicada posteriormente. Os dois operandos já mencionados correspondem às saídas de resultados de operações anteriores no grafo atual, não morfológicos, correspondentes às operações lógicas e aritméticas de uma determinada aplicação. Quando houver instruções morfológicas a serem processadas, é necessário especificar apenas o primeiro argumento, pois o segundo já está implícito ao procedimento que está sendo realizado, conforme visto Tabela 4.1.

Após gerar os grafos iniciais da aplicação (*popI*), o próximo passo é avaliar cada um dos indivíduos gerados, com base, principalmente, nas imagens de treinamento já citadas no módulo *Folds*, além dos parâmetros citados na etapa anterior. Assim, para cada indivíduo, o erro absoluto médio é utilizado para avaliar os resultados gerados, comparando-os com os valores desejados, após a aplicação de uma determinada imagem de entrada do conjunto de treinamento (*n_training_pair_set*) (ver a ilustração detalhada de **Cost_Eval** na Figura). A equação 4.1 mostra o cálculo completo, considerando todos os pares de imagens de treinamento envolvidos neste processo. Na equação 4.1, *F1* (*Média_QoF*): qualidade média do filtro) representa a média dos erros das imagens $N1$ comparadas com as imagens alvo do conjunto de treinamento e, *F2*, neste caso, será igual a zero, pois, para esta primeira parte, o algoritmo NSGAI está sendo adaptado para este fim (**NSGAI-A**). Este valor será utilizado na segunda parte da implementação referente ao mapeamento das aplicações para a arquitetura *manycore* já mencionada acima.

$$\begin{cases} F1 = \sum_{i=1}^{N1} abs\left(\frac{img_in_tr_i - img_in_tg_tr_i}{N1}\right) \\ F2 = 0; \end{cases} \quad (4.1)$$

A função **NSGAI-A** é baseada no algoritmo clássico NSGAI proposto por Deb (DEB et al., 2000), salvo uma adaptação em seus operadores genéticos de cruzamento e mutação. O operador de recombinação foi ignorado por meio de um *bypass* para a adaptação proposta e o operador de mutação foi adaptado por um processo de estratégia evolutiva. Assim, segundo o pseudo-código NSGAI-A (Figura 4.3), este processo, a partir de uma probabilidade dada

por Mt_Rt , escolhe um dado $gene_i$ de um $individual_j$ de pop_k , alterando seus operadores e operandos, aleatoriamente, conforme o domínio de possíveis soluções da Tabela 4.1 e as regras da Figura 4.2. Os demais parâmetros de entrada ($F1$, $F2$, N , e L), já citados acima, são utilizados pela função principal do NSGAI para ordenar as fronteiras de Pareto da abordagem original, retornando uma nova população com melhor qualidade ao final deste processo evolutivo, além do $Pareto_Front_ID$, neste caso $F2=0$, que permitem ao usuário escolher o melhor filtro.

A função **Graph_Gen** é responsável por gerar o gráfico selecionado pelo usuário de **Pareto_Front**. O procedimento também classifica todos os indivíduos gerados neste processo, conforme visto no canto superior direito da Figura 4.1, com base em sua *QoF métrica*, em cada *Fold* do conjunto de treinamento, conforme discutido acima.

4.1.4 Módulo de Testes

O Módulo de testes contém os seguintes parâmetros de entrada: parâmetros das Tabelas 4.1 e 4.2, conforme sobredito, o conjunto de imagens de teste $n2_testing_pairs_set$ e os dez principais cromossomos do módulo de treinamento (representados por grafos), discutidos anteriormente. Como já mencionado na seção *Folds*, $N2$ é igual a 10, correspondendo a 10 pares de imagens de teste com origem e destino, selecionadas aleatoriamente do conjunto original de imagens de entrada (N). Em sua saída, os dez indivíduos inscritos serão classificados pela métrica *QoF*, também já mencionada, pelo procedimento. Assim, o melhor filtro (**Best Chromosome**) será utilizado para o módulo de mapeamento, detalhado na próxima seção. Por fim, o procedimento de classificação é dado pela Equação 4.1, dadas as imagens do conjunto de teste. Mais informações relacionadas às estatísticas utilizadas nos testes serão discutidas no Capítulo 5.

4.1.5 Módulo de Mapeamento

O módulo Mapeamento distribui as tarefas da aplicação (Filtros Morfológicos) de forma inteligente, em uma arquitetura *manycore* previamente selecionada, para obter um mapeamento energeticamente eficiente, resiliente e de alto desempenho.

O módulo do sistema de mapeamento de filtros morfológicos para arquiteturas *manycore*, proposto nesta tese, tem como entradas: o melhor cromossomo (melhor *QoF*) do módulo de teste, o melhor algoritmo a ser selecionado pelo usuário para treinamento, sendo que o melhor, para uma dada aplicação, é escolhido a partir de um experimento a ser discutido no Capítulo 5, com os parâmetros genéticos necessários para a operação do referido procedimento (Tabela

5.5). Como resultado de saída, tem-se uma superfície de Pareto 3D (Figura 4.1), através da qual o usuário pode escolher o melhor mapa de compromisso para o *manycore*, para a aplicação de filtragem morfológica dada, no que diz respeito à otimização das seguintes métricas: Energia, Tolerância a falhas de núcleos e Comunicação, definidos pela função de custo do Algoritmo I (Figura 4.3).

Para melhor descrever como funciona o procedimento de mapeamento das aplicações, é preciso tomar como base o algoritmo I (Figura 4.3); as funções marcadas em negrito são o *kernel* para o correto funcionamento do procedimento de mapeamento; a função **Create_Pop**, descrito na Figura 4.4, tem como objetivo principal a geração aleatória de uma população conforme o tamanho N_i , com cada indivíduo codificado da seguinte forma: $Pop_i = [T_1, P_1, T_2, P_2, \dots, T_n, P_n]$, $n = 1..size(GRAPH)$, T (Application Tasks (Image Filter) e P (Processadores alocados no *grid manycore* (Grid)).

```

Manycore Mapping Procedure


---


INPUT: Pop, Grid, GRAPH (S,T), Mt_Rt
OUTPUT: PARETO (F1, F2, F3)

% Create initial population
[Pop] ← Create Pop (Ni, Pop, GRAPH)
FOR L:Size(NGer)
% Calculate Costs
FOR i:Size(Pop)
  [Idle Active] = Status (Popi, Grid)
  FOR j:Size(Idle)
    FOR k:Size(Active)
      [FTik] = Distance ([Idlej]-[Activek])
    END
  END
  F1i=Max(Min(FTik)) % Fault Tolerance
  FOR j:Size(GRAPH)
    [posSX, PosSY]=Position (S_Procj) % Source Processor Position
    [posTX, PosTY]= Position (T_Procj) % Target Processor Position

    [Energyi]= XY_Routing (posSX, PosSY, posTX, PosTY,Grid,Popi)
    [Communicationi]= Communication (posSX, PosSY, posTX, PosTY,Grid,Popi)
  END
  F2i=SUM(Energyi) % Energy Cost
  F3i=SUM(Communicationi) % Communication
END
% Multiobjective procedure
[PopL+1,F1L+1,F2L+1,F3L+1]=MOEA(PopL,F1,F2,F3,Mt_Rt)
END
Pareto=[F1,F2,F3]
RETURN Pareto, Pop

```

Figura 4.3: Pseudo código que representa o procedimento MOEA-A .

A função **STATUS** determina o relacionamento entre todas as tarefas alocadas e não alocadas em processadores específicos usando o (Pop_i), que representa um dos indivíduos contidos

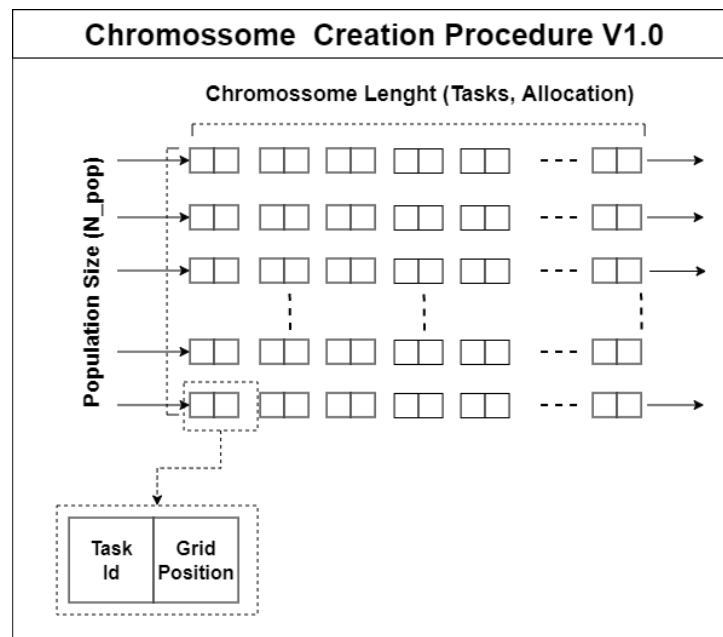


Figura 4.4: Procedimento utilizado para criação da população.

na população e o *grid* da arquitetura *manycore* correspondente (*Grid*), retornando assim, as tarefas que foram alocadas (Ativas) e os processadores que estão em estado ocioso (*Idle*); esta função será uma parte crucial do procedimento de tolerância a falhas.

As seguintes funções são responsáveis pelos cálculos de custos do procedimento de mapeamento: Tolerância a Falhas, Energia e Comunicação; a função **Distance** tem o papel de determinar a distância entre todos os processadores (*Idle* e *Active*) para determinar a tolerância a falhas de uma determinada aplicação usando a distância Manhattan (SINWAR; KAUSHIK, 2014); este procedimento funciona da seguinte forma: primeiro são obtidas as menores distâncias entre todos os processadores (*Idle*) em relação a cada processador (*Active*); e, por fim, determina-se a distância global mais significativa necessária para que um processador em estado ocioso seja migrado para um processador ativo.

A função **Distance** calcula, para cada nó Ativo, a distância Manhattan do nó ocioso mais próximo. Uma grade de R linhas e C colunas é usada para representar a localização física de cada nó indicado pela tupla, (r, c) , que representa a linha r e a coluna c do nó em relação ao canto superior esquerdo da grade. A equação 4.2, então, retorna a maior distância entre qualquer nó ativo e seu nó ocioso mais próximo.

$$FT(r, c) = \text{Max}(\text{Min}(|(\text{active}_r - \text{idle}_r)| + |(\text{active}_c - \text{idle}_c)|)) \quad (4.2)$$

A função **XY Routing** visa percorrer os *links* (caminhos percorridos entre os nós da ar-

quitetura *manycore*), entre dois processadores com tarefas alocadas que se comunicam entre si. Este procedimento é usado para determinar a energia necessária para tal comunicação. As tuplas Origem (S_Proc_i) e Destino (T_Proc_i) usadas como balizadores para o método, usando o método de roteamento XY (CHAWADE; GAIKWAD; PATRIKAR, 2012) como um caminho de deslocamento no referido *Grid*. Contando o número de enlaces ativos, tal abordagem é utilizada para quantificar a energia utilizada por uma determinada aplicação (*GRAPH*), utilizando uma modificação da métrica Bit Energy (HU; MARCULESCU, 2005) como base.

$$Energy = \sum_{i=0}^G |(S_Proc(i))_r - T_Proc(i))_r| + |(S_Proc(i))_c - T_Proc(i))_c| \quad (4.3)$$

Além disso, é utilizada a função **Communication**, que objetiva quantificar o número de comunicações ($TComm$) que ocorre em cada um dos caminhos percorridos no *grid manycore*, com base na tupla [S, T] contida no grafo de aplicação, usando-o como base para o deslocamento entre *cores* o algoritmo de roteamento XY. Finalmente, quando o processo termina, as comunicações internas de cada um dos processadores com as tarefas alocadas ($TComp$) são somadas e o tempo crítico de comunicação daquela aplicação (*GRAPH*) é retornado (equação 4.4).

$$T_{tot} = \mathbf{Max}(T_{comp}_i + T_{net}_i : i \in P) \quad (4.4)$$

O procedimento MOEA-A (Multiobjective Evolutionary Algorithm - A) é utilizado para aplicar um algoritmo multiobjetivo específico a um determinado problema. Como já mencionado, este procedimento foi adaptado, para ser mais simples, utilizando apenas um novo tipo de procedimento de mutação, sem o uso de uma operação de cruzamento, sendo comumente utilizada neste cenário. Este procedimento tem como parâmetros de entrada: os custos (Tolerância a Falhas, Energia, Comunicação e Taxa de Mutação (Mt_Rt)), com os procedimentos evolutivos sendo executados conforme o algoritmo selecionado, retornando a população evoluída ($PopL + 1$) e seus respectivos custos ($F1_L + 1$ (Tolerância a Falhas), $F2_L + 1$ (Energia) e $F3_L + 1$ (Comunicação)).

A otimização multiobjetivo do mapeamento é a parte mais computacionalmente intensiva do conjunto de ferramentas utilizadas no referido procedimento. Com o objetivo de identificar o MOEA mais eficaz para a tarefa, realizou-se um conjunto de experimentos em grafos sintéticos. O algoritmo de melhor desempenho foi então usado em experimentos explorando duas aplicações do mundo real (análise de PCB e detecção de plantas petrolíferas).

No Capítulo 5 são apresentados os resultados referentes a metodologia supramencionada.

4.2 *Framework* autoadaptativo para mapeamento de aplicações em arquiteturas *manycore*

O objetivo deste capítulo é demonstrar a metodologia utilizada para criar um *framework* com evolução autoadaptativa para mapeamento de aplicações em arquiteturas *manycore*. As interconexões e o funcionamento de cada um dos módulos serão detalhados descritivamente. Sempre que possível, serão apresentados exemplos práticos dos cálculos efetuados e/ou avaliação de funções existentes em cada um dos módulos do referido *framework* autoadaptativo ilustrado na Figura 4.5.

4.2.1 Módulo de Entradas

O módulo de entradas é responsável por armazenar e distribuir as informações referentes ao procedimento posterior (Módulo Autoadaptativo Multiobjetivo), sendo assim, existe um submódulo denominado TGFF, onde é utilizado o gerador de grafos TGFF (DICK; RHODES; WOLF, 1998). Pode-se notar três módulos internos denominados: 20-30, 40-60, 70-90, cada uma dessas classes representa o intervalo de valores de possíveis tamanhos de grafos contidos em cada um dos submódulos referidos. Os grafos são gerados por meio de um arquivo de configuração (Figura 4.6), onde:

- A primeira linha deste arquivo contém o comando **tg_cnt 3**, o qual corresponde ao número de grafos que serão gerados pelo procedimento. Já, o comando **task_cnt 30** indica que os gráficos de tarefas devem conter, em média, 30 tarefas. É importante destacar que o primeiro número representa o valor médio (30) e o segundo número representa o intervalo de variação (+/- 2).
- Os grafos podem variar além dos parâmetros mencionados anteriormente, por dependerem de outros valores que podem influenciar no cálculo de ligações e tamanho. Por exemplo, o comando **period_mul** é responsável pela correlação das ligações entre os grafos.
- Também é importante destacar o comando **task_degree 4 3**, utilizado para indicar o número máximo de arcos de entrada e saída que uma tarefa pode ter. No exemplo apresentado na Figura 4.6, as tarefas podem ter até quatro arcos de entrada e três de saída.
- Deve-se prestar atenção em dois comandos que possuem uma relação mais complexa com a geração dos grafos. O comando **period_laxity** representa a tolerância existente na




Figura 4.5: Framework autoadaptativo proposto.

relação entre os prazos de sincronismo. O valor padrão utilizado pelo programa é definido como (1,0), ou seja, o período a ser definido para o grafo da tarefa a ser gerado é igual ao maior prazo existente em toda a configuração relacionada a tempo. Já, o comando **period_mul** é utilizado para determinar o relacionamento periódico entre os grafos de tarefas a serem obtidos pelo procedimento. No exemplo apresentado, os valores (1, 0,5 e 2) atribuídos aos comandos indicam que existe uma razão de 1:0,5:2 entre os períodos

relacionados aos grafos a serem gerados pelo procedimento realizado pelo TGFF.

Um exemplo de grafo gerado a partir do arquivo de configuração mencionado é anteriormente apresentado na Figura 4.6. Além disso, a Figura 4.7 apresenta um exemplo de arquivo de saída para este exemplo, enquanto a Figura 4.8 exibe uma representação gráfica do arquivo de saída gerado a partir do arquivo de configuração mostrado na Figura 4.6.

```
tg_cnt 3
task_cnt 30 2
task_degree 4 3
period_laxity 1
period_mul 1, 0.5, 2
tg_write
eps_write
vcg_write

table_label COMMUN
table_cnt 3
table_attrib price 80 20
type_attrib exec_time 50 20
trans_write
```

Figura 4.6: Exemplo de um arquivo de configuração utilizado no TGFF.

Para o presente experimento, foi definido um tamanho nG (Número de Grafos) igual a 10. Isso significa que existem 10 grafos de aplicação para cada uma das configurações de tamanho mencionadas anteriormente (10-20 $nTar$ (Número de Tarefas), 40-60 $nTar$, 70-90 $nTar$).

Essa configuração foi escolhida para melhor compor a distribuição de tarefas nos tamanhos de *grids* descritos na Tabela 4.3: 4 x 4, totalizando 16 elementos de processamento (PE); 6 x 6, totalizando 36 elementos de processamento; e 8 x 8, totalizando 64 elementos de processamento. Dessa forma, pode-se contemplar duas importantes características dos sistemas de mapeamento *manycore*: a capacidade de mapear tarefas com composição de elementos de processamento maior que o número de tarefas ($PE > nTar$) e a capacidade de mapear tarefas em que a composição de elementos de processamento é menor que o número de tarefas ($nTar > PE$).

No presente módulo, também é possível encontrar um distribuidor selecionável (*multiplex*), responsável por selecionar o conjunto de grafos que serão direcionados ao procedimento realizado pelo módulo posterior de mapeamento multiobjetivo autoadaptativo. A configuração desse seletor é feita pelo arquivo de configuração principal, que contém a Tabela de Parâmetros 4.3 e a Tabela 4.4, relacionada aos algoritmos que serão utilizados durante o procedimento.

```

@TASK_GRAPH 0 {
  PERIOD 1300

  TASK t0_0  TYPE 19  ARC a0_0  FROM t0_0  TO  t0_1  TYPE 0
  TASK t0_1  TYPE 1   ARC a0_1  FROM t0_0  TO  t0_2  TYPE 42
  TASK t0_2  TYPE 12  ARC a0_2  FROM t0_1  TO  t0_2  TYPE 9
  TASK t0_3  TYPE 3   ARC a0_3  FROM t0_2  TO  t0_3  TYPE 16
  TASK t0_4  TYPE 9   ARC a0_4  FROM t0_2  TO  t0_4  TYPE 20
  TASK t0_5  TYPE 17  ARC a0_5  FROM t0_2  TO  t0_5  TYPE 28
  TASK t0_6  TYPE 11  ARC a0_6  FROM t0_5  TO  t0_6  TYPE 44
  TASK t0_7  TYPE 10  ARC a0_7  FROM t0_5  TO  t0_7  TYPE 35
  TASK t0_8  TYPE 3   ARC a0_8  FROM t0_5  TO  t0_8  TYPE 36
  TASK t0_9  TYPE 6   ARC a0_9  FROM t0_6  TO  t0_9  TYPE 32
  TASK t0_10 TYPE 19  ARC a0_10 FROM t0_4  TO  t0_9  TYPE 11
  TASK t0_11 TYPE 9   ARC a0_11 FROM t0_3  TO  t0_9  TYPE 28
  TASK t0_12 TYPE 1   ARC a0_12 FROM t0_7  TO  t0_10 TYPE 39
  TASK t0_13 TYPE 6   ARC a0_13 FROM t0_6  TO  t0_10 TYPE 44
  TASK t0_14 TYPE 1   ARC a0_14 FROM t0_8  TO  t0_10 TYPE 38
  TASK t0_15 TYPE 3   ARC a0_15 FROM t0_4  TO  t0_10 TYPE 11
  TASK t0_16 TYPE 7   ARC a0_16 FROM t0_1  TO  t0_11 TYPE 25
  TASK t0_17 TYPE 3   ARC a0_17 FROM t0_6  TO  t0_11 TYPE 22
  TASK t0_18 TYPE 7   ARC a0_18 FROM t0_10 TO  t0_11 TYPE 12
  TASK t0_19 TYPE 5   ARC a0_19 FROM t0_0  TO  t0_12 TYPE 42
  TASK t0_20 TYPE 16  ARC a0_20 FROM t0_4  TO  t0_12 TYPE 28
  TASK t0_21 TYPE 15  ARC a0_21 FROM t0_3  TO  t0_12 TYPE 33
  TASK t0_22 TYPE 7   ARC a0_22 FROM t0_8  TO  t0_12 TYPE 11
  TASK t0_23 TYPE 2   ARC a0_23 FROM t0_11 TO  t0_13 TYPE 30
  TASK t0_24 TYPE 5   ARC a0_24 FROM t0_11 TO  t0_14 TYPE 1
  TASK t0_25 TYPE 8   ARC a0_25 FROM t0_13 TO  t0_15 TYPE 18
  TASK t0_26 TYPE 5   ARC a0_26 FROM t0_12 TO  t0_16 TYPE 28
  TASK t0_27 TYPE 18  ARC a0_27 FROM t0_14 TO  t0_17 TYPE 49
  TASK t0_28 TYPE 5   ARC a0_28 FROM t0_1  TO  t0_18 TYPE 47
  TASK t0_29 TYPE 8   ARC a0_29 FROM t0_15 TO  t0_18 TYPE 18
  TASK t0_30 TYPE 2   ARC a0_30 FROM t0_16 TO  t0_19 TYPE 48

  ARC a0_31 FROM t0_18 TO  t0_20 TYPE 35
  ARC a0_32 FROM t0_20 TO  t0_21 TYPE 46
  ARC a0_33 FROM t0_20 TO  t0_22 TYPE 34
  ARC a0_34 FROM t0_22 TO  t0_23 TYPE 5
  ARC a0_35 FROM t0_22 TO  t0_24 TYPE 2
  ARC a0_36 FROM t0_22 TO  t0_25 TYPE 46
  ARC a0_37 FROM t0_19 TO  t0_26 TYPE 42
  ARC a0_38 FROM t0_17 TO  t0_27 TYPE 39
  ARC a0_39 FROM t0_19 TO  t0_28 TYPE 11
  ARC a0_40 FROM t0_13 TO  t0_28 TYPE 31
  ARC a0_41 FROM t0_18 TO  t0_29 TYPE 42
  ARC a0_42 FROM t0_15 TO  t0_29 TYPE 45
  ARC a0_43 FROM t0_9  TO  t0_29 TYPE 45
  ARC a0_44 FROM t0_13 TO  t0_29 TYPE 18
  ARC a0_45 FROM t0_14 TO  t0_30 TYPE 25
  ARC a0_46 FROM t0_10 TO  t0_30 TYPE 25

```

Figura 4.7: Exemplo de um arquivo de saída resultante do procedimento realizado no TGFF, representando um dos três grafos configurados para serem gerados, onde: *Task* representa as tarefas e seus respectivos pesos de computação contida no grafo em tela e *Arc* representa as ligações entre as tarefas e seus respectivos custos de comunicação.

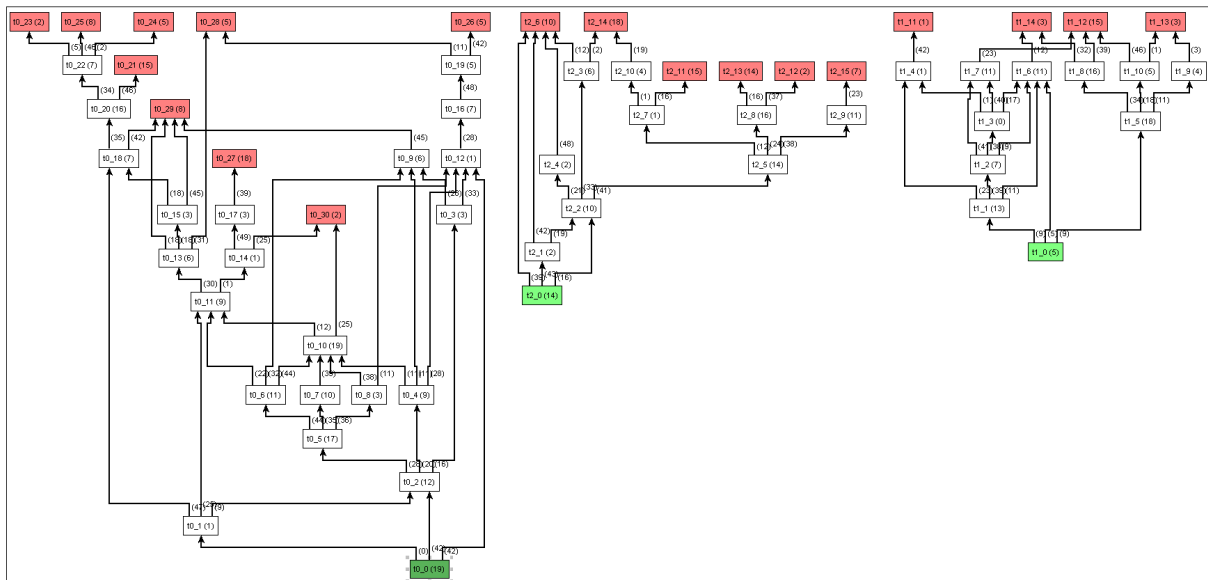


Figura 4.8: Representação gráfica de um arquivo de saída resultante do procedimento realizado no TGFF, representando um dos três grafos configurados para serem gerados.

Além disso, no presente módulo é possível visualizar outro distribuidor selecionável, responsável pela distribuição dos grafos contidos em cada um dos três submódulos do módulo TGFF. Essa distribuição é controlada pelo arquivo de configuração que contém a sequência de experimentos a serem realizados, conforme mencionado anteriormente.

Tabela 4.3: Parâmetros utilizados no procedimento de mapeamento autoadaptativo.

EA Parâmetros	Descrição
<i>Routing Type</i>	XY
<i>Grid Size</i>	4x4,6x6,8x8
<i>Generations</i>	10000,20000,50000
<i>Population</i>	100

Tabela 4.4: Algoritmos utilizados no procedimento de mapeamento auto adaptativo.

Algoritmos	Referências
<i>NSGA II</i>	(DEB et al., 2000)
<i>NSGA III</i>	(DEB; JAIN, 2013)
<i>SPEA 2</i>	(ZITZLER; LAUMANN; THIELE, 2001)
<i>PESA II</i>	(CORNE et al., 2001)
<i>KnEA</i>	(ZHANG; TIAN; JIN, 2014)

4.2.2 Módulo de Mapeamento Multiobjetivo.

Geração da População Inicial

A população inicial utilizada pelo módulo MOEA autoadaptativo é gerada utilizando os seguintes parâmetros: o conjunto de grafos selecionados e enviados para o procedimento, sendo que cada um contém 10 grafos gerados em diferentes tamanhos (20-30, 40-60, 70-90), obtidos conforme procedimento descrito na Seção 4.2.1; o tamanho da população (Pop_{sz}) e o tamanho do *Grid* a ser avaliado durante o procedimento. Esses parâmetros podem ser encontrados na Tabela 4.3. Dessa forma, a população inicial é gerada da seguinte maneira:

- A partir de um grafo (convertido para um formato compatível com a ferramenta no procedimento realizado na seção anterior), é extraído o número de tarefas ($Task_n$).
- Com base no tamanho do *Grid* ($Grid_{sz}$), é calculado o número de processadores disponíveis para a execução do procedimento de mapeamento. Por exemplo, no *Grid* (4x4), existem 16 elementos de processamento (PE_n) disponíveis.
- O tamanho da população (Pop_{sz}) é utilizado para determinar o número de indivíduos que serão criados nessa etapa.

Com base em todos os elementos acima mencionados, o procedimento inicia a criação da população inicial da seguinte forma: o cromossomo é gerado com base no número de elementos de processamento ($PE_1, PE_2, PE_3, \dots, PE_{PE_n}$) e no número de tarefas a serem mapeadas ($Task_1, Task_2, Task_3, \dots, Task_{Task_n}$). Dessa forma, os cromossomos ($[Task_1, PE], [Task_2, PE], [Task_3, PE], \dots, [Task_{Task_n}, PE]$) são formados, em que os elementos

de processamento PE são inseridos de forma randômica em cada uma das tarefas, da seguinte maneira: $rand(n = 1..size(PE_n))$. Por fim, é utilizado o tamanho da população (Pop_{sz}) para indicar quantos cromossomos deverão ser gerados para a formação da população, conforme demonstrado na Figura 4.9.

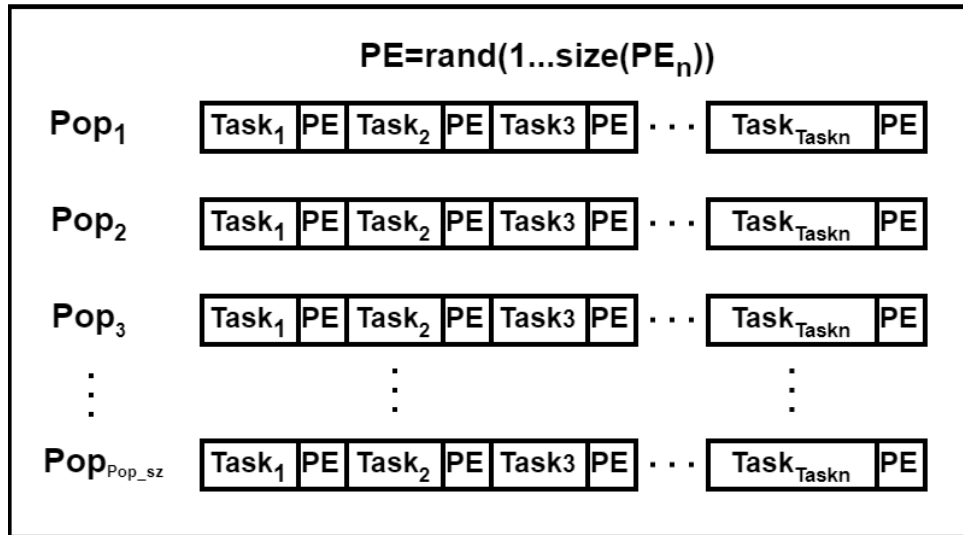


Figura 4.9: Representação da criação da população inicial com base nos cromossomos gerados e tamanho da população.

Critério de Término do Algoritmo

O presente submódulo tem como função avaliar se o critério de término do algoritmo foi alcançado. Ele verifica se o número de iterações ($Iter_n$) é menor que o número de *Evaluations* ($Eval_n = Pop_{sz} \times$ número de gerações (Ger_n)). Caso o número de iterações seja menor, o procedimento de mapeamento é continuado. Caso contrário, o procedimento é encerrado e os resultados são enviados ao módulo de armazenamento, onde serão posteriormente armazenados de forma hierárquica.

Módulo de Cálculo de Custo

O presente submódulo tem como principal função calcular os valores resultantes de cada uma das métricas de custo a serem utilizadas durante o procedimento de mapeamento, que são: Tolerância a Falhas, Energia, Balanceamento de Carga e Comunicação.

A função relacionada à Tolerância a Falhas ($Ftol$) é responsável por quantificar a máxima distância que um elemento de processamento defeituoso pode ter em relação a um elemento de processamento em modo de espera (*Idle*), tendo como base o *GRID* de migração.

A função relacionada à Energia (*Energy*) identifica o consumo energético de uma determinada aplicação com base no número de canais físicos utilizados por essa aplicação durante sua

execução.

A função de balanceamento de carga (*Load Balance*) tem como objetivo identificar a distribuição equânime de tarefas em relação ao número de elementos de processamento disponíveis para o procedimento em questão. Esse balanceamento pode estar relacionado à dissipação de calor pela superfície do *chip* que contém a arquitetura *manycore*.

Por fim, a função de Comunicação (*Comm*) é responsável por mensurar a máxima comunicação que ocorre durante a execução de uma determinada aplicação, evidenciando um critério limitante à execução de tarefas em arquiteturas *manycore* que executam tarefas serialmente.

Cada uma dessas funções será definida com mais detalhes a seguir:

Tolerância a Falhas

A função de tolerância a falhas é uma métrica que tem como objetivo calcular o custo necessário para migrar uma tarefa alocada em um elemento de processamento com falha para um elemento de processamento em espera mais próximo. A função retorna o valor do maior caminho necessário para realizar a migração da tarefa.

Para cada nó ativo (com tarefas alocadas), é calculada a distância de Manhattan (SINWAR; KAUSHIK, 2014) para cada um dos nós ociosos, a fim de encontrar a menor distância de migração, ou seja, obter a distância do nó, em espera, mais próximo ao nó ativo. Um *Grid* de R linhas e C colunas é usado para representar a localização física de cada nó, indicado pela tupla (r, c), que representa a linha r e a coluna c do nó em relação ao canto superior esquerdo da grade.

A Equação 4.5 retorna a maior distância entre qualquer nó ativo e seu nó ocioso mais próximo.

$$FT(r, c) = \text{Max}(\text{Min}(|(active_r - idle_r)| + |(active_c - idle_c)|)) \quad (4.5)$$

Como forma de representar melhor o cálculo, é apresentado na Figura 4.10 um exemplo prático da aplicação da função de tolerância a falhas. O cálculo ocorre da seguinte maneira:

A posição se refere à localização espacial (linha e coluna) de cada elemento de processamento no Grid, que é definido pelo número de linhas e colunas. No caso específico da arquitetura *manycore* em questão, o Grid tem tamanho 3x3 e é numerado a partir do canto inferior esquerdo. Assim, o elemento de processamento localizado na linha 1 e coluna 1 é numerado como posição 1, enquanto o elemento de processamento localizado na linha 3 e coluna 3 é

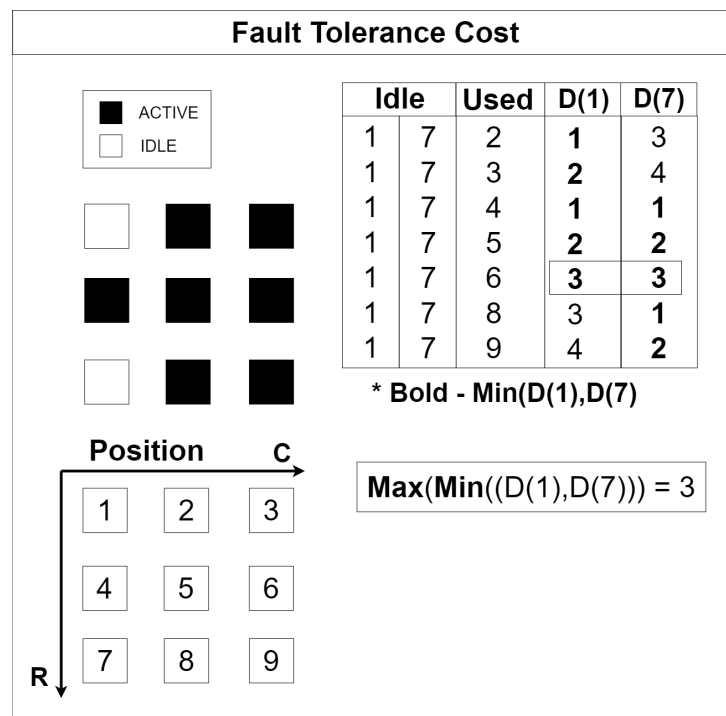


Figura 4.10: Exemplo prático do cálculo efetuado pela métrica de tolerância a falhas, conforme apresentado na Equação 4.5.

numerado como posição 9.

Na Figura 4.10, no canto superior esquerdo, é possível ver os elementos de processamento com tarefas alocadas (2, 3, 4, 5, 6, 8, 9) e os elementos de processamento sem tarefas alocadas (1, 7). O procedimento de balanceamento de carga é mostrado em detalhes no canto superior direito, onde todos os elementos de processamento ativos são comparados em relação à distância com todos os elementos de processamento em estado de espera. A distância entre elementos de processamento é medida usando a distância Manhattan.

Um exemplo de cálculo de distância pode ser visto entre os elementos de processamento 1 (em estado de espera) e 9 (em estado ativo). A distância para migrar uma tarefa do elemento 9 para o elemento 1 é de 4 saltos (9-6, 6-3, 3-2, 2-1).

Após o cálculo das distâncias, é selecionado o menor valor necessário para que uma tarefa seja migrada para um elemento de processamento em estado de espera. Por exemplo, o elemento de processamento 3 (em estado ativo) tem dois possíveis elementos para os quais uma tarefa pode ser migrada (1 e 7), com distâncias de migração de 2 e 4, respectivamente. O menor caminho de migração é escolhido, nesse caso, como sendo a distância de 2 para o elemento de processamento 1.

Os resultados em negrito na Figura 4.10 representam as menores distâncias necessárias para

a migração de cada um dos elementos de processamento em estado ativo (com tarefas alocadas).

Por fim, o procedimento calcula o maior valor (caso crítico) necessário para que uma tarefa seja migrada de um elemento de processamento ativo, que sofra uma falha, para um elemento de processamento em estado ocioso. No exemplo apresentado, os valores de distância são (1, 2, 1, 2, 3, 1, 2). Ao final do procedimento, o valor de distância 3 (conforme destacado na Figura 4.10) é a métrica de tolerância a falhas calculada para esse exemplo prático.

Energia

A função que calcula a energia utilizada por uma dada aplicação baseada em grafo (G), com base na métrica descrita na Equação 4.6, tem como principal função quantificar o número de caminhos percorridos (*links*) durante a execução de uma determinada aplicação, ou seja, caso a tarefa 1 esteja alocada em um elemento de processamento no *grid* contido na arquitetura *many-core*, e esta tarefa se comunica com a tarefa 4, alocada em outro elemento de processamento, a função visa determinar quantos *links* foram necessários para que esta comunicação ocorra. Este procedimento é utilizado para determinar a energia necessária para tal comunicação, as tuplas Origem (S_Proc_i) e Destino (T_Proc_i) são utilizadas como referências para o método, usando o método de roteamento XY (CHAWADE; GAIKWAD; PATRIKAR, 2012), sendo esta uma modificação da métrica *Bit Energy* (HU; MARCULESCU, 2005).

$$Energy = \sum_{i=0}^G |(S_Proc(i))_r - T_Proc(i))_r| + |(S_Proc(i))_c - T_Proc(i))_c| \quad (4.6)$$

De modo a melhor contextualizar o método de cálculo utilizado pela métrica energia, será apresentada na Figura 4.11, uma representação gráfica como base de um exemplo de cálculo da referida métrica.

No exemplo apresentado na Figura 4.11, o canto inferior direito mostra o *grid* que representa uma arquitetura manycore com 9 elementos de processamento dispostos em uma malha 3 x 3. A localização espacial de cada elemento é mostrada, por exemplo, o elemento 5 está localizado na posição (2,2), usando as linhas (R) e colunas (C), respectivamente. No canto superior direito, há uma representação de um grafo de aplicação (G). As tarefas nesse grafo de aplicação foram alocadas aleatoriamente e a alocação é mostrada no canto superior esquerdo, como (Posição, Tarefa): (1,T4 2,T7 3,T1 4,T6 5,T5 6,X 7,T3 8,X 9,T2).

Observação: O X indica uma posição sem tarefa alocada.

No canto inferior direito da figura, há uma tabela com as representações de s (source) e t

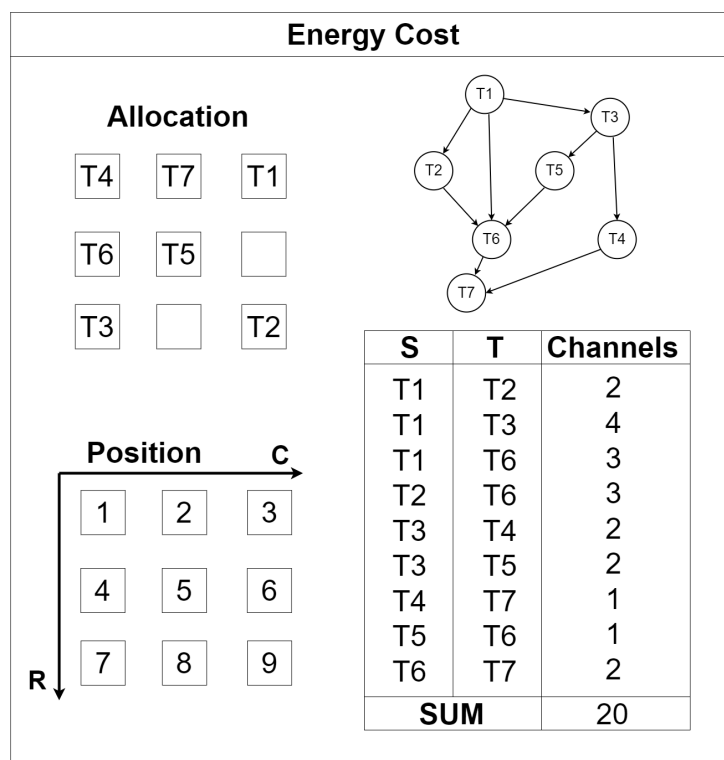


Figura 4.11: Exemplo prático do cálculo efetuado pela métrica de energia, conforme apresentado na Equação 4.6.

(target), que representam as conexões existentes no grafo de aplicação (G), ou seja, as comunicações entre as tarefas no grafo. Por exemplo, na primeira linha da tabela (T1 se comunica com T2), pode-se ver que T1 está alocado na posição 3 e T2 está alocado na posição 9. Usando o algoritmo de roteamento XY para quantificar o deslocamento, são contabilizados 2 links de comunicação (3-6,6-9). Esse cálculo é feito para todas as conexões no grafo de aplicação (G). Finalmente, a soma de todos os links utilizados pelo grafo de aplicação (G) é realizada, totalizando 20 usos de links, como mostrado na tabela na Figura 4.11.

Balanceamento de Carga

A função de balanceamento de carga é usada para distribuir tarefas entre os processadores de um grid manycore. A métrica usada para avaliar o balanceamento de carga é o número de tarefas alocadas em cada processador durante o procedimento de mapeamento. Após a coleta desses dados, é calculado o desvio padrão em relação à alocação de tarefas.

Comunicação

A métrica de comunicação T_{tot} é calculada com base nas alocações de tarefas que ocorreram durante o processo de mapeamento e no grafo de aplicações (G). Os arcos do grafo de aplicação representam as comunicações que ocorrem entre as tarefas. Para cada um dos arcos de comunicação, é efetuado o seguinte procedimento: se duas tarefas que se comuniquem fo-

rem alocadas no mesmo elemento de processamento, o valor de T_{comm} é considerado nulo. Entretanto, se essas duas tarefas se comunicarem e estiverem alocadas em elementos de processamento distintos, o valor de T_{comm} é calculado como $T_{comm} = T_{net} \times C$, onde T_{net} e C são, respectivamente, o custo de rede e o custo de comunicação. Para aplicações reais, assume-se os valores $T_{net} = 1$ e $C = 1$, enquanto para aplicações sintéticas, assume-se $T_{net} = 4$ e $C = \#$ (tabela de comunicação existente no arquivo gerado pelo TGFF), conforme demonstrado pela Equação 4.7. A quantificação do número de canais de comunicação é efetuada pelo deslocamento ao longo do grid que representa a arquitetura manycore, com base no algoritmo de roteamento XY. Ao final de cada um dos cálculos para obtenção de T_{comm} para cada um dos elementos de processamento, o valor referente a T_{comp} é somado. T_{comp} representa o custo computacional referente a cada uma das tarefas existentes no grafo de aplicação.

$$T_{tot} = \mathbf{Max}(T_{comp_i} + T_{comm_i} : i \in P) \quad (4.7)$$

A comunicação entre as tarefas alocadas no elemento de processamento 2 é representada por uma tabela na Figura 4.12, onde a primeira coluna representa a tarefa de origem (s) e a segunda coluna representa a tarefa de destino (t), os números presentes nas células da tabela representam o número de canais de comunicação necessários para a comunicação entre as tarefas. Por exemplo, para a comunicação entre as tarefas T5 (alocada no elemento de processamento 2) e T1 (alocada no elemento de processamento 1), é necessário o uso de 2 canais de comunicação (célula (1,2) da tabela). Essa tabela é preenchida com base no algoritmo de roteamento XY, que quantifica o número de canais de comunicação necessário para a comunicação entre cada par de tarefas.

Após o cálculo do número de canais de comunicação para cada par de tarefas, o valor de T_{comm} é calculado para cada elemento de processamento. No exemplo dado, o valor de T_{comm} para o elemento de processamento 2 é a soma dos valores de canais de comunicação necessários para as comunicações entre as tarefas alocadas nesse elemento de processamento com as tarefas alocadas em outros elementos de processamento. Esse valor é somado ao valor de T_{comp} para cada tarefa alocada nesse elemento de processamento, resultando no valor total de T_{tot} para esse elemento de processamento.

No elemento de processamento 2, foram alocadas as tarefas T3 e T5. Portanto, analisam-se as comunicações que ocorrem no lado esquerdo do elemento de processamento (T7-T5, T1-T3, T4-T3) = 3 e no lado direito (T5-T6, T3-T6) = 2, totalizando $T_{comm_{p2}} = 5$. Em seguida, soma-se a quantidade de computação necessária para cada uma das tarefas alocadas (T3=9, T5=3), totalizando $T_{comp_{p2}} = 12$. Por fim, efetua-se a soma de $T_{comm_{p2}} + T_{comp_{p2}}$, obtendo-

se $T_{totP2} = 17$. O procedimento acima descrito é realizado para cada um dos elementos de processamento existentes no *grid* referente à arquitetura manycore em estudo. Ao final do processo, é avaliado qual o maior valor de T_{tot} entre todos os elementos de processamento, conforme demonstrado na Equação 4.7. Tal valor representa o tempo crítico de comunicação da aplicação descrita pelo grafo de aplicações (G).

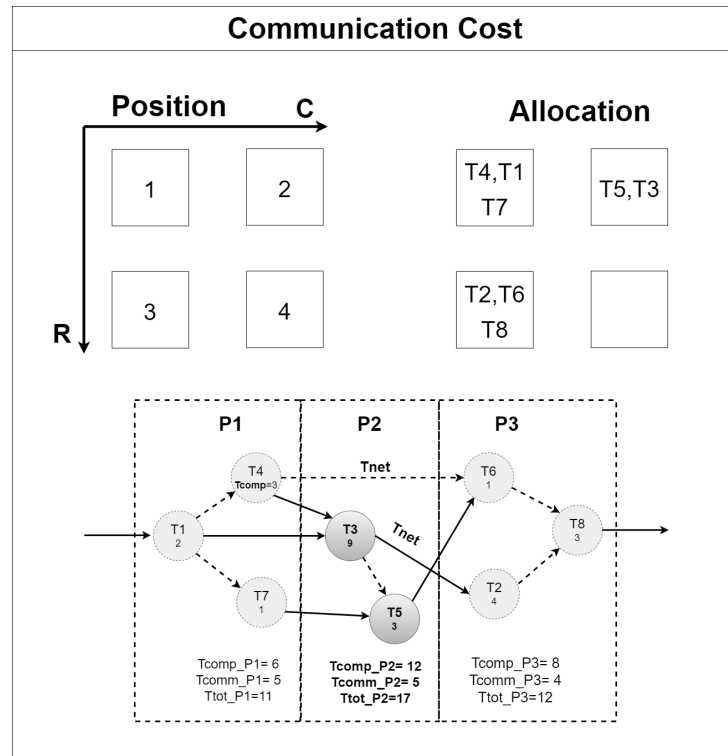


Figura 4.12: Exemplo prático do cálculo efetuado pela métrica de comunicação, conforme apresentado na Equação 4.7.

4.2.3 Módulo Autoadaptativo

O procedimento utilizado, nesta tese, baseia-se nas abordagens propostas por Korejo et al. (2013), Xue et al. (2021) e Xue, Zhu e Neri (2022). Será detalhada a implementação de um método autoadaptativo baseado em um *ensemble* de estratégias de cruzamento selecionáveis, com o objetivo de melhorar a métrica *Hypervolume* (BRINGMANN; FRIEDRICH, 2013).

A cada iteração, uma nova população Pop_{i+1} é gerada a partir da população anterior Pop_i , utilizando operações de mutação e cruzamento. Essas operações permitem encontrar indivíduos mais aptos para a solução do problema em questão. Para isso, serão utilizadas cinco formas de cruzamento: One point (POLI; LANGDON, 1998), Two point (HONGZE; YE; MAOSHENG, 2000), Uniform (SYSWERDA et al., 1989), Two point uniform (KORA; YADLAPALLI, 2017) e Shuffled (UMBARKAR; SHETH, 2015).

O processo para geração da nova população ocorre da seguinte forma: primeiro, é criado um vetor de probabilidades (conforme a Equação 4.8), que fornece ao procedimento de seleção a probabilidade de cada um dos operadores de cruzamento supramencionados. O vetor tem a seguinte forma:

$$P_{Cross} = \left[\frac{1}{CE}, \frac{1}{CE}, \frac{1}{CE}, \frac{1}{CE}, \frac{1}{CE} \right] \quad (4.8)$$

Onde P_{Cross} é o vetor de probabilidades de seleção e CE é o número de estratégias de cruzamentos disponíveis no procedimento. O tamanho do vetor é proporcional a CE .

Em seguida, são inicializados dois vetores responsáveis por armazenar os resultados obtidos por cada uma das estratégias de cruzamento.

$$Penalty = [0 \ 0 \ 0 \ 0 \ 0 \ 0];$$

$$Reward = [0 \ 0 \ 0 \ 0 \ 0 \ 0];$$

O método de seleção de roleta é utilizado para selecionar os indivíduos para a próxima geração, e é comumente usado em algoritmos genéticos. Uma roleta é construída a partir da aptidão relativa de cada indivíduo (ou seja, a razão entre a aptidão individual e a aptidão total da população). A roleta é representada graficamente na forma de um gráfico de pizza, onde a área ocupada por cada indivíduo na roleta é proporcional à sua aptidão relativa (DEY et al., 2019). No entanto, nesta abordagem, o método de roleta é utilizado para selecionar a estratégia de cruzamento a ser utilizada. A roleta recebe o vetor P_{Cross} como entrada para configurar a área ocupada por cada uma das estratégias de cruzamento.

$$Sel = Roulette(P_{Cross})$$

Após a seleção da estratégia de cruzamento, o cruzamento é realizado de acordo com a estratégia escolhida. Abaixo é apresentada uma forma abstrata desta operação:

Seja P_1 e P_2 dois pais selecionados da população Pop_i , e C_1 e C_2 dois filhos gerados a partir dos pais utilizando a estratégia de cruzamento selecionada Sel . Então, o processo de cruzamento pode ser representado da seguinte forma:

$$P_1 = [a_1, a_2, \dots, a_n]$$

$$P_2 = [b_1, b_2, \dots, b_n]$$

Sel = estratégia de cruzamento selecionada

$$C_1, C_2 = Sel(P_1, P_2)$$

$$C_1 = [c_{1,1}, c_{1,2}, \dots, c_{1,n}]$$

$$C_2 = [c_{2,1}, c_{2,2}, \dots, c_{2,n}]$$

onde n é o tamanho dos cromossomos (ou genes) dos pais P_1 e P_2 , e $c_{1,i}$ e $c_{2,i}$ são os genes dos filhos C_1 e C_2 na posição i .

O método proposto avalia a qualidade das novas soluções geradas ($Children_1$ e $Children_2$) por meio de uma métrica simplificada do cálculo do *Hypervolume*, uma vez que essa métrica tem um alto custo computacional para ser executada (GUERREIRO; FONSECA; PAQUETE, 2020). A Figura 4.13 apresenta um exemplo prático da implementação.

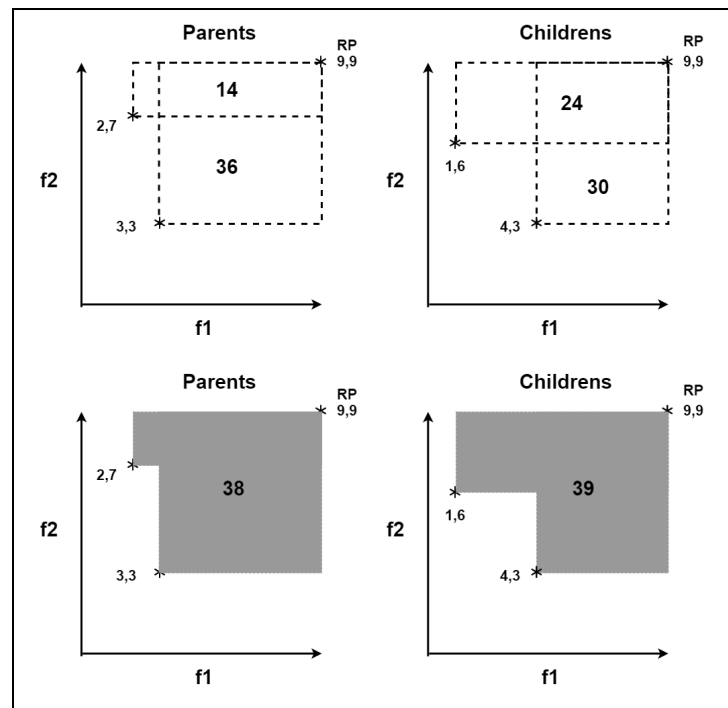


Figura 4.13: Exemplo prático do cálculo simplificado efetuado para obtenção do *Hypervolume* para avaliação da qualidade apresentada pelas novas soluções durante o procedimento de cruzamento.

Na parte superior da Figura 4.13, há a representação de duas soluções: a primeira (canto superior direito) é a solução obtida pelos cromossomos pais ($Parent_1 = [2\ 7]$ e $Parent_2 = [3\ 3]$). São traçados dois retângulos que representam o *hypervolume* de cada uma das soluções. Esses retângulos são traçados usando dois pontos: o ponto relacionado à solução em questão e o $RP = [9\ 9]$ (*Reference Point* - ponto de referência). Em seguida, é demonstrado o valor da área ocupada por cada um dos retângulos ($Parent_1 = 14$ e $Parent_2 = 36$).

Em seguida, o mesmo procedimento é realizado nos cromossomos filhos gerados pela estratégia de cruzamento, resultando nas soluções ($Children_1 = [1\ 6]$ e $Children_2 = [4\ 3]$). Traçando novamente os retângulos usando o mesmo RP, as áreas obtidas foram ($Children_1 = 24$ e $Children_2 = 30$).

Em seguida, é realizada uma operação de união (\cup) entre os retângulos. Na parte inferior da Figura 4.13, os polígonos resultantes da operação de união são mostrados, com a representação da solução obtida pelos cromossomos pais no lado esquerdo e a representação da solução obtida pelos cromossomos filhos no lado direito. As áreas obtidas foram: $Parent_1 \cup Parent_2 = 38$ e $Children_1 \cup Children_2 = 39$.

Dando continuidade ao procedimento, os valores referentes aos vetores *Penalty* e *Reward* devem ser atualizados da seguinte forma:

Para a continuidade do procedimento, os valores referentes aos vetores *Penalty* e *Reward* devem ser atualizados usando a seguinte equação:

$$\Delta HV = HV_{Children_1 \cup Children_2} - HV_{Parent_1 \cup Parent_2}$$

Onde:

ΔHV : diferença entre o *hypervolume* obtido pelas soluções dos cromossomos pais em relação ao *hypervolume* obtido pelas soluções contidas nos cromossomos filhos;

$HV_{Children_1 \cup Children_2}$: *hypervolume* obtido pela solução dos cromossomos filhos;

$HV_{Parent_1 \cup Parent_2}$: *hypervolume* obtido pela solução dos cromossomos pais.

Se o valor de *hyp_{tot}* for **positivo**, a estratégia de cruzamento recebe uma recompensa e o vetor *Reward* é atualizado com o valor de *hyp_{tot}* na posição correspondente à estratégia avaliada.

Se o valor de *hyp_{tot}* for **negativo**, a estratégia de cruzamento recebe uma penalidade e o vetor *Penalty* é atualizado com o valor de *hyp_{tot}* na posição correspondente à estratégia avaliada.

No exemplo mencionado, o valor de $hypervolume(Children_1 \cap Children_2) - hypervolume(Parent_1 \cap Parent_2)$ é igual a 1, o que significa que houve uma recompensa em relação à estratégia de cruzamento selecionada. Supondo que a estratégia de seleção escolhida seja a número 1 ($Sel = 1$), o vetor *Reward* seria atualizado da seguinte maneira: $Reward = [hyp_{tot}\ 0\ 0\ 0\ 0]$, ou seja, $Reward = [1\ 0\ 0\ 0\ 0]$. Esse processo é realizado iterativamente a cada nova seleção de estratégia de cruzamento e geração de novos cromossomos filhos, acumulando o valor *hyp_{tot}* nos vetores *Penalty* e *Reward* de acordo com a seleção da estratégia e análise baseada

Tabela 4.5: Exemplo teórico de cálculo efetuado para obtenção e normalização das probabilidades referentes a cada um das estratégias de cruzamento

MOp	5,00				
PCross	0,20	0,20	0,20	0,20	0,20
Reward	12	15	14	25	48
Penalty	20	8	10	5	2
Eq 4.9	0,38	0,65	0,58	0,83	0,96
Eq 4.10	0,11	0,19	0,17	0,24	0,28
Eq 4.11	0,16	0,20	0,19	0,22	0,24

em recompensa ou penalidade.

A proposta de uma metodologia que utiliza como mecanismo de recompensa e penalidade uma métrica baseada no *Hypervolume* é sugerida devido à grande parte das pesquisas envolvendo otimização multiobjetivo usarem essa métrica para validar e classificar a qualidade de soluções obtidas por procedimentos MOEA.

Ao fim da execução de todas as operações de cruzamento ($Pop/2$) realizadas sobre uma população Pop , gerando uma nova população Pop_{+1} , são calculadas novas probabilidades com base nas penalidades e recompensas recebidas por cada uma das estratégias de cruzamento. Um exemplo de cálculo é demonstrado na Tabela 4.5.

A Tabela 4.5 representa um exemplo para melhor contextualizar o procedimento realizado durante o cálculo, atualização e normalização das probabilidades referentes às estratégias de cruzamento. Nesse exemplo, $CE=5$ é o número de estratégias de cruzamento existentes, e P_{Cross} é definido da seguinte forma: $P_{Cross} = [0.2 \ 0.2 \ 0.2 \ 0.2 \ 0.2]$.

Em seguida, é realizado o cálculo de probabilidades em relação aos vetores *Penalty* e *Reward*, descrito na Equação 4.9, conforme apresentado em (XUE; ZHU; NERI, 2022) e (XUE et al., 2021).

$$P_i = \frac{(Reward_i + \varepsilon)}{(Reward_i + \varepsilon) + Penalty_i} \quad (4.9)$$

Onde i varia de 1 a CE , P é um vetor de probabilidades de cada uma das estratégias de cruzamento, baseado na relação entre os vetores *Reward* e *Penalty*, e CE é o número de operadores de cruzamento disponíveis para avaliação. Para evitar divisões por zero durante a avaliação da Equação 4.9, como proposto por Xue, Zhu e Neri (2022), um pequeno valor é atribuído à variável ε . Neste estudo, ε é igual a 0,001.

A aplicação da Equação 4.9 resulta nos seguintes valores para P : [0.38 0.65 0.58 0.83 0.96],

correspondendo a cada uma das estratégias de cruzamento, respectivamente.

Em seguida, é utilizada a Equação 4.10, descrita por Korejo et al. (2013), para obter as probabilidades normalizadas, de modo que o somatório de todas as probabilidades existentes no vetor P seja igual a 1 (ou seja, 100%)

$$PCross_i = \frac{P_i}{\sum_{j=1}^{CE} P_j} (1 - CE * \gamma) + \gamma \quad (4.10)$$

Onde i varia de 1 a CE , $PCross$ é um vetor de probabilidades de cada uma das estratégias de cruzamento, P é um vetor de probabilidades de cada uma das estratégias de cruzamento baseado na relação entre os vetores *Reward* e *Penalty*, e CE é o número de operadores de cruzamento disponíveis para avaliação. Uma variável γ é atribuída com o menor valor de probabilidade de cada um dos operadores de cruzamento, evitando que algum operador tenha sua probabilidade igual a zero. Neste estudo, o valor utilizado é $\gamma = 0,01$.

Além disso, é executada uma segunda normalização, levando em consideração os valores de probabilidades das estratégias de cruzamento na população anterior (Pop_{i-1}), $PCross = [0.2 \ 0.2 \ 0.2 \ 0.2]$, e os valores obtidos para a nova população (Pop_i), $PCross = [0.11 \ 0.19 \ 0.17 \ 0.24 \ 0.28]$. A normalização é um procedimento aritmético realizado para obter um conjunto de probabilidades cuja soma é igual a 1, quando as probabilidades relativas são conhecidas e uma das possibilidades é verdadeira. Por exemplo, para a primeira coluna do vetor $PCross$ da população atual e da população anterior (ou seja, 0.11 e 0.2, respectivamente), aplicando a Equação 4.11, tem-se $(0.50.11) + (0.50.2) = 0.155$.

$$PCross_j(Pop_i) : PCross_j(Pop_{i-1}) = (0,5 * PCross_j(Pop_i)) + (0,5 * PCross_j(Pop_{i-1})) \quad (4.11)$$

Onde j varia de 1 a CE , $PCross(Pop_i)$ representa o vetor de probabilidades de estratégias de seleção calculado para a nova população gerada por meio das operações de cruzamento, e $PCross(Pop_{i-1})$ representa o vetor de probabilidades de estratégias de seleção calculadas para a população anteriormente avaliada.

Ao final do procedimento descrito acima, todos os valores de probabilidade do vetor $PCross$ são atualizados e estão disponíveis para uso.

Mutação

A operação de mutação é usada para aumentar a diversidade das soluções encontradas e prevenir a convergência prematura a mínimos locais. A mutação ocorre selecionando aleatoriamente um indivíduo da população e mudando o valor de um de seus genes com base em

uma probabilidade fixa de 0,1. Como o cromossomo usado nessa abordagem representa processadores, apenas os genes que correspondem a esses processadores são alterados. A mutação ocorre de forma aleatória, variando de 1 até N_Proc, onde N_Proc é o número de processadores disponíveis na arquitetura.

Seleção e Ranqueamento

Após a atualização das probabilidades das estratégias de cruzamento, o processo evolutivo continua concatenando as duas populações, Pop_i e Pop_{i-1} .

Em seguida, dependendo do algoritmo utilizado, são realizados procedimentos de seleção e ranqueamento para formar uma nova população a partir da concatenação acima. Essa nova população tem tamanho igual ao original e descarta indivíduos não selecionados durante o processo.

4.2.4 Módulo de Resultados

Os resultados obtidos na Seção 4.2.3 são armazenados de forma hierárquica e compatibilizados pelo procedimento para a posterior análise de resultados.

A avaliação dos resultados será realizada principalmente com base em duas métricas bem conhecidas da literatura para avaliação das soluções geradas por MOEAs: HV (*Hypervolume*) e IGD (*Inverted Generational Distance*).

Conforme descrito por Coello e Cortés (2005), o GD pode ser utilizado como uma forma de estimar a distância entre os elementos na fronteira de Pareto produzida por um *set* de soluções obtidas por um MOEA em relação a uma fronteira de Pareto "real" de um dado problema. Sendo definida pelos autores conforme mostrado na Equação 4.12.

$$GD = \frac{\sqrt{\sum_{i=1}^n d_i^2}}{n} \quad (4.12)$$

Considere um procedimento MOEA que está sendo analisado para um problema de otimização multiobjetivo. Suponha que o procedimento tenha gerado n soluções não dominadas. Para avaliar a qualidade dessas soluções, podemos calcular a distância euclidiana d_i entre cada solução e a solução mais próxima na fronteira de Pareto "real" do problema (ou seja, a fronteira de Pareto que inclui as soluções verdadeiramente não dominadas). Se o valor calculado para todas as soluções for zero, isso indica que todas as soluções geradas estão na fronteira de Pareto "real" do problema. Caso contrário, quanto menor o valor médio de d_i , melhor a qualidade das soluções geradas em relação à fronteira de Pareto "real".

Na abordagem proposta por Coello e Cortés (2005), é implementada uma métrica de distância geracional "invertida" para avaliar a qualidade das soluções geradas por um procedimento MOEA em um problema de otimização multiobjetivo. Nessa métrica, a fronteira de Pareto "real" é usada como referência e cada uma de suas soluções é comparada com a fronteira de Pareto produzida pelo procedimento MOEA. Isso reduz problemas associados à métrica de distância geracional, que pode ser imprecisa quando o algoritmo gera poucas soluções não dominadas. Usando a fronteira de Pareto "real" como referência, a métrica de distância geracional invertida fornece uma avaliação mais precisa e robusta da qualidade das soluções geradas pelo MOEA.

Uma definição formal da métrica *Hypervolume* é demonstrada por (GUERREIRO; FONSECA; PAQUETE, 2020), de modo que um conjunto de pontos $S \subset \mathfrak{X}$ e um ponto de referência $r \in \mathfrak{X}$ são tomados em conta para efeito de cálculo. O indicador de *Hypervolume* de S é denominado medida da região fracamente dominada por S e limitada em sua parte superior por r , ou seja, conforme apresentado na Equação 4.13.

$$H(S) = \Lambda(q \in \mathfrak{X}^d | \exists p \in S : p \leq q \text{ and } p \leq r) \quad (4.13)$$

De acordo com Guerreiro, Fonseca e Paquete (2020), a medida de Lebesgue $\Lambda(\cdot)$ é utilizada na definição do indicador de *Hypervolume*. Essa medida pode ser interpretada como a medida relacionada à união de caixas que representam a área de cada uma das soluções em um espaço objetivo, conforme apresentado na Equação 4.14.

$$H(S) = \Lambda \left(\bigcup_{\substack{p \in S \\ p \leq r}} [p, r] \right) \quad (4.14)$$

Onde: $[p, r] = q \in \mathfrak{X}^d | \exists p \in S : p \leq q \text{ and } p \leq r$ demonstram uma caixa com limite inferior dado por $p \in S$ e o limite superior dado por r .

O ponto de referência é um parâmetro crucial na obtenção da métrica de *Hypervolume*. No entanto, em problemas de otimização multiobjetivo nos quais as soluções analíticas não estão disponíveis ou as fronteiras de Pareto "reais" ainda não foram determinadas, a definição desse ponto pode ser complexa e difícil. Para contornar essa dificuldade, a presente tese adota uma abordagem experimental para obter o ponto de referência. O procedimento funciona da seguinte maneira: cinco rodadas de testes são realizadas e os maiores valores obtidos para cada uma das métricas (Energia, Tolerância a Falhas, Comunicação e Balanceamento de Carga) são somados a uma constante e definidos como pontos de referência para o cálculo do indicador de

Hypervolume.

Em resumo, o uso de arquiteturas manycore para acelerar o processamento de aplicações baseadas em grafos tem se tornado cada vez mais comum. No entanto, o mapeamento dessas aplicações em muitos núcleos é um desafio complexo, que requer equilíbrio de carga, gerenciamento de comunicação e escalabilidade.

Neste capítulo foram apresentados dois *frameworks* propostos para facilitar o mapeamento de grafos em arquiteturas manycore, visando otimizar o uso dos recursos computacionais disponíveis. O primeiro *framework* proposto, apresentado na Seção 4.1, é voltado para o mapeamento de grafos de aplicativos de morfologia matemática em arquiteturas manycore. Já, o segundo *framework*, apresentado na Seção 4.1, é autoadaptativo e visa adaptar o procedimento evolutivo de mapeamento de aplicações em arquiteturas manycore, destacando-se o procedimento autoadaptativo multiobjetivo proposto para o mapeamento de grafos.

Com a apresentação desses *frameworks*, espera-se fornecer uma visão abrangente dos desafios envolvidos no mapeamento de grafos em arquiteturas manycore, bem como soluções propostas para enfrentá-los. Essas soluções apresentadas podem contribuir para o avanço da pesquisa nessa área e aprimorar o desempenho do mapeamento de aplicações em arquiteturas *manycore*.

Capítulo 5

RESULTADOS

5.1 Resultados - *Framework* proposto para mapeamento de grafos de aplicações em arquiteturas *manycore*

Na avaliação de resultados realizada, empregou-se uma estação de trabalho equipada com Windows 10, processador Intel i7 de 2.7 GHz e 16 GB de RAM como plataforma de hardware para os testes e simulações. Adicionalmente, o Matlab Educational Edition 2018b e o ambiente de desenvolvimento PlatEMO v1.5 serviram como base de software.

A metodologia dos experimentos seguiu a seguinte estrutura: inicialmente, definiu-se quais aplicações seriam cruciais para validar a generalização, precisão e acurácia do *framework* proposto. Nesse sentido, duas aplicações foram selecionadas: Imagens Binárias (detecção de imagens de alta resolução de PCB) e Escala de Cinza (detecção de reservatórios em planta de refino GeoEye Ikonos), ambas utilizando imagens de alta resolução espacial. O processo de treinamento e teste dessas aplicações de detecção visou obter os melhores grafos de filtros morfológicos para essas imagens de alta resolução, que foram posteriormente empregados no procedimento de mapeamento de grafos - a ser detalhado adiante. Na sequência, um primeiro experimento foi conduzido para identificar os melhores parâmetros e algoritmos a serem empregados no procedimento de mapeamento. Por fim, como um segundo experimento, o mapeamento de grafos de aplicações de filtros morfológicos para a arquitetura *manycore* foi realizado.

Aplicação 1 - Detecção de padrões de imagem de alta resolução em PCB (*Printed Circuit Board*)

Para esta primeira aplicação, que será discutida em mais detalhes a seguir, foi desenvolvido um *benchmarking* proprietário em nosso grupo de pesquisa (Tabela 5.4) com o objetivo de avaliar o desempenho da abordagem proposta. Os conjuntos $n_train_pairs_set$ e $n_test_pair_set$

(Seção 4.1.3) utilizaram sub-imagens binárias derivadas da imagem monocromática original apresentada na Fig. 5.1, com resolução espacial de 3277 x 2048 *pixels*. O principal objetivo nesta etapa foi detectar três tipos específicos de padrões: ilhas circulares, ilhas quadradas e trilhas. Os tamanhos das imagens dos conjuntos de treinamento e teste foram determinados por meio de um procedimento de recorte aleatório, resultando em imagens de 194 x 174 *pixels*.




Figura 5.1: Imagem da (PCB) usada para os experimentos. A área destacada mostra os três tipos de padrões (ilha quadrada, ilha circular e trilha) a serem detectados pelo filtro.

A Fig. 5.2 apresenta alguns exemplos de sub-imagens utilizadas para treinamento e teste do aplicativo 1. Observa-se que todas as sub-imagens contêm três alvos na figura (ilha circular, ilha quadrada e segmentos de trilha).



Figura 5.2: Exemplo de sub-imagens usadas no conjunto de teste e treinamento para a aplicação de detecção de padrões em imagens de PCB de alta resolução.

Aplicação - GeoEye Ikonos Planta de refino de petróleo

A segunda aplicação teve como objetivo detectar tanques de armazenamento de combus-

tível em uma planta de produção de petróleo. Para isso, outro *benchmark* proprietário foi desenvolvido pelo nosso grupo de pesquisa, apresentando características ilustradas na Figura 5.3. A imagem possui uma resolução espacial de 2312 x 1632 *pixels* e foi capturada pelo satélite Ikonos, com resolução espacial de 1 m. Os conjuntos de treinamento e teste são compostos por sub-imagens em tons de cinza, utilizadas para detectar padrões circulares que correspondem aos tanques de armazenamento presentes nessas imagens. As sub-imagens possuem um tamanho de 200 x 200 *pixels* e extraídas automaticamente por meio de um procedimento de recorte de imagem aleatório.



Figura 5.3: A planta de refino de petróleo foi capturada pelo satélite Ikonos RGB com resolução de 1 m (Imagem disponível em: <https://effigis.com/en/solutions/satellite-images/satellite-image-samples/>).

Figure 5.4 mostra alguns exemplos de sub-imagens em tons de cinza usadas para o treinamento e teste da aplicação 2.

5.1.1 Resultados do treinamento e teste

Os parâmetros utilizados durante o processo de treinamento e teste são apresentados na Tabela 5.1. Nesta tese, conforme mencionado anteriormente, optou-se por empregar imagens




Figura 5.4: Exemplos de sub-imagens em tons de cinza usadas para o treinamento e teste da aplicação 2.

Tabela 5.1: Parâmetros utilizados para os procedimentos de treinamento e teste

Múmero de <i>Evaluations</i>	1000
Número de indivíduos	100
Taxa de mutação	0.05
Imagens de Treinamento	30 por alvo
Imagens de Teste	10 por alvo
Número de Execuções	30
Número de <i>Folds</i>	10
Total de cromossomos = 3000 por alvo	

binárias e monocromáticas para as aplicações propostas, com o objetivo de validar o *framework* no que se refere ao procedimento de mapeamento de tarefas para arquiteturas *manycore*.

Após o processo de treinamento e teste, o *framework* proposto obteve os seguintes resultados: a Figura 5.5 exibe alguns dos melhores resultados alcançados durante o processo de treinamento da aplicação. Ao analisar essas imagens, verifica-se que o procedimento foi bem-sucedido na detecção dos padrões mencionados.

Após a conclusão desse processo, é possível obter o grafo de aplicação otimizado (filtro morfológico). Além disso, os grafos podem ser traduzidos em programas de fácil entendimento. Esses grafos e os programas correspondentes são ilustrados na Figura 5.6.

As imagens obtidas após a conclusão dos procedimentos de treinamento e teste comprovam a eficácia do método na detecção dos padrões estabelecidos previamente. Na aplicação 1, os padrões detectados incluem círculo, quadrado e trilha, conforme evidenciado pelas imagens. Para a aplicação 2, as imagens também demonstram o sucesso do método na detecção dos padrões específicos dessa aplicação.

Os resultados alcançados durante o procedimento de treinamento são apresentados na Tabela 5.2 e os resultados obtidos durante o procedimento de teste são exibidos na Tabela 5.3. Esses resultados servem como guia na seleção dos melhores grafos de aplicação para uma tarefa específica, neste caso, filtros morfológicos projetados para detectar formas geométricas. Os melhores resultados contribuíram para a escolha dos melhores cromossomos (destacados em negrito). Ao particionar os conjuntos de treinamento em *Folds*, foi possível alcançar uma maior




Figura 5.5: As imagens obtidas ao final dos procedimentos de treinamento e teste demonstram a eficácia do método em detectar os padrões previamente estabelecidos. Para a aplicação 1, os padrões detectados incluem círculo, quadrado e pista, conforme mostrado nas imagens. Já para a aplicação 2, os resultados também evidenciam o sucesso do método na detecção dos padrões específicos dessa aplicação.

generalização do resultado final, permitindo que o melhor cromossomo obtenha um resultado de ótima qualidade (*QoF*) para toda a quantidade de dados analisados.

5.1.2 Resultados do Mapeamento

Durante a execução do *framework* proposto, um procedimento *a priori* foi realizado para determinar o melhor algoritmo a ser utilizado no mapeamento de grafos de aplicação em arquiteturas *manycore*. Conforme ilustrado na Figura 5.7, o método atual abrange: o Módulo de Entrada, o Procedimento Multiobjetivo, o Módulo de Resultados e o Módulo de Análise de Resultados.

Conforme ilustrado na Figura 5.7, o método atual abrange: o Módulo de Entrada, o Procedimento Multiobjetivo, o Módulo de Resultados e o Módulo de Análise de Resultados.

Neste cenário, o Módulo de Entrada é responsável por armazenar os grafos de aplicação, que incluem 12 aplicações reais e quatro aplicações sintéticas geradas sinteticamente pelo TGFF

Tabela 5.2: Resultados relacionados com o treinamento.

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Fold 6	Fold 7	Fold 8	Fold 9	Fold 10	Mean	SD	Best	Worst
CIRCLE	1,541	1,477	1,535	1,538	1,542	1,543	1,508	1,536	1,535	1,424	Mean			
	0,000	0,107	0,018	0,019	0,000	0,000	0,093	0,066	0,020	0,088	SD			
	1,541	1,185	1,438	1,349	1,542	1,543	0,867	0,880	1,388	1,194	Best			
	1,541	1,542	1,541	1,540	1,542	1,543	1,541	1,543	1,540	1,539	Worst			
SQUARE	0,752	0,747	0,998	0,456	0,699	0,381	0,505	0,304	0,482	0,624	Mean			
	0,217	0,212	0,202	0,141	0,192	0,108	0,166	0,124	0,143	0,227	SD			
	0,181	0,328	0,360	0,099	0,200	0,139	0,135	0,007	0,167	0,073	Best			
	1,047	1,083	1,186	0,695	0,930	0,542	0,767	0,466	0,673	0,944	Worst			
TRACK	5,820	4,786	1,490	5,498	6,107	4,911	5,967	5,525	4,328	6,095	Mean			
	0,566	0,676	1,173	0,468	0,625	0,436	0,450	0,633	0,817	0,355	SD			
	4,226	1,969	0,323	2,408	2,832	4,342	4,234	3,870	2,145	5,078	Best			
	6,463	5,427	3,769	5,910	6,560	5,556	6,441	6,256	5,304	6,502	Worst			
SATELLITE	704,052	712,893	712,224	712,793	712,877	712,903	710,594	712,912	710,696	712,602	Mean			
	17,318	0,092	1,077	0,912	0,081	0,047	4,278	0,000	4,796	0,462	SD			
	632,680	712,167	705,191	703,852	712,334	712,486	695,619	712,912	678,550	709,990	Best			
	712,899	712,912	712,898	712,912	712,912	712,912	712,912	712,912	712,678	712,869	Worst			

Tabela 5.3: Resultados relacionados com o teste.

	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Fold 6	Fold 7	Fold 8	Fold 9	Fold 10	Mean	SD	Best	Worst	
CIRCLE	0,051	0,039	0,048	0,045	0,051	0,051	0,036	0,030	0,047	0,040	Mean	0,001	0,000	0,001	0,040
	0,001	0,000	0,001	0,001	0,000	0,000	0,035	0,002	0,004	0,001	SD	0,051	0,039	0,047	0,040
	0,051	0,039	0,047	0,044	0,051	0,051	0,009	0,028	0,043	0,040	Best	0,053	0,040	0,052	0,042
	0,053	0,040	0,052	0,047	0,052	0,051	0,087	0,035	0,054	0,042	Worst	0,007	0,001	0,001	0,023
SQUARE	0,008	0,008	0,008	0,008	0,008	0,008	0,008	0,008	0,008	0,008	Mean	0,001	0,001	0,001	0,008
	0,001	0,001	0,004	0,002	0,003	0,001	0,003	0,000	0,000	0,001	SD	0,024	0,003	0,074	0,074
	0,024	0,003	0,005	0,076	0,073	0,074	0,075	0,075	0,065	0,074	Best	0,138	0,064	0,007	0,084
	0,138	0,064	0,007	0,084	0,096	0,144	0,138	0,128	0,068	0,179	Worst	0,008	0,008	0,008	0,008
TRACK	0,008	0,008	0,001	0,018	0,021	0,009	0,012	0,008	0,004	0,011	Mean	0,121	0,047	0,006	0,063
	0,147	0,070	0,009	0,131	0,154	0,151	0,155	0,138	0,072	0,191	SD	0,121	0,047	0,006	0,063
	0,121	0,047	0,006	0,063	0,079	0,121	0,119	0,116	0,060	0,160	Best	0,147	0,070	0,009	0,131
	0,147	0,070	0,009	0,131	0,154	0,151	0,155	0,138	0,072	0,191	Worst	23,173	26,229	26,280	25,826
SATELLITE	11,770	15,068	14,390	14,479	15,102	15,137	14,298	15,133	11,149	14,903	Mean	6,122	5,709	6,645	5,793
	41,539	49,365	47,763	47,768	49,423	49,699	47,907	49,483	41,356	48,980	SD	41,539	49,365	47,763	47,768
	23,173	26,229	26,280	25,826	26,215	26,270	25,630	26,220	25,171	26,189	Best	11,770	15,068	14,390	14,479
	11,770	15,068	14,390	14,479	15,102	15,137	14,298	15,133	11,149	14,903	Worst	6,122	5,709	6,645	5,793

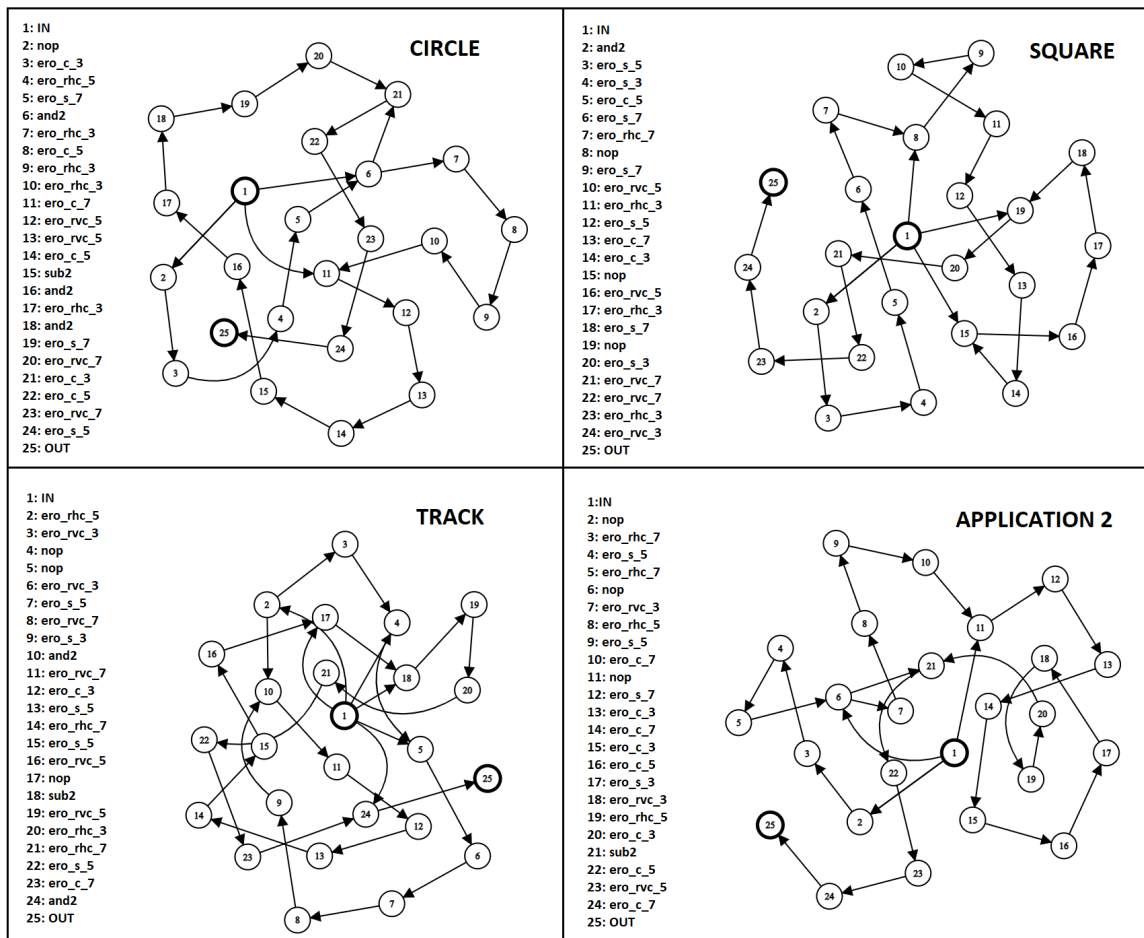


Figura 5.6: Os grafos de aplicação e seus respectivos programas obtidos para a aplicação 1, que mostram os padrões (círculo, quadrado e trilha), e para a aplicação 2 são apresentados, respectivamente. Esses grafos ilustram as soluções encontradas pelo método para detectar os padrões específicos de cada aplicação.

(DICK; RHODES; WOLF, 1998). Essas aplicações estão listadas na Tabela 5.4 sendo convertidas e adaptadas ao procedimento conforme o processo apresentado na Figura 5.8. Neste processo, os grafos são transformados em forma de texto, tornando-se assim um formato compreensível para o Procedimento Multiobjetivo. O Módulo de Entrada também é responsável por ler os arquivos de configuração que selecionam os parâmetros a serem utilizados pelo Procedimento Multiobjetivo (Tabela 5.5) e os algoritmos (A1, A2, ..., A5), contidos na Tabela 5.5, que serão escolhidos pelo referido procedimento.

O Procedimento Multiobjetivo é responsável por gerar os resultados e encaminhá-los para o Módulo de Resultados. Ele também é responsável por apresentar os resultados ao usuário na forma de uma fronteira de Pareto, representada por uma superfície contendo várias soluções obtidas por meio do procedimento multiobjetivo. Essas soluções são representadas por três métricas de compromisso: energia, tolerância a falhas e comunicação. O funcionamento deste módulo foi explicado em detalhes na seção 4.1.5. Os resultados são apresentados em relação às

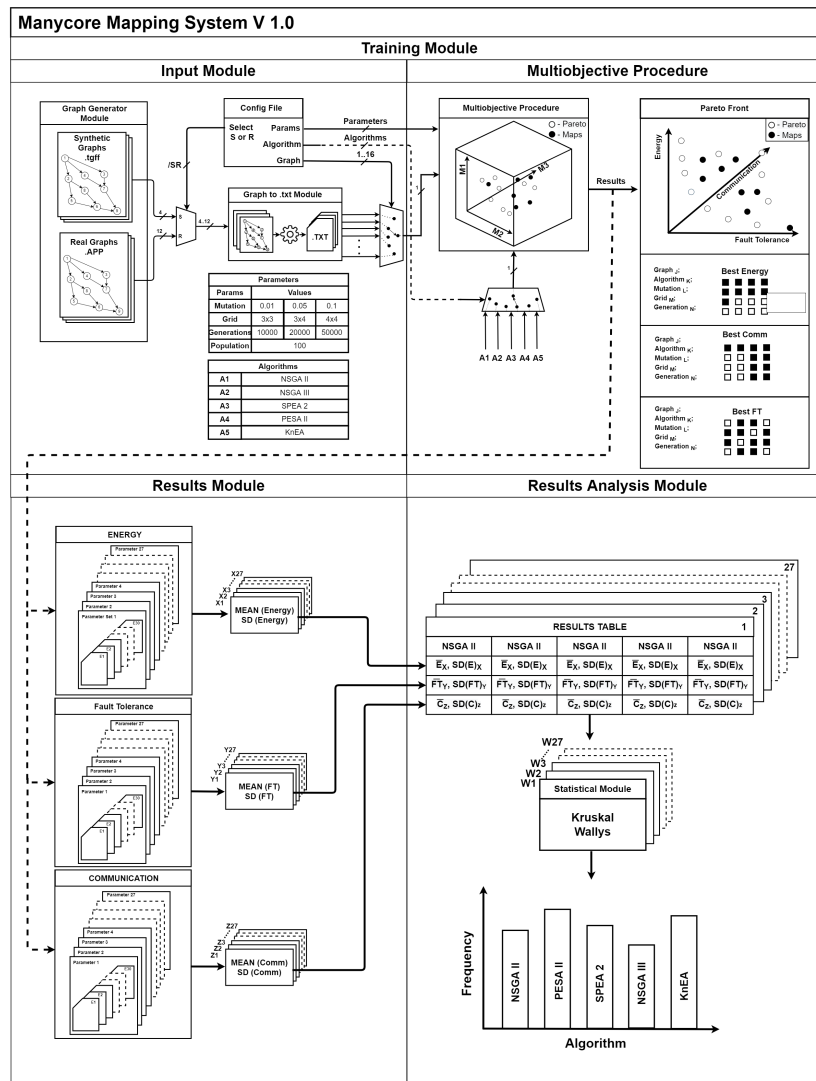


Figura 5.7: Descrição do procedimento de calibração para obtenção do melhor MOEA para o framework proposto quanto à aplicação de filtros de detecção de padrões.

seguintes variações: grafo (1...J), algoritmo (1...K), taxa de mutação (1...L), tamanho do *grid* (1...M) e número de gerações/*evaluations* (1...N). Onde: J=16, K=5, L=3, M=3, N=3.

Assim, o Módulo de Resultados tem como objetivo armazenar e calcular os resultados obtidos no módulo anterior. Esses dados são armazenados da seguinte maneira: cada grafo (J) possui cinco diretórios referentes a cada um dos algoritmos (K), e cada diretório de algoritmo contém três diretórios que armazenam os resultados relativos às três métricas mencionadas anteriormente. Dentro de cada repositório referente às métricas, existem 27 outros diretórios que correspondem ao número de variações de parâmetros obtidas ($L \times M \times N$). Além disso, dentro de cada diretório de variações de parâmetro, há mais 30 diretórios referentes a 30 rodadas de testes. A partir dos diretórios descritos, são extraídas as seguintes métricas: Média (Mean) e Desvio Padrão (SD), os quais são posteriormente enviados ao Módulo de Análise de Resultados.

O Módulo de Resultados visa organizar e armazenar os resultados obtidos anteriormente, de modo a facilitar a análise por meio de ferramentas estatísticas. Os resultados são armazenados em forma de tabela, com cada planilha composta por 27 tabelas (W1,...,W27). Cada planilha representa um grafo (j), totalizando 16 planilhas. Para analisar os resultados, esse módulo aplica o método de Kruskal-Wallis, determinando assim os resultados com significância estatística de 5%. Todos os resultados são quantificados e apresentados em um histograma de frequência (Figura 5.9), contabilizando o maior número de acertos. Como resultado, cada um dos algoritmos obteve acertos neste estudo.

Após a conclusão do processo, os histogramas de todos os grafos de cada aplicativo são calculados, determinando assim o algoritmo que apresentou o melhor desempenho entre os 16 aplicativos testados inicialmente. Essa análise permite identificar qual algoritmo é mais adequado para o mapeamento de grafos de aplicação em arquiteturas *manycore*, considerando as métricas de compromisso avaliadas (energia, tolerância a falhas e comunicação). Com base nesses resultados, pode-se selecionar o algoritmo mais apropriado para ser utilizado no *framework* proposto, visando otimizar o desempenho das aplicações em arquiteturas *manycore*.

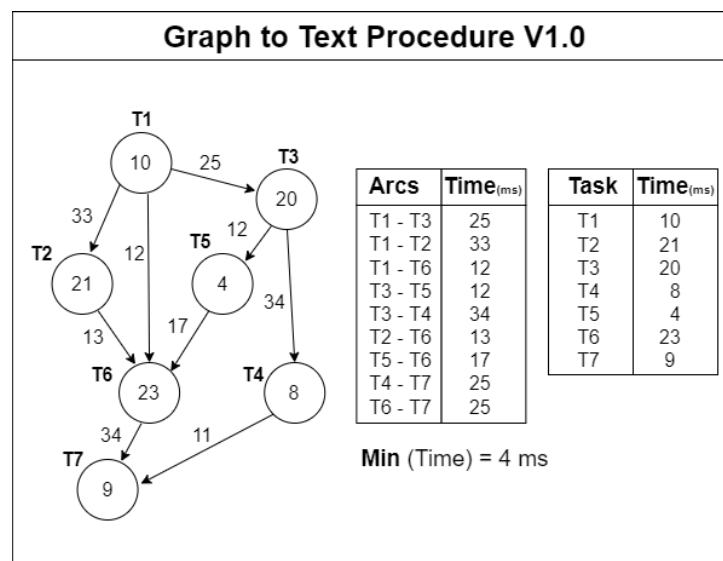


Figura 5.8: Procedimento para conversão de grafo para texto.

Como pode ser visto na Figura 5.9, o algoritmo KnEA obteve o melhor desempenho sobre a métrica *Ftol* (Tolerância a falhas), mas seu desempenho em relação às outras duas métricas (*Energy* e *Ttot* (Comunicação)) não foi muito expressivo. O algoritmo NSGA-II teve um desempenho ligeiramente inferior ao KnEA para as métricas *Energy* e *Ttot*, mas teve o pior desempenho entre todos os algoritmos estudados na métrica *Ttot*. O algoritmo NSGA-III teve melhor desempenho que o NSGA-II sobre a métrica *Ttot* e foi semelhante à métrica *Energy*, mas teve um desempenho inferior para a métrica *Ftol*.

Tabela 5.4: Lista de aplicações utilizadas no experimento de mapeamento de tarefas em arquiteturas *manycore*

VOPD(Video Object Decoder: 16 tarefas)
MMS (Multimedia System: 25 tarefas)
MWD (Multi Window Display: 12 tarefas)
80211 (Wifi: 25 tarefas)
CAVLC (H.24 Encoder: 16 tarefas)
MPEG4 (12 tarefas)
VCE (Video Conference Encoder: 25 tarefas)
AutoIndustry (E3s Auto Industry Benchmark: 25 tarefas)
Consumer (E3s Consumer Benchmark: 12 tarefas)
Telecom (E3s Telecom Benchmark: 12 tarefas)
WifiRX (Wifi Baseband Receiver: 25 tarefas)
- 4 Grafos de aplicação sintéticos
TGFF Random Graph (48 tarefas)
TGFF Random Graph (87 tarefas)
TGFF Random Graph (104 tarefas)
TGFF Random Graph (192 tarefas)

Tabela 5.5: Parâmetros e Algoritmos utilizados no procedimento de mapeamento.

EA Parâmetros	Descrição
<i>Mutação</i>	0.01,0.05,0.1
<i>Tamanho do Grid</i>	3x3,3x4,4x4
<i>Número de gerações</i>	10000,20000,50000
<i>Tamanho da População</i>	100
Algoritmos	Referências
<i>NSGA II</i>	(DEB et al., 2000)
<i>NSGA III</i>	(DEB; JAIN, 2013)
<i>SPEA 2</i>	(ZITZLER; LAUMANNNS; THIELE, 2001)
<i>PESA II</i>	(CORNE et al., 2001)
<i>KnEA</i>	(ZHANG; TIAN; JIN, 2014)

No entanto, deve-se destacar que o algoritmo PESA-II obteve o melhor desempenho para as métricas *Energy* e *TTot*, sendo superado pelo algoritmo KnEA para a métrica *Ftol*. O algoritmo SPEA2 obteve o resultado mais equilibrado entre todos os outros estudados em relação a todas as métricas.

Portanto, optou-se por classificar os algoritmos conforme o desempenho obtido para os acertos sobre as três métricas utilizadas neste estudo: PESA-II, SPEA2, KnEA, NSGA-II e NSGA-III. O algoritmo PESA-II e os parâmetros referidos na Tabela 5.5 são utilizados no procedimento de mapeamento de aplicações de filtros morfológicos para arquiteturas *manycore*.

Na Tabela 5.6, é mostrado um exemplo dos resultados obtidos durante o procedimento de mapeamento. Os itens marcados em negrito são semelhantes com 5% de significância estatís-

Tabela 5.6: Exemplo de resultados do procedimento de mapeamento aplicado para o gráfico número 3 na Tabela 5.4 (MWD (Multi Window Display)), onde foram avaliadas diferentes taxas de mutação, número de avaliações, tamanhos de *grid* e cinco algoritmos estado da arte.

		N 100 Eval 10000 Grid 9 3 3														
		KnEA			NSGAI			NSGA III			PESA II			SPEA 2		
Mutation	Metrics	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol
0.01	Mean	8,71	6,72	1,63	8,77	7,63	1,75	8,76	7,38	1,68	7,69	6,03	1,38	8,63	7,09	1,58
	SD	1,56	2,11	0,50	1,50	1,88	0,66	1,69	1,71	0,75	1,39	2,16	0,51	1,59	2,03	0,70
	BEST	6,00	3,00	1,00	6,00	4,00	1,00	6,00	3,00	1,00	6,00	2,00	1,00	6,00	3,00	1,00
0.05	Mean	8,66	7,07	1,54	9,17	7,83	1,53	8,37	7,53	1,68	7,79	6,03	1,49	8,19	6,95	1,54
	SD	1,41	2,10	0,51	1,83	2,16	0,54	1,42	1,84	0,62	1,37	1,81	0,63	1,59	1,90	0,66
	BEST	6,00	4,00	1,00	6,00	3,00	1,00	6,00	3,00	1,00	6,00	3,00	1,00	6,00	3,00	1,00
0.1	Mean	9,00	7,40	1,61	8,87	7,09	1,55	9,12	7,74	1,58	8,01	6,29	1,44	8,57	6,87	1,63
	SD	1,36	2,11	0,70	1,78	2,31	0,66	1,69	1,88	0,67	1,64	1,96	0,64	1,96	1,54	0,64
	BEST	6,00	3,00	1,00	6,00	3,00	1,00	6,00	3,00	1,00	6,00	2,00	1,00	6,00	4,00	1,00

		100 10000 12 4 3														
		KnEA			NSGAI			NSGA III			PESA II			SPEA 2		
Mutation	Metrics	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol
0.01	Mean	8,72	9,12	1,32	8,77	8,51	1,44	8,72	9,13	1,43	7,49	7,12	1,29	8,08	7,61	1,33
	SD	1,65	2,11	0,47	1,87	2,00	0,50	1,88	2,35	0,54	1,22	2,10	0,46	1,32	2,18	0,52
	BEST	6,00	4,00	1,00	6,00	4,00	1,00	6,00	5,00	1,00	6,00	4,00	1,00	6,00	3,00	1,00
0.05	Mean	8,67	8,59	1,37	8,75	7,82	1,24	9,05	8,86	1,37	7,36	6,70	1,23	8,08	7,39	1,32
	SD	1,74	2,56	0,50	1,84	2,34	0,49	2,01	2,46	0,59	1,30	2,13	0,46	1,61	2,22	0,50
	BEST	6,00	3,00	1,00	6,00	4,00	1,00	6,00	3,00	1,00	5,00	4,00	1,00	6,00	3,00	1,00
0.1	Mean	8,71	8,30	1,34	8,43	8,97	1,44	8,78	9,60	1,42	7,67	7,16	1,29	8,19	8,54	1,32
	SD	1,35	1,86	0,47	1,39	2,69	0,52	1,70	2,36	0,56	1,36	2,25	0,51	1,61	2,17	0,47
	BEST	6,00	4,00	1,00	6,00	5,00	1,00	6,00	5,00	1,00	5,00	4,00	1,00	6,00	5,00	1,00

		100 10000 16 4 4														
		KnEA			NSGA II			NSGA III			PESA II			SPEA 2		
Mutation	Metrics	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol
0.01	Mean	8,39	10,69	1,08	8,17	11,16	1,20	8,33	11,54	1,38	6,72	8,57	1,19	7,85	10,64	1,33
	SD	1,63	2,75	0,28	1,64	2,71	0,40	2,04	2,39	0,51	1,14	1,98	0,39	1,48	3,38	0,50
	BEST	6,00	6,00	1,00	5,00	5,00	1,00	5,00	6,00	1,00	5,00	5,00	1,00	5,00	4,00	1,00
0.05	Mean	7,84	10,91	1,20	8,20	11,05	1,23	8,63	12,41	1,43	7,07	9,07	1,17	7,67	10,99	1,22
	SD	1,53	2,59	0,40	1,86	2,73	0,46	1,95	2,61	0,53	1,64	2,42	0,39	1,65	2,76	0,45
	BEST	6,00	6,00	1,00	6,00	5,00	1,00	6,00	6,00	1,00	5,00	4,00	1,00	5,00	5,00	1,00
0.1	Mean	8,05	10,84	1,20	8,33	11,14	1,23	8,50	11,90	1,29	6,99	8,31	1,15	7,91	10,86	1,28
	SD	1,24	1,94	0,40	1,38	2,72	0,45	1,57	3,29	0,48	1,11	2,39	0,39	1,60	2,64	0,45
	BEST	5,00	6,00	1,00	5,00	6,00	1,00	6,00	5,00	1,00	6,00	4,00	1,00	5,00	6,00	1,00

		100 20000 9 3 3														
		KnEA			NSGAI			NSGA III			PESA II			SPEA 2		
Mutation	Metrics	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol
0.01	Mean	8,83	7,56	1,55	8,05	6,08	1,46	8,13	5,85	1,46	7,42	5,71	1,49	7,16	4,96	1,43
	SD	1,66	2,08	0,56	1,33	1,67	0,56	1,47	1,94	0,56	1,27	2,15	0,58	1,17	1,74	0,60
	BEST	6,00	3,00	1,00	6,00	3,00	1,00	6,00	2,00	1,00	5,00	2,00	1,00	6,00	2,00	1,00
0.05	Mean	8,45	6,73	1,60	7,92	6,46	1,59	8,20	5,95	1,44	7,11	5,19	1,46	7,32	5,18	1,31
	SD	1,58	2,07	0,62	1,39	2,23	0,64	1,26	2,06	0,53	1,13	1,81	0,58	1,18	2,13	0,52
	BEST	6,00	3,00	1,00	6,00	1,00	1,00	6,00	1,00	1,00	6,00	2,00	1,00	6,00	2,00	1,00
0.1	Mean	8,81	6,77	1,48	8,06	6,37	1,70	8,18	6,25	1,51	7,02	4,72	1,41	7,29	5,30	1,48
	SD	1,34	1,96	0,50	1,59	2,17	0,66	1,70	2,17	0,60	1,00	1,50	0,58	1,34	2,01	0,67
	BEST	6,00	3,00	1,00	6,00	2,00	1,00	6,00	1,00	1,00	6,00	2,00	1,00	6,00	2,00	1,00

		100 20000 12 4 3														
		KnEA			NSGAI			NSGA III			PESA II			SPEA 2		
Mutation	Metrics	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol
0.01	Mean	8,49	8,18	1,21	7,95	7,19	1,32	7,66	7,50	1,32	6,88	6,50	1,27	6,77	6,54	1,26
	SD	1,84	1,97	0,41	1,67	2,19	0,47	1,36	2,21	0,52	1,22	2,05	0,46	1,09	1,96	0,44
	BEST	5,00	3,00	1,00	5,00	3,00	1,00	5,00	3,00	1,00	5,00	3,00	1,00	5,00	3,00	1,00
0.05	Mean	7,42	7,17	1,23	8,03	7,66	1,21	7,53	7,48	1,34	7,00	6,74	1,24	7,22	6,47	1,21
	SD	1,47	2,26	0,42	1,65	2,64	0,41	1,34	2,32	0,53	1,11	1,93	0,43	1,26	2,14	0,41
	BEST	5,00	4,00	1,00	5,00	3,00	1,00	5,00	3,00	1,00	5,00	2,00	1,00	5,00	1,00	1,00
0.1	Mean	7,84	7,57	1,27	7,81	7,36	1,28	8,06	8,07	1,37	6,74	6,06	1,18	7,12	6,62	1,29
	SD	1,36	2,67	0,44	1,50	2,30	0,46	1,48	2,44	0,50	1,14	1,95	0,39	1,47	2,30	0,45
	BEST	6,00	3,00	1,00	5,00	3,00	1,00	6,00	3,00	1,00	5,00	3,00	1,00	5,00	2,00	1,00

		100 20000 16 4 4														
		KnEA			NSGAI			NSGA III			PESA II			SPEA 2		
Mutation	Metrics	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol
0.01	Mean	7,16	9,22	1,12	7,25	8,58	1,24	7,34	9,08	1,12	6,50	7,61	1,11	6,85	7,59	1,15
	SD	1,40	3,07	0,33	1,19	2,52	0,43	1,29	2,45	0,32	0,93	2,10	0,31	1,33	2,13	0,36
	BEST	5,00	2,00	1,00	5,00	4,00	1,00	5,00	3,00	1,00	5,00	4,00	1,00	5,00	2,00	1,00
0.05	Mean	7,61	9,41	1,22	7,71	9,16	1,12	7,10	8,66	1,25	6,36	7,11	1,14	6,77	8,68	1,20
	SD	1,00	3,06	0,41	1,64	2,41	0,35	1,21	2,41	0,44	0,87	2,43	0,35	1,38	2,69	0,43
	BEST	6,00	4,00	1,00	5,00	4,00	1,00	5,00	5,00	1,00	5,00	2,00	1,00	5,00	4,00	1,00
0.1	Mean	7,70	9,16	1,14	8,16	9,46	1,16	6,99	8,95	1,18	6,29	7,91	1,13	7,03	8,41	1,21
	SD	1,42	2,83	0,35	1,31	2,15	0,37	1,29	2,43	0,41	0,96	2,30	0,33	1,35	2,79	0,41
	BEST	5,00	4,00	1,00	5,00	5,00	1,00	5,00	5,00	1,00	5,00	2,00	1,00	5,00	4,00	1,00

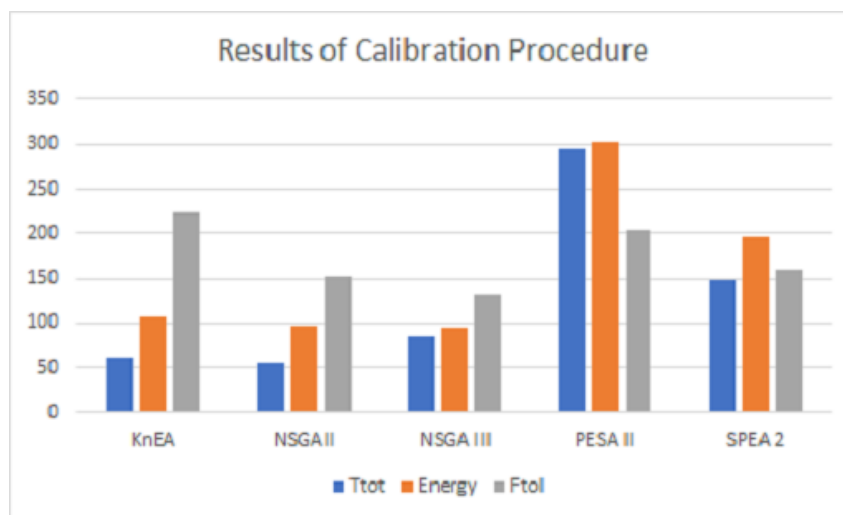


Figura 5.9: O histograma apresenta o número de acertos obtidos por cada um dos algoritmos avaliados em relação às três métricas descritas anteriormente: Energia, Tolerância a Falhas e Comunicação. O histograma inclui um total de 16 grafos de aplicação utilizados no procedimento de mapeamento.

tica. Os parâmetros relacionados ao tamanho do *grid*, taxa de mutação, número de avaliações e cinco algoritmos foram variados para selecionar a melhor configuração para a execução do procedimento de mapeamento.

Com esses dados, pode-se inferir que a taxa de mutação influencia na obtenção dos melhores resultados, bem como o número de avaliações realizadas após a execução de todo o procedimento aplicado para as 16 aplicações detalhadas na Tabela 5.4. Além disso, pode-se observar que a taxa de mutação 0,05 e 50000 avaliações tiveram o melhor desempenho, conforme mostrado na Figura 5.9.

O algoritmo PESA-II foi o melhor durante o estudo proposto. Essa melhoria de desempenho é atribuída à sua eficiente estratégia de seleção e arquivamento, que permite manter uma distribuição uniforme dos indivíduos ao longo da fronteira de Pareto. Além disso, o PESAI utiliza um mecanismo de grade adaptativo para estimar a densidade das soluções, resultando em uma melhor exploração do espaço de busca. Isso, no que lhe concerne, proporciona uma convergência mais rápida e uma diversidade mais ampla entre as soluções não dominadas. Portanto, em comparação com os outros algoritmos mencionados, o PESAI tem se destacado como uma opção mais eficaz e confiável para resolver problemas de otimização multiobjetivo.

Nas Figuras (5.10, 5.11, 5.12), os resultados relacionados à Tabela 5.6 são apresentados em forma de boxplot. As métricas (Comunicação, Energia e Tolerância a Falhas) são mostradas em relação aos cinco algoritmos mencionados acima na Tabela 5.5. Esses resultados são baseados na taxa de mutação de 0,05, 50000 avaliações e tamanho do *grid* (9, 12, 16), respectivamente.

5.1 Resultados - Framework proposto para mapeamento de grafos de aplicações em arquiteturas *manycore* 108

		100 50000 9 3 3														
		KnEA			NSGAI			NSGA III			PESA II			SPEA 2		
Mutation	Metrics	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol
0.01	Mean	8,59	5,99	1,47	7,69	4,94	1,41	7,22	5,03	1,55	6,80	4,30	1,31	6,67	4,01	1,45
	SD	1,34	2,20	0,50	1,48	1,52	0,51	1,11	1,90	0,64	1,00	1,65	0,53	0,77	1,39	0,64
	BEST	6,00	1,00	1,00	6,00	2,00	1,00	6,00	2,00	1,00	6,00	2,00	1,00	5,00	2,00	1,00
0.05	Mean	7,91	5,73	1,66	8,05	5,75	1,44	6,93	4,45	1,44	6,87	4,16	1,29	6,97	4,11	1,39
	SD	1,25	2,39	0,47	1,51	2,12	0,55	0,85	1,51	0,51	0,91	1,67	0,47	1,02	1,41	0,57
	BEST	6,00	1,00	1,00	6,00	2,00	1,00	5,00	2,00	1,00	5,00	2,00	1,00	5,00	2,00	1,00
0.1	Mean	8,03	6,01	1,62	7,48	5,21	1,60	7,20	4,69	1,39	6,96	4,45	1,32	6,73	4,09	1,42
	SD	1,71	2,11	0,55	1,21	1,94	0,79	1,07	1,64	0,54	1,03	1,48	0,50	0,86	1,35	0,63
	BEST	6,00	2,00	1,00	6,00	2,00	1,00	6,00	2,00	1,00	6,00	2,00	1,00	5,00	2,00	1,00

		100 50000 12 4 3														
		KnEA			NSGAI			NSGA III			PESA II			SPEA 2		
Mutation	Metrics	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol
0.01	Mean	7,95	7,21	1,35	7,48	7,15	1,32	6,75	5,55	1,25	6,59	4,76	1,15	6,39	4,75	1,19
	SD	1,56	1,94	0,54	1,28	2,23	0,47	0,88	1,81	0,43	0,85	1,50	0,35	0,72	1,53	0,39
	BEST	5,00	3,00	1,00	6,00	3,00	1,00	5,00	3,00	1,00	5,00	3,00	1,00	5,00	2,00	1,00
0.05	Mean	7,70	6,84	1,19	7,19	6,99	1,25	6,81	5,64	1,15	6,44	5,03	1,17	6,47	4,56	1,16
	SD	1,17	1,88	0,39	1,46	2,04	0,43	0,95	1,83	0,35	0,85	1,67	0,40	0,84	1,96	0,58
	BEST	6,00	3,00	1,00	5,00	4,00	1,00	6,00	2,00	1,00	5,00	2,00	1,00	5,00	2,00	1,00
0.1	Mean	7,46	7,22	1,34	7,61	6,59	1,26	7,05	5,95	1,24	6,50	5,19	1,19	6,29	4,72	1,22
	SD	1,48	2,02	0,47	2,02	2,31	0,48	0,95	2,19	0,44	0,64	2,01	0,39	0,87	1,60	0,44
	BEST	5,00	4,00	1,00	5,00	3,00	1,00	5,00	2,00	1,00	5,00	2,00	1,00	5,00	2,00	1,00

		100 50000 16 4 4														
		KnEA			NSGAI			NSGA III			PESA II			SPEA 2		
Mutation	Metrics	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol	Ttot	Energy	Ftol
0.01	Mean	7,62	8,72	1,09	7,19	7,73	1,09	6,46	7,10	1,14	6,07	6,49	1,09	5,98	6,35	1,06
	SD	1,59	2,94	0,28	1,23	2,11	0,28	1,03	1,93	0,35	0,74	1,93	0,29	0,94	2,06	0,23
	BEST	5,00	4,00	1,00	5,00	4,00	1,00	5,00	4,00	1,00	5,00	3,00	1,00	4,00	3,00	1,00
0.05	Mean	6,76	7,38	1,16	7,26	7,96	1,17	6,60	6,81	1,15	6,14	6,44	1,08	6,10	6,33	1,15
	SD	1,11	2,39	0,37	1,35	2,39	0,43	1,10	2,03	0,38	0,87	2,18	0,27	0,79	1,88	0,41
	BEST	5,00	3,00	1,00	5,00	3,00	1,00	5,00	2,00	1,00	5,00	3,00	1,00	4,00	2,00	1,00
0.1	Mean	7,02	8,72	1,17	6,96	8,40	1,18	6,63	6,86	1,07	6,12	6,20	1,07	6,14	5,84	1,06
	SD	1,02	2,18	0,37	1,33	2,72	0,38	1,36	2,26	0,25	0,89	1,42	0,26	0,76	1,90	0,23
	BEST	5,00	2,00	1,00	5,00	4,00	1,00	5,00	3,00	1,00	5,00	3,00	1,00	5,00	2,00	1,00

Ttot	KnEA	NSGAI	NSGA III	PESA II	SPEA 2	
Mutation 0.01	0	0	0	6	4	10
Mutation 0.05	0	0	1	8	3	12
Mutation 0.1	0	0	0	8	2	10
	0	0	1	22	9	

Sum of Means			
Eval 10000	Ttot	Energy	Ftol
9 3 3	137,06	113,01	25,29
12 4 3	125,47	123,42	20,15
16 4 4	118,66	160,07	18,58

Energy	KnEA	NSGAI	NSGA III	PESA II	SPEA 2	
Mutation 0.01	0	0	0	7	6	13
Mutation 0.05	0	0	0	7	5	12
Mutation 0.1	0	0	0	7	2	9
	0	0	0	21	13	

Sum of Means			
Eval 20000	Ttot	Energy	Ftol
9 3 3	117,95	89,10	22,37
12 4 3	112,52	107,09	18,99
16 4 4	106,82	129,01	17,49

Ftol	KnEA	NSGAI	NSGA III	PESA II	SPEA 2	
Mutation 0.01	4	1	2	5	2	14
Mutation 0.05	2	4	1	6	3	16
Mutation 0.1	3	0	2	7	3	15
	9	5	5	18	8	

Sum of Means			
Eval 50000	Ttot	Energy	Ftol
9 3 3	110,10	72,91	21,75
12 4 3	104,70	88,14	18,39
16 4 4	99,05	107,36	16,72

Number of hits	KnEA	NSGAI	NSGA III	PESA II	SPEA 2
Ttot	0	0	1	22	9
Energy	0	0	0	21	13
Ftol	9	5	5	18	8
Total	9	5	6	61	30

>Grid <Ftol
>Grid >Energy
>Evaluation <Error

A alocação inteligente de grafos de aplicativos em arquiteturas *manycore* tornou-se crucial, como mencionado anteriormente. Portanto, a abordagem apresentada aqui se concentrou nessa tarefa desafiadora. A seguir, serão demonstrados os resultados obtidos pelo procedimento de mapeamento.

Os melhores resultados (cromossomos) obtidos durante as fases de treinamento e teste (Fi-

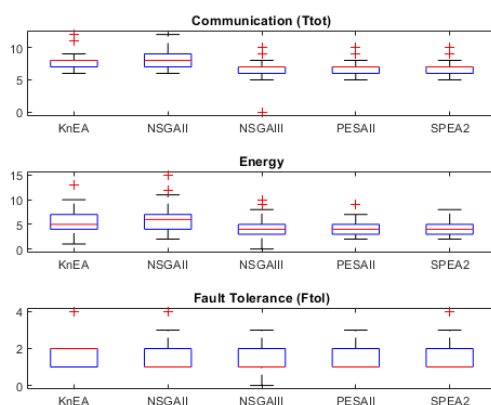


Figura 5.10: *Boxplot* dos resultados de Comunicação, Energia e Tolerância a Falhas do procedimento de mapeamento da Tabela 5.6, usando tamanho de *grid* 9 (3 x 3), taxa de mutação 0,05 e 50000 avaliações.

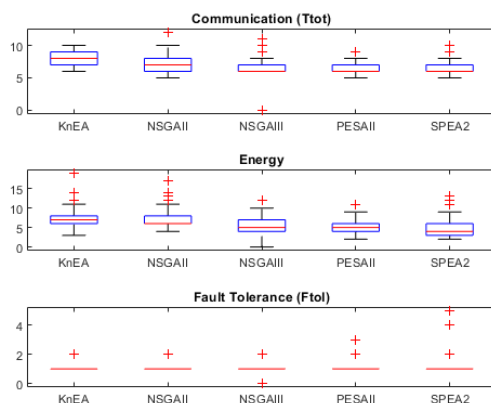


Figura 5.11: *Boxplot* dos resultados de comunicação, energia e tolerância a falhas do procedimento de mapeamento da Tabela 5.6, usando tamanho de *grid* 12 (4 x 3), taxa de mutação 0,05 e 50000 avaliações.

Figura 5.7) são usados como dados de entrada para o procedimento de mapeamento, utilizando o algoritmo PESA-II e os parâmetros obtidos durante o primeiro processo do experimento. Inicialmente, foi escolhida uma *grid* de 6 x 6 para este estudo, totalizando 36 processadores dispostos na arquitetura de muitos núcleos. A escolha deste tamanho está diretamente relacionada ao *grid* de muitos núcleos do processador físico em prática, sendo utilizado em estudos publicados anteriormente (BONNEY et al., 2016) (CAMPOS et al., 2016). Parâmetros adicionais na Tabela 5.7 são usados no procedimento de mapeamento.

Assim, são obtidos aproximadamente 3000 mapas candidatos para cada uma das métricas utilizadas acima. A abordagem empregada durante este estudo consistiu na união das três formas (círculo, quadrado e trilha) dos grafos de extração apresentados na aplicação 1, utilizando o operador *nop*. Dessa maneira, foi possível obter apenas um grafo de maior complexidade para




Figura 5.12: *Boxplot* dos resultados de Comunicação, Energia e Tolerância a Falhas do procedimento de mapeamento da Tabela 5.6, usando tamanho de *grid* 16 (4 x 4), taxa de mutação 0,05 e 50000 avaliações.

Tabela 5.7: Parâmetros adicionais utilizados no procedimento de mapeamento

Número de Individuos	100
Tamanho do <i>Grid</i> (Processadores)	36
Número de Linhas	6
Número de Colunas	6
Taxa de Mutação	0,05
<i>Evaluations</i>	10000

realizar a extração da forma. Os resultados resumidos dessa operação estão descritos na Tabela 5.8.

Tabela 5.8: Resumo dos resultados do procedimento de mapeamento *manycore* para o aplicativo 1

	TTot	Energy	FT
MÉDIA	111,11	80,31	2,77
SD	22,92	11,72	1,06
MIN	80	58	1
MAX	244	114	6

Tabela 5.9: Resumo dos resultados do procedimento de mapeamento *manycore* para o aplicativo 2

	TTot	Energy	FT
MÉDIA	64,52	25,59	1,26
SD	16,65	5,04	0,44
MIN	51	15	1
MAX	146	43	2

A Tabela 5.8 e a Figura 5.13 representam os melhores resultados obtidos durante o procedimento de mapeamento para o aplicativo 1 (Filtro Morfológico para extração de formas em imagens binárias) obtido na Seção 5.1.1. Assim, pode-se identificar um agrupamento maior

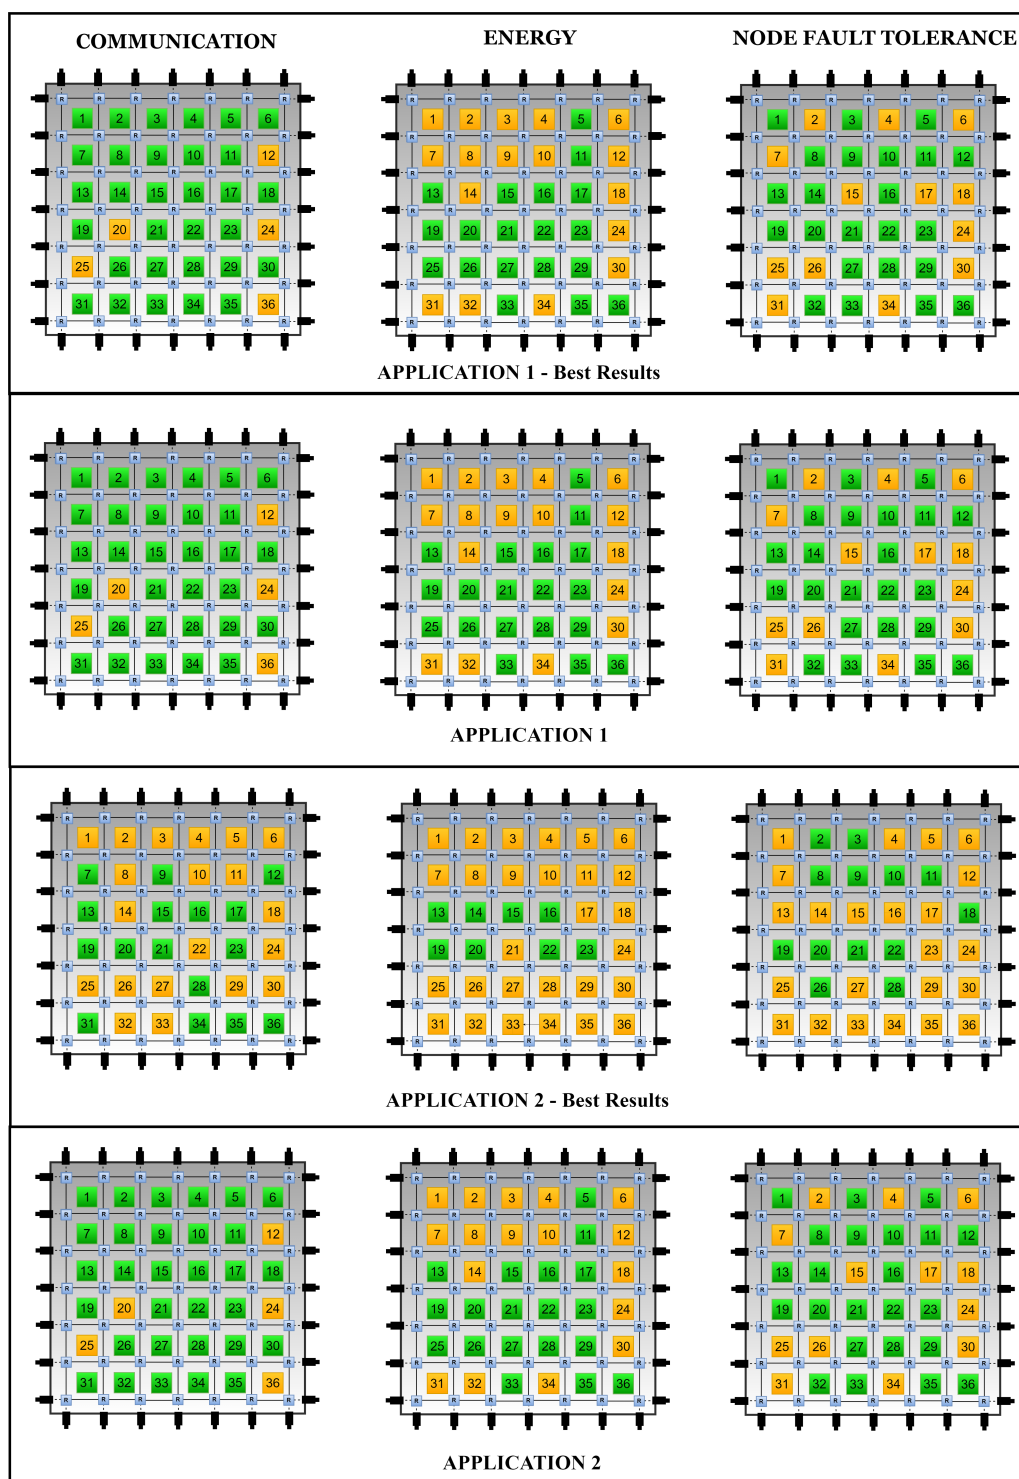


Figura 5.13: Os nós em verde representam quais tarefas foram alocadas; nós em laranja representam quais nós não possuem tarefas alocadas.

no mapa, correspondente à métrica de energia, tentando minimizar o número de *links* de comunicação utilizados por aquela aplicação. Na parte da figura que corresponde à métrica de comunicação, há uma distribuição mais ampla dos processadores utilizados, de modo que a comunicação utilizada por toda a aplicação seja minimizada e tenha um desempenho superior.

Por outro lado, na parte da figura correspondente à métrica de tolerância a falhas, é possível verificar uma distribuição mais uniforme dos processadores utilizados. Além disso, é possível inferir que cada um dos processadores utilizados possui um processador ocioso próximo a ele, com uma distância máxima de 1 salto, como pode ser visto na Tabela 5.8.

5.2 Resultados - Framework autoadaptativo para mapeamento de aplicações em arquiteturas manycore

Neste capítulo, será apresentado uma quantidade significativa de simulações numéricas para determinar qual dos algoritmos propostos na literatura apresenta o melhor desempenho com base nas métricas *Hypervolume* e *IGD*. Essas métricas indicam a qualidade da solução fornecida por um algoritmo específico e a distribuição das soluções ao longo da fronteira de Pareto, respectivamente. A seção 5.2 está dividida em duas partes: a primeira apresenta os resultados numéricos sem utilizar a abordagem autoadaptativa; a segunda parte expõe os resultados numéricos obtidos ao empregar a abordagem autoadaptativa proposta.

A avaliação dos resultados foi realizada em uma estação de trabalho com Windows 10, processador Intel i7 CPU @ 3.60GHz e 32 GB de RAM, utilizados como plataforma de hardware para os testes e simulações. Além disso, o *Matlab Educational Edition 2020b* e o ambiente de desenvolvimento PlatEMO v3.4 foram empregados como plataforma de software.

O cálculo do *Hypervolume*, utilizado na avaliação dos resultados, foi baseado nos pontos de referência apresentados na Tabela 5.10. Esses pontos foram obtidos com base nos piores valores alcançados para cada par de métricas, considerando 1000 avaliações e 5 rodadas de testes para fins estatísticos.

Tabela 5.10: Pontos de referência utilizados para cálculo do *Hypervolume*.

	Tolerância a Falhas x Energia		Tolerância a Falhas x Comunicação		Comunicação x Energia		Energia x Balanceamento de Carga	
4x4	10	100	10	1500	2000	100	100	3
6x6	10	150	10	1800	2300	200	150	3
8x8	14	300	14	2000	3200	300	300	3

Para avaliação dos resultados foram usados 3 conjuntos contendo cada um 10 grafos, as identificações dos respectivos tamanhos de cada um dos grafos podem ser encontradas na Tabela 5.11, os resultados foram obtidos de acordo com tamanhos de *grid* (4 X 4, 6 X 6 e 8 X 8) específicos para cada um dos conjuntos.

As tabelas utilizadas nas análises das Seções 5.3 e 5.4 estão dispostas no ANEXO A, tal disposição foi adotada para melhor organização dos resultados.

Tabela 5.11: Tamanho de cada um dos 10 grafos utilizados durante o procedimento de avaliação de resultados, organizados em relação ao tamanho do *grid* onde os conjuntos de grafos foram mapeados

	4 X 4	6 X 6	8 X 8
MAP1	27	42	72
MAP2	29	49	79
MAP3	27	47	77
MAP4	32	52	82
MAP5	24	44	84
MAP6	34	54	84
MAP7	36	56	86
MAP8	37	57	87
MAP9	40	60	90
MAP10	27	47	86

5.3 Resultados numéricos sem o uso do procedimento autoadaptativo

O (HV) e o (IGD) são adotados como indicadores de desempenho, conforme diversos estudos na literatura, para avaliar a qualidade de cada população obtida pelos MOEAs comparados. Um maior valor de HV e um menor valor de IGD indicam melhor desempenho. É importante ressaltar que todos os valores objetivos são normalizados no intervalo [0, 1] para o cálculo do HV. Cada MOEA é executado em cada um dos conjuntos de dados por 30 execuções, e a média/desvio padrão dos valores de HV e IGD são registrados em tabelas.

Para uma melhor compreensão das tabelas apresentadas, algumas informações são necessárias. Todos os resultados nas tabelas são avaliados utilizando o teste estatístico de Wilcoxon (CUZICK, 1985) com 5% de significância, a fim de determinar se os resultados obtidos são estatisticamente melhores, piores ou equivalentes. Para tal distinção, é utilizada uma representação gráfica (+/−/≈). As marcações em negrito indicam os algoritmos que obtiveram os melhores resultados. O número de avaliações (tamanho da população x número de gerações) utilizadas neste estudo foi de 10000, 20000 e 50000. Todas as tabelas empregam um algoritmo para fins de comparação com os demais. Nesta tese, o algoritmo utilizado para comparação é o PESA II, devido aos bons resultados obtidos no estudo preliminar descrito nos Capítulos 4 e 5.

5.3.1 Energia x Balanceamento de Carga

Hypervolume

Com base nas Tabelas A.1, A.9 e A.17, observa-se que, ao considerar o *grid* de tamanho 4 x 4 (Tabela A.1), os melhores resultados foram alcançados pelos algoritmos SPEA 2 (14) e PESAI (16). O algoritmo NSGAI ficou em terceiro lugar com o *score* (0/17/13), seguido pelo

algoritmo NSGAIII com *score* (0/24/6). O algoritmo com o pior desempenho geral foi o KnEA (0/30/0), obtendo 30 resultados inferiores ao algoritmo PESAI.

Analisando o desempenho em relação ao *grid* de tamanho 6 x 6 (Tabela A.9), o excelente desempenho do algoritmo SPEA 2 é evidenciado, alcançando os 30 melhores resultados. O segundo lugar foi obtido pelo algoritmo NSGAI (24/0/6), enquanto o terceiro lugar foi alcançado pelo algoritmo KnEA (5/0/25). O quarto lugar foi registrado para o algoritmo NSGAIII (5/3/22) e, em último lugar, pelo algoritmo PESAI.

Por fim, com base na Tabela A.17, relacionada ao *grid* de tamanho 8 x 8, o algoritmo NSGAI (15) obteve o melhor desempenho com *score* (29/0/1). O segundo lugar foi alcançado pelo algoritmo SPEA 2 (11) com um *score* (29/0/1). Em terceiro lugar, temos o algoritmo KnEA (3) (25/0/1), e o algoritmo NSGAIII (1) (24/0/6) ficou na quarta colocação. O algoritmo PESAI apresentou novamente baixo desempenho, ocupando a última posição.

Em uma análise mais abrangente, considerando os resultados obtidos nos *grids* 4 x 4 (Tabela A.1), 6 x 6 (Tabela A.9) e 8 x 8 (Tabela A.17), o algoritmo SPEA2 obteve um total de 55 melhores resultados. Em segundo lugar geral está o algoritmo PESAI (16), seguido de perto pelo algoritmo NSGAI (15), que ocupa o terceiro lugar geral. Os algoritmos KnEA (3) e NSGAIII apresentaram desempenho muito inferior ao esperado, ficando em quarto e quinto lugares, respectivamente.

Portanto, com base na análise realizada sobre as tabelas mencionadas, pode-se inferir que, para tarefas de mapeamento de aplicações em arquiteturas *manycore*, considerando as métricas (Energia x Balanceamento de Carga), o algoritmo SPEA 2 apresenta os melhores resultados gerais em relação à métrica de desempenho (*Hypervolume*). Dessa forma, pode-se determinar que o algoritmo SPEA 2 é uma boa escolha para essa tarefa.

Em suma, a análise dos resultados nas tabelas supracitadas demonstra que diferentes algoritmos apresentam desempenho variado dependendo do tamanho do *grid* e das métricas consideradas. Essa informação é crucial para a seleção adequada do algoritmo a ser utilizado em cenários específicos, permitindo a otimização do processo de mapeamento e, conseqüentemente, a melhoria no desempenho das arquiteturas *manycore*.

IGD

Utilizando como referência as tabelas A.2, A.10 e A.18, em relação à métrica de desempenho IGD, observa-se que, considerando o *grid* de tamanho 4 x 4, os algoritmos NSGAIII (12) e SPEA2 (16) alcançam os melhores resultados. Nas Tabelas A.10 (6 x 6) e A.18 (8 x 8), a mesma relação é apresentada, onde estão dispostos os algoritmos NSGAI (11) e SPEA2 (13),

NSGAI (13) e SPEA2 (11), respectivamente em cada uma das tabelas.

Ao realizar uma análise mais abrangente, considerando todo o cenário apresentado nas três referidas tabelas, verifica-se um desempenho similar dos dois algoritmos NSGAI (36) e SPEA (40), sem que haja uma tendência clara em relação aos tamanhos de *grid*. Por outro lado, os demais algoritmos obtiveram resultados pouco expressivos. Por exemplo, o algoritmo NSGAI alcançou 10 melhores resultados gerais, seguido pelo KnEA (4) e PESAI (0). Portanto, para tarefas que envolvam mapeamento de tarefas com relação às métricas (Energia e Balanceamento de Carga) e a distribuição de soluções ao longo da fronteira de Pareto, os algoritmos NSGAI e SPEA2 são boas escolhas. No entanto, com base no número de experimentos realizados, não é possível identificar diferenças significativas entre seus desempenhos.

5.3.2 Tolerância a falhas x Energia

Hypervolume

Com base nas Tabelas A.3, A.11 e A.19, em relação às métricas (Tolerância a falhas x Energia), observa-se que, considerando o *grid* de tamanho 4 x 4 (Tabela A.3), o algoritmo NSGAI (10) apresenta o melhor desempenho e, conseqüentemente, ocupa o primeiro lugar. O algoritmo SPEA2, com (9) melhores resultados, está em segundo lugar, seguido pelo algoritmo KnEA (6) em terceiro lugar. O algoritmo NSGAI ocupa a quarta posição, com 5 melhores resultados, enquanto o algoritmo PESAI exibe o pior desempenho, ficando na quinta posição. Vale ressaltar que, pelos valores de *score* obtidos pelos quatro primeiros colocados - NSGAI (19/0/11), NSGAI (22/2/6), SPEA2 (24/0/6) e KnEA (20/0/10) - o desempenho de todos foi bastante similar.

Na Tabela A.11, referente ao *grid* de tamanho 6 x 6, o algoritmo PESAI tem o melhor desempenho, com 10 melhores resultados, assumindo o primeiro lugar. O algoritmo KnEA (8) fica em segundo lugar, seguido pelo algoritmo NSGAI (6) em terceiro. Os algoritmos SPEA2 (3/10/17) e NSGAI (4/14/12), com 3 melhores resultados cada, estão na quarta e quinta posições, respectivamente, com base em seus *scores*.

A Tabela A.19, que apresenta os resultados para o *grid* de tamanho 8 x 8, mostra o algoritmo PESAI (26) com o melhor desempenho, ocupando o primeiro lugar. O algoritmo SPEA2 (3) está em segundo lugar e o algoritmo NSGAI (1) em terceiro. Os demais algoritmos não obtiveram os melhores resultados e foram classificados com base em seus *scores*: PESAI, KnEA (0/16/14) e NSGAI (0/21/9), ocupando o terceiro, quarto e quinto lugares, respectivamente.

Analisando de forma geral e considerando os resultados obtidos nos *grids* 4 x 4 (Tabela

A.1), 6 x 6 (Tabela A.9) e 8 x 8 (Tabela A.17), o algoritmo PESAI apresenta o melhor desempenho geral, alcançando um total de 36 melhores resultados e ocupando o primeiro lugar. Os demais algoritmos obtiveram resultados gerais bastante próximos: SPEA2 (15), KnEA (14), NSGAIII (13) e NSGAI (12), colocando-os em segundo, terceiro, quarto e quinto lugares, respectivamente. Há uma provável tendência de que, com o aumento do tamanho do *grid*, o algoritmo PESAI possa obter melhores resultados.

Para confirmar essa tendência, seria necessário realizar um número maior de testes. No entanto, com base nos dados apresentados, o algoritmo PESAI obteve o melhor desempenho no mapeamento de tarefas em arquiteturas *manycore* ao considerar as métricas (Tolerância a falhas e Energia). Sendo assim, o algoritmo PESAI é uma boa escolha para realizar tal tarefa.

IGD

Em uma análise focada na métrica de desempenho IGD, com base nas Tabelas A.4, A.12 e A.20, observa-se que, considerando o *grid* de tamanho 4 x 4 (Tabela A.4), o algoritmo PESAI apresenta o melhor desempenho, com um total de 24 melhores resultados. Na Tabela A.12 (*grid* de tamanho 6 x 6), os melhores desempenhos foram obtidos pelos algoritmos NSGA III (17) e PESAI (9), mostrando uma queda de desempenho do algoritmo PESA II. Por fim, ao analisar a Tabela A.20, correspondente ao *grid* de tamanho 8 x 8, verifica-se um grande número de melhores resultados obtidos pelo algoritmo NSGAI (23) e uma queda drástica no desempenho do algoritmo PESAI (0). Os outros algoritmos não foram contemplados nesta análise devido ao baixo desempenho geral obtido, onde o algoritmo NSGAI teve um desempenho geral (considerando as três tabelas supracitadas) de 6 melhores resultados, seguido por KnEA (5) e SPEA2 (2).

Analisando os aspectos gerais e desempenhos obtidos pelos algoritmos NSGAIII (44) e PESAI (33), nota-se um aumento do desempenho do algoritmo NSGAIII à medida que o tamanho do *grid* aumenta, enquanto em relação ao algoritmo PESAI ocorre o efeito inverso (queda no desempenho) conforme o tamanho do *grid* aumenta. Para comprovar efetivamente essa tendência, seria necessário realizar um número maior de experimentos. No entanto, é possível afirmar que, para tarefas de mapeamento em arquiteturas *manycore* considerando as métricas (Tolerância a Falhas e Energia), onde a distribuição de soluções ao longo da fronteira de Pareto é importante, favorecendo a escolha de bons mapas pelo usuário e/ou sistema inteligente e garantindo uma grande diversidade de soluções possíveis, os algoritmos NSGAI e PESAI são boas escolhas. Contudo, devido à possível tendência mencionada, caso seja necessário escolher apenas um algoritmo candidato, a opção mais provável seria o algoritmo NSGAIII.

5.3.3 Tolerância a falhas x Comunicação

Hypervolume

Considerando as Tabelas A.5, A.13 e A.21 em relação às métricas (Tolerância a falhas x Comunicação), observa-se que, para o *grid* de tamanho 4 x 4 (Tabela A.5), o algoritmo PESAI obtém o melhor resultado, alcançando o primeiro lugar com 11 melhores resultados. O segundo lugar é obtido pelo algoritmo SPEA2 (8); os algoritmos KnEA (5) e NSGAI (4) são posicionados em terceiro e quarto lugar, respectivamente; o quinto lugar é dedicado ao algoritmo NSGAIII (2). Entretanto, nenhum dos algoritmos conseguiu obter um resultado estatisticamente melhor quando comparados ao PESAI, e grande parte deles possui uma quantidade elevada de resultados estatisticamente iguais ao PESA II.

Na Tabela A.13, referente ao tamanho de *grid* 6 x 6, o algoritmo SPEA2 apresenta o melhor desempenho com 12 melhores resultados, seguido pelo algoritmo NSGAI (8) em segundo lugar; em terceiro lugar, encontra-se o algoritmo KnEA (7); o algoritmo PESAI ocupa o quarto lugar com apenas 3 dos melhores resultados obtidos. O algoritmo NSGAIII obteve o pior desempenho, sendo colocado em quinta posição.

Analisando a Tabela A.21 para o *grid* de tamanho 8 x 8, o algoritmo PESA II obtém 10 dos melhores resultados, posicionando-se em primeiro lugar; com resultados bem similares, o algoritmo KnEA (9) ocupa o segundo lugar; o terceiro lugar é obtido pelo algoritmo NSGAI; o algoritmo SPEA2 atinge um total de apenas 3 melhores resultados, obtendo a quarta posição; e, finalmente, com o pior desempenho, o algoritmo NSGAIII é posicionado em quinto lugar.

Em uma análise mais aprofundada, considerando todo o cenário (Tabelas A.5, A.13 e A.21), os algoritmos NSGAI (20), SPEA2 (23), KnEA (21) e PESAI (24) têm resultados gerais bem próximos. Mesmo com uma quantidade geral de melhores resultados maior obtida pelo PESAI, é difícil determinar qual é o melhor algoritmo relacionado à tarefa de mapeamento em arquiteturas *manycore* com relação às métricas (Tolerância a falhas x Comunicação). No entanto, ao analisar os *scores* gerais obtidos NSGAI (17/11/62), NSGAIII (6/32/52), SPEA2 (18/9/63) e KnEA (17/16/67), nota-se um grande número de resultados estatisticamente iguais ao PESAI e poucos resultados estatisticamente mais significativos que ele, além de vários resultados estatisticamente inferiores, fazendo assim com que o PESAI seja uma boa escolha para essa tarefa de mapeamento. Todavia, um número maior de experimentos com vistas à métrica supramencionada é necessário para comprovar a eficácia do algoritmo PESAI para a referida tarefa de mapeamento e corroborar com as assertivas efetuadas em relação à métrica de desempenho (*Hypervolume*).

Em resumo, embora o PESAI apresente uma quantidade geral maior de melhores resultados quando comparado aos demais algoritmos e pareça ser uma boa escolha para a tarefa de mapeamento em arquiteturas *manycore* com relação às métricas (Tolerância a falhas x Comunicação), é necessário realizar mais experimentos e análises para confirmar a eficácia do algoritmo PESAI para essa tarefa específica. Além disso, vale ressaltar que os algoritmos NSGAI, SPEA2 e KnEA também apresentam resultados próximos, o que indica que eles também podem ser considerados alternativas válidas para a tarefa de mapeamento em questão.

IGD

As Tabelas A.6, A.14 e A.22 apresentam os resultados referentes às métricas de Tolerância a Falhas e Comunicação. Observa-se que, para o *grid* de tamanho 4×4 apresentado na Tabela A.6, o algoritmo NSGA-III alcança o melhor resultado, obtendo um total de 26 acertos, seguido pelos algoritmos NSGAI (3) e KnEA (1). Ao analisar a Tabela A.14 (6×6), verifica-se novamente o melhor desempenho obtido pelo algoritmo NSGAI (28), enquanto o algoritmo SPEA2 alcança um resultado pouco expressivo com apenas 2 melhores resultados. Por fim, ao examinar a Tabela A.22 correspondente ao *grid* de tamanho 8×8 , constata-se uma ligeira diminuição do desempenho do algoritmo NSGAI (19) e um resultado mais distribuído entre os algoritmos NSGAI (6), SPEA2 (2) e KnEA (3).

O algoritmo NSGA-III obtém o melhor resultado considerando todas as tabelas mencionadas, perfazendo um total de 73 melhores resultados. Os demais algoritmos alcançam resultados pouco significativos, como, por exemplo, NSGAI (9), SPEA2 (4), KnEA (4) e PESAI (0). Portanto, pode-se inferir que o algoritmo NSGA-III é uma opção adequada quando a diversidade de soluções é necessária em tarefas de mapeamento de aplicações em arquiteturas *manycore*, com restrições relacionadas às métricas de Tolerância a Falhas e Comunicação.

5.3.4 Comunicação x Energia

Hypervolume

Ao analisar as Tabelas A.7, A.15 e A.23 em relação às métricas (Comunicação x Energia), observa-se que, no *grid* 4×4 representado pela Tabela A.7, o algoritmo PESAI apresenta um excelente desempenho, alcançando 19 melhores resultados e ocupando o primeiro lugar. Em segundo lugar, está o algoritmo SPEA2 (10), seguido pelo algoritmo NSGAI (1), posicionado em terceiro lugar. Os algoritmos NSGAI (0/23/7) e KnEA (0/25/5) estão em quarto e quinto lugares, respectivamente.

Ao examinar a Tabela A.15, que apresenta os resultados obtidos para o *grid* 6×6 , o algo-

ritmo PESAI novamente se destaca, ocupando o primeiro lugar com 18 melhores resultados. O algoritmo SPEA2 (12) está em segundo lugar, enquanto os algoritmos NSGAI (0/18/12), KnEA (0/25/5) e NSGA III (0/29/1) ocupam o terceiro, quarto e quinto lugares, respectivamente.

A análise da Tabela A.23, que representa os resultados referentes ao *grid* 8 x 8, mostra mais uma vez o melhor desempenho do algoritmo PESAI (17), posicionando-o em primeiro lugar. O algoritmo SPEA2 está em segundo lugar com 8 melhores resultados, enquanto o algoritmo NSGAI (5) ocupa o terceiro lugar. Os algoritmos KnEA (1/12/17) e NSGAIII (0/26/4) estão em quarto e quinto lugares, respectivamente.

Com base nos resultados gerais obtidos nas Tabelas A.7, A.15 e A.23, pode-se concluir que o algoritmo PESAI (54) apresenta o melhor desempenho, sendo uma boa opção para o mapeamento de tarefas em arquiteturas manycore, considerando as métricas (Comunicação x Energia). Vale destacar também o bom desempenho do algoritmo SPEA2 (30), que pode ser considerado como outra alternativa viável para essa finalidade. Ambos os algoritmos obtiveram resultados satisfatórios em relação à métrica de desempenho (*Hypervolume*).

IGD

As Tabelas A.8, A.16 e A.24 apresentam os resultados referentes aos *grids* de tamanho 4 x 4, 6 x 6 e 8 x 8, considerando a métrica IGD como forma de avaliação de desempenho dos MOEAs. Com base na Tabela A.7, os melhores resultados foram alcançados pelos algoritmos SPEA2 (20) e NSGAI (10), enquanto os outros algoritmos não obtiveram nenhum resultado superior. Na Tabela A.16, o algoritmo SPEA2 superou o NSGAI, apresentando 25 melhores resultados; o NSGAIII obteve 4 melhores resultados e o KnEA (1). Por fim, ao analisar a Tabela A.24, observa-se um empate entre os algoritmos NSGAIII e SPEA2, ambos com 14 melhores resultados, e o algoritmo NSGAI obteve 2 melhores resultados.

Examinando os resultados gerais das Tabelas A.8, A.16 e A.24, verifica-se que o algoritmo SPEA2 (59) apresenta um desempenho superior; o segundo melhor resultado geral foi obtido pelo algoritmo NSGAIII (28). Os algoritmos NSGAI (2) e KNEA (1) mostraram-se pouco efetivos na tarefa de mapeamento proposta em relação à métrica (Comunicação e Energia), enquanto o algoritmo PESAI (0) não obteve nenhum resultado superior. Portanto, para tarefas de mapeamento em arquiteturas manycore que demandem uma grande diversidade de soluções em relação à métrica (Comunicação e Energia), o algoritmo SPEA2 é uma boa escolha.

5.4 Resultados numéricos com o uso do procedimento autoadaptativo

Na presente seção é demonstrada uma análise pormenorizada dos resultados obtidos pelos algoritmos de mapeamento, quando se recorre ao uso do procedimento autoadaptativo proposto nesta tese.

5.4.1 Energia x Balanceamento de Carga

Hypervolume

Nas Tabelas A.1 e A.25, são apresentadas os resultados sem e com o procedimento autoadaptativo para o *grid* de tamanho 4 x 4. Observa-se um desempenho semelhante das duas abordagens. No procedimento sem adaptação, os algoritmos SPEA2 e PESAI obtiveram 14 e 16 melhores resultados, respectivamente. Já com o uso do procedimento autoadaptativo, foram alcançados os mesmos resultados, enquanto os outros algoritmos não obtiveram bons resultados.

As Tabelas A.9 e A.33 é mostrado os resultados para o *grid* 6 x 6, sem e com adaptação, respectivamente. O desempenho do algoritmo PESAI melhorou com o uso do procedimento autoadaptativo, diminuindo o número de melhores resultados obtidos pelo algoritmo SPEA2. Antes do uso do procedimento autoadaptativo, o algoritmo SPEA2 possuía um *score* de (30 0 0), ou seja, 30 resultados melhores que o PESAI. Com o uso do procedimento, o *score* do SPEA2 mudou para (16 0 14), apresentando apenas 16 melhores resultados e 14 resultados estatisticamente semelhantes ao PESAI.

Nas Tabelas A.17 e A.41, são apresentados os resultados correspondentes ao *grid* de tamanho 8 x 8 sem e com o uso do procedimento autoadaptativo. Observa-se que o algoritmo SPEA2 teve seu desempenho otimizado, pois com o procedimento autoadaptativo, obteve 26 melhores resultados, em comparação aos 11 melhores resultados alcançados sem o procedimento. Nota-se também uma melhora no algoritmo PESAI, pois, com a adição do referido procedimento, o *score* do SPEA2 (29 0 1) passou para (16 0 14).

Ao analisar as Tabelas A.1, A.9 e A.17, referentes ao não uso do procedimento autoadaptativo, em comparação às Tabelas A.25, A.33 e A.41, nota-se a melhora geral dos algoritmos SPEA2 e PESAI. Com o procedimento autoadaptativo, os dois algoritmos obtiveram 68 e 22 melhores resultados, respectivamente. No entanto, sem o procedimento, foram alcançados SPEA2 (55) e PESAI (16). Outro ponto a ser considerado é que, antes do procedimento, os al-

goritmos alcançaram os seguintes resultados: NSGAI (15), NSGAIII (1) e KnEA (3); todavia, após o uso do procedimento, não obtiveram nenhum melhor resultado. Isso evidencia a melhor resposta dos algoritmos SPEA2 e PESAI ao procedimento proposto.

Em resumo, a implementação do procedimento autoadaptativo mostrou-se benéfica para os algoritmos SPEA2 e PESAI, melhorando seu desempenho em relação aos melhores resultados alcançados. A análise das tabelas indica que o uso do procedimento autoadaptativo pode ajudar na otimização do mapeamento de tarefas em arquiteturas manycore, especialmente em relação às métricas de Comunicação e Energia. A escolha do algoritmo SPEA2 ou PESAI dependerá das necessidades específicas do problema em questão, mas ambos mostraram-se eficazes com a implementação do procedimento autoadaptativo.

IGD

A análise em relação à métrica de desempenho IGD será realizada de forma sucinta. Considerando as Tabelas A.2, A.10 e A.18, referentes ao não uso do procedimento autoadaptativo, em comparação com as Tabelas A.26, A.34 e A.42, que fazem uso do procedimento, observa-se um pequeno ganho de desempenho do algoritmo SPEA2. Antes do uso do procedimento, foram obtidos 40 melhores resultados; ao aplicar o referido procedimento, o algoritmo em questão alcançou 48 melhores resultados.

Os outros algoritmos, em detrimento do melhor resultado do SPEA2, obtiveram resultados menos significativos. Por exemplo, o algoritmo NSGAI foi de 10 para apenas 5 melhores resultados, já os algoritmos KnEA (4 – 3) e NSGAIII (36 – 34) não tiveram seu desempenho prejudicado significativamente.

Essa análise sugere que o procedimento autoadaptativo proporcionou uma melhora no desempenho do algoritmo SPEA2 em relação à métrica IGD. Por outro lado, os demais algoritmos não apresentaram melhorias significativas ou tiveram seus desempenhos levemente prejudicados. Portanto, a implementação do procedimento autoadaptativo pode ser benéfica para problemas que exigem uma maior diversidade de soluções na métrica de Comunicação e Energia, em especial quando se utiliza o algoritmo SPEA2.

5.4.2 Tolerância a falhas x Energia

Hypervolume

O tamanho do *grid* 4x4 é apresentado nas Tabelas A.3 e A.27 sem e com a utilização do procedimento autoadaptativo proposto, respectivamente. Ao analisar as tabelas, pode-se notar

um desempenho bem similar entre as abordagens.

Entretanto, ao consultar as Tabelas A.11 e A.35, referente ao grid de tamanho 6x6, observa-se um aumento evidente no desempenho do algoritmo PESAI, que totaliza 22 melhores resultados, seguido por NSGAI (1), SPEA2 (4) e KnEA (3).

O resultado mais expressivo foi obtido na comparação das Tabelas A.19 e A.43, que correspondem ao *grid* de tamanho 8x8. O algoritmo PESAI obteve todos os melhores resultados, e nenhum dos outros algoritmos alcançou ao menos um resultado significativamente melhor que ele.

Ao comparar as Tabelas A.3, A.11 e A.19 (sem o uso do procedimento) e as Tabelas A.27, A.35 e A.43 (com o uso do procedimento), nota-se um aumento significativo do desempenho geral obtido pelo algoritmo PESAI quando se recorre ao procedimento autoadaptativo. Esse algoritmo obteve um total de 52 melhores resultados, comparado aos 36 melhores resultados obtidos anteriormente sem o uso do procedimento.

Essa comparação evidencia o aumento de desempenho obtido pelo algoritmo PESAI com a utilização do procedimento autoadaptativo proposto na presente tese, demonstrando sua eficácia na melhoria do desempenho em diferentes tamanhos de *grid*.

IGD

Nas Tabelas A.4, A.12 e A.20 (sem o uso do procedimento) e as Tabelas A.28, A.36 e A.44 (com o uso do procedimento), são apresentados os resultados obtidos em relação às métricas (Tolerância a falhas x Energia) considerando os tamanhos de grid 4x4, 6x6 e 8x8. A presente análise tem como base a métrica de avaliação de desempenho de MOEAs denominada IGD.

A partir dos dados contidos nessas tabelas, pode-se inferir que houve um aumento significativo no desempenho do algoritmo NSGAIII, que saltou de 44 melhores resultados para 63 melhores resultados, sem e com o uso do procedimento autoadaptativo, respectivamente. O algoritmo PESAI teve uma queda no desempenho, com uma redução de 7 melhores resultados (de 33 para 26). Os algoritmos KnEA e NSGAI foram os que tiveram as quedas de desempenho mais significativas, pois não obtiveram nenhum melhor resultado após a aplicação do procedimento autoadaptativo.

Portanto, pode-se dizer que, com a utilização do procedimento autoadaptativo, o algoritmo NSGAIII teve seu desempenho aprimorado, sugerindo que a maioria dos algoritmos que fazem uso do procedimento têm suas possíveis qualidades na obtenção de bons resultados aperfeiçoadas. No entanto, vale ressaltar que nem todos os algoritmos apresentaram melhora no desempenho, indicando que a aplicação do procedimento autoadaptativo pode ter efeitos distintos

dependendo do algoritmo utilizado.

5.4.3 Tolerância a falhas x Comunicação

Hypervolume

Nas Tabelas A.5 e A.29 são apresentados resultados referentes ao *grid* de tamanho 4 x 4, com e sem a utilização do procedimento autoadaptativo. A partir desses resultados, pode-se inferir um leve aumento no desempenho obtido pelo algoritmo PESAI, que obteve 13 melhores resultados com o procedimento, em comparação aos 11 melhores resultados sem o uso do procedimento.

Analisando as Tabelas A.13 e A.37, que representam as soluções para o *grid* de tamanho 6 x 6 sem e com o procedimento proposto, nota-se um aumento mais significativo no desempenho obtido pelo algoritmo PESAI, que obteve 15 melhores resultados com o procedimento, comparado a apenas 3 melhores resultados sem a utilização do procedimento autoadaptativo.

Ao considerar as Tabelas A.21 e A.45, referentes aos resultados sem e com o procedimento autoadaptativo para o *grid* de tamanho 8 x 8, nota-se um grande aumento no desempenho obtido pelo algoritmo PESAI. Com o procedimento, o algoritmo alcançou 29 melhores resultados, enquanto sem o procedimento foram apenas 10 melhores resultados.

Ao analisar todas as tabelas referentes ao não uso do procedimento (A.5, A.13 e A.21) e as tabelas com o uso do procedimento autoadaptativo (A.29, A.37 e A.45), pode-se inferir um aumento significativo do desempenho obtido pelo algoritmo PESAI quando utilizado com o procedimento autoadaptativo proposto. O total de melhores resultados aumentou de 24 sem o procedimento para 57 com o procedimento. Além disso, pode-se sugerir que o desempenho seja influenciado pelo aumento do tamanho do *grid*, uma vez que os melhores resultados aparecem nos *grids* de tamanho 6 x 6 e 8 x 8.

IGD

Para obter uma visão mais realista sobre a qualidade dos resultados em relação à distribuição de soluções na fronteira de Pareto (IGD), considerando as métricas de Tolerância a Falhas e Comunicação, foram observados os tamanhos de grade 4x4, 6x6 e 8x8. Os resultados são apresentados nas Tabelas A.6, A.14 e A.22, referentes ao uso do procedimento convencional, e nas Tabelas A.30, A.38 e A.46, correspondentes ao uso do procedimento autoadaptativo.

Observou-se que o uso do procedimento autoadaptativo resultou em um desempenho aprimorado em relação ao procedimento convencional. Por exemplo, o algoritmo NSGAIII apre-

sentou um aumento de 73 para 83 dos melhores resultados, dentre os 90 melhores resultados possíveis. Isso corrobora a tese do melhor desempenho do algoritmo NSGAIII em relação ao IGD quando consideradas as métricas de Tolerância a Falhas e Comunicação.

5.4.4 Comunicação x Energia

Hypervolume

As Tabelas A.7 e A.31 apresentam os resultados obtidos para o grid de tamanho 4x4, sem e com o uso do procedimento autoadaptativo proposto. Observou-se um pequeno ganho de desempenho para o algoritmo PESAI (21) em relação ao desempenho anterior, sem o uso do procedimento (19 melhores resultados).

Já as Tabelas A.15 e A.39 correspondem ao grid de tamanho 6x6, sem e com o uso do procedimento proposto. Verificou-se um resultado mais significativo para o algoritmo PESAI (25 melhores resultados) em comparação à abordagem sem o uso do procedimento (18), e uma queda no desempenho do algoritmo SPEA2, que obteve 12 melhores resultados antes da aplicação do procedimento e 5 melhores resultados com o uso deste. Isso evidencia o melhor desempenho do algoritmo PESAI quando utiliza o procedimento autoadaptativo, superando amplamente os outros algoritmos avaliados.

Além disso, é importante considerar as Tabelas A.23 e A.47 correspondentes ao grid de tamanho 8x8, sem e com o uso do procedimento proposto. Observou-se um desempenho inferior ao obtido anteriormente sem o uso do procedimento, com 17 melhores resultados sem o uso e 16 melhores resultados com o uso. Tal diminuição de desempenho, ainda que pequena, requer um estudo mais aprofundado para determinar a causa.

No entanto, ao analisar o cenário completo apresentado pelas Tabelas A.7, A.15 e A.23 (sem o uso do procedimento) e as Tabelas A.31, A.39 e A.47 (com o uso do procedimento), notou-se um aumento no desempenho geral do algoritmo PESAI. Anteriormente, sem o uso do procedimento, foram alcançados 54 melhores resultados em comparação à abordagem com o uso do procedimento, que obteve um total de 62 melhores resultados. É importante destacar que o algoritmo SPEA2 manteve um bom desempenho, obtendo 27 melhores resultados com o uso do procedimento e 30 melhores resultados sem o uso deste.

IGD

Ao analisar o cenário completo apresentado pelas Tabelas A.8, A.16 e A.24 (sem o uso do procedimento) e as Tabelas A.32, A.40 e A.48 (com o uso do procedimento), considerando

os tamanhos de grid 4x4, 6x6 e 8x8 e as métricas de Comunicação e Energia, observou-se novamente um aumento de desempenho dos algoritmos quando se utiliza o procedimento autoadaptativo. Neste caso, o algoritmo SPEA2 foi o grande vencedor, obtendo um total de 67 melhores resultados, em comparação aos 59 melhores resultados obtidos anteriormente sem o uso do procedimento.

Os outros algoritmos NSGAI (2 - 5), NSGAIII (28 - 18) e KnEA (1 - 0) não apresentaram um aumento significativo de desempenho com o uso do procedimento. Desta forma, pode-se sugerir que o algoritmo SPEA2 é o mais indicado quando se consideram as métricas de Comunicação e Energia para obtenção de melhores resultados de IGD.

No capítulo em questão foi apresentada uma análise aprofundada sobre o uso de algoritmos MOEAs e suas métricas de desempenho, para avaliar o desempenho desses algoritmos em diferentes cenários. As métricas de desempenho utilizadas foram o IGD e o *Hypervolume*, que são indicadores comumente utilizados para avaliar a qualidade das soluções obtidas pelos algoritmos MOEAs.

Além disso, o capítulo abordou uma análise detalhada sobre as métricas utilizadas para o mapeamento de tarefas em arquiteturas manycore. Esse tipo de arquitetura é caracterizado pela presença de múltiplos núcleos de processamento, permitindo a execução de várias tarefas simultaneamente. No entanto, o mapeamento adequado das tarefas é crucial para garantir um desempenho eficiente do sistema.

Nesse sentido, a análise das métricas de desempenho dos algoritmos MOEAs é de grande importância para a escolha adequada do algoritmo a ser utilizado no mapeamento de tarefas em arquiteturas manycore. O IGD e o *Hypervolume* são indicadores que podem fornecer informações valiosas sobre o desempenho dos algoritmos MOEAs, permitindo que sejam selecionados os mais adequados para cada caso específico.

Portanto, a realização de estudos que avaliem o desempenho dos algoritmos MOEAs em diferentes cenários e a análise das métricas de desempenho para o mapeamento de tarefas em arquiteturas manycore são temas de grande relevância na área de computação, contribuindo para o avanço do conhecimento e para a melhoria do desempenho dos sistemas computacionais.

Capítulo 6

CONCLUSÃO, LIMITAÇÕES E TRABALHOS FUTUROS

Na presente tese é apresentado o desenvolvimento de um *framework* para estudos de técnicas de mapeamento de aplicações baseadas em grafos acíclicos orientados em arquiteturas *manycore*. Para isso, foram implementados alguns algoritmos multiobjetivos (MOEAs) visando otimizar quatro métricas importantes: tolerância a falhas, eficiência energética, comunicação e balanceamento de carga. Por meio da solução apresentada, o usuário tem a possibilidade de escolher o melhor mapeamento de uma certa aplicação para uma dada métrica ou uma solução que contemple uma interação entre duas ou mais, além de facilitar a escolha do algoritmo a ser utilizado para a alocação de tarefas na referida arquitetura.

Antes do estudo de técnicas de mapeamento de aplicações reais proposto, foi realizado um processo de calibração, por meio do uso de grafos contendo aplicações reais e sintéticas, visando determinar o melhor algoritmo MOEA para tal propósito. Foi constatado que o melhor algoritmo para este objetivo foi o PESAI, contrariando os trabalhos mais tradicionais encontrados na literatura da área, que usaram os algoritmos NSGAI e NSGAIII no mesmo contexto.

Após a fase de testes inicial, foi utilizado um procedimento de otimização 1D, de um objetivo, para determinar o melhor filtro a ser utilizado no processo de mapeamento, para o *manycore*, por meio do uso do PESAI para otimização de métricas simultâneas. A metodologia proposta foi eficaz em obter os melhores resultados para as métricas estudadas, tanto para grafos sintéticos quanto para aplicações reais.

Além das métricas estudadas, foram apresentados estudos referentes à otimização de novas métricas, tais como IGD e *Hypervolume*. Os resultados encontrados demonstraram a maior efetividade do PESAI em obter os melhores resultados para essas métricas em arquiteturas

manycore.

Foi proposta uma nova ideia de procedimento autoadaptativo em relação às operações de cruzamento dos algoritmos utilizados, que aumentou o desempenho dos algoritmos previamente testados. O procedimento autoadaptativo proposto demonstrou a capacidade de aprimorar e obter melhores resultados para os MOEAs testados para os mapeamentos estudados nesta tese.

As limitações encontradas incluem a quantidade de simulações necessárias e a dependência de *hardware* para simulação. Em trabalhos futuros, podem ser incorporadas novas métricas, algoritmos e estratégias autoadaptativas, além da adição de outras funcionalidades, como a incorporação de novas formas de roteamento e outras topologias.

Em resumo, a presente tese apresentou um *framework* eficaz para estudos de técnicas de mapeamento de aplicações em arquiteturas *manycore*, com resultados significativos na otimização de métricas importantes e contribuições relevantes para a área.

REFERÊNCIAS

- AGARWAL, A.; ISKANDER, C.; SHANKAR, R. Survey of network on chip (noc) architectures & contributions. *Journal of engineering, Computing and Architecture*, v. 3, n. 1, p. 21–27, 2009.
- AGGARWAL, A.; FRANKLIN, M. Hierarchical interconnects for on-chip clustering. In: IEEE. *Proceedings 16th International Parallel and Distributed Processing Symposium*. [S.l.], 2001. p. 8–pp.
- ALEXOUDI, T.; TERZENIDIS, N.; PITRIS, S.; MORALIS-PEGIOS, M.; MANIOTIS, P.; VAGIONAS, C.; MITSOLIDOU, C.; MOURGIAS-ALEXANDRIS, G.; KANELLOS, G. T.; MILIOU, A. et al. Optics in computing: from photonic network-on-chip to chip-to-chip interconnects and disintegrated architectures. *Journal of Lightwave Technology*, IEEE, v. 37, n. 2, p. 363–379, 2019.
- AMIN, W.; HUSSAIN, F.; ANJUM, S.; KHAN, S.; BALOCH, N. K.; NAIN, Z.; KIM, S. W. Performance evaluation of application mapping approaches for network-on-chip designs. *IEEE Access*, IEEE, v. 8, p. 63607–63631, 2020.
- ASCIA, G.; CATANIA, V.; PALESI, M. Multi-objective mapping for mesh-based noc architectures. In: ACM. *Proceedings of the 2nd IEEE/ACM/IFIP international conference on Hardware/software codesign and system synthesis*. [S.l.], 2004. p. 182–187.
- AZAD, S. P.; NIAZMAND, B.; JANSON, K.; GEORGE, N.; OYENIRAN, A. S.; PUTKARADZE, T.; KAUR, A.; RAIK, J.; JERVAN, G.; UBAR, R. et al. From online fault detection to fault management in network-on-chips: A ground-up approach. In: IEEE. *2017 IEEE 20th International Symposium on Design and Diagnostics of Electronic Circuits & Systems (DDECS)*. [S.l.], 2017. p. 48–53.
- BEECHU, N. K. R.; HARISHCHANDRA, V. M.; BALACHANDRA, N. K. Y. High-performance and energy-efficient fault-tolerance core mapping in noc. *Sustainable Computing: Informatics and Systems*, Elsevier, v. 16, p. 1–10, 2017.
- BEECHU, N. K. R.; HARISHCHANDRA, V. M.; BALACHANDRA, N. K. Y. An energy-efficient fault-aware core mapping in mesh-based network on chip systems. *Journal of Network and Computer Applications*, Elsevier, v. 105, p. 79–87, 2018.
- BHOWMIK, B.; BISWAS, S.; DEKA, J. K.; BHATTACHARYA, B. B. Reliability-aware test methodology for detecting short-channel faults in on-chip networks. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, IEEE, v. 26, n. 6, p. 1026–1039, 2018.

- BJERREGAARD, T.; MAHADEVAN, S. A survey of research and practices of network-on-chip. *ACM Computing Surveys (CSUR)*, ACM New York, NY, USA, v. 38, n. 1, p. 1–es, 2006.
- BONNEY, C.; CAMPOS, P.; DAHIR, N.; TEMPESTI, G. Fault tolerant task mapping on many-core arrays. In: IEEE. *2016 IEEE Symposium Series on Computational Intelligence (SSCI)*. [S.l.], 2016. p. 1–8.
- BRINGMANN, K.; FRIEDRICH, T. Approximation quality of the hypervolume indicator. *Artificial Intelligence*, Elsevier, v. 195, p. 265–290, 2013.
- BRODTKORB, A. R.; HAGEN, T. R.; SCHULZ, C.; HASLE, G. Gpu computing in discrete optimization. part i: Introduction to the gpu. *EURO journal on transportation and logistics*, Elsevier, v. 2, n. 1-2, p. 129–157, 2013.
- CAMPOS, P.; DAHIR, N.; BONNEY, C.; TREFZER, M.; TYRRELL, A.; TEMPESTI, G. Xl-stage: A cross-layer scalable tool for graph generation, evaluation and implementation. In: IEEE. *2016 International Conference on Embedded Computer Systems: Architectures, Modeling and Simulation (SAMOS)*. [S.l.], 2016. p. 354–359.
- CASTILHOS, G.; MANDELLI, M.; OST, L.; MORAES, F. G. Hierarchical energy monitoring for task mapping in many-core systems. *Journal of Systems Architecture*, Elsevier, v. 63, p. 80–92, 2016.
- CHATTERJEE, N.; PAUL, S.; CHATTOPADHYAY, S. Fault-tolerant dynamic task mapping and scheduling for network-on-chip-based multicore platform. *ACM Transactions on Embedded Computing Systems (TECS)*, ACM New York, NY, USA, v. 16, n. 4, p. 1–24, 2017.
- CHATTERJEE, N.; PAUL, S.; MUKHERJEE, P.; CHATTOPADHYAY, S. Deadline and energy aware dynamic task mapping and scheduling for network-on-chip based multi-core platform. *Journal of Systems Architecture*, Elsevier, v. 74, p. 61–77, 2017.
- CHAWADE, S. D.; GAIKWAD, M. A.; PATRIKAR, R. M. Review of xy routing algorithm for network-on-chip architecture. *International Journal of Computer Applications*, International Journal of Computer Applications, 244 5 th Avenue,# 1526, New . . . , v. 43, n. 21, p. 975–8887, 2012.
- COELLO, C. A. C.; CORTÉS, N. C. Solving multiobjective optimization problems using an artificial immune system. *Genetic programming and evolvable machines*, Springer, v. 6, n. 2, p. 163–190, 2005.
- CORNE, D. W.; JERRAM, N. R.; KNOWLES, J. D.; OATES, M. J. Pesa-ii: Region-based selection in evolutionary multiobjective optimization. In: *Proceedings of the 3rd Annual Conference on Genetic and Evolutionary Computation*. [S.l.: s.n.], 2001. p. 283–290.
- CULLER, D.; SINGH, J. P.; GUPTA, A. *Parallel computer architecture: a hardware/software approach*. [S.l.]: Gulf Professional Publishing, 1999.
- CUZICK, J. A wilcoxon-type test for trend. *Statistics in medicine*, Wiley Online Library, v. 4, n. 1, p. 87–90, 1985.
- DALLY, W. J.; TOWLES, B. Route packets, not wires: on-chip interconnection networks. In: *Proceedings of the 38th annual design automation conference*. [S.l.: s.n.], 2001. p. 684–689.

- DALLY, W. J.; TOWLES, B. P. *Principles and practices of interconnection networks*. [S.l.]: Elsevier, 2004.
- DEB, K. Multi-objective optimisation using evolutionary algorithms: an introduction. In: *Multi-objective evolutionary optimisation for product design and manufacturing*. [S.l.]: Springer, 2011. p. 3–34.
- DEB, K.; AGRAWAL, S.; PRATAP, A.; MEYARIVAN, T. A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: NSGA-II. In: SPRINGER. *International conference on parallel problem solving from nature*. [S.l.], 2000. p. 849–858.
- DEB, K.; JAIN, H. An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, part i: solving problems with box constraints. *IEEE transactions on evolutionary computation*, IEEE, v. 18, n. 4, p. 577–601, 2013.
- DEB, K.; SINHA, A. An efficient and accurate solution methodology for bilevel multi-objective programming problems using a hybrid evolutionary-local-search algorithm. *Evolutionary computation*, MIT Press One Rogers Street, Cambridge, MA 02142-1209, USA journals-info ..., v. 18, n. 3, p. 403–449, 2010.
- DEY, N.; DAS, H.; NAIK, B.; BEHERA, H. S. *Big data analytics for intelligent healthcare management*. [S.l.]: Academic Press, 2019.
- DICK, R. P.; RHODES, D. L.; WOLF, W. Tgff: task graphs for free. In: IEEE. *Proceedings of the Sixth International Workshop on Hardware/Software Codesign.(CODES/CASHE'98)*. [S.l.], 1998. p. 97–101.
- DONYANAVARD, B.; MÜCK, T.; SARMA, S.; DUTT, N. Sparta: Runtime task allocation for energy efficient heterogeneous manycores. In: IEEE. *2016 International Conference on Hardware/Software Codesign and System Synthesis (CODES+ ISSS)*. [S.l.], 2016. p. 1–10.
- GUERREIRO, A. P.; FONSECA, C. M.; PAQUETE, L. The hypervolume indicator: Problems and algorithms. *arXiv preprint arXiv:2005.00515*, 2020.
- GUNANTARA, N. A review of multi-objective optimization: Methods and its applications. *Cogent Engineering*, Taylor & Francis, v. 5, n. 1, p. 1502242, 2018.
- GUO, D.; CHO, Y. J.; ZHU, J. *Partial ordering methods in nonlinear problems*. [S.l.]: Nova Publishers, 2004.
- HAGHBAYAN, M.-H.; MIELE, A.; RAHMANI, A. M.; LILJEBERG, P.; TENHUNEN, H. A lifetime-aware runtime mapping approach for many-core systems in the dark silicon era. In: IEEE. *2016 Design, Automation & Test in Europe Conference & Exhibition (DATE)*. [S.l.], 2016. p. 854–857.
- HONGZE, X.; YE, W. X.; MAOSHENG, X. Schema analysis of multi-points crossover genetic algorithm. In: IEEE. *Proceedings of the 3rd World Congress on Intelligent Control and Automation (Cat. No. 00EX393)*. [S.l.], 2000. v. 1, p. 521–524.
- HU, J.; MARCULESCU, R. Energy-and performance-aware mapping for regular noc architectures. *IEEE Transactions on computer-aided design of integrated circuits and systems*, IEEE, v. 24, n. 4, p. 551–562, 2005.

- JANTSCH, A. Communication performance in networks-on-chip. *Royal Institute of Technology, Stockholm, November, 2003*.
- JIAO, F.; DONG, S.; YU, B.; LI, B.; SCHLICHTMANN, U. Thermal-aware placement and routing for 3d optical networks-on-chips. In: IEEE. *2018 IEEE International Symposium on Circuits and Systems (ISCAS)*. [S.l.], 2018. p. 1–4.
- JU, T.; ZHANG, Y.; ZHANG, X.; DU, X.; DONG, X. Energy-efficient thread mapping for heterogeneous many-core systems via dynamically adjusting the thread count. *Energies*, Multi-disciplinary Digital Publishing Institute, v. 12, n. 7, p. 1346, 2019.
- KARKAR, A.; MAK, T.; TONG, K.-F.; YAKOVLEV, A. A survey of emerging interconnects for on-chip efficient multicast and broadcast in many-cores. *IEEE Circuits and Systems Magazine*, IEEE, v. 16, n. 1, p. 58–72, 2016.
- KERMANI, P.; KLEINROCK, L. Virtual cut-through: A new computer communication switching technique. *Computer Networks (1976)*, Elsevier, v. 3, n. 4, p. 267–286, 1979.
- KIM, T.; SUN, Z.; CHEN, H.-B.; WANG, H.; TAN, S. X.-D. Energy and lifetime optimizations for dark silicon manycore microprocessor considering both hard and soft errors. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, IEEE, v. 25, n. 9, p. 2561–2574, 2017.
- KORA, P.; YADLAPALLI, P. Crossover operators in genetic algorithms: A review. *International Journal of Computer Applications*, Foundation of Computer Science, v. 162, n. 10, 2017.
- KOREJO, I. A.; KHUHRO, Z.; JOKHIO, F.; CHANNA, N.; NIZAMANI, H. An adaptive crossover operator for genetic algorithms to solve the optimization problems. *Sindh University Research Journal-SURJ (Science Series)*, v. 45, n. 2, 2013.
- KRAMER, O. Evolutionary self-adaptation: a survey of operators and strategy parameters. *Evolutionary Intelligence*, Springer, v. 3, n. 2, p. 51–65, 2010.
- LI, R.; GONG, W.; LU, C. Self-adaptive multi-objective evolutionary algorithm for flexible job shop scheduling with fuzzy processing time. *Computers & Industrial Engineering*, Elsevier, v. 168, p. 108099, 2022.
- LIANG, J.; WANG, P.; GUO, L.; QU, B.; YUE, C.; YU, K.; WANG, Y. Multi-objective flow shop scheduling with limited buffers using hybrid self-adaptive differential evolution. *Memetic Computing*, Springer, v. 11, n. 4, p. 407–422, 2019.
- LIU, W.; YANG, L.; JIANG, W.; FENG, L.; GUAN, N.; ZHANG, W.; DUTT, N. Thermal-aware task mapping on dynamically reconfigurable network-on-chip based multiprocessor system-on-chip. *IEEE Transactions on Computers*, IEEE, v. 67, n. 12, p. 1818–1834, 2018.
- MANFERDELLI, J. L.; GOVINDARAJU, N. K.; CRALL, C. Challenges and opportunities in many-core computing. *Proceedings of the IEEE*, IEEE, v. 96, n. 5, p. 808–815, 2008.
- MARTINS, A. L. del M.; SILVA, A. H. L. da; RAHMANI, A. M.; DUTT, N.; MORAES, F. G. Hierarchical adaptive multi-objective resource management for many-core systems. *Journal of Systems Architecture*, Elsevier, v. 97, p. 416–427, 2019.

- MARWEDEL, P.; BACIVAROV, I.; LEE, C.; TEICH, J.; THIELE, L.; XU, Q.; KOUVELI, G.; HA, S.; HUANG, L. Mapping of applications to mpsocs. In: IEEE. *2011 Proceedings of the Ninth IEEE/ACM/IFIP International Conference on Hardware/Software Codesign and System Synthesis (CODES+ ISSS)*. [S.l.], 2011. p. 109–118.
- MEYER-NIEBERG, S.; BEYER, H.-G. Self-adaptation in evolutionary algorithms. In: *Parameter setting in evolutionary algorithms*. [S.l.]: Springer, 2007. p. 47–75.
- MOHAMMAD, M. E. *Distributed run-time and power constraints mapping for many-core systems*. [S.l.]: Southern Illinois University at Carbondale, 2016.
- NAMAZI, A.; ABDOLLAHI, M.; SAFARI, S.; MOHAMMADI, S. Lorap: low-overhead power and reliability-aware task mapping based on instruction footprint for real-time applications. In: IEEE. *2017 Euromicro Conference on Digital System Design (DSD)*. [S.l.], 2017. p. 364–367.
- NAMAZI, A.; ABDOLLAHI, M.; SAFARI, S.; MOHAMMADI, S. A majority-based reliability-aware task mapping in high-performance homogenous noc architectures. *ACM Transactions on Embedded Computing Systems (TECS)*, ACM New York, NY, USA, v. 17, n. 1, p. 1–31, 2017.
- PANDE, P. P.; GRECU, C.; JONES, M.; IVANOV, A.; SALEH, R. Performance evaluation and design trade-offs for network-on-chip interconnect architectures. *IEEE transactions on Computers*, IEEE, v. 54, n. 8, p. 1025–1040, 2005.
- PARHAMI, B. *Introduction to parallel processing: algorithms and architectures*. [S.l.]: Springer Science & Business Media, 2006.
- PATTERSON, D. The trouble with multi-core. *IEEE Spectrum*, IEEE, v. 47, n. 7, p. 28–32, 2010.
- POLI, R.; LANGDON, W. B. Genetic programming with one-point crossover. In: *Soft Computing in Engineering Design and Manufacturing*. [S.l.]: Springer, 1998. p. 180–189.
- QU, B.; ZHU, Y.; JIAO, Y.; WU, M.; SUGANTHAN, P. N.; LIANG, J. A survey on multi-objective evolutionary algorithms for the solution of the environmental/economic dispatch problems. *Swarm and Evolutionary Computation*, Elsevier, v. 38, p. 1–11, 2018.
- RETTKOWSKI, J.; GÖHRINGER, D. Asir: Application-specific instruction-set router for noc-based mpsocs. *Computers*, Multidisciplinary Digital Publishing Institute, v. 7, n. 3, p. 38, 2018.
- SAHNER, R. A.; TRIVEDI, K. S. Performance and reliability analysis using directed acyclic graphs. *IEEE Transactions on Software Engineering*, IEEE, n. 10, p. 1105–1114, 1987.
- SAHU, P. K.; CHATTOPADHYAY, S. A survey on application mapping strategies for network-on-chip design. *Journal of systems architecture*, Elsevier, v. 59, n. 1, p. 60–76, 2013.
- SALEHI, M.; EJLALI, A.; SHAFIQUE, M. Run-time adaptive power-aware reliability management for manycores. *IEEE Design & Test*, IEEE, v. 35, n. 5, p. 36–44, 2017.
- SALMINEN, E.; KULMALA, A.; HAMALAINEN, T. D. Survey of network-on-chip proposals. *white paper, OCP-IP*, v. 1, p. 13, 2008.

- SEYDIM, A. Y. Wormhole routing in parallel computers. Citeseer, 1998.
- SHAH, P.; KANNIGANTI, A.; SOUMYA, J. Fault-tolerant application specific network-on-chip design. In: IEEE. *2017 7th International Symposium on Embedded Computing and System Design (ISED)*. [S.l.], 2017. p. 1–5.
- SHAH, P.; SHENOY, R. G.; SRINIVASAN, V.; BOSE, P.; BUYUKTOSUNOGLU, A. Tokensmart: Distributed, scalable power management in the many-core era. *IEEE Computer Architecture Letters*, v. 20, n. 1, p. 42–45, 2021.
- SINGH, A. K.; DZIURZANSKI, P.; MENDIS, H. R.; INDRUSIAK, L. S. A survey and comparative study of hard and soft real-time dynamic resource allocation strategies for multi-/many-core systems. *ACM Computing Surveys (CSUR)*, ACM New York, NY, USA, v. 50, n. 2, p. 1–40, 2017.
- SINGH, A. K.; SHAFIQUE, M.; KUMAR, A.; HENKEL, J. Mapping on multi-/many-core systems: survey of current and emerging trends. In: IEEE. *2013 50th ACM/EDAC/IEEE Design Automation Conference (DAC)*. [S.l.], 2013. p. 1–10.
- SINWAR, D.; KAUSHIK, R. Study of euclidean and manhattan distance metrics using simple k-means clustering. *Int. J. Res. Appl. Sci. Eng. Technol*, v. 2, n. 5, p. 270–274, 2014.
- SYSWERDA, G. et al. Uniform crossover in genetic algorithms. In: *ICGA*. [S.l.: s.n.], 1989. v. 3, p. 2–9.
- TAMAKI, H.; KITA, H.; KOBAYASHI, S. Multi-objective optimization by genetic algorithms: A review. In: IEEE. *Proceedings of IEEE international conference on evolutionary computation*. [S.l.], 1996. p. 517–522.
- THEOCHARIDES, T.; MICHAEL, M. K.; POLYCARPOU, M.; DINGANKAR, A. Towards embedded runtime system level optimization for mpsoCs: on-chip task allocation. In: ACM. *Proceedings of the 19th ACM Great Lakes symposium on VLSI*. [S.l.], 2009. p. 121–124.
- TIAN, Y.; CHENG, R.; ZHANG, X.; JIN, Y. Platemo: A matlab platform for evolutionary multi-objective optimization [educational forum]. *IEEE Computational Intelligence Magazine*, IEEE, v. 12, n. 4, p. 73–87, 2017.
- TSAI, W.-C.; LAN, Y.-C.; HU, Y.-H.; CHEN, S.-J. Networks on chips: structure and design methodologies. *Journal of Electrical and Computer Engineering*, Hindawi, v. 2012, 2012.
- UMBARKAR, A. J.; SHETH, P. D. Crossover operators in genetic algorithms: a review. *IC-TACT journal on soft computing*, v. 6, n. 1, 2015.
- WAN, C.; YUAN, X.; DAI, X.; ZHANG, T.; HE, Q. A self-adaptive multi-objective harmony search based fuzzy clustering technique for image segmentation. *Journal of Ambient Intelligence and Humanized Computing*, Springer, p. 1–16, 2018.
- WANG, L.; LV, P.; LIU, L.; HAN, J.; LEUNG, H.-F.; WANG, X.; YIN, S.; WEI, S.; MAK, T. A lifetime reliability-constrained runtime mapping for throughput optimization in many-core systems. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, IEEE, v. 38, n. 9, p. 1771–1784, 2018.

- WANG, S.; JIN, T. Wireless network-on-chip: A survey. *The Journal of Engineering*, IET, v. 2014, n. 3, p. 98–104, 2014.
- WEICHSLGARTNER, A.; WILDERMANN, S.; GANGADHARAN, D.; GLASS, M.; TEICH, J. A design-time/run-time application mapping methodology for predictable execution time in mpsoCs. *ACM Transactions on Embedded Computing Systems (TECS)*, ACM New York, NY, USA, v. 17, n. 5, p. 1–25, 2018.
- WEICHSLGARTNER, A.; WILDERMANN, S.; GLASS, M.; TEICH, J. *Invasive computing for mapping parallel programs to many-core architectures*. [S.l.]: Springer, 2018. v. 1.
- WERNER, S.; NAVARIDAS, J.; LUJÁN, M. A survey on optical network-on-chip architectures. *ACM Computing Surveys (CSUR)*, ACM New York, NY, USA, v. 50, n. 6, p. 1–37, 2017.
- WU, Y.; LU, C.; CHEN, Y. A survey of routing algorithm for mesh network-on-chip. *Frontiers of Computer Science*, Springer, v. 10, n. 4, p. 591–601, 2016.
- XUE, Y.; ZHU, H.; LIANG, J.; SŁOWIK, A. Adaptive crossover operator based multi-objective binary genetic algorithm for feature selection in classification. *Knowledge-Based Systems*, Elsevier, v. 227, p. 107218, 2021.
- XUE, Y.; ZHU, H.; NERI, F. A self-adaptive multi-objective feature selection approach for classification problems. *Integrated Computer-Aided Engineering*, IOS Press, n. Preprint, p. 1–19, 2022.
- ZHANG, Q.; YANG, L. T.; CHEN, Z.; LI, P. A survey on deep learning for big data. *Information Fusion*, Elsevier, v. 42, p. 146–157, 2018.
- ZHANG, X.; TIAN, Y.; JIN, Y. A knee point-driven evolutionary algorithm for many-objective optimization. *IEEE Transactions on Evolutionary Computation*, IEEE, v. 19, n. 6, p. 761–776, 2014.
- ZHOU, X.; LIU, L.; ZHU, Z. A fault-tolerant deflection routing for network-on-chip. *Journal of Circuits, Systems and Computers*, World Scientific, v. 26, n. 03, p. 1750037, 2017.
- ZITZLER, E.; LAUMANN, M.; THIELE, L. Spea2: Improving the strength pareto evolutionary algorithm. *TIK-report*, Eidgenössische Technische Hochschule Zürich (ETH), Institut für Technische ..., v. 103, 2001.

GLOSSÁRIO

HV – *Hypervolume*

IGD – *Inverted Generational Distance*

MM – *Mathematical morphology*

MM – *Mathematical morphology*

PCB – *Printed Circuit Board*

QoS – *Quality of Service*

Apêndice A

TABELAS - RESULTADOS B

No presente apêndice são demonstradas as tabelas referentes aos resultados obtidos. Tal disposição foi utilizada devido ao grande número de tabelas obtidas durante a execução e a avaliação dos resultados. Tais tabelas serão analisadas no Capítulo 5.

As tabelas estão divididas em dois grandes grupos, apresentados nas Seções 5.3 e 5.4 (com e sem procedimento autoadaptativo), e em cada um dos grupos existem as divisões relacionadas com as métricas avaliadas (Energia X Balanceamento de Carga, Tolerância a Falhas X Energia, Tolerância a falhas X Comunicação e Comunicação X Energia). Ainda são demonstradas duas tabelas para cada uma das métricas utilizadas para avaliação de resultados (*Hypervolume* e *IGD*).

Para fins de entendimento das tabelas apresentadas, algumas informações são necessárias: todas as tabelas apresentadas possuem seus resultados avaliados utilizando a ferramenta estatística Wilcoxon (CUZICK, 1985) com 5% de significância, de modo a determinar se os resultados obtidos são estatisticamente melhores, estatisticamente piores ou estatisticamente iguais. Para tal separação, é utilizada uma representação gráfica (+ / - / \approx). As marcações em negrito denotam os algoritmos que obtiveram os melhores resultados.

A.1 Sem uso do procedimento autoadaptativo

A seguir, são apresentadas as tabelas referentes aos resultados obtidos sem o uso do procedimento autoadaptativo apresentado no Capítulo 4, com base na Tabela 4.3, com 30 repetições independentes para cada uma das configurações utilizadas.

Tabela A.1: Resultados para o cálculo do Hypervolume para as métricas de Energia e Balanceamento de Carga em relação ao grid de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	7.3292e-1 (7.29e-3) –	7.2942e-1 (8.81e-3) –	7.3968e-1 (7.90e-3) ≈	7.2444e-1 (2.18e-2) –	7.3764e-1 (1.06e-2)
	100	2	20000	7.4366e-1 (7.84e-3) ≈	7.4270e-1 (6.73e-3) –	7.5167e-1 (8.20e-3) ≈	6.9064e-1 (2.46e-2) –	7.4725e-1 (8.59e-3)
	100	2	50000	7.5235e-1 (7.94e-3) ≈	7.5398e-1 (8.49e-3) ≈	7.5938e-1 (7.39e-3) +	6.9676e-1 (2.02e-2) –	7.5026e-1 (6.93e-3)
MAP2	100	2	10000	7.0893e-1 (9.99e-3) –	6.9660e-1 (8.83e-3) –	7.1536e-1 (8.83e-3) –	7.0972e-1 (9.00e-3) –	7.2252e-1 (1.05e-2)
	100	2	20000	7.2613e-1 (9.15e-3) ≈	7.2095e-1 (8.06e-3) –	7.3477e-1 (8.07e-3) ≈	7.1047e-1 (2.58e-2) –	7.3277e-1 (1.35e-2)
	100	2	50000	7.4499e-1 (7.13e-3) ≈	7.4142e-1 (8.38e-3) ≈	7.5187e-1 (7.35e-3) +	6.8618e-1 (2.45e-2) –	7.4303e-1 (9.82e-3)
MAP3	100	2	10000	7.0875e-1 (8.75e-3) –	6.9491e-1 (7.86e-3) –	7.1191e-1 (9.24e-3) –	7.0667e-1 (1.05e-2) –	7.1807e-1 (1.21e-2)
	100	2	20000	7.2101e-1 (7.69e-3) ≈	7.1855e-1 (8.47e-3) –	7.2923e-1 (6.73e-3) +	7.0408e-1 (2.75e-2) –	7.2539e-1 (9.46e-3)
	100	2	50000	7.3402e-1 (9.73e-3) ≈	7.3345e-1 (7.81e-3) ≈	7.4429e-1 (6.74e-3) +	6.8638e-1 (2.63e-2) –	7.3394e-1 (9.98e-3)
MAP4	100	2	10000	7.0825e-1 (2.67e-2) –	6.9092e-1 (2.57e-2) –	7.2278e-1 (3.35e-2) –	7.0564e-1 (2.40e-2) –	7.4315e-1 (3.55e-2)
	100	2	20000	7.6180e-1 (3.63e-2) –	7.3030e-1 (3.28e-2) –	7.7012e-1 (3.33e-2) ≈	7.5339e-1 (4.43e-2) –	7.7985e-1 (3.58e-2)
	100	2	50000	8.0654e-1 (2.43e-2) ≈	7.9078e-1 (2.81e-2) –	8.1638e-1 (1.58e-2) ≈	7.1770e-1 (6.67e-2) –	8.1326e-1 (1.98e-2)
MAP5	100	2	10000	7.2342e-1 (7.02e-3) –	7.1350e-1 (7.58e-3) –	7.2673e-1 (8.94e-3) ≈	7.2166e-1 (9.27e-3) –	7.2825e-1 (1.11e-2)
	100	2	20000	7.3162e-1 (8.50e-3) –	7.2980e-1 (8.28e-3) –	7.3994e-1 (6.67e-3) ≈	7.0580e-1 (3.05e-2) –	7.3640e-1 (8.29e-3)
	100	2	50000	7.4102e-1 (7.93e-3) ≈	7.4281e-1 (7.98e-3) ≈	7.4961e-1 (6.35e-3) +	6.9132e-1 (2.27e-2) –	7.4034e-1 (9.00e-3)
MAP6	100	2	10000	6.8528e-1 (1.40e-2) –	6.6442e-1 (1.77e-2) –	6.9095e-1 (1.52e-2) –	6.8078e-1 (1.39e-2) –	7.0882e-1 (1.10e-2)
	100	2	20000	7.1260e-1 (1.15e-2) –	7.0232e-1 (1.01e-2) –	7.1758e-1 (7.22e-3) ≈	7.0804e-1 (1.30e-2) –	7.2317e-1 (1.34e-2)
	100	2	50000	7.3478e-1 (1.08e-2) ≈	7.2965e-1 (1.03e-2) –	7.3563e-1 (8.74e-3) ≈	6.9030e-1 (3.60e-2) –	7.3739e-1 (1.12e-2)
MAP7	100	2	10000	6.5351e-1 (1.14e-2) –	6.4078e-1 (8.85e-3) –	6.6137e-1 (8.09e-3) –	6.5698e-1 (1.01e-2) –	6.7736e-1 (9.81e-3)
	100	2	20000	6.7902e-1 (9.74e-3) –	6.6558e-1 (8.33e-3) –	6.8301e-1 (6.43e-3) –	6.7818e-1 (7.40e-3) –	6.9002e-1 (1.19e-2)
	100	2	50000	7.0020e-1 (9.73e-3) ≈	6.9556e-1 (8.00e-3) –	7.0531e-1 (6.24e-3) ≈	6.8012e-1 (2.90e-2) –	7.0469e-1 (1.11e-2)
MAP8	100	2	10000	6.5884e-1 (9.58e-3) –	6.2754e-1 (3.17e+0) +	6.4652e-1 (3.53e+0) +	6.4533e-1 (8.55e-3) –	6.6816e-1 (1.17e-2)
	100	2	20000	6.6628e-1 (9.55e-3) –	6.5784e-1 (7.49e-3) –	6.7412e-1 (5.65e-3) –	6.6952e-1 (8.26e-3) –	6.8121e-1 (1.14e-2)
	100	2	50000	6.8768e-1 (9.89e-3) ≈	6.8576e-1 (7.21e-3) ≈	6.9559e-1 (7.23e-3) ≈	6.8203e-1 (1.72e-2) –	6.9055e-1 (1.18e-2)
MAP9	100	2	10000	6.2497e-1 (8.51e-3) –	6.1230e-1 (8.33e-3) –	6.2924e-1 (6.45e-3) –	6.2129e-1 (8.89e-3) –	6.4502e-1 (1.18e-2)
	100	2	20000	6.4701e-1 (7.74e-3) –	6.3383e-1 (8.40e-3) –	6.5207e-1 (6.03e-3) –	6.4531e-1 (9.43e-3) –	6.6073e-1 (1.21e-2)
	100	2	50000	6.6883e-1 (6.19e-3) –	6.6273e-1 (6.67e-3) –	6.7459e-1 (7.15e-3) ≈	6.6795e-1 (1.60e-2) –	6.7769e-1 (1.12e-2)
MAP10	100	2	10000	7.0589e-1 (6.96e-3) –	6.9326e-1 (1.06e-2) –	7.1174e-1 (6.28e-3) –	7.0832e-1 (8.45e-3) –	7.1769e-1 (1.05e-2)
	100	2	20000	7.2353e-1 (9.54e-3) ≈	7.1779e-1 (9.16e-3) –	7.2893e-1 (7.85e-3) ≈	7.0612e-1 (2.28e-2) –	7.2435e-1 (1.09e-2)
	100	2	50000	7.3597e-1 (8.27e-3) ≈	7.3559e-1 (9.28e-3) ≈	7.4324e-1 (8.03e-3) +	6.8322e-1 (2.46e-2) –	7.3429e-1 (1.03e-2)
+/-/≈				0/17/13	0/24/6	6/11/13	0/30/0	

Tabela A.2: Resultados para o cálculo do IGD para as métricas de Energia e Balanceamento de Carga em relação ao grid de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	7.4642e+1 (2.30e+0) +	7.4042e+1 (1.96e+0) +	7.3809e+1 (1.99e+0) +	7.4875e+1 (2.20e+0) +	7.7174e+1 (2.06e+0)
	100	2	20000	7.7174e+1 (1.78e+0) ≈	7.6574e+1 (1.81e+0) +	7.6141e+1 (1.97e+0) +	7.9402e+1 (3.20e+0) –	7.7774e+1 (2.07e+0)
	100	2	50000	7.8540e+1 (1.50e+0) ≈	7.8740e+1 (1.95e+0) ≈	7.8673e+1 (1.65e+0) ≈	8.0835e+1 (2.09e+0) –	7.8940e+1 (1.42e+0)
MAP2	100	2	10000	6.5884e+1 (2.39e+0) +	6.2754e+1 (3.17e+0) +	6.4652e+1 (3.53e+0) +	6.4752e+1 (2.98e+0) +	7.0914e+1 (3.16e+0)
	100	2	20000	7.0515e+1 (2.11e+0) +	6.8849e+1 (2.40e+0) +	6.8449e+1 (3.25e+0) +	7.0613e+1 (2.43e+0) +	7.3313e+1 (2.42e+0)
	100	2	50000	7.3812e+1 (1.75e+0) +	7.4945e+1 (2.32e+0) ≈	7.3679e+1 (1.97e+0) +	7.6607e+1 (2.11e+0) ≈	7.5311e+1 (1.95e+0)
MAP3	100	2	10000	7.1045e+1 (2.32e+0) +	6.7780e+1 (2.26e+0) +	6.8313e+1 (2.18e+0) +	7.0712e+1 (2.34e+0) +	7.4043e+1 (2.64e+0)
	100	2	20000	7.4076e+1 (2.20e+0) +	7.2944e+1 (2.14e+0) +	7.2011e+1 (1.77e+0) +	7.3942e+1 (2.42e+0) +	7.5242e+1 (2.09e+0)
	100	2	50000	7.6542e+1 (1.50e+0) ≈	7.6142e+1 (1.86e+0) +	7.5809e+1 (2.08e+0) +	7.7438e+1 (3.10e+0) ≈	7.7275e+1 (2.09e+0)
MAP4	100	2	10000	6.2424e+1 (3.68e+0) +	5.9992e+1 (3.50e+0) +	6.0263e+1 (3.89e+0) +	6.1525e+1 (4.18e+0) +	6.6359e+1 (4.50e+0)
	100	2	20000	6.4830e+1 (4.18e+0) +	6.1928e+1 (4.42e+0) +	6.0969e+1 (4.70e+0) +	6.5728e+1 (5.49e+0) ≈	6.7796e+1 (3.58e+0)
	100	2	50000	6.6200e+1 (4.81e+0) ≈	6.5633e+1 (4.59e+0) +	6.5302e+1 (4.76e+0) +	7.1451e+1 (3.32e+0) –	6.8033e+1 (3.81e+0)
MAP5	100	2	10000	7.4308e+1 (2.16e+0) +	7.2609e+1 (1.77e+0) +	7.3242e+1 (1.88e+0) +	7.4108e+1 (2.53e+0) +	7.6640e+1 (2.24e+0)
	100	2	20000	7.7140e+1 (1.42e+0) +	7.6374e+1 (1.54e+0) +	7.6540e+1 (1.68e+0) +	7.8571e+1 (2.09e+0) ≈	7.8506e+1 (1.85e+0)
	100	2	50000	7.8473e+1 (1.92e+0) ≈	7.8972e+1 (1.78e+0) ≈	7.8839e+1 (1.71e+0) ≈	7.9702e+1 (1.80e+0) ≈	7.9039e+1 (1.74e+0)
MAP6	100	2	10000	6.1556e+1 (2.72e+0) +	6.0422e+1 (2.59e+0) +	5.8955e+1 (2.32e+0) +	6.0923e+1 (3.72e+0) +	6.6586e+1 (3.23e+0)
	100	2	20000	6.5221e+1 (3.74e+0) +	6.1191e+1 (3.03e+0) +	6.3023e+1 (2.47e+0) +	6.5587e+1 (3.75e+0) +	6.9917e+1 (3.15e+0)
	100	2	50000	7.1083e+1 (2.56e+0) +	6.9484e+1 (3.01e+0) +	6.8119e+1 (2.52e+0) +	7.2545e+1 (2.95e+0) ≈	7.2316e+1 (2.32e+0)
MAP7	100	2	10000	6.0420e+1 (2.90e+0) +	5.8389e+1 (2.71e+0) +	5.8692e+1 (2.33e+0) +	6.1486e+1 (3.93e+0) +	6.6283e+1 (2.79e+0)
	100	2	20000	6.5983e+1 (2.89e+0) +	6.3618e+1 (2.46e+0) +	6.3685e+1 (2.26e+0) +	6.6216e+1 (2.56e+0) +	7.0180e+1 (2.05e+0)
	100	2	50000	7.0680e+1 (2.47e+0) +	7.0047e+1 (3.31e+0) +	6.8881e+1 (1.84e+0) +	7.1078e+1 (2.67e+0) ≈	7.2312e+1 (2.84e+0)
MAP8	100	2	10000	6.1585e+1 (2.39e+0) +	5.9220e+1 (2.48e+0) +	6.0619e+1 (2.33e+0) +	6.2018e+1 (2.25e+0) +	6.6447e+1 (2.54e+0)
	100	2	20000	6.5782e+1 (1.64e+0) +	6.4383e+1 (2.18e+0) +	6.4083e+1 (1.56e+0) +	6.5782e+1 (2.27e+0) +	7.0345e+1 (2.70e+0)
	100	2	50000	7.0612e+1 (2.25e+0) +	7.0345e+1 (2.75e+0) +	6.9046e+1 (2.43e+0) +	7.1211e+1 (2.27e+0) +	7.2411e+1 (2.02e+0)
MAP9	100	2	10000	6.1517e+1 (1.41e+0) +	5.8919e+1 (1.38e+0) +	5.8952e+1 (2.15e+0) +	6.0651e+1 (2.08e+0) +	6.6447e+1 (2.95e+0)
	100	2	20000	6.5147e+1 (2.15e+0) +	6.3116e+1 (1.93e+0) +	6.2683e+1 (1.97e+0) +	6.5081e+1 (2.44e+0) +	6.9711e+1 (2.56e+0)
	100	2	50000	7.0377e+1 (2.15e+0) +	6.8945e+1 (2.23e+0) +	6.8212e+1 (1.93e+0) +	7.0977e+1 (2.84e+0) +	7.2976e+1 (1.95e+0)
MAP10	100	2	10000	7.0079e+1 (2.47e+0) +	6.7414e+1 (1.73e+0) +	6.8413e+1 (2.35e+0) +	7.0645e+1 (2.06e+0) +	6.6447e+1 (2.79e+0)
	100	2	20000	7.4076e+1 (1.90e+0) +	7.1911e+1 (2.58e+0) +	7.2444e+1 (1.96e+0) +	7.4175e+1 (3.09e+0) ≈	7.5376e+1 (2.09e+0)
	100	2	50000	7.6408e+1 (1.96e+0) +	7.6342e+1 (1.84e+0) +	7.6108e+1 (1.96e+0) +	7.6305e+1 (2.33e+0) +	7.7441e+1 (1.52e+0)
+/-/≈				25/0/5	27/0/3	28/0/2	19/3/8	

Tabela A.3: Resultados para o cálculo do *Hypervolume* para as métricas de Tolerância a Falhas e Energia em relação ao *grid* de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAI
MAP1	100	2	10000	8.6088e-1 (1.02e-2) +	8.6171e-1 (8.93e-3) +	8.6143e-1 (1.01e-2) +	8.5923e-1 (1.03e-2) +	8.5096e-1 (1.16e-2)
	100	2	20000	8.6556e-1 (1.11e-2) +	8.6832e-1 (1.06e-2) +	8.6749e-1 (1.33e-2) +	8.6474e-1 (1.07e-2) +	8.5152e-1 (1.66e-2)
	100	2	50000	8.6667e-1 (9.88e-3) ≈	8.7658e-1 (7.81e-3) +	8.7796e-1 (8.03e-3) +	8.6584e-1 (1.06e-2) ≈	8.6501e-1 (1.38e-2)
MAP2	100	2	10000	8.4325e-1 (1.07e-2) +	8.3466e-1 (1.29e-2) ≈	8.4435e-1 (1.41e-2) +	8.4460e-1 (1.56e-2) +	8.2906e-1 (1.56e-2)
	100	2	20000	8.5234e-1 (1.44e-2) +	8.5207e-1 (8.78e-3) +	8.5647e-1 (1.12e-2) +	8.5339e-1 (1.13e-2) +	8.4022e-1 (1.59e-2)
	100	2	50000	8.5840e-1 (9.39e-3) ≈	8.6639e-1 (8.43e-3) +	8.6198e-1 (9.25e-3) +	8.5262e-1 (1.25e-2) ≈	8.5344e-1 (1.28e-2)
MAP3	100	2	10000	8.4804e-1 (1.32e-2) +	8.4460e-1 (1.20e-2) +	8.4518e-1 (1.23e-2) +	8.5118e-1 (1.15e-2) +	8.3388e-1 (1.75e-2)
	100	2	20000	8.5317e-1 (1.08e-2) ≈	8.5978e-1 (9.58e-3) +	8.5179e-1 (1.26e-2) ≈	8.5427e-1 (1.38e-2) +	8.4298e-1 (2.05e-2)
	100	2	50000	8.6006e-1 (9.93e-3) ≈	8.6612e-1 (9.31e-3) +	8.6556e-1 (9.69e-3) +	8.5647e-1 (9.82e-3) ≈	8.5372e-1 (1.47e-2)
MAP4	100	2	10000	8.3245e-1 (1.15e-2) +	8.2355e-1 (1.45e-2) +	8.2501e-1 (1.72e-2) ≈	8.3138e-1 (1.35e-2) ≈	8.1871e-1 (2.49e-2)
	100	2	20000	8.4950e-1 (1.28e-2) +	8.4567e-1 (1.38e-2) +	8.4601e-1 (1.24e-2) +	8.5124e-1 (9.21e-3) +	8.3196e-1 (1.78e-2)
	100	2	50000	8.5096e-1 (1.33e-2) ≈	8.6006e-1 (8.66e-3) +	8.5647e-1 (1.35e-2) +	8.4904e-1 (1.19e-2) ≈	8.5234e-1 (1.59e-2)
MAP5	100	2	10000	8.5096e-1 (1.05e-2) ≈	8.5730e-1 (8.39e-3) +	8.6143e-1 (8.86e-3) +	8.5923e-1 (9.07e-3) +	8.4435e-1 (1.63e-2)
	100	2	20000	8.6391e-1 (1.12e-2) +	8.6771e-1 (1.00e-2) +	8.6088e-1 (1.23e-2) +	8.6006e-1 (1.25e-2) +	8.4931e-1 (1.72e-2)
	100	2	50000	8.6915e-1 (8.97e-3) +	8.7190e-1 (8.88e-3) +	8.7218e-1 (9.64e-3) +	8.6364e-1 (1.01e-2) ≈	8.6116e-1 (1.22e-2)
MAP6	100	2	10000	8.2044e-1 (1.32e-2) +	8.0719e-1 (1.74e-2) ≈	8.1920e-1 (1.42e-2) +	8.1650e-1 (1.29e-2) +	7.9736e-1 (3.02e-2)
	100	2	20000	8.3747e-1 (1.48e-2) +	8.3840e-1 (1.48e-2) +	8.3678e-1 (1.25e-2) +	8.3945e-1 (1.41e-2) +	8.1928e-1 (2.80e-2)
	100	2	50000	8.4738e-1 (1.45e-2) +	8.5466e-1 (1.15e-2) +	8.5207e-1 (1.36e-2) +	8.4788e-1 (1.52e-2) +	8.3774e-1 (1.59e-2)
MAP7	100	2	10000	8.0708e-1 (1.54e-2) ≈	7.9719e-1 (1.21e-2) +	8.0240e-1 (2.57e-2) ≈	8.1325e-1 (1.55e-2) ≈	8.0479e-1 (2.85e-2)
	100	2	20000	8.3132e-1 (1.47e-2) +	8.3113e-1 (1.38e-2) +	8.2887e-1 (2.10e-2) +	8.3085e-1 (1.44e-2) +	8.1590e-1 (1.90e-2)
	100	2	50000	8.4157e-1 (1.64e-2) +	8.5069e-1 (1.41e-2) +	8.4983e-1 (1.36e-2) +	8.4077e-1 (1.50e-2) +	8.2507e-1 (1.84e-2)
MAP8	100	2	10000	7.9780e-1 (2.33e-2) ≈	7.8920e-1 (1.84e-2) ≈	8.0468e-1 (2.02e-2) ≈	8.0455e-1 (1.67e-2) ≈	7.8983e-1 (3.86e-2)
	100	2	20000	8.3190e-1 (1.48e-2) +	8.2176e-1 (1.55e-2) ≈	8.3402e-1 (1.27e-2) +	8.3358e-1 (1.72e-2) +	8.1956e-1 (1.83e-2)
	100	2	50000	8.3939e-1 (1.70e-2) +	8.4540e-1 (1.20e-2) +	8.4738e-1 (1.03e-2) +	8.3782e-1 (1.30e-2) +	8.2755e-1 (1.86e-2)
MAP9	100	2	10000	7.9074e-1 (1.76e-2) ≈	7.7824e-1 (1.46e-2) ≈	7.8722e-1 (2.23e-2) ≈	7.9424e-1 (2.00e-2) ≈	7.9399e-1 (2.52e-2)
	100	2	20000	8.1793e-1 (1.44e-2) +	8.1311e-1 (1.52e-2) ≈	8.1634e-1 (2.19e-2) +	8.1634e-1 (2.22e-2) +	8.0284e-1 (1.37e-2)
	100	2	50000	8.3490e-1 (1.40e-2) +	8.3490e-1 (1.35e-2) +	8.3636e-1 (1.59e-2) +	8.3240e-1 (1.65e-2) +	8.2036e-1 (1.75e-2)
MAP10	100	2	10000	8.4986e-1 (1.27e-2) +	8.4490e-1 (9.13e-3) +	8.4959e-1 (1.36e-2) +	8.4242e-1 (1.80e-2) +	8.3328e-1 (1.83e-2)
	100	2	20000	8.5372e-1 (1.17e-2) ≈	8.5840e-1 (9.64e-3) +	8.5868e-1 (1.25e-2) +	8.5565e-1 (1.24e-2) +	8.4652e-1 (1.55e-2)
	100	2	50000	8.6165e-1 (9.80e-3) ≈	8.6722e-1 (8.66e-3) +	8.6639e-1 (1.34e-2) +	8.5895e-1 (1.17e-2) ≈	8.5537e-1 (1.42e-2)
+/-/≈				19/0/11	22/2/6	24/0/6	20/0/10	

Tabela A.4: Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Energia em relação ao *grid* de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAI
MAP1	100	2	10000	9.4596e+1 (1.23e+0) -	9.4695e+1 (1.08e+0) -	9.4662e+1 (1.22e+0) -	9.4397e+1 (1.24e+0) -	9.3401e+1 (1.40e+0)
	100	2	20000	9.5160e+1 (1.33e+0) -	9.5492e+1 (1.28e+0) -	9.5392e+1 (1.60e+0) -	9.5060e+1 (1.29e+0) -	9.3468e+1 (2.00e+0)
	100	2	50000	9.5293e+1 (1.19e+0) ≈	9.6487e+1 (9.40e-1) -	9.6653e+1 (9.67e-1) -	9.5193e+1 (1.27e+0) ≈	9.5094e+1 (1.66e+0)
MAP2	100	2	10000	9.2472e+1 (1.29e+0) -	9.1378e+1 (1.59e+0) ≈	9.2605e+1 (1.70e+0) -	9.2605e+1 (1.94e+0) -	9.0615e+1 (1.96e+0)
	100	2	20000	9.3567e+1 (1.73e+0) -	9.3534e+1 (1.06e+0) -	9.4065e+1 (1.35e+0) -	9.3634e+1 (1.42e+0) -	9.2108e+1 (1.91e+0)
	100	2	50000	9.4297e+1 (1.13e+0) ≈	9.5259e+1 (1.02e+0) -	9.4729e+1 (1.11e+0) -	9.3600e+1 (1.50e+0) ≈	9.3700e+1 (1.54e+0)
MAP3	100	2	10000	9.2871e+1 (2.17e+0) -	9.2605e+1 (1.53e+0) -	9.2705e+1 (1.48e+0) -	9.3368e+1 (1.48e+0) -	9.1345e+1 (2.11e+0)
	100	2	20000	9.3667e+1 (1.30e+0) ≈	9.4463e+1 (1.15e+0) -	9.3501e+1 (1.52e+0) ≈	9.3800e+1 (1.66e+0) -	9.2439e+1 (2.47e+0)
	100	2	50000	9.4496e+1 (1.20e+0) ≈	9.5226e+1 (1.12e+0) -	9.5160e+1 (1.17e+0) -	9.4065e+1 (1.18e+0) ≈	9.3733e+1 (1.78e+0)
MAP4	100	2	10000	9.1112e+1 (1.42e+0) ≈	8.9952e+1 (1.88e+0) ≈	9.0217e+1 (2.15e+0) ≈	9.1013e+1 (1.60e+0) ≈	8.9849e+1 (2.59e+0)
	100	2	20000	9.3136e+1 (1.68e+0) -	9.2705e+1 (1.73e+0) -	9.2804e+1 (1.49e+0) -	9.3435e+1 (1.11e+0) -	9.1113e+1 (2.14e+0)
	100	2	50000	9.3401e+1 (1.60e+0) ≈	9.4496e+1 (1.04e+0) -	9.4065e+1 (1.62e+0) ≈	9.3169e+1 (1.43e+0) ≈	9.3567e+1 (1.92e+0)
MAP5	100	2	10000	9.3401e+1 (1.27e+0) ≈	9.4164e+1 (1.01e+0) -	9.4662e+1 (1.07e+0) -	9.4397e+1 (1.09e+0) -	9.2605e+1 (1.96e+0)
	100	2	20000	9.4961e+1 (1.35e+0) -	9.5359e+1 (1.31e+0) -	9.4596e+1 (1.48e+0) -	9.4496e+1 (1.50e+0) -	9.3202e+1 (2.07e+0)
	100	2	50000	9.5591e+1 (1.08e+0) -	9.5923e+1 (1.07e+0) -	9.5956e+1 (1.16e+0) -	9.4928e+1 (1.22e+0) ≈	9.4629e+1 (1.46e+0)
MAP6	100	2	10000	8.9487e+1 (1.98e+0) -	8.7564e+1 (2.72e+0) ≈	8.9487e+1 (1.72e+0) -	8.8924e+1 (1.99e+0) ≈	8.7919e+1 (2.58e+0)
	100	2	20000	9.1776e+1 (1.78e+0) -	9.1710e+1 (2.22e+0) -	9.1544e+1 (1.78e+0) -	9.1776e+1 (2.24e+0) -	8.9916e+1 (2.91e+0)
	100	2	50000	9.2970e+1 (1.75e+0) -	9.3667e+1 (1.58e+0) -	9.3534e+1 (1.64e+0) -	9.2970e+1 (1.88e+0) -	9.1809e+1 (1.91e+0)
MAP7	100	2	10000	8.7730e+1 (2.35e+0) ≈	8.6569e+1 (1.68e+0) +	8.7296e+1 (3.09e+0) ≈	8.8592e+1 (2.30e+0) ≈	8.8158e+1 (2.76e+0)
	100	2	20000	9.0648e+1 (2.54e+0) -	9.1013e+1 (1.67e+0) -	9.1076e+1 (1.98e+0) -	9.0980e+1 (1.73e+0) -	8.9089e+1 (2.22e+0)
	100	2	50000	9.2240e+1 (2.01e+0) -	9.3368e+1 (1.69e+0) -	9.3236e+1 (1.68e+0) -	9.2174e+1 (1.81e+0) -	9.0283e+1 (2.24e+0)
MAP8	100	2	10000	8.7163e+1 (2.14e+0) ≈	8.5608e+1 (2.26e+0) ≈	8.8124e+1 (1.96e+0) ≈	8.7664e+1 (2.22e+0) ≈	8.6891e+1 (3.49e+0)
	100	2	20000	9.1046e+1 (1.88e+0) -	9.8885e+1 (1.86e+0) ≈	9.1212e+1 (1.79e+0) -	9.1278e+1 (2.09e+0) -	8.9620e+1 (2.20e+0)
	100	2	50000	9.2008e+1 (2.05e+0) -	9.2672e+1 (1.54e+0) -	9.2970e+1 (1.25e+0) -	9.1610e+1 (1.72e+0) -	9.0582e+1 (2.24e+0)
MAP9	100	2	10000	8.5377e+1 (3.41e+0) ≈	8.4050e+1 (2.47e+0) +	8.5737e+1 (2.46e+0) ≈	8.6304e+1 (2.74e+0) ≈	8.6865e+1 (2.67e+0)
	100	2	20000	8.9156e+1 (2.01e+0) -	8.8725e+1 (2.06e+0) ≈	8.9517e+1 (2.09e+0) -	8.9023e+1 (1.88e+0) -	8.7892e+1 (2.05e+0)
	100	2	50000	9.1378e+1 (1.83e+0) -	9.1378e+1 (1.67e+0) -	9.1643e+1 (1.91e+0) -	9.1046e+1 (2.21e+0) -	8.9686e+1 (2.13e+0)
MAP10	100	2	10000	9.3269e+1 (1.53e+0) -	9.2671e+1 (1.10e+0) -	9.3236e+1 (1.64e+0) -	9.2373e+1 (2.17e+0) -	9.1212e+1 (2.26e+0)
	100	2	20000	9.3733e+1 (1.41e+0) ≈	9.4297e+1 (1.16e+0) -	9.4330e+1 (1.51e+0) -	9.3965e+1 (1.50e+0) -	9.2871e+1 (1.86e+0)
	100	2	50000	9.4629e+1 (1.09e+0) ≈	9.5359e+1 (1.04e+0) -	9.5260e+1 (1.61e+0) -	9.4364e+1 (1.41e+0) ≈	9.3932e+1 (1.71e+0)
+/-/≈				0/18/12	2/22/6	0/24/6	0/19/11	

Tabela A.5: Resultados para o cálculo do Hypervolume para as métricas de Tolerância a Falhas e Comunicação em relação ao grid de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	7.3976e-1 (1.08e-2) ≈	7.3399e-1 (7.91e-3) –	7.3805e-1 (7.87e-3) –	7.4292e-1 (7.59e-3) ≈	7.4459e-1 (8.55e-3)
	100	2	20000	7.5200e-1 (7.03e-3) ≈	7.4814e-1 (8.49e-3) ≈	7.5100e-1 (7.55e-3) ≈	7.3573e-1 (2.87e-2) –	7.5222e-1 (8.10e-3)
	100	2	50000	7.5634e-1 (7.37e-3) ≈	7.5912e-1 (7.72e-3) ≈	7.5923e-1 (6.10e-3) ≈	7.3348e-1 (3.56e-2) –	7.6009e-1 (9.53e-3)
MAP2	100	2	10000	6.6459e-1 (8.94e-3) ≈	6.5087e-1 (1.87e-2) ≈	6.6481e-1 (1.33e-2) ≈	6.6648e-1 (1.47e-2) ≈	6.5411e-1 (3.70e-2)
	100	2	20000	6.8554e-1 (1.16e-2) ≈	6.7958e-1 (1.19e-2) ≈	6.8207e-1 (1.64e-2) ≈	6.8292e-1 (1.29e-2) ≈	6.7515e-1 (3.27e-2)
	100	2	50000	6.9926e-1 (1.34e-2) ≈	7.0002e-1 (1.25e-2) ≈	7.0291e-1 (9.87e-3) ≈	6.8709e-1 (2.70e-2) –	6.9992e-1 (2.28e-2)
MAP3	100	2	10000	6.9870e-1 (9.28e-3) –	6.8862e-1 (8.57e-3) –	6.9858e-1 (9.47e-3) –	6.9881e-1 (9.11e-3) –	7.0320e-1 (2.28e-2)
	100	2	20000	7.1693e-1 (9.89e-3) ≈	7.0731e-1 (1.06e-2) ≈	7.1267e-1 (1.06e-2) ≈	7.1252e-1 (1.03e-2) ≈	7.1015e-1 (2.54e-2)
	100	2	50000	7.2838e-1 (8.16e-3) –	7.2930e-1 (8.19e-3) –	7.2735e-1 (9.30e-3) –	6.9901e-1 (3.98e-2) –	7.3336e-1 (1.08e-2)
MAP4	100	2	10000	6.3988e-1 (1.93e-2) ≈	6.3195e-1 (1.52e-2) ≈	6.3905e-1 (2.09e-2) ≈	6.3294e-1 (2.23e-2) ≈	6.3613e-1 (3.35e-2)
	100	2	20000	6.5467e-1 (2.45e-2) –	6.5655e-1 (1.39e-2) –	6.6523e-1 (1.97e-2) –	6.6415e-1 (1.93e-2) ≈	6.6279e-1 (3.08e-2)
	100	2	50000	6.7743e-1 (2.43e-2) –	6.8484e-1 (9.77e-3) –	6.8747e-1 (1.44e-2) ≈	6.7687e-1 (3.00e-2) ≈	6.7212e-1 (3.44e-2)
MAP5	100	2	10000	7.3069e-1 (1.10e-2) –	7.2101e-1 (9.81e-3) –	7.2867e-1 (9.65e-3) –	7.2390e-1 (2.32e-2) –	7.3957e-1 (1.66e-2)
	100	2	20000	7.3937e-1 (7.37e-3) –	7.3618e-1 (7.77e-3) –	7.4124e-1 (6.94e-3) –	7.3629e-1 (2.10e-2) –	7.4430e-1 (1.57e-2)
	100	2	50000	7.4814e-1 (6.63e-3) –	7.5434e-1 (8.76e-3) ≈	7.5284e-1 (8.12e-3) ≈	7.3941e-1 (2.63e-2) –	7.5304e-1 (1.42e-2)
MAP6	100	2	10000	6.1971e-1 (2.54e-2) ≈	6.0975e-1 (2.45e-2) ≈	6.2454e-1 (2.78e-2) ≈	6.2679e-1 (2.46e-2) ≈	6.2472e-1 (3.04e-2)
	100	2	20000	6.4946e-1 (2.42e-2) ≈	6.3307e-1 (2.64e-2) ≈	6.4677e-1 (2.05e-2) ≈	6.4995e-1 (2.32e-2) ≈	6.3328e-1 (3.30e-2)
	100	2	50000	6.7635e-1 (1.88e-2) ≈	6.7924e-1 (1.58e-2) ≈	6.6527e-1 (2.67e-2) ≈	6.5685e-1 (3.29e-2) ≈	6.6463e-1 (3.71e-2)
MAP7	100	2	10000	5.8762e-1 (2.97e-2) ≈	5.8227e-1 (2.50e-2) ≈	5.9098e-1 (2.34e-2) ≈	5.8761e-1 (2.81e-2) ≈	5.8946e-1 (3.13e-2)
	100	2	20000	6.1648e-1 (2.63e-2) ≈	6.1172e-1 (2.07e-2) ≈	6.2153e-1 (2.80e-2) ≈	6.1348e-1 (2.92e-2) ≈	6.1185e-1 (2.79e-2)
	100	2	50000	6.4055e-1 (2.89e-2) ≈	6.3444e-1 (2.35e-2) ≈	6.4553e-1 (2.56e-2) ≈	6.4020e-1 (2.90e-2) ≈	6.3277e-1 (3.27e-2)
MAP8	100	2	10000	5.7961e-1 (2.77e-2) ≈	5.6959e-1 (2.20e-2) ≈	5.7810e-1 (2.78e-2) ≈	5.7703e-1 (2.90e-2) ≈	5.8861e-1 (2.86e-2)
	100	2	20000	6.0798e-1 (2.98e-2) ≈	5.9556e-1 (2.82e-2) ≈	6.1622e-1 (2.98e-2) ≈	6.0579e-1 (3.24e-2) ≈	6.0585e-1 (2.90e-2)
	100	2	50000	6.2454e-1 (3.06e-2) ≈	6.3646e-1 (2.31e-2) ≈	6.3442e-1 (3.03e-2) ≈	6.3944e-1 (2.96e-2) ≈	6.3320e-1 (3.60e-2)
MAP9	100	2	10000	5.5440e-1 (2.75e-2) ≈	5.2705e-1 (2.51e-2) ≈	5.3975e-1 (2.69e-2) ≈	5.3976e-1 (2.63e-2) ≈	5.5601e-1 (2.05e-2)
	100	2	20000	5.7474e-1 (3.02e-2) ≈	5.6642e-1 (2.59e-2) ≈	5.8179e-1 (2.87e-2) ≈	5.7399e-1 (2.89e-2) ≈	5.8467e-1 (2.86e-2)
	100	2	50000	6.0833e-1 (3.04e-2) ≈	6.0764e-1 (2.73e-2) ≈	5.9505e-1 (2.72e-2) ≈	6.0943e-1 (3.55e-2) ≈	6.0107e-1 (2.63e-2)
MAP10	100	2	10000	7.0158e-1 (1.04e-2) ≈	6.8776e-1 (8.92e-3) –	6.9768e-1 (9.71e-3) –	6.9571e-1 (1.52e-2) –	6.9930e-1 (2.67e-2)
	100	2	20000	7.1577e-1 (1.07e-2) ≈	7.0927e-1 (1.07e-2) ≈	7.1752e-1 (8.56e-3) ≈	7.0719e-1 (1.69e-2) –	7.1704e-1 (2.12e-2)
	100	2	50000	7.2956e-1 (9.77e-3) ≈	7.2893e-1 (6.32e-3) –	7.2863e-1 (9.45e-3) –	7.1005e-1 (3.55e-2) –	7.3446e-1 (9.90e-3)
+/-/≈				0/6/24	0/10/20	0/8/22	0/12/18	

Tabela A.6: Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Comunicação em relação ao grid de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	1.1606e+3 (2.58e+1) ≈	1.1387e+3 (1.95e+1) +	1.1605e+3 (2.22e+1) ≈	1.1673e+3 (2.81e+1) ≈	1.1679e+3 (2.64e+1)
	100	2	20000	1.1946e+3 (2.26e+1) ≈	1.1822e+3 (2.53e+1) ≈	1.1861e+3 (1.86e+1) ≈	1.1865e+3 (2.96e+1) ≈	1.1868e+3 (2.24e+1)
	100	2	50000	1.2038e+3 (2.17e+1) ≈	1.2060e+3 (2.15e+1) ≈	1.2082e+3 (1.55e+1) ≈	1.2064e+3 (2.46e+1) ≈	1.2127e+3 (1.99e+1)
MAP2	100	2	10000	9.9902e+2 (3.27e+1) +	9.7024e+2 (4.28e+1) +	1.0014e+3 (2.89e+1) +	9.8728e+2 (4.72e+1) +	1.0623e+3 (4.17e+1)
	100	2	20000	1.0396e+3 (3.33e+1) +	1.0261e+3 (3.53e+1) +	1.0400e+3 (3.26e+1) +	1.0385e+3 (4.04e+1) +	1.0875e+3 (3.45e+1)
	100	2	50000	1.0784e+3 (3.58e+1) +	1.0790e+3 (3.50e+1) +	1.0870e+3 (3.07e+1) +	1.0813e+3 (4.10e+1) ≈	1.1009e+3 (2.58e+1)
MAP3	100	2	10000	1.0580e+3 (3.11e+1) +	1.0407e+3 (2.22e+1) +	1.0696e+3 (3.19e+1) +	1.0713e+3 (3.19e+1) +	1.1021e+3 (3.69e+1)
	100	2	20000	1.1063e+3 (3.63e+1) +	1.0912e+3 (2.95e+1) +	1.1065e+3 (3.35e+1) +	1.1030e+3 (2.97e+1) +	1.1309e+3 (2.89e+1)
	100	2	50000	1.1345e+3 (2.67e+1) +	1.1408e+3 (2.42e+1) ≈	1.1361e+3 (2.43e+1) +	1.1465e+3 (3.40e+1) ≈	1.1527e+3 (3.17e+1)
MAP4	100	2	10000	9.4316e+2 (4.46e+1) +	9.0276e+2 (6.25e+1) +	9.4926e+2 (5.42e+1) +	9.4466e+2 (8.22e+1) +	1.0373e+3 (4.46e+1)
	100	2	20000	9.9035e+2 (4.33e+1) +	9.7529e+2 (3.86e+1) +	1.0074e+3 (3.86e+1) +	9.9734e+2 (4.18e+1) +	1.0473e+3 (5.05e+1)
	100	2	50000	1.0463e+3 (3.67e+1) +	1.0218e+3 (3.70e+1) +	1.0625e+3 (3.57e+1) ≈	1.0524e+3 (3.46e+1) +	1.0776e+3 (3.61e+1)
MAP5	100	2	10000	1.1362e+3 (3.07e+1) +	1.1135e+3 (2.92e+1) +	1.1380e+3 (2.79e+1) +	1.1398e+3 (2.99e+1) +	1.1610e+3 (3.33e+1)
	100	2	20000	1.1675e+3 (2.38e+1) ≈	1.1535e+3 (2.45e+1) +	1.1675e+3 (2.70e+1) ≈	1.1555e+3 (4.36e+1) ≈	1.1706e+3 (3.14e+1)
	100	2	50000	1.1856e+3 (2.05e+1) ≈	1.1881e+3 (2.39e+1) ≈	1.1936e+3 (1.84e+1) ≈	1.1815e+3 (3.37e+1) ≈	1.1957e+3 (2.34e+1)
MAP6	100	2	10000	9.4814e+2 (6.09e+1) +	8.9389e+2 (4.27e+1) +	9.5787e+2 (4.75e+1) +	9.3643e+2 (4.12e+1) +	1.0308e+3 (4.02e+1)
	100	2	20000	9.9578e+2 (3.87e+1) +	9.4558e+2 (4.91e+1) +	9.8875e+2 (4.13e+1) +	9.8899e+2 (4.99e+1) +	1.0483e+3 (3.23e+1)
	100	2	50000	1.0356e+3 (3.76e+1) +	1.0203e+3 (4.91e+1) +	1.0385e+3 (4.01e+1) +	1.0404e+3 (4.80e+1) +	1.0775e+3 (2.78e+1)
MAP7	100	2	10000	8.8202e+2 (6.29e+1) +	8.4153e+2 (6.07e+1) +	8.8303e+2 (6.44e+1) +	8.7665e+2 (8.01e+1) +	9.7101e+2 (4.42e+1)
	100	2	20000	9.3169e+2 (5.92e+1) +	8.9220e+2 (5.16e+1) +	9.5076e+2 (4.28e+1) +	9.3347e+2 (5.48e+1) +	9.9908e+2 (4.83e+1)
	100	2	50000	9.9293e+2 (4.99e+1) +	9.7638e+2 (5.03e+1) +	9.8471e+2 (4.82e+1) +	1.0023e+3 (5.53e+1) +	1.0458e+3 (3.57e+1)
MAP8	100	2	10000	8.9247e+2 (5.94e+1) +	8.0800e+2 (9.05e+1) +	8.8797e+2 (5.72e+1) +	8.6407e+2 (8.50e+1) +	9.8232e+2 (4.54e+1)
	100	2	20000	9.5124e+2 (5.58e+1) +	8.9771e+2 (6.20e+1) +	9.1531e+2 (4.57e+1) +	9.3672e+2 (5.50e+1) +	1.0157e+3 (3.77e+1)
	100	2	50000	9.9686e+2 (6.54e+1) ≈	9.5221e+2 (5.57e+1) +	9.9004e+2 (4.72e+1) +	9.9764e+2 (5.11e+1) +	1.0351e+3 (3.54e+1)
MAP9	100	2	10000	8.4813e+2 (6.00e+1) +	7.8899e+2 (8.27e+1) +	8.4437e+2 (5.20e+1) +	8.4272e+2 (7.57e+1) +	9.3323e+2 (4.20e+1)
	100	2	20000	9.0603e+2 (5.58e+1) +	8.4525e+2 (7.89e+1) +	8.9460e+2 (7.04e+1) +	9.1367e+2 (6.23e+1) +	9.6398e+2 (4.50e+1)
	100	2	50000	9.3124e+2 (6.75e+1) +	9.1021e+2 (5.77e+1) +	9.6094e+2 (5.82e+1) +	9.6295e+2 (4.55e+1) +	9.9766e+2 (4.17e+1)
MAP10	100	2	10000	1.0744e+3 (3.89e+1) +	1.0341e+3 (2.38e+1) +	1.0735e+3 (2.52e+1) +	1.0614e+3 (3.02e+1) +	1.1109e+3 (3.49e+1)
	100	2	20000	1.1067e+3 (3.01e+1) +	1.0903e+3 (3.59e+1) +	1.1180e+3 (3.00e+1) +	1.0986e+3 (5.99e+1) +	1.1345e+3 (2.94e+1)
	100	2	50000	1.1423e+3 (3.28e+1) ≈	1.1327e+3 (3.12e+1) +	1.1452e+3 (2.37e+1) ≈	1.1405e+3 (4.02e+1) ≈	1.1528e+3 (2.70e+1)
+/-/≈				23/0/7	26/0/4	22/0/8	22/0/8	

Tabela A.7: Resultados para o cálculo do Hypervolume para as métricas de Comunicação e Energia em relação ao *grid* de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>M</i>	<i>D</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	2	1	7.6204e-1 (1.37e-2) ≈	7.5294e-1 (1.13e-2) –	7.6375e-1 (1.25e-2) ≈	7.5970e-1 (1.50e-2) –	7.6913e-1 (1.40e-2)
	2	2	7.8081e-1 (1.51e-2) ≈	7.7526e-1 (1.22e-2) –	7.8933e-1 (1.39e-2) ≈	7.5772e-1 (1.94e-2) –	7.8479e-1 (1.35e-2)
	2	3	7.9550e-1 (1.29e-2) ≈	7.9520e-1 (1.50e-2) ≈	8.0282e-1 (1.22e-2) +	7.5077e-1 (1.66e-2) –	7.8983e-1 (1.30e-2)
MAP2	2	1	6.6514e-1 (1.39e-2) –	6.5242e-1 (1.53e-2) –	6.7529e-1 (1.05e-2) –	6.7103e-1 (1.24e-2) –	6.9451e-1 (1.91e-2)
	2	2	6.9693e-1 (1.15e-2) –	6.8419e-1 (1.57e-2) –	7.0217e-1 (1.59e-2) –	6.9876e-1 (1.86e-2) –	7.0631e-1 (1.45e-2)
	2	3	7.2336e-1 (1.06e-2) ≈	7.2548e-1 (1.08e-2) ≈	7.2849e-1 (1.27e-2) ≈	6.8652e-1 (2.11e-2) –	7.2743e-1 (1.76e-2)
MAP3	2	1	7.0713e-1 (1.83e-2) –	6.9082e-1 (1.10e-2) –	7.0765e-1 (1.32e-2) –	7.0146e-1 (1.46e-2) –	7.2694e-1 (1.66e-2)
	2	2	7.3630e-1 (1.17e-2) ≈	7.2459e-1 (1.53e-2) –	7.3103e-1 (1.39e-2) ≈	7.3117e-1 (1.63e-2) ≈	7.3521e-1 (1.66e-2)
	2	3	7.5381e-1 (1.28e-2) ≈	7.5679e-1 (1.25e-2) ≈	7.6661e-1 (1.38e-2) +	7.1329e-1 (2.75e-2) –	7.5722e-1 (1.57e-2)
MAP4	2	1	6.4318e-1 (1.66e-2) –	6.2456e-1 (1.26e-2) –	6.4617e-1 (1.30e-2) –	6.3380e-1 (1.23e-2) –	6.6399e-1 (1.74e-2)
	2	2	6.7218e-1 (1.57e-2) –	6.6001e-1 (1.59e-2) –	6.7967e-1 (1.29e-2) –	6.7665e-1 (1.29e-2) –	6.8996e-1 (1.58e-2)
	2	3	7.0280e-1 (1.84e-2) ≈	7.0084e-1 (1.07e-2) ≈	7.0491e-1 (1.47e-2) ≈	6.8123e-1 (2.16e-2) –	7.0695e-1 (1.68e-2)
MAP5	2	1	7.4957e-1 (1.44e-2) –	7.3625e-1 (1.41e-2) –	7.5470e-1 (1.16e-2) ≈	7.4624e-1 (1.67e-2) –	7.6145e-1 (1.47e-2)
	2	2	7.7080e-1 (1.47e-2) ≈	7.6647e-1 (1.43e-2) ≈	7.7522e-1 (1.40e-2) ≈	7.5746e-1 (1.70e-2) –	7.6954e-1 (1.10e-2)
	2	3	7.8171e-1 (1.32e-2) ≈	7.8962e-1 (1.17e-2) ≈	7.9501e-1 (1.32e-2) +	7.4320e-1 (1.71e-2) –	7.8648e-1 (1.32e-2)
MAP6	2	1	6.2155e-1 (1.12e-2) –	6.0723e-1 (1.08e-2) –	6.2550e-1 (1.29e-2) –	6.1932e-1 (1.14e-2) –	6.4723e-1 (2.05e-2)
	2	2	6.5540e-1 (1.53e-2) –	6.4277e-1 (1.37e-2) –	6.6384e-1 (1.20e-2) ≈	6.5704e-1 (1.44e-2) –	6.7400e-1 (2.19e-2)
	2	3	6.8846e-1 (1.40e-2) –	6.8638e-1 (1.45e-2) –	6.8999e-1 (1.65e-2) –	6.8462e-1 (1.92e-2) –	7.0116e-1 (1.70e-2)
MAP7	2	1	5.9492e-1 (1.46e-2) –	5.8019e-1 (1.33e-2) –	6.0217e-1 (1.43e-2) –	5.9986e-1 (1.76e-2) –	6.1974e-1 (1.95e-2)
	2	2	6.2935e-1 (1.42e-2) –	6.1059e-1 (1.47e-2) –	6.3156e-1 (1.22e-2) –	6.2927e-1 (1.56e-2) –	6.4595e-1 (1.56e-2)
	2	3	6.6231e-1 (1.36e-2) ≈	6.5624e-1 (1.34e-2) –	6.7354e-1 (1.37e-2) ≈	6.5765e-1 (2.42e-2) –	6.7162e-1 (1.91e-2)
MAP8	2	1	5.8642e-1 (1.60e-2) –	5.7197e-1 (1.04e-2) –	5.9173e-1 (1.19e-2) –	5.8685e-1 (1.21e-2) –	6.1648e-1 (1.71e-2)
	2	2	6.2125e-1 (1.58e-2) –	6.0527e-1 (9.71e-3) –	6.2469e-1 (1.49e-2) –	6.2122e-1 (1.33e-2) –	6.3820e-1 (1.42e-2)
	2	3	6.5690e-1 (1.68e-2) ≈	6.4909e-1 (1.62e-2) –	6.6357e-1 (1.39e-2) ≈	6.5663e-1 (1.99e-2) ≈	6.5921e-1 (1.70e-2)
MAP9	2	1	5.5754e-1 (1.40e-2) –	5.4186e-1 (9.70e-3) –	5.5881e-1 (1.22e-2) –	5.5930e-1 (1.21e-2) –	5.8862e-1 (1.77e-2)
	2	2	5.9384e-1 (1.07e-2) –	5.7772e-1 (1.37e-2) –	6.0053e-1 (1.12e-2) –	5.9209e-1 (9.80e-3) –	6.1914e-1 (1.93e-2)
	2	3	6.3513e-1 (1.95e-2) ≈	6.1928e-1 (1.72e-2) –	6.3696e-1 (1.45e-2) ≈	6.3227e-1 (1.61e-2) ≈	6.4321e-1 (2.14e-2)
MAP10	2	1	7.0710e-1 (1.75e-2) –	6.8407e-1 (1.47e-2) –	7.0954e-1 (1.11e-2) –	7.0791e-1 (1.46e-2) –	7.1954e-1 (2.17e-2)
	2	2	7.3187e-1 (1.29e-2) ≈	7.2373e-1 (1.29e-2) –	7.3879e-1 (1.46e-2) ≈	7.3755e-1 (1.30e-2) ≈	7.3512e-1 (1.75e-2)
	2	3	7.5513e-1 (1.43e-2) ≈	7.5382e-1 (1.03e-2) ≈	7.5983e-1 (1.42e-2) ≈	7.1776e-1 (2.42e-2) –	7.5742e-1 (1.39e-2)
+ / - / ≈			0/16/14	0/23/7	3/13/14	0/25/5	

Tabela A.8: Resultados para o cálculo do IGD para as métricas de Comunicação e Energia em relação ao *grid* de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>M</i>	<i>D</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	2	1	1.4287e+3 (1.18e+2) +	1.4101e+3 (1.24e+2) +	1.4112e+3 (1.37e+2) +	1.4648e+3 (9.22e+1) +	1.5283e+3 (6.92e+1)
	2	2	1.5172e+3 (8.48e+1) ≈	1.4595e+3 (1.14e+2) +	1.4435e+3 (7.61e+1) +	1.5791e+3 (6.83e+1) –	1.5475e+3 (6.00e+1)
	2	3	1.4949e+3 (5.82e+1) +	1.4922e+3 (8.15e+1) +	1.4990e+3 (5.45e+1) +	1.6282e+3 (5.23e+1) –	1.5570e+3 (6.05e+1)
MAP2	2	1	1.1902e+3 (1.79e+2) +	1.1228e+3 (1.50e+2) +	1.0802e+3 (2.02e+2) +	1.2597e+3 (1.08e+2) +	1.3716e+3 (1.27e+2)
	2	2	1.3318e+3 (1.05e+2) +	1.2531e+3 (1.55e+2) +	1.1851e+3 (1.62e+2) +	1.3009e+3 (1.47e+2) +	1.4120e+3 (9.47e+1)
	2	3	1.3497e+3 (1.14e+2) +	1.3441e+3 (1.15e+2) +	1.3404e+3 (9.47e+1) +	1.4808e+3 (7.30e+1) –	1.4384e+3 (8.30e+1)
MAP3	2	1	1.3156e+3 (1.51e+2) +	1.2358e+3 (1.38e+2) +	1.2796e+3 (1.17e+2) +	1.3171e+3 (1.53e+2) +	1.4657e+3 (9.31e+1)
	2	2	1.3711e+3 (1.17e+2) +	1.3207e+3 (1.25e+2) +	1.3062e+3 (1.39e+2) +	1.4144e+3 (1.19e+2) ≈	1.4297e+3 (1.11e+2)
	2	3	1.4560e+3 (7.85e+1) ≈	1.4248e+3 (1.05e+2) +	1.4167e+3 (9.77e+1) +	1.5772e+3 (6.14e+1) –	1.4857e+3 (1.02e+2)
MAP4	2	1	1.1477e+3 (1.53e+2) +	1.0723e+3 (1.96e+2) +	1.0223e+3 (1.77e+2) +	1.1528e+3 (1.48e+2) +	1.3604e+3 (1.00e+2)
	2	2	1.1901e+3 (1.45e+2) +	1.1582e+3 (1.59e+2) +	1.1428e+3 (1.42e+2) +	1.2200e+3 (1.30e+2) +	1.3812e+3 (1.02e+2)
	2	3	1.3556e+3 (1.35e+2) +	1.2906e+3 (1.09e+2) +	1.2521e+3 (1.37e+2) +	1.3960e+3 (1.23e+2) ≈	1.4491e+3 (6.32e+1)
MAP5	2	1	1.3902e+3 (1.07e+2) +	1.3083e+3 (1.39e+2) +	1.3190e+3 (1.60e+2) +	1.4020e+3 (1.54e+2) +	1.5252e+3 (8.11e+1)
	2	2	1.4708e+3 (9.94e+1) +	1.4072e+3 (1.31e+2) +	1.4338e+3 (1.09e+2) +	1.5343e+3 (9.48e+1) ≈	1.5554e+3 (7.19e+1)
	2	3	1.5084e+3 (9.02e+1) ≈	1.4828e+3 (9.53e+1) +	1.4806e+3 (8.14e+1) +	1.6083e+3 (6.97e+1) –	1.5368e+3 (9.08e+1)
MAP6	2	1	1.1569e+3 (1.52e+2) +	1.0698e+3 (1.88e+2) +	1.0594e+3 (2.39e+2) +	1.0817e+3 (1.74e+2) +	1.3341e+3 (9.88e+1)
	2	2	1.1931e+3 (1.29e+2) +	1.0747e+3 (2.45e+2) +	1.1137e+3 (1.66e+2) +	1.1881e+3 (1.47e+2) +	1.3725e+3 (1.02e+2)
	2	3	1.2781e+3 (1.32e+2) +	1.1996e+3 (1.43e+2) +	1.2455e+3 (1.42e+2) +	1.3371e+3 (1.34e+2) +	1.4124e+3 (8.55e+1)
MAP7	2	1	1.0573e+3 (1.64e+2) +	9.5999e+2 (1.61e+2) +	1.0177e+3 (1.67e+2) +	1.0393e+3 (2.03e+2) +	1.2562e+3 (1.56e+2)
	2	2	1.1229e+3 (1.47e+2) +	1.0409e+3 (1.99e+2) +	1.0359e+3 (2.04e+2) +	1.0693e+3 (1.85e+2) +	1.3423e+3 (1.08e+2)
	2	3	1.1671e+3 (1.43e+2) +	1.1613e+3 (1.84e+2) +	1.1405e+3 (1.36e+2) +	1.2659e+3 (1.22e+2) +	1.3678e+3 (9.12e+1)
MAP8	2	1	1.0122e+3 (1.25e+2) +	9.6673e+2 (1.57e+2) +	9.3760e+2 (1.77e+2) +	1.0920e+3 (1.29e+2) +	1.2732e+3 (1.08e+2)
	2	2	1.0963e+3 (1.42e+2) +	1.0509e+3 (1.54e+2) +	9.7396e+2 (1.51e+2) +	1.0975e+3 (1.85e+2) +	1.2964e+3 (1.00e+2)
	2	3	1.1795e+3 (1.32e+2) +	1.1176e+3 (1.51e+2) +	1.1614e+3 (1.29e+2) +	1.2504e+3 (1.49e+2) +	1.3806e+3 (8.53e+1)
MAP9	2	1	9.0813e+2 (2.30e+2) +	9.3335e+2 (1.65e+2) +	8.6847e+2 (2.32e+2) +	1.0081e+3 (1.70e+2) +	1.2079e+3 (1.15e+2)
	2	2	1.0462e+3 (1.58e+2) +	9.7922e+2 (1.85e+2) +	9.0345e+2 (2.03e+2) +	1.0568e+3 (1.53e+2) +	1.2678e+3 (1.21e+2)
	2	3	1.1366e+3 (1.34e+2) +	1.1145e+3 (1.53e+2) +	1.0559e+3 (1.92e+2) +	1.1501e+3 (1.50e+2) +	1.3461e+3 (8.95e+1)
MAP10	2	1	1.3304e+3 (1.48e+2) +	1.2456e+3 (1.48e+2) +	1.2269e+3 (1.54e+2) +	1.3257e+3 (1.35e+2) +	1.4687e+3 (9.80e+1)
	2	2	1.3795e+3 (1.62e+2) +	1.3120e+3 (1.44e+2) +	1.3265e+3 (1.47e+2) +	1.4186e+3 (9.04e+1) +	1.4938e+3 (8.60e+1)
	2	3	1.4341e+3 (1.03e+2) +	1.4398e+3 (1.21e+2) +	1.3737e+3 (1.09e+2) +	1.5669e+3 (8.23e+1) –	1.5035e+3 (6.59e+1)
+ / - / ≈			27/0/3	30/0/0	30/0/0	21/6/3	

Tabela A.9: Resultados para o cálculo do Hypervolume para as métricas de Energia e Balanceamento de Carga em relação ao grid de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	N	M	FE	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	6.1145e-1 (1.32e-2) ≈	5.9855e-1 (8.72e-3) −	6.1935e-1 (8.62e-3) +	6.0603e-1 (1.14e-2) ≈	6.0802e-1 (1.84e-2)
	100	2	20000	6.2972e-1 (1.20e-2) +	6.2312e-1 (7.48e-3) ≈	6.3954e-1 (8.95e-3) ≈	6.2518e-1 (9.70e-3) ≈	6.1998e-1 (1.01e-2)
	100	2	50000	6.5035e-1 (1.12e-2) +	6.4050e-1 (1.02e-2) ≈	6.5385e-1 (1.19e-2) +	6.2578e-1 (2.22e-2) ≈	6.3681e-1 (1.41e-2)
MAP2	100	2	10000	5.6055e-1 (1.22e-2) +	5.5387e-1 (9.02e-3) ≈	5.7135e-1 (8.07e-3) +	5.5926e-1 (8.90e-3) ≈	5.5201e-1 (1.73e-2)
	100	2	20000	5.8253e-1 (1.23e-2) +	5.7373e-1 (1.04e-2) ≈	5.8754e-1 (9.11e-3) +	5.7640e-1 (1.03e-2) ≈	5.7138e-1 (1.21e-2)
	100	2	50000	5.9933e-1 (1.18e-2) +	5.9623e-1 (8.89e-3) +	6.0333e-1 (8.98e-3) +	5.8998e-1 (1.37e-2) ≈	5.8688e-1 (1.49e-2)
MAP3	100	2	10000	5.7816e-1 (1.01e-2) +	5.6482e-1 (9.02e-3) −	5.8377e-1 (8.01e-3) +	5.7485e-1 (6.88e-3) ≈	5.7076e-1 (1.04e-2)
	100	2	20000	5.9762e-1 (8.85e-3) +	5.8881e-1 (9.40e-3) ≈	6.0217e-1 (9.69e-3) +	5.9358e-1 (1.07e-2) +	5.8622e-1 (1.22e-2)
	100	2	50000	6.1587e-1 (9.25e-3) +	6.0632e-1 (9.53e-3) ≈	6.2167e-1 (9.72e-3) +	6.0685e-1 (1.54e-2) ≈	6.0425e-1 (1.11e-2)
MAP4	100	2	10000	5.4968e-1 (8.59e-3) +	5.3829e-1 (6.86e-3) −	5.5561e-1 (8.44e-3) +	5.4729e-1 (9.80e-3) ≈	5.4147e-1 (1.69e-2)
	100	2	20000	5.6547e-1 (8.42e-3) ≈	5.5787e-1 (1.04e-2) ≈	5.7350e-1 (6.44e-3) +	5.6123e-1 (8.81e-3) ≈	5.6038e-1 (1.19e-2)
	100	2	50000	5.8483e-1 (9.64e-3) +	5.8419e-1 (1.04e-2) +	5.9078e-1 (1.12e-2) +	5.8081e-1 (1.11e-2) ≈	5.7623e-1 (1.20e-2)
MAP5	100	2	10000	5.9411e-1 (9.13e-3) +	5.8430e-1 (9.48e-3) ≈	6.0045e-1 (8.53e-3) +	5.8676e-1 (1.11e-2) ≈	5.8678e-1 (1.25e-2)
	100	2	20000	6.1386e-1 (1.05e-2) ≈	6.0325e-1 (9.60e-3) ≈	6.2006e-1 (1.01e-2) +	6.0387e-1 (8.90e-3) ≈	6.0686e-1 (1.44e-2)
	100	2	50000	6.3105e-1 (1.29e-2) +	6.2291e-1 (1.35e-2) ≈	6.3479e-1 (8.75e-3) +	6.1587e-1 (1.53e-2) ≈	6.2141e-1 (1.11e-2)
MAP6	100	2	10000	5.3911e-1 (9.34e-3) ≈	5.2998e-1 (9.30e-3) ≈	5.4356e-1 (8.69e-3) +	5.3524e-1 (1.04e-2) ≈	5.3411e-1 (1.21e-2)
	100	2	20000	5.5863e-1 (8.88e-3) +	5.4859e-1 (6.82e-3) ≈	5.6186e-1 (8.24e-3) +	5.5324e-1 (1.06e-2) ≈	5.4737e-1 (1.45e-2)
	100	2	50000	5.7329e-1 (9.08e-3) +	5.6850e-1 (8.74e-3) ≈	5.8022e-1 (5.14e-3) +	5.7026e-1 (8.63e-3) ≈	5.6783e-1 (1.20e-2)
MAP7	100	2	10000	5.2527e-1 (1.13e-2) ≈	5.1427e-1 (7.81e-3) ≈	5.2949e-1 (9.69e-3) +	5.1991e-1 (8.56e-3) ≈	5.1957e-1 (9.90e-3)
	100	2	20000	5.3972e-1 (8.77e-3) +	5.3143e-1 (9.06e-3) ≈	5.4226e-1 (8.31e-3) +	5.3723e-1 (7.34e-3) +	5.3428e-1 (1.28e-2)
	100	2	50000	5.5952e-1 (8.72e-3) +	5.5653e-1 (7.83e-3) +	5.6228e-1 (7.89e-3) +	5.5514e-1 (7.93e-3) ≈	5.4940e-1 (1.54e-2)
MAP8	100	2	10000	5.1832e-1 (7.79e-3) ≈	5.1285e-1 (9.38e-3) ≈	5.2543e-1 (9.31e-3) +	5.1616e-1 (8.79e-3) ≈	5.1353e-1 (1.39e-2)
	100	2	20000	5.3746e-1 (8.26e-3) +	5.3135e-1 (9.85e-3) ≈	5.3995e-1 (8.03e-3) +	5.3315e-1 (7.86e-3) ≈	5.2840e-1 (1.49e-2)
	100	2	50000	5.5299e-1 (8.40e-3) +	5.4809e-1 (9.09e-3) ≈	5.6070e-1 (8.25e-3) +	5.5220e-1 (9.38e-3) +	5.4464e-1 (1.32e-2)
MAP9	100	2	10000	5.0640e-1 (9.16e-3) +	4.9814e-1 (6.72e-3) ≈	5.1070e-1 (7.33e-3) +	5.0636e-1 (7.13e-3) +	4.9891e-1 (1.12e-2)
	100	2	20000	5.2520e-1 (9.09e-3) +	5.2003e-1 (7.57e-3) +	5.2626e-1 (8.45e-3) +	5.1961e-1 (8.55e-3) ≈	5.1381e-1 (1.05e-2)
	100	2	50000	5.3984e-1 (7.71e-3) +	5.3293e-1 (9.33e-3) ≈	5.4728e-1 (7.67e-3) +	5.3817e-1 (1.01e-2) +	5.3115e-1 (1.18e-2)
MAP10	100	2	10000	5.7677e-1 (1.08e-2) +	5.6685e-1 (9.61e-3) ≈	5.8302e-1 (1.01e-2) +	5.7389e-1 (8.28e-3) ≈	5.6843e-1 (1.35e-2)
	100	2	20000	5.9538e-1 (8.65e-3) +	5.8747e-1 (1.04e-2) ≈	6.0367e-1 (9.73e-3) +	5.9216e-1 (1.39e-2) ≈	5.8562e-1 (1.40e-2)
	100	2	50000	6.1088e-1 (9.36e-3) +	6.0834e-1 (7.98e-3) +	6.2073e-1 (7.21e-3) +	6.0837e-1 (1.10e-2) ≈	6.0217e-1 (1.31e-2)
+/-/≈				24/0/6	5/3/22	30/0/0	5/0/25	

Tabela A.10: Resultados para o cálculo do IGD para as métricas de Energia e Balanceamento de Carga em relação ao grid de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	N	M	FE	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	5.4321e+1 (8.63e+0) ≈	5.6284e+1 (6.15e+0) ≈	5.3388e+1 (5.18e+0) ≈	5.1823e+1 (6.59e+0) ≈	5.5750e+1 (6.85e+0)
	100	2	20000	5.8218e+1 (7.26e+0) ≈	5.2623e+1 (7.22e+0) +	5.3223e+1 (6.13e+0) +	5.6918e+1 (6.89e+0) ≈	5.9481e+1 (7.75e+0)
	100	2	50000	6.0482e+1 (8.15e+0) ≈	5.6219e+1 (7.82e+0) +	5.7552e+1 (7.89e+0) +	6.7908e+1 (9.62e+0) −	6.2246e+1 (7.37e+0)
MAP2	100	2	10000	4.5760e+1 (5.37e+0) ≈	4.6259e+1 (4.86e+0) ≈	4.4198e+1 (5.17e+0) +	4.4630e+1 (4.88e+0) +	4.8857e+1 (8.55e+0)
	100	2	20000	4.7493e+1 (5.57e+0) ≈	4.5231e+1 (7.84e+0) ≈	4.5230e+1 (5.00e+0) ≈	4.8157e+1 (5.09e+0) ≈	4.7158e+1 (5.41e+0)
	100	2	50000	4.8326e+1 (5.41e+0) ≈	4.8992e+1 (6.84e+0) +	4.9492e+1 (6.63e+0) +	5.1522e+1 (8.24e+0) ≈	5.1254e+1 (7.06e+0)
MAP3	100	2	10000	5.0355e+1 (6.29e+0) ≈	4.7093e+1 (7.27e+0) +	4.5630e+1 (6.57e+0) +	4.7526e+1 (4.99e+0) +	5.2052e+1 (6.30e+0)
	100	2	20000	5.3121e+1 (7.24e+0) ≈	5.0124e+1 (6.59e+0) ≈	4.8594e+1 (6.92e+0) ≈	5.0690e+1 (7.42e+0) ≈	5.1854e+1 (7.20e+0)
	100	2	50000	5.3554e+1 (6.44e+0) +	5.4353e+1 (8.56e+0) +	5.4587e+1 (6.52e+0) +	5.6983e+1 (6.63e+0) ≈	5.8914e+1 (8.02e+0)
MAP4	100	2	10000	4.1068e+1 (6.00e+0) +	4.2863e+1 (5.13e+0) +	4.1801e+1 (5.71e+0) +	4.3163e+1 (4.64e+0) +	4.8089e+1 (6.95e+0)
	100	2	20000	4.3365e+1 (5.02e+0) +	4.3796e+1 (5.14e+0) +	4.4230e+1 (5.50e+0) +	4.6958e+1 (7.03e+0) ≈	4.8090e+1 (6.31e+0)
	100	2	50000	4.7726e+1 (5.25e+0) ≈	4.4631e+1 (5.78e+0) +	4.4565e+1 (5.33e+0) +	4.6927e+1 (6.83e+0) ≈	5.0655e+1 (8.01e+0)
MAP5	100	2	10000	5.0889e+1 (6.40e+0) +	4.8526e+1 (6.13e+0) +	4.9592e+1 (7.01e+0) +	4.9891e+1 (6.55e+0) +	5.8580e+1 (6.46e+0)
	100	2	20000	5.4054e+1 (7.96e+0) ≈	5.3753e+1 (6.27e+0) ≈	5.2523e+1 (7.33e+0) ≈	5.2555e+1 (7.25e+0) ≈	5.3853e+1 (7.15e+0)
	100	2	50000	5.7484e+1 (6.17e+0) ≈	5.3388e+1 (6.67e+0) +	5.6253e+1 (7.51e+0) ≈	5.9914e+1 (8.28e+0) ≈	5.9681e+1 (7.54e+0)
MAP6	100	2	10000	4.3928e+1 (4.54e+0) ≈	4.4360e+1 (5.28e+0) ≈	4.3330e+1 (5.31e+0) ≈	4.2464e+1 (4.99e+0) +	4.6658e+1 (5.80e+0)
	100	2	20000	4.5028e+1 (5.09e+0) ≈	4.3762e+1 (4.90e+0) +	4.4862e+1 (4.94e+0) ≈	4.4795e+1 (5.66e+0) ≈	4.7323e+1 (6.69e+0)
	100	2	50000	4.7891e+1 (6.28e+0) ≈	4.6259e+1 (4.90e+0) ≈	4.4365e+1 (5.99e+0) +	4.8257e+1 (6.25e+0) ≈	4.8556e+1 (7.12e+0)
MAP7	100	2	10000	4.2297e+1 (4.80e+0) ≈	4.0399e+1 (4.08e+0) +	3.7473e+1 (4.94e+0) +	4.2030e+1 (4.91e+0) +	4.5593e+1 (5.30e+0)
	100	2	20000	4.3395e+1 (4.91e+0) ≈	4.1930e+1 (4.32e+0) +	4.3196e+1 (5.54e+0) ≈	4.4427e+1 (5.05e+0) ≈	4.4826e+1 (5.73e+0)
	100	2	50000	4.3232e+1 (5.26e+0) +	4.3164e+1 (5.69e+0) ≈	4.3064e+1 (4.77e+0) +	4.5295e+1 (5.67e+0) ≈	4.6490e+1 (5.69e+0)
MAP8	100	2	10000	4.0465e+1 (3.09e+0) ≈	3.9800e+1 (5.35e+0) ≈	3.9569e+1 (4.85e+0) +	4.1496e+1 (4.95e+0) ≈	4.2629e+1 (6.16e+0)
	100	2	20000	4.0301e+1 (4.69e+0) +	3.9569e+1 (5.07e+0) +	4.0667e+1 (5.15e+0) +	4.0567e+1 (6.02e+0) +	4.4193e+1 (5.40e+0)
	100	2	50000	4.2431e+1 (5.20e+0) +	4.3463e+1 (6.18e+0) +	4.1336e+1 (5.71e+0) +	4.2765e+1 (5.46e+0) +	4.6490e+1 (6.03e+0)
MAP9	100	2	10000	4.0664e+1 (3.91e+0) +	3.9265e+1 (4.21e+0) ≈	3.8602e+1 (4.46e+0) +	3.8867e+1 (4.01e+0) +	4.1795e+1 (5.82e+0)
	100	2	20000	4.0600e+1 (4.92e+0) ≈	3.8270e+1 (4.31e+0) +	3.8338e+1 (4.70e+0) ≈	4.1064e+1 (4.73e+0) ≈	4.1496e+1 (6.27e+0)
	100	2	50000	4.3196e+1 (4.23e+0) +	4.1997e+1 (5.85e+0) +	4.4007e+1 (4.67e+0) +	4.4227e+1 (5.37e+0) ≈	4.3793e+1 (5.67e+0)
MAP10	100	2	10000	4.8824e+1 (6.46e+0) +	4.6461e+1 (6.22e+0) +	4.6495e+1 (5.95e+0) +	4.6727e+1 (4.50e+0) +	5.5450e+1 (7.92e+0)
	100	2	20000	5.2288e+1 (6.43e+0) ≈	4.8192e+1 (6.44e+0) +	4.8959e+1 (6.18e+0) +	5.1323e+1 (7.39e+0) ≈	5.2686e+1 (5.58e+0)
	100	2	50000	5.6350e+1 (5.47e+0) ≈	5.2487e+1 (6.10e+0) +	5.3588e+1 (5.41e+0) +	5.5585e+1 (6.95e+0) ≈	5.7448e+1 (6.26e+0)
+/-/≈				8/0/22	17/0/13	19/0/11	8/1/21	

Tabela A.11: Resultados para o cálculo do *Hypervolume* para as métricas de Tolerância a Falhas e Energia em relação ao *grid* de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAI
MAP1	100	2	10000	8.2197e-1 (1.90e-2) ≈	8.0659e-1 (1.24e-2) −	8.2130e-1 (1.64e-2) ≈	8.2828e-1 (1.84e-2) ≈	8.2854e-1 (1.76e-2)
	100	2	20000	8.4501e-1 (1.26e-2) +	8.3528e-1 (1.40e-2) ≈	8.4092e-1 (1.38e-2) ≈	8.4571e-1 (1.28e-2) +	8.3230e-1 (1.68e-2)
	100	2	50000	8.5363e-1 (1.25e-2) +	8.5725e-1 (1.02e-2) +	8.5207e-1 (1.37e-2) ≈	8.5473e-1 (8.53e-3) +	8.4481e-1 (1.43e-2)
MAP2	100	2	10000	7.9357e-1 (1.92e-2) −	7.8233e-1 (1.77e-2) −	7.9488e-1 (1.74e-2) −	7.9787e-1 (1.78e-2) ≈	8.0410e-1 (2.80e-2)
	100	2	20000	8.1769e-1 (1.59e-2) ≈	8.1723e-1 (1.90e-2) ≈	8.1234e-1 (1.91e-2) ≈	8.2228e-1 (1.65e-2) ≈	8.1816e-1 (1.91e-2)
	100	2	50000	8.4388e-1 (1.45e-2) +	8.4318e-1 (1.84e-2) ≈	8.4298e-1 (1.37e-2) ≈	8.4628e-1 (1.37e-2) +	8.3361e-1 (2.14e-2)
MAP3	100	2	10000	8.0264e-1 (2.85e-2) −	7.8505e-1 (2.43e-2) −	7.9464e-1 (1.51e-2) −	8.0463e-1 (1.46e-2) −	8.1785e-1 (1.72e-2)
	100	2	20000	8.2595e-1 (2.25e-2) ≈	8.2626e-1 (1.48e-2) ≈	8.3047e-1 (1.74e-2) ≈	8.2981e-1 (1.61e-2) ≈	8.2202e-1 (2.74e-2)
	100	2	50000	8.4553e-1 (1.54e-2) +	8.4680e-1 (1.35e-2) +	8.4646e-1 (1.25e-2) +	8.4353e-1 (1.42e-2) ≈	8.3673e-1 (1.53e-2)
MAP4	100	2	10000	7.8872e-1 (1.91e-2) −	7.7293e-1 (1.44e-2) −	7.8973e-1 (1.53e-2) −	7.8641e-1 (1.74e-2) −	7.9642e-1 (2.82e-2)
	100	2	20000	8.0841e-1 (2.99e-2) ≈	8.0208e-1 (1.88e-2) −	8.1025e-1 (1.62e-2) ≈	8.1477e-1 (1.75e-2) ≈	8.1247e-1 (2.98e-2)
	100	2	50000	8.3298e-1 (2.14e-2) ≈	8.3319e-1 (1.51e-2) ≈	8.3451e-1 (1.36e-2) ≈	8.3486e-1 (1.48e-2) ≈	8.2847e-1 (1.99e-2)
MAP5	100	2	10000	8.1021e-1 (1.93e-2) −	7.9594e-1 (1.25e-2) −	8.0485e-1 (1.47e-2) −	8.1317e-1 (1.81e-2) ≈	8.1958e-1 (2.11e-2)
	100	2	20000	8.3798e-1 (1.71e-2) ≈	8.3201e-1 (1.58e-2) ≈	8.3401e-1 (1.75e-2) ≈	8.3693e-1 (1.60e-2) ≈	8.2938e-1 (1.75e-2)
	100	2	50000	8.4865e-1 (1.32e-2) ≈	8.5232e-1 (1.21e-2) +	8.4995e-1 (1.06e-2) ≈	8.4922e-1 (1.18e-2) ≈	8.4096e-1 (1.82e-2)
MAP6	100	2	10000	7.7868e-1 (2.51e-2) −	7.5684e-1 (2.62e-2) −	7.7616e-1 (2.50e-2) −	7.6670e-1 (2.80e-2) −	7.9535e-1 (2.60e-2)
	100	2	20000	8.0935e-1 (2.15e-2) ≈	7.9444e-1 (1.88e-2) −	8.0913e-1 (2.00e-2) ≈	8.0812e-1 (1.42e-2) ≈	7.9893e-1 (3.74e-2)
	100	2	50000	8.2762e-1 (2.29e-2) ≈	8.2674e-1 (2.04e-2) ≈	8.3295e-1 (1.64e-2) ≈	8.3460e-1 (1.58e-2) +	8.1996e-1 (2.85e-2)
MAP7	100	2	10000	7.5917e-1 (3.34e-2) −	7.3273e-1 (3.87e-2) −	7.6197e-1 (2.84e-2) −	7.6720e-1 (2.27e-2) −	7.7805e-1 (4.11e-2)
	100	2	20000	7.9060e-1 (2.01e-2) ≈	7.8209e-1 (3.09e-2) ≈	7.9346e-1 (2.51e-2) ≈	8.0757e-1 (2.01e-2) +	7.8981e-1 (3.81e-2)
	100	2	50000	8.2235e-1 (1.42e-2) ≈	8.2323e-1 (1.57e-2) ≈	8.2760e-1 (1.43e-2) +	8.2468e-1 (2.62e-2) ≈	8.1947e-1 (1.52e-2)
MAP8	100	2	10000	7.5442e-1 (3.40e-2) −	7.3741e-1 (3.78e-2) −	7.6169e-1 (2.95e-2) −	7.5175e-1 (3.94e-2) −	7.8162e-1 (4.00e-2)
	100	2	20000	7.9565e-1 (1.89e-2) ≈	7.8274e-1 (2.12e-2) ≈	7.8768e-1 (2.27e-2) ≈	7.8812e-1 (2.41e-2) ≈	7.9436e-1 (2.45e-2)
	100	2	50000	8.2292e-1 (2.37e-2) +	8.2072e-1 (2.89e-2) ≈	8.2338e-1 (1.89e-2) ≈	8.1475e-1 (2.00e-2) ≈	8.0615e-1 (3.65e-2)
MAP9	100	2	10000	7.6419e-1 (2.50e-2) −	7.2632e-1 (3.70e-2) −	7.5140e-1 (3.54e-2) −	7.4724e-1 (3.47e-2) −	7.6760e-1 (4.51e-2)
	100	2	20000	7.8086e-1 (2.80e-2) ≈	7.6825e-1 (3.43e-2) −	7.8678e-1 (1.86e-2) −	7.8929e-1 (2.01e-2) −	7.9436e-1 (4.22e-2)
	100	2	50000	8.1289e-1 (2.40e-2) ≈	8.0973e-1 (2.53e-2) ≈	8.1229e-1 (2.92e-2) ≈	8.1196e-1 (2.60e-2) ≈	8.0476e-1 (2.90e-2)
MAP10	100	2	10000	8.0803e-1 (1.29e-2) ≈	7.9170e-1 (1.64e-2) −	7.9833e-1 (1.57e-2) −	8.0274e-1 (1.43e-2) −	8.0663e-1 (2.58e-2)
	100	2	20000	8.2924e-1 (1.65e-2) ≈	8.2290e-1 (1.63e-2) ≈	8.2841e-1 (1.50e-2) ≈	8.2793e-1 (2.03e-2) ≈	8.2048e-1 (2.40e-2)
	100	2	50000	8.4597e-1 (1.37e-2) +	8.4669e-1 (1.48e-2) +	8.4555e-1 (1.44e-2) +	8.4707e-1 (1.20e-2) +	8.3524e-1 (1.59e-2)
+ / − / ≈				6/8/16	4/14/12	3/10/17	6/8/16	

Tabela A.12: Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Energia em relação ao *grid* de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAI
MAP1	100	2	10000	1.3407e+2 (4.20e+0) ≈	1.2988e+2 (3.61e+0) +	1.3407e+2 (3.31e+0) ≈	1.3533e+2 (3.67e+0) ≈	1.3550e+2 (3.37e+0)
	100	2	20000	1.3839e+2 (2.95e+0) −	1.3633e+2 (3.40e+0) ≈	1.3786e+2 (2.56e+0) ≈	1.3876e+2 (2.35e+0) −	1.3633e+2 (3.05e+0)
	100	2	50000	1.4022e+2 (2.27e+0) −	1.4079e+2 (1.94e+0) −	1.3979e+2 (2.55e+0) ≈	1.4042e+2 (1.54e+0) −	1.3863e+2 (2.60e+0)
MAP2	100	2	10000	1.2732e+2 (4.86e+0) +	1.2423e+2 (8.75e+0) +	1.2842e+2 (4.78e+0) +	1.2845e+2 (5.72e+0) +	1.3210e+2 (3.57e+0)
	100	2	20000	1.3350e+2 (3.13e+0) ≈	1.3237e+2 (4.96e+0) ≈	1.3191e+2 (4.30e+0) ≈	1.3434e+2 (3.16e+0) ≈	1.3377e+2 (3.44e+0)
	100	2	50000	1.3813e+2 (3.42e+0) ≈	1.3776e+2 (4.26e+0) ≈	1.3829e+2 (2.49e+0) ≈	1.3859e+2 (2.97e+0) −	1.3686e+2 (3.20e+0)
MAP3	100	2	10000	1.3031e+2 (4.81e+0) +	1.2608e+2 (3.35e+0) +	1.2828e+2 (3.82e+0) +	1.2991e+2 (4.63e+0) +	1.3350e+2 (3.25e+0)
	100	2	20000	1.3543e+2 (3.28e+0) ≈	1.3467e+2 (3.50e+0) ≈	1.3600e+2 (3.20e+0) ≈	1.3540e+2 (3.61e+0) ≈	1.3447e+2 (5.03e+0)
	100	2	50000	1.3873e+2 (2.81e+0) −	1.3893e+2 (2.49e+0) −	1.3893e+2 (2.26e+0) −	1.3839e+2 (2.57e+0) −	1.3716e+2 (2.77e+0)
MAP4	100	2	10000	1.2748e+2 (3.93e+0) +	1.1994e+2 (1.03e+1) +	1.2719e+2 (4.85e+0) +	1.2695e+2 (3.77e+0) +	1.3127e+2 (3.46e+0)
	100	2	20000	1.3197e+2 (4.15e+0) ≈	1.2898e+2 (7.34e+0) +	1.3201e+2 (3.47e+0) ≈	1.3241e+2 (4.22e+0) ≈	1.3357e+2 (3.82e+0)
	100	2	50000	1.3693e+2 (2.84e+0) ≈	1.3583e+2 (3.61e+0) ≈	1.3673e+2 (2.48e+0) ≈	1.3646e+2 (3.06e+0) ≈	1.3567e+2 (3.60e+0)
MAP5	100	2	10000	1.3074e+2 (5.08e+0) +	1.2795e+2 (3.59e+0) +	1.3061e+2 (4.01e+0) +	1.3161e+2 (4.58e+0) +	1.3450e+2 (3.18e+0)
	100	2	20000	1.3673e+2 (3.79e+0) ≈	1.3580e+2 (3.51e+0) ≈	1.3643e+2 (3.67e+0) ≈	1.3693e+2 (3.30e+0) ≈	1.3583e+2 (3.17e+0)
	100	2	50000	1.3929e+2 (2.47e+0) ≈	1.3996e+2 (2.21e+0) −	1.3956e+2 (1.92e+0) ≈	1.3942e+2 (2.14e+0) ≈	1.3793e+2 (3.30e+0)
MAP6	100	2	10000	1.2598e+2 (3.91e+0) +	1.1900e+2 (1.16e+1) +	1.2495e+2 (4.02e+0) +	1.2448e+2 (3.46e+0) +	1.3034e+2 (2.95e+0)
	100	2	20000	1.3171e+2 (4.02e+0) ≈	1.2825e+2 (4.00e+0) +	1.3177e+2 (4.00e+0) ≈	1.3144e+2 (3.42e+0) ≈	1.3323e+2 (3.09e+0)
	100	2	50000	1.3550e+2 (3.41e+0) ≈	1.3520e+2 (3.57e+0) ≈	1.3630e+2 (3.23e+0) ≈	1.3630e+2 (3.41e+0) ≈	1.3460e+2 (3.71e+0)
MAP7	100	2	10000	1.2405e+2 (4.56e+0) +	1.1978e+2 (7.92e+0) +	1.2402e+2 (4.98e+0) +	1.2246e+2 (5.60e+0) +	1.2933e+2 (3.48e+0)
	100	2	20000	1.2831e+2 (3.20e+0) ≈	1.2645e+2 (4.75e+0) +	1.2987e+2 (3.31e+0) ≈	1.3144e+2 (3.87e+0) ≈	1.2981e+2 (5.06e+0)
	100	2	50000	1.3387e+2 (3.31e+0) ≈	1.3397e+2 (3.67e+0) ≈	1.3530e+2 (2.92e+0) ≈	1.3520e+2 (3.77e+0) ≈	1.3404e+2 (3.75e+0)
MAP8	100	2	10000	1.2271e+2 (6.34e+0) +	1.2171e+2 (4.68e+0) +	1.2415e+2 (3.76e+0) +	1.2547e+2 (3.67e+0) +	1.3003e+2 (3.40e+0)
	100	2	20000	1.2961e+2 (3.36e+0) ≈	1.2532e+2 (4.20e+0) +	1.2884e+2 (2.80e+0) ≈	1.2665e+2 (5.72e+0) +	1.3037e+2 (3.23e+0)
	100	2	50000	1.3500e+2 (3.05e+0) ≈	1.3506e+2 (3.25e+0) ≈	1.3453e+2 (3.67e+0) ≈	1.3284e+2 (3.06e+0) ≈	1.3356e+2 (3.25e+0)
MAP9	100	2	10000	1.2213e+2 (3.92e+0) +	1.2037e+2 (5.45e+0) +	1.2351e+2 (3.60e+0) +	1.2285e+2 (4.01e+0) +	1.2880e+2 (3.61e+0)
	100	2	20000	1.2678e+2 (4.90e+0) +	1.2544e+2 (3.57e+0) +	1.2728e+2 (3.90e+0) +	1.2698e+2 (3.83e+0) +	1.3253e+2 (4.26e+0)
	100	2	50000	1.3227e+2 (3.83e+0) ≈	1.3257e+2 (3.53e+0) ≈	1.3410e+2 (2.80e+0) −	1.3330e+2 (3.47e+0) ≈	1.3234e+2 (3.20e+0)
MAP10	100	2	10000	1.3098e+2 (3.22e+0) ≈	1.2685e+2 (4.45e+0) +	1.2898e+2 (4.38e+0) +	1.3038e+2 (3.37e+0) +	1.3250e+2 (2.48e+0)
	100	2	20000	1.3557e+2 (3.45e+0) ≈	1.3367e+2 (3.64e+0) ≈	1.3557e+2 (2.91e+0) ≈	1.3470e+2 (5.10e+0) ≈	1.3460e+2 (3.72e+0)
	100	2	50000	1.3863e+2 (2.89e+0) −	1.3873e+2 (3.04e+0) −	1.3876e+2 (2.60e+0) −	1.3883e+2 (2.22e+0) −	1.3686e+2 (2.90e+0)
+ / − / ≈				9/4/17	15/4/11	10/3/17	11/4/15	

Tabela A.13: Resultados para o cálculo do *Hypervolume* para as métricas de Tolerância a Falhas e Comunicação em relação ao *grid* de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	6.6934e-1 (8.79e-3) ≈	6.6122e-1 (8.52e-3) ≈	6.6526e-1 (1.22e-2) ≈	6.7034e-1 (1.01e-2) ≈	6.5825e-1 (3.18e-2)
	100	2	20000	6.8658e-1 (8.36e-3) ≈	6.7702e-1 (9.26e-3) ≈	6.8504e-1 (9.76e-3) ≈	6.8131e-1 (1.89e-2) ≈	6.7730e-1 (2.52e-2)
	100	2	50000	7.0436e-1 (7.46e-3) +	6.9643e-1 (8.25e-3) ≈	7.0133e-1 (1.12e-2) ≈	7.0578e-1 (8.29e-3) +	6.8947e-1 (2.80e-2)
MAP2	100	2	10000	5.8855e-1 (2.57e-2) ≈	5.8151e-1 (2.68e-2) ≈	5.9557e-1 (2.55e-2) ≈	5.8274e-1 (2.59e-2) ≈	5.8465e-1 (2.65e-2)
	100	2	20000	6.1499e-1 (2.47e-2) +	6.1362e-1 (1.73e-2) +	6.1582e-1 (2.39e-2) +	6.1262e-1 (2.32e-2) ≈	5.9590e-1 (2.93e-2)
	100	2	50000	6.4219e-1 (2.21e-2) +	6.3873e-1 (2.20e-2) +	6.4134e-1 (2.48e-2) +	6.4516e-1 (1.33e-2) +	6.1000e-1 (2.69e-2)
MAP3	100	2	10000	6.2842e-1 (2.51e-2) ≈	6.1569e-1 (2.00e-2) ≈	6.2366e-1 (2.29e-2) ≈	6.2128e-1 (2.33e-2) ≈	6.1808e-1 (2.97e-2)
	100	2	20000	6.4607e-1 (1.89e-2) ≈	6.4036e-1 (1.03e-2) ≈	6.4654e-1 (1.81e-2) +	6.3260e-1 (2.59e-2) ≈	6.2518e-1 (3.15e-2)
	100	2	50000	6.6914e-1 (1.69e-2) +	6.6788e-1 (1.07e-2) +	6.6749e-1 (1.63e-2) +	6.6403e-1 (2.04e-2) +	6.3997e-1 (2.97e-2)
MAP4	100	2	10000	5.6557e-1 (2.81e-2) ≈	5.5107e-1 (2.43e-2) ≈	5.6928e-1 (2.63e-2) ≈	5.6627e-1 (2.59e-2) ≈	5.6456e-1 (1.88e-2)
	100	2	20000	5.8469e-1 (2.42e-2) ≈	5.7860e-1 (2.47e-2) ≈	5.9259e-1 (2.43e-2) ≈	5.8340e-1 (2.62e-2) ≈	5.8763e-1 (2.72e-2)
	100	2	50000	6.1360e-1 (2.89e-2) ≈	6.0844e-1 (2.48e-2) ≈	6.2010e-1 (2.74e-2) +	6.1868e-1 (2.98e-2) +	5.9644e-1 (1.79e-2)
MAP5	100	2	10000	6.4809e-1 (1.50e-2) +	6.4364e-1 (8.66e-3) +	6.4782e-1 (1.93e-2) +	6.5105e-1 (2.06e-2) +	6.2494e-1 (3.16e-2)
	100	2	20000	6.6840e-1 (1.22e-2) +	6.6004e-1 (8.01e-3) ≈	6.6525e-1 (1.70e-2) ≈	6.6675e-1 (1.20e-2) +	6.4279e-1 (3.24e-2)
	100	2	50000	6.8487e-1 (1.58e-2) +	6.8301e-1 (1.06e-2) ≈	6.8534e-1 (9.65e-3) ≈	6.8633e-1 (9.85e-3) +	6.6685e-1 (3.15e-2)
MAP6	100	2	10000	5.5097e-1 (2.14e-2) ≈	5.3706e-1 (2.11e-2) ≈	5.6124e-1 (2.47e-2) ≈	5.5269e-1 (2.14e-2) ≈	5.5737e-1 (2.47e-2)
	100	2	20000	5.7197e-1 (2.54e-2) ≈	5.6580e-1 (2.51e-2) ≈	5.7759e-1 (2.66e-2) +	5.8125e-1 (2.71e-2) +	5.6363e-1 (2.09e-2)
	100	2	50000	5.9318e-1 (2.92e-2) ≈	5.9505e-1 (2.77e-2) ≈	6.0978e-1 (2.60e-2) +	5.9256e-1 (2.83e-2) ≈	5.8398e-1 (2.09e-2)
MAP7	100	2	10000	5.2793e-1 (1.85e-2) ≈	5.1613e-1 (1.54e-2) ≈	5.3440e-1 (2.10e-2) ≈	5.3743e-1 (1.98e-2) ≈	5.3463e-1 (1.69e-2)
	100	2	20000	5.4852e-1 (2.06e-2) ≈	5.4117e-1 (2.24e-2) ≈	5.5549e-1 (2.72e-2) ≈	5.5225e-1 (2.12e-2) ≈	5.5466e-1 (1.75e-2)
	100	2	50000	5.7847e-1 (2.57e-2) +	5.7123e-1 (2.61e-2) ≈	5.8530e-1 (2.46e-2) +	5.8118e-1 (2.67e-2) +	5.6518e-1 (1.97e-2)
MAP8	100	2	10000	5.2530e-1 (1.86e-2) ≈	5.1688e-1 (2.06e-2) ≈	5.2524e-1 (1.73e-2) ≈	5.2238e-1 (1.96e-2) ≈	5.3133e-1 (1.54e-2)
	100	2	20000	5.4859e-1 (2.19e-2) ≈	5.3101e-1 (1.80e-2) ≈	5.4421e-1 (1.99e-2) ≈	5.3951e-1 (1.81e-2) ≈	5.4860e-1 (1.85e-2)
	100	2	50000	5.7022e-1 (2.48e-2) ≈	5.6126e-1 (1.96e-2) ≈	5.7801e-1 (2.70e-2) +	5.6581e-1 (2.49e-2) ≈	5.6265e-1 (2.28e-2)
MAP9	100	2	10000	5.0528e-1 (9.14e-3) ≈	4.9757e-1 (1.30e-2) ≈	5.1235e-1 (1.36e-2) ≈	5.0687e-1 (1.13e-2) ≈	5.2020e-1 (1.38e-2)
	100	2	20000	5.3434e-1 (2.48e-2) ≈	5.2277e-1 (1.99e-2) ≈	5.2876e-1 (1.82e-2) ≈	5.3354e-1 (1.97e-2) ≈	5.3160e-1 (1.84e-2)
	100	2	50000	5.5894e-1 (2.44e-2) ≈	5.4442e-1 (1.91e-2) ≈	5.5433e-1 (2.05e-2) ≈	5.4964e-1 (1.64e-2) ≈	5.5115e-1 (1.48e-2)
MAP10	100	2	10000	6.2364e-1 (2.21e-2) ≈	6.1577e-1 (2.24e-2) ≈	6.2856e-1 (2.17e-2) ≈	6.2365e-1 (2.63e-2) ≈	6.1616e-1 (3.06e-2)
	100	2	20000	6.4342e-1 (2.09e-2) +	6.3554e-1 (1.73e-2) +	6.3460e-1 (2.46e-2) +	6.4323e-1 (1.93e-2) +	6.1608e-1 (2.57e-2)
	100	2	50000	6.6472e-1 (2.29e-2) +	6.6294e-1 (1.73e-2) +	6.6214e-1 (2.25e-2) +	6.6447e-1 (2.78e-2) +	6.3619e-1 (2.94e-2)
+/-/≈				11/3/16	6/9/15	12/1/17	11/3/16	

Tabela A.14: Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Comunicação em relação ao *grid* de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	1.1909e+3 (5.11e+1) +	1.1627e+3 (3.91e+1) +	1.2014e+3 (3.47e+1) +	1.1887e+3 (5.07e+1) +	1.2795e+3 (4.53e+1)
	100	2	20000	1.2385e+3 (2.98e+1) +	1.2173e+3 (3.98e+1) +	1.2371e+3 (3.64e+1) +	1.2384e+3 (4.63e+1) +	1.2866e+3 (5.42e+1)
	100	2	50000	1.2817e+3 (4.60e+1) +	1.2688e+3 (2.34e+1) +	1.3003e+3 (3.72e+1) ≈	1.2968e+3 (3.34e+1) ≈	1.3064e+3 (4.40e+1)
MAP2	100	2	10000	1.0802e+3 (1.07e+2) +	1.0094e+3 (1.19e+2) +	1.0674e+3 (1.05e+2) +	1.0879e+3 (9.21e+1) +	1.1655e+3 (5.40e+1)
	100	2	20000	1.1024e+3 (9.17e+1) +	1.0235e+3 (8.24e+1) +	1.1011e+3 (9.29e+1) +	1.0928e+3 (8.88e+1) +	1.1792e+3 (6.06e+1)
	100	2	50000	1.1456e+3 (5.87e+1) +	1.1192e+3 (7.30e+1) +	1.1790e+3 (6.65e+1) +	1.1214e+3 (5.91e+1) +	1.2295e+3 (5.00e+1)
MAP3	100	2	10000	1.1141e+3 (6.87e+1) +	1.0369e+3 (1.10e+2) +	1.1130e+3 (7.35e+1) +	1.1192e+3 (9.80e+1) +	1.2068e+3 (6.12e+1)
	100	2	20000	1.1409e+3 (6.91e+1) +	1.0907e+3 (5.91e+1) +	1.1485e+3 (5.19e+1) +	1.1731e+3 (7.61e+1) +	1.2437e+3 (4.60e+1)
	100	2	50000	1.2018e+3 (4.90e+1) +	1.1761e+3 (4.30e+1) +	1.2195e+3 (5.53e+1) +	1.2006e+3 (5.39e+1) +	1.2669e+3 (5.10e+1)
MAP4	100	2	10000	1.0602e+3 (8.69e+1) +	1.0420e+3 (1.00e+2) +	1.0710e+3 (8.20e+1) +	1.0672e+3 (1.06e+2) +	1.1512e+3 (6.31e+1)
	100	2	20000	1.1231e+3 (9.46e+1) ≈	1.0498e+3 (1.25e+2) +	1.1059e+3 (8.34e+1) +	1.1261e+3 (8.49e+1) ≈	1.1520e+3 (6.43e+1)
	100	2	50000	1.1638e+3 (7.53e+1) +	1.1150e+3 (9.33e+1) +	1.1538e+3 (8.06e+1) +	1.1577e+3 (1.02e+2) +	1.2301e+3 (5.39e+1)
MAP5	100	2	10000	1.1180e+3 (6.04e+1) +	1.1053e+3 (4.54e+1) +	1.1511e+3 (5.22e+1) +	1.1555e+3 (9.95e+1) +	1.2432e+3 (5.11e+1)
	100	2	20000	1.1903e+3 (6.05e+1) +	1.1642e+3 (5.45e+1) +	1.1856e+3 (4.70e+1) +	1.1920e+3 (4.42e+1) +	1.2759e+3 (4.48e+1)
	100	2	50000	1.2519e+3 (4.59e+1) +	1.2344e+3 (4.60e+1) +	1.2448e+3 (4.40e+1) +	1.2446e+3 (4.07e+1) +	1.2801e+3 (5.15e+1)
MAP6	100	2	10000	1.0753e+3 (7.11e+1) +	1.0349e+3 (9.09e+1) +	1.0312e+3 (1.06e+2) +	1.0544e+3 (1.10e+2) +	1.1358e+3 (3.29e+1)
	100	2	20000	1.1006e+3 (7.64e+1) +	1.0384e+3 (1.05e+2) +	1.0716e+3 (1.03e+2) +	1.0889e+3 (1.03e+2) ≈	1.1359e+3 (6.45e+1)
	100	2	50000	1.1465e+3 (7.57e+1) +	1.0993e+3 (8.92e+1) +	1.1333e+3 (7.60e+1) +	1.1555e+3 (7.50e+1) +	1.2007e+3 (3.94e+1)
MAP7	100	2	10000	1.0429e+3 (7.34e+1) +	1.0156e+3 (4.98e+1) +	1.0411e+3 (8.29e+1) +	1.0296e+3 (9.26e+1) +	1.0806e+3 (4.73e+1)
	100	2	20000	1.0715e+3 (8.95e+1) +	1.0397e+3 (8.32e+1) +	1.0614e+3 (8.76e+1) +	1.0602e+3 (1.04e+2) +	1.1368e+3 (4.44e+1)
	100	2	50000	1.1198e+3 (7.79e+1) ≈	1.0763e+3 (8.58e+1) +	1.1099e+3 (9.00e+1) ≈	1.1112e+3 (9.24e+1) ≈	1.1522e+3 (5.24e+1)
MAP8	100	2	10000	1.0055e+3 (9.99e+1) +	9.5390e+2 (1.22e+2) +	1.0027e+3 (9.72e+1) +	1.0199e+3 (6.29e+1) +	1.0739e+3 (5.13e+1)
	100	2	20000	1.0389e+3 (1.12e+2) +	1.0296e+3 (9.86e+1) +	1.0634e+3 (9.06e+1) +	1.0694e+3 (7.13e+1) +	1.1078e+3 (7.69e+1)
	100	2	50000	1.1237e+3 (6.22e+1) ≈	1.0947e+3 (8.90e+1) +	1.0943e+3 (7.61e+1) +	1.1067e+3 (8.31e+1) ≈	1.1408e+3 (4.43e+1)
MAP9	100	2	10000	1.0114e+3 (2.75e+1) +	9.6569e+2 (5.65e+1) +	1.0235e+3 (4.99e+1) +	1.0142e+3 (4.39e+1) +	1.0588e+3 (3.88e+1)
	100	2	20000	1.0309e+3 (7.98e+1) +	9.8375e+2 (1.20e+2) +	1.0364e+3 (7.94e+1) +	1.0318e+3 (1.10e+2) +	1.0844e+3 (5.75e+1)
	100	2	50000	1.0857e+3 (7.95e+1) +	1.0598e+3 (9.42e+1) +	1.0981e+3 (6.80e+1) +	1.1009e+3 (7.53e+1) +	1.1365e+3 (3.96e+1)
MAP10	100	2	10000	1.1088e+3 (7.22e+1) +	1.0390e+3 (1.31e+2) +	1.0980e+3 (1.01e+2) +	1.1067e+3 (8.96e+1) +	1.2047e+3 (6.18e+1)
	100	2	20000	1.1550e+3 (7.82e+1) +	1.1152e+3 (5.64e+1) +	1.1681e+3 (6.72e+1) +	1.1409e+3 (8.07e+1) +	1.2315e+3 (9.46e+1)
	100	2	50000	1.2100e+3 (5.68e+1) +	1.1644e+3 (5.47e+1) +	1.2049e+3 (5.46e+1) +	1.2198e+3 (6.97e+1) +	1.2740e+3 (4.79e+1)
+/-/≈				27/0/3	30/0/0	28/0/2	25/0/5	

Tabela A.15: Resultados para o cálculo do *Hypervolume* para as métricas de Comunicação e Energia em relação ao *grid* de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAI
MAP1	100	2	10000	6.5859e-1 (9.16e-3) -	6.5135e-1 (7.46e-3) -	6.6813e-1 (1.02e-2) ≈	6.6056e-1 (8.14e-3) -	6.6954e-1 (1.42e-2)
	100	2	20000	6.8388e-1 (1.13e-2) -	6.7877e-1 (8.25e-3) -	6.8811e-1 (9.41e-3) ≈	6.8405e-1 (9.55e-3) -	6.9436e-1 (1.37e-2)
	100	2	50000	7.1006e-1 (1.14e-2) -	7.0279e-1 (9.32e-3) -	7.1685e-1 (8.68e-3) ≈	7.1030e-1 (8.82e-3) -	7.1795e-1 (1.20e-2)
MAP2	100	2	10000	5.9470e-1 (8.48e-3) -	5.8809e-1 (8.13e-3) -	6.0188e-1 (7.83e-3) -	5.9491e-1 (8.01e-3) -	6.0894e-1 (8.69e-3)
	100	2	20000	6.2086e-1 (7.84e-3) ≈	6.1200e-1 (7.50e-3) -	6.2676e-1 (9.34e-3) ≈	6.1966e-1 (8.22e-3) -	6.2486e-1 (8.57e-3)
	100	2	50000	6.4735e-1 (1.23e-2) ≈	6.3670e-1 (7.43e-3) -	6.5448e-1 (9.85e-3) ≈	6.4856e-1 (8.01e-3) ≈	6.5323e-1 (1.18e-2)
MAP3	100	2	10000	6.2137e-1 (9.64e-3) -	6.1306e-1 (9.29e-3) -	6.2714e-1 (9.07e-3) -	6.2258e-1 (8.30e-3) -	6.3384e-1 (1.13e-2)
	100	2	20000	6.4582e-1 (1.14e-2) -	6.3436e-1 (7.57e-3) -	6.4910e-1 (1.16e-2) ≈	6.4310e-1 (7.49e-3) -	6.5413e-1 (9.54e-3)
	100	2	50000	6.7134e-1 (8.89e-3) ≈	6.6218e-1 (1.04e-2) -	6.7653e-1 (8.84e-3) ≈	6.7002e-1 (7.89e-3) ≈	6.7473e-1 (1.14e-2)
MAP4	100	2	10000	5.8244e-1 (1.03e-2) -	5.7216e-1 (5.92e-3) -	5.9024e-1 (7.42e-3) -	5.8333e-1 (7.93e-3) -	5.8885e-1 (1.04e-2)
	100	2	20000	6.0554e-1 (9.43e-3) -	5.9684e-1 (7.09e-3) -	6.1357e-1 (1.21e-2) ≈	6.0470e-1 (9.84e-3) -	6.1470e-1 (8.95e-3)
	100	2	50000	6.3287e-1 (8.42e-3) ≈	6.2362e-1 (9.17e-3) -	6.3904e-1 (8.76e-3) ≈	6.2958e-1 (9.51e-3) -	6.3461e-1 (9.11e-3)
MAP5	100	2	10000	6.4203e-1 (8.72e-3) -	6.2949e-1 (7.90e-3) -	6.4701e-1 (9.62e-3) ≈	6.4106e-1 (9.10e-3) -	6.5318e-1 (1.32e-2)
	100	2	20000	6.6355e-1 (9.55e-3) -	6.5184e-1 (8.22e-3) -	6.7427e-1 (8.94e-3) ≈	6.6098e-1 (7.18e-3) -	6.7569e-1 (1.31e-2)
	100	2	50000	6.9227e-1 (1.01e-2) ≈	6.8575e-1 (8.99e-3) -	6.9875e-1 (1.03e-2) ≈	6.9055e-1 (8.95e-3) ≈	6.9689e-1 (1.43e-2)
MAP6	100	2	10000	5.7660e-1 (8.69e-3) -	5.6512e-1 (7.84e-3) -	5.7967e-1 (7.49e-3) ≈	5.7636e-1 (6.34e-3) -	5.8123e-1 (9.70e-3)
	100	2	20000	5.9596e-1 (8.46e-3) -	5.8773e-1 (7.17e-3) -	6.0291e-1 (8.48e-3) ≈	5.9557e-1 (8.60e-3) -	6.0199e-1 (1.27e-2)
	100	2	50000	6.2316e-1 (1.01e-2) ≈	6.1793e-1 (9.87e-3) -	6.2658e-1 (9.92e-3) ≈	6.1887e-1 (9.64e-3) -	6.2524e-1 (1.13e-2)
MAP7	100	2	10000	5.5568e-1 (1.01e-2) -	5.4684e-1 (9.78e-3) -	5.5982e-1 (8.79e-3) -	5.5680e-1 (7.08e-3) -	5.6541e-1 (9.42e-3)
	100	2	20000	5.8033e-1 (7.77e-3) ≈	5.7109e-1 (1.04e-2) -	5.8579e-1 (8.88e-3) ≈	5.7665e-1 (7.94e-3) -	5.8179e-1 (1.41e-2)
	100	2	50000	6.0968e-1 (1.03e-2) ≈	5.9889e-1 (9.58e-3) ≈	6.1098e-1 (1.02e-2) +	6.0281e-1 (1.15e-2) ≈	6.0550e-1 (1.31e-2)
MAP8	100	2	10000	5.4960e-1 (7.82e-3) -	5.4074e-1 (6.93e-3) -	5.5341e-1 (8.01e-3) -	5.5053e-1 (8.05e-3) -	5.5644e-1 (1.28e-2)
	100	2	20000	5.7501e-1 (8.40e-3) ≈	5.6199e-1 (9.59e-3) -	5.7771e-1 (7.12e-3) ≈	5.7129e-1 (9.15e-3) -	5.7644e-1 (7.32e-3)
	100	2	50000	5.9917e-1 (1.05e-2) ≈	5.9061e-1 (1.03e-2) -	6.0086e-1 (9.71e-3) ≈	5.9494e-1 (8.57e-3) -	6.0397e-1 (1.15e-2)
MAP9	100	2	10000	5.3533e-1 (8.48e-3) -	5.3036e-1 (6.75e-3) -	5.4437e-1 (8.84e-3) ≈	5.3497e-1 (7.81e-3) -	5.4639e-1 (1.03e-2)
	100	2	20000	5.5859e-1 (7.10e-3) -	5.4995e-1 (8.03e-3) -	5.6323e-1 (8.52e-3) ≈	5.5742e-1 (9.74e-3) -	5.6412e-1 (1.01e-2)
	100	2	50000	5.8556e-1 (7.50e-3) ≈	5.7671e-1 (8.69e-3) -	5.9179e-1 (1.17e-2) +	5.8415e-1 (1.09e-2) ≈	5.8529e-1 (8.10e-3)
MAP10	100	2	10000	6.2284e-1 (7.77e-3) -	6.1172e-1 (9.73e-3) -	6.2690e-1 (1.08e-2) ≈	6.2489e-1 (8.39e-3) -	6.3151e-1 (9.44e-3)
	100	2	20000	6.4751e-1 (1.19e-2) -	6.3514e-1 (8.81e-3) -	6.5093e-1 (1.13e-2) ≈	6.4008e-1 (8.79e-3) -	6.5426e-1 (1.30e-2)
	100	2	50000	6.7418e-1 (1.13e-2) ≈	6.6453e-1 (8.47e-3) -	6.7632e-1 (8.22e-3) ≈	6.6805e-1 (7.91e-3) -	6.7886e-1 (1.06e-2)
				+/-/≈	0/18/12	0/29/1	2/3/25	0/25/5

Tabela A.16: Resultados para o cálculo do IGD para as métricas de Comunicação e Energia em relação ao *grid* de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAI
MAP1	100	2	10000	1.2023e+3 (1.99e+2) +	1.1583e+3 (2.05e+2) +	1.1610e+3 (1.87e+2) +	1.1387e+3 (2.10e+2) +	1.3416e+3 (1.51e+2)
	100	2	20000	1.2822e+3 (1.75e+2) +	1.1385e+3 (1.92e+2) +	1.2045e+3 (2.07e+2) +	1.3372e+3 (1.40e+2) +	1.4549e+3 (1.53e+2)
	100	2	50000	1.3798e+3 (1.51e+2) +	1.3487e+3 (1.89e+2) +	1.2927e+3 (1.55e+2) +	1.4084e+3 (1.30e+2) +	1.5467e+3 (1.29e+2)
MAP2	100	2	10000	1.0292e+3 (1.64e+2) +	1.0012e+3 (2.31e+2) +	9.3612e+2 (1.75e+2) +	9.9053e+2 (2.05e+2) +	1.1508e+3 (1.43e+2)
	100	2	20000	1.0452e+3 (1.92e+2) +	1.0091e+3 (2.07e+2) +	9.4370e+2 (1.87e+2) +	1.0886e+3 (1.78e+2) +	1.2371e+3 (1.52e+2)
	100	2	50000	1.0652e+3 (2.56e+2) +	1.1303e+3 (2.16e+2) +	1.0593e+3 (1.31e+2) +	1.1707e+3 (1.59e+2) +	1.3744e+3 (1.31e+2)
MAP3	100	2	10000	1.1137e+3 (1.39e+2) +	1.0474e+3 (1.81e+2) +	9.6520e+2 (1.93e+2) +	1.0681e+3 (1.68e+2) +	1.2575e+3 (2.12e+2)
	100	2	20000	1.1462e+3 (1.64e+2) +	1.0520e+3 (1.88e+2) +	1.0820e+3 (1.78e+2) +	1.1567e+3 (1.67e+2) +	1.3779e+3 (1.32e+2)
	100	2	50000	1.2548e+3 (1.37e+2) +	1.2114e+3 (1.85e+2) +	1.1321e+3 (2.01e+2) +	1.2492e+3 (1.00e+2) +	1.4291e+3 (1.43e+2)
MAP4	100	2	10000	9.2784e+2 (1.26e+2) +	9.1421e+2 (1.84e+2) +	8.2529e+2 (1.72e+2) +	1.0515e+3 (1.66e+2) +	1.1573e+3 (1.38e+2)
	100	2	20000	1.0265e+3 (1.77e+2) +	9.5597e+2 (1.88e+2) +	8.8604e+2 (2.75e+2) +	1.0448e+3 (1.50e+2) +	1.2272e+3 (1.54e+2)
	100	2	50000	1.1453e+3 (1.85e+2) +	1.0644e+3 (2.15e+2) +	1.0249e+3 (2.13e+2) +	1.1045e+3 (1.99e+2) +	1.2824e+3 (1.52e+2)
MAP5	100	2	10000	1.1484e+3 (1.72e+2) +	1.1331e+3 (1.52e+2) +	1.0494e+3 (1.68e+2) +	1.1999e+3 (1.89e+2) +	1.3278e+3 (1.04e+2)
	100	2	20000	1.2224e+3 (1.79e+2) +	1.1108e+3 (2.08e+2) +	1.1199e+3 (1.81e+2) +	1.2582e+3 (1.58e+2) +	1.4290e+3 (1.64e+2)
	100	2	50000	1.3012e+3 (1.85e+2) +	1.2576e+3 (1.36e+2) +	1.2076e+3 (1.63e+2) +	1.3713e+3 (1.42e+2) +	1.5456e+3 (1.22e+2)
MAP6	100	2	10000	9.0515e+2 (2.08e+2) +	8.4438e+2 (2.13e+2) +	8.1371e+2 (2.34e+2) +	9.9859e+2 (1.34e+2) +	1.1042e+3 (1.64e+2)
	100	2	20000	1.0129e+3 (1.41e+2) +	9.0435e+2 (1.93e+2) +	9.0314e+2 (1.99e+2) +	9.5912e+2 (1.68e+2) +	1.2247e+3 (1.62e+2)
	100	2	50000	1.0867e+3 (1.28e+2) +	1.0196e+3 (1.96e+2) +	9.1266e+2 (2.47e+2) +	1.1142e+3 (1.52e+2) +	1.2489e+3 (1.43e+2)
MAP7	100	2	10000	9.0928e+2 (1.42e+2) +	8.5885e+2 (1.82e+2) +	7.7490e+2 (2.39e+2) +	9.1964e+2 (1.55e+2) +	1.1195e+3 (1.36e+2)
	100	2	20000	9.2661e+2 (1.76e+2) +	8.6168e+2 (2.35e+2) +	8.1570e+2 (1.88e+2) +	9.7200e+2 (1.68e+2) +	1.1371e+3 (1.45e+2)
	100	2	50000	9.8890e+2 (1.98e+2) +	9.5026e+2 (2.04e+2) +	9.5000e+2 (2.03e+2) +	1.0898e+3 (1.64e+2) +	1.2134e+3 (1.32e+2)
MAP8	100	2	10000	8.5430e+2 (1.73e+2) +	7.8829e+2 (2.09e+2) +	7.5396e+2 (2.34e+2) +	8.7002e+2 (1.69e+2) +	1.0247e+3 (1.67e+2)
	100	2	20000	8.9241e+2 (1.78e+2) +	8.1115e+2 (2.49e+2) +	7.6539e+2 (2.45e+2) +	9.0489e+2 (1.76e+2) +	1.0727e+3 (1.47e+2)
	100	2	50000	1.0185e+3 (1.85e+2) +	9.1749e+2 (2.04e+2) +	8.9597e+2 (1.91e+2) +	1.0141e+3 (2.02e+2) +	1.2134e+3 (1.32e+2)
MAP9	100	2	10000	7.6605e+2 (1.97e+2) +	7.7163e+2 (1.24e+2) +	6.2608e+2 (2.55e+2) +	8.3208e+2 (1.94e+2) +	1.0285e+3 (1.33e+2)
	100	2	20000	8.7260e+2 (2.16e+2) +	8.4290e+2 (1.95e+2) +	7.3768e+2 (2.18e+2) +	8.8470e+2 (1.94e+2) +	1.0307e+3 (1.82e+2)
	100	2	50000	9.5717e+2 (1.38e+2) +	9.0636e+2 (1.61e+2) +	7.5698e+2 (2.35e+2) +	9.7148e+2 (1.82e+2) +	1.1470e+3 (1.31e+2)
MAP10	100	2	10000	1.0328e+3 (2.08e+2) +	1.0397e+3 (1.40e+2) +	9.7709e+2 (2.11e+2) +	1.1010e+3 (1.31e+2) +	1.2178e+3 (1.56e+2)
	100	2	20000	1.1546e+3 (1.77e+2) +	1.0356e+3 (1.44e+2) +	1.0452e+3 (1.54e+2) +	1.1877e+3 (1.34e+2) +	1.3630e+3 (1.73e+2)
	100	2	50000	1.2576e+3 (1.59e+2) +	1.1794e+3 (1.37e+2) +	1.0934e+3 (2.17e+2) +	1.2879e+3 (1.27e+2) +	1.4255e+3 (1.41e+2)
				+/-/≈	30/0/0	30/0/0	30/0/0	30/0/0

Tabela A.17: Resultados para o cálculo do Hypervolume para as métricas de Energia e Balanceamento de Carga em relação ao grid de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	N	M	FE	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	5.9987e-1 (6.34e-3) +	5.9623e-1 (5.71e-3) ≈	6.0109e-1 (4.99e-3) +	5.9744e-1 (5.81e-3) ≈	5.9343e-1 (8.03e-3)
	100	2	20000	6.0693e-1 (5.09e-3) ≈	6.0564e-1 (5.43e-3) ≈	6.1071e-1 (5.78e-3) +	6.0647e-1 (4.90e-3) ≈	6.0459e-1 (7.04e-3)
	100	2	50000	6.1876e-1 (5.71e-3) +	6.1486e-1 (4.85e-3) +	6.1819e-1 (6.21e-3) +	6.1588e-1 (6.94e-3) +	6.1102e-1 (9.00e-3)
MAP2	100	2	10000	5.7490e-1 (5.12e-3) +	5.7125e-1 (5.15e-3) ≈	5.7167e-1 (5.35e-3) ≈	5.7250e-1 (6.91e-3) ≈	5.6825e-1 (8.58e-3)
	100	2	20000	5.8260e-1 (5.65e-3) +	5.7911e-1 (6.22e-3) ≈	5.8242e-1 (5.56e-3) +	5.7901e-1 (5.23e-3) +	5.7551e-1 (8.74e-3)
	100	2	50000	5.9211e-1 (6.71e-3) +	5.8937e-1 (5.54e-3) +	5.9029e-1 (5.67e-3) +	5.8962e-1 (8.57e-3) +	5.8450e-1 (7.45e-3)
MAP3	100	2	10000	5.7978e-1 (5.85e-3) +	5.7678e-1 (5.16e-3) +	5.8153e-1 (4.74e-3) +	5.8089e-1 (6.93e-3) +	5.7112e-1 (1.25e-2)
	100	2	20000	5.9141e-1 (5.70e-3) +	5.8656e-1 (5.10e-3) +	5.8881e-1 (6.49e-3) +	5.8620e-1 (6.98e-3) ≈	5.8270e-1 (7.44e-3)
	100	2	50000	5.9827e-1 (6.31e-3) +	5.9655e-1 (4.93e-3) +	6.0164e-1 (7.19e-3) +	5.9715e-1 (6.30e-3) +	5.8898e-1 (8.17e-3)
MAP4	100	2	10000	5.6174e-1 (6.20e-3) +	5.5910e-1 (4.76e-3) +	5.6113e-1 (5.76e-3) +	5.6211e-1 (5.95e-3) +	5.5466e-1 (9.82e-3)
	100	2	20000	5.7095e-1 (5.21e-3) +	5.7115e-1 (5.70e-3) +	5.6917e-1 (6.45e-3) +	5.7113e-1 (5.05e-3) +	5.6295e-1 (7.86e-3)
	100	2	50000	5.8147e-1 (5.67e-3) +	5.7789e-1 (4.45e-3) +	5.7957e-1 (5.30e-3) +	5.7923e-1 (8.37e-3) +	5.7124e-1 (6.90e-3)
MAP5	100	2	10000	5.5335e-1 (6.10e-3) +	5.5138e-1 (6.64e-3) ≈	5.5312e-1 (5.28e-3) +	5.5477e-1 (6.46e-3) +	5.4914e-1 (8.02e-3)
	100	2	20000	5.6302e-1 (4.98e-3) +	5.6224e-1 (5.23e-3) +	5.6317e-1 (5.33e-3) +	5.6218e-1 (5.69e-3) +	5.5678e-1 (8.16e-3)
	100	2	50000	5.7542e-1 (7.59e-3) +	5.7332e-1 (6.03e-3) +	5.7313e-1 (6.16e-3) +	5.7014e-1 (6.58e-3) +	5.6590e-1 (6.25e-3)
MAP6	100	2	10000	5.5702e-1 (7.41e-3) +	5.5225e-1 (5.43e-3) +	5.5624e-1 (4.52e-3) +	5.5519e-1 (7.38e-3) +	5.4671e-1 (1.36e-2)
	100	2	20000	5.6245e-1 (5.95e-3) +	5.6004e-1 (5.94e-3) ≈	5.6543e-1 (6.18e-3) +	5.6062e-1 (4.66e-3) ≈	5.5769e-1 (6.80e-3)
	100	2	50000	5.7495e-1 (6.63e-3) +	5.7457e-1 (6.43e-3) +	5.7365e-1 (6.58e-3) +	5.7307e-1 (7.52e-3) +	5.6640e-1 (8.72e-3)
MAP7	100	2	10000	5.4767e-1 (6.53e-3) +	5.4284e-1 (4.89e-3) +	5.4797e-1 (5.32e-3) +	5.4478e-1 (6.42e-3) +	5.3819e-1 (8.29e-3)
	100	2	20000	5.5367e-1 (5.42e-3) +	5.5493e-1 (5.79e-3) +	5.5488e-1 (5.99e-3) +	5.5702e-1 (6.23e-3) +	5.4679e-1 (7.71e-3)
	100	2	50000	5.6518e-1 (5.49e-3) +	5.6289e-1 (6.44e-3) +	5.6808e-1 (5.95e-3) +	5.6237e-1 (5.88e-3) +	5.5738e-1 (8.49e-3)
MAP8	100	2	10000	5.4346e-1 (5.73e-3) +	5.3971e-1 (5.61e-3) +	5.4153e-1 (5.96e-3) +	5.4188e-1 (6.35e-3) +	5.3496e-1 (9.97e-3)
	100	2	20000	5.5256e-1 (6.11e-3) +	5.4896e-1 (5.09e-3) +	5.5184e-1 (5.08e-3) +	5.5163e-1 (5.52e-3) +	5.4422e-1 (6.71e-3)
	100	2	50000	5.6118e-1 (7.36e-3) +	5.6123e-1 (6.33e-3) +	5.6139e-1 (4.59e-3) +	5.5873e-1 (6.76e-3) +	5.5260e-1 (8.03e-3)
MAP9	100	2	10000	5.3224e-1 (6.22e-3) +	5.2899e-1 (5.40e-3) +	5.2949e-1 (6.88e-3) +	5.3050e-1 (6.28e-3) +	5.2235e-1 (9.67e-3)
	100	2	20000	5.4146e-1 (5.62e-3) +	5.3945e-1 (5.23e-3) +	5.4245e-1 (6.25e-3) +	5.4009e-1 (4.86e-3) +	5.3393e-1 (7.31e-3)
	100	2	50000	5.5293e-1 (7.06e-3) +	5.5058e-1 (7.03e-3) +	5.4985e-1 (6.05e-3) +	5.4939e-1 (6.43e-3) +	5.4341e-1 (9.34e-3)
MAP10	100	2	10000	5.4609e-1 (5.96e-3) +	5.4494e-1 (5.45e-3) +	5.4748e-1 (5.73e-3) +	5.4582e-1 (7.11e-3) +	5.3930e-1 (9.67e-3)
	100	2	20000	5.5543e-1 (5.55e-3) +	5.5331e-1 (5.35e-3) +	5.5413e-1 (5.99e-3) +	5.5420e-1 (6.97e-3) +	5.4984e-1 (9.09e-3)
	100	2	50000	5.6645e-1 (5.95e-3) +	5.6291e-1 (5.65e-3) +	5.6414e-1 (6.12e-3) +	5.6293e-1 (6.79e-3) +	5.5663e-1 (6.47e-3)
+/-/≈				29/0/1	24/0/6	29/0/1	25/0/5	

Tabela A.18: Resultados para o cálculo do IGD para as métricas de Energia e Balanceamento de Carga em relação ao grid de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	N	M	FE	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	1.0716e+2 (9.12e+0) ≈	1.0499e+2 (9.18e+0) ≈	1.0439e+2 (8.05e+0) +	1.0796e+2 (8.42e+0) ≈	1.1042e+2 (1.10e+1)
	100	2	20000	1.1016e+2 (8.55e+0) ≈	1.0799e+2 (7.21e+0) ≈	1.0832e+2 (8.13e+0) ≈	1.0726e+2 (9.67e+0) +	1.1226e+2 (9.32e+0)
	100	2	50000	1.1092e+2 (8.44e+0) ≈	1.1032e+2 (6.58e+0) +	1.1119e+2 (8.50e+0) ≈	1.1269e+2 (1.16e+1) +	1.1322e+2 (1.07e+1)
MAP2	100	2	10000	1.0029e+2 (8.95e+0) ≈	9.7858e+1 (7.98e+0) +	9.9625e+1 (6.61e+0) +	1.0212e+2 (8.94e+0) ≈	1.0462e+2 (9.21e+0)
	100	2	20000	1.0072e+2 (6.89e+0) +	1.0202e+2 (8.16e+0) +	9.9292e+1 (7.86e+0) +	1.0192e+2 (8.11e+0) +	1.0599e+2 (8.88e+0)
	100	2	50000	1.0246e+2 (8.01e+0) ≈	1.0362e+2 (8.84e+0) +	1.0422e+2 (9.62e+0) +	1.0299e+2 (9.22e+0) ≈	1.0639e+2 (8.66e+0)
MAP3	100	2	10000	1.0352e+2 (8.11e+0) ≈	1.0169e+2 (7.04e+0) ≈	1.0016e+2 (8.71e+0) +	1.0172e+2 (7.87e+0) +	1.0642e+2 (8.01e+0)
	100	2	20000	1.0172e+2 (9.14e+0) ≈	1.0412e+2 (4.21e+0) ≈	1.0346e+2 (7.24e+0) ≈	1.0309e+2 (7.06e+0) ≈	1.0349e+2 (9.47e+0)
	100	2	50000	1.0496e+2 (8.31e+0) +	1.0292e+2 (6.41e+0) +	1.0519e+2 (8.55e+0) +	1.0479e+2 (9.68e+0) +	1.1089e+2 (1.07e+1)
MAP4	100	2	10000	9.6792e+1 (8.56e+0) +	9.6425e+1 (8.64e+0) +	9.8758e+1 (7.76e+0) +	9.9258e+1 (7.89e+0) ≈	1.0382e+2 (8.09e+0)
	100	2	20000	1.0059e+2 (7.59e+0) ≈	9.8625e+1 (8.37e+0) ≈	9.8725e+1 (7.59e+0) +	9.8825e+1 (9.46e+0) ≈	1.0372e+2 (8.42e+0)
	100	2	50000	1.0056e+2 (7.60e+0) ≈	9.9358e+1 (7.94e+0) +	9.9658e+1 (8.14e+0) +	1.0426e+2 (9.06e+0) ≈	1.0362e+2 (6.74e+0)
MAP5	100	2	10000	9.7491e+1 (6.54e+0) +	9.5392e+1 (6.56e+0) +	9.6391e+1 (7.06e+0) +	9.7725e+1 (6.69e+0) ≈	9.9857e+1 (6.42e+0)
	100	2	20000	9.9157e+1 (7.83e+0) ≈	9.8191e+1 (7.30e+0) ≈	9.7025e+1 (6.34e+0) ≈	1.0116e+2 (9.18e+0) ≈	9.7591e+1 (5.80e+0)
	100	2	50000	9.8492e+1 (8.35e+0) +	9.7658e+1 (7.70e+0) +	9.8525e+1 (6.83e+0) +	1.0202e+2 (8.12e+0) +	1.0306e+2 (8.35e+0)
MAP6	100	2	10000	9.8758e+1 (7.84e+0) ≈	9.7924e+1 (6.72e+0) +	9.8891e+1 (8.17e+0) +	9.7791e+1 (8.18e+0) +	1.0256e+2 (5.79e+0)
	100	2	20000	9.9691e+1 (6.79e+0) ≈	9.9790e+1 (8.42e+0) ≈	9.6192e+1 (9.97e+0) ≈	9.6958e+1 (7.57e+0) ≈	9.9357e+1 (6.38e+0)
	100	2	50000	1.0222e+2 (8.29e+0) ≈	9.9358e+1 (6.79e+0) ≈	9.8792e+1 (8.23e+0) +	1.0392e+2 (1.09e+1) +	1.0306e+2 (8.82e+0)
MAP7	100	2	10000	9.6291e+1 (7.02e+0) +	9.4792e+1 (6.01e+0) +	9.5758e+1 (7.49e+0) +	9.7158e+1 (6.10e+0) +	1.0216e+2 (8.28e+0)
	100	2	20000	9.8157e+1 (6.79e+0) ≈	9.5558e+1 (7.19e+0) ≈	9.6092e+1 (7.53e+0) ≈	9.5892e+1 (8.02e+0) ≈	9.7991e+1 (7.16e+0)
	100	2	50000	9.6925e+1 (6.41e+0) ≈	9.7924e+1 (8.44e+0) +	9.9791e+1 (6.45e+0) +	1.0136e+2 (8.25e+0) ≈	9.9457e+1 (6.84e+0)
MAP8	100	2	10000	9.4258e+1 (5.18e+0) +	9.4125e+1 (6.59e+0) +	9.5158e+1 (7.54e+0) ≈	9.9090e+1 (5.96e+0) ≈	9.8524e+1 (8.03e+0)
	100	2	20000	9.8991e+1 (7.43e+0) ≈	9.3592e+1 (7.20e+0) +	9.2026e+1 (5.62e+0) +	9.5558e+1 (6.03e+0) +	9.9757e+1 (6.16e+0)
	100	2	50000	9.8591e+1 (7.57e+0) +	9.9191e+1 (9.72e+0) +	9.7058e+1 (6.78e+0) +	9.9324e+1 (8.15e+0) ≈	1.0239e+2 (6.75e+0)
MAP9	100	2	10000	9.2359e+1 (5.77e+0) +	9.3691e+1 (6.25e+0) ≈	9.4991e+1 (6.25e+0) ≈	9.3491e+1 (7.56e+0) ≈	9.5791e+1 (8.55e+0)
	100	2	20000	9.4991e+1 (6.63e+0) ≈	9.8224e+1 (8.49e+0) ≈	9.3925e+1 (7.94e+0) ≈	9.4791e+1 (6.56e+0) ≈	9.7090e+1 (7.83e+0)
	100	2	50000	9.7225e+1 (8.28e+0) ≈	9.5591e+1 (4.89e+0) ≈	9.8757e+1 (8.93e+0) +	9.9324e+1 (8.59e+0) +	9.6924e+1 (8.41e+0)
MAP10	100	2	10000	9.8424e+1 (7.45e+0) ≈	9.3192e+1 (7.15e+0) +	9.5925e+1 (4.91e+0) +	9.6358e+1 (7.88e+0) +	1.0006e+2 (6.86e+0)
	100	2	20000	9.8424e+1 (7.89e+0) ≈	9.6558e+1 (7.42e+0) ≈	9.4759e+1 (8.24e+0) ≈	1.0022e+2 (7.78e+0) ≈	9.8857e+1 (8.57e+0)
	100	2	50000	9.9324e+1 (6.85e+0) ≈	9.9124e+1 (6.83e+0) ≈	9.8858e+1 (7.42e+0) ≈	1.0116e+2 (9.58e+0) ≈	9.9757e+1 (7.03e+0)
+/-/≈				7/0/23	12/0/18	13/0/17	8/0/22	

Tabela A.19: Resultados para o cálculo do *Hypervolume* para as métricas de Tolerância a Falhas e Energia em relação ao *grid* de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAI	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	8.1057e-1 (2.62e-2) –	8.0572e-1 (2.82e-2) –	8.2171e-1 (2.95e-2) –	8.2260e-1 (3.13e-2) –	8.4390e-1 (3.72e-2)
	100	2	20000	8.3824e-1 (3.07e-2) ≈	8.3893e-1 (2.86e-2) ≈	8.4337e-1 (3.02e-2) ≈	8.4821e-1 (2.77e-2) ≈	8.4892e-1 (3.78e-2)
	100	2	50000	8.6584e-1 (2.79e-2) ≈	8.5918e-1 (2.70e-2) ≈	8.7259e-1 (2.58e-2) ≈	8.6743e-1 (2.96e-2) ≈	8.7532e-1 (2.46e-2)
MAP2	100	2	10000	7.9731e-1 (2.02e-2) –	7.8705e-1 (1.51e-2) –	7.9953e-1 (2.19e-2) ≈	7.9628e-1 (2.00e-2) –	8.0835e-1 (3.17e-2)
	100	2	20000	8.1521e-1 (2.78e-2) –	8.1286e-1 (2.79e-2) –	8.2920e-1 (3.10e-2) ≈	8.2382e-1 (3.34e-2) ≈	8.3341e-1 (3.88e-2)
	100	2	50000	8.5384e-1 (3.11e-2) ≈	8.4731e-1 (2.70e-2) ≈	8.4352e-1 (3.16e-2) ≈	8.5081e-1 (2.93e-2) ≈	8.5598e-1 (3.87e-2)
MAP3	100	2	10000	8.0454e-1 (2.52e-2) –	7.9828e-1 (2.55e-2) –	8.0851e-1 (2.94e-2) –	8.0699e-1 (2.55e-2) –	8.2395e-1 (3.53e-2)
	100	2	20000	8.2687e-1 (3.04e-2) –	8.1126e-1 (2.77e-2) –	8.3577e-1 (3.27e-2) –	8.2789e-1 (3.15e-2) –	8.4720e-1 (3.72e-2)
	100	2	50000	8.5887e-1 (3.23e-2) ≈	8.5361e-1 (2.07e-2) ≈	8.5401e-1 (2.99e-2) ≈	8.4416e-1 (3.24e-2) –	8.5765e-1 (3.89e-2)
MAP4	100	2	10000	7.9242e-1 (1.70e-2) –	7.9012e-1 (2.00e-2) –	7.9770e-1 (2.45e-2) –	7.9075e-1 (1.79e-2) –	8.1693e-1 (3.23e-2)
	100	2	20000	8.0920e-1 (2.71e-2) –	8.0316e-1 (2.26e-2) –	8.2041e-1 (3.01e-2) ≈	8.2311e-1 (3.00e-2) ≈	8.2562e-1 (3.53e-2)
	100	2	50000	8.4277e-1 (3.14e-2) ≈	8.3699e-1 (2.95e-2) ≈	8.4752e-1 (3.02e-2) ≈	8.4143e-1 (2.89e-2) ≈	8.3215e-1 (3.77e-2)
MAP5	100	2	10000	7.8665e-1 (7.57e-3) –	7.8723e-1 (1.73e-2) –	7.8998e-1 (1.51e-2) –	7.9008e-1 (1.83e-2) –	8.1320e-1 (3.28e-2)
	100	2	20000	8.1311e-1 (2.86e-2) ≈	7.9794e-1 (2.01e-2) –	8.1381e-1 (3.25e-2) ≈	8.0970e-1 (2.89e-2) ≈	8.2366e-1 (3.66e-2)
	100	2	50000	8.3210e-1 (3.22e-2) ≈	8.3018e-1 (3.01e-2) ≈	8.3756e-1 (3.41e-2) ≈	8.3275e-1 (2.91e-2) ≈	8.3078e-1 (3.49e-2)
MAP6	100	2	10000	7.8920e-1 (1.52e-2) –	7.8459e-1 (1.46e-2) –	7.9323e-1 (2.16e-2) –	7.9258e-1 (1.94e-2) –	8.0923e-1 (2.94e-2)
	100	2	20000	8.1007e-1 (2.72e-2) ≈	8.0206e-1 (2.26e-2) –	8.0909e-1 (2.71e-2) ≈	8.0891e-1 (2.60e-2) –	8.2177e-1 (3.52e-2)
	100	2	50000	8.3624e-1 (3.22e-2) ≈	8.3167e-1 (2.98e-2) ≈	8.3404e-1 (3.60e-2) ≈	8.3300e-1 (3.04e-2) ≈	8.3935e-1 (3.67e-2)
MAP7	100	2	10000	7.9119e-1 (1.93e-2) –	7.8449e-1 (1.46e-2) –	7.8935e-1 (1.91e-2) –	7.9391e-1 (2.16e-2) –	8.0685e-1 (2.95e-2)
	100	2	20000	8.0995e-1 (2.84e-2) ≈	8.0208e-1 (2.53e-2) –	8.1072e-1 (2.71e-2) ≈	8.1325e-1 (2.63e-2) ≈	8.1966e-1 (3.47e-2)
	100	2	50000	8.2764e-1 (3.21e-2) ≈	8.3614e-1 (3.09e-2) ≈	8.2447e-1 (3.01e-2) ≈	8.3006e-1 (3.16e-2) ≈	8.4019e-1 (4.10e-2)
MAP8	100	2	10000	7.8838e-1 (1.49e-2) –	7.8396e-1 (1.50e-2) –	7.8881e-1 (1.38e-2) –	7.8821e-1 (1.45e-2) –	8.0794e-1 (3.00e-2)
	100	2	20000	7.9521e-1 (1.46e-2) –	8.0228e-1 (2.58e-2) –	8.0749e-1 (2.81e-2) ≈	8.1002e-1 (3.10e-2) ≈	8.1519e-1 (3.25e-2)
	100	2	50000	8.2720e-1 (3.17e-2) ≈	8.1757e-1 (2.92e-2) –	8.4262e-1 (3.31e-2) ≈	8.3235e-1 (3.30e-2) ≈	8.2967e-1 (3.42e-2)
MAP9	100	2	10000	7.8542e-1 (1.63e-2) –	7.8377e-1 (1.75e-2) –	7.8470e-1 (1.13e-2) –	7.8733e-1 (1.79e-2) –	8.0172e-1 (2.86e-2)
	100	2	20000	7.9626e-1 (1.83e-2) –	7.9268e-1 (1.71e-2) –	8.0224e-1 (2.50e-2) –	7.9377e-1 (1.49e-2) –	8.0432e-1 (2.71e-2)
	100	2	50000	8.2569e-1 (3.08e-2) ≈	8.1486e-1 (2.68e-2) ≈	8.2321e-1 (3.07e-2) ≈	8.2396e-1 (3.09e-2) ≈	8.2596e-1 (3.65e-2)
MAP10	100	2	10000	7.8574e-1 (1.10e-2) –	7.8162e-1 (3.07e-3) –	7.9296e-1 (1.99e-2) –	7.8919e-1 (1.77e-2) –	8.1388e-1 (3.38e-2)
	100	2	20000	8.0755e-1 (2.73e-2) ≈	8.0051e-1 (2.37e-2) –	8.0524e-1 (2.58e-2) –	8.0447e-1 (2.53e-2) –	8.1618e-1 (3.06e-2)
	100	2	50000	8.2793e-1 (2.97e-2) ≈	8.2779e-1 (3.19e-2) ≈	8.2587e-1 (3.12e-2) ≈	8.2429e-1 (2.88e-2) –	8.3831e-1 (3.37e-2)
+/-/≈				0/15/15	0/21/9	0/12/18	0/16/14	

Tabela A.20: Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Energia em relação ao *grid* de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAI	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	2.6792e+2 (1.53e+1) +	2.6000e+2 (2.89e+1) +	2.6769e+2 (9.85e+0) +	2.6716e+2 (1.26e+1) +	2.7655e+2 (4.45e+0)
	100	2	20000	2.7166e+2 (8.33e+0) +	2.6248e+2 (2.69e+1) +	2.7566e+2 (5.26e+0) ≈	2.7080e+2 (1.68e+1) ≈	2.7679e+2 (5.64e+0)
	100	2	50000	2.7929e+2 (5.09e+0) ≈	2.7633e+2 (4.69e+0) +	2.8086e+2 (4.66e+0) ≈	2.7966e+2 (5.87e+0) ≈	2.8130e+2 (4.93e+0)
MAP2	100	2	10000	2.6578e+2 (1.68e+1) +	2.6704e+2 (1.73e+0) +	2.6675e+2 (9.63e+0) +	2.6914e+2 (1.58e+0) +	2.7224e+2 (4.07e+0)
	100	2	20000	2.7195e+2 (3.10e+0) +	2.6945e+2 (4.75e+0) +	2.7039e+2 (3.76e+0) +	2.7179e+2 (3.28e+0) +	2.7621e+2 (5.00e+0)
	100	2	50000	2.7639e+2 (4.80e+0) +	2.7453e+2 (3.12e+0) +	2.7605e+2 (4.18e+0) +	2.7549e+2 (4.16e+0) +	2.7929e+2 (5.39e+0)
MAP3	100	2	10000	2.6715e+2 (9.23e+0) +	2.6698e+2 (2.69e+0) +	2.6872e+2 (2.65e+0) +	2.5777e+2 (3.37e+1) +	2.7338e+2 (4.37e+0)
	100	2	20000	2.7219e+2 (3.40e+0) +	2.7035e+2 (1.87e+0) +	2.7233e+2 (4.54e+0) +	2.7162e+2 (7.57e+0) +	2.7692e+2 (4.33e+0)
	100	2	50000	2.7779e+2 (4.72e+0) ≈	2.7340e+2 (3.51e+0) +	2.7666e+2 (4.94e+0) +	2.7559e+2 (3.99e+0) +	2.7912e+2 (5.59e+0)
MAP4	100	2	10000	2.6831e+2 (1.76e+0) +	2.6441e+2 (1.24e+1) +	2.6765e+2 (2.46e+0) +	2.6767e+2 (2.33e+0) +	2.7112e+2 (4.08e+0)
	100	2	20000	2.7138e+2 (2.56e+0) +	2.6422e+2 (2.24e+1) +	2.6929e+2 (4.07e+0) +	2.6832e+2 (1.69e+1) +	2.7345e+2 (3.81e+0)
	100	2	50000	2.7442e+2 (3.60e+0) ≈	2.7283e+2 (2.80e+0) ≈	2.7556e+2 (4.89e+0) ≈	2.7492e+2 (4.01e+0) ≈	2.7561e+2 (5.24e+0)
MAP5	100	2	10000	2.6458e+2 (1.97e+1) +	2.6648e+2 (1.31e+0) +	2.6824e+2 (2.02e+0) +	2.6757e+2 (1.89e+0) +	2.7095e+2 (3.36e+0)
	100	2	20000	2.7065e+2 (2.23e+0) +	2.6701e+2 (1.50e+1) +	2.7108e+2 (2.95e+0) +	2.7094e+2 (2.42e+0) +	2.7348e+2 (4.90e+0)
	100	2	50000	2.7408e+2 (3.68e+0) +	2.7202e+2 (3.43e+0) +	2.7552e+2 (4.86e+0) +	2.7422e+2 (2.78e+0) ≈	2.7618e+2 (3.87e+0)
MAP6	100	2	10000	2.6797e+2 (1.28e+0) +	2.6621e+2 (1.50e+0) +	2.6764e+2 (1.86e+0) +	2.6754e+2 (1.99e+0) +	2.7174e+2 (3.46e+0)
	100	2	20000	2.7101e+2 (2.76e+0) +	2.6598e+2 (2.02e+1) +	2.7028e+2 (3.44e+0) +	2.7028e+2 (2.49e+0) +	2.7355e+2 (3.53e+0)
	100	2	50000	2.7479e+2 (3.23e+0) ≈	2.7289e+2 (3.70e+0) +	2.7522e+2 (4.88e+0) ≈	2.7265e+2 (8.50e+0) +	2.7705e+2 (4.90e+0)
MAP7	100	2	10000	2.6279e+2 (2.50e+1) +	2.6611e+2 (1.81e+0) +	2.6707e+2 (2.18e+0) +	2.6462e+2 (1.51e+1) +	2.7064e+2 (4.12e+0)
	100	2	20000	2.6908e+2 (6.16e+0) +	2.6828e+2 (3.02e+0) +	2.7031e+2 (2.81e+0) +	2.6988e+2 (2.65e+0) +	2.7338e+2 (3.97e+0)
	100	2	50000	2.7282e+2 (3.25e+0) +	2.7273e+2 (3.94e+0) +	2.7415e+2 (3.81e+0) +	2.7382e+2 (4.46e+0) +	2.7735e+2 (5.11e+0)
MAP8	100	2	10000	2.6761e+2 (1.82e+0) +	2.6587e+2 (1.58e+0) +	2.6777e+2 (1.77e+0) +	2.6761e+2 (1.55e+0) +	2.7041e+2 (3.75e+0)
	100	2	20000	2.7034e+2 (1.50e+0) +	2.6831e+2 (2.40e+0) +	2.6998e+2 (2.55e+0) +	2.7001e+2 (3.20e+0) +	2.7254e+2 (4.01e+0)
	100	2	50000	2.7358e+2 (3.99e+0) +	2.7198e+2 (2.02e+0) +	2.7403e+2 (4.06e+0) ≈	2.7362e+2 (3.64e+0) ≈	2.7578e+2 (5.11e+0)
MAP9	100	2	10000	2.6654e+2 (1.28e+0) +	2.6511e+2 (1.57e+0) +	2.6707e+2 (1.42e+0) +	2.6651e+2 (1.84e+0) +	2.6898e+2 (2.66e+0)
	100	2	20000	2.6981e+2 (2.35e+0) +	2.6837e+2 (2.01e+0) +	2.6968e+2 (2.14e+0) +	2.6967e+2 (1.71e+0) +	2.7304e+2 (3.27e+0)
	100	2	50000	2.7175e+2 (4.19e+0) +	2.7205e+2 (3.09e+0) +	2.7292e+2 (3.43e+0) ≈	2.7212e+2 (3.41e+0) +	2.7481e+2 (5.11e+0)
MAP10	100	2	10000	2.6740e+2 (1.54e+0) +	2.6670e+2 (1.16e+0) +	2.6468e+2 (1.33e+1) +	2.6684e+2 (2.58e+0) +	2.7131e+2 (3.69e+0)
	100	2	20000	2.6995e+2 (2.22e+0) +	2.6858e+2 (2.27e+0) +	2.6951e+2 (2.59e+0) +	2.6944e+2 (2.34e+0) +	2.7208e+2 (3.57e+0)
	100	2	50000	2.7372e+2 (3.12e+0) +	2.7275e+2 (3.24e+0) +	2.7391e+2 (3.17e+0) ≈	2.7302e+2 (2.71e+0) +	2.7582e+2 (4.53e+0)
+/-/≈				26/0/4	29/0/1	21/0/9	26/0/4	

Tabela A.21: Resultados para o cálculo do *Hypervolume* para as métricas de Tolerância a Falhas e Comunicação em relação ao *grid* de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	5.7514e-1 (1.65e-2) +	5.6956e-1 (1.54e-2) ≈	5.7254e-1 (1.36e-2) ≈	5.8020e-1 (1.76e-2) +	5.6520e-1 (1.24e-2)
	100	2	20000	5.9418e-1 (1.89e-2) ≈	5.8703e-1 (1.79e-2) ≈	5.9185e-1 (1.60e-2) ≈	5.8847e-1 (1.65e-2) ≈	5.8801e-1 (1.47e-2)
	100	2	50000	6.0888e-1 (2.05e-2) ≈	6.0770e-1 (1.83e-2) ≈	6.1366e-1 (2.06e-2) +	6.1524e-1 (1.90e-2) +	5.9836e-1 (1.59e-2)
MAP2	100	2	10000	5.3134e-1 (1.16e-2) ≈	5.2461e-1 (1.06e-2) -	5.3177e-1 (1.05e-2) ≈	5.3453e-1 (1.03e-2) ≈	5.3334e-1 (1.25e-2)
	100	2	20000	5.4313e-1 (1.22e-2) ≈	5.3519e-1 (9.49e-3) ≈	5.4060e-1 (1.07e-2) ≈	5.4341e-1 (1.33e-2) ≈	5.4294e-1 (1.86e-2)
	100	2	50000	5.6689e-1 (1.16e-2) +	5.5843e-1 (1.34e-2) ≈	5.6410e-1 (1.17e-2) +	5.6522e-1 (1.52e-2) +	5.5760e-1 (1.75e-2)
MAP3	100	2	10000	5.3602e-1 (9.30e-3) ≈	5.3331e-1 (9.07e-3) -	5.3874e-1 (1.54e-2) ≈	5.3987e-1 (1.10e-2) ≈	5.4034e-1 (1.34e-2)
	100	2	20000	5.5540e-1 (1.11e-2) ≈	5.4491e-1 (1.30e-2) ≈	5.5504e-1 (1.61e-2) ≈	5.5053e-1 (1.54e-2) ≈	5.5079e-1 (1.58e-2)
	100	2	50000	5.7104e-1 (1.61e-2) ≈	5.6043e-1 (1.24e-2) ≈	5.7454e-1 (1.68e-2) ≈	5.6962e-1 (1.23e-2) ≈	5.6506e-1 (1.75e-2)
MAP4	100	2	10000	5.2144e-1 (1.53e-2) ≈	5.1491e-1 (8.43e-3) -	5.2022e-1 (9.58e-3) ≈	5.1923e-1 (1.09e-2) ≈	5.2577e-1 (1.57e-2)
	100	2	20000	5.2144e-1 (1.53e-2) ≈	5.1491e-1 (8.43e-3) -	5.2022e-1 (9.58e-3) ≈	5.1923e-1 (1.09e-2) ≈	5.2577e-1 (1.57e-2)
	100	2	50000	5.2144e-1 (1.53e-2) ≈	5.1491e-1 (8.43e-3) -	5.2022e-1 (9.58e-3) ≈	5.1923e-1 (1.09e-2) ≈	5.2577e-1 (1.57e-2)
MAP5	100	2	10000	5.1574e-1 (1.06e-2) ≈	5.0669e-1 (1.02e-2) -	5.1537e-1 (1.20e-2) ≈	5.1022e-1 (8.91e-3) -	5.1942e-1 (1.60e-2)
	100	2	20000	5.2353e-1 (1.02e-2) -	5.2401e-1 (9.85e-3) ≈	5.2840e-1 (1.41e-2) ≈	5.3194e-1 (1.22e-2) ≈	5.3085e-1 (1.56e-2)
	100	2	50000	5.5132e-1 (1.29e-2) +	5.3905e-1 (1.20e-2) ≈	5.4724e-1 (1.16e-2) +	5.4682e-1 (1.29e-2) +	5.3760e-1 (1.84e-2)
MAP6	100	2	10000	5.1292e-1 (9.62e-3) ≈	5.0581e-1 (7.98e-3) -	5.1252e-1 (1.19e-2) ≈	5.1300e-1 (8.59e-3) ≈	5.1706e-1 (1.79e-2)
	100	2	20000	5.2865e-1 (1.36e-2) ≈	5.1980e-1 (9.62e-3) -	5.2809e-1 (8.68e-3) ≈	5.2631e-1 (1.29e-2) ≈	5.2635e-1 (1.27e-2)
	100	2	50000	5.4706e-1 (1.31e-2) +	5.3962e-1 (1.18e-2) ≈	5.4816e-1 (7.02e-3) +	5.4896e-1 (1.24e-2) +	5.3619e-1 (1.44e-2)
MAP7	100	2	10000	5.0405e-1 (8.99e-3) ≈	4.9640e-1 (1.19e-2) -	5.0423e-1 (1.05e-2) ≈	5.0488e-1 (9.62e-3) ≈	5.0858e-1 (1.78e-2)
	100	2	20000	5.1884e-1 (1.04e-2) ≈	5.0737e-1 (9.58e-3) ≈	5.1716e-1 (1.04e-2) ≈	5.1933e-1 (1.06e-2) ≈	5.1445e-1 (1.88e-2)
	100	2	50000	5.3440e-1 (1.08e-2) ≈	5.2872e-1 (1.07e-2) ≈	5.3502e-1 (9.73e-3) ≈	5.3359e-1 (1.18e-2) ≈	5.2783e-1 (1.72e-2)
MAP8	100	2	10000	4.9994e-1 (9.12e-3) -	4.9274e-1 (9.91e-3) -	5.0438e-1 (1.16e-2) ≈	5.0009e-1 (9.71e-3) ≈	5.0579e-1 (1.59e-2)
	100	2	20000	5.0866e-1 (1.21e-2) ≈	5.0567e-1 (1.15e-2) -	5.1280e-1 (1.01e-2) ≈	5.1312e-1 (1.21e-2) ≈	5.1482e-1 (1.94e-2)
	100	2	50000	5.3325e-1 (1.36e-2) +	5.2407e-1 (1.03e-2) ≈	5.3159e-1 (1.16e-2) +	5.3448e-1 (1.19e-2) +	5.2286e-1 (1.66e-2)
MAP9	100	2	10000	4.8756e-1 (9.35e-3) ≈	4.8485e-1 (1.09e-2) ≈	4.9404e-1 (1.36e-2) ≈	4.9226e-1 (1.22e-2) ≈	4.9052e-1 (1.33e-2)
	100	2	20000	5.0231e-1 (1.29e-2) ≈	4.9661e-1 (8.48e-3) -	5.0276e-1 (9.34e-3) ≈	5.0330e-1 (1.18e-2) ≈	5.0388e-1 (1.86e-2)
	100	2	50000	5.2217e-1 (1.13e-2) +	5.1086e-1 (7.71e-3) ≈	5.2144e-1 (1.07e-2) +	5.1985e-1 (1.30e-2) ≈	5.1460e-1 (1.29e-2)
MAP10	100	2	10000	5.0897e-1 (1.35e-2) ≈	4.9821e-1 (7.08e-3) -	5.0221e-1 (1.08e-2) ≈	5.0666e-1 (1.06e-2) ≈	5.0395e-1 (1.55e-2)
	100	2	20000	5.1791e-1 (1.11e-2) ≈	5.0696e-1 (8.06e-3) ≈	5.1524e-1 (1.20e-2) ≈	5.1523e-1 (8.46e-3) ≈	5.1400e-1 (1.38e-2)
	100	2	50000	5.3207e-1 (8.88e-3) ≈	5.2746e-1 (1.04e-2) ≈	5.3469e-1 (1.02e-2) ≈	5.3624e-1 (1.13e-2) ≈	5.3182e-1 (1.44e-2)
+/-/≈				6/2/22	0/13/17	6/0/24	6/1/23	

Tabela A.22: Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Comunicação em relação ao *grid* de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	1.1628e+3 (1.16e+2) ≈	1.0915e+3 (1.58e+2) +	1.1678e+3 (1.06e+2) ≈	1.1004e+3 (1.66e+2) +	1.2177e+3 (3.58e+1)
	100	2	20000	1.1493e+3 (1.32e+2) +	1.1152e+3 (1.64e+2) +	1.1637e+3 (1.33e+2) +	1.1711e+3 (1.21e+2) +	1.2524e+3 (7.21e+1)
	100	2	50000	1.2165e+3 (1.08e+2) ≈	1.1476e+3 (1.52e+2) +	1.2257e+3 (1.27e+2) ≈	1.1701e+3 (1.28e+2) +	1.2545e+3 (6.52e+1)
MAP2	100	2	10000	1.1049e+3 (4.57e+1) +	1.0785e+3 (6.89e+1) +	1.0840e+3 (1.19e+2) +	1.0793e+3 (1.49e+2) ≈	1.1284e+3 (4.17e+1)
	100	2	20000	1.1180e+3 (7.65e+1) ≈	1.1098e+3 (7.29e+1) +	1.1122e+3 (9.40e+1) ≈	1.1380e+3 (4.88e+1) ≈	1.1447e+3 (5.12e+1)
	100	2	50000	1.1625e+3 (1.00e+2) ≈	1.1509e+3 (1.02e+2) ≈	1.1821e+3 (8.23e+1) ≈	1.1499e+3 (1.06e+2) ≈	1.1885e+3 (4.29e+1)
MAP3	100	2	10000	1.1022e+3 (9.71e+1) +	1.0881e+3 (9.55e+1) +	1.1227e+3 (2.84e+1) +	1.0779e+3 (1.45e+2) +	1.1524e+3 (3.41e+1)
	100	2	20000	1.1197e+3 (1.74e+2) ≈	1.1205e+3 (9.29e+1) +	1.0908e+3 (1.47e+2) +	1.1409e+3 (8.19e+1) +	1.1769e+3 (4.38e+1)
	100	2	50000	1.1633e+3 (1.02e+2) ≈	1.1711e+3 (8.22e+1) +	1.1907e+3 (5.51e+1) ≈	1.1938e+3 (6.93e+1) ≈	1.1982e+3 (8.60e+1)
MAP4	100	2	10000	1.0555e+3 (8.43e+1) +	1.0573e+3 (3.34e+1) +	1.0763e+3 (2.75e+1) +	1.0822e+3 (3.17e+1) ≈	1.0997e+3 (4.69e+1)
	100	2	20000	1.0555e+3 (8.43e+1) +	1.0573e+3 (3.34e+1) +	1.0763e+3 (2.75e+1) +	1.0822e+3 (3.17e+1) ≈	1.0997e+3 (4.69e+1)
	100	2	50000	1.0555e+3 (8.43e+1) +	1.0573e+3 (3.34e+1) +	1.0763e+3 (2.75e+1) +	1.0822e+3 (3.17e+1) ≈	1.0997e+3 (4.69e+1)
MAP5	100	2	10000	1.0520e+3 (4.25e+1) +	1.0336e+3 (2.26e+1) +	1.0586e+3 (5.10e+1) +	1.0630e+3 (3.19e+1) +	1.0834e+3 (3.85e+1)
	100	2	20000	1.0932e+3 (3.02e+1) ≈	1.0879e+3 (3.84e+1) +	1.0801e+3 (7.13e+1) +	1.1033e+3 (3.37e+1) ≈	1.1126e+3 (4.59e+1)
	100	2	50000	1.1337e+3 (8.63e+1) -	1.1144e+3 (7.66e+1) ≈	1.1424e+3 (6.36e+1) -	1.1260e+3 (7.58e+1) -	1.1222e+3 (5.87e+1)
MAP6	100	2	10000	1.0630e+3 (2.66e+1) ≈	1.0431e+3 (2.93e+1) +	1.0590e+3 (3.60e+1) ≈	1.0629e+3 (2.44e+1) ≈	1.0689e+3 (4.74e+1)
	100	2	20000	1.0932e+3 (3.42e+1) ≈	1.0862e+3 (3.09e+1) ≈	1.1007e+3 (2.87e+1) ≈	1.0892e+3 (3.52e+1) ≈	1.0866e+3 (6.51e+1)
	100	2	50000	1.1043e+3 (1.12e+2) ≈	1.1248e+3 (6.45e+1) ≈	1.1630e+3 (2.58e+1) -	1.1443e+3 (6.32e+1) ≈	1.1385e+3 (4.10e+1)
MAP7	100	2	10000	1.0432e+3 (3.64e+1) ≈	1.0167e+3 (3.64e+1) +	1.0343e+3 (2.99e+1) +	1.0363e+3 (2.76e+1) +	1.0595e+3 (5.25e+1)
	100	2	20000	1.0751e+3 (3.29e+1) ≈	1.0474e+3 (3.09e+1) +	1.0675e+3 (6.99e+1) ≈	1.0700e+3 (3.24e+1) ≈	1.0796e+3 (4.93e+1)
	100	2	50000	1.0893e+3 (9.80e+1) ≈	1.0959e+3 (3.25e+1) ≈	1.1227e+3 (3.43e+1) ≈	1.1139e+3 (3.97e+1) ≈	1.1087e+3 (5.47e+1)
MAP8	100	2	10000	1.0219e+3 (3.31e+1) +	1.0018e+3 (3.08e+1) +	1.0318e+3 (3.48e+1) ≈	1.0226e+3 (3.69e+1) ≈	1.0447e+3 (5.07e+1)
	100	2	20000	1.0499e+3 (4.03e+1) ≈	1.0241e+3 (5.27e+1) +	1.0556e+3 (3.82e+1) ≈	1.0520e+3 (2.39e+1) ≈	1.0661e+3 (5.31e+1)
	100	2	50000	1.0986e+3 (5.67e+1) ≈	1.0866e+3 (2.68e+1) ≈	1.1174e+3 (3.25e+1) ≈	1.0817e+3 (1.00e+2) ≈	1.0986e+3 (5.01e+1)
MAP9	100	2	10000	9.8279e+2 (3.47e+1) +	9.6793e+2 (2.87e+1) +	1.0018e+3 (4.40e+1) ≈	9.8279e+2 (7.89e+1) ≈	1.0044e+3 (4.30e+1)
	100	2	20000	1.0347e+3 (3.31e+1) ≈	1.0136e+3 (4.49e+1) ≈	1.0215e+3 (2.89e+1) ≈	1.0273e+3 (3.43e+1) ≈	1.0317e+3 (5.28e+1)
	100	2	50000	1.0738e+3 (8.44e+1) ≈	1.0565e+3 (2.80e+1) ≈	1.0574e+3 (1.21e+2) ≈	1.0805e+3 (4.23e+1) ≈	1.0622e+3 (4.77e+1)
MAP10	100	2	10000	1.0413e+3 (4.09e+1) ≈	1.0064e+3 (2.44e+1) +	1.0331e+3 (3.07e+1) +	1.0343e+3 (3.60e+1) ≈	1.0477e+3 (5.06e+1)
	100	2	20000	1.0669e+3 (6.30e+1) ≈	1.0486e+3 (3.20e+1) +	1.0580e+3 (8.16e+1) ≈	1.0746e+3 (2.61e+1) ≈	1.0726e+3 (4.37e+1)
	100	2	50000	1.1040e+3 (2.89e+1) ≈	1.0988e+3 (3.59e+1) ≈	1.1217e+3 (3.21e+1) ≈	1.1003e+3 (9.83e+1) ≈	1.1021e+3 (8.45e+1)
+/-/≈				9/1/20	21/0/9	11/2/17	7/0/23	

Tabela A.23: Resultados para o cálculo do *Hypervolume* para as métricas de Comunicação e Energia em relação ao *grid* de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAI	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	6.2988e-1 (4.09e-3) ≈	6.1769e-1 (5.51e-3) –	6.2711e-1 (5.01e-3) –	6.2659e-1 (4.28e-3) –	6.3291e-1 (7.13e-3)
	100	2	20000	6.4032e-1 (4.65e-3) ≈	6.3654e-1 (4.42e-3) –	6.4435e-1 (6.57e-3) ≈	6.4225e-1 (6.19e-3) ≈	6.4290e-1 (6.86e-3)
	100	2	50000	6.6153e-1 (5.78e-3) ≈	6.5442e-1 (5.00e-3) –	6.6294e-1 (6.53e-3) +	6.6046e-1 (5.18e-3) ≈	6.5988e-1 (4.51e-3)
MAP2	100	2	10000	5.8998e-1 (5.27e-3) –	5.8211e-1 (4.70e-3) –	5.9051e-1 (4.60e-3) –	5.9168e-1 (6.00e-3) –	5.9756e-1 (8.03e-3)
	100	2	20000	6.0694e-1 (7.36e-3) ≈	5.9932e-1 (4.33e-3) –	6.0722e-1 (6.32e-3) ≈	6.0588e-1 (6.15e-3) ≈	6.0775e-1 (6.17e-3)
	100	2	50000	6.2763e-1 (6.54e-3) ≈	6.2029e-1 (5.41e-3) –	6.2940e-1 (5.62e-3) +	6.2426e-1 (5.33e-3) ≈	6.2486e-1 (6.84e-3)
MAP3	100	2	10000	5.9836e-1 (5.65e-3) –	5.9007e-1 (5.09e-3) –	5.9709e-1 (5.02e-3) –	5.9685e-1 (5.67e-3) –	6.0245e-1 (7.41e-3)
	100	2	20000	6.1305e-1 (7.11e-3) –	6.0797e-1 (4.46e-3) –	6.1471e-1 (5.09e-3) ≈	6.1161e-1 (4.92e-3) ≈	6.1752e-1 (6.91e-3)
	100	2	50000	6.3251e-1 (5.45e-3) +	6.2640e-1 (3.81e-3) ≈	6.3490e-1 (5.82e-3) +	6.3212e-1 (6.67e-3) +	6.2789e-1 (7.22e-3)
MAP4	100	2	10000	5.8087e-1 (6.44e-3) –	5.7322e-1 (5.87e-3) –	5.7982e-1 (5.49e-3) –	5.7913e-1 (4.70e-3) –	5.8612e-1 (6.81e-3)
	100	2	20000	5.9693e-1 (5.80e-3) ≈	5.9180e-1 (3.87e-3) –	5.9670e-1 (6.92e-3) ≈	5.9667e-1 (4.74e-3) ≈	5.9740e-1 (8.08e-3)
	100	2	50000	6.1564e-1 (5.15e-3) ≈	6.0853e-1 (5.81e-3) –	6.1715e-1 (4.88e-3) ≈	6.1653e-1 (6.74e-3) ≈	6.1529e-1 (6.81e-3)
MAP5	100	2	10000	5.7402e-1 (4.99e-3) –	5.6819e-1 (4.60e-3) –	5.7499e-1 (5.70e-3) –	5.7394e-1 (6.49e-3) –	5.7926e-1 (6.40e-3)
	100	2	20000	5.9159e-1 (6.66e-3) ≈	5.8407e-1 (4.77e-3) –	5.9054e-1 (5.90e-3) ≈	5.9057e-1 (5.29e-3) ≈	5.9072e-1 (7.13e-3)
	100	2	50000	6.1123e-1 (6.05e-3) +	6.0580e-1 (5.75e-3) ≈	6.1197e-1 (5.60e-3) +	6.1063e-1 (5.26e-3) ≈	6.0824e-1 (7.63e-3)
MAP6	100	2	10000	5.7565e-1 (5.67e-3) –	5.6748e-1 (6.20e-3) –	5.7485e-1 (5.44e-3) –	5.7491e-1 (6.49e-3) –	5.8100e-1 (7.48e-3)
	100	2	20000	5.9260e-1 (6.25e-3) ≈	5.8508e-1 (4.69e-3) –	5.9149e-1 (6.83e-3) ≈	5.9087e-1 (5.98e-3) ≈	5.9359e-1 (5.52e-3)
	100	2	50000	6.0987e-1 (4.64e-3) ≈	6.0605e-1 (6.70e-3) ≈	6.0986e-1 (6.38e-3) ≈	6.0893e-1 (5.86e-3) ≈	6.0756e-1 (5.37e-3)
MAP7	100	2	10000	5.6284e-1 (6.47e-3) –	5.5678e-1 (5.35e-3) –	5.6399e-1 (8.05e-3) –	5.6365e-1 (6.43e-3) –	5.7115e-1 (7.30e-3)
	100	2	20000	5.8141e-1 (6.02e-3) ≈	5.7488e-1 (7.84e-3) –	5.8001e-1 (5.60e-3) –	5.8108e-1 (5.78e-3) ≈	5.8366e-1 (5.54e-3)
	100	2	50000	6.0244e-1 (6.88e-3) +	5.9479e-1 (4.84e-3) ≈	6.0101e-1 (5.76e-3) +	6.0012e-1 (7.66e-3) ≈	5.9762e-1 (7.65e-3)
MAP8	100	2	10000	5.6118e-1 (6.42e-3) –	5.5293e-1 (4.51e-3) –	5.6050e-1 (5.89e-3) ≈	5.6103e-1 (8.08e-3) ≈	5.6367e-1 (7.69e-3)
	100	2	20000	5.7848e-1 (6.07e-3) ≈	5.7142e-1 (5.60e-3) –	5.7684e-1 (5.28e-3) ≈	5.7410e-1 (5.67e-3) ≈	5.7771e-1 (5.53e-3)
	100	2	50000	5.9629e-1 (5.47e-3) ≈	5.9123e-1 (5.12e-3) –	5.9541e-1 (5.20e-3) ≈	5.9462e-1 (5.19e-3) ≈	5.9605e-1 (6.46e-3)
MAP9	100	2	10000	5.4955e-1 (5.18e-3) –	5.4301e-1 (5.64e-3) –	5.4954e-1 (5.34e-3) –	5.5041e-1 (6.06e-3) –	5.5494e-1 (6.15e-3)
	100	2	20000	5.6826e-1 (5.17e-3) ≈	5.6094e-1 (5.55e-3) –	5.6598e-1 (5.05e-3) –	5.6388e-1 (4.98e-3) –	5.7046e-1 (6.83e-3)
	100	2	50000	5.8637e-1 (6.11e-3) ≈	5.7938e-1 (5.99e-3) –	5.8653e-1 (7.35e-3) ≈	5.8570e-1 (4.54e-3) ≈	5.8564e-1 (7.17e-3)
MAP10	100	2	10000	5.6321e-1 (5.21e-3) –	5.5584e-1 (5.99e-3) –	5.6370e-1 (5.53e-3) –	5.6408e-1 (4.60e-3) –	5.6853e-1 (8.76e-3)
	100	2	20000	5.8116e-1 (4.88e-3) ≈	5.7217e-1 (5.92e-3) –	5.8110e-1 (4.84e-3) ≈	5.8145e-1 (6.78e-3) ≈	5.8231e-1 (8.51e-3)
	100	2	50000	6.0007e-1 (5.56e-3) ≈	5.9270e-1 (4.76e-3) –	6.0255e-1 (6.53e-3) ≈	5.9945e-1 (6.25e-3) ≈	6.0144e-1 (6.44e-3)
+/-/≈				3/9/18	0/26/4	5/11/14	1/12/17	

Tabela A.24: Resultados para o cálculo do IGD para as métricas de Comunicação e Energia em relação ao *grid* de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAI	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	1.3314e+3 (1.67e+2) +	1.2979e+3 (1.95e+2) +	1.3142e+3 (2.30e+2) +	1.3956e+3 (1.74e+2) ≈	1.4703e+3 (1.96e+2)
	100	2	20000	1.4442e+3 (1.31e+2) +	1.3525e+3 (1.64e+2) +	1.3680e+3 (2.02e+2) +	1.5068e+3 (1.69e+2) ≈	1.5309e+3 (1.48e+2)
	100	2	50000	1.4218e+3 (2.17e+2) +	1.4992e+3 (1.84e+2) +	1.4461e+3 (1.56e+2) +	1.6302e+3 (1.12e+2) ≈	1.6405e+3 (1.46e+2)
MAP2	100	2	10000	1.1817e+3 (2.00e+2) ≈	1.1474e+3 (1.78e+2) +	1.0412e+3 (2.34e+2) +	1.1571e+3 (1.38e+2) +	1.2797e+3 (1.42e+2)
	100	2	20000	1.2381e+3 (1.81e+2) +	1.1859e+3 (1.82e+2) +	1.1056e+3 (2.03e+2) +	1.2356e+3 (1.76e+2) +	1.3784e+3 (1.77e+2)
	100	2	50000	1.3429e+3 (1.64e+2) +	1.2710e+3 (1.84e+2) +	1.2451e+3 (1.72e+2) +	1.3584e+3 (1.72e+2) +	1.4565e+3 (1.41e+2)
MAP3	100	2	10000	1.1568e+3 (1.58e+2) +	1.1217e+3 (1.66e+2) +	1.1295e+3 (2.14e+2) +	1.1818e+3 (2.47e+2) +	1.3442e+3 (1.57e+2)
	100	2	20000	1.3009e+3 (1.39e+2) +	1.2085e+3 (1.97e+2) +	1.2095e+3 (1.91e+2) +	1.2977e+3 (1.47e+2) +	1.4208e+3 (2.11e+2)
	100	2	50000	1.3343e+3 (1.75e+2) +	1.3073e+3 (2.13e+2) +	1.2934e+3 (1.98e+2) +	1.3478e+3 (1.66e+2) +	1.4966e+3 (1.26e+2)
MAP4	100	2	10000	1.1553e+3 (1.71e+2) +	1.1203e+3 (1.76e+2) +	1.0674e+3 (2.05e+2) +	1.1016e+3 (2.02e+2) +	1.2875e+3 (1.40e+2)
	100	2	20000	1.2437e+3 (1.23e+2) +	1.1119e+3 (2.15e+2) +	1.1257e+3 (2.14e+2) +	1.2216e+3 (2.11e+2) +	1.3319e+3 (1.58e+2)
	100	2	50000	1.2850e+3 (1.92e+2) +	1.2496e+3 (1.76e+2) +	1.1493e+3 (2.50e+2) +	1.3293e+3 (2.31e+2) ≈	1.4181e+3 (1.56e+2)
MAP5	100	2	10000	1.0478e+3 (1.63e+2) +	9.8791e+2 (1.99e+2) +	9.9195e+2 (1.57e+2) +	1.0838e+3 (2.14e+2) +	1.2073e+3 (1.43e+2)
	100	2	20000	1.1288e+3 (1.92e+2) +	1.0450e+3 (1.88e+2) +	1.1274e+3 (1.88e+2) +	1.1261e+3 (2.39e+2) +	1.2928e+3 (1.38e+2)
	100	2	50000	1.1968e+3 (2.09e+2) +	1.2044e+3 (1.56e+2) +	1.2110e+3 (1.93e+2) +	1.2501e+3 (2.29e+2) +	1.3890e+3 (1.50e+2)
MAP6	100	2	10000	1.0498e+3 (1.79e+2) +	1.0103e+3 (2.12e+2) +	9.7734e+2 (2.39e+2) +	1.0514e+3 (2.11e+2) +	1.1799e+3 (1.55e+2)
	100	2	20000	1.1722e+3 (1.80e+2) ≈	1.0960e+3 (2.35e+2) +	1.0587e+3 (2.41e+2) +	1.1612e+3 (1.59e+2) +	1.2595e+3 (1.51e+2)
	100	2	50000	1.2433e+3 (2.20e+2) ≈	1.1390e+3 (2.24e+2) +	1.2120e+3 (1.44e+2) +	1.2774e+3 (1.84e+2) ≈	1.3400e+3 (1.76e+2)
MAP7	100	2	10000	9.6286e+2 (2.31e+2) +	9.8274e+2 (1.74e+2) +	9.3122e+2 (2.19e+2) +	9.8091e+2 (2.02e+2) +	1.1069e+3 (1.81e+2)
	100	2	20000	1.0593e+3 (1.50e+2) +	1.0029e+3 (2.52e+2) +	1.0022e+3 (2.15e+2) +	1.1312e+3 (1.83e+2) ≈	1.2263e+3 (1.65e+2)
	100	2	50000	1.1824e+3 (2.37e+2) +	1.0955e+3 (1.82e+2) +	1.1493e+3 (1.24e+2) +	1.1853e+3 (1.50e+2) +	1.3164e+3 (1.51e+2)
MAP8	100	2	10000	1.0106e+3 (2.00e+2) +	9.2351e+2 (1.68e+2) +	8.9755e+2 (2.44e+2) +	9.9281e+2 (2.13e+2) +	1.1461e+3 (1.63e+2)
	100	2	20000	1.1095e+3 (1.65e+2) +	9.6665e+2 (2.13e+2) +	1.0552e+3 (2.09e+2) +	1.1315e+3 (1.80e+2) +	1.2856e+3 (1.61e+2)
	100	2	50000	1.2317e+3 (1.45e+2) +	1.1723e+3 (1.87e+2) +	1.1378e+3 (1.77e+2) +	1.2112e+3 (1.65e+2) +	1.3325e+3 (1.66e+2)
MAP9	100	2	10000	9.4257e+2 (1.91e+2) +	8.8285e+2 (1.55e+2) +	9.0226e+2 (2.02e+2) +	9.4678e+2 (1.97e+2) +	1.1227e+3 (1.56e+2)
	100	2	20000	1.0371e+3 (1.45e+2) +	9.7401e+2 (2.13e+2) +	1.0085e+3 (2.40e+2) ≈	1.0868e+3 (1.62e+2) ≈	1.1257e+3 (1.82e+2)
	100	2	50000	1.1445e+3 (1.96e+2) +	1.0989e+3 (1.82e+2) +	1.1034e+3 (2.17e+2) +	1.1198e+3 (2.70e+2) +	1.2732e+3 (1.49e+2)
MAP10	100	2	10000	1.0587e+3 (1.95e+2) +	9.4268e+2 (2.11e+2) +	9.0842e+2 (2.47e+2) +	1.0212e+3 (1.77e+2) +	1.1741e+3 (1.68e+2)
	100	2	20000	1.0644e+3 (1.77e+2) +	1.0282e+3 (1.96e+2) +	1.0684e+3 (1.83e+2) +	1.0624e+3 (2.05e+2) +	1.2470e+3 (1.56e+2)
	100	2	50000	1.1470e+3 (2.00e+2) +	1.1347e+3 (2.14e+2) +	1.1291e+3 (2.04e+2) +	1.2503e+3 (1.48e+2) ≈	1.2702e+3 (2.13e+2)
+/-/≈				27/0/3	30/0/0	29/0/1	22/0/8	

A.2 Com uso do procedimento autoadaptativo

A seguir, são apresentadas as tabelas referentes aos resultados obtidos com o uso do procedimento autoadaptativo apresentado no Capítulo 4, com base na Tabela 4.3, com 30 repetições independentes para cada uma das configurações utilizadas.

Tabela A.25: Resultados para o cálculo do *Hypervolume* para as métricas de Energia e Balanceamento de Carga em relação ao *grid* de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAI	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	7.3624e-1 (8.28e-3) –	7.3137e-1 (9.53e-3) –	7.3978e-1 (7.71e-3) ≈	7.2644e-1 (1.82e-2) –	7.4321e-1 (1.11e-2)
	100	2	20000	7.4477e-1 (9.52e-3) ≈	7.4421e-1 (8.98e-3) ≈	7.4981e-1 (8.20e-3) +	6.9725e-1 (2.59e-2) –	7.4469e-1 (1.02e-2)
	100	2	50000	7.5326e-1 (8.01e-3) ≈	7.5796e-1 (7.25e-3) +	7.6192e-1 (6.56e-3) +	6.8902e-1 (2.05e-2) –	7.5330e-1 (1.01e-2)
MAP2	100	2	10000	7.1101e-1 (9.06e-3) –	7.0184e-1 (7.44e-3) –	7.1594e-1 (7.59e-3) –	7.0987e-1 (1.07e-2) –	7.2243e-1 (1.07e-2)
	100	2	20000	7.2601e-1 (9.08e-3) ≈	7.2294e-1 (7.49e-3) –	7.3280e-1 (8.47e-3) ≈	7.0375e-1 (2.85e-2) –	7.3168e-1 (9.88e-3)
	100	2	50000	7.4418e-1 (7.54e-3) ≈	7.4373e-1 (9.08e-3) ≈	7.5204e-1 (7.79e-3) +	6.8486e-1 (3.47e-2) –	7.4481e-1 (1.04e-2)
MAP3	100	2	10000	7.1095e-1 (6.95e-3) –	7.0117e-1 (8.91e-3) –	7.1444e-1 (8.86e-3) ≈	7.0714e-1 (1.04e-2) –	7.1804e-1 (8.96e-3)
	100	2	20000	7.2306e-1 (7.91e-3) ≈	7.1668e-1 (7.84e-3) –	7.3098e-1 (8.40e-3) ≈	7.0189e-1 (2.54e-2) –	7.2595e-1 (1.00e-2)
	100	2	50000	7.3668e-1 (8.26e-3) ≈	7.3443e-1 (1.02e-2) ≈	7.4102e-1 (7.95e-3) ≈	6.7268e-1 (2.17e-2) –	7.3749e-1 (8.38e-3)
MAP4	100	2	10000	7.3189e-1 (3.55e-2) –	6.9498e-1 (1.86e-2) –	7.2988e-1 (3.02e-2) –	7.1464e-1 (2.45e-2) –	7.4449e-1 (3.43e-2)
	100	2	20000	7.6762e-1 (3.49e-2) –	7.4042e-1 (3.54e-2) –	7.8627e-1 (2.51e-2) ≈	7.4994e-1 (4.93e-2) –	7.8154e-1 (3.43e-2)
	100	2	50000	8.1261e-1 (2.34e-2) ≈	8.0313e-1 (2.24e-2) –	8.1878e-1 (1.58e-2) ≈	7.1769e-1 (7.10e-2) –	8.1810e-1 (1.15e-2)
MAP5	100	2	10000	7.2426e-1 (1.00e-2) ≈	7.1904e-1 (6.30e-3) –	7.2934e-1 (7.66e-3) ≈	7.1868e-1 (1.67e-2) –	7.2841e-1 (9.30e-3)
	100	2	20000	7.3434e-1 (8.50e-3) ≈	7.3271e-1 (8.50e-3) ≈	7.4418e-1 (6.45e-3) +	6.9784e-1 (1.93e-2) –	7.3561e-1 (9.41e-3)
	100	2	50000	7.4461e-1 (8.36e-3) ≈	7.4660e-1 (8.68e-3) ≈	7.5013e-1 (9.42e-3) ≈	6.9021e-1 (2.06e-2) –	7.4429e-1 (1.07e-2)
MAP6	100	2	10000	6.9130e-1 (1.09e-2) –	6.7626e-1 (1.40e-2) –	6.9658e-1 (8.88e-3) –	6.9227e-1 (1.00e-2) –	7.0762e-1 (1.42e-2)
	100	2	20000	7.1049e-1 (8.90e-3) –	7.0852e-1 (9.15e-3) –	7.1982e-1 (6.25e-3) ≈	7.0862e-1 (2.03e-2) –	7.2393e-1 (1.32e-2)
	100	2	50000	7.3313e-1 (1.23e-2) ≈	7.3120e-1 (7.57e-3) –	7.4036e-1 (9.42e-3) ≈	6.9417e-1 (3.30e-2) –	7.3780e-1 (9.11e-3)
MAP7	100	2	10000	6.6014e-1 (9.48e-3) –	6.4817e-1 (6.74e-3) –	6.6591e-1 (6.27e-3) –	6.6379e-1 (7.69e-3) –	6.7634e-1 (8.89e-3)
	100	2	20000	6.7953e-1 (7.04e-3) –	6.6985e-1 (9.07e-3) –	6.8471e-1 (7.29e-3) –	6.7883e-1 (1.06e-2) –	6.9226e-1 (9.82e-3)
	100	2	50000	7.0337e-1 (1.04e-2) ≈	6.9764e-1 (6.94e-3) –	7.0522e-1 (9.19e-3) ≈	6.8191e-1 (1.91e-2) –	7.0562e-1 (1.04e-2)
MAP8	100	2	10000	6.5142e-1 (7.32e-3) –	6.4185e-1 (8.20e-3) –	6.5790e-1 (5.94e-3) –	6.4992e-1 (8.77e-3) –	6.6998e-1 (9.98e-3)
	100	2	20000	6.7019e-1 (8.63e-3) –	6.6277e-1 (8.25e-3) –	6.7848e-1 (5.93e-3) –	6.7090e-1 (1.03e-2) –	6.8605e-1 (8.88e-3)
	100	2	50000	6.9166e-1 (6.01e-3) –	6.8739e-1 (9.07e-3) –	6.9634e-1 (7.92e-3) ≈	6.7930e-1 (1.76e-2) –	6.9911e-1 (1.44e-2)
MAP9	100	2	10000	6.2861e-1 (7.89e-3) –	6.1718e-1 (7.65e-3) –	6.3513e-1 (6.66e-3) –	6.2737e-1 (7.67e-3) –	6.4761e-1 (1.08e-2)
	100	2	20000	6.4846e-1 (7.24e-3) –	6.3893e-1 (6.24e-3) –	6.5480e-1 (4.41e-3) –	6.4930e-1 (8.46e-3) –	6.6309e-1 (7.92e-3)
	100	2	50000	6.6869e-1 (8.59e-3) –	6.6416e-1 (8.75e-3) –	6.7791e-1 (6.17e-3) ≈	6.6206e-1 (1.68e-2) –	6.7914e-1 (1.06e-2)
MAP10	100	2	10000	7.0706e-1 (9.48e-3) –	6.9951e-1 (8.13e-3) –	7.1456e-1 (7.25e-3) ≈	7.0851e-1 (8.36e-3) –	7.1690e-1 (1.07e-2)
	100	2	20000	7.2505e-1 (7.23e-3) ≈	7.1665e-1 (7.95e-3) –	7.2967e-1 (6.69e-3) +	7.0385e-1 (2.57e-2) –	7.2366e-1 (9.04e-3)
	100	2	50000	7.3525e-1 (9.14e-3) ≈	7.3749e-1 (8.21e-3) ≈	7.4355e-1 (7.58e-3) +	6.7747e-1 (2.68e-2) –	7.3609e-1 (8.64e-3)
			+ / – / ≈	0/16/14	1/23/6	6/9/15	0/30/0	

Tabela A.26: Resultados para o cálculo do IGD para as métricas de Energia e Balançamento de Carga em relação ao *grid* de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	7.5242e+1 (1.94e+0) +	7.4042e+1 (1.86e+0) +	7.4575e+1 (1.98e+0) +	7.5241e+1 (2.25e+0) +	7.7207e+1 (1.76e+0)
	100	2	20000	7.6974e+1 (1.53e+0) ≈	7.6774e+1 (1.82e+0) +	7.6974e+1 (1.36e+0) ≈	7.8970e+1 (2.78e+0) ≈	7.7873e+1 (1.82e+0)
	100	2	50000	7.8473e+1 (1.61e+0) ≈	7.9506e+1 (1.33e+0) ≈	7.9173e+1 (1.48e+0) ≈	8.0068e+1 (2.77e+0) -	7.8873e+1 (1.58e+0)
MAP2	100	2	10000	6.6384e+1 (2.78e+0) +	6.4352e+1 (2.20e+0) +	6.5218e+1 (2.59e+0) +	6.6318e+1 (2.10e+0) +	7.0048e+1 (2.56e+0)
	100	2	20000	7.0448e+1 (1.97e+0) +	6.8749e+1 (3.32e+0) +	7.0281e+1 (1.75e+0) +	7.0745e+1 (3.38e+0) +	7.2513e+1 (2.34e+0)
	100	2	50000	7.4079e+1 (2.01e+0) +	7.4112e+1 (1.95e+0) +	7.4512e+1 (2.37e+0) ≈	7.5507e+1 (2.41e+0) ≈	7.5411e+1 (2.04e+0)
MAP3	100	2	10000	7.1045e+1 (2.02e+0) +	6.9113e+1 (1.93e+0) +	6.9279e+1 (1.79e+0) +	7.0378e+1 (1.77e+0) +	7.3876e+1 (2.86e+0)
	100	2	20000	7.4143e+1 (2.19e+0) ≈	7.2544e+1 (1.98e+0) +	7.3110e+1 (1.84e+0) +	7.3575e+1 (3.57e+0) ≈	7.4909e+1 (1.87e+0)
	100	2	50000	7.6542e+1 (1.46e+0) ≈	7.6508e+1 (2.34e+0) ≈	7.5909e+1 (1.68e+0) +	7.7970e+1 (2.06e+0) ≈	7.7075e+1 (1.97e+0)
MAP4	100	2	10000	6.1232e+1 (3.72e+0) +	6.0392e+1 (3.40e+0) +	5.9831e+1 (3.96e+0) +	6.2658e+1 (4.02e+0) ≈	6.3662e+1 (5.68e+0)
	100	2	20000	6.4265e+1 (4.59e+0) +	6.3295e+1 (4.33e+0) +	6.1372e+1 (3.79e+0) +	6.4330e+1 (5.05e+0) ≈	6.6331e+1 (4.67e+0)
	100	2	50000	6.6400e+1 (3.67e+0) +	6.6134e+1 (4.37e+0) +	6.6567e+1 (3.57e+0) +	7.2217e+1 (4.15e+0) -	7.0031e+1 (3.55e+0)
MAP5	100	2	10000	7.4408e+1 (1.75e+0) +	7.3076e+1 (2.06e+0) +	7.4575e+1 (1.79e+0) +	7.4907e+1 (2.27e+0) +	7.6240e+1 (1.61e+0)
	100	2	20000	7.7073e+1 (2.11e+0) +	7.6307e+1 (1.31e+0) +	7.6407e+1 (2.56e+0) +	7.8171e+1 (2.34e+0) +	7.8406e+1 (1.59e+0)
	100	2	50000	7.8439e+1 (1.07e+0) +	7.9372e+1 (1.75e+0) ≈	7.8673e+1 (1.52e+0) ≈	8.0435e+1 (1.43e+0) ≈	7.9505e+1 (1.85e+0)
MAP6	100	2	10000	6.0891e+1 (3.80e+0) +	5.9026e+1 (2.78e+0) +	5.9859e+1 (2.49e+0) +	6.1158e+1 (3.28e+0) +	6.5188e+1 (3.71e+0)
	100	2	20000	6.5254e+1 (2.40e+0) +	6.3855e+1 (2.67e+0) +	6.3756e+1 (2.26e+0) +	6.6153e+1 (3.13e+0) +	7.0017e+1 (2.70e+0)
	100	2	50000	7.0317e+1 (2.47e+0) +	7.0384e+1 (2.55e+0) +	6.9984e+1 (2.94e+0) +	7.1380e+1 (4.47e+0) ≈	7.2382e+1 (2.17e+0)
MAP7	100	2	10000	6.2153e+1 (2.37e+0) +	6.0254e+1 (2.56e+0) +	6.0287e+1 (2.08e+0) +	6.2019e+1 (2.64e+0) +	6.6482e+1 (2.97e+0)
	100	2	20000	6.6248e+1 (2.23e+0) +	6.4483e+1 (2.63e+0) +	6.4717e+1 (2.15e+0) +	6.6482e+1 (2.54e+0) +	6.9946e+1 (2.47e+0)
	100	2	50000	7.0580e+1 (2.31e+0) +	6.9280e+1 (2.33e+0) +	6.9280e+1 (2.39e+0) +	7.0746e+1 (3.33e+0) +	7.2878e+1 (2.69e+0)
MAP8	100	2	10000	6.1752e+1 (2.04e+0) +	6.0652e+1 (2.19e+0) +	6.1352e+1 (2.00e+0) +	6.2418e+1 (2.28e+0) +	6.8014e+1 (3.30e+0)
	100	2	20000	6.6248e+1 (2.23e+0) +	6.4483e+1 (2.63e+0) +	6.4717e+1 (2.03e+0) +	6.7314e+1 (1.85e+0) +	6.9946e+1 (2.76e+0)
	100	2	50000	7.0678e+1 (2.01e+0) +	7.0478e+1 (2.11e+0) +	6.9313e+1 (1.95e+0) +	7.0645e+1 (3.81e+0) +	7.3443e+1 (2.19e+0)
MAP9	100	2	10000	6.2083e+1 (2.06e+0) +	6.0218e+1 (1.58e+0) +	6.0884e+1 (2.21e+0) +	6.1317e+1 (1.85e+0) +	6.6247e+1 (2.50e+0)
	100	2	20000	6.5780e+1 (1.36e+0) +	6.4415e+1 (1.67e+0) +	6.4215e+1 (1.34e+0) +	6.6113e+1 (2.29e+0) +	6.9946e+1 (2.80e+0)
	100	2	50000	7.0077e+1 (1.83e+0) +	6.9111e+1 (1.64e+0) +	6.8545e+1 (2.24e+0) +	7.0777e+1 (2.23e+0) +	7.3176e+1 (2.58e+0)
MAP10	100	2	10000	7.0245e+1 (1.81e+0) +	6.8813e+1 (2.01e+0) +	6.9779e+1 (2.23e+0) +	7.0045e+1 (2.02e+0) +	7.2977e+1 (2.27e+0)
	100	2	20000	7.3410e+1 (2.06e+0) +	7.2610e+1 (1.43e+0) +	7.2610e+1 (1.77e+0) +	7.5041e+1 (2.05e+0) ≈	7.5609e+1 (1.61e+0)
	100	2	50000	7.6108e+1 (1.96e+0) +	7.6009e+1 (1.99e+0) +	7.6342e+1 (1.60e+0) ≈	7.7970e+1 (1.82e+0) ≈	7.7075e+1 (1.83e+0)
				+/-/≈	26/0/4	27/0/3	25/0/5	17/2/11

Tabela A.27: Resultados para o cálculo do Hypervolume para as métricas de Tolerância a Falhas e Energia em relação ao *grid* de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	8.6364e-1 (1.16e-2) +	8.6006e-1 (8.66e-3) ≈	8.6474e-1 (9.82e-3) +	8.6143e-1 (1.26e-2) ≈	8.5510e-1 (1.24e-2)
	100	2	20000	8.6584e-1 (1.18e-2) +	8.6804e-1 (1.05e-2) +	8.7080e-1 (1.31e-2) +	8.6446e-1 (1.05e-2) +	8.5813e-1 (1.25e-2)
	100	2	50000	8.6829e-1 (1.83e-2) ≈	8.8264e-1 (7.64e-3) +	8.7769e-1 (1.36e-2) +	8.6887e-1 (1.33e-2) ≈	8.6061e-1 (1.90e-2)
MAP2	100	2	10000	8.3733e-1 (1.53e-2) +	8.3102e-1 (1.59e-2) ≈	8.3956e-1 (1.67e-2) +	8.3664e-1 (1.37e-2) +	8.2397e-1 (2.11e-2)
	100	2	20000	8.4821e-1 (1.36e-2) +	8.5372e-1 (1.34e-2) +	8.5565e-1 (1.26e-2) +	8.4986e-1 (1.44e-2) +	8.3444e-1 (1.62e-2)
	100	2	50000	8.6171e-1 (1.28e-2) +	8.6639e-1 (1.02e-2) +	8.6033e-1 (2.01e-2) +	8.5675e-1 (1.43e-2) ≈	8.4959e-1 (1.73e-2)
MAP3	100	2	10000	8.4298e-1 (1.64e-2) ≈	8.3581e-1 (1.72e-2) ≈	8.4567e-1 (1.43e-2) +	8.4212e-1 (1.47e-2) ≈	8.3251e-1 (2.18e-2)
	100	2	20000	8.5537e-1 (1.56e-2) +	8.5614e-1 (1.13e-2) +	8.6116e-1 (1.38e-2) +	8.5730e-1 (1.49e-2) +	8.4490e-1 (1.68e-2)
	100	2	50000	8.5675e-1 (1.54e-2) ≈	8.6612e-1 (1.29e-2) +	8.6501e-1 (1.00e-2) +	8.6281e-1 (9.61e-3) ≈	8.5592e-1 (1.75e-2)
MAP4	100	2	10000	8.2410e-1 (1.28e-2) ≈	8.1490e-1 (1.71e-2) ≈	8.2722e-1 (1.65e-2) ≈	8.2551e-1 (1.31e-2) ≈	8.1923e-1 (2.54e-2)
	100	2	20000	8.4766e-1 (1.40e-2) +	8.4347e-1 (1.01e-2) +	8.4019e-1 (1.98e-2) ≈	8.4501e-1 (1.51e-2) +	8.3003e-1 (1.94e-2)
	100	2	50000	8.5785e-1 (1.27e-2) +	8.5923e-1 (1.20e-2) +	8.6061e-1 (1.18e-2) +	8.4926e-1 (1.26e-2) ≈	8.4209e-1 (2.28e-2)
MAP5	100	2	10000	8.5647e-1 (1.46e-2) +	8.5118e-1 (1.48e-2) ≈	8.5675e-1 (1.21e-2) +	8.5259e-1 (1.32e-2) ≈	8.4242e-1 (2.06e-2)
	100	2	20000	8.6088e-1 (1.27e-2) +	8.6915e-1 (9.23e-3) +	8.6419e-1 (1.06e-2) +	8.6639e-1 (9.73e-3) +	8.4738e-1 (2.02e-2)
	100	2	50000	8.6749e-1 (1.29e-2) ≈	8.7493e-1 (1.01e-2) +	8.7355e-1 (1.51e-2) +	8.6446e-1 (1.42e-2) ≈	8.6006e-1 (1.99e-2)
MAP6	100	2	10000	8.1471e-1 (1.65e-2) ≈	7.9967e-1 (1.54e-2) ≈	8.1413e-1 (1.71e-2) ≈	8.1424e-1 (2.15e-2) ≈	8.0275e-1 (2.19e-2)
	100	2	20000	8.3835e-1 (2.08e-2) +	8.3306e-1 (1.43e-2) +	8.3581e-1 (1.68e-2) +	8.3364e-1 (2.14e-2) +	8.2011e-1 (1.77e-2)
	100	2	50000	8.4187e-1 (1.48e-2) +	8.5758e-1 (1.16e-2) +	8.5562e-1 (1.61e-2) +	8.4507e-1 (1.75e-2) +	8.3912e-1 (1.88e-2)
MAP7	100	2	10000	7.9669e-1 (1.50e-2) ≈	7.8992e-1 (1.42e-2) -	7.9868e-1 (2.00e-2) ≈	8.0198e-1 (2.03e-2) ≈	7.9832e-1 (2.67e-2)
	100	2	20000	8.2771e-1 (1.95e-2) +	8.2449e-1 (1.72e-2) +	8.2672e-1 (2.15e-2) +	8.2879e-1 (1.83e-2) +	8.1543e-1 (2.29e-2)
	100	2	50000	8.4573e-1 (2.38e-2) +	8.4672e-1 (1.32e-2) +	8.4738e-1 (1.16e-2) +	8.3719e-1 (1.86e-2) +	8.2612e-1 (1.97e-2)
MAP8	100	2	10000	8.0102e-1 (1.48e-2) ≈	7.8661e-1 (2.00e-2) ≈	7.9477e-1 (2.04e-2) ≈	7.9736e-1 (2.50e-2) ≈	7.9413e-1 (4.25e-2)
	100	2	20000	8.3000e-1 (1.64e-2) +	8.1419e-1 (1.54e-2) +	8.2292e-1 (1.93e-2) +	8.2143e-1 (1.83e-2) +	8.1028e-1 (2.97e-2)
	100	2	50000	8.4187e-1 (1.47e-2) +	8.4402e-1 (1.38e-2) +	8.4463e-1 (1.36e-2) +	8.4314e-1 (1.52e-2) +	8.2835e-1 (1.98e-2)
MAP9	100	2	10000	7.8565e-1 (1.92e-2) ≈	7.7127e-1 (1.34e-2) -	7.7942e-1 (1.60e-2) ≈	7.7713e-1 (1.30e-2) ≈	7.7972e-1 (3.93e-2)
	100	2	20000	8.1639e-1 (1.50e-2) +	8.0477e-1 (1.65e-2) +	8.1658e-1 (1.84e-2) +	8.1140e-1 (2.10e-2) +	7.9336e-1 (2.22e-2)
	100	2	50000	8.3829e-1 (1.93e-2) +	8.3416e-1 (1.30e-2) +	8.3601e-1 (1.90e-2) +	8.3802e-1 (1.65e-2) +	8.1815e-1 (2.20e-2)
MAP10	100	2	10000	8.4680e-1 (1.61e-2) +	8.3686e-1 (1.17e-2) ≈	8.4185e-1 (1.30e-2) ≈	8.4645e-1 (1.23e-2) ≈	8.3306e-1 (1.71e-2)
	100	2	20000	8.5647e-1 (1.22e-2) +	8.6058e-1 (1.22e-2) +	8.6006e-1 (1.23e-2) +	8.5311e-1 (1.59e-2) +	8.3521e-1 (1.92e-2)
	100	2	50000	8.6667e-1 (1.16e-2) +	8.7080e-1 (1.14e-2) +	8.6694e-1 (1.31e-2) +	8.6088e-1 (1.61e-2) ≈	8.5317e-1 (1.59e-2)
				+/-/≈	20/0/10	18/2/10	22/0/8	14/0/16

Tabela A.28: Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Energia em relação ao *grid* de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	9.4928e+1 (1.40e+0) –	9.4496e+1 (1.04e+0) ≈	9.5060e+1 (1.18e+0) –	9.4662e+1 (1.52e+0) ≈	9.3899e+1 (1.50e+0)
	100	2	20000	9.5193e+1 (1.42e+0) –	9.5459e+1 (1.27e+0) –	9.5791e+1 (1.58e+0) –	9.5027e+1 (1.27e+0) –	9.4264e+1 (1.50e+0)
	100	2	50000	9.5459e+1 (2.26e+0) ≈	9.7218e+1 (9.21e-1) –	9.6620e+1 (1.64e+0) –	9.5558e+1 (1.61e+0) ≈	9.4563e+1 (2.29e+0)
MAP2	100	2	10000	9.1610e+1 (1.92e+0) –	9.0880e+1 (2.10e+0) ≈	9.1909e+1 (2.17e+0) –	9.1676e+1 (1.65e+0) –	9.0151e+1 (2.54e+0)
	100	2	20000	9.3070e+1 (1.64e+0) –	9.3733e+1 (1.61e+0) –	9.3965e+1 (1.52e+0) –	9.3269e+1 (1.74e+0) –	9.1411e+1 (1.95e+0)
	100	2	50000	9.4695e+1 (1.55e+0) –	9.5260e+1 (1.23e+0) –	9.4530e+1 (2.41e+0) –	9.4098e+1 (1.72e+0) ≈	9.3236e+1 (2.08e+0)
MAP3	100	2	10000	9.2439e+1 (1.97e+0) ≈	9.1577e+1 (2.07e+0) ≈	9.2705e+1 (1.81e+0) –	9.2307e+1 (1.75e+0) ≈	9.1179e+1 (2.63e+0)
	100	2	20000	9.3932e+1 (1.88e+0) –	9.3965e+1 (1.52e+0) –	9.4629e+1 (1.66e+0) –	9.4165e+1 (1.79e+0) –	9.2672e+1 (2.02e+0)
	100	2	50000	9.4098e+1 (1.85e+0) ≈	9.5226e+1 (1.56e+0) –	9.5094e+1 (1.21e+0) –	9.4828e+1 (1.16e+0) ≈	9.3999e+1 (2.10e+0)
MAP4	100	2	10000	9.0018e+1 (1.79e+0) ≈	8.8791e+1 (2.43e+0) ≈	9.0482e+1 (2.08e+0) ≈	9.0217e+1 (1.67e+0) ≈	8.9916e+1 (2.77e+0)
	100	2	20000	9.3003e+1 (1.69e+0) –	9.2439e+1 (1.23e+0) –	9.2075e+1 (2.40e+0) ≈	9.2506e+1 (2.14e+0) –	9.0880e+1 (2.33e+0)
	100	2	50000	9.4231e+1 (1.53e+0) –	9.4397e+1 (1.44e+0) –	9.4563e+1 (1.43e+0) –	9.3136e+1 (1.59e+0) ≈	9.2669e+1 (1.99e+0)
MAP5	100	2	10000	9.4065e+1 (1.76e+0) –	9.3368e+1 (1.85e+0) ≈	9.4098e+1 (1.46e+0) –	9.3567e+1 (1.63e+0) –	9.2373e+1 (2.48e+0)
	100	2	20000	9.4596e+1 (1.53e+0) –	9.5591e+1 (1.11e+0) –	9.4994e+1 (1.27e+0) –	9.5260e+1 (1.17e+0) –	9.2970e+1 (2.44e+0)
	100	2	50000	9.5392e+1 (1.56e+0) ≈	9.6288e+1 (1.22e+0) –	9.6122e+1 (1.81e+0) –	9.5027e+1 (1.71e+0) ≈	9.4496e+1 (1.92e+0)
MAP6	100	2	10000	8.8857e+1 (2.08e+0) ≈	8.6569e+1 (2.45e+0) ≈	8.8758e+1 (2.25e+0) ≈	8.8891e+1 (2.74e+0) ≈	8.7597e+1 (2.63e+0)
	100	2	20000	9.1643e+1 (2.83e+0) –	9.1245e+1 (1.72e+0) –	9.1577e+1 (2.02e+0) –	9.1046e+1 (2.83e+0) –	8.9686e+1 (2.13e+0)
	100	2	50000	9.2307e+1 (1.79e+0) ≈	9.4198e+1 (1.40e+0) –	9.3932e+1 (1.99e+0) –	9.2572e+1 (2.24e+0) ≈	9.1975e+1 (2.26e+0)
MAP7	100	2	10000	8.6304e+1 (2.02e+0) ≈	8.5575e+1 (2.11e+0) +	8.6868e+1 (2.59e+0) ≈	8.7266e+1 (2.64e+0) ≈	8.7163e+1 (2.27e+0)
	100	2	20000	9.0482e+1 (2.66e+0) –	9.0184e+1 (2.06e+0) –	9.0482e+1 (2.59e+0) –	9.0582e+1 (2.52e+0) –	8.9123e+1 (2.76e+0)
	100	2	50000	9.2771e+1 (2.87e+0) –	9.2771e+1 (1.68e+0) –	9.2970e+1 (1.40e+0) –	9.1743e+1 (2.24e+0) –	9.0350e+1 (2.47e+0)
MAP8	100	2	10000	8.7000e+1 (2.17e+0) ≈	8.4879e+1 (2.96e+0) +	8.6337e+1 (2.69e+0) ≈	8.6931e+1 (2.52e+0) ≈	8.7817e+1 (3.39e+0)
	100	2	20000	9.0847e+1 (2.02e+0) –	8.8526e+1 (2.53e+0) ≈	8.9786e+1 (2.74e+0) ≈	8.9786e+1 (2.30e+0) ≈	8.9116e+1 (2.44e+0)
	100	2	50000	9.2307e+1 (1.77e+0) –	9.2506e+1 (1.75e+0) –	9.2638e+1 (1.64e+0) –	9.2340e+1 (1.96e+0) –	9.0648e+1 (2.39e+0)
MAP9	100	2	10000	8.5509e+1 (2.33e+0) ≈	8.2824e+1 (2.89e+0) +	8.4017e+1 (2.67e+0) +	8.3686e+1 (2.54e+0) +	8.5989e+1 (2.79e+0)
	100	2	20000	8.8493e+1 (3.02e+0) –	8.7630e+1 (1.97e+0) –	8.9023e+1 (2.39e+0) –	8.8161e+1 (3.15e+0) –	8.6437e+1 (2.70e+0)
	100	2	50000	9.1875e+1 (2.32e+0) –	9.1378e+1 (1.57e+0) –	9.1511e+1 (2.41e+0) –	9.1842e+1 (1.98e+0) –	8.9783e+1 (2.19e+0)
MAP10	100	2	10000	9.2871e+1 (2.00e+0) –	9.1643e+1 (1.42e+0) ≈	9.2273e+1 (1.59e+0) ≈	9.2738e+1 (1.68e+0) ≈	9.1245e+1 (2.06e+0)
	100	2	20000	9.4065e+1 (1.47e+0) –	9.4530e+1 (1.51e+0) –	9.4496e+1 (1.48e+0) –	9.3601e+1 (1.92e+0) –	9.1444e+1 (2.92e+0)
	100	2	50000	9.5293e+1 (1.40e+0) –	9.5790e+1 (1.37e+0) –	9.5326e+1 (1.58e+0) –	9.4596e+1 (1.94e+0) ≈	9.3667e+1 (1.92e+0)
				+/-/≈	0/20/10	3/18/9	1/22/7	1/14/15

Tabela A.29: Resultados para o cálculo do *Hypervolume* para as métricas de Tolerância a Falhas e Comunicação em relação ao *grid* de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	7.3482e-1 (8.89e-3) –	7.3277e-1 (6.83e-3) –	7.3277e-1 (8.65e-3) –	7.3681e-1 (1.49e-2) ≈	7.4137e-1 (8.05e-3)
	100	2	20000	7.4962e-1 (9.76e-3) ≈	7.4688e-1 (7.30e-3) –	7.4946e-1 (6.24e-3) ≈	7.3828e-1 (3.35e-2) –	7.5297e-1 (8.22e-3)
	100	2	50000	7.5769e-1 (6.79e-3) ≈	7.5781e-1 (5.99e-3) ≈	7.5801e-1 (5.93e-3) ≈	7.2855e-1 (3.61e-2) –	7.5908e-1 (6.88e-3)
MAP2	100	2	10000	6.5957e-1 (1.94e-2) ≈	6.5240e-1 (1.70e-2) –	6.6754e-1 (1.14e-2) ≈	6.5796e-1 (2.13e-2) ≈	6.5802e-1 (3.10e-2)
	100	2	20000	6.7914e-1 (1.36e-2) ≈	6.7857e-1 (7.81e-3) +	6.7962e-1 (1.87e-2) ≈	6.8175e-1 (1.55e-2) ≈	6.7849e-1 (2.88e-2)
	100	2	50000	6.9884e-1 (1.38e-2) ≈	6.9957e-1 (9.54e-3) ≈	6.9898e-1 (1.84e-2) –	6.8100e-1 (3.11e-2) –	6.9891e-1 (1.85e-2)
MAP3	100	2	10000	6.9260e-1 (1.67e-2) –	6.8922e-1 (9.95e-3) –	6.9683e-1 (8.95e-3) ≈	6.9334e-1 (9.77e-3) –	6.9529e-1 (2.66e-2)
	100	2	20000	7.1595e-1 (8.72e-3) ≈	7.0672e-1 (9.14e-3) –	7.1242e-1 (8.48e-3) –	7.0714e-1 (1.91e-2) –	7.1586e-1 (2.25e-2)
	100	2	50000	7.2775e-1 (8.56e-3) ≈	7.2795e-1 (9.00e-3) ≈	7.3070e-1 (7.77e-3) ≈	6.9324e-1 (3.90e-2) –	7.2400e-1 (2.30e-2)
MAP4	100	2	10000	6.3876e-1 (2.48e-2) ≈	6.2728e-1 (2.41e-2) ≈	6.3707e-1 (2.48e-2) ≈	6.3845e-1 (2.16e-2) ≈	6.3744e-1 (3.28e-2)
	100	2	20000	6.5479e-1 (2.43e-2) ≈	6.5162e-1 (1.86e-2) ≈	6.6176e-1 (2.32e-2) ≈	6.4988e-1 (2.39e-2) ≈	6.4519e-1 (3.35e-2)
	100	2	50000	6.7651e-1 (2.27e-2) ≈	6.8415e-1 (1.56e-2) ≈	6.8197e-1 (1.53e-2) ≈	6.4876e-1 (3.44e-2) –	6.7531e-1 (3.18e-2)
MAP5	100	2	10000	7.3134e-1 (7.52e-3) ≈	7.2123e-1 (7.65e-3) –	7.2582e-1 (1.05e-2) –	7.2619e-1 (1.57e-2) –	7.3914e-1 (9.33e-3)
	100	2	20000	7.4195e-1 (8.06e-3) ≈	7.3805e-1 (5.59e-3) –	7.4181e-1 (8.01e-3) ≈	7.3313e-1 (2.61e-2) –	7.4610e-1 (8.48e-3)
	100	2	50000	7.4896e-1 (9.09e-3) ≈	7.4988e-1 (8.38e-3) ≈	7.5560e-1 (6.51e-3) ≈	7.2576e-1 (3.61e-2) –	7.5248e-1 (8.37e-3)
MAP6	100	2	10000	6.1944e-1 (2.99e-2) ≈	6.1761e-1 (1.68e-2) –	6.2008e-1 (2.44e-2) –	6.1902e-1 (2.63e-2) ≈	6.2691e-1 (2.90e-2)
	100	2	20000	6.4325e-1 (2.67e-2) ≈	6.3601e-1 (2.22e-2) ≈	6.4975e-1 (2.07e-2) ≈	6.3705e-1 (2.96e-2) ≈	6.4550e-1 (3.26e-2)
	100	2	50000	6.6330e-1 (2.56e-2) –	6.6550e-1 (2.36e-2) –	6.6264e-1 (2.49e-2) –	6.5263e-1 (3.30e-2) –	6.7402e-1 (2.75e-2)
MAP7	100	2	10000	5.7957e-1 (2.90e-2) ≈	5.7660e-1 (2.75e-2) –	5.8240e-1 (2.77e-2) ≈	5.7598e-1 (2.44e-2) ≈	5.8599e-1 (2.58e-2)
	100	2	20000	6.2081e-1 (2.83e-2) ≈	6.0528e-1 (2.40e-2) ≈	6.0966e-1 (2.81e-2) ≈	6.1799e-1 (2.60e-2) ≈	6.1035e-1 (2.67e-2)
	100	2	50000	6.4787e-1 (2.17e-2) ≈	6.3111e-1 (3.01e-2) ≈	6.3895e-1 (2.95e-2) ≈	6.3230e-1 (2.99e-2) ≈	6.2585e-1 (3.78e-2)
MAP8	100	2	10000	5.8448e-1 (3.01e-2) ≈	5.7106e-1 (2.78e-2) –	5.7712e-1 (2.74e-2) –	5.7950e-1 (2.76e-2) ≈	5.8567e-1 (2.55e-2)
	100	2	20000	5.9752e-1 (2.90e-2) ≈	5.8737e-1 (2.74e-2) –	6.0684e-1 (3.12e-2) ≈	6.0689e-1 (2.75e-2) ≈	6.0256e-1 (2.92e-2)
	100	2	50000	6.3090e-1 (2.89e-2) ≈	6.3282e-1 (2.55e-2) ≈	6.3899e-1 (2.26e-2) ≈	6.1980e-1 (3.01e-2) ≈	6.2683e-1 (3.30e-2)
MAP9	100	2	10000	5.3838e-1 (2.08e-2) –	5.3645e-1 (2.63e-2) –	5.4446e-1 (1.99e-2) –	5.4194e-1 (2.15e-2) –	5.5237e-1 (1.52e-2)
	100	2	20000	5.6962e-1 (2.94e-2) –	5.6408e-1 (2.52e-2) –	5.7291e-1 (2.91e-2) ≈	5.6801e-1 (2.32e-2) –	5.8483e-1 (2.91e-2)
	100	2	50000	6.0659e-1 (3.23e-2) ≈	6.0990e-1 (2.56e-2) ≈	5.9911e-1 (2.68e-2) –	6.0348e-1 (2.95e-2) –	6.0909e-1 (3.10e-2)
MAP10	100	2	10000	6.9634e-1 (1.47e-2) ≈	6.9032e-1 (8.21e-3) –	6.9748e-1 (9.80e-3) ≈	7.0023e-1 (1.20e-2) ≈	6.9311e-1 (2.99e-2)
	100	2	20000	7.1221e-1 (1.21e-2) –	7.0856e-1 (9.70e-3) –	7.1212e-1 (1.15e-2) –	7.0940e-1 (1.58e-2) –	7.1570e-1 (2.11e-2)
	100	2	50000	7.2557e-1 (1.01e-2) –	7.2936e-1 (7.22e-3) –	7.2985e-1 (1.03e-2) ≈	6.9136e-1 (3.59e-2) –	7.3235e-1 (1.88e-2)
				+/-/≈	0/8/22	1/14/15	0/6/24	0/15/15

Tabela A.30: Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Comunicação em relação ao grid de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	N	M	FE	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	1.1565e+3 (2.35e+1) +	1.1467e+3 (2.01e+1) +	1.1520e+3 (2.08e+1) +	1.1547e+3 (4.92e+1) ≈	1.1729e+3 (2.09e+1)
	100	2	20000	1.1880e+3 (2.55e+1) ≈	1.1777e+3 (2.30e+1) ≈	1.1841e+3 (1.72e+1) ≈	1.1865e+3 (2.22e+1) ≈	1.1900e+3 (2.28e+1)
	100	2	50000	1.2022e+3 (2.23e+1) ≈	1.2034e+3 (1.81e+1) ≈	1.2079e+3 (1.63e+1) ≈	1.2050e+3 (2.19e+1) ≈	1.2086e+3 (1.65e+1)
MAP2	100	2	10000	1.0097e+3 (4.05e+1) +	9.6809e+2 (3.63e+1) +	1.0035e+3 (3.76e+1) +	1.0032e+3 (4.73e+1) +	1.0590e+3 (3.89e+1)
	100	2	20000	1.0477e+3 (3.13e+1) +	1.0184e+3 (3.02e+1) +	1.0465e+3 (3.27e+1) +	1.0345e+3 (3.71e+1) +	1.0743e+3 (3.52e+1)
	100	2	50000	1.0813e+3 (2.93e+1) ≈	1.0613e+3 (3.17e+1) +	1.0792e+3 (3.10e+1) ≈	1.0892e+3 (3.72e+1) ≈	1.0929e+3 (2.56e+1)
MAP3	100	2	10000	1.0537e+3 (3.88e+1) +	1.0414e+3 (3.17e+1) +	1.0608e+3 (2.76e+1) +	1.0590e+3 (2.54e+1) +	1.1052e+3 (4.12e+1)
	100	2	20000	1.1096e+3 (2.38e+1) ≈	1.0815e+3 (2.61e+1) +	1.1053e+3 (2.18e+1) ≈	1.1034e+3 (3.25e+1) ≈	1.1218e+3 (3.96e+1)
	100	2	50000	1.1299e+3 (3.06e+1) +	1.1339e+3 (2.69e+1) +	1.1488e+3 (2.75e+1) ≈	1.1436e+3 (3.11e+1) ≈	1.1520e+3 (3.26e+1)
MAP4	100	2	10000	9.4596e+2 (6.57e+1) +	9.2631e+2 (5.14e+1) +	9.6369e+2 (4.44e+1) +	9.5938e+2 (4.40e+1) +	1.0396e+3 (4.27e+1)
	100	2	20000	1.0151e+3 (4.83e+1) +	9.8395e+2 (3.96e+1) +	1.0092e+3 (3.36e+1) +	1.0207e+3 (4.77e+1) +	1.0537e+3 (4.65e+1)
	100	2	50000	1.0446e+3 (4.22e+1) +	1.0419e+3 (2.99e+1) +	1.0442e+3 (3.22e+1) +	1.0740e+3 (4.15e+1) ≈	1.0773e+3 (2.63e+1)
MAP5	100	2	10000	1.1338e+3 (2.96e+1) +	1.1219e+3 (2.30e+1) +	1.1332e+3 (2.58e+1) +	1.1271e+3 (2.68e+1) +	1.1633e+3 (2.25e+1)
	100	2	20000	1.1658e+3 (2.64e+1) +	1.1525e+3 (2.56e+1) +	1.1649e+3 (2.40e+1) +	1.1608e+3 (2.60e+1) +	1.1777e+3 (2.10e+1)
	100	2	50000	1.1825e+3 (2.14e+1) ≈	1.1805e+3 (2.43e+1) ≈	1.1930e+3 (2.01e+1) ≈	1.1768e+3 (3.82e+1) ≈	1.1913e+3 (2.36e+1)
MAP6	100	2	10000	9.4858e+2 (4.54e+1) +	8.8399e+2 (5.61e+1) +	9.4411e+2 (4.40e+1) +	9.2439e+2 (5.88e+1) +	1.0304e+3 (4.05e+1)
	100	2	20000	9.9479e+2 (4.54e+1) +	9.6348e+2 (4.55e+1) +	9.8554e+2 (4.25e+1) +	9.8975e+2 (3.96e+1) +	1.0459e+3 (4.14e+1)
	100	2	50000	1.0364e+3 (4.36e+1) +	1.0213e+3 (3.89e+1) +	1.0448e+3 (3.84e+1) ≈	1.0495e+3 (4.44e+1) ≈	1.0611e+3 (4.25e+1)
MAP7	100	2	10000	8.9931e+2 (5.92e+1) +	8.4200e+2 (7.91e+1) +	8.9248e+2 (5.56e+1) +	9.1793e+2 (5.41e+1) +	9.8019e+2 (4.50e+1)
	100	2	20000	9.3822e+2 (5.19e+1) +	9.0232e+2 (6.67e+1) +	9.3079e+2 (6.17e+1) +	9.4363e+2 (5.25e+1) +	1.0088e+3 (4.34e+1)
	100	2	50000	9.7785e+2 (4.64e+1) +	9.7063e+2 (5.36e+1) +	1.0013e+3 (3.57e+1) +	1.0012e+3 (4.91e+1) ≈	1.0212e+3 (4.13e+1)
MAP8	100	2	10000	8.9444e+2 (4.93e+1) +	8.5315e+2 (6.51e+1) +	8.8519e+2 (4.84e+1) +	8.9017e+2 (6.52e+1) +	9.7620e+2 (4.72e+1)
	100	2	20000	9.4544e+2 (4.74e+1) +	9.1766e+2 (6.02e+1) +	9.3760e+2 (4.72e+1) +	9.3783e+2 (5.09e+1) +	1.0047e+3 (4.01e+1)
	100	2	50000	9.9253e+2 (4.49e+1) ≈	9.3746e+2 (9.26e+1) +	9.8543e+2 (5.20e+1) +	9.8717e+2 (5.30e+1) +	1.0168e+3 (4.20e+1)
MAP9	100	2	10000	8.6388e+2 (4.27e+1) +	8.0683e+2 (7.48e+1) +	8.7040e+2 (5.06e+1) +	8.7121e+2 (4.48e+1) +	9.4065e+2 (2.89e+1)
	100	2	20000	9.0232e+2 (4.81e+1) +	8.7235e+2 (7.04e+1) +	9.3079e+2 (5.37e+1) +	9.1806e+2 (4.85e+1) +	9.4769e+2 (4.16e+1)
	100	2	50000	9.4929e+2 (6.14e+1) +	9.1306e+2 (5.68e+1) +	9.5312e+2 (4.83e+1) +	9.4886e+2 (6.72e+1) +	9.9619e+2 (5.89e+1)
MAP10	100	2	10000	1.0704e+3 (2.78e+1) +	1.0427e+3 (2.45e+1) +	1.0669e+3 (3.56e+1) +	1.0654e+3 (3.21e+1) +	1.1097e+3 (3.94e+1)
	100	2	20000	1.1003e+3 (3.04e+1) +	1.0890e+3 (2.89e+1) +	1.0998e+3 (3.06e+1) +	1.1017e+3 (3.02e+1) +	1.1273e+3 (3.62e+1)
	100	2	50000	1.1277e+3 (3.02e+1) +	1.1330e+3 (2.51e+1) +	1.1432e+3 (2.81e+1) ≈	1.1338e+3 (2.97e+1) +	1.1539e+3 (3.02e+1)
+/-/≈				24/0/6	27/0/3	22/0/8	20/0/10	

Tabela A.31: Resultados para o cálculo do Hypervolume para as métricas de Comunicação e Energia em relação ao grid de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	N	M	FE	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	7.6155e-1 (1.07e-2) ≈	7.5098e-1 (1.13e-2) -	7.6346e-1 (1.42e-2) ≈	7.6093e-1 (1.51e-2) ≈	7.6606e-1 (1.74e-2)
	100	2	20000	7.8390e-1 (1.66e-2) ≈	7.7992e-1 (1.48e-2) -	7.9026e-1 (1.29e-2) ≈	7.5566e-1 (2.16e-2) -	7.8861e-1 (1.34e-2)
	100	2	50000	8.0134e-1 (1.43e-2) ≈	7.9814e-1 (1.53e-2) ≈	8.0441e-1 (1.36e-2) +	7.4198e-1 (1.86e-2) -	7.9653e-1 (1.53e-2)
MAP2	100	2	10000	6.7154e-1 (1.45e-2) -	6.6098e-1 (1.39e-2) -	6.7410e-1 (1.15e-2) -	6.7155e-1 (1.53e-2) -	6.9009e-1 (1.53e-2)
	100	2	20000	6.9634e-1 (1.21e-2) -	6.9074e-1 (1.21e-2) -	6.9929e-1 (1.79e-2) -	6.9688e-1 (1.65e-2) -	7.1086e-1 (1.75e-2)
	100	2	50000	7.2811e-1 (1.30e-2) ≈	7.2218e-1 (1.41e-2) ≈	7.3790e-1 (1.34e-2) ≈	6.8592e-1 (2.21e-2) -	7.2933e-1 (1.68e-2)
MAP3	100	2	10000	7.1080e-1 (1.46e-2) -	6.9511e-1 (1.53e-2) -	7.1492e-1 (1.50e-2) ≈	7.0675e-1 (1.44e-2) -	7.1854e-1 (1.22e-2)
	100	2	20000	7.3516e-1 (1.71e-2) ≈	7.2608e-1 (1.42e-2) -	7.4042e-1 (1.29e-2) -	7.2058e-1 (2.68e-2) -	7.4070e-1 (1.77e-2)
	100	2	50000	7.5759e-1 (1.60e-2) ≈	7.5780e-1 (1.18e-2) ≈	7.6501e-1 (1.31e-2) +	7.1902e-1 (2.39e-2) -	7.5632e-1 (1.71e-2)
MAP4	100	2	10000	6.4346e-1 (1.35e-2) -	6.3517e-1 (1.72e-2) -	6.4852e-1 (1.34e-2) -	6.4210e-1 (1.04e-2) -	6.6459e-1 (1.33e-2)
	100	2	20000	6.7534e-1 (1.58e-2) -	6.6101e-1 (1.19e-2) -	6.8153e-1 (1.32e-2) ≈	6.7191e-1 (1.43e-2) -	6.8874e-1 (1.66e-2)
	100	2	50000	7.1047e-1 (1.72e-2) ≈	7.0501e-1 (1.56e-2) -	7.1457e-1 (1.29e-2) ≈	6.8034e-1 (2.41e-2) -	7.1490e-1 (1.84e-2)
MAP5	100	2	10000	7.4843e-1 (1.43e-2) -	7.3562e-1 (1.15e-2) -	7.4853e-1 (1.43e-2) -	7.4220e-1 (1.48e-2) -	7.5773e-1 (1.26e-2)
	100	2	20000	7.6811e-1 (1.34e-2) ≈	7.6873e-1 (1.44e-2) ≈	7.7544e-1 (1.35e-2) ≈	7.5123e-1 (2.40e-2) -	7.7170e-1 (1.38e-2)
	100	2	50000	7.8776e-1 (1.24e-2) ≈	7.9330e-1 (8.87e-3) +	7.9434e-1 (1.19e-2) +	7.3865e-1 (1.66e-2) -	7.8420e-1 (1.13e-2)
MAP6	100	2	10000	6.2746e-1 (1.09e-2) -	6.1402e-1 (1.42e-2) -	6.3087e-1 (1.21e-2) -	6.2883e-1 (1.23e-2) -	6.4999e-1 (1.56e-2)
	100	2	20000	6.6157e-1 (1.53e-2) ≈	6.4623e-1 (1.27e-2) -	6.6048e-1 (1.43e-2) -	6.5964e-1 (1.47e-2) -	6.7222e-1 (1.70e-2)
	100	2	50000	6.9818e-1 (1.25e-2) ≈	6.8391e-1 (1.52e-2) -	6.9918e-1 (1.36e-2) ≈	6.8157e-1 (2.09e-2) -	6.6988e-1 (1.65e-2)
MAP7	100	2	10000	5.9775e-1 (1.27e-2) -	5.8792e-1 (1.53e-2) -	6.0562e-1 (1.09e-2) -	5.9989e-1 (1.06e-2) -	6.2219e-1 (1.94e-2)
	100	2	20000	6.3801e-1 (1.51e-2) -	6.1769e-1 (9.90e-3) -	6.3826e-1 (1.22e-2) -	6.3158e-1 (1.52e-2) -	6.4837e-1 (1.41e-2)
	100	2	50000	6.6413e-1 (1.57e-2) ≈	6.5845e-1 (1.36e-2) -	6.7026e-1 (1.40e-2) ≈	6.5747e-1 (1.86e-2) -	6.6988e-1 (1.70e-2)
MAP8	100	2	10000	5.9245e-1 (1.31e-2) -	5.8097e-1 (1.47e-2) -	5.9789e-1 (8.36e-3) -	5.9504e-1 (1.31e-2) -	6.1447e-1 (1.30e-2)
	100	2	20000	6.2685e-1 (1.15e-2) -	6.1313e-1 (1.14e-2) -	6.2836e-1 (1.46e-2) -	6.1974e-1 (1.35e-2) -	6.3996e-1 (2.01e-2)
	100	2	50000	6.6183e-1 (1.37e-2) ≈	6.5269e-1 (1.55e-2) -	6.6624e-1 (1.69e-2) ≈	6.4824e-1 (2.60e-2) -	6.6522e-1 (1.83e-2)
MAP9	100	2	10000	5.6726e-1 (1.51e-2) -	5.5018e-1 (1.18e-2) -	5.6855e-1 (1.31e-2) -	5.6083e-1 (1.26e-2) -	5.9021e-1 (1.55e-2)
	100	2	20000	5.9780e-1 (1.63e-2) -	5.8579e-1 (1.27e-2) -	6.0987e-1 (1.59e-2) ≈	5.9445e-1 (1.19e-2) -	6.1728e-1 (1.47e-2)
	100	2	50000	6.3563e-1 (1.36e-2) -	6.2530e-1 (1.20e-2) -	6.4155e-1 (1.72e-2) -	6.3605e-1 (2.02e-2) -	6.4971e-1 (1.73e-2)
MAP10	100	2	10000	7.0568e-1 (1.35e-2) -	6.9091e-1 (1.33e-2) -	7.1234e-1 (1.18e-2) -	7.0243e-1 (1.39e-2) -	7.2176e-1 (1.29e-2)
	100	2	20000	7.3054e-1 (1.37e-2) -	7.2744e-1 (1.47e-2) -	7.4148e-1 (1.41e-2) ≈	7.2739e-1 (1.74e-2) -	7.3929e-1 (1.64e-2)
	100	2	50000	7.6097e-1 (1.26e-2) ≈	7.5830e-1 (1.23e-2) ≈	7.6439e-1 (1.65e-2) ≈	7.1805e-1 (2.50e-2) -	7.6445e-1 (1.27e-2)
+/-/≈				0/17/13	1/24/5	3/13/14	0/29/1	

Tabela A.32: Resultados para o cálculo do IGD para as métricas de Comunicação e Energia em relação ao *grid* de tamanho 4x4, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAI	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	1.4081e+3 (9.62e+1) +	1.4175e+3 (1.09e+2) +	1.3732e+3 (1.18e+2) +	1.4232e+3 (9.89e+1) +	1.5376e+3 (6.63e+1)
	100	2	20000	1.4540e+3 (9.80e+1) +	1.4470e+3 (1.12e+2) +	1.4291e+3 (9.08e+1) +	1.5859e+3 (5.98e+1) -	1.5152e+3 (7.28e+1)
	100	2	50000	1.4915e+3 (8.19e+1) ≈	1.5096e+3 (8.34e+1) ≈	1.5071e+3 (6.39e+1) ≈	1.6457e+3 (4.42e+1) -	1.5211e+3 (8.03e+1)
MAP2	100	2	10000	1.1510e+3 (1.51e+2) +	1.0933e+3 (1.25e+2) +	1.0583e+3 (2.11e+2) +	1.1506e+3 (1.97e+2) +	1.3871e+3 (9.19e+1)
	100	2	20000	1.2801e+3 (1.09e+2) +	1.1592e+3 (1.58e+2) +	1.2297e+3 (1.65e+2) +	1.2578e+3 (1.30e+2) +	1.3945e+3 (8.37e+1)
	100	2	50000	1.3122e+3 (1.30e+2) +	1.3331e+3 (1.26e+2) +	1.2865e+3 (8.95e+1) +	1.5003e+3 (8.04e+1) -	1.4009e+3 (7.81e+1)
MAP3	100	2	10000	1.3031e+3 (1.40e+2) +	1.2464e+3 (1.69e+2) +	1.2418e+3 (1.51e+2) +	1.3014e+3 (1.33e+2) +	1.4566e+3 (6.60e+1)
	100	2	20000	1.3859e+3 (1.16e+2) +	1.3200e+3 (1.45e+2) +	1.2934e+3 (1.09e+2) +	1.4270e+3 (1.24e+2) +	1.4487e+3 (1.06e+2)
	100	2	50000	1.4347e+3 (9.02e+1) +	1.4214e+3 (1.10e+2) +	1.4102e+3 (8.76e+1) +	1.5626e+3 (6.86e+1) -	1.5040e+3 (1.03e+2)
MAP4	100	2	10000	1.1055e+3 (1.87e+2) +	9.9411e+2 (2.00e+2) +	1.0186e+3 (1.36e+2) +	1.0760e+3 (1.60e+2) +	1.2974e+3 (1.42e+2)
	100	2	20000	1.2332e+3 (1.54e+2) +	1.1614e+3 (2.06e+2) +	1.1453e+3 (1.26e+2) +	1.1681e+3 (1.79e+2) +	1.3538e+3 (1.30e+2)
	100	2	50000	1.2899e+3 (1.25e+2) +	1.2090e+3 (1.63e+2) +	1.2378e+3 (1.17e+2) +	1.4223e+3 (1.06e+2) ≈	1.4034e+3 (9.22e+1)
MAP5	100	2	10000	1.3352e+3 (1.22e+2) +	1.3226e+3 (1.46e+2) +	1.3185e+3 (1.50e+2) +	1.4245e+3 (1.22e+2) +	1.4984e+3 (8.64e+1)
	100	2	20000	1.4720e+3 (8.03e+1) +	1.3608e+3 (1.52e+2) +	1.4019e+3 (1.07e+2) +	1.5047e+3 (1.07e+2) ≈	1.5227e+3 (8.75e+1)
	100	2	50000	1.5063e+3 (7.80e+1) ≈	1.4684e+3 (9.20e+1) +	1.4667e+3 (9.37e+1) +	1.6343e+3 (5.21e+1) -	1.5316e+3 (1.00e+2)
MAP6	100	2	10000	1.0423e+3 (1.68e+2) +	1.0154e+3 (1.93e+2) +	1.0005e+3 (2.14e+2) +	1.1144e+3 (1.44e+2) +	1.2631e+3 (8.92e+1)
	100	2	20000	1.1775e+3 (1.58e+2) +	1.0994e+3 (1.70e+2) +	1.1362e+3 (1.19e+2) +	1.1578e+3 (1.69e+2) +	1.3013e+3 (8.25e+1)
	100	2	50000	1.2671e+3 (1.48e+2) +	1.2262e+3 (1.34e+2) +	1.2328e+3 (1.60e+2) +	1.3581e+3 (9.25e+1) ≈	1.3825e+3 (9.99e+1)
MAP7	100	2	10000	1.0062e+3 (1.47e+2) +	9.4702e+2 (1.75e+2) +	9.2446e+2 (1.57e+2) +	1.0243e+3 (1.65e+2) +	1.2450e+3 (1.21e+2)
	100	2	20000	1.0586e+3 (1.27e+2) +	9.7240e+2 (1.96e+2) +	9.5346e+2 (2.08e+2) +	1.1190e+3 (1.35e+2) +	1.3139e+3 (8.96e+1)
	100	2	50000	1.2300e+3 (1.26e+2) +	1.1420e+3 (1.36e+2) +	1.1223e+3 (1.05e+2) +	1.2426e+3 (1.68e+2) +	1.3543e+3 (1.03e+2)
MAP8	100	2	10000	1.0118e+3 (1.73e+2) +	9.3021e+2 (1.67e+2) +	9.3132e+2 (1.50e+2) +	1.0103e+3 (1.09e+2) +	1.1751e+3 (1.20e+2)
	100	2	20000	1.0830e+3 (1.37e+2) +	1.0145e+3 (1.90e+2) +	9.7305e+2 (1.82e+2) +	1.0615e+3 (1.35e+2) +	1.2748e+3 (1.03e+2)
	100	2	50000	1.1834e+3 (1.41e+2) +	1.1280e+3 (1.41e+2) +	1.0924e+3 (1.55e+2) +	1.2771e+3 (9.54e+1) +	1.3378e+3 (7.68e+1)
MAP9	100	2	10000	9.3197e+2 (1.65e+2) +	8.9139e+2 (1.27e+2) +	8.4066e+2 (2.10e+2) +	9.7140e+2 (1.74e+2) +	1.1345e+3 (1.26e+2)
	100	2	20000	1.0349e+3 (1.45e+2) +	8.7269e+2 (1.96e+2) +	9.3882e+2 (1.39e+2) +	1.0062e+3 (1.75e+2) +	1.2330e+3 (1.11e+2)
	100	2	50000	1.0824e+3 (2.02e+2) +	1.0539e+3 (1.80e+2) +	1.0549e+3 (1.83e+2) +	1.1941e+3 (9.57e+1) +	1.3056e+3 (1.11e+2)
MAP10	100	2	10000	1.2818e+3 (1.25e+2) +	1.2092e+3 (1.58e+2) +	1.1824e+3 (1.51e+2) +	1.2974e+3 (1.61e+2) +	1.4494e+3 (9.62e+1)
	100	2	20000	1.3945e+3 (1.11e+2) +	1.3084e+3 (1.58e+2) +	1.3047e+3 (1.20e+2) +	1.3890e+3 (1.07e+2) +	1.4691e+3 (7.97e+1)
	100	2	50000	1.3835e+3 (1.17e+2) +	1.4084e+3 (1.10e+2) ≈	1.4268e+3 (1.04e+2) ≈	1.5776e+3 (5.95e+1) -	1.4654e+3 (8.64e+1)
				+/-/≈	28/0/2	28/0/2	28/0/2	20/6/4

Tabela A.33: Resultados para o cálculo do *Hypervolume* para as métricas de Energia e Balanceamento de Carga em relação ao *grid* de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAI	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	5.8871e-1 (1.42e-2) ≈	5.7006e-1 (1.37e-2) -	6.0001e-1 (1.40e-2) ≈	5.8478e-1 (1.14e-2) -	5.9674e-1 (1.17e-2)
	100	2	20000	6.2070e-1 (1.21e-2) ≈	6.0276e-1 (1.28e-2) -	6.3167e-1 (1.25e-2) +	6.1375e-1 (1.28e-2) -	6.2252e-1 (1.58e-2)
	100	2	50000	6.5392e-1 (1.11e-2) ≈	6.4751e-1 (1.09e-2) -	6.6443e-1 (8.38e-3) +	6.4139e-1 (1.43e-2) -	6.5476e-1 (1.49e-2)
MAP2	100	2	10000	5.2611e-1 (1.46e-2) ≈	5.1330e-1 (1.26e-2) -	5.3319e-1 (9.66e-3) ≈	5.2358e-1 (1.66e-2) ≈	5.3060e-1 (1.68e-2)
	100	2	20000	5.6077e-1 (1.19e-2) ≈	5.4359e-1 (1.10e-2) -	5.6425e-1 (1.17e-2) +	5.5315e-1 (1.42e-2) ≈	5.5812e-1 (1.32e-2)
	100	2	50000	5.9227e-1 (1.37e-2) ≈	5.7634e-1 (1.09e-2) -	6.0127e-1 (9.88e-3) +	5.8368e-1 (1.01e-2) ≈	5.8610e-1 (1.70e-2)
MAP3	100	2	10000	5.3974e-1 (1.39e-2) ≈	5.3086e-1 (1.26e-2) -	5.5369e-1 (1.38e-2) +	5.3792e-1 (1.20e-2) ≈	5.5031e-1 (1.53e-2)
	100	2	20000	5.7350e-1 (1.51e-2) ≈	5.5969e-1 (1.31e-2) -	5.8424e-1 (1.12e-2) +	5.7238e-1 (1.25e-2) ≈	5.7543e-1 (1.58e-2)
	100	2	50000	6.0921e-1 (9.03e-3) +	5.9817e-1 (1.07e-2) ≈	6.1485e-1 (7.45e-3) +	5.9743e-1 (9.67e-3) ≈	6.0183e-1 (1.22e-2)
MAP4	100	2	10000	5.1633e-1 (1.06e-2) ≈	4.9266e-1 (1.04e-2) -	5.2043e-1 (9.80e-3) ≈	5.0509e-1 (1.34e-2) -	5.1718e-1 (1.21e-2)
	100	2	20000	5.3697e-1 (1.25e-2) -	5.2502e-1 (9.74e-3) -	5.4856e-1 (1.02e-2) +	5.3572e-1 (1.09e-2) -	5.4542e-1 (1.40e-2)
	100	2	50000	5.7220e-1 (1.07e-2) ≈	5.6137e-1 (9.50e-3) -	5.8388e-1 (7.11e-3) +	5.6763e-1 (9.73e-3) ≈	5.7304e-1 (1.78e-2)
MAP5	100	2	10000	5.6528e-1 (1.41e-2) ≈	5.4779e-1 (1.50e-2) -	5.6871e-1 (1.12e-2) ≈	5.6554e-1 (1.18e-2) ≈	5.7042e-1 (1.28e-2)
	100	2	20000	5.9476e-1 (1.46e-2) ≈	5.8250e-1 (1.52e-2) -	5.9983e-1 (1.36e-2) ≈	5.8908e-1 (1.07e-2) ≈	5.9591e-1 (1.71e-2)
	100	2	50000	6.3004e-1 (1.17e-2) ≈	6.1867e-1 (1.14e-2) -	6.3324e-1 (1.04e-2) ≈	6.2114e-1 (1.43e-2) ≈	6.2754e-1 (1.45e-2)
MAP6	100	2	10000	5.0319e-1 (1.70e-2) ≈	4.8396e-1 (1.42e-2) -	5.0636e-1 (1.23e-2) ≈	4.9800e-1 (1.34e-2) -	5.0939e-1 (1.17e-2)
	100	2	20000	5.3450e-1 (1.21e-2) +	5.1839e-1 (1.21e-2) -	5.4352e-1 (1.08e-2) +	5.2728e-1 (1.01e-2) ≈	5.2790e-1 (1.29e-2)
	100	2	50000	5.6139e-1 (1.14e-2) ≈	5.5001e-1 (1.13e-2) -	5.7344e-1 (1.08e-2) +	5.6106e-1 (1.08e-2) ≈	5.6187e-1 (1.29e-2)
MAP7	100	2	10000	4.8571e-1 (1.42e-2) ≈	4.6779e-1 (1.20e-2) -	4.9184e-1 (1.12e-2) ≈	4.7893e-1 (1.12e-2) ≈	4.8553e-1 (1.58e-2)
	100	2	20000	5.1259e-1 (1.05e-2) ≈	4.9804e-1 (7.47e-3) -	5.2557e-1 (1.13e-2) +	5.1249e-1 (1.39e-2) ≈	5.1182e-1 (1.05e-2)
	100	2	50000	5.5017e-1 (1.20e-2) +	5.3623e-1 (1.16e-2) -	5.5914e-1 (8.75e-3) +	5.4486e-1 (1.17e-2) ≈	5.4407e-1 (1.20e-2)
MAP8	100	2	10000	4.8148e-1 (1.32e-2) ≈	4.6524e-1 (9.10e-3) -	4.8930e-1 (1.20e-2) ≈	4.7757e-1 (1.61e-2) ≈	4.8418e-1 (1.43e-2)
	100	2	20000	5.1023e-1 (1.15e-2) ≈	4.9263e-1 (1.22e-2) -	5.1712e-1 (8.79e-3) +	5.0873e-1 (1.21e-2) ≈	5.1086e-1 (1.06e-2)
	100	2	50000	5.4735e-1 (1.18e-2) +	5.3242e-1 (9.17e-3) -	5.5235e-1 (8.89e-3) +	5.3745e-1 (9.58e-3) ≈	5.4102e-1 (1.26e-2)
MAP9	100	2	10000	4.7154e-1 (1.13e-2) ≈	4.5420e-1 (1.11e-2) -	4.7972e-1 (1.46e-2) ≈	4.6453e-1 (9.30e-3) -	4.7754e-1 (1.39e-2)
	100	2	20000	5.0197e-1 (1.12e-2) ≈	4.8412e-1 (1.16e-2) -	5.0842e-1 (1.06e-2) +	4.9239e-1 (1.09e-2) ≈	4.9713e-1 (1.69e-2)
	100	2	50000	5.3917e-1 (1.17e-2) +	5.1813e-1 (1.16e-2) -	5.4551e-1 (9.74e-3) +	5.3017e-1 (1.11e-2) ≈	5.3143e-1 (1.32e-2)
MAP10	100	2	10000	5.4586e-1 (1.25e-2) ≈	5.2620e-1 (9.76e-3) -	5.5099e-1 (1.34e-2) ≈	5.4189e-1 (1.00e-2) ≈	5.4722e-1 (1.46e-2)
	100	2	20000	5.7498e-1 (1.21e-2) ≈	5.5509e-1 (1.02e-2) -	5.8416e-1 (9.83e-3) ≈	5.7314e-1 (1.27e-2) ≈	5.7836e-1 (1.30e-2)
	100	2	50000	6.0756e-1 (1.65e-2) ≈	5.9852e-1 (1.02e-2) ≈	6.1844e-1 (1.24e-2) +	6.0205e-1 (1.21e-2) ≈	6.0207e-1 (1.30e-2)
				+/-/≈	5/2/23	0/28/2	16/0/14	0/8/22

Tabela A.34: Resultados para o cálculo do IGD para as métricas de Energia e Balançamento de Carga em relação ao *grid* de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	5.3662e+1 (6.24e+0) +	5.2395e+1 (5.87e+0) +	4.9634e+1 (5.71e+0) +	5.2464e+1 (7.98e+0) +	5.7491e+1 (5.90e+0)
	100	2	20000	5.5562e+1 (6.50e+0) ≈	5.4362e+1 (5.85e+0) ≈	5.2532e+1 (6.84e+0) +	5.8957e+1 (6.45e+0) +	5.7827e+1 (9.54e+0)
	100	2	50000	6.0990e+1 (6.30e+0) +	5.8493e+1 (7.65e+0) +	5.7727e+1 (4.97e+0) +	6.5352e+1 (6.25e+0) ≈	6.8284e+1 (8.12e+0)
MAP2	100	2	10000	4.5404e+1 (6.69e+0) +	4.3605e+1 (6.58e+0) +	4.3573e+1 (5.05e+0) +	4.4138e+1 (5.39e+0) +	5.3426e+1 (5.84e+0)
	100	2	20000	4.9265e+1 (4.57e+0) +	4.7267e+1 (5.36e+0) +	4.7866e+1 (4.19e+0) +	4.8233e+1 (4.93e+0) +	5.5657e+1 (5.53e+0)
	100	2	50000	5.9020e+1 (3.56e+0) +	5.3193e+1 (4.56e+0) +	5.6423e+1 (4.27e+0) +	5.6390e+1 (5.36e+0) +	6.3650e+1 (5.08e+0)
MAP3	100	2	10000	4.7534e+1 (6.35e+0) +	4.4238e+1 (6.92e+0) +	4.5006e+1 (6.71e+0) +	4.7434e+1 (5.73e+0) +	5.2062e+1 (6.17e+0)
	100	2	20000	4.8833e+1 (5.46e+0) +	4.9398e+1 (6.12e+0) +	4.6303e+1 (4.52e+0) +	5.0032e+1 (7.96e+0) +	5.8389e+1 (7.29e+0)
	100	2	50000	5.8688e+1 (4.62e+0) +	5.5192e+1 (5.88e+0) +	5.7290e+1 (4.39e+0) +	5.5159e+1 (5.99e+0) +	6.5150e+1 (7.66e+0)
MAP4	100	2	10000	4.3339e+1 (4.86e+0) +	4.1441e+1 (4.86e+0) +	4.1942e+1 (5.40e+0) +	4.4903e+1 (5.70e+0) +	4.8398e+1 (6.81e+0)
	100	2	20000	4.7001e+1 (5.66e+0) +	4.6634e+1 (5.37e+0) +	4.7466e+1 (4.33e+0) +	4.7667e+1 (6.52e+0) +	5.4724e+1 (5.44e+0)
	100	2	50000	5.6922e+1 (4.29e+0) +	5.2926e+1 (5.91e+0) +	5.5490e+1 (3.62e+0) +	5.6755e+1 (3.64e+0) +	6.2717e+1 (5.29e+0)
MAP5	100	2	10000	4.8967e+1 (4.92e+0) +	4.8998e+1 (6.52e+0) +	4.5739e+1 (7.69e+0) +	5.0598e+1 (7.15e+0) ≈	5.4627e+1 (6.22e+0)
	100	2	20000	4.8935e+1 (7.04e+0) +	4.9134e+1 (6.80e+0) +	4.8669e+1 (6.73e+0) +	5.2264e+1 (5.70e+0) +	5.6289e+1 (5.89e+0)
	100	2	50000	5.7092e+1 (6.06e+0) +	5.4195e+1 (5.82e+0) +	5.7658e+1 (5.16e+0) +	5.8491e+1 (6.50e+0) +	6.4985e+1 (6.35e+0)
MAP6	100	2	10000	4.5501e+1 (4.36e+0) +	4.2638e+1 (6.21e+0) +	4.2873e+1 (5.32e+0) +	4.3371e+1 (4.88e+0) +	5.1327e+1 (5.56e+0)
	100	2	20000	4.8698e+1 (5.57e+0) +	4.7699e+1 (6.09e+0) +	4.7865e+1 (4.42e+0) +	4.8997e+1 (5.65e+0) +	5.6289e+1 (5.89e+0)
	100	2	50000	5.6622e+1 (5.09e+0) +	5.4824e+1 (3.90e+0) +	5.5889e+1 (4.06e+0) +	5.7921e+1 (3.75e+0) +	6.6780e+1 (4.66e+0)
MAP7	100	2	10000	3.9579e+1 (5.13e+0) +	3.9776e+1 (4.90e+0) +	3.8547e+1 (4.88e+0) +	4.0809e+1 (5.33e+0) +	4.6800e+1 (5.57e+0)
	100	2	20000	4.2474e+1 (4.98e+0) +	4.0910e+1 (3.98e+0) +	4.2607e+1 (4.45e+0) +	4.4005e+1 (4.43e+0) +	4.7600e+1 (6.35e+0)
	100	2	50000	5.2193e+1 (3.96e+0) +	4.8499e+1 (5.76e+0) +	5.0862e+1 (4.13e+0) +	5.2793e+1 (4.37e+0) +	5.9620e+1 (6.23e+0)
MAP8	100	2	10000	4.0410e+1 (5.45e+0) +	3.8246e+1 (5.05e+0) +	3.8714e+1 (5.09e+0) +	3.9711e+1 (4.16e+0) +	4.4270e+1 (5.37e+0)
	100	2	20000	4.1775e+1 (3.68e+0) +	4.1076e+1 (5.58e+0) +	3.9547e+1 (4.33e+0) +	4.2374e+1 (4.90e+0) +	4.7600e+1 (6.35e+0)
	100	2	50000	4.9198e+1 (5.37e+0) +	4.7467e+1 (5.63e+0) +	4.5636e+1 (5.20e+0) +	4.5104e+1 (6.44e+0) +	5.3160e+1 (7.12e+0)
MAP9	100	2	10000	4.0043e+1 (3.98e+0) +	3.8212e+1 (4.33e+0) +	3.8314e+1 (5.51e+0) +	4.0808e+1 (5.57e+0) +	4.6933e+1 (5.02e+0)
	100	2	20000	4.2208e+1 (4.82e+0) +	4.0210e+1 (4.41e+0) +	3.9947e+1 (5.68e+0) +	4.1477e+1 (5.08e+0) +	4.7667e+1 (5.01e+0)
	100	2	50000	4.3807e+1 (4.38e+0) +	4.4572e+1 (5.10e+0) +	4.4406e+1 (6.22e+0) +	4.4207e+1 (5.97e+0) +	5.0497e+1 (5.36e+0)
MAP10	100	2	10000	4.5770e+1 (5.41e+0) +	4.8098e+1 (6.45e+0) +	4.5837e+1 (5.71e+0) +	4.4538e+1 (4.99e+0) +	5.1763e+1 (6.94e+0)
	100	2	20000	5.0697e+1 (5.41e+0) +	4.7701e+1 (5.73e+0) +	4.4973e+1 (6.45e+0) +	5.0065e+1 (5.43e+0) +	5.5192e+1 (5.54e+0)
	100	2	50000	5.5458e+1 (5.75e+0) +	5.2995e+1 (6.89e+0) +	5.4626e+1 (4.98e+0) +	5.6757e+1 (5.80e+0) +	6.4184e+1 (7.92e+0)
				+/-/≈	29/0/1	29/0/1	30/0/0	27/0/3

Tabela A.35: Resultados para o cálculo do Hypervolume para as métricas de Tolerância a Falhas e Energia em relação ao *grid* de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	7.3803e-1 (2.00e-2) -	7.1052e-1 (1.96e-2) -	7.3813e-1 (1.93e-2) -	7.3987e-1 (2.21e-2) -	7.6562e-1 (2.42e-2)
	100	2	20000	7.8588e-1 (2.33e-2) ≈	7.6830e-1 (2.16e-2) -	7.8691e-1 (1.90e-2) ≈	7.8804e-1 (1.69e-2) ≈	7.8476e-1 (2.49e-2)
	100	2	50000	8.2129e-1 (1.64e-2) +	8.1357e-1 (1.44e-2) +	8.2755e-1 (2.23e-2) +	8.2351e-1 (1.78e-2) +	8.0147e-1 (2.28e-2)
MAP2	100	2	10000	6.8735e-1 (1.74e-2) -	6.6275e-1 (1.97e-2) -	6.8248e-1 (2.26e-2) -	6.8920e-1 (2.13e-2) -	7.3005e-1 (2.45e-2)
	100	2	20000	7.1317e-1 (2.05e-2) -	7.1761e-1 (2.13e-2) -	7.3697e-1 (2.54e-2) ≈	7.4215e-1 (2.28e-2) ≈	7.5146e-1 (3.12e-2)
	100	2	50000	7.8593e-1 (1.85e-2) ≈	7.7638e-1 (1.94e-2) ≈	7.9027e-1 (2.52e-2) ≈	7.8621e-1 (1.99e-2) ≈	7.8090e-1 (2.59e-2)
MAP3	100	2	10000	7.0511e-1 (2.20e-2) -	7.6464e-1 (1.74e-2) -	6.9278e-1 (1.93e-2) -	7.0084e-1 (2.14e-2) -	7.3603e-1 (2.91e-2)
	100	2	20000	7.4961e-1 (2.32e-2) -	7.3376e-1 (1.82e-2) -	7.4661e-1 (2.05e-2) -	7.5361e-1 (1.57e-2) -	7.6459e-1 (2.46e-2)
	100	2	50000	7.9655e-1 (2.16e-2) ≈	7.8610e-1 (1.68e-2) ≈	7.9570e-1 (1.98e-2) ≈	7.9522e-1 (1.36e-2) ≈	7.8972e-1 (2.35e-2)
MAP4	100	2	10000	6.6806e-1 (1.63e-2) -	6.5118e-1 (1.58e-2) -	6.6298e-1 (1.65e-2) -	6.6681e-1 (1.99e-2) -	7.1111e-1 (2.57e-2)
	100	2	20000	7.1934e-1 (2.51e-2) -	7.0485e-1 (2.11e-2) -	7.0496e-1 (1.88e-2) -	7.2707e-1 (1.96e-2) -	7.3701e-1 (3.08e-2)
	100	2	50000	7.7012e-1 (2.04e-2) ≈	7.6097e-1 (2.04e-2) -	7.6714e-1 (2.62e-2) ≈	7.6470e-1 (1.77e-2) ≈	7.7170e-1 (2.29e-2)
MAP5	100	2	10000	7.1862e-1 (2.21e-2) -	6.9287e-1 (1.63e-2) -	7.1348e-1 (2.06e-2) -	7.1914e-1 (2.28e-2) -	7.5242e-1 (2.80e-2)
	100	2	20000	7.6433e-1 (2.02e-2) ≈	7.5306e-1 (1.69e-2) -	7.6503e-1 (1.97e-2) ≈	7.7499e-1 (1.88e-2) ≈	7.7073e-1 (2.12e-2)
	100	2	50000	8.0758e-1 (1.86e-2) ≈	8.1038e-1 (1.87e-2) ≈	8.0621e-1 (2.40e-2) ≈	8.1350e-1 (2.38e-2) +	7.9798e-1 (2.43e-2)
MAP6	100	2	10000	6.6474e-1 (2.02e-2) -	6.4055e-1 (1.83e-2) -	6.5583e-1 (1.87e-2) -	6.6410e-1 (2.38e-2) -	7.0900e-1 (2.88e-2)
	100	2	20000	7.1728e-1 (2.08e-2) -	6.9071e-1 (1.47e-2) -	7.0347e-1 (1.55e-2) -	7.1530e-1 (2.28e-2) -	7.3051e-1 (3.26e-2)
	100	2	50000	7.5464e-1 (2.03e-2) ≈	7.4681e-1 (2.06e-2) -	7.5945e-1 (1.54e-2) ≈	7.5016e-1 (2.55e-2) ≈	7.6171e-1 (2.86e-2)
MAP7	100	2	10000	6.5019e-1 (2.22e-2) ≈	6.1750e-1 (1.57e-2) -	6.4213e-1 (2.17e-2) -	6.3870e-1 (2.69e-2) -	6.6331e-1 (4.53e-2)
	100	2	20000	7.0107e-1 (2.77e-2) ≈	6.6770e-1 (2.05e-2) -	6.8422e-1 (3.03e-2) -	6.9658e-1 (2.50e-2) ≈	7.0916e-1 (3.77e-2)
	100	2	50000	7.4972e-1 (2.40e-2) ≈	7.3163e-1 (1.67e-2) -	7.5355e-1 (2.44e-2) ≈	7.4145e-1 (1.98e-2) ≈	7.4130e-1 (3.78e-2)
MAP8	100	2	10000	6.3818e-1 (2.73e-2) -	6.1701e-1 (2.98e-2) -	6.3752e-1 (2.24e-2) -	6.3993e-1 (2.34e-2) -	6.7609e-1 (3.87e-2)
	100	2	20000	6.9144e-1 (2.03e-2) -	6.6718e-1 (1.32e-2) -	6.8927e-1 (2.50e-2) -	6.8832e-1 (2.04e-2) -	7.1559e-1 (3.02e-2)
	100	2	50000	7.4193e-1 (2.28e-2) ≈	7.3295e-1 (1.82e-2) -	7.4055e-1 (2.24e-2) ≈	7.4149e-1 (1.71e-2) ≈	7.4770e-1 (2.96e-2)
MAP9	100	2	10000	6.1600e-1 (3.25e-2) -	5.8955e-1 (3.29e-2) -	6.2303e-1 (2.35e-2) -	6.1357e-1 (2.61e-2) -	6.6702e-1 (3.38e-2)
	100	2	20000	6.7633e-1 (2.44e-2) -	6.5657e-1 (2.82e-2) -	6.7427e-1 (1.55e-2) -	6.7666e-1 (3.17e-2) -	7.0105e-1 (2.28e-2)
	100	2	50000	7.2604e-1 (2.89e-2) ≈	7.1956e-1 (2.01e-2) -	7.2826e-1 (2.02e-2) ≈	7.2461e-1 (2.15e-2) ≈	7.3047e-1 (3.28e-2)
MAP10	100	2	10000	7.0301e-1 (2.08e-2) -	6.7879e-1 (1.87e-2) -	7.0933e-1 (2.71e-2) -	7.0050e-1 (1.93e-2) -	7.327e-1 (2.47e-2)
	100	2	20000	7.5051e-1 (2.52e-2) -	7.2979e-1 (1.94e-2) -	7.5060e-1 (2.12e-2) -	7.5306e-1 (3.01e-2) -	7.6887e-1 (2.93e-2)
	100	2	50000	7.8972e-1 (1.99e-2) ≈	7.8797e-1 (1.90e-2) ≈	7.9653e-1 (1.82e-2) ≈	7.9453e-1 (1.88e-2) ≈	7.8747e-1 (2.02e-2)
				+/-/≈	1/16/13	1/25/4	1/17/12	2/16/12

Tabela A.36: Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Energia em relação ao *grid* de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	1.1738e+2 (4.31e+0) +	1.1156e+2 (4.21e+0) +	1.1844e+2 (4.15e+0) +	1.1838e+2 (4.30e+0) +	1.2423e+2 (4.37e+0)
	100	2	20000	1.2739e+2 (4.62e+0) ≈	1.2370e+2 (4.85e+0) +	1.2785e+2 (3.78e+0) ≈	1.2772e+2 (3.98e+0) ≈	1.2775e+2 (4.50e+0)
	100	2	50000	1.3434e+2 (2.96e+0) -	1.3294e+2 (2.67e+0) -	1.3550e+2 (4.04e+0) -	1.3477e+2 (3.22e+0) -	1.3078e+2 (4.13e+0)
MAP2	100	2	10000	1.0588e+2 (5.54e+0) +	9.9941e+1 (5.25e+0) +	1.0628e+2 (5.00e+0) +	1.0685e+2 (5.81e+0) +	1.1748e+2 (3.82e+0)
	100	2	20000	1.1638e+2 (4.92e+0) +	1.1243e+2 (6.12e+0) +	1.1784e+2 (4.95e+0) +	1.1831e+2 (6.09e+0) ≈	1.2163e+2 (5.54e+0)
	100	2	50000	1.2778e+2 (3.53e+0) ≈	1.2546e+2 (4.26e+0) ≈	1.2845e+2 (4.71e+0) ≈	1.2768e+2 (4.04e+0) ≈	1.2705e+2 (4.69e+0)
MAP3	100	2	10000	1.1014e+2 (5.38e+0) +	1.0316e+2 (4.12e+0) +	1.0884e+2 (4.82e+0) +	1.0990e+2 (5.07e+0) +	1.1884e+2 (5.45e+0)
	100	2	20000	1.2067e+2 (4.82e+0) +	1.1652e+2 (4.20e+0) +	1.2004e+2 (4.13e+0) +	1.2044e+2 (3.89e+0) +	1.2360e+2 (5.26e+0)
	100	2	50000	1.2965e+2 (4.04e+0) ≈	1.2689e+2 (3.43e+0) +	1.2961e+2 (3.62e+0) ≈	1.2935e+2 (2.89e+0) ≈	1.2865e+2 (4.25e+0)
MAP4	100	2	10000	1.0004e+2 (6.99e+0) +	9.6621e+1 (4.87e+0) +	1.0064e+2 (5.32e+0) +	1.0226e+2 (6.05e+0) +	1.1472e+2 (4.66e+0)
	100	2	20000	1.1286e+2 (5.81e+0) +	1.1027e+2 (4.57e+0) +	1.1047e+2 (3.81e+0) +	1.1549e+2 (4.59e+0) +	1.1990e+2 (5.19e+0)
	100	2	50000	1.2459e+2 (3.96e+0) ≈	1.2180e+2 (4.53e+0) +	1.2399e+2 (5.03e+0) ≈	1.2316e+2 (3.82e+0) +	1.2536e+2 (4.18e+0)
MAP5	100	2	10000	1.1426e+2 (4.87e+0) +	1.0728e+2 (4.23e+0) +	1.1362e+2 (4.64e+0) +	1.1372e+2 (5.77e+0) +	1.2187e+2 (5.08e+0)
	100	2	20000	1.2310e+2 (4.05e+0) ≈	1.2094e+2 (3.92e+0) +	1.2376e+2 (3.93e+0) ≈	1.2532e+2 (4.35e+0) ≈	1.2509e+2 (5.89e+0)
	100	2	50000	1.3167e+2 (3.55e+0) ≈	1.3164e+2 (4.48e+0) ≈	1.3158e+2 (4.41e+0) ≈	1.3281e+2 (4.59e+0) -	1.3015e+2 (4.41e+0)
MAP6	100	2	10000	1.0216e+2 (5.53e+0) +	9.2740e+1 (6.35e+0) +	9.9576e+1 (6.08e+0) +	1.0057e+2 (6.92e+0) +	1.1451e+2 (4.85e+0)
	100	2	20000	1.1243e+2 (5.22e+0) +	1.0502e+2 (5.01e+0) +	1.1077e+2 (4.21e+0) +	1.1183e+2 (6.18e+0) +	1.1781e+2 (5.89e+0)
	100	2	50000	1.2110e+2 (4.11e+0) ≈	1.1891e+2 (4.39e+0) +	1.2233e+2 (4.17e+0) ≈	1.2017e+2 (5.50e+0) +	1.2406e+2 (5.10e+0)
MAP7	100	2	10000	9.7020e+1 (5.81e+0) +	8.5776e+1 (6.56e+0) +	9.6822e+1 (7.39e+0) +	9.6382e+1 (6.52e+0) +	1.0882e+2 (6.54e+0)
	100	2	20000	1.0881e+2 (7.62e+0) +	1.0140e+2 (5.13e+0) +	1.0615e+2 (7.13e+0) +	1.0818e+2 (7.04e+0) +	1.1581e+2 (5.86e+0)
	100	2	50000	1.2057e+2 (4.72e+0) ≈	1.1565e+2 (5.04e+0) +	1.2094e+2 (5.61e+0) ≈	1.1848e+2 (4.62e+0) ≈	1.2000e+2 (5.59e+0)
MAP8	100	2	10000	9.4761e+1 (7.21e+0) +	8.9119e+1 (6.10e+0) +	9.6185e+1 (6.07e+0) +	9.5524e+1 (6.37e+0) +	1.0803e+2 (7.54e+0)
	100	2	20000	1.0575e+2 (6.81e+0) +	9.8413e+1 (4.51e+0) +	1.0698e+2 (6.17e+0) +	1.0701e+2 (4.47e+0) +	1.1581e+2 (5.31e+0)
	100	2	50000	1.1814e+2 (5.99e+0) +	1.1625e+2 (5.78e+0) +	1.1924e+2 (4.40e+0) +	1.1794e+2 (4.31e+0) +	1.2183e+2 (4.24e+0)
MAP9	100	2	10000	9.5269e+1 (6.32e+0) +	8.7775e+1 (7.84e+0) +	9.1908e+1 (6.23e+0) +	9.4841e+1 (6.30e+0) +	1.0624e+2 (5.06e+0)
	100	2	20000	1.0353e+2 (6.84e+0) +	9.9006e+1 (6.75e+0) +	1.0339e+2 (3.40e+0) +	1.0332e+2 (7.97e+0) +	1.1179e+2 (5.15e+0)
	100	2	50000	1.1562e+2 (6.65e+0) +	1.1176e+2 (6.14e+0) +	1.1645e+2 (4.44e+0) +	1.1432e+2 (4.23e+0) +	1.1923e+2 (4.66e+0)
MAP10	100	2	10000	1.0904e+2 (6.09e+0) +	1.0270e+2 (5.11e+0) +	1.1150e+2 (6.87e+0) +	1.0987e+2 (4.88e+0) +	1.1931e+2 (4.53e+0)
	100	2	20000	1.2020e+2 (5.53e+0) +	1.1472e+2 (5.43e+0) +	1.2067e+2 (4.35e+0) +	1.2124e+2 (5.95e+0) +	1.2473e+2 (5.42e+0)
	100	2	50000	1.2805e+2 (4.15e+0) ≈	1.2729e+2 (4.86e+0) ≈	1.2961e+2 (3.86e+0) ≈	1.2928e+2 (3.58e+0) ≈	1.2818e+2 (3.66e+0)
				+/-/≈	20/1/9	26/1/3	20/1/9	21/2/7

Tabela A.37: Resultados para o cálculo do *Hypervolume* para as métricas de Tolerância a Falhas e Comunicação em relação ao *grid* de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	6.8299e-1 (7.68e-3) -	6.7691e-1 (6.30e-3) -	6.7987e-1 (1.89e-2) -	6.8218e-1 (1.42e-2) -	6.8629e-1 (2.70e-2)
	100	2	20000	6.9911e-1 (7.48e-3) +	6.9000e-1 (6.75e-3) -	6.9832e-1 (8.43e-3) +	6.9893e-1 (7.67e-3) +	6.9577e-1 (3.18e-2)
	100	2	50000	7.1412e-1 (6.61e-3) -	7.1315e-1 (5.74e-3) -	7.1710e-1 (6.66e-3) -	7.1598e-1 (7.72e-3) -	7.2162e-1 (1.92e-2)
MAP2	100	2	10000	6.0407e-1 (2.89e-2) ≈	5.9230e-1 (2.69e-2) -	5.9675e-1 (2.87e-2) -	6.0967e-1 (2.83e-2) ≈	6.1164e-1 (2.81e-2)
	100	2	20000	6.2185e-1 (2.95e-2) ≈	6.2887e-1 (2.25e-2) ≈	6.2962e-1 (2.76e-2) ≈	6.2246e-1 (2.82e-2) ≈	6.2629e-1 (2.91e-2)
	100	2	50000	6.5069e-1 (2.84e-2) ≈	6.4959e-1 (2.41e-2) ≈	6.5362e-1 (2.57e-2) ≈	6.4505e-1 (2.90e-2) ≈	6.4300e-1 (2.53e-2)
MAP3	100	2	10000	6.3216e-1 (2.79e-2) ≈	6.3724e-1 (1.85e-2) ≈	6.4369e-1 (2.13e-2) ≈	6.4069e-1 (2.52e-2) ≈	6.3502e-1 (2.94e-2)
	100	2	20000	6.5967e-1 (2.53e-2) ≈	6.5091e-1 (2.44e-2) ≈	6.5858e-1 (2.05e-2) ≈	6.6002e-1 (2.28e-2) +	6.3896e-1 (2.92e-2)
	100	2	50000	6.7577e-1 (2.69e-2) ≈	6.7574e-1 (1.92e-2) ≈	6.8086e-1 (1.83e-2) ≈	6.7860e-1 (2.31e-2) ≈	6.7540e-1 (2.96e-2)
MAP4	100	2	10000	5.8019e-1 (2.47e-2) -	5.7845e-1 (2.89e-2) ≈	5.7650e-1 (2.35e-2) -	5.8641e-1 (2.74e-2) ≈	5.9168e-1 (1.69e-2)
	100	2	20000	6.0388e-1 (3.03e-2) ≈	5.9486e-1 (2.90e-2) ≈	6.1253e-1 (2.87e-2) ≈	6.0548e-1 (3.10e-2) ≈	6.0571e-1 (2.41e-2)
	100	2	50000	6.2324e-1 (3.03e-2) ≈	6.1634e-1 (3.00e-2) ≈	6.2335e-1 (2.91e-2) ≈	6.2339e-1 (2.92e-2) ≈	6.2087e-1 (2.59e-2)
MAP5	100	2	10000	6.6400e-1 (1.70e-2) ≈	6.5506e-1 (1.52e-2) ≈	6.6223e-1 (1.77e-2) ≈	6.5789e-1 (2.16e-2) ≈	6.5901e-1 (3.11e-2)
	100	2	20000	6.7789e-1 (1.63e-2) -	6.7597e-1 (7.02e-3) -	6.7772e-1 (2.13e-2) -	6.8043e-1 (1.65e-2) ≈	6.7903e-1 (3.18e-2)
	100	2	50000	7.0039e-1 (1.20e-2) ≈	6.9832e-1 (8.06e-3) ≈	7.0106e-1 (7.44e-3) ≈	6.9966e-1 (1.13e-2) ≈	6.9612e-1 (2.80e-2)
MAP6	100	2	10000	5.6169e-1 (1.94e-2) -	5.5441e-1 (1.89e-2) -	5.7848e-1 (2.74e-2) ≈	5.6895e-1 (2.09e-2) -	5.8055e-1 (1.86e-2)
	100	2	20000	5.8776e-1 (2.28e-2) -	5.8771e-1 (2.67e-2) -	5.8861e-1 (2.76e-2) -	5.9443e-1 (2.74e-2) ≈	6.0033e-1 (2.50e-2)
	100	2	50000	6.0878e-1 (2.75e-2) -	5.9916e-1 (2.62e-2) -	6.0724e-1 (2.89e-2) -	6.1232e-1 (2.71e-2) ≈	6.1456e-1 (2.39e-2)
MAP7	100	2	10000	5.5214e-1 (1.58e-2) -	5.3670e-1 (1.53e-2) -	5.5204e-1 (1.73e-2) -	5.5159e-1 (2.12e-2) -	5.6613e-1 (1.76e-2)
	100	2	20000	5.6448e-1 (1.85e-2) -	5.6585e-1 (2.55e-2) -	5.6304e-1 (1.80e-2) -	5.6953e-1 (2.36e-2) -	5.7706e-1 (1.51e-2)
	100	2	50000	5.9284e-1 (2.57e-2) -	5.9498e-1 (2.87e-2) ≈	5.9262e-1 (2.38e-2) -	5.9262e-1 (2.70e-2) -	5.9907e-1 (2.24e-2)
MAP8	100	2	10000	5.4285e-1 (2.04e-2) -	5.3405e-1 (1.67e-2) -	5.4425e-1 (1.81e-2) -	5.4611e-1 (1.91e-2) -	5.5663e-1 (1.57e-2)
	100	2	20000	5.5905e-1 (1.71e-2) -	5.4903e-1 (1.39e-2) -	5.5955e-1 (1.91e-2) -	5.5580e-1 (1.31e-2) -	5.7402e-1 (1.67e-2)
	100	2	50000	5.8732e-1 (2.46e-2) -	5.7864e-1 (2.25e-2) -	5.9374e-1 (2.60e-2) ≈	5.9117e-1 (2.45e-2) ≈	5.9249e-1 (1.98e-2)
MAP9	100	2	10000	5.3132e-1 (1.70e-2) -	5.2196e-1 (1.48e-2) -	5.2829e-1 (1.68e-2) -	5.2929e-1 (1.34e-2) -	5.5082e-1 (1.42e-2)
	100	2	20000	5.4579e-1 (1.49e-2) -	5.4052e-1 (2.04e-2) -	5.4769e-1 (1.37e-2) -	5.4681e-1 (1.62e-2) -	5.6214e-1 (8.34e-3)
	100	2	50000	5.7065e-1 (1.88e-2) -	5.6320e-1 (1.51e-2) -	5.7730e-1 (2.55e-2) -	5.6814e-1 (1.48e-2) -	5.8644e-1 (1.79e-2)
MAP10	100	2	10000	6.3876e-1 (2.82e-2) ≈	6.3572e-1 (2.30e-2) ≈	6.3463e-1 (2.50e-2) ≈	6.4007e-1 (2.47e-2) ≈	6.3543e-1 (3.15e-2)
	100	2	20000	6.6071e-1 (2.37e-2) ≈	6.5258e-1 (2.12e-2) ≈	6.5991e-1 (2.00e-2) ≈	6.6290e-1 (2.20e-2) ≈	6.4827e-1 (3.09e-2)
	100	2	50000	6.8414e-1 (1.51e-2) ≈	6.7901e-1 (1.42e-2) ≈	6.8371e-1 (1.37e-2) ≈	6.8256e-1 (1.86e-2) ≈	6.7507e-1 (2.91e-2)
				+/-/≈	1/16/13	0/16/14	1/15/14	2/11/17

Tabela A.38: Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Comunicação em relação ao grid de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	N	M	FE	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	1.2434e+3 (2.59e+1) +	1.2260e+3 (2.45e+1) +	1.2580e+3 (2.81e+1) +	1.2498e+3 (3.12e+1) +	1.3281e+3 (4.18e+1)
	100	2	20000	1.2795e+3 (2.37e+1) +	1.2641e+3 (2.38e+1) +	1.2985e+3 (2.43e+1) +	1.2838e+3 (2.70e+1) +	1.3517e+3 (3.47e+1)
	100	2	50000	1.3343e+3 (2.45e+1) +	1.3159e+3 (2.43e+1) +	1.3303e+3 (2.35e+1) +	1.3327e+3 (2.04e+1) +	1.3693e+3 (2.60e+1)
MAP2	100	2	10000	1.1542e+3 (4.70e+1) +	1.1021e+3 (8.80e+1) +	1.1492e+3 (7.55e+1) +	1.1325e+3 (6.73e+1) +	1.2244e+3 (4.61e+1)
	100	2	20000	1.1931e+3 (5.13e+1) +	1.1180e+3 (8.79e+1) +	1.1756e+3 (5.83e+1) +	1.1763e+3 (6.09e+1) +	1.2569e+3 (4.83e+1)
	100	2	50000	1.2232e+3 (4.35e+1) +	1.1921e+3 (5.00e+1) +	1.2323e+3 (4.12e+1) +	1.2281e+3 (5.25e+1) +	1.2970e+3 (5.76e+1)
MAP3	100	2	10000	1.1868e+3 (5.96e+1) +	1.1093e+3 (6.76e+1) +	1.1575e+3 (7.53e+1) +	1.1681e+3 (5.28e+1) +	1.2787e+3 (4.62e+1)
	100	2	20000	1.2129e+3 (5.49e+1) +	1.1978e+3 (5.13e+1) +	1.2176e+3 (4.34e+1) +	1.1987e+3 (4.27e+1) +	1.3068e+3 (3.92e+1)
	100	2	50000	1.2764e+3 (4.29e+1) +	1.2433e+3 (3.65e+1) +	1.2604e+3 (3.75e+1) +	1.2530e+3 (5.05e+1) +	1.3171e+3 (4.26e+1)
MAP4	100	2	10000	1.1241e+3 (1.07e+2) +	1.0949e+3 (6.44e+1) +	1.1297e+3 (6.21e+1) +	1.1182e+3 (8.87e+1) +	1.2257e+3 (4.69e+1)
	100	2	20000	1.1645e+3 (5.27e+1) +	1.1379e+3 (6.25e+1) +	1.1646e+3 (5.59e+1) +	1.1550e+3 (6.35e+1) +	1.2468e+3 (3.96e+1)
	100	2	50000	1.2238e+3 (4.89e+1) +	1.2062e+3 (4.77e+1) +	1.2177e+3 (5.32e+1) +	1.2115e+3 (7.22e+1) +	1.2747e+3 (4.03e+1)
MAP5	100	2	10000	1.1920e+3 (5.06e+1) +	1.1840e+3 (3.73e+1) +	1.2026e+3 (2.94e+1) +	1.2151e+3 (4.62e+1) +	1.2921e+3 (4.33e+1)
	100	2	20000	1.2378e+3 (4.98e+1) +	1.2120e+3 (5.29e+1) +	1.2472e+3 (4.85e+1) +	1.2620e+3 (3.26e+1) +	1.3179e+3 (4.05e+1)
	100	2	50000	1.2970e+3 (3.46e+1) +	1.2793e+3 (2.81e+1) +	1.2916e+3 (3.03e+1) +	1.3006e+3 (2.68e+1) +	1.3404e+3 (3.33e+1)
MAP6	100	2	10000	1.1324e+3 (5.07e+1) +	1.0975e+3 (7.55e+1) +	1.1111e+3 (6.92e+1) +	1.1351e+3 (4.82e+1) +	1.1981e+3 (4.14e+1)
	100	2	20000	1.1599e+3 (7.69e+1) +	1.1043e+3 (1.00e+2) +	1.1548e+3 (6.83e+1) +	1.1484e+3 (7.40e+1) +	1.2253e+3 (3.01e+1)
	100	2	50000	1.2113e+3 (4.95e+1) +	1.2002e+3 (4.55e+1) +	1.2100e+3 (4.74e+1) +	1.2021e+3 (7.47e+1) +	1.2621e+3 (3.31e+1)
MAP7	100	2	10000	1.0968e+3 (5.33e+1) +	1.0786e+3 (5.76e+1) +	1.0955e+3 (6.12e+1) +	1.0676e+3 (9.53e+1) +	1.1532e+3 (4.43e+1)
	100	2	20000	1.1423e+3 (3.68e+1) +	1.0832e+3 (8.30e+1) +	1.1407e+3 (3.06e+1) +	1.1209e+3 (6.52e+1) +	1.2004e+3 (3.10e+1)
	100	2	50000	1.1822e+3 (5.51e+1) +	1.1255e+3 (8.79e+1) +	1.1920e+3 (4.67e+1) +	1.1691e+3 (5.66e+1) +	1.2299e+3 (4.53e+1)
MAP8	100	2	10000	1.0769e+3 (4.14e+1) +	1.0396e+3 (7.37e+1) +	1.0865e+3 (5.83e+1) +	1.0813e+3 (4.58e+1) +	1.1453e+3 (3.38e+1)
	100	2	20000	1.1297e+3 (4.66e+1) +	1.1075e+3 (4.44e+1) +	1.1373e+3 (3.50e+1) +	1.1343e+3 (2.31e+1) +	1.1854e+3 (3.54e+1)
	100	2	50000	1.1752e+3 (4.94e+1) +	1.1484e+3 (6.57e+1) +	1.1686e+3 (5.71e+1) +	1.1463e+3 (9.18e+1) +	1.2243e+3 (4.48e+1)
MAP9	100	2	10000	1.0419e+3 (9.17e+1) +	1.0400e+3 (3.52e+1) +	1.0532e+3 (5.03e+1) +	1.0640e+3 (2.88e+1) +	1.1325e+3 (3.26e+1)
	100	2	20000	1.1078e+3 (4.74e+1) +	1.0678e+3 (1.08e+2) +	1.1111e+3 (3.16e+1) +	1.1021e+3 (3.40e+1) +	1.2253e+3 (2.55e+1)
	100	2	50000	1.1597e+3 (3.95e+1) +	1.1354e+3 (4.86e+1) +	1.1319e+3 (7.55e+1) +	1.1461e+3 (5.03e+1) +	1.2021e+3 (4.66e+1)
MAP10	100	2	10000	1.1467e+3 (9.83e+1) +	1.1124e+3 (1.05e+2) +	1.1716e+3 (7.12e+1) +	1.1581e+3 (5.82e+1) +	1.2662e+3 (4.79e+1)
	100	2	20000	1.2177e+3 (3.99e+1) +	1.1687e+3 (9.43e+1) +	1.2206e+3 (4.97e+1) +	1.1986e+3 (4.52e+1) +	1.3024e+3 (5.57e+1)
	100	2	50000	1.2544e+3 (2.45e+1) +	1.2319e+3 (3.26e+1) +	1.2622e+3 (2.92e+1) +	1.2673e+3 (3.93e+1) +	1.3074e+3 (4.15e+1)
				+/-/≈	30/0/0	30/0/0	30/0/0	30/0/0

Tabela A.39: Resultados para o cálculo do Hypervolume para as métricas de Comunicação e Energia em relação ao grid de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	N	M	FE	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	6.2548e-1 (1.08e-2) -	6.0985e-1 (1.08e-2) -	6.2542e-1 (1.05e-2) -	6.2282e-1 (1.38e-2) -	6.3909e-1 (1.42e-2)
	100	2	20000	6.5545e-1 (1.30e-2) -	6.3942e-1 (1.32e-2) -	6.6106e-1 (1.08e-2) -	6.4920e-1 (1.07e-2) -	6.6745e-1 (1.48e-2)
	100	2	50000	6.8985e-1 (1.24e-2) -	6.8137e-1 (1.07e-2) -	6.9341e-1 (1.31e-2) -	6.8547e-1 (1.27e-2) -	7.0000e-1 (1.10e-2)
MAP2	100	2	10000	5.5788e-1 (1.07e-2) -	5.3898e-1 (1.11e-2) -	5.6297e-1 (1.09e-2) -	5.5432e-1 (1.05e-2) -	5.7090e-1 (1.19e-2)
	100	2	20000	5.8745e-1 (1.16e-2) ≈	5.7458e-1 (1.08e-2) -	5.9155e-1 (1.21e-2) ≈	5.8002e-1 (1.07e-2) -	5.9422e-1 (1.31e-2)
	100	2	50000	6.2079e-1 (9.96e-3) -	6.0964e-1 (1.14e-2) -	6.2622e-1 (1.20e-2) ≈	6.2016e-1 (1.11e-2) -	6.2764e-1 (1.36e-2)
MAP3	100	2	10000	5.7924e-1 (1.34e-2) -	5.6794e-1 (7.90e-3) -	5.8226e-1 (1.25e-2) -	5.7848e-1 (8.47e-3) -	5.9144e-1 (1.66e-2)
	100	2	20000	6.0839e-1 (1.37e-2) -	5.9435e-1 (9.57e-3) -	6.1784e-1 (9.30e-3) -	6.0848e-1 (1.31e-2) -	6.1797e-1 (1.58e-2)
	100	2	50000	6.4337e-1 (1.29e-2) -	6.3752e-1 (1.01e-2) -	6.4665e-1 (8.30e-3) ≈	6.4130e-1 (1.33e-2) -	6.5285e-1 (1.70e-2)
MAP4	100	2	10000	5.4003e-1 (1.38e-2) -	5.2254e-1 (8.94e-3) -	5.4442e-1 (1.26e-2) ≈	5.3820e-1 (9.78e-3) -	5.5124e-1 (1.19e-2)
	100	2	20000	5.6936e-1 (1.22e-2) ≈	5.5493e-1 (1.01e-2) -	5.7302e-1 (1.25e-2) ≈	5.6711e-1 (9.06e-3) -	5.7357e-1 (1.27e-2)
	100	2	50000	6.0038e-1 (1.19e-2) -	5.9260e-1 (8.12e-3) -	6.0940e-1 (1.25e-2) ≈	6.0089e-1 (1.25e-2) -	6.1186e-1 (1.54e-2)
MAP5	100	2	10000	6.0012e-1 (1.25e-2) -	5.9078e-1 (1.12e-2) -	6.0332e-1 (1.17e-2) -	5.9939e-1 (1.55e-2) -	6.1616e-1 (1.35e-2)
	100	2	20000	6.3326e-1 (1.25e-2) ≈	6.1972e-1 (1.02e-2) -	6.3877e-1 (1.08e-2) ≈	6.2546e-1 (1.17e-2) -	6.3841e-1 (1.66e-2)
	100	2	50000	6.6808e-1 (1.21e-2) ≈	6.5374e-1 (1.19e-2) -	6.7057e-1 (1.07e-2) -	6.6435e-1 (1.43e-2) -	6.7367e-1 (1.58e-2)
MAP6	100	2	10000	5.2598e-1 (1.19e-2) -	5.1604e-1 (1.10e-2) -	5.3325e-1 (1.24e-2) ≈	5.2268e-1 (1.04e-2) -	5.3680e-1 (1.32e-2)
	100	2	20000	5.6357e-1 (1.26e-2) ≈	5.3965e-1 (1.14e-2) -	5.5984e-1 (1.12e-2) ≈	5.5188e-1 (1.04e-2) -	5.6468e-1 (1.47e-2)
	100	2	50000	5.9091e-1 (1.19e-2) ≈	5.8464e-1 (1.05e-2) -	5.9659e-1 (1.13e-2) ≈	5.8984e-1 (1.25e-2) -	5.9575e-1 (1.22e-2)
MAP7	100	2	10000	5.0773e-1 (1.21e-2) -	4.9610e-1 (9.89e-3) -	5.1459e-1 (1.07e-2) -	5.0696e-1 (1.30e-2) -	5.2304e-1 (1.92e-2)
	100	2	20000	5.4280e-1 (1.14e-2) ≈	5.2668e-1 (9.75e-3) -	5.4211e-1 (9.12e-3) ≈	5.3499e-1 (9.40e-3) -	5.4548e-1 (9.50e-3)
	100	2	50000	5.7236e-1 (8.69e-3) ≈	5.6040e-1 (9.98e-3) -	5.8064e-1 (1.01e-2) ≈	5.7209e-1 (1.20e-2) ≈	5.7761e-1 (1.72e-2)
MAP8	100	2	10000	5.0285e-1 (8.64e-3) -	4.8670e-1 (8.67e-3) -	5.0723e-1 (1.09e-2) -	4.9873e-1 (8.10e-3) -	5.1565e-1 (1.15e-2)
	100	2	20000	5.3158e-1 (1.26e-2) ≈	5.1788e-1 (9.26e-3) -	5.3630e-1 (1.12e-2) ≈	5.2919e-1 (1.25e-2) -	5.3658e-1 (1.28e-2)
	100	2	50000	5.6806e-1 (1.09e-2) ≈	5.5726e-1 (1.22e-2) -	5.7358e-1 (1.03e-2) ≈	5.6257e-1 (8.23e-3) -	5.6313e-1 (1.32e-2)
MAP9	100	2	10000	4.8880e-1 (1.06e-2) -	4.7510e-1 (9.79e-3) -	4.9539e-1 (1.01e-2) -	4.8708e-1 (1.17e-2) -	5.0986e-1 (1.55e-2)
	100	2	20000	5.1494e-1 (1.24e-2) -	5.0558e-1 (8.55e-3) -	5.2208e-1 (1.25e-2) ≈	5.1307e-1 (1.02e-2) -	5.2754e-1 (1.35e-2)
	100	2	50000	5.5160e-1 (1.18e-2) ≈	5.4343e-1 (1.21e-2) -	5.5748e-1 (1.08e-2) ≈	5.5063e-1 (1.03e-2) ≈	5.5405e-1 (1.25e-2)
MAP10	100	2	10000	5.7885e-1 (1.53e-2) -	5.6669e-1 (9.36e-3) -	5.8448e-1 (1.10e-2) -	5.7359e-1 (9.13e-3) -	5.9577e-1 (1.23e-2)
	100	2	20000	6.0549e-1 (1.30e-2) -	5.9699e-1 (8.99e-3) -	6.1276e-1 (1.32e-2) ≈	6.0443e-1 (1.18e-2) -	6.1435e-1 (1.43e-2)
	100	2	50000	6.4700e-1 (1.35e-2) ≈	6.3421e-1 (1.19e-2) -	6.4859e-1 (8.89e-3) ≈	6.4313e-1 (1.08e-2) -	6.5023e-1 (1.12e-2)
				+/-/≈	0/18/12	0/30/0	0/10/20	0/28/2

Tabela A.40: Resultados para o cálculo do IGD para as métricas de Comunicação e Energia em relação ao *grid* de tamanho 6x6, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAI	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	1.2765e+3 (1.54e+2) +	1.2561e+3 (1.73e+2) +	1.2398e+3 (1.78e+2) +	1.3179e+3 (1.91e+2) +	1.5342e+3 (1.22e+2)
	100	2	20000	1.2781e+3 (1.55e+2) +	1.3027e+3 (1.52e+2) +	1.2774e+3 (1.49e+2) +	1.3290e+3 (1.61e+2) +	1.5161e+3 (1.46e+2)
	100	2	50000	1.3806e+3 (1.53e+2) +	1.3582e+3 (1.82e+2) +	1.3595e+3 (1.54e+2) +	1.3969e+3 (1.62e+2) +	1.6074e+3 (1.06e+2)
MAP2	100	2	10000	1.0655e+3 (1.84e+2) +	1.0202e+3 (2.04e+2) +	1.0109e+3 (1.66e+2) +	1.1369e+3 (1.94e+2) +	1.2947e+3 (1.59e+2)
	100	2	20000	1.0980e+3 (1.52e+2) +	1.1014e+3 (1.39e+2) +	9.8912e+2 (2.01e+2) +	1.1417e+3 (1.28e+2) +	1.3451e+3 (1.48e+2)
	100	2	50000	1.1727e+3 (1.28e+2) +	1.1448e+3 (1.74e+2) +	1.1083e+3 (1.61e+2) +	1.2219e+3 (2.16e+2) +	1.4200e+3 (1.50e+2)
MAP3	100	2	10000	1.1628e+3 (2.35e+2) +	1.1388e+3 (2.11e+2) +	1.0829e+3 (2.04e+2) +	1.2337e+3 (1.16e+2) +	1.3970e+3 (1.29e+2)
	100	2	20000	1.2248e+3 (1.66e+2) +	1.2061e+3 (1.73e+2) +	1.0863e+3 (1.70e+2) +	1.2318e+3 (2.16e+2) +	1.4037e+3 (1.77e+2)
	100	2	50000	1.2959e+3 (1.64e+2) +	1.2405e+3 (1.74e+2) +	1.1913e+3 (1.71e+2) +	1.3106e+3 (1.76e+2) +	1.5242e+3 (1.34e+2)
MAP4	100	2	10000	1.1047e+3 (1.74e+2) +	1.0602e+3 (1.66e+2) +	1.0283e+3 (2.33e+2) +	1.0705e+3 (1.81e+2) +	1.3266e+3 (1.32e+2)
	100	2	20000	1.0838e+3 (1.78e+2) +	1.0832e+3 (2.08e+2) +	1.0086e+3 (1.87e+2) +	1.1204e+3 (1.63e+2) +	1.3164e+3 (1.28e+2)
	100	2	50000	1.1401e+3 (2.14e+2) +	1.1114e+3 (2.21e+2) +	1.0514e+3 (2.40e+2) +	1.1719e+3 (1.82e+2) +	1.3389e+3 (1.87e+2)
MAP5	100	2	10000	1.2626e+3 (1.29e+2) +	1.1750e+3 (1.60e+2) +	1.1603e+3 (1.58e+2) +	1.2288e+3 (1.67e+2) +	1.4564e+3 (1.08e+2)
	100	2	20000	1.2651e+3 (1.40e+2) +	1.2117e+3 (1.62e+2) +	1.1813e+3 (1.84e+2) +	1.3107e+3 (1.52e+2) +	1.4539e+3 (1.92e+2)
	100	2	50000	1.3712e+3 (1.29e+2) +	1.3005e+3 (1.67e+2) +	1.2626e+3 (1.58e+2) +	1.3656e+3 (1.29e+2) +	1.5682e+3 (1.03e+2)
MAP6	100	2	10000	1.0655e+3 (1.55e+2) +	1.0010e+3 (1.51e+2) +	9.8484e+2 (2.15e+2) +	1.0263e+3 (1.86e+2) +	1.2805e+3 (1.60e+2)
	100	2	20000	1.0738e+3 (1.38e+2) +	1.0231e+3 (1.87e+2) +	1.0547e+3 (1.60e+2) +	1.1125e+3 (1.59e+2) +	1.2984e+3 (1.42e+2)
	100	2	50000	1.1362e+3 (1.89e+2) +	1.0811e+3 (1.77e+2) +	1.0574e+3 (1.78e+2) +	1.1041e+3 (1.75e+2) +	1.3323e+3 (1.66e+2)
MAP7	100	2	10000	1.0646e+3 (1.68e+2) +	9.9815e+2 (2.56e+2) +	9.8142e+2 (2.12e+2) +	1.0529e+3 (1.34e+2) +	1.2035e+3 (1.69e+2)
	100	2	20000	9.6919e+2 (2.31e+2) +	1.0247e+3 (1.47e+2) +	9.4112e+2 (2.09e+2) +	1.0793e+3 (1.81e+2) +	1.2597e+3 (1.58e+2)
	100	2	50000	1.1190e+3 (1.72e+2) +	1.1113e+3 (1.82e+2) +	9.7951e+2 (2.36e+2) +	1.1150e+3 (1.69e+2) +	1.2910e+3 (1.62e+2)
MAP8	100	2	10000	9.8784e+2 (1.31e+2) +	9.8137e+2 (1.57e+2) +	8.4143e+2 (1.77e+2) +	9.9155e+2 (1.53e+2) +	1.2146e+3 (1.37e+2)
	100	2	20000	1.0623e+3 (1.71e+2) +	9.9826e+2 (1.68e+2) +	8.9673e+2 (2.18e+2) +	1.0246e+3 (2.14e+2) +	1.2533e+3 (1.49e+2)
	100	2	50000	1.1084e+3 (2.01e+2) +	1.0319e+3 (1.98e+2) +	9.3997e+2 (1.86e+2) +	1.0767e+3 (1.56e+2) +	1.3108e+3 (1.29e+2)
MAP9	100	2	10000	9.5858e+2 (1.32e+2) +	9.5785e+2 (1.68e+2) +	8.9760e+2 (1.88e+2) +	9.6690e+2 (2.08e+2) +	1.1100e+3 (1.99e+2)
	100	2	20000	9.3645e+2 (2.18e+2) +	9.2534e+2 (2.04e+2) +	8.8697e+2 (1.61e+2) +	1.0185e+3 (1.56e+2) +	1.2363e+3 (1.70e+2)
	100	2	50000	1.0324e+3 (1.49e+2) +	9.4476e+2 (2.23e+2) +	9.0579e+2 (2.04e+2) +	1.0600e+3 (1.96e+2) +	1.2463e+3 (1.45e+2)
MAP10	100	2	10000	1.1915e+3 (1.77e+2) +	1.1531e+3 (1.82e+2) +	1.1280e+3 (1.63e+2) +	1.2030e+3 (1.93e+2) +	1.4024e+3 (1.45e+2)
	100	2	20000	1.2263e+3 (1.61e+2) +	1.1662e+3 (1.72e+2) +	1.1770e+3 (1.56e+2) +	1.2340e+3 (1.84e+2) +	1.4065e+3 (1.61e+2)
	100	2	50000	1.3155e+3 (1.39e+2) +	1.2480e+3 (2.05e+2) +	1.1906e+3 (1.69e+2) +	1.3473e+3 (9.04e+1) +	1.4606e+3 (1.32e+2)
+/-/≈				30/0/0	30/0/0	30/0/0	30/0/0	

Tabela A.41: Resultados para o cálculo do *Hypervolume* para as métricas de Energia e Balanceamento de Carga em relação ao *grid* de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAI	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	5.2060e-1 (7.46e-3) ≈	5.0483e-1 (9.27e-3) -	5.2544e-1 (1.13e-2) ≈	5.1826e-1 (1.04e-2) -	5.2594e-1 (1.29e-2)
	100	2	20000	5.4801e-1 (8.74e-3) ≈	5.3229e-1 (8.72e-3) -	5.5240e-1 (9.01e-3) +	5.4363e-1 (9.89e-3) ≈	5.4715e-1 (9.41e-3)
	100	2	50000	5.8886e-1 (8.77e-3) +	5.7177e-1 (8.11e-3) -	5.9277e-1 (7.32e-3) +	5.7996e-1 (1.04e-2) ≈	5.7681e-1 (1.05e-2)
MAP2	100	2	10000	4.9018e-1 (7.54e-3) -	4.7903e-1 (8.78e-3) -	4.9752e-1 (8.95e-3) ≈	4.8769e-1 (1.05e-2) -	4.9465e-1 (7.67e-3)
	100	2	20000	5.1950e-1 (1.19e-2) ≈	5.0790e-1 (9.15e-3) -	5.2760e-1 (9.61e-3) +	5.1962e-1 (1.02e-2) ≈	5.1892e-1 (1.24e-2)
	100	2	50000	5.5641e-1 (1.01e-2) -	5.4343e-1 (8.42e-3) -	5.6215e-1 (1.04e-2) +	5.4804e-1 (1.35e-2) -	5.4964e-1 (1.11e-2)
MAP3	100	2	10000	4.9973e-1 (1.02e-2) -	4.8589e-1 (1.47e-2) -	5.0292e-1 (1.05e-2) ≈	4.9854e-1 (1.15e-2) -	5.0543e-1 (1.18e-2)
	100	2	20000	5.2766e-1 (1.00e-2) ≈	5.1507e-1 (8.97e-3) -	5.3373e-1 (1.01e-2) +	5.2403e-1 (7.95e-3) ≈	5.2313e-1 (1.26e-2)
	100	2	50000	5.6281e-1 (8.69e-3) ≈	5.4812e-1 (9.87e-3) -	5.7149e-1 (8.51e-3) +	5.5766e-1 (1.29e-2) -	5.5885e-1 (1.46e-2)
MAP4	100	2	10000	4.8350e-1 (9.91e-3) ≈	4.6785e-1 (9.92e-3) -	4.8744e-1 (8.76e-3) ≈	4.7719e-1 (8.44e-3) -	4.8301e-1 (1.05e-2)
	100	2	20000	5.1026e-1 (7.40e-3) ≈	4.9509e-1 (1.10e-2) -	5.1421e-1 (1.12e-2) -	5.0851e-1 (9.26e-3) ≈	5.1104e-1 (1.35e-2)
	100	2	50000	5.4225e-1 (9.70e-3) +	5.2943e-1 (9.34e-3) ≈	5.5329e-1 (9.65e-3) +	5.3938e-1 (1.08e-2) ≈	5.3291e-1 (1.21e-2)
MAP5	100	2	10000	4.7769e-1 (1.12e-2) ≈	4.6338e-1 (8.10e-3) -	4.8443e-1 (8.00e-3) ≈	4.7486e-1 (1.14e-2) ≈	4.7913e-1 (9.71e-3)
	100	2	20000	5.0470e-1 (1.03e-2) ≈	4.9247e-1 (1.04e-2) -	5.0942e-1 (1.03e-2) ≈	5.0000e-1 (9.61e-3) ≈	5.0498e-1 (1.39e-2)
	100	2	50000	5.3896e-1 (8.41e-3) +	5.2707e-1 (1.03e-2) ≈	5.4436e-1 (9.06e-3) +	5.3240e-1 (1.09e-2) ≈	5.3083e-1 (1.10e-2)
MAP6	100	2	10000	4.8082e-1 (1.21e-2) ≈	4.6378e-1 (8.10e-3) -	4.7897e-1 (8.74e-3) ≈	4.7386e-1 (8.59e-3) -	4.8292e-1 (1.22e-2)
	100	2	20000	5.0506e-1 (1.06e-2) ≈	4.8978e-1 (9.81e-3) -	5.1201e-1 (1.16e-2) +	5.0002e-1 (1.01e-2) ≈	4.9997e-1 (1.23e-2)
	100	2	50000	5.3662e-1 (9.77e-3) ≈	5.2512e-1 (8.07e-3) -	5.4193e-1 (9.39e-3) +	5.3623e-1 (7.89e-3) ≈	5.3215e-1 (1.12e-2)
MAP7	100	2	10000	4.6907e-1 (9.92e-3) ≈	4.5671e-1 (1.15e-2) -	4.7529e-1 (9.19e-3) ≈	4.6760e-1 (1.04e-2) -	4.7258e-1 (8.60e-3)
	100	2	20000	4.9460e-1 (1.13e-2) ≈	4.8468e-1 (7.95e-3) -	5.0244e-1 (1.12e-2) ≈	4.9554e-1 (1.12e-2) ≈	4.9803e-1 (1.17e-2)
	100	2	50000	5.3089e-1 (9.63e-3) +	5.1419e-1 (9.41e-3) -	5.3491e-1 (8.23e-3) +	5.2386e-1 (7.68e-3) ≈	5.2109e-1 (1.39e-2)
MAP8	100	2	10000	4.6609e-1 (1.27e-2) ≈	4.5232e-1 (9.93e-3) -	4.7116e-1 (1.16e-2) ≈	4.6176e-1 (1.40e-2) -	4.7107e-1 (1.29e-2)
	100	2	20000	4.9195e-1 (1.01e-2) ≈	4.8089e-1 (8.51e-3) -	5.0114e-1 (1.10e-2) ≈	4.8960e-1 (1.02e-2) ≈	4.9830e-1 (9.49e-3)
	100	2	50000	5.2530e-1 (1.03e-2) +	5.1377e-1 (1.02e-2) ≈	5.3066e-1 (8.60e-3) +	5.2083e-1 (1.01e-2) ≈	5.1766e-1 (1.11e-2)
MAP9	100	2	10000	4.5552e-1 (8.39e-3) -	4.4563e-1 (9.50e-3) -	4.6204e-1 (1.04e-2) ≈	4.5304e-1 (9.69e-3) -	4.6446e-1 (1.15e-2)
	100	2	20000	4.8544e-1 (1.06e-2) ≈	4.7073e-1 (7.64e-3) -	4.9227e-1 (1.12e-2) +	4.7917e-1 (9.22e-3) ≈	4.8102e-1 (1.03e-2)
	100	2	50000	5.1634e-1 (9.48e-3) +	5.0515e-1 (9.49e-3) ≈	5.2564e-1 (7.97e-3) +	5.1279e-1 (8.33e-3) ≈	5.0833e-1 (1.24e-2)
MAP10	100	2	10000	4.7156e-1 (9.04e-3) ≈	4.5495e-1 (9.57e-3) -	4.7428e-1 (7.99e-3) ≈	4.6687e-1 (9.62e-3) -	4.7297e-1 (1.06e-2)
	100	2	20000	4.9316e-1 (1.07e-2) ≈	4.8584e-1 (1.03e-2) -	4.9879e-1 (1.00e-2) ≈	4.9180e-1 (1.12e-2) ≈	4.9492e-1 (1.30e-2)
	100	2	50000	5.3113e-1 (9.70e-3) +	5.1702e-1 (8.19e-3) ≈	5.3719e-1 (1.07e-2) +	5.2989e-1 (1.14e-2) +	5.1997e-1 (1.53e-2)
+/-/≈				8/3/19	0/2/5	16/0/14	19/20	

Tabela A.42: Resultados para o cálculo do IGD para as métricas de Energia e Balanceamento de Carga em relação ao grid de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	N	M	FE	NSGAII	NSGAIII	SPEA2	KnEA	PESAI
MAP1	100	2	10000	1.0736e+2 (9.42e+0) +	1.0929e+2 (8.90e+0) +	1.0310e+2 (8.75e+0) +	1.0956e+2 (9.54e+0) +	1.1679e+2 (1.02e+1)
	100	2	20000	1.0790e+2 (1.02e+1) +	1.1066e+2 (7.73e+0) +	1.0706e+2 (1.03e+1) +	1.0810e+2 (9.39e+0) +	1.1916e+2 (1.07e+1)
	100	2	50000	1.1076e+2 (9.90e+0) +	1.1179e+2 (8.69e+0) +	1.0610e+2 (1.02e+1) +	1.1353e+2 (8.97e+0) +	1.2043e+2 (1.28e+1)
MAP2	100	2	10000	1.0246e+2 (6.94e+0) +	1.0139e+2 (6.42e+0) +	9.6830e+1 (6.78e+0) +	1.0286e+2 (7.55e+0) +	1.1189e+2 (1.02e+1)
	100	2	20000	1.0546e+2 (7.43e+0) +	1.0363e+2 (6.84e+0) +	9.7698e+1 (7.23e+0) +	1.0146e+2 (7.81e+0) +	1.0683e+2 (1.07e+1)
	100	2	50000	1.0300e+2 (8.50e+0) +	1.0320e+2 (7.51e+0) +	9.8532e+1 (7.78e+0) +	1.0743e+2 (1.08e+1) ≈	1.1093e+2 (1.10e+1)
MAP3	100	2	10000	1.0493e+2 (8.34e+0) ≈	1.0259e+2 (8.32e+0) +	9.9963e+1 (7.77e+0) +	1.0336e+2 (9.46e+0) +	1.0969e+2 (1.04e+1)
	100	2	20000	1.0346e+2 (9.79e+0) +	1.0453e+2 (7.80e+0) +	1.0203e+2 (8.09e+0) +	1.0506e+2 (9.06e+0) +	1.1246e+2 (8.49e+0)
	100	2	50000	1.0513e+2 (7.75e+0) +	1.0593e+2 (9.37e+0) ≈	1.0203e+2 (6.94e+0) +	1.0610e+2 (7.59e+0) ≈	1.1026e+2 (1.21e+1)
MAP4	100	2	10000	9.5930e+1 (7.08e+0) +	9.8662e+1 (7.45e+0) +	9.7396e+1 (8.96e+0) +	9.9562e+1 (6.87e+0) +	1.0923e+2 (9.82e+0)
	100	2	20000	1.0120e+2 (8.84e+0) +	1.0306e+2 (8.20e+0) +	9.7297e+1 (9.53e+0) +	1.0110e+2 (1.02e+1) +	1.0983e+2 (7.12e+0)
	100	2	50000	1.0446e+2 (7.00e+0) +	1.0200e+2 (9.65e+0) +	1.0066e+2 (8.56e+0) +	1.0306e+2 (7.67e+0) +	1.1383e+2 (1.09e+1)
MAP5	100	2	10000	1.0033e+2 (7.70e+0) +	9.8095e+1 (7.90e+0) +	9.2831e+1 (7.40e+0) +	9.9496e+1 (8.05e+0) +	1.0909e+2 (7.87e+0)
	100	2	20000	1.0003e+2 (8.49e+0) +	1.0020e+2 (6.71e+0) +	9.5331e+1 (7.12e+0) +	1.0113e+2 (9.08e+0) +	1.0683e+2 (7.98e+0)
	100	2	50000	1.0110e+2 (5.34e+0) ≈	1.0176e+2 (7.97e+0) ≈	9.9165e+1 (6.33e+0) +	1.0286e+2 (6.68e+0) ≈	1.0456e+2 (1.04e+1)
MAP6	100	2	10000	9.6197e+1 (7.81e+0) +	9.6063e+1 (8.89e+0) +	9.6197e+1 (8.01e+0) +	9.8962e+1 (9.38e+0) +	1.0573e+2 (1.12e+1)
	100	2	20000	9.8597e+1 (7.02e+0) +	9.9529e+1 (8.91e+0) +	9.7064e+1 (5.91e+0) +	1.0190e+2 (9.01e+0) +	1.1093e+2 (8.90e+0)
	100	2	50000	1.0080e+2 (6.94e+0) +	1.0293e+2 (7.01e+0) +	9.7265e+1 (6.46e+0) +	1.0120e+2 (7.33e+0) +	1.1123e+2 (9.89e+0)
MAP7	100	2	10000	9.7162e+1 (6.36e+0) +	9.6895e+1 (6.16e+0) +	9.4031e+1 (6.44e+0) +	9.7330e+1 (7.39e+0) +	1.0353e+2 (8.82e+0)
	100	2	20000	9.9863e+1 (7.57e+0) +	9.7330e+1 (8.25e+0) +	9.3898e+1 (8.42e+0) +	9.7863e+1 (8.68e+0) +	1.0609e+2 (6.64e+0)
	100	2	50000	1.0063e+2 (5.95e+0) +	9.9763e+1 (8.44e+0) +	9.8565e+1 (7.49e+0) +	1.0233e+2 (7.56e+0) ≈	1.0530e+2 (9.41e+0)
MAP8	100	2	10000	9.5030e+1 (9.36e+0) +	9.6462e+1 (8.72e+0) +	9.4797e+1 (7.68e+0) +	9.7429e+1 (6.11e+0) +	1.0693e+2 (6.29e+0)
	100	2	20000	9.7830e+1 (6.86e+0) +	9.8129e+1 (8.22e+0) +	9.5331e+1 (6.66e+0) +	1.0076e+2 (8.00e+0) +	1.0579e+2 (9.33e+0)
	100	2	50000	9.8931e+1 (6.87e+0) +	9.9830e+1 (9.23e+0) +	9.7765e+1 (6.98e+0) +	1.0280e+2 (7.90e+0) +	1.0993e+2 (1.04e+1)
MAP9	100	2	10000	9.5263e+1 (6.60e+0) +	9.4663e+1 (6.98e+0) +	9.0398e+1 (6.44e+0) +	9.6629e+1 (7.39e+0) +	1.0130e+2 (1.03e+1)
	100	2	20000	9.5297e+1 (5.56e+0) +	9.7562e+1 (6.72e+0) +	9.2865e+1 (7.20e+0) +	9.7496e+1 (5.60e+0) +	1.0336e+2 (9.06e+0)
	100	2	50000	9.6998e+1 (5.52e+0) +	9.7597e+1 (7.69e+0) +	9.4466e+1 (8.09e+0) +	9.7264e+1 (8.57e+0) +	1.0400e+2 (1.07e+1)
MAP10	100	2	10000	9.9062e+1 (7.46e+0) ≈	9.6929e+1 (8.38e+0) +	9.3464e+1 (6.32e+0) +	9.6196e+1 (5.82e+0) +	1.0283e+2 (8.16e+0)
	100	2	20000	9.9130e+1 (8.72e+0) +	9.7296e+1 (7.60e+0) +	9.5565e+1 (6.93e+0) +	9.9129e+1 (7.03e+0) +	1.0460e+2 (1.04e+1)
	100	2	50000	1.0106e+2 (8.47e+0) +	9.9363e+1 (8.29e+0) +	9.8931e+1 (5.60e+0) +	1.0306e+2 (8.55e+0) +	1.0850e+2 (1.05e+1)
+/-/≈				27/0/3	28/0/2	30/0/0	26/0/4	

Tabela A.43: Resultados para o cálculo do Hypervolume para as métricas de Tolerância a Falhas e Energia em relação ao grid de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	N	M	D	FE	NSGAII	NSGAIII	SPEA2	KnEA	PESAI
MAP1	100	2	1	10000	6.5677e-1 (1.37e-2) -	6.4337e-1 (1.66e-2) -	6.5672e-1 (1.73e-2) -	6.5927e-1 (1.87e-2) -	6.9415e-1 (2.53e-2)
	100	2	2	20000	6.9725e-1 (1.36e-2) -	6.8725e-1 (1.40e-2) -	6.9379e-1 (1.96e-2) -	6.9792e-1 (1.33e-2) -	7.3780e-1 (2.27e-2)
	100	2	3	50000	7.4031e-1 (1.55e-2) -	7.3349e-1 (1.40e-2) -	7.3929e-1 (2.02e-2) -	7.4470e-1 (1.54e-2) -	7.7148e-1 (2.31e-2)
MAP2	100	2	1	10000	6.2841e-1 (1.98e-2) -	6.0988e-1 (1.50e-2) -	6.2983e-1 (2.01e-2) -	6.2220e-1 (2.45e-2) -	6.6092e-1 (2.38e-2)
	100	2	2	20000	6.7517e-1 (2.07e-2) -	6.5240e-1 (1.65e-2) -	6.6647e-1 (1.67e-2) -	6.6718e-1 (1.58e-2) -	6.9518e-1 (2.17e-2)
	100	2	3	50000	7.1340e-1 (1.52e-2) -	7.0443e-1 (1.26e-2) -	7.1290e-1 (1.92e-2) -	7.1521e-1 (1.57e-2) -	7.3786e-1 (2.18e-2)
MAP3	100	2	1	10000	6.3071e-1 (2.19e-2) -	6.1999e-1 (2.05e-2) -	6.3350e-1 (1.63e-2) -	6.3792e-1 (2.15e-2) -	6.6502e-1 (2.60e-2)
	100	2	2	20000	6.8022e-1 (2.05e-2) -	6.6314e-1 (1.85e-2) -	6.6863e-1 (1.89e-2) -	6.7639e-1 (1.89e-2) -	7.0218e-1 (2.53e-2)
	100	2	3	50000	7.2272e-1 (1.77e-2) -	7.1316e-1 (1.24e-2) -	7.2134e-1 (1.34e-2) -	7.1471e-1 (1.48e-2) -	7.5150e-1 (2.76e-2)
MAP4	100	2	1	10000	6.0953e-1 (2.44e-2) -	5.9273e-1 (2.40e-2) -	6.1627e-1 (2.17e-2) -	6.0691e-1 (2.18e-2) -	6.4963e-1 (2.96e-2)
	100	2	2	20000	6.5717e-1 (2.16e-2) -	6.4065e-1 (2.22e-2) -	6.5405e-1 (1.95e-2) -	6.5986e-1 (2.09e-2) -	6.7575e-1 (2.26e-2)
	100	2	3	50000	7.0863e-1 (1.58e-2) -	6.9220e-1 (2.08e-2) -	6.9719e-1 (1.76e-2) -	7.0498e-1 (1.61e-2) -	7.2655e-1 (2.76e-2)
MAP5	100	2	1	10000	6.0943e-1 (1.73e-2) -	5.8787e-1 (1.97e-2) -	6.0178e-1 (2.12e-2) -	6.0555e-1 (2.11e-2) -	6.3680e-1 (2.16e-2)
	100	2	2	20000	6.4613e-1 (1.77e-2) -	6.3196e-1 (2.36e-2) -	6.4374e-1 (2.20e-2) -	6.5286e-1 (2.04e-2) -	6.7774e-1 (2.59e-2)
	100	2	3	50000	6.9698e-1 (1.83e-2) -	6.7845e-1 (2.07e-2) -	6.8739e-1 (1.66e-2) -	6.9555e-1 (2.34e-2) -	7.1435e-1 (2.68e-2)
MAP6	100	2	1	10000	6.0250e-1 (2.73e-2) -	5.7648e-1 (1.90e-2) -	5.9962e-1 (2.69e-2) -	6.0575e-1 (2.78e-2) -	6.4561e-1 (2.43e-2)
	100	2	2	20000	6.4181e-1 (2.20e-2) -	6.2961e-1 (2.14e-2) -	6.4625e-1 (2.08e-2) -	6.4256e-1 (2.44e-2) -	6.7122e-1 (2.58e-2)
	100	2	3	50000	7.0237e-1 (2.20e-2) -	6.8776e-1 (1.64e-2) -	6.9610e-1 (2.08e-2) -	7.0307e-1 (1.98e-2) -	7.1760e-1 (2.52e-2)
MAP7	100	2	1	10000	6.0452e-1 (2.32e-2) -	5.7000e-1 (2.31e-2) -	5.9967e-1 (2.39e-2) -	5.9616e-1 (2.12e-2) -	6.3412e-1 (2.32e-2)
	100	2	2	20000	6.4123e-1 (2.70e-2) -	6.1600e-1 (2.64e-2) -	6.3717e-1 (2.25e-2) -	6.3744e-1 (2.57e-2) -	6.5885e-1 (2.80e-2)
	100	2	3	50000	6.8849e-1 (1.98e-2) -	6.7702e-1 (2.05e-2) -	6.8408e-1 (2.43e-2) -	6.8744e-1 (1.95e-2) -	7.1140e-1 (2.81e-2)
MAP8	100	2	1	10000	5.9212e-1 (2.52e-2) -	5.6780e-1 (1.58e-2) -	5.9190e-1 (1.91e-2) -	5.8719e-1 (2.08e-2) -	6.2907e-1 (2.50e-2)
	100	2	2	20000	6.3851e-1 (2.71e-2) -	6.2270e-1 (2.44e-2) -	6.2990e-1 (2.01e-2) -	6.2242e-1 (2.00e-2) -	6.5948e-1 (3.06e-2)
	100	2	3	50000	6.7761e-1 (2.10e-2) -	6.6529e-1 (2.28e-2) -	6.8271e-1 (1.66e-2) -	6.8285e-1 (1.94e-2) -	7.0511e-1 (2.22e-2)
MAP9	100	2	1	10000	5.7789e-1 (2.39e-2) -	5.5111e-1 (1.74e-2) -	5.8082e-1 (2.05e-2) -	5.8501e-1 (1.97e-2) -	6.1457e-1 (2.23e-2)
	100	2	2	20000	6.2351e-1 (2.47e-2) -	6.0174e-1 (2.58e-2) -	6.2255e-1 (2.24e-2) -	6.1937e-1 (2.27e-2) -	6.5243e-1 (2.92e-2)
	100	2	3	50000	6.7098e-1 (2.03e-2) -	6.6762e-1 (2.34e-2) -	6.6401e-1 (1.90e-2) -	6.6816e-1 (2.59e-2) -	6.9002e-1 (2.15e-2)
MAP10	100	2	1	10000	5.8376e-1 (2.44e-2) -	5.7687e-1 (2.31e-2) -	6.0007e-1 (1.60e-2) -	5.9733e-1 (2.20e-2) -	6.2989e-1 (2.34e-2)
	100	2	2	20000	6.3984e-1 (2.71e-2) -	6.1384e-1 (2.10e-2) -	6.3806e-1 (1.47e-2) -	6.3720e-1 (2.31e-2) -	6.6044e-1 (2.44e-2)
	100	2	3	50000	6.8153e-1 (2.23e-2) -	6.7598e-1 (2.27e-2) -	6.8693e-1 (1.97e-2) -	6.9222e-1 (2.10e-2) -	7.1041e-1 (2.58e-2)
+/-/≈				0/30/0	0/30/0	0/30/0	0/30/0		

Tabela A.44: Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Energia em relação ao *grid* de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>D</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAI
MAP1	100	2	1	10000	1.8702e+2 (1.02e+1) +	1.7801e+2 (1.03e+1) +	1.8798e+2 (8.73e+0) +	1.8709e+2 (1.08e+1) +	2.1737e+2 (8.46e+0)
	100	2	2	20000	2.0378e+2 (1.05e+1) +	1.9500e+2 (8.58e+0) +	2.0454e+2 (8.88e+0) +	2.0292e+2 (9.72e+0) +	2.2953e+2 (8.39e+0)
	100	2	3	50000	2.2155e+2 (8.22e+0) +	2.1676e+2 (8.89e+0) +	2.2388e+2 (9.90e+0) +	2.2275e+2 (9.63e+0) +	2.4208e+2 (7.56e+0)
MAP2	100	2	1	10000	1.8092e+2 (1.38e+1) +	1.6859e+2 (1.53e+1) +	1.7804e+2 (1.29e+1) +	1.7926e+2 (1.37e+1) +	2.1153e+2 (1.13e+1)
	100	2	2	20000	1.9662e+2 (1.15e+1) +	1.8392e+2 (1.26e+1) +	1.8997e+2 (1.12e+1) +	1.9147e+2 (1.29e+1) +	2.1840e+2 (1.01e+1)
	100	2	3	50000	2.1223e+2 (9.45e+0) +	2.0085e+2 (8.54e+0) +	2.1649e+2 (9.09e+0) +	2.0987e+2 (1.01e+1) +	2.2970e+2 (9.76e+0)
MAP3	100	2	1	10000	1.8325e+2 (1.29e+1) +	1.7145e+2 (1.36e+1) +	1.7561e+2 (1.09e+1) +	1.8219e+2 (1.31e+1) +	2.0828e+2 (1.13e+1)
	100	2	2	20000	1.9443e+2 (1.55e+1) +	1.8775e+2 (1.05e+1) +	1.9606e+2 (1.24e+1) +	1.9387e+2 (1.10e+1) +	2.2219e+2 (1.11e+1)
	100	2	3	50000	2.1579e+2 (8.15e+0) +	2.0631e+2 (9.77e+0) +	2.1423e+2 (8.68e+0) +	2.1180e+2 (9.53e+0) +	2.3485e+2 (1.12e+1)
MAP4	100	2	1	10000	1.8054e+2 (1.39e+1) +	1.6941e+2 (1.77e+1) +	1.8065e+2 (1.53e+1) +	1.8419e+2 (1.49e+1) +	2.0578e+2 (1.20e+1)
	100	2	2	20000	1.9213e+2 (1.32e+1) +	1.8527e+2 (1.58e+1) +	1.9253e+2 (1.22e+1) +	1.9047e+2 (1.32e+1) +	2.1427e+2 (9.29e+0)
	100	2	3	50000	2.0634e+2 (6.97e+0) +	2.0244e+2 (1.12e+1) +	2.0740e+2 (9.55e+0) +	2.1006e+2 (1.09e+1) +	2.2992e+2 (1.18e+1)
MAP5	100	2	1	10000	1.7540e+2 (1.75e+1) +	1.6961e+2 (1.57e+1) +	1.7646e+2 (1.37e+1) +	1.8187e+2 (1.35e+1) +	2.0391e+2 (1.35e+1)
	100	2	2	20000	1.8787e+2 (1.54e+1) +	1.8178e+2 (1.67e+1) +	1.8966e+2 (1.53e+1) +	1.9020e+2 (1.32e+1) +	2.1370e+2 (1.06e+1)
	100	2	3	50000	2.0521e+2 (1.03e+1) +	1.9964e+2 (1.49e+1) +	2.0471e+2 (1.18e+1) +	2.0999e+2 (1.35e+1) +	2.2682e+2 (8.53e+0)
MAP6	100	2	1	10000	1.7924e+2 (1.42e+1) +	1.7634e+2 (1.26e+1) +	1.8090e+2 (1.44e+1) +	1.7961e+2 (1.29e+1) +	2.0737e+2 (1.08e+1)
	100	2	2	20000	1.8491e+2 (1.56e+1) +	1.8513e+2 (1.60e+1) +	1.8731e+2 (1.02e+1) +	1.9032e+2 (1.51e+1) +	2.1532e+2 (1.08e+1)
	100	2	3	50000	2.0614e+2 (1.24e+1) +	1.9526e+2 (1.20e+1) +	2.0654e+2 (1.17e+1) +	2.0537e+2 (1.23e+1) +	2.2423e+2 (1.04e+1)
MAP7	100	2	1	10000	1.7486e+2 (1.52e+1) +	1.7424e+2 (1.40e+1) +	1.8143e+2 (1.32e+1) +	1.8153e+2 (1.45e+1) +	2.0079e+2 (1.19e+1)
	100	2	2	20000	1.8893e+2 (1.34e+1) +	1.8436e+2 (1.47e+1) +	1.9058e+2 (1.45e+1) +	1.9401e+2 (1.42e+1) +	2.0941e+2 (1.19e+1)
	100	2	3	50000	2.0334e+2 (1.37e+1) +	1.9373e+2 (1.72e+1) +	2.0298e+2 (1.11e+1) +	2.0573e+2 (1.52e+1) +	2.2402e+2 (1.12e+1)
MAP8	100	2	1	10000	1.8039e+2 (1.43e+1) +	1.7460e+2 (1.76e+1) +	1.8159e+2 (1.54e+1) +	1.7953e+2 (1.49e+1) +	2.0071e+2 (1.23e+1)
	100	2	2	20000	1.9185e+2 (1.41e+1) +	1.7952e+2 (1.57e+1) +	1.8879e+2 (1.46e+1) +	1.9539e+2 (1.27e+1) +	2.0970e+2 (1.15e+1)
	100	2	3	50000	2.0639e+2 (1.36e+1) +	2.0023e+2 (1.55e+1) +	2.0630e+2 (1.18e+1) +	2.0403e+2 (1.47e+1) +	2.2060e+2 (1.34e+1)
MAP9	100	2	1	10000	1.7640e+2 (1.29e+1) +	1.7247e+2 (1.22e+1) +	1.7906e+2 (1.40e+1) +	1.7886e+2 (1.27e+1) +	1.9579e+2 (1.09e+1)
	100	2	2	20000	1.8938e+2 (1.38e+1) +	1.8166e+2 (1.49e+1) +	1.8460e+2 (1.56e+1) +	1.8968e+2 (1.45e+1) +	2.0873e+2 (1.21e+1)
	100	2	3	50000	2.0207e+2 (1.34e+1) +	1.9359e+2 (1.53e+1) +	2.0515e+2 (1.49e+1) +	2.0492e+2 (1.35e+1) +	2.2002e+2 (1.24e+1)
MAP10	100	2	1	10000	1.7796e+2 (1.68e+1) +	1.7132e+2 (1.77e+1) +	1.7844e+2 (1.53e+1) +	1.7828e+2 (1.59e+1) +	2.0254e+2 (9.77e+0)
	100	2	2	20000	1.9102e+2 (1.56e+1) +	1.7915e+2 (1.57e+1) +	1.8823e+2 (1.58e+1) +	1.8882e+2 (1.52e+1) +	2.1070e+2 (1.18e+1)
	100	2	3	50000	2.0234e+2 (1.22e+1) +	1.9383e+2 (1.39e+1) +	2.0547e+2 (1.28e+1) +	2.0231e+2 (1.19e+1) +	2.2094e+2 (9.74e+0)
+/-/≈					30/0/0	30/0/0	30/0/0	30/0/0	

Tabela A.45: Resultados para o cálculo do *Hypervolume* para as métricas de Tolerância a Falhas e Comunicação em relação ao *grid* de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAII	NSGAIII	SPEA2	KnEA	PESAI
MAP1	100	2	10000	6.0517e-1 (1.83e-2) -	6.0759e-1 (1.97e-2) -	6.1093e-1 (2.00e-2) -	6.0999e-1 (1.99e-2) -	6.2167e-1 (1.62e-2)
	100	2	20000	6.2185e-1 (1.63e-2) -	6.2250e-1 (1.93e-2) -	6.2284e-1 (1.67e-2) -	6.2657e-1 (1.98e-2) -	6.3753e-1 (1.89e-2)
	100	2	50000	6.4739e-1 (2.28e-2) ≈	6.4488e-1 (2.25e-2) ≈	6.5196e-1 (2.07e-2) ≈	6.4570e-1 (2.16e-2) -	6.5566e-1 (2.07e-2)
MAP2	100	2	10000	5.7137e-1 (1.32e-2) -	5.5880e-1 (7.62e-3) -	5.6775e-1 (1.21e-2) -	5.6639e-1 (9.59e-3) -	5.8301e-1 (8.88e-3)
	100	2	20000	5.8854e-1 (1.54e-2) -	5.7335e-1 (1.31e-2) -	5.8495e-1 (1.34e-2) -	5.8082e-1 (7.83e-3) -	5.9757e-1 (1.37e-2)
	100	2	50000	6.0496e-1 (1.65e-2) -	6.0003e-1 (1.58e-2) -	6.0151e-1 (1.42e-2) -	6.0333e-1 (1.80e-2) -	6.1297e-1 (1.56e-2)
MAP3	100	2	10000	5.8007e-1 (1.58e-2) -	5.7194e-1 (1.62e-2) -	5.7277e-1 (1.34e-2) -	5.7853e-1 (1.52e-2) -	5.8999e-1 (8.79e-3)
	100	2	20000	5.8895e-1 (1.40e-2) -	5.8618e-1 (1.74e-2) -	5.9233e-1 (1.68e-2) -	5.8836e-1 (1.09e-2) -	6.0487e-1 (1.14e-2)
	100	2	50000	6.1376e-1 (1.91e-2) ≈	6.0606e-1 (1.89e-2) -	6.1246e-1 (1.93e-2) -	6.1692e-1 (2.12e-2) ≈	6.1553e-1 (9.90e-3)
MAP4	100	2	10000	5.6002e-1 (1.05e-2) -	5.5257e-1 (9.43e-3) -	5.5925e-1 (8.44e-3) -	5.5781e-1 (6.42e-3) -	5.7755e-1 (8.42e-3)
	100	2	20000	5.7220e-1 (1.09e-2) -	5.6651e-1 (7.79e-3) -	5.7650e-1 (1.11e-2) -	5.7706e-1 (1.41e-2) -	5.8786e-1 (9.34e-3)
	100	2	50000	5.9124e-1 (1.02e-2) -	5.8883e-1 (1.58e-2) -	5.9615e-1 (1.69e-2) -	5.9602e-1 (1.70e-2) -	6.0428e-1 (1.35e-2)
MAP5	100	2	10000	5.5393e-1 (1.21e-2) -	5.4318e-1 (7.55e-3) -	5.5378e-1 (1.11e-2) -	5.5143e-1 (6.22e-3) -	5.6882e-1 (1.19e-2)
	100	2	20000	5.6928e-1 (9.89e-3) -	5.5995e-1 (8.18e-3) -	5.6811e-1 (1.19e-2) -	5.7046e-1 (1.12e-2) -	5.7840e-1 (1.01e-2)
	100	2	50000	5.8817e-1 (1.27e-2) -	5.7768e-1 (1.07e-2) -	5.8552e-1 (1.09e-2) -	5.8436e-1 (8.55e-3) -	5.9555e-1 (1.08e-2)
MAP6	100	2	10000	5.5310e-1 (1.18e-2) -	5.4489e-1 (6.41e-3) -	5.5143e-1 (9.13e-3) -	5.5427e-1 (8.32e-3) -	5.6912e-1 (1.22e-2)
	100	2	20000	5.6810e-1 (9.72e-3) -	5.6178e-1 (1.04e-2) -	5.6489e-1 (8.60e-3) -	5.7144e-1 (1.02e-2) -	5.7955e-1 (1.03e-2)
	100	2	50000	5.8893e-1 (1.22e-2) -	5.7983e-1 (1.32e-2) -	5.8585e-1 (1.16e-2) -	5.8372e-1 (1.11e-2) -	5.9551e-1 (7.86e-3)
MAP7	100	2	10000	5.4238e-1 (8.20e-3) -	5.3858e-1 (8.83e-3) -	5.4572e-1 (7.11e-3) -	5.4235e-1 (7.67e-3) -	5.5899e-1 (1.00e-2)
	100	2	20000	5.5955e-1 (6.01e-3) -	5.5143e-1 (7.21e-3) -	5.5605e-1 (9.42e-3) -	5.6079e-1 (9.38e-3) -	5.7543e-1 (1.43e-2)
	100	2	50000	5.7682e-1 (1.15e-2) -	5.6865e-1 (8.14e-3) -	5.7770e-1 (1.21e-2) -	5.7637e-1 (7.83e-3) -	5.8926e-1 (8.00e-3)
MAP8	100	2	10000	5.4063e-1 (1.02e-2) -	5.3151e-1 (4.96e-3) -	5.4037e-1 (8.70e-3) -	5.3921e-1 (6.51e-3) -	5.5719e-1 (1.01e-2)
	100	2	20000	5.5512e-1 (6.27e-3) -	5.4802e-1 (5.03e-3) -	5.5551e-1 (6.16e-3) -	5.5422e-1 (6.67e-3) -	5.6998e-1 (9.91e-3)
	100	2	50000	5.7402e-1 (6.31e-3) -	5.6580e-1 (9.23e-3) -	5.7385e-1 (1.14e-2) -	5.7599e-1 (1.13e-2) -	5.8347e-1 (9.80e-3)
MAP9	100	2	10000	5.3266e-1 (1.01e-2) -	5.2342e-1 (7.85e-3) -	5.3117e-1 (7.66e-3) -	5.3037e-1 (7.47e-3) -	5.4512e-1 (8.88e-3)
	100	2	20000	5.4450e-1 (6.71e-3) -	5.3780e-1 (6.05e-3) -	5.4644e-1 (8.18e-3) -	5.4764e-1 (7.74e-3) -	5.5745e-1 (1.34e-2)
	100	2	50000	5.6389e-1 (7.17e-3) -	5.5805e-1 (8.93e-3) -	5.6792e-1 (1.10e-2) -	5.6609e-1 (1.01e-2) -	5.7715e-1 (9.86e-3)
MAP10	100	2	10000	5.4212e-1 (6.42e-3) -	5.3490e-1 (8.49e-3) -	5.4474e-1 (9.18e-3) -	5.4525e-1 (1.16e-2) -	5.6066e-1 (1.27e-2)
	100	2	20000	5.5841e-1 (9.11e-3) -	5.5077e-1 (1.19e-2) -	5.5727e-1 (1.06e-2) -	5.5635e-1 (7.00e-3) -	5.7213e-1 (9.89e-3)
	100	2	50000	5.7696e-1 (1.05e-2) -	5.6949e-1 (6.87e-3) -	5.7731e-1 (8.25e-3) -	5.7627e-1 (5.06e-3) -	5.9098e-1 (1.41e-2)
+/-/≈				0/28/2	0/29/1	0/29/1	0/29/1	

Tabela A.46: Resultados para o cálculo do IGD para as métricas de Tolerância a Falhas e Comunicação em relação ao grid de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	N	M	FE	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	1.2608e+3 (6.31e+1) +	1.1857e+3 (1.58e+2) +	1.2660e+3 (6.76e+1) +	1.2280e+3 (1.26e+2) +	1.3426e+3 (4.11e+1)
	100	2	20000	1.2845e+3 (9.88e+1) +	1.2272e+3 (1.34e+2) +	1.3028e+3 (6.38e+1) +	1.2772e+3 (7.33e+1) +	1.3569e+3 (3.97e+1)
	100	2	50000	1.3329e+3 (6.58e+1) +	1.3117e+3 (6.24e+1) +	1.3273e+3 (5.28e+1) +	1.3344e+3 (5.52e+1) +	1.3847e+3 (4.58e+1)
MAP2	100	2	10000	1.1813e+3 (9.90e+1) +	1.1938e+3 (2.07e+1) +	1.2076e+3 (4.21e+1) +	1.2067e+3 (3.81e+1) +	1.2643e+3 (2.90e+1)
	100	2	20000	1.2356e+3 (5.55e+1) +	1.2164e+3 (5.64e+1) +	1.2411e+3 (4.17e+1) +	1.2504e+3 (1.93e+1) +	1.2935e+3 (3.59e+1)
	100	2	50000	1.2679e+3 (5.67e+1) +	1.2519e+3 (6.67e+1) +	1.2802e+3 (4.73e+1) +	1.2736e+3 (5.45e+1) +	1.3260e+3 (3.99e+1)
MAP3	100	2	10000	1.1967e+3 (7.84e+1) +	1.1645e+3 (1.06e+2) +	1.2117e+3 (5.00e+1) +	1.1957e+3 (9.15e+1) +	1.2784e+3 (2.83e+1)
	100	2	20000	1.2357e+3 (7.10e+1) +	1.2140e+3 (7.23e+1) +	1.2381e+3 (5.66e+1) +	1.2586e+3 (4.40e+1) +	1.3131e+3 (3.70e+1)
	100	2	50000	1.2751e+3 (6.82e+1) +	1.2615e+3 (6.41e+1) +	1.2941e+3 (4.96e+1) +	1.2786e+3 (5.18e+1) +	1.3514e+3 (2.40e+1)
MAP4	100	2	10000	1.1777e+3 (4.72e+1) +	1.1591e+3 (5.83e+1) +	1.1956e+3 (2.85e+1) +	1.1891e+3 (1.78e+1) +	1.2497e+3 (2.60e+1)
	100	2	20000	1.2224e+3 (2.63e+1) +	1.2066e+3 (3.53e+1) +	1.2185e+3 (8.65e+1) +	1.2138e+3 (5.87e+1) +	1.2778e+3 (2.78e+1)
	100	2	50000	1.2687e+3 (3.84e+1) +	1.2354e+3 (5.48e+1) +	1.2528e+3 (5.40e+1) +	1.2619e+3 (4.81e+1) +	1.3110e+3 (4.65e+1)
MAP5	100	2	10000	1.1657e+3 (3.83e+1) +	1.1510e+3 (2.22e+1) +	1.1678e+3 (5.11e+1) +	1.1769e+3 (1.90e+1) +	1.2232e+3 (3.18e+1)
	100	2	20000	1.2056e+3 (4.07e+1) +	1.1814e+3 (8.24e+1) +	1.2079e+3 (3.46e+1) +	1.2179e+3 (3.00e+1) +	1.2548e+3 (2.96e+1)
	100	2	50000	1.2521e+3 (3.33e+1) +	1.2308e+3 (5.07e+1) +	1.2589e+3 (2.74e+1) +	1.2563e+3 (4.42e+1) +	1.2971e+3 (2.91e+1)
MAP6	100	2	10000	1.1686e+3 (4.73e+1) +	1.1536e+3 (2.13e+1) +	1.1641e+3 (4.25e+1) +	1.1768e+3 (2.52e+1) +	1.2296e+3 (3.22e+1)
	100	2	20000	1.2110e+3 (3.96e+1) +	1.1885e+3 (4.18e+1) +	1.1905e+3 (9.11e+1) +	1.2207e+3 (3.10e+1) +	1.2548e+3 (2.96e+1)
	100	2	50000	1.2624e+3 (3.98e+1) +	1.2323e+3 (3.73e+1) +	1.2594e+3 (2.70e+1) +	1.2576e+3 (2.56e+1) +	1.3009e+3 (2.01e+1)
MAP7	100	2	10000	1.1559e+3 (2.39e+1) +	1.1107e+3 (7.64e+1) +	1.1537e+3 (2.80e+1) +	1.1430e+3 (2.49e+1) +	1.2074e+3 (2.80e+1)
	100	2	20000	1.1920e+3 (1.74e+1) +	1.1751e+3 (2.28e+1) +	1.1855e+3 (2.50e+1) +	1.1920e+3 (3.28e+1) +	1.2371e+3 (3.44e+1)
	100	2	50000	1.2360e+3 (4.35e+1) +	1.2174e+3 (2.33e+1) +	1.2278e+3 (3.83e+1) +	1.2344e+3 (2.09e+1) +	1.2796e+3 (2.43e+1)
MAP8	100	2	10000	1.1403e+3 (2.31e+1) +	1.1180e+3 (2.03e+1) +	1.1460e+3 (2.32e+1) +	1.1415e+3 (2.42e+1) +	1.1959e+3 (2.45e+1)
	100	2	20000	1.1800e+3 (2.08e+1) +	1.1645e+3 (2.02e+1) +	1.1855e+3 (1.95e+1) +	1.1824e+3 (2.22e+1) +	1.2237e+3 (3.22e+1)
	100	2	50000	1.2354e+3 (2.24e+1) +	1.1965e+3 (4.44e+1) +	1.2267e+3 (2.87e+1) +	1.2272e+3 (3.97e+1) +	1.2668e+3 (2.34e+1)
MAP9	100	2	10000	1.1166e+3 (3.21e+1) +	1.0871e+3 (2.45e+1) +	1.1221e+3 (2.63e+1) +	1.1149e+3 (2.07e+1) +	1.1607e+3 (2.56e+1)
	100	2	20000	1.1551e+3 (1.90e+1) +	1.1376e+3 (2.12e+1) +	1.1587e+3 (2.05e+1) +	1.1647e+3 (2.21e+1) +	1.2001e+3 (3.09e+1)
	100	2	50000	1.2128e+3 (2.52e+1) +	1.1822e+3 (2.80e+1) +	1.1966e+3 (4.93e+1) +	1.2026e+3 (3.76e+1) +	1.2456e+3 (2.57e+1)
MAP10	100	2	10000	1.1523e+3 (2.06e+1) +	1.1232e+3 (4.30e+1) +	1.1481e+3 (4.01e+1) +	1.1423e+3 (5.17e+1) +	1.2023e+3 (3.50e+1)
	100	2	20000	1.1891e+3 (2.16e+1) +	1.1495e+3 (5.86e+1) +	1.1740e+3 (6.44e+1) +	1.1854e+3 (2.36e+1) +	1.2355e+3 (1.78e+1)
	100	2	50000	1.2336e+3 (3.94e+1) +	1.2220e+3 (2.01e+1) +	1.2434e+3 (2.52e+1) +	1.2391e+3 (1.78e+1) +	1.2670e+3 (4.37e+1)
				+/-/≈	30/0/0	30/0/0	30/0/0	30/0/0

Tabela A.47: Resultados para o cálculo do Hypervolume para as métricas de Comunicação e Energia em relação ao grid de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	N	M	FE	NSGAII	NSGAIII	SPEA2	KnEA	PESAII
MAP1	100	2	10000	5.0190e-1 (1.18e-2) -	4.8969e-1 (1.22e-2) -	5.1097e-1 (9.67e-3) ≈	5.0255e-1 (1.05e-2) -	5.1515e-1 (1.27e-2)
	100	2	20000	5.2991e-1 (1.30e-2) -	5.2110e-1 (9.64e-3) -	5.3740e-1 (1.29e-2) ≈	5.2852e-1 (1.11e-2) -	5.3955e-1 (1.42e-2)
	100	2	50000	5.6731e-1 (1.19e-2) ≈	5.5528e-1 (1.24e-2) -	5.7541e-1 (1.05e-2) +	5.6323e-1 (1.09e-2) -	5.6873e-1 (9.88e-3)
MAP2	100	2	10000	4.6670e-1 (9.38e-3) -	4.5818e-1 (9.58e-3) -	4.7163e-1 (1.35e-2) ≈	4.6664e-1 (1.27e-2) -	4.7799e-1 (1.69e-2)
	100	2	20000	4.9405e-1 (9.12e-3) -	4.8292e-1 (1.24e-2) -	5.0563e-1 (1.38e-2) ≈	4.9070e-1 (9.63e-3) -	5.0410e-1 (1.44e-2)
	100	2	50000	5.2446e-1 (1.33e-2) ≈	5.1711e-1 (1.13e-2) -	5.3297e-1 (1.17e-2) ≈	5.2626e-1 (1.33e-2) ≈	5.2717e-1 (1.34e-2)
MAP3	100	2	10000	4.7344e-1 (9.12e-3) -	4.5698e-1 (7.59e-3) -	4.8050e-1 (1.15e-2) -	4.7501e-1 (1.08e-2) -	4.8869e-1 (1.39e-2)
	100	2	20000	5.0108e-1 (1.03e-2) ≈	4.8996e-1 (1.00e-2) -	5.0799e-1 (1.17e-2) ≈	5.0399e-1 (1.01e-2) ≈	5.0775e-1 (1.59e-2)
	100	2	50000	5.3995e-1 (1.02e-2) ≈	5.2362e-1 (8.28e-3) -	5.4529e-1 (1.20e-2) ≈	5.3879e-1 (9.81e-3) ≈	5.3804e-1 (1.50e-2)
MAP4	100	2	10000	4.5695e-1 (8.96e-3) -	4.4470e-1 (1.06e-2) -	4.6209e-1 (1.14e-2) ≈	4.5207e-1 (1.15e-2) -	4.6652e-1 (1.33e-2)
	100	2	20000	4.8199e-1 (8.08e-3) -	4.6789e-1 (9.51e-3) -	4.8708e-1 (1.01e-2) ≈	4.8459e-1 (1.37e-2) ≈	4.8847e-1 (1.51e-2)
	100	2	50000	5.1894e-1 (9.74e-3) ≈	5.0810e-1 (1.35e-2) -	5.2512e-1 (1.06e-2) +	5.1251e-1 (1.13e-2) ≈	5.1594e-1 (1.41e-2)
MAP5	100	2	10000	4.5142e-1 (1.18e-2) ≈	4.3882e-1 (9.32e-3) -	4.5387e-1 (9.97e-3) ≈	4.5187e-1 (9.97e-3) ≈	4.5714e-1 (1.69e-2)
	100	2	20000	4.7914e-1 (1.05e-2) ≈	4.6126e-1 (8.29e-3) -	4.7923e-1 (1.01e-2) -	4.7276e-1 (1.25e-2) -	4.8390e-1 (1.06e-2)
	100	2	50000	5.1247e-1 (1.34e-2) ≈	4.9717e-1 (1.31e-2) -	5.1238e-1 (1.06e-2) -	5.0871e-1 (7.91e-3) ≈	5.0792e-1 (1.41e-2)
MAP6	100	2	10000	4.5064e-1 (1.08e-2) -	4.3942e-1 (1.15e-2) -	4.5439e-1 (1.21e-2) ≈	4.4852e-1 (8.26e-3) -	4.6004e-1 (1.20e-2)
	100	2	20000	4.7853e-1 (1.40e-2) ≈	4.6322e-1 (1.15e-2) -	4.8031e-1 (1.05e-2) -	4.7259e-1 (1.16e-2) -	4.8258e-1 (1.30e-2)
	100	2	50000	5.1166e-1 (1.19e-2) ≈	4.9977e-1 (9.36e-3) -	5.1832e-1 (1.13e-2) +	5.1030e-1 (1.15e-2) ≈	5.0818e-1 (1.44e-2)
MAP7	100	2	10000	4.4203e-1 (1.13e-2) -	4.2701e-1 (7.86e-3) -	4.4272e-1 (8.33e-3) -	4.3941e-1 (1.12e-2) -	4.5074e-1 (1.19e-2)
	100	2	20000	4.6975e-1 (1.02e-2) ≈	4.5803e-1 (1.17e-2) -	4.7192e-1 (1.03e-2) ≈	4.6485e-1 (9.71e-3) -	4.7243e-1 (1.33e-2)
	100	2	50000	5.0030e-1 (1.39e-2) ≈	4.8909e-1 (1.17e-2) -	5.0619e-1 (9.40e-3) ≈	4.9912e-1 (1.07e-2) ≈	4.9871e-1 (1.84e-2)
MAP8	100	2	10000	4.3403e-1 (1.06e-2) -	4.2286e-1 (9.42e-3) -	4.3945e-1 (1.09e-2) -	4.3742e-1 (1.38e-2) -	4.4777e-1 (1.63e-2)
	100	2	20000	4.6594e-1 (1.35e-2) ≈	4.5324e-1 (1.06e-2) -	4.6824e-1 (1.05e-2) ≈	4.6371e-1 (1.17e-2) -	4.6957e-1 (1.26e-2)
	100	2	50000	4.9779e-1 (1.40e-2) ≈	4.8086e-1 (9.12e-3) -	5.0390e-1 (1.02e-2) ≈	4.9795e-1 (8.87e-3) ≈	4.9708e-1 (1.77e-2)
MAP9	100	2	10000	4.2535e-1 (1.25e-2) -	4.1702e-1 (8.81e-3) -	4.3138e-1 (9.21e-3) -	4.2703e-1 (8.75e-3) -	4.4037e-1 (1.25e-2)
	100	2	20000	4.5543e-1 (1.03e-2) ≈	4.4341e-1 (9.41e-3) -	4.6135e-1 (1.18e-2) ≈	4.4806e-1 (7.13e-3) -	4.5704e-1 (1.24e-2)
	100	2	50000	4.8834e-1 (1.42e-2) ≈	4.7860e-1 (1.08e-2) -	4.9037e-1 (1.46e-2) ≈	4.8280e-1 (1.05e-2) ≈	4.8646e-1 (1.63e-2)
MAP10	100	2	10000	4.4262e-1 (9.39e-3) ≈	4.3024e-1 (8.75e-3) -	4.4448e-1 (1.00e-2) ≈	4.3791e-1 (1.11e-2) -	4.4843e-1 (1.27e-2)
	100	2	20000	4.6350e-1 (1.24e-2) -	4.5471e-1 (1.16e-2) -	4.7384e-1 (9.33e-3) ≈	4.6639e-1 (1.21e-2) ≈	4.7198e-1 (1.11e-2)
	100	2	50000	4.9848e-1 (1.13e-2) ≈	4.9048e-1 (1.06e-2) -	5.0751e-1 (1.27e-2) ≈	4.9580e-1 (8.62e-3) ≈	5.0076e-1 (1.42e-2)
				+/-/≈	0/12/18	0/30/0	3/5/22	0/17/13

Tabela A.48: Resultados para o cálculo do IGD para as métricas de Comunicação e Energia em relação ao *grid* de tamanho 8x8, população de tamanho 100 e Evaluations 10000, 20000, 50000.

Problem	<i>N</i>	<i>M</i>	<i>FE</i>	NSGAI	NSGAIII	SPEA2	KnEA	PESAI
MAP1	100	2	10000	1.8626e+3 (1.56e+2) +	1.8123e+3 (1.73e+2) +	1.7266e+3 (2.15e+2) +	1.9174e+3 (1.70e+2) +	2.0121e+3 (1.46e+2)
	100	2	20000	1.8659e+3 (1.84e+2) +	1.7998e+3 (1.49e+2) +	1.8184e+3 (2.00e+2) +	1.8288e+3 (1.75e+2) +	2.0624e+3 (1.60e+2)
	100	2	50000	1.8330e+3 (1.87e+2) +	1.8666e+3 (1.78e+2) +	1.7957e+3 (1.78e+2) +	1.8813e+3 (1.89e+2) +	2.0585e+3 (1.53e+2)
MAP2	100	2	10000	1.7347e+3 (1.81e+2) +	1.7080e+3 (1.80e+2) +	1.6889e+3 (2.19e+2) +	1.7696e+3 (2.02e+2) +	1.9486e+3 (1.54e+2)
	100	2	20000	1.7280e+3 (1.79e+2) +	1.7266e+3 (1.95e+2) +	1.6211e+3 (1.99e+2) +	1.8116e+3 (1.51e+2) ≈	1.8960e+3 (1.36e+2)
	100	2	50000	1.7433e+3 (2.17e+2) +	1.7385e+3 (1.70e+2) +	1.6567e+3 (1.79e+2) +	1.7455e+3 (1.84e+2) +	1.9468e+3 (1.62e+2)
MAP3	100	2	10000	1.7393e+3 (1.49e+2) +	1.7823e+3 (1.68e+2) +	1.6243e+3 (2.45e+2) +	1.8284e+3 (1.67e+2) ≈	1.8856e+3 (1.47e+2)
	100	2	20000	1.7546e+3 (1.68e+2) +	1.7393e+3 (1.66e+2) +	1.6585e+3 (2.31e+2) +	1.7039e+3 (1.78e+2) +	1.9863e+3 (1.28e+2)
	100	2	50000	1.7547e+3 (1.83e+2) +	1.7427e+3 (2.39e+2) +	1.6561e+3 (1.55e+2) +	1.7704e+3 (1.71e+2) +	1.9695e+3 (1.39e+2)
MAP4	100	2	10000	1.7377e+3 (1.77e+2) +	1.6906e+3 (2.02e+2) +	1.6530e+3 (1.94e+2) +	1.7663e+3 (1.45e+2) +	1.8897e+3 (1.50e+2)
	100	2	20000	1.6662e+3 (1.73e+2) +	1.6717e+3 (1.75e+2) +	1.7046e+3 (2.05e+2) +	1.6936e+3 (1.69e+2) +	1.8846e+3 (1.35e+2)
	100	2	50000	1.7032e+3 (2.02e+2) +	1.6743e+3 (2.27e+2) +	1.6133e+3 (2.13e+2) +	1.7559e+3 (1.44e+2) +	1.9095e+3 (1.78e+2)
MAP5	100	2	10000	1.7152e+3 (2.13e+2) +	1.6545e+3 (1.91e+2) +	1.6202e+3 (1.74e+2) +	1.6802e+3 (1.18e+2) +	1.9256e+3 (1.56e+2)
	100	2	20000	1.7164e+3 (1.72e+2) +	1.6927e+3 (2.07e+2) +	1.6749e+3 (1.73e+2) +	1.7269e+3 (2.06e+2) +	1.8482e+3 (1.57e+2)
	100	2	50000	1.6256e+3 (2.07e+2) +	1.7347e+3 (1.48e+2) +	1.6703e+3 (2.23e+2) +	1.7475e+3 (1.75e+2) +	1.8879e+3 (1.52e+2)
MAP6	100	2	10000	1.6794e+3 (2.00e+2) +	1.6471e+3 (2.19e+2) +	1.6271e+3 (2.11e+2) +	1.7147e+3 (1.96e+2) +	1.8715e+3 (1.66e+2)
	100	2	20000	1.6696e+3 (1.78e+2) +	1.6579e+3 (2.34e+2) +	1.6554e+3 (1.67e+2) +	1.7333e+3 (1.91e+2) +	1.8742e+3 (1.38e+2)
	100	2	50000	1.7614e+3 (1.50e+2) +	1.6290e+3 (2.24e+2) +	1.6191e+3 (1.64e+2) +	1.7044e+3 (1.61e+2) +	1.9120e+3 (2.09e+2)
MAP7	100	2	10000	1.6620e+3 (1.98e+2) +	1.6164e+3 (1.81e+2) +	1.6592e+3 (1.95e+2) +	1.6969e+3 (1.67e+2) +	1.8555e+3 (1.02e+2)
	100	2	20000	1.7068e+3 (1.74e+2) +	1.6814e+3 (1.89e+2) +	1.6015e+3 (1.44e+2) +	1.6625e+3 (1.65e+2) +	1.8510e+3 (1.22e+2)
	100	2	50000	1.7081e+3 (1.53e+2) +	1.6776e+3 (1.38e+2) +	1.5338e+3 (2.45e+2) +	1.6605e+3 (2.25e+2) +	1.8792e+3 (1.54e+2)
MAP8	100	2	10000	1.6399e+3 (1.98e+2) +	1.6054e+3 (1.65e+2) +	1.6221e+3 (1.97e+2) +	1.6242e+3 (2.09e+2) +	1.8808e+3 (1.31e+2)
	100	2	20000	1.6639e+3 (1.88e+2) +	1.6012e+3 (2.30e+2) +	1.6545e+3 (1.91e+2) +	1.6932e+3 (1.66e+2) +	1.8715e+3 (1.56e+2)
	100	2	50000	1.6197e+3 (2.64e+2) +	1.6634e+3 (1.83e+2) +	1.5907e+3 (1.58e+2) +	1.6855e+3 (2.17e+2) +	1.8649e+3 (1.32e+2)
MAP9	100	2	10000	1.6759e+3 (1.77e+2) +	1.5536e+3 (2.25e+2) +	1.5536e+3 (1.94e+2) +	1.6569e+3 (1.67e+2) +	1.7732e+3 (1.61e+2)
	100	2	20000	1.6828e+3 (1.82e+2) +	1.5455e+3 (1.99e+2) +	1.5637e+3 (2.54e+2) +	1.6771e+3 (1.98e+2) +	1.8346e+3 (1.08e+2)
	100	2	50000	1.6320e+3 (1.93e+2) +	1.6426e+3 (2.05e+2) +	1.6068e+3 (2.18e+2) +	1.6985e+3 (1.91e+2) ≈	1.7949e+3 (1.54e+2)
MAP10	100	2	10000	1.6199e+3 (1.99e+2) +	1.6796e+3 (2.08e+2) +	1.6301e+3 (2.12e+2) +	1.7013e+3 (2.31e+2) +	1.8416e+3 (1.90e+2)
	100	2	20000	1.6824e+3 (1.94e+2) +	1.6830e+3 (2.03e+2) +	1.5756e+3 (2.25e+2) +	1.6834e+3 (1.81e+2) +	1.8369e+3 (1.52e+2)
	100	2	50000	1.6299e+3 (1.83e+2) +	1.7170e+3 (1.62e+2) ≈	1.6128e+3 (2.07e+2) +	1.7119e+3 (2.02e+2) ≈	1.8097e+3 (1.80e+2)
				+/-/≈	30/0/0	29/0/1	30/0/0	26/0/4