

**UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**ALGORITMO GENÉTICO COM INTERAÇÃO SOCIAL NEBULOSA**

**OTÁVIO NOURA TEIXEIRA**

TD: 06/2012

**UFPA / ITEC / PPGE  
Campus Universitário do Guamá  
Belém – Pará – Brasil  
2012**

**UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**OTÁVIO NOURA TEIXEIRA**

**ALGORITMO GENÉTICO COM INTERAÇÃO SOCIAL NEBULOSA**

TD: 06/2012

**UFPA / ITEC / PPGE  
Campus Universitário do Guamá  
Belém – Pará – Brasil  
2012**

**UNIVERSIDADE FEDERAL DO PARÁ  
INSTITUTO DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**OTÁVIO NOURA TEIXEIRA**

**ALGORITMO GENÉTICO COM INTERAÇÃO SOCIAL NEBULOSA**

Tese submetida à Banca Examinadora do Programa de Pós-Graduação em Engenharia Elétrica da UFPA como parte dos requisitos necessários para a obtenção do Título de Doutor em Engenharia Elétrica na área de Computação Aplicada.

**UFPA / ITEC / PPGE  
Campus Universitário do Guamá  
Belém – Pará – Brasil  
2012**

**UNIVERSIDADE FEDERAL DO PARÁ**  
**INSTITUTO DE TECNOLOGIA**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**ALGORITMO GENÉTICO COM INTERAÇÃO SOCIAL NEBULOSA**

**AUTOR: OTÁVIO NOURA TEIXEIRA**

TESE DE DOUTORADO SUBMETIDA À AVALIAÇÃO DA BANCA EXAMINADORA APROVADA PELO COLEGIADO DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA DA UNIVERSIDADE FEDERAL DO PARÁ E JULGADA ADEQUADA PARA A OBTENÇÃO DO TÍTULO DE DOUTOR EM ENGENHARIA ELÉTRICA NA ÁREA DE COMPUTAÇÃO APLICADA.

APROVADA EM: 19/04/2012

BANCA EXAMINADORA:

---

Prof. Roberto Célio Limão de Oliveira, Dr.  
(Orientador – PPGEE-UFPA)

---

Prof. Gustavo Augusto Lima de Campos, Dr.  
(Membro Externo – MACC-UECE)

---

Profª. Adriana Rosa Garcez Castro, Dra.  
(Membro – PPGEE-UFPA)

---

Prof. João Viana da Fonseca Neto, Dr.  
(Membro Externo – PPGEE-UFMA)

---

Prof. Elói Luiz Favero, Dr.  
(Membro – PPGCC-UFPA)

---

Prof. Ronaldo de Freitas Zampolo, Dr.  
(Membro – FCT-UFPA)

Visto

---

Prof. Marcos Vinícius Alves Nunes, Dr.  
(Coordenador do PPGEE-UFPA)

“Aprenda olhando para a Natureza, use-a como mentora”.

Leonardo da Vinci

Às minhas meninas, Gabriela e Rafaela.

## AGRADECIMENTOS

À **Deus** e a todos os **Seres de Luz**, por sempre estarem comigo em todos os momentos, os bons e os não bons. A força, a energia e o cuidado de vocês me ajudaram e muito a ser persistente, resiliente e jamais parar de seguir em frente rumo ao sonho de concluir mais essa etapa em minha vida. Gratidão!

Aos meus pais, **Artur** e **Maria do Carmo**, por terem sido os meus primeiros mestres nesta vida, desempenhando brilhantemente suas funções nos cargos de pai e mãe, e que em todas as circunstâncias estiveram ao meu lado, orientando-me em todas as decisões da minha vida, dando-me tanto o suporte material, quanto, e principalmente, suporte emocional e afetivo. Eu escolhi vocês como pais e a decisão foi mais que acertada. Amo demais vocês!

À **Universidade Federal do Pará**, ao **Programa de Pós-Graduação em Engenharia Elétrica (PPGEE)**, e em especial ao meu amigo e orientador **Roberto Célio Limão de Oliveira**, pela parceria, amizade, crença e paciência. Muito obrigado por tudo!

Ao **Centro Universitário do Estado do Pará (CESUPA)**, minha segunda casa há 18 anos, e onde tive o suporte dos meus amigos professores e alunos; da reitoria, e que agradeço em nome dos professores João Paulo do Vale Mendes, Sérgio Fiuza de Melo Mendes, e da minha segunda mãe, a professora Conceição Rangel Fiuza de Melo. Obrigado por compartilharem o sonho de um projeto educacional focado na liberdade dos indivíduos através do conhecimento. Sou filho dessa casa e sempre o serei!

# SUMÁRIO

LISTA DE FIGURAS .....	xi
LISTA DE TABELAS .....	xiii
LISTA DE GRÁFICOS .....	xvii
RESUMO.....	xx
ABSTRACT.....	xxi

## CAPITULO I

1. INTRODUÇÃO .....	1
1.1. MOTIVAÇÃO E JUSTIFICATIVA .....	1
1.2. OBJETIVOS .....	10
1.2.1. Objetivo Geral.....	10
1.2.2. Objetivos Específicos .....	11
1.4. PRINCÍPAIS CONTRIBUIÇÕES .....	12
1.3. ESTRUTURA DA TESE .....	13

## CAPITULO II

2. PROPOSTA DE ALGORITMOS COM INTERAÇÃO SOCIAL .....	15
2.1. APRESENTAÇÃO .....	15
2.2. ALGORITMO SIGA .....	18
2.3. MÉTODOS DE SELEÇÃO DILEMA DO PRISIONEIRO .....	22
2.3.1. Dilema do Prisioneiro Roleta (DPR) .....	22
a. $DPRr = 1$ .....	24
b. $DPRr > 1$ .....	26
2.3.2. Dilema do Prisioneiro Torneio (DPT) .....	29
a. $DPTr = 1$ .....	31
b. $DPTr > 1$ .....	34
2.4. ALGORITMO NpSIGA .....	37
2.5. ALGORITMO F-SIGA .....	43
2.5.1. Abordagem Nebulosa do Dilema do Prisioneiro .....	44

2.5.2. Função de Pagamento do Dilema do Prisioneiro Nebuloso .....	45
2.5.3. Fatores de Decisão.....	46
a. Fator $f_1$ : Relação entre as Riquezas Acumuladas.....	47
b. Fator $f_2$ : Últimas Iterações entre os Jogadores .....	49
c. Fator $f_3$ : Relação entre as Tendências Globais de Riqueza .....	50
2.5.4. Conjunto de Regras Nebulosas .....	52
2.5.5. Determinação da Ação do Jogador .....	53
2.5.6. Exemplificação .....	53
2.5.7. Codificação das Estratégias de Comportamento.....	59
2.6. ALGORITMO ESIA .....	62
2.6.1. Fator de Experiência.....	64
a. Fator de experiência em relação à idade.....	64
b. Fator de experiência em relação à quantidade de disputas .....	65
c. Função Fator Experiência (idade, disputas).....	66
2.6.2. Função Fitness com o Fator de Experiência .....	67
2.6.3. Possibilidades de Extensão do Uso do ESIA .....	67
2.7. CONSIDERAÇÕES FINAIS .....	68

## CAPITULO III

3. PROBLEMAS, SIMULAÇÕES E RESULTADOS .....	71
3.1. APRESENTAÇÃO .....	71
3.2. PROBLEMAS DE OTIMIZAÇÃO GLOBAL SEM RESTRIÇÕES.....	73
3.2.1. Função $f_1$ - <i>Shifted Sphere Function</i> .....	73
3.2.2. Função $f_6$ - <i>Shifted Rosenbrock's Function</i> .....	78
3.2.3. Função $f_8$ - <i>Shifted Rotated Ackley's Function with Global Optimum on Bounds</i> .....	82
3.3. PROBLEMAS DE OTIMIZAÇÃO GLOBAL COM RESTRIÇÕES.....	86
3.3.1. Projeto de Viga de Aço .....	86
3.3.2. Projeto de Vaso de Pressão .....	92
3.3.3. Minimização do Peso da Tensão/Compressão sobre Mola .....	96
3.3.4. Projeto de Redutor de Velocidade .....	101
3.4. PROBLEMA DO CAIXEIRO VIAJANTE (PCV) .....	107
3.4.1. Instância: <i>br26</i> .....	109
3.4.2. Instância: <i>kro100</i> .....	112
3.4.3. Instância: <i>att532</i> .....	115
3.4.4. Instância: <i>pcp1173</i> .....	119
3.5. CONSIDERAÇÕES FINAIS .....	123

## CAPITULO IV

<b>4. CONSIDERAÇÕES FINAIS.....</b>	<b>124</b>
<b>4.1. SUMARIZAÇÃO E CONCLUSÕES.....</b>	<b>124</b>
<b>4.2. LIMITAÇÕES DA TESE E TRABALHOS FUTUROS .....</b>	<b>127</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>	<b>130</b>

## ANEXOS

<b>ANEXO A – ALGORITMOS GENÉTICOS: UMA VISÃO GERAL .....</b>	<b>145</b>
<b>A.1. APRESENTAÇÃO .....</b>	<b>145</b>
<b>A.2. ESTRUTURA BÁSICA .....</b>	<b>146</b>
<b>A.3. COMO IMPLEMENTAR UM ALGORITMO GENÉTICO.....</b>	<b>147</b>
<b>ANEXO B – FUNDAMENTOS DA TEORIA DOS JOGOS .....</b>	<b>151</b>
<b>B.1. APRESENTAÇÃO.....</b>	<b>151</b>
<b>B.2. COMPONENTES DE UM JOGO ESTRATÉGICO .....</b>	<b>152</b>
<b>B.3. TIPOS DE JOGOS .....</b>	<b>153</b>
<b>B.4. O PARADIGMA DO DILEMA DO PRISIONEIRO .....</b>	<b>154</b>
<b>ANEXO C – CONJUNTOS E SISTEMAS NEBULOSOS.....</b>	<b>159</b>
<b>C.1. APRESENTAÇÃO .....</b>	<b>159</b>
<b>C.2. CONJUNTOS NEBULOSOS.....</b>	<b>160</b>
<b>C.3. OPERAÇÕES E RELAÇÕES SOBRE CONJUNTOS NEBULOSOS .....</b>	<b>162</b>
<b>C.4. VARIÁVEIS LINGUÍSTICAS .....</b>	<b>167</b>
<b>C.5. LÓGICA NEBULOSA .....</b>	<b>170</b>
<b>C.6. SISTEMAS NEBULOSOS .....</b>	<b>172</b>
<b>ANEXO D – ESTRATÉGIAS DE COMPORTAMENTO .....</b>	<b>175</b>
<b>D.1. ESTRATÉGIAS UTILIZADAS NO ALGORITMO SIGA .....</b>	<b>175</b>
<b>D.2. ESTRATÉGIAS UTILIZADAS NO ALGORITMO F-SIGA.....</b>	<b>175</b>
<b>ANEXO E – CONFIGURAÇÕES DAS SIMULAÇÕES.....</b>	<b>184</b>

<b>ANEXO F – RESULTADOS PARA OS PROBLEMAS DE OTIMIZAÇÃO GLOBAL SEM RESTRIÇÕES.....</b>	<b>188</b>
<b>F.1. FUNÇÃO <math>F_1</math> – <i>SHIFTED SPHERE FUNCTION</i> .....</b>	<b>188</b>
<b>F.2. FUNÇÃO <math>F_6</math> – <i>SHIFTED ROSENBROCK’S FUNCTION</i> .....</b>	<b>191</b>
<b>F.3. FUNÇÃO <math>F_8</math> – <i>SHIFTED ROTATED ACKLEY’S FUNCTION WITH GLOBAL OPTIMUM ON BOUNDS</i>.....</b>	<b>194</b>
<b>ANEXO G – RESULTADOS PARA OS PROBLEMAS DE OTIMIZAÇÃO GLOBAL COM RESTRIÇÕES .....</b>	<b>197</b>
<b>G.1. PROJETO DE VIGA DE AÇO .....</b>	<b>197</b>
<b>G.2. PROJETO DE VASO DE PRESSÃO .....</b>	<b>200</b>
<b>G.3. MINIMIZAÇÃO DO PESO DA TENSÃO / COMPRESSÃO SOBRE MOLA.....</b>	<b>203</b>
<b>G.4. PROJETO DE REDUTOR DE VELOCIDADE .....</b>	<b>206</b>
<b>ANEXO H – RESULTADOS DAS SIMULAÇÕES PARA O PROBLEMA DO CAIXEIRO VIAJANTE .....</b>	<b>209</b>
<b>H.1. INSTÂNCIA:: BR26 .....</b>	<b>209</b>
<b>H.2. INSTÂNCIA: KROA100.....</b>	<b>214</b>
<b>H.3. INSTÂNCIA: ATT532.....</b>	<b>219</b>
<b>H.4. INSTÂNCIA: PCB1173.....</b>	<b>224</b>
<b>ANEXO I – LISTA DE PUBLICAÇÕES.....</b>	<b>229</b>

## LISTA DE FIGURAS

Figura 2.1 – Esquema do Algoritmo Genético com Interação Social. ....	16
Figura 2.2 – Representação esquemática dos indivíduos com dois cromossomos.....	17
Figura 2.3 – Pseudocódigo do algoritmo SIGA. ....	19
Figura 2.4 – Esquema de composição do SIGA.....	22
Figura 2.5 – Parte do pseudocódigo do método DPR.....	23
Figura 2.6 – Parâmetros para exemplificação dos métodos DPR e DPT. ....	23
Figura 2.7 – Simulação do método $DPRr = 1$ .....	25
Figura 2.8 – Simulação do método $DPRr > 1$ .....	27
Figura 2.9 – Parte do pseudocódigo do método DPT.....	30
Figura 2.10 – Simulação do método $DPTr = 1$ .....	32
Figura 2.11 – Simulação do método $DPRr > 1$ .....	35
Figura 2.12 – Parte do pseudocódigo do algoritmo NpSIGA. ....	37
Figura 2.13 – Parâmetros para exemplificação do algoritmo NpSIGA.....	38
Figura 2.14 – Realização da iteração um e dois da simulação do algoritmo NpSIGA. ....	39
Figura 2.15 – Realização da iteração três e quatro da simulação do algoritmo NpSIGA. ..	40
Figura 2.16 – Realização da iteração cinco da simulação do algoritmo NpSIGA. ....	41
Figura 2.17 – Pseudocódigo do algoritmo F-SIGA.....	43
Figura 2.18 – Diagrama do processo de geração da ação do jogador a partir dos fatores de decisão. ....	54
Figura 2.19 – Parâmetros utilizados na simulação do DPN. ....	55
Figura 2.20 – Configuração dos parâmetros da população após as disputas.....	59
Figura 2.21 – Esquema do cromossomo para as estratégias utilizadas no algoritmo F-SIGA. .....	61
Figura 2.21 – Esquema de acoplamento do algoritmo ESIA a outros métodos .....	68
Figura 3.1 – Projeto de viga de aço. ....	87
Figura 3.2 – Projeto de vaso de pressão. ....	92
Figura 3.3 – Minimização do peso da tensão/compressão sobre mola.....	97
Figura 3.4 – Projeto de redutor de velocidade.....	101
Figura A.1 – Estrutura básica de um Algoritmo Genético. ....	146
Figura A.2 - Operação de cruzamento com um ponto de corte. ....	149

Figura A.3 - Operação de cruzamento com dois pontos de corte.....	149
Figura A.4 – Exemplificação da operação de mutação. ....	149
Figura C.1 – Exemplo do complemento de um conjunto nebuloso. ....	163
Figura C.2 – Exemplo de união de conjuntos.....	163
Figura C.3 – Exemplo de interseção de conjuntos. ....	163
Figura C.1 – Funções de pertinência da variável linguística velocidade.....	168
Figura C.2 – Funções de pertinência para as restrições “muito” e “mais ou menos”. ....	169
Figura C.3 – Sistema nebuloso de Mamdani com fuzzificador e defuzzificador.....	172

## LISTA DE TABELAS

Tabela 2.1 – Distribuição da roleta antes e depois da interação social via $DPRr = 1$ .....	26
Tabela 2.2 – Distribuição da roleta antes e depois da interação social via $DPRr > 1$ .....	29
Tabela 2.3 – Distribuição da roleta antes e depois da interação social via $DPTr = 1$ .....	33
Tabela 2.4 – Distribuição das participações antes e depois da interação social via $DPTr > 1$ .....	36
Tabela 2.5 – Distribuição das participações antes e depois da interação social via NpSIGA .....	42
Tabela 2.6 – Conjunto de regras de produção nebulosas para os fatores $f_1, f_2$ e $f_3$ .....	52
Tabela 3.1 – Distribuição das configurações entre as categorias de problemas.....	73
Tabela 3.2 – Melhor resultado, média e desvio padrão para o problema $f_1$ .....	74
Tabela 3.3 – Distribuição dos algoritmos vitoriosos para o problema $f_1$ .....	75
Tabela 3.4 – Melhor resultado, média e desvio padrão para o problema $f_6$ .....	79
Tabela 3.5 – Distribuição dos algoritmos vitoriosos para o problema $f_6$ .....	80
Tabela 3.6 – Melhor resultado, média e desvio padrão para o problema $f_8$ .....	83
Tabela 3.7 – Distribuição dos algoritmos vitoriosos para o problema $f_8$ .....	84
Tabela 3.8 – Melhor resultado, média e desvio padrão para o problema $WBD$ . .....	89
Tabela 3.9 – Distribuição dos algoritmos vitoriosos para o problema $WBD$ . .....	90
Tabela 3.10 – Resultados comparativos para o problema $WBD$ .....	91
Tabela 3.11 – Melhor resultado, média e desvio padrão para o problema $DPV$ . .....	93
Tabela 3.12 – Distribuição dos algoritmos vitoriosos para o problema $WBD$ . .....	94
Tabela 3.13 – Resultados comparativos para o problema $DPV$ . .....	96
Tabela 3.14 – Melhor resultado, média e desvio padrão para o problema $MWTCS$ . .....	98
Tabela 3.15 – Distribuição dos algoritmos vitoriosos para o problema $MWTCS$ .....	99
Tabela 3.16 – Resultados comparativos para o problema $MWTCS$ .....	100
Tabela 3.17 – Melhor resultado, média e desvio padrão para o problema $SRD$ .....	103
Tabela 3.18 – Distribuição dos algoritmos vitoriosos para o problema $SRD$ .....	104
Tabela 3.19 – Resultados comparativos para o problema $SRD$ . .....	106
Tabela 3.20 – Tempo estimado para processar todas as soluções possíveis para $n$ cidades. ....	108
Tabela 3.21 – Informações sobre as instâncias do PCVS utilizadas nas simulações. ....	108

Tabela 3.22 – Melhor resultado, média e desvio padrão para o problema <i>br26</i> . .....	109
Tabela 3.23 – Distribuição dos algoritmos vitoriosos para o problema <i>br26</i> .....	110
Tabela 3.24 – Melhor resultado, média e desvio padrão para o problema <i>kroa100</i> .....	112
Tabela 3.25 – Distribuição dos algoritmos vitoriosos para o problema <i>kroa100</i> .....	113
Tabela 3.26 – Melhor resultado, média e desvio padrão para o problema <i>att532</i> .....	115
Tabela 3.27 – Distribuição dos algoritmos vitoriosos para o problema <i>att532</i> .....	116
Tabela 3.27 – Melhor resultado, média e desvio padrão para o problema <i>pcb1173</i> . .....	119
Tabela 3.28 – Distribuição dos algoritmos vitoriosos para o problema <i>pcb1173</i> . .....	120
Tabela B.1 – Tabela de pagamentos do dilema do prisioneiro.....	155
Tabela B.2 – Outros jogos que podem ser gerados a partir da tabela de pagamento do DP. .....	156
Tabela B.3 – Tabela de pagamentos para o Dilema do Prisioneiro N-Pessoas. ....	157
Tabela C.1 – Propriedades das operações de união e interseção.....	164
Tabela D.1 – Codificação genética das estratégias de comportamento usadas no SIGA..	175
Tabela D.2 – Codificação genética das estratégias de comportamento usadas no F-SIGA. .....	175
Tabela F.1 (a) – Resultados obtidos nas simulações para o problema $f_1$ .....	188
Tabela F.1 (b) – Resultados obtidos nas simulações para o problema $f_1$ .....	188
Tabela F.1 (c) – Resultados obtidos nas simulações para o problema $f_1$ .....	189
Tabela F.1 (d) – Resultados obtidos nas simulações para o problema $f_1$ .....	189
Tabela F.1 (e) – Resultados obtidos nas simulações para o problema $f_1$ .....	190
Tabela F.2 (a) – Resultados obtidos nas simulações para o problema $f_6$ .....	191
Tabela F.2 (b) – Resultados obtidos nas simulações para o problema $f_6$ .....	191
Tabela F.2 (c) – Resultados obtidos nas simulações para o problema $f_6$ .....	192
Tabela F.2 (d) – Resultados obtidos nas simulações para o problema $f_6$ .....	192
Tabela F.2 (e) – Resultados obtidos nas simulações para o problema $f_6$ .....	193
Tabela F.3 (a) – Resultados obtidos nas simulações para o problema $f_8$ .....	194
Tabela F.3 (b) – Resultados obtidos nas simulações para o problema $f_8$ .....	194
Tabela F.3 (c) – Resultados obtidos nas simulações para o problema $f_8$ .....	195
Tabela F.3 (d) – Resultados obtidos nas simulações para o problema $f_8$ .....	195
Tabela F.3 (e) – Resultados obtidos nas simulações para o problema $f_8$ .....	196
Tabela G.1 (a) – Resultados obtidos nas simulações para o problema WBD. ....	197

Tabela G.1 (b) – Resultados obtidos nas simulações para o problema WBD. ....	198
Tabela G.1 (c) – Resultados obtidos nas simulações para o problema WBD. ....	198
Tabela G.1 (d) – Resultados obtidos nas simulações para o problema WBD. ....	199
Tabela G.1 (e) – Resultados obtidos nas simulações para o problema WBD. ....	199
Tabela G.2 (a) – Resultados obtidos nas simulações para o problema DPV. ....	200
Tabela G.2 (b) – Resultados obtidos nas simulações para o problema DPV. ....	200
Tabela G.2 (c) – Resultados obtidos nas simulações para o problema DPV. ....	201
Tabela G.2 (d) – Resultados obtidos nas simulações para o problema DPV. ....	201
Tabela G.2 (e) – Resultados obtidos nas simulações para o problema DPV. ....	202
Tabela G.3 (a) – Resultados obtidos nas simulações para o problema MWTCS. ....	203
Tabela G.3 (b) – Resultados obtidos nas simulações para o problema MWTCS. ....	204
Tabela G.3 (c) – Resultados obtidos nas simulações para o problema MWTCS. ....	204
Tabela G.3 (d) – Resultados obtidos nas simulações para o problema MWTCS. ....	205
Tabela G.3 (e) – Resultados obtidos nas simulações para o problema MWTCS. ....	205
Tabela G.4 (a) – Resultados obtidos nas simulações para o problema SRD. ....	206
Tabela G.4 (b) – Resultados obtidos nas simulações para o problema SRD. ....	206
Tabela G.4 (c) – Resultados obtidos nas simulações para o problema SRD. ....	207
Tabela G.4 (d) – Resultados obtidos nas simulações para o problema SRD. ....	207
Tabela G.4 (e) – Resultados obtidos nas simulações para o problema SRD. ....	208
Tabela H.1 (a) – Resultados obtidos nas simulações para o problema br26. ....	209
Tabela H.1 (b) – Resultados obtidos nas simulações para o problema br26. ....	210
Tabela H.1 (c) – Resultados obtidos nas simulações para o problema br26. ....	211
Tabela H.1 (d) – Resultados obtidos nas simulações para o problema br26. ....	212
Tabela H.1 (e) – Resultados obtidos nas simulações para o problema br26. ....	213
Tabela H.2 (a) – Resultados obtidos nas simulações para o problema kroa100. ....	214
Tabela H.2 (b) – Resultados obtidos nas simulações para o problema kroa100. ....	215
Tabela H.2 (c) – Resultados obtidos nas simulações para o problema kroa100. ....	216
Tabela H.2 (d) – Resultados obtidos nas simulações para o problema kroa100. ....	217
Tabela H.2 (e) – Resultados obtidos nas simulações para o problema kroa100. ....	218
Tabela H.3 (a) – Resultados obtidos nas simulações para o problema att532. ....	219
Tabela H.3 (b) – Resultados obtidos nas simulações para o problema att532. ....	220
Tabela H.3 (c) – Resultados obtidos nas simulações para o problema att532. ....	221

Tabela H.3 (d) – Resultados obtidos nas simulações para o problema att532. ....	222
Tabela H.3 (e) – Resultados obtidos nas simulações para o problema att532.....	223
Tabela H.4 (a) – Resultados obtidos nas simulações para o problema pcb1173.....	224
Tabela H.4 (b) – Resultados obtidos nas simulações para o problema pcb1173.....	225
Tabela H.4 (c) – Resultados obtidos nas simulações para o problema pcb1173.....	226
Tabela H.4 (d) – Resultados obtidos nas simulações para o problema pcb1173.....	227
Tabela H.4 (e) – Resultados obtidos nas simulações para o problema pcb1173.....	228

## LISTA DE GRÁFICOS

Gráfico 2.1 – Evolução dos indivíduos no processo de interação social do $DPRr = 1$ . ....	26
Gráfico 2.2 – Evolução dos indivíduos no processo de interação social do $DPRr > 1$ . ....	28
Gráfico 2.3 – Evolução dos indivíduos no processo de interação social do $DPT_r = 1$ .....	33
Gráfico 2.4 – Evolução dos indivíduos no processo de interação social do $DPRr > 1$ . ....	36
Gráfico 2.5 – Evolução dos indivíduos no processo de interação social do NpSIGA. ....	41
Gráfico 2.6 – Participação proporcional dos indivíduos antes e depois da interação social. .....	42
Gráfico 2.7 – Possíveis comportamentos dos indivíduos no FIPD. ....	44
Gráfico 2.8 – Função de Pagamento do FIPD. ....	46
Gráfico 2.9 – Conjuntos nebulosos para o fator $f_1$ .....	48
Gráfico 2.10 – Conjuntos nebulosos para o fator $f_2$ .....	50
Gráfico 2.11 – Função Gaussiana para representar o FE <i>i</i> . ....	65
Gráfico 2.12 – Função aproximativa exponencial para representar o FE <i>d</i> . ....	66
Gráfico 2.13 – Fator de experiência de um indivíduo em função da sua idade e da quantidade de disputas.....	66
Gráfico 3.1 – Visualização da função $f_1$ . ....	74
Gráfico 3.2 – Gráfico de dispersão para os resultados das simulações do problema $f_1$ .....	75
Gráfico 3.3 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema $f_1$ . ....	76
Gráfico 3.4 – Visualização da função $f_6$ . ....	78
Gráfico 3.5 – Gráfico de dispersão para os resultados das simulações do problema $f_6$ .....	79
Gráfico 3.6 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema $f_6$ . ....	80
Gráfico 3.7 – Visualização da função $f_8$ . ....	82
Gráfico 3.8 – Gráfico de dispersão para os resultados das simulações do problema $f_8$ .....	83
Gráfico 3.9 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema $f_8$ . ....	84
Gráfico 3.10 – Gráfico de dispersão para os resultados das simulações do problema <i>WBD</i> . .....	89

Gráfico 3.11 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema <i>WBD</i> . .....	90
Gráfico 3.12 – Gráfico de dispersão para os resultados das simulações do problema <i>DPV</i> . .....	94
Gráfico 3.13 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema <i>WBD</i> . .....	95
Gráfico 3.14 – Gráfico de dispersão para os resultados das simulações do problema <i>MWTCS</i> . .....	98
Gráfico 3.15 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema <i>MWTCS</i> . .....	99
Gráfico 3.16 – Gráfico de dispersão para os resultados das simulações do problema <i>SRD</i> . .....	104
Gráfico 3.17 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema <i>SRD</i> . .....	105
Gráfico 3.18 – Gráfico de dispersão para os resultados das simulações do problema <i>br26</i> . .....	110
Gráfico 3.19 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema <i>br26</i> . .....	111
Gráfico 3.20 – Gráfico de dispersão para os resultados das simulações do problema <i>kroa100</i> . .....	113
Gráfico 3.21 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema <i>kroa100</i> . .....	114
Gráfico 3.22 – Gráfico de dispersão para os resultados das simulações do problema <i>att532</i> . .....	116
Gráfico 3.23 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema <i>att532</i> . .....	117
Gráfico 3.24 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema <i>att532</i> sem os resultados do algoritmo NpSIGA. ....	118
Gráfico 3.25 – Gráfico de dispersão para os resultados das simulações do problema <i>pcb1173</i> . .....	120

Gráfico 3.26 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema <i>pcb1173</i> . .....	121
Gráfico 3.27 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema <i>pcb1173</i> sem os resultados do algoritmo NpSIGA. ....	122

## RESUMO

Este trabalho apresenta uma nova metaheurística híbrida e bioinspirada na natureza, baseada em três pilares fundamentais, que são: os Algoritmos Genéticos; a Teoria dos Jogos; e, a Lógica Nebulosa. Assim, o Algoritmo Genético com Interação Social Nebulosa, ou F-SIGA, é fundamentado e caracterizado por permitir aos indivíduos da população a possibilidade de participar do processo de Interação Social. Essa etapa é anterior ao processo de seleção para a geração dos descendentes, e nela eles podem obter ganhos através das disputas com outros indivíduos. Para isso, cada indivíduo é caracterizado por dois cromossomos, sendo um referente a solução do problema em questão; e, o outro, com a codificação genética da sua estratégia de comportamento. Como ambiente de disputas é utilizado o jogo Dilema do Prisioneiro, nas versões de 2-pessoas e N-pessoas, inclusive com a abordagem nebulosa. Além disso, os indivíduos são avaliados por uma função de fitness que engloba: a representação da solução do problema, os ganhos obtidos nas disputas e, ainda, o Fator de Experiência, que utiliza da experiência adquirida pelo indivíduo também como componente para auxiliar no processo evolutivo da população. Esta característica deu origem ao algoritmo ESIA – não previsto inicialmente – onde apenas as informações obtidas nas Interações Sociais são consideradas na seleção dos indivíduos para a etapa de reprodução. Metodologicamente, o trabalho evoluiu para o surgimento do algoritmo ESIA, que é uma nova classe de Algoritmos Evolucionários baseados em Interação Social. Sendo assim, este trabalho apresenta quatro algoritmos: o SIGA, o NpSIGA, o F-SIGA e o ESIA, com suas fundamentações teóricas e, também, resultados práticos ao aplicá-los à problemas de otimização global, com e sem restrições; e, à instâncias do Problema do Caixeiro Viajante.

Palavras-Chave: Algoritmos Genéticos, Teoria dos Jogos, Sistemas Nebulosos, Algoritmo Genético com Interação Social, SIGA, Algoritmo Genético com Interação Social Nebulosa, F-SIGA, Algoritmo Evolucionário de Interação Social, ESIA, Problemas Multimodais, Problemas com Restrições, Problema do Caixeiro Viajante.

## ABSTRACT

This work presents a new new hybrid metaheuristic and bioinspired in nature, based on three main pillars, namely: Genetic Algorithms; Game Theory; and Fuzzy Logic. Thus, the Fuzzy Social Interaction Genetic Algorithm , or F-SIGA, is based and characterized by allowing individuals in the population the possibility to participate in the Social Interaction process. This step is prior to the selection process for the generation of offspring, and in it they can make gains through disputes with other individuals. For this, each individual is characterized by two chromosomes, one related to solving the problem in question; and, the other, with the gene encoding a behavioral strategy. As disputes environment is used the Prisoner's Dilemma game, in 2-person and N-person versions, including the fuzzy approach. In addition, individuals are evaluated by a fitness function that includes: a representation of the problem´ solution, the gains made in disputes and also the experience factor, using the experience acquired by the individual as well as a component to assist in the evolving process of the population. This characteristic gave rise to the ESIA algorithm - not originally planned - where only the information obtained from social interactions are considered in the selection of individuals for reproduction stage. Methodologically, the work evolved into the emergence of the ESIA algorithm, which is a new class of Evolutionary Algorithms based on social interaction. Thus, this work presents four algorithms: SIGA, NpSIGA, F-SIGA and ESIA, with its theoretical foundations and also practical results of applying them to global optimization problems with and without constraints; and the instances of the Travelling Salesman Problem.

Keywords: Genetic Algorithm, Game Theory, Fuzzy Systems, Social Interaction Genetic Algorithm, SIGA, Fuzzy Social Interaction Genetic Algorithm, F-SIGA, Evolutionary Social Interaction Algorithm, ESIA, Multimodal Problems, Problems with Constraints, Traveling Salesman Problem.

# CAPÍTULO I

## 1. INTRODUÇÃO

### 1.1. MOTIVAÇÃO E JUSTIFICATIVA

Em setembro de 1948, John Von Neumann ao participar do *Hixon Symposium on the Brain*, evento realizado no Instituto de Tecnologia da Califórnia e prestigiado em sua quase totalidade por estudiosos das Ciências Cognitivas e Psicológicas, sugeriu em sua palestra *The General and Logical Theory of Automata*, que o novato campo da computação poderia aprender muito com o estudo da natureza e, assim disse:

**Organismos naturais são, em regra, muito mais complicados e sutis, e então muito menos compreendidos em detalhes do que são os autômatos artificiais. Todavia, algumas regularidades que observamos na sua organização podem ser completamente instrutivas em nosso pensamento e planejamento destes outros (FORBES, 2005).**

O mais importante nisso tudo, é que Von Neumann percebeu logo que a natureza havia criado o mais poderoso sistema de informação concebível, o cérebro humano, e a sua computação seria a chave para a criação de computadores igualmente poderosos. Isto acabou inspirando-o na concepção de um modelo abstrato dos primeiros computadores digitais, chamado de **Máquina de Von Neumann**.

Conforme FORBES (2005), algumas décadas após a palestra de Von Neumann, Seymour Cray – “Pai do Supercomputador” – disse também que acreditava na significativa influência da biologia no futuro do processamento da informação.

Ele afirmou, em discurso realizado em 1994, que havia lido nos últimos anos diversos artigos que o deixaram de queixo caído, pois não haviam sido escritos pela comunidade de Ciência da Computação e, sim, pela de Biologia Molecular.

Esses artigos o fizeram pensar em dois caminhos de uma revolução tecnológica muito maior: (1) **a construção de elementos computacionais inspirados na biologia**; (2) **a utilização de dispositivos biológicos na computação de informação**.

Atualmente, um pouco mais de quinze anos depois da afirmação de Cray, tem-se a área de **Computação Natural (CN)**, que pode ser definida a partir de todos os sistemas computacionais desenvolvidos com inspiração ou utilização de algum mecanismo natural ou biológico de processamento de informação.

De acordo com DE CASTRO (2010), a Computação Natural atua na interseção entre a natureza e a computação, pois permite a criação de universos completos, com reino animal, vegetal e mineral, tudo dentro do ambiente digital; e, também, na resolução de problemas complexos do cotidiano das pessoas, empresas e indústrias, que vão desde a decisão do caminho a seguir para chegar ao trabalho até a melhor configuração de matéria prima para a fabricação de um produto de qualidade.

Ela, a Computação Natural, é caracterizada por metáforas e inspirações, onde: (1) a natureza pode servir de inspiração para a computação; (2) a computação pode ser utilizada para entender melhor a natureza; e, (3) a própria natureza pode ser utilizada para computar. E, dessa forma, a Computação Natural está subdividida em três subáreas, conforme são brevemente apresentadas a seguir.

1. **Computação Bio-inspirada:** é a abordagem mais antiga e popular da Computação Natural e está alicerçada em duas ideias principais, que são:
  - a. Modelagem de sistemas e processos naturais com objetivo de simulá-los em computadores;
  - b. Estudo de fenômenos biológicos, processos e até mesmo de modelos teóricos para o desenvolvimento de sistemas computacionais e algoritmos capazes de solucionar problemas complexos;
2. **Vida Artificial e Geometria Fractal da Natureza:** analisa organismos vivos – as criaturas e seus comportamentos – na tentativa de sintetizá-los computacionalmente, como forma de aumentar a compreensão sobre a natureza, gerar modelos artificiais que possibilitem novas formas de vida e o desenvolvimento de novas tecnologias, tais como: robôs-humanoides;

3. **Computação com Significado Natural:** objetiva utilizar mecanismos naturais, cadeias de DNA e técnicas de engenharia genética como novos paradigmas de computação, de forma que possam a vir complementar e/ou complementar os computadores atuais baseados em tecnologia de silício e na *Máquina de Von Neumann*. Como exemplo, tem-se: a Computação Molecular e a Computação Quântica.

A motivação para a construção de métodos computacionais inspirados no comportamento biológico, item 1.b., é a obtenção de técnicas, denominadas de *Heurísticas* ou *Metaheurísticas*<sup>1</sup>, capazes de solucionar problemas ou, pelo menos, obter soluções satisfatórias melhores do que as obtidas por técnicas clássicas de otimização, por exemplo, tais como: programação linear e não linear (FORBES, 2005; DE CASTRO, 2006).

E com esse intuito, nos últimos onze anos, alguns trabalhos foram desenvolvidos, de forma a aplicar conceitos da **Teoria dos Jogos Evolucionários (TJE)**<sup>2</sup> e da **Teoria dos Jogos (TJ)**<sup>3</sup> aos **Algoritmos Genéticos (AG)**<sup>4</sup>, através do uso dos jogos *Hawk-Dove* (HD),

---

<sup>1</sup> De acordo com BLUM e ROLI (2003) uma **Metaheurística** é um conjunto de conceitos usados para definir métodos heurísticos, ou seja, é uma estrutura genérica de um algoritmo que pode ser aplicada em diferentes problemas de otimização com o objetivo de encontrar uma solução factível – não necessariamente ótima – em tempo de processamento aceitável.

<sup>2</sup> Os **Jogos Evolucionários** são uma classe especial de jogos, e são tratados pela **Teoria dos Jogos Evolucionários**, que surgiram com o trabalho de Maynard Smith e Price em 1973, ao introduzirem o conceito de **Estratégia Evolucionária Estável** (*Evolutionary Stable Strategy – ESS*). Enquanto que nos Jogos Não-Cooperativos os jogadores são analisados como se todos fossem totalmente racionais, conhecendo todos os detalhes do jogo e todas as preferências dos seus adversários, nos Jogos Evolucionários, eles são condicionados biologicamente ou socialmente, e escolhidos aleatoriamente dentro de uma população, e de certa forma estão pré-programados geneticamente com alguma estratégia de comportamento. E, ainda, algum processo evolucionário opera na população distribuindo os comportamentos (SMITH e PRICE, 1973; SMITH, 1980).

<sup>3</sup> A **Teoria dos Jogos** lida com situações de conflito de interesses, onde dois ou mais agentes disputam algum recurso limitado ou escasso disponível em um ambiente, como por exemplo: alimentos. Esses agentes são considerados racionais e, assim, levam em consideração as possíveis consequências de cada curso de ação que têm diante de si, ao perceberem certa preferência entre elas e, por isso, escolhem a linha de ação que, em suas estimativas, poderá levá-los a um maior ganho. Porém, isso não depende somente de si, mas também das escolhas dos outros indivíduos. Em outras palavras, os agentes racionais fazem tudo o que estiver ao seu alcance para atingir os seus objetivos. De forma mais objetiva, a Teoria dos Jogos modela matematicamente situações de conflito de interesses entre agentes racionais (NEUMANN e MORGENSTERN, 1944; LUCE e RAIFFA, 1957; RAPOPORT, 1966; RAPOPORT, 1980; BORGES, 1996).

Dilema do Prisioneiro (DP) e ainda outros tipos de jogos, conforme podem ser vistos em LEHRER (2000), TEIXEIRA (2005), BRITO et al. (2005), TEIXEIRA et al. (2006a), TEIXEIRA et al. (2006b), LAHOZ-BELTRA et al. (2009), DIAS et al. (2010), TEIXEIRA et al. (2010a), TEIXEIRA et al. (2010b) e TEIXEIRA et al. (2011).

Da mesma forma que os trabalhos mencionados anteriormente, muitas outras metaheurísticas já foram concebidas e desenvolvidas a partir da observação de como a natureza funciona, tanto em nível de genes quanto de comportamento social e cultural, como por exemplo, uma colônia de formigas, um enxame de abelhas e, até mesmo, a sociedade humana (ZHU, 1998; CASTRO e VON ZUBEN, 2005; ALFARES e ESAT, 2007; HE e WANG, 2007; CANIGNA e ESQUIVEL, 2008; BRAJEVIC et al., 2010; MOREIRA, 2010).

Nesse sentido, ao considerar a estrutura do **Algoritmo Genético** de *John Holland* (HOLLAND, 1975), o **Algoritmo Genético Simples** (*Simple Genetic Algorithm - SGA*) de David Goldberg (GOLDBERG, 1989), o **Algoritmo Genético Canônico** (MICHALEWICZ, 1999) e todos os seus descendentes diretos e indiretos, é possível verificar que não implementam, de fato, o conceito de **Fenótipo** (características morfológicas, fisiológicas e comportamentais) e, sim, afirmam apenas que ele é o valor de *fitness* (adaptabilidade) do indivíduo.

No entanto, a definição de fenótipo é bem mais abrangente na **Biologia Evolutiva**, do que esta empregada na teoria dos Algoritmos Genéticos, sendo que ele, o fenótipo, contribui e muito para o processo evolutivo dos indivíduos de uma população (FUTUYAMA, 2002; OTTA e YAMAMOTO, 2009). E o comportamento de um animal tende a maximizar a sobrevivência de seus genes para aquele comportamento (DAWKINS, 1982).

---

<sup>4</sup> O enunciado, **a biologia é um processo de otimização**, é a filosofia de suporte dos métodos da Computação Evolucionária, entre os quais, os Algoritmos Genéticos (AG) são tidos como um dos seus principais paradigmas. Eles estão baseados nos princípios biológicos da Teoria da Evolução de Darwin (Variabilidade das Espécies, Luta pela Existência e Seleção Natural) e nos conceitos da Genética (Gene, Cromossomo, Genótipo e Fenótipo). Dessa forma, uma população durante várias gerações se desenvolve e evolui. A partir desses princípios e conceitos, os AG são capazes de desenvolver soluções para problemas do mundo real, tais como problemas de busca e otimização, e são mais comumente utilizados em problemas que necessitem de uma busca através de um amplo espaço de soluções candidatas, tais como o Problema do Caixeiro Viajante (GOLDBERG, 1989; HAUPT e HAUPT, 2004).

No mesmo caminho, FUTUYAMA (2002) afirma que o conceito de fenótipo está também intimamente relacionado ao comportamento dos indivíduos e é fator determinante para a sobrevivência dos seus genes, considerando a influência exercida pelo ambiente sobre o comportamento, o que reflete conseqüentemente na manutenção de determinados genes, seja em populações de humanos ou de outras espécies de animais.

POUNDSTONE (1992) reforça mais ainda esta afirmação quando diz que o código genético permite aos indivíduos passar não apenas as características físicas, mas também características comportamentais para as gerações seguintes.

Além disso, durante a vida de um indivíduo, mesmo que não tenha características genótípicas tão favoráveis à prática de determinada atividade, ele consegue realizá-la adaptando-se ao ambiente em que está inserido.

De acordo com OTTA e YAMAMOTO (2009), a lógica da teoria evolucionista darwiniana, somada às descobertas da genética, baseia-se em **três princípios dos organismos vivos**, que são:

1. **Princípio da Variabilidade:** os indivíduos de uma mesma espécie apresentam variações no seu fenótipo, ou seja, apresentam variação genética, que é resultante dos processos de mutação e cruzamento;
2. **Princípio da Hereditariedade:** a variação desses fenótipos é hereditária, ou seja, os descendentes de indivíduos que carregam genes que determinam uma variação nas características morfológicas, fisiológicas e/ou comportamentais herdam esses genes;
3. **Princípio da Adaptação:** indivíduos que possuem determinadas variações no fenótipo deixam mais descendentes do que indivíduos que possuem outro fenótipo, ou seja, certas variações genéticas permitem aos indivíduos portadores deixarem mais descendentes.

A partir das considerações expostas, um questionamento pode e deve ser feito e, assim, requer uma resposta: no contexto da teoria clássica dos Algoritmos Genéticos há

alguma maneira que permita aos indivíduos alterar o seu valor de *fitness* durante o processo evolutivo e, dessa forma, evoluírem ao longo do processo de execução do algoritmo? A resposta é: “Não, não há! Mas, sim, é possível! Mas como?”.

A Teoria dos Jogos pode ser utilizada como pilar teórico fundamental para caracterizar uma nova abordagem fenotípica para os Algoritmos Genéticos, pois formaliza matematicamente situações de conflito de interesses. Nessas situações, os indivíduos são caracterizados como agentes racionais e, assim, devem tomar decisões com o objetivo de maximizar os seus ganhos, através da obtenção de recursos dispostos em um ambiente (jogo), conforme já mencionado.

Consequentemente, os indivíduos através de estratégias de comportamento podem participar de disputas entre si e obter mais ou menos recursos que lhes possibilitem maiores chances de sobreviver e gerar, assim, descendentes, ao preservar vivo nas gerações seguintes o seu material genético.

Além disso, é importante e necessário também mencionar e levar em consideração os três principais aspectos que possibilitam a evolução de uma população de indivíduos, estabelecidos em Darwin (1859), que são: (1) **a diversidade em uma população da mesma espécie** ou **variabilidade das espécies**<sup>5</sup>; (2) **a luta permanente pela existência**<sup>6</sup>; e, (3) o processo **seleção natural**<sup>7</sup>.

---

<sup>5</sup> A **variabilidade das espécies** é de fundamental importância para o processo de evolução de uma determinada população. Caso esta seja homogênea, ou seja, os indivíduos sejam muito parecidos, a possibilidade de que haja alguma alteração nas características dessa população, ao ocorrer à troca de material genético para a geração de descendentes, fica bastante reduzida e, conseqüentemente, diminui o seu ritmo de evolução (DARWIN, 1859).

<sup>6</sup> Devido à **luta pela existência**, quaisquer variações, independentemente da sua significância ou causa, desde que sejam de alguma forma úteis para o indivíduo de uma espécie, no que se refere às relações com os outros seres vivos e com o meio ambiente, contribuirão para a sua preservação, sendo geralmente herdadas pelos seus descendentes, que assim terão uma maior possibilidade de sobreviver. A isto se chama de **Seleção Natural**.

<sup>7</sup> A **Seleção Natural** ocorre quando os indivíduos que carregam genes codificadores de certas características físicas e comportamentais (características fenotípicas) conseguem, por exemplo, obter mais recursos alimentares ou atrair mais parceiros reprodutivos do que os indivíduos que não possuem tais características (OTTA e YAMAMOTO, 2009).

Ao compreender melhor a estrutura básica e os fundamentos dos Algoritmos Genéticos, é possível afirmar que esses três aspectos são contemplados sim, através de abstrações simplificadas do modelo presente na natureza, como por exemplo, as relações existentes entre os seres humanos e, deles com a natureza. Ou seja, a abordagem feita por eles, apesar de funcionar e resolver problemas complexos, é incompleta do ponto de vista de bio-inspiração, mais especificamente na visão da **Sociobiologia**<sup>8</sup>.

Como consequência há necessidade de expressar alguns fatos e, ainda, gerar breve discussão sobre esses três aspectos aplicados ao contexto dos Algoritmos Genéticos. Neles, a diversidade populacional tende a decrescer ao longo do processo evolutivo e, com isso, é possível e comum de ocorrer, ao seu final, uma homogeneidade genotípica dos indivíduos, ou seja, eles passam a ser idênticos (GOLDBERG, 1989; MICHALEWICZ, 1999; HAUPT e HAUPT, 2004).

Esse fenômeno é conhecido como **Convergência Prematura**<sup>9</sup> e, consequentemente, o algoritmo fica preso em ótimos locais, pois não há nenhum

---

<sup>8</sup> A **Sociobiologia** é um ramo da biologia que estuda o comportamento social dos animais, usando conceitos da etologia, evolução, sociologia e genética das populações. Nela são propostos que os comportamentos e os sentimentos animais, também existentes nos seres humanos, como o altruísmo e a agressividade, são em parte derivados da genética, e não apenas culturais ou socialmente adquiridos (FUTUYAMA, 2002; TRIVERS, 2002). Mais especificamente, a etologia é a disciplina que estuda o comportamento animal sob a influência da Teoria da Evolução, com foco na evolução do comportamento através do processo de seleção natural. E cada espécie tem o seu próprio repertório de padrões de comportamento (DARWIN, 1859).

<sup>9</sup> A **Convergência Prematura** é um problema crucial encontrado pelos Algoritmos Genéticos e seus métodos híbridos derivativos, que influenciam no sucesso em obter no seu processo evolutivo a solução ótima, ao convergir para regiões sub-ótimas da região de superfície, que caracteriza o problema a ser resolvido.

Ocorre quando os genes de um indivíduo altamente qualificado passam a dominar a população, o que restringe o processo evolutivo a um ótimo local. E, dessa forma, os operadores genéticos não conseguem produzir novos descendentes melhores que seus antecedentes, o que diminui a habilidade do algoritmo em continuar a busca por melhores soluções (FOGEL, 2000).

Para evitar a ocorrência da convergência prematura, no algoritmo genético é necessário que haja a preservação da diversidade populacional durante o processo evolutivo. Ou seja, a manutenção da diversidade assegura a não ocorrência da convergência prematura.

Para isso, alguns métodos são empregados, tais como: seleção restrita de indivíduos, aplicação dinâmica do operador de mutação, restrições nas taxas de mutação e cruzamento, amostragem universal estocástica, atribuição de fitness variável, reinicialização parcial da população, métodos de agrupamento de indivíduos, acasalamento restrito, elitismo, simbiogênese, técnicas de conservação de espécies, busca local baseada na diversidade. Todos esses métodos são heurísticas e os seus efeitos variam para diferentes problemas (NICOARÁ, 2009).

mecanismo específico de manutenção de variabilidade em sua estrutura clássica, como por exemplo: a ocorrência de um desastre natural, uma epidemia virótica ou, simplesmente, a possibilidade de alterar o valor de *fitness* dos indivíduos no decorrer de sua existência (GOLDBERG, 1989; DE JONG, 2006).

Apesar da existência dos operadores de mutação e cruzamento, que possibilitam a geração de variabilidade dentro de uma população, e como os valores para as suas respectivas taxas que são aplicadas em uma execução do algoritmo são fixas, a convergência prematura ocorre em certas aplicações, como no caso do Problema do Caixeiro Viajante.

Em NICOARĂ (2009), por exemplo, são definidos dois métodos para manutenção da variabilidade: (1) alteração dinâmica das taxas dos operadores de cruzamento e mutação; (2) reinicialização parcial da população quando for observada diminuição de variabilidade.

Em relação à luta pela existência, MITCHELL (1999) afirma que todos os indivíduos nascem com seus valores de *fitness* fixos e imutáveis e, assim, pode-se afirmar que os AG não tem, também, nenhum mecanismo que possibilite a ocorrência de disputas entre os indivíduos, de forma que lhes permitam evoluir e melhorarem a sua adaptabilidade, com a alteração de seus valores de *fitness*, sem que se transformem em outros indivíduos.

E o processo de seleção natural? Pode-se afirmar que é um modelo bastante simplificado e que privilegia muito os indivíduos mais bem adaptados, com uma maior possibilidade de reproduzir e passar, para as próximas gerações, o seu material genético.

---

No mundo real, há difíceis instâncias de problemas onde um único método não é adequado. E, assim, outro aspecto chave a ser considerado é a dupla característica da diversidade populacional, que são: a diversidade do espaço de busca; e, a diversidade no espaço de parâmetros.

Dessa forma, para alguns problemas é suficiente preservar a diversidade em apenas um dos dois aspectos mencionados; para outros, um bom algoritmo genético deve manter a diversidade populacional nos dois aspectos. É importante identificar a ocorrência de convergência prematura através de varias medidas, tais como: a diferença entre o melhor *fitness* e média de *fitness*, ou até mesmo medidas estatísticas através da distância de *Hamming* entre os indivíduos e a variância dessas distâncias, por exemplo; e, avaliar a sua extensão (BELEA et al., 2004).

Isso ocorre independentemente do mecanismo de seleção utilizado, como por exemplo, os métodos:

- (1) Roleta, onde apesar de todos os indivíduos terem alguma chance de serem selecionados, a seleção é proporcional ao valor de *fitness*, ou seja, é extremamente elitista;
- (2) Torneio, onde somente o pior indivíduo não tem chance alguma de ser escolhido para reproduzir (GOLDBERG, 1989; MICHALEWICZ, 1999; HAUPT e HAUPT, 2004).

Na espécie humana, por exemplo, um indivíduo tem a possibilidade de evoluir e alterar o seu valor de *fitness* através de ascensão social, por exemplo, mesmo que não seja geneticamente bem adaptado.

Dessa forma, não é modificada necessariamente a sua estrutura genotípica no que se refere à solução do problema, mas lhe permite assim uma maior chance de gerar descendentes mais evoluídos. Isso pode ser melhor compreendido através do **Dawinismo Social**<sup>10</sup>.

---

<sup>10</sup> O **Dawinismo Social** surgiu nas Ciências Sociais com o objetivo de explicar o processo evolutivo de uma sociedade, pois afirma a existência de características biológicas e sociais que determinam que uma pessoa seja superior a outra e, dessa forma, aquelas pessoas que se enquadram em determinados critérios são mais aptas. Exemplos de critérios que indicariam superioridade de um ser humano em relação a outros são: (1) maior poder aquisitivo; (2) habilidade nas ciências exatas e humanas em detrimento de outras ciências, tais como as artes; (3) ou, até mesmo, a raça a que pertence (BANNISTER, 1979; WEIKART, 1995).

Para alguns pensadores, a sua origem é atribuída ao próprio Charles Darwin, devido à sua obra **A Origem do Homem** (DARWIN, 1882), onde ele aplicou os conceitos da Origem das Espécies ao processo de evolução humana. No entanto foi Herbert Spencer que popularizou a ideia de que grupos e sociedades evoluem através do conflito e da competição. E lembrando que a teoria de Darwin afirma que no mundo sobrevive o mais bem adaptado e por isso há evolução, e que os seres vivos evoluem para continuarem vivos, da mesma forma que a espécie humana.

Nesse sentido, o evolucionismo social é uma tentativa de formalizar o pensamento social a partir de bases científicas pautadas na teoria da biológica da evolução. “Se organismos podem ser desenvolvidos com o passar do tempo de acordo com leis compreensíveis e determinísticas, então é razoável que sociedades também possam” (HODGSON, 2004).

Nesse contexto, o processo de ascensão social pode ser definido através de um ambiente de jogo, formalizado pela Teoria dos Jogos, onde os indivíduos apresentam basicamente os comportamentos **cooperar** ou **trair**, conforme o jogo Dilema do Prisioneiro, por exemplo.

No entanto, é sabido que o comportamento humano não está pautado somente em atitudes de cooperação e traição totais e, sim, são adotados certos graus ou níveis de cooperação/traição, de acordo com o objetivo de cada indivíduo.

Para atingir esse objetivo é possível aplicar os conceitos pertinentes à **Teoria dos Conjuntos Nebulosos**<sup>11</sup>, de forma a produzir comportamento mais próximo do comportamento humano. Assim, um indivíduo pode apresentar, em determinada situação, o comportamento cooperar ou trair com diferentes graus de intensidade.

## 1.2. OBJETIVOS

### 1.2.1. Objetivo Geral

Em síntese, todos esses aspectos apresentados serviram de inspiração e justificativa para a concepção e desenvolvimento de uma nova metaheurística híbrida de otimização inspirada na natureza, denominada de **Algoritmo Genético com Interação Social Nebulosa** ou, simplesmente, **Algoritmo F-SIGA**<sup>12</sup>, através da inclusão da etapa de Interação Social na estrutura dos Algoritmos Genéticos e da aplicação dos conceitos da

---

<sup>11</sup> Lotfi A. Zadeh, em seu trabalho *Fuzzy Sets*, de 1965, apresentou as noções dos conjuntos nebulosos como uma extensão dos conceitos da teoria dos conjuntos clássica, onde uma afirmação só pode ser verdadeira ou falsa (0 ou 1). A proposta da lógica nebulosa, base para compreensão da teoria dos conjuntos nebulosos, é permitir a qualquer afirmação a atribuição de um valor verdade variando continuamente entre os valores 0 e 1.

Dessa forma, ela possibilita a representação do conhecimento a partir de termos linguísticos e, assim, traduz matematicamente a informação aproximada ou imprecisa pertinente a um conjunto de regras linguísticas. Estas, por sua vez, representam o conhecimento de um especialista humano acerca de um determinado domínio. Além disso, a lógica nebulosa lida qualitativamente com as características de um objeto, que podem ser vagas ou imprecisas, tais como: alto, baixo, grande, pequeno, por exemplo (ZADEH, 1965; DUBOIS e PRADE, 1980; KANDEL e LANGHOLZ, 1993; WANG, 1997).

<sup>12</sup> Em inglês: *Fuzzy Social Interaction Genetic Algorithm (F-SIGA)*.

Teoria dos Conjuntos Nebulosos aos comportamentos *trair* e *cooperar* dos indivíduos durante esta etapa.

A proposição desse novo algoritmo tem três perspectivas:

- (1) ser uma nova metaheurística bioinspirada na natureza;
- (2) ser uma evolução metodológica dos Algoritmos Genéticos, ao caracterizar formalmente o comportamento dos indivíduos, em situações de conflito de interesses, como um aspecto fenotípico. E o comportamento ser expresso através de graus de intensidade, tal como os seres humanos;
- (3) ser uma metaheurística capaz de solucionar problemas de uma forma mais eficaz, comparada a outros métodos, sendo (a) um modelo mais próximo da natureza; (b) que mantenha a diversidade populacional, ao controlar a convergência prematura; e, (c) obtenha resultados melhores do que outras técnicas para problemas-teste já consagrados na literatura e no meio científico.

### **1.2.2. Objetivos Específicos**

Como forma de atingir o objetivo geral descrito, tem-se os seguintes objetivos específicos:

1. Realizar estudos sobre a aplicação do conceito de Lógica e Sistemas Nebulosos ao contexto da Teoria dos Jogos, através de trabalhos correlatos;
2. Especificar o jogo Dilema do Prisioneiro Nebuloso;
3. Especificar a estrutura do Algoritmo Genético com Interação Nebulosa;
4. Codificar geneticamente as estratégias de comportamento nebulosas;

5. Desenvolver a ferramenta de software para a realização das simulações e testes, com aplicação dos algoritmos na resolução de Problemas de Otimização Global, com e sem restrições; e, em instâncias do Problema do Caixeiro Viajante.
6. Definir as configurações da simulações para validação do método proposto;
7. Realizar a descrição e análise dos resultados obtidos nas simulações.

## 1.4. PRINCÍPAIS CONTRIBUIÇÕES

As contribuições advindas do desenvolvimento deste trabalho são as seguintes:

1. Evolução metodológica do Algoritmos Genéticos, a partir da inclusão da fase de Interação Social, que formaliza o aspecto fenotípico do método.
2. Hibridização do Algoritmos Genéticos através da Teoria dos Jogos e, esta pela Teoria dos Conjuntos e Sistemas Nebulosos;
3. Concepção e especificação de quatro algoritmos híbridos inspirados na natureza, que são: SIGA, NpSIGA, F-SIGA e o ESIA;
4. Aplicação dos algoritmos à três categorias de problemas: (a) otimização global sem restrições; (b) otimização global com restrições; e, (c) otimização combinatória, através do Problema do Caixeiro Viajante Simétrico<sup>13</sup>;
5. A definição do Fator de Experiência, que caracteriza o algoritmo ESIA e, assim, surge a possibilidade de uma nova classe de Algoritmos Evolucionários, baseados em Evolução Social;

---

<sup>13</sup> O NpSIGA foi aplicado somente ao Problema do Caixeiro Viajante.

6. Um nova função de fitness, que considera: (a) a solução do problema; (b) os ganhos obtidos nas disputas no processo de Interação Social; e ainda, (3) a experiência obtida pelo indivíduo ao longo de sua existência nesse processo, através do Fator de Experiência;
7. A ferramenta de software desenvolvida em linguagem JAVA, que permite a execução das simulações.
8. E as publicações, que estão listadas no anexo F.

### 1.3. ESTRUTURA DA TESE

Este trabalho está estruturado em **quatro capítulos** e **nove anexos**. Os outros três capítulos são: o Capítulo dois apresenta os algoritmos com interação social, o SIGA, o NpSIGA, F-SIGA e o ESIA; no Capítulo três são apresentados os problemas utilizados nas simulações e a descrição e análise dos seus respectivos resultados; e, por fim, no Capítulo quatro são apresentadas as considerações finais, através das conclusões, limitações da tese e os trabalhos futuros.

Nos anexos são apresentados conteúdos que foram considerados adjacentes – apesar de básicos – ao foco principal do trabalho e, dessa forma, a fundamentação teórica foi colocada nesse formato.

Assim, os três primeiros anexos (**A**, **B** e **C**) apresentam brevemente cada um dos três pilares teóricos fundamentais que embasam o propósito da tese, nomeados da seguinte maneira, respectivamente: Algoritmos Genéticos: Uma Visão Geral; Fundamentos da Teoria dos Jogos; e, Teoria dos Conjuntos e Sistemas Nebulosos.

Nos anexos seguintes são apresentados: (**D**) as estratégias de comportamento geneticamente codificadas e utilizadas no Dilema do Prisioneiro, nas versões clássica e nebulosa; (**E**) as configurações dos parâmetros utilizados nas simulações; (**F**) Resultados obtidos nas simulações para os Problemas de Otimização Global sem Restrições; (**G**) Resultados obtidos nas simulações para os Problemas de Otimização Global com

Restrições; **(H)** Resultados obtidos nas simulações para quatro instâncias do Problema do Caixeiro Viajante; **(I)** Lista das publicações realizadas no período de doutoramento, incluindo as publicações que culminaram na tese, além de outras derivadas de orientação e/ou co-orientação de projetos de iniciação científica, trabalhos de conclusão de curso e dissertações de mestrado e tese de doutorado, que tem alguma relação com a temática da tese.

## CAPÍTULO II

### 2. PROPOSTA DE ALGORITMOS COM INTERAÇÃO SOCIAL

#### 2.1. APRESENTAÇÃO

Para tornar os Algoritmos Genéticos mais próximos do modelo presente na natureza, além de possuírem as características genóticas inerentes a eles, as fenotípicas podem ser caracterizadas através de um processo de interação social, sendo este anterior ao processo de reprodução dos indivíduos para a geração dos descendentes.

Esta nova fase tem por objetivo caracterizar a luta pela existência entre os indivíduos e, assim, dar-lhes a oportunidade de melhorar a sua adaptabilidade a partir da obtenção de recursos/ganhos durante essa etapa. Como consequência, para aqueles que participam, há uma modificação nas suas adaptabilidades (Valor de *Fitness*), o que pode lhes proporcionar maiores chances de seleção para o processo de reprodução. Assim, esses indivíduos não ficam sujeitos apenas ao fator hereditário e fadados à estagnação evolutiva por toda sua existência.

Nesse sentido, através da Teoria dos Jogos, que formaliza matematicamente situações de conflito de interesses, é definido o ambiente de **Interação Social**<sup>14</sup>. Nele os indivíduos, agentes, disputam entre si recursos disponíveis no jogo, ambiente, e através da obtenção desses recursos, valores de pagamento, eles podem evoluir ao longo da sua existência.

O grau de evolução pode ser maior ou menor, pois um indivíduo pode evoluir mais ou menos do que outros em decorrência dos ganhos obtidos nas interações sociais. Isso caracteriza o processo de evolução social da população.

---

<sup>14</sup> O termo **Interação Social** representa muito bem o que se deseja com esse processo, pois significa a **interação entre indivíduos de uma população** e não somente o encontro de dois indivíduos para reproduzirem, conforme ocorre na teoria dos Algoritmos Genéticos. Deve-se ter em mente que ele está diretamente ligado a quaisquer situações de conflito de interesses que possam vir a existir entre os indivíduos de uma população, o que pode ser demonstrado por um jogo social, econômico ou até mesmo evolutivo.

Além disso, os ganhos obtidos são posteriormente adicionados aos valores de *fitness* de cada um dos indivíduos a nível fenotípico e, portanto, as características genóticas são mantidas intactas. Assim, a integridade da informação relativa à solução do problema não é afetada.

Dessa forma, na figura 2.1 é apresentado o esquema do **Algoritmo Genético com Interação Social**<sup>15</sup>, que é resultado da união da teoria clássica dos Algoritmos Genéticos e dos fundamentos da Teoria dos Jogos. O primeiro caracteriza o aspecto genotípico da nova metaheurística, devido à representação cromossômica dos indivíduos (soluções candidatas do problema); enquanto que o segundo caracteriza o seu aspecto fenotípico, pois mune os indivíduos de estratégias de comportamento, além de especificar o ambiente de interação social e os valores de ganhos advindos das interações entre os indivíduos.

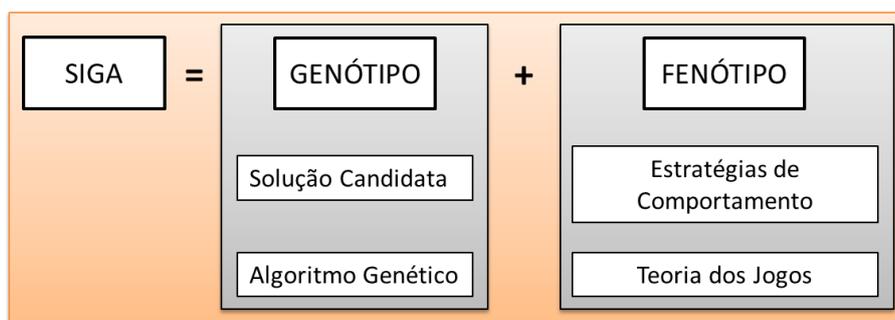


Figura 2.1 – Esquema do Algoritmo Genético com Interação Social.

Dessa forma, a afirmativa de MITCHELL (1999) que diz: “quando um indivíduo da população de um Algoritmo Genético nasce, a sua possibilidade de sobreviver e gerar descendência é fixa e imutável”, torna-se falsa. E, além disso, a visão de fenótipo existente nos AG deixa de ser focada apenas no cálculo do valor de *fitness* do indivíduo, que é obtido a partir do seu cromossomo e a função objetivo do problema a ser resolvido, e passa a contar também com os ganhos obtidos nas interações sociais.

Esse novo componente possibilita a caracterização genotípica de um indivíduo, conforme a figura 2.2., sendo este composto por dois cromossomos, onde: (1) cromossomo

<sup>15</sup> Em inglês: *Social Interaction Genetic Algorithm (SIGA)*.

solução, que representa as informações referentes à solução do problema; (2) cromossomo estratégia, representa as informações sobre a sua estratégia de comportamento.

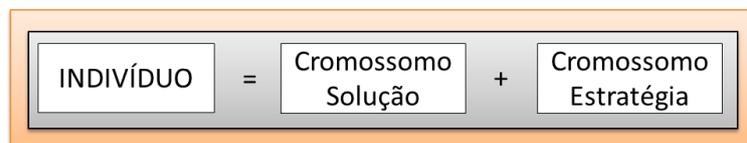


Figura 2.2 – Representação esquemática dos indivíduos com dois cromossomos.

Além da adição de características fenotípicas aos Algoritmos Genéticos, a inserção desta etapa objetiva também a diminuição do alto grau de aleatoriedade do processo de busca realizado por eles ou, pelo menos, ter outro componente na tentativa de guiar um pouco mais esse processo. Conseqüentemente, o processo evolutivo da população é favorecido, acelerado e auxiliado na busca pelo ótimo global, na tentativa de impedir a estagnação da busca em ótimos locais, com a perda da diversidade populacional, o que pode acarretar a convergência prematura para um ótimo local.

Com esse mesmo intuito, muitos pesquisadores agregaram novas variáveis biológicas à estrutura tradicional dos AG, tais como em BÄCK e HOFFMEISTER (1991); FREISLEBEN e MERZ (1996); LEFORT et al. (1999; 2004); SIMÕES e COSTA (2001); CHANG et al. (2005) e OTMAN e JAFFAR (2011).

Somente a partir do trabalho de LEHRER (2000) é que foi utilizada a Teoria dos Jogos Evolucionários com esse objetivo. Nesse trabalho foi proposto um novo método de seleção baseado no jogo evolucionário *Hawk-Dove* e, assim, surgiu o método ***Hawk-Dove Roleta (HDR)***. Posteriormente, em BRITO (2004), foi desenvolvida uma variação do HDR, com a simples troca do método roleta pelo torneio utilizado no processo de seleção dos pais para o processo de reprodução e, assim, surgiu o ***Hawk-Dove Torneio (HDT)***. Ambos os métodos foram aplicados na solução do Problema do Caixeiro Viajante.

É importante registrar que, apesar da luta pela existência ser um componente da Biologia Evolutiva, com a inserção da Teoria dos Jogos no contexto dos Algoritmos Genéticos, mais especificamente o jogo Dilema do Prisioneiro, além do componente biológico, passou-se a ter também um aspecto social e econômico. E, assim, foram

inicialmente propostos os novos métodos de seleção **Dilema do Prisioneiro Roleta (DPR)** e **Dilema do Prisioneiro Torneio (DPT)** em Teixeira (2005). Uma infinidade de outros métodos, além desses, podem ser concebidos a partir da simples combinação dos diversos métodos de seleção e configurações de jogos.

## 2.2. ALGORITMO SIGA

A partir dos métodos de seleção desenvolvidos, os citados **HDR** (LEHRER, 2000), **HDT** (BRITO, 2004), **DPR** e **DPT** (TEIXEIRA, 2005), ficou clara a possibilidade de aglutiná-los através de uma classe de algoritmos e, assim, generalizá-los. E, assim, foi denominado de **Algoritmo Genético com Interação Social (SIGA)**.

Ele surge com a proposta de relacionar os universos dos Algoritmos Genéticos, com a representação genotípica dos indivíduos; e, o da Teoria dos Jogos, com a modelagem matemática de situações de conflito de interesses entre indivíduos (agentes racionais), que possuem estratégias de comportamento (características fenotípicas).

É importante enfatizar que o SIGA tem como principal objetivo ser uma metaheurística de busca bio-inspirada, constituída por mecanismos que abstraíam o modelo encontrado na natureza; e que possa ser facilmente adaptada na resolução de problemas complexos. Nessa visão, o SIGA engloba todos os métodos de seleção mencionados e que podem ser instanciados em sua estrutura genérica, conforme é apresentado no pseudocódigo do seu algoritmo na figura 2.3.

A principal diferença entre o Algoritmo Genético de HOLLAND (1975), o Algoritmo Genético Simples de GOLDBERG (1989) e o SIGA é o processo de **Interação Social**, em destaque na figura 2.3. Esse novo processo (passo 4.1) foi incluído antes do processo de reprodução dos indivíduos (passo 4.2), o que lhes permite lutar pela sua existência e obter ganhos nas interações sociais e, assim, tornarem-se mais aptos antes do processo de seleção para, posterior, cruzamento e geração de descendentes.

<ol style="list-style-type: none"> <li>1. Início;</li> <li>2. Gerar população inicial;</li> <li>3. Avaliar cada indivíduo da população inicial;</li> <li>4. Repetir até <math>m</math> gerações</li> </ol>
<pre>// Processo de Interação Social 4.1. Repetir até <math>d</math> disputas   4.1.1. Selecionar aleatoriamente dois indivíduos;   4.1.2. Repetir até <math>r</math> rodadas     a. Obter o comportamento de cada um dos indivíduos, a partir de       suas estratégias de comportamento     b. Alterar as suas adaptabilidades, com base nos seus       comportamentos e na tabela de pagamentos do jogo</pre>
<pre>// Processo de reprodução 4.2. Repetir até o número de descendentes ser igual à quantidade desejada       (% de cruzamento)   4.2.1. Selecionar dois indivíduos conforme o método de seleção;   4.2.2. Realizar a operação de cruzamento nos indivíduos selecionados       no passo anterior;   4.2.3. Realizar a operação de mutação nos descendentes gerados no       passo anterior;   4.2.4. Avaliar os descendentes;  4.3. Substituir os indivíduos da população pelos novos indivíduos gerados       na etapa de reprodução; 5. O melhor indivíduo da população é a solução do problema; 6. Fim.</pre>

Figura 2.3 – Pseudocódigo do algoritmo SIGA.

Esse processo é composto de três etapas, que são: (1) selecionar aleatoriamente dois indivíduos<sup>16</sup>; (2) obter o comportamento de cada um dos indivíduos, a partir de suas estratégias de comportamento; e, (3) alterar as suas adaptabilidades (*Fitness*), com base nos seus comportamentos e na tabela de pagamentos do jogo.

A seleção dos indivíduos para participarem desse processo é realizada aleatoriamente, onde todos têm iguais probabilidades de serem escolhidos. Contudo, nada impede que possa ser utilizado algum critério mais elaborado de seleção.

<sup>16</sup> De acordo com o tipo de jogo que estiver em uso, podem ser selecionados dois ou mais indivíduos para participarem da interação social a cada instante. No caso, por exemplo, do clássico, o Dilema do Prisioneiro, que é um jogo do tipo 2-pessoas, são sempre selecionados apenas dois indivíduos a cada instante para participar da disputa. Maiores detalhes sobre a Teoria dos Jogos estão apresentados no Anexo B.

No entanto, de forma a preservar a característica bio-inspirada do SIGA é preciso ter cuidado para não privilegiar alguns indivíduos em detrimento de outros, por exemplo, e assim, infringir os princípios que regem o processo evolutivo de uma população, principalmente a variabilidade das espécies.

Após a seleção, o comportamento dos indivíduos é obtido através de suas estratégias<sup>17</sup> e, conseqüentemente, as suas adaptabilidades são alteradas conforme a tabela de pagamentos do jogo, como por exemplo, a tabela B.1, do jogo Dilema do Prisioneiro.

O valor de *fitness* de um indivíduo ( $Fitness_{Total}$ ) não é mais somente o valor obtido através do seu genótipo solução ( $Fitness_{Solução}$ ) que é calculado a partir da função objetivo, mas sim a partir da soma ponderada deste com a soma dos recursos obtidos durante as disputas no processo de interação social ( $Fitness_{Estratégia}$ ), conforme a equação (1).

$$Fitness_{Total} = [(\alpha \times Fitness_{Solução}) \pm (\beta \times Fitness_{Estratégia})] \quad (1)$$

Onde:  $\alpha$  e  $\beta \in \mathbb{R}^{18}$ , e o  $\pm$  significa dizer que se for um problema de minimização, logo será subtraído o valor de  $(\beta \times Fitness_{Estratégia})$  do valor de  $(\alpha \times Fitness_{Solução})$ . Caso contrário, o problema seja de maximização esses valores serão somados.

É importante observar que a adaptabilidade dos indivíduos pode tanto aumentar quanto diminuir a partir das disputas, o que depende diretamente do tipo de jogo definido como ambiente de interação social e dos valores atribuídos aos ganhos.

---

<sup>17</sup> As **estratégias de comportamento** utilizadas na estrutura do SIGA e do NpSIGA são codificadas geneticamente e, assim, caracterizadas por um cromossomo com dois genes, que podem assumir os valores {0,1,2}. Dessa forma, é possível configurar nove genótipos, que representam as quatro estratégias definidas, que são: **Sempre Cooperar (ALL-C)**, **Sempre Trair (ALL-D)**, **Tit-For-Tat (TFT)** e **Aleatório**, conforme pode ser visto no anexo D.

Elas são atribuídas aos indivíduos no processo de geração da população inicial, aleatoriamente, seguindo a proporção inicial de 3/9 (ALL-C) : 3/9 (ALL-D) : 2/9 (TFT) : 1/9 (Aleatório). Além disso, nas operações de cruzamento, para a geração dos descendentes, a estratégia do novo indivíduo gerado é obtida através dos cromossomos estratégias dos pais, através de um cruzamento simples.

<sup>18</sup> Não há ainda quaisquer estudos específicos para a determinação dos valores ideais para  $\alpha$  e  $\beta$ .

Dessa forma, é possível ocorrer uma melhora significativa na adaptabilidade de um indivíduo que a priori não era tão apto, como também o inverso, um indivíduo bem adaptado obter perdas nas disputas e, assim, tornar-se menos apto.

Essa possibilidade é justamente o fator que inspirou a inserção do processo de Interação Social na estrutura dos Algoritmos Genéticos, que é dar oportunidade aos menos adaptados obterem recursos.

Assim, eles passam a ter maiores possibilidades de serem selecionados no processo de reprodução. Há certa similaridade com o que ocorre em sociedades humanas, onde, por exemplo, parte da população que é menos abastada, passa a ter acesso a determinados benefícios sociais e assistenciais para poder melhorar de vida.

E, principalmente, é possível que no seu material genético haja alguma informação que proporcione encontrar uma melhor solução para o problema que se quer solucionar, ou até mesmo, possibilitar a saída de um ótimo local, em busca do ótimo global.

Em contraste, no AG, os piores indivíduos são logo descartados, sem considerar essa possibilidade. Como consequência, com o advento do processo de Interação Social há a criação de condições para que sejam encontradas melhores soluções, considerando uma maior manutenção da variabilidade populacional; e, o uso de outro parâmetro no processo de busca, na tentativa de torná-lo menos aleatório.

O acréscimo do processo de Interação Social transforma o Algoritmo Genético em uma metaheurística com dois motores de otimização, conforme demonstrado na figura 2.4, onde:

- (3) o tradicional processo de seleção/reprodução dos indivíduos mais aptos para a geração de descendentes;
- (4) o processo de disputa por recursos, ao objetivar a evolução fenotípica a partir da interação social entre indivíduos.

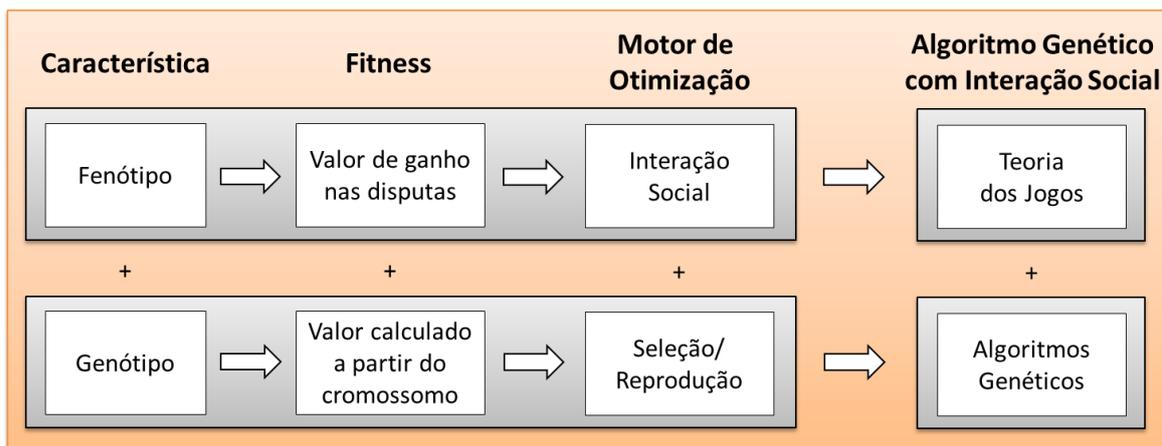


Figura 2.4 – Esquema de composição do SIGA.

## 2.3. MÉTODOS DE SELEÇÃO DILEMA DO PRISIONEIRO

Como forma de exemplificar o funcionamento do SIGA, são apresentados métodos de seleção baseados na combinação do jogo Dilema do Prisioneiro, em seu formato de duas pessoas, com os tradicionais métodos de seleção roleta e torneio. Além disso, cada método é visto em duas abordagens distintas, no que se refere à quantidade de interações em uma mesma disputa, ou seja, com uma ou mais rodadas.

### 2.3.1. Dilema do Prisioneiro Roleta (DPR)

Este método está baseado na estrutura do pseudocódigo do SIGA, apresentado na figura 2.3. As suas únicas diferenças são:

- (1) a inserção de um novo passo 4.2, destinado à montagem da roleta a partir do  $Fitness_{Total}$ , que passa a considerar os ganhos obtidos no processo de Interação Social também, conforme a equação (1); o processo de reprodução passa a ser o passo 4.3 e, assim,
- (2) no passo 4.3.1, a seleção dos indivíduos é realizada com o uso da roleta montada no passo 4.2, conforme em destaque na figura 2.5.

```

...
4. Repetir até  $m$  gerações
  // Processo de Interação Social
  4.1. Repetir até  $d$  disputas
    4.1.1. Selecionar aleatoriamente dois indivíduos;
    4.1.2. Repetir até  $r$  rodadas
      a. Obter o comportamento de cada um dos indivíduos, a partir de
        suas estratégias de comportamento
      b. Alterar as suas adaptabilidades, com base nos seus
        comportamentos e na tabela de pagamentos do jogo
  4.2. Montar a roleta através do  $Fitness_{Total}$ ;
  // Processo de reprodução
  4.3. Repetir até o número de descendentes ser igual à quantidade desejada
    (% de cruzamento)
    4.3.1. Selecionar dois indivíduos utilizando a roleta;
...

```

Figura 2.5 – Parte do pseudocódigo do método DPR.

Como forma de exemplificar o funcionamento dos métodos, na figura 2.6 estão definidos os parâmetros utilizados nas simulações, que são: (1) uma população inicial com quatro indivíduos, sendo estes compostos por: cromossomo, aptidão (*Fitness*) e estratégia de comportamento; e, (2) a definição dos recursos do jogo baseado nos valores dos parâmetros<sup>19</sup>  $T$ ,  $R$ ,  $P$  e  $S$ , e nas relações existentes entre os comportamentos dos dois jogadores, presentes na tabela de pagamentos do Dilema do Prisioneiro.

Estrutura dos Indivíduos			Iteração: 0
Cromossomo	Aptidão	Estratégia	
1	100	Cooperar	
2	60	Trair	
3	130	TFT	
4	110	Aleatório	

		J <sub>2</sub>	
		Cooperar	Trair
J <sub>1</sub>	Cooperar	(25,25)	(10,30)
	Trair	(30,10)	(15,15)

**Obs:**  
1.  $T=30, R=25, P=15, S=10$ ;  
2.  $T > R > P > S$ ;  
3.  $R > ((T + P) / 2) > S$

Figura 2.6 – Parâmetros para exemplificação dos métodos DPR e DPT.

<sup>19</sup> Os parâmetros  $T$ ,  $R$ ,  $P$  e  $S$  referem-se aos valores que compõem a tabela de pagamentos do jogo Dilema do Prisioneiro, que são definidos em maiores detalhes na seção B.4, do anexo B.

Com a população inicial e a tabela de pagamento definidas é possível realizar as simulações do método DPR, onde somente os passos 4.1 e 4.2 do algoritmo da figura 2.5 são utilizados. Esses passos são responsáveis pelo processo de interação social e a montagem da roleta após a sua realização, o que permite demonstrar a influência desse processo na evolução e alteração da adaptabilidade dos indivíduos da população.

a.  $DPR_{(r=1)}$

Esta simulação considera que as disputas entre os indivíduos é composta por apenas uma única rodada, por isso  $r = 1$ . Dessa forma, são totalizadas quatro disputas com uma rodada cada, conforme pode ser visto na figura 2.7.

Além disso, são cinco iterações da população, onde a iteração zero é constituída pela população inicial, definida na figura 2.6, e as outras quatro iterações (1, 2, 3 e após I.S.) são resultado dessas disputas, a partir da seleção aleatória dos seus participantes.

Na primeira disputa os indivíduos **dois** e **três** foram selecionados e as suas respectivas estratégias de comportamento foram obtidas, ou seja, **Sempre Trair** e **TFT**<sup>20</sup>. Assim é configurado o confronto “Trair” vs “Cooperar”, pois é o primeiro encontro entre eles e, assim, o indivíduo age cooperativamente.

Como consequência os indivíduos obtêm valores de ganho iguais a 30 e 10 unidades de valores respectivamente. Estes valores são adicionados às suas aptidões e atualizados, conforme pode ser visto na configuração do estado da população na iteração um, onde o indivíduo dois passa a ter uma aptidão igual a 90 e o indivíduo três igual a 140.

Dessa forma, o processo continua com a realização das disputas entre os indivíduos selecionados até a geração da quinta iteração, que apresenta o estado da população após a realização do processo de interação social. Na parte inferior direita da figura 2.7 é

---

<sup>20</sup> A estratégia TFT (TIT-FOR-TAT) diz: no primeiro encontro com determinado oponente coopere. A partir do encontro seguinte comporte-se da mesma forma que o seu oponente se comportou no encontro anterior (RAPOPORT, 1966; BORGES, 1996).

apresentada, através de um gráfico em formato de pizza, a configuração da roleta antes e depois da realização do processo de interação social.

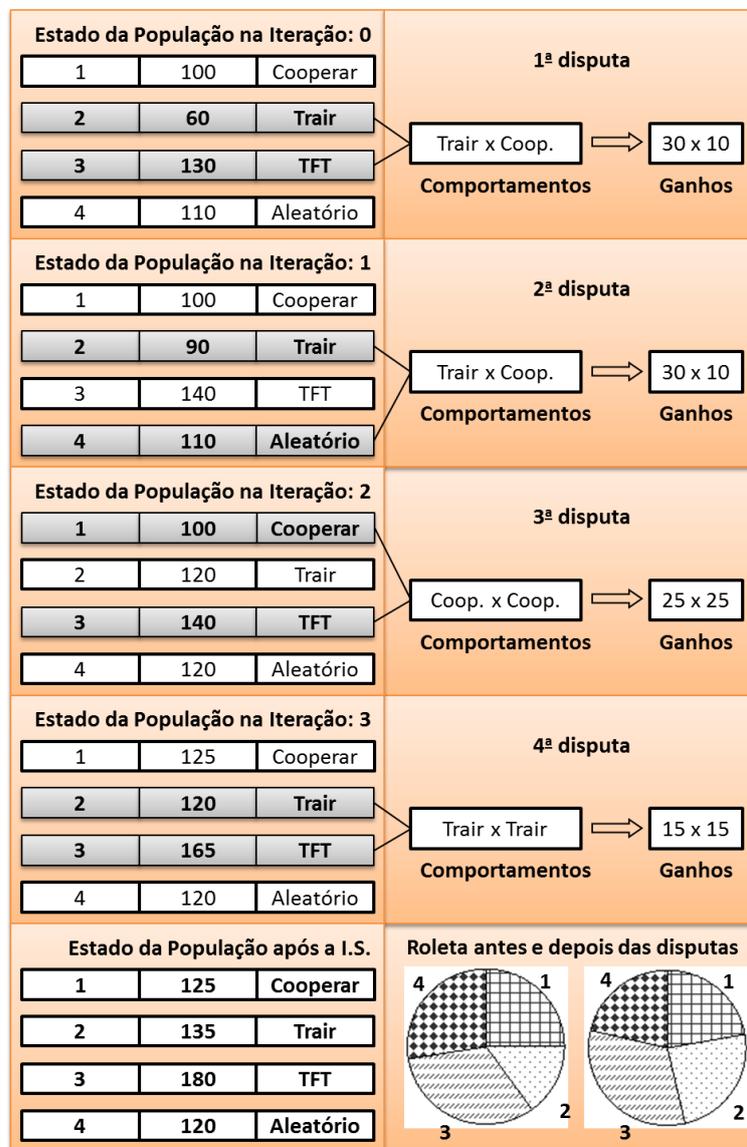


Figura 2.7 – Simulação do método  $DPR_{(r=1)}$ .

A distribuição das porções da roleta sofreram alterações para todos os quatro indivíduos e no gráfico 2.1 é possível visualizar os seus processos evolutivos durante a realização das disputas, em relação à aptidão proporcional em cada disputa.

O mais importante a se observar na evolução dos indivíduos é que cada um deles sofreu influência desse processo de formas diferentes, mas com o mesmo objetivo:

tornarem-se mais adaptados na tentativa de aumentar as suas chances de seleção para participação no processo de reprodução.

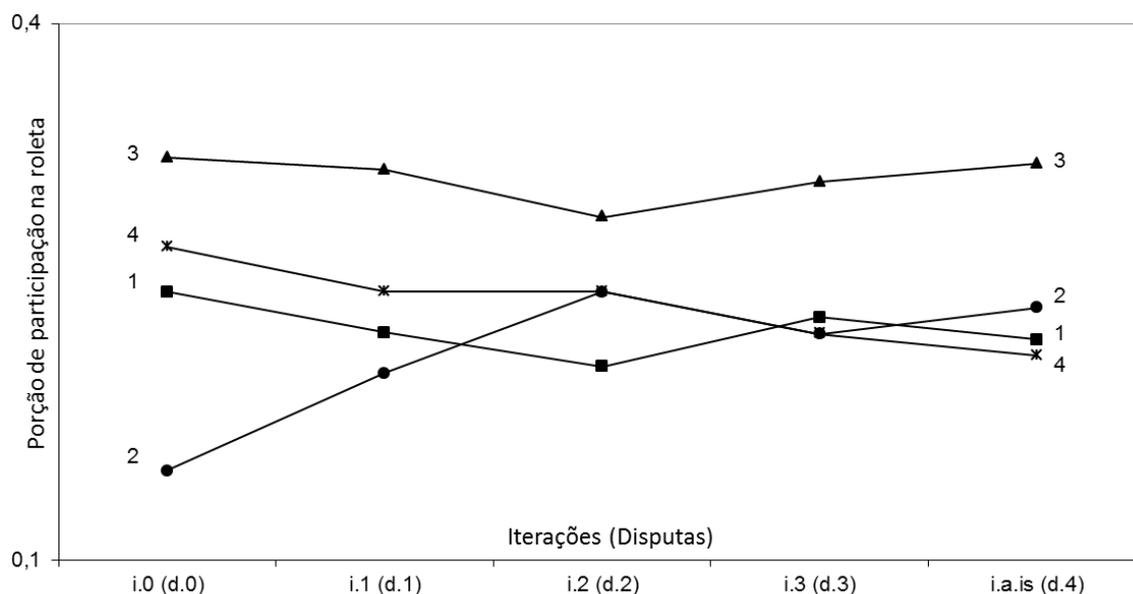


Gráfico 2.1 – Evolução dos indivíduos no processo de interação social do  $DPR_{(r=1)}$ .

Na tabela 2.1, por exemplo, os indivíduos dois e quatro são os que sofreram as maiores mudanças, onde o dois aumentou a sua participação na roleta em 9%, enquanto que o quatro diminuiu a sua porção em 6%. O indivíduo um diminuiu em 3% e o indivíduo três manteve estável a sua participação em 32% do total da roleta.

Tabela 2.1 – Distribuição da roleta antes e depois da interação social via  $DPR_{(r=1)}$

Indivíduo	Fitness (i.0)	Fitness (i.a.IS)	% antes	% depois	Avaliação
1	100	125	25,0 %	22,3 %	↓
2	060	135	15,0 %	24,1 %	↑
3	130	180	32,5 %	32,2 %	↑↓
4	110	120	27,5 %	21,4 %	↓
<b>Totais</b>	<b>400</b>	<b>560</b>	<b>100,0 %</b>	<b>100,0 %</b>	-

#### b. $DPR_{(r>1)}$

Esta simulação considera que as disputas entre os indivíduos é composta por quatro rodadas, por isso  $r > 1$ . Dessa forma, são totalizadas quatro disputas com quatro rodadas cada, conforme pode ser visto na figura 2.8.

Além disso, são cinco iterações da população, onde a iteração zero é constituída pela população inicial, definida na figura 2.6, e as outras quatro iterações (1, 2, 3 e após I.S.) são resultado dessas disputas a partir da seleção aleatória dos seus participantes. Foram utilizados nas disputas os mesmos indivíduos da simulação anterior.

Na primeira disputa os indivíduos **dois** e **três** foram selecionados e as suas respectivas estratégias de comportamento foram obtidas, ou seja, **Sempre Trair** e **TFT**. Assim é configurado o confronto “Trair” vs “Cooperar”, pois é o primeiro encontro entre eles e, assim, o indivíduo age cooperativamente. Como consequência os indivíduos obtêm valores de ganho iguais a 30 e 10 unidades de valor respectivamente.

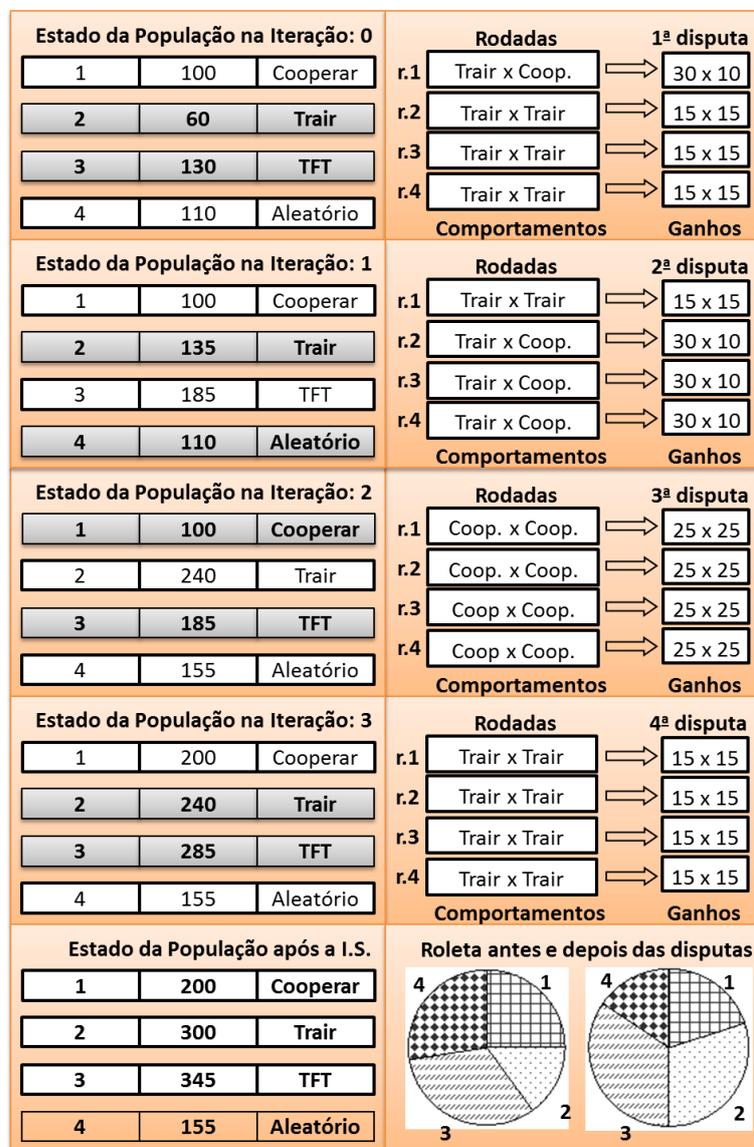


Figura 2.8 – Simulação do método  $DPR_{(r>1)}$ .

A partir da segunda rodada é configurado o confronto “Trair” vs “Trair” e, assim, desta até a última rodada cada um dos indivíduos obtêm valores de ganho iguais a 15 unidades de valor em cada uma das três rodadas. Ao final a somatória desses valores é adicionada às suas aptidões que são atualizadas, conforme pode ser visto na configuração do estado da população na iteração um, onde o indivíduo dois passa a ter uma aptidão igual a 135 e o indivíduo três igual a 185.

Dessa forma, o processo continua com a realização das disputas entre os indivíduos selecionados até a geração da quinta iteração, que apresenta o estado da população após a realização do processo de interação social. Na parte inferior direita da figura 2.8 é apresentada, através de um gráfico em formato de pizza, a configuração da roleta antes e depois da realização do processo de interação social.

A distribuição das porções da roleta sofreram alterações para todos os quatro indivíduos e na gráfico 2.2 é possível visualizar o processo evolutivo dos quatro indivíduos durante a realização das quatro disputas com quatro rodadas cada, em relação ao valor de *fitness* proporcional em cada disputa.

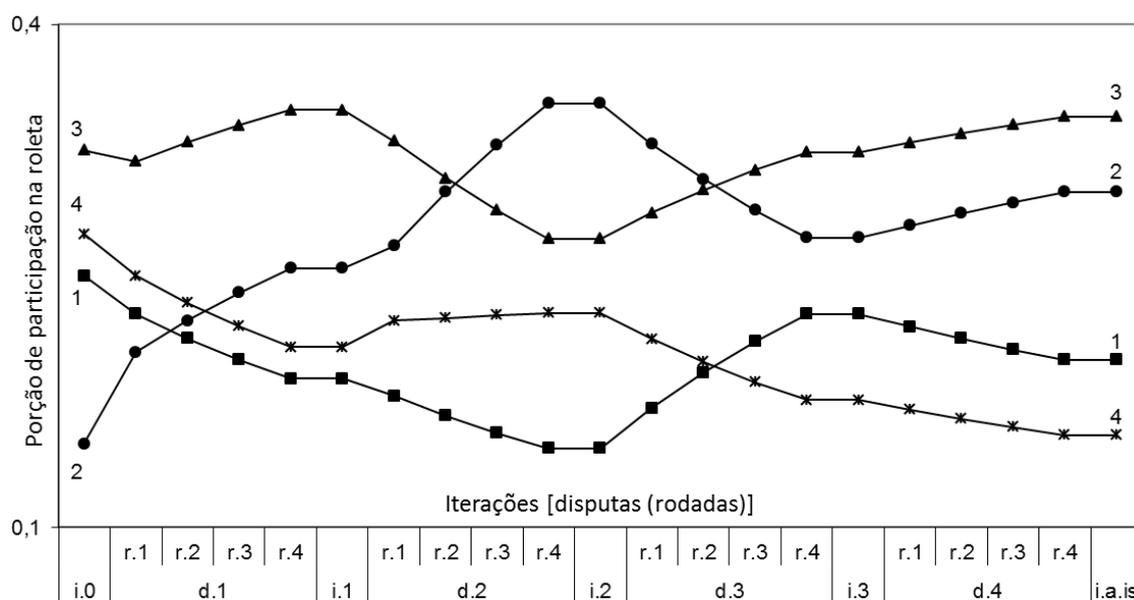


Gráfico 2.2 – Evolução dos indivíduos no processo de interação social do  $DPR_{(r>1)}$ .

O mais importante a se observar na evolução dos indivíduos é que cada um deles sofreu influência desse processo de formas diferentes, mas com o mesmo objetivo:

tornarem-se mais adaptados na tentativa de aumentar as suas chances de seleção para participação no processo de reprodução.

Na tabela 2.2, por exemplo, os indivíduos dois e quatro são os que sofreram as maiores mudanças, onde o dois dobrou a sua participação na roleta, pois foi de 15% a 30%, enquanto que o quatro diminuiu a sua porção em 12%. O indivíduo um diminuiu em 5% e o indivíduo três obteve um aumento de apenas 2% em sua participação na roleta.

Tabela 2.2 – Distribuição da roleta antes e depois da interação social via  $DPR_{(r>1)}$

<b>Indivíduo</b>	<b>Fitness (i.0)</b>	<b>Fitness (i.a. IS)</b>	<b>% antes</b>	<b>% depois</b>	<b>Avaliação</b>
1	100	200	25,0 %	20,0 %	↓
2	060	300	15,0 %	30,0 %	↑↑
3	130	345	32,5 %	34,5 %	↑
4	110	155	27,5 %	15,5 %	↓↓
<b>Totais</b>	<b>400</b>	<b>1000</b>	<b>100,0 %</b>	<b>100,0 %</b>	<b>-</b>

### 2.3.2. Dilema do Prisioneiro Torneio (DPT)

Este método está também baseado na estrutura do pseudocódigo do SIGA, apresentado na figura 2.3. As suas únicas diferenças são: (1) a inserção de um novo passo 4.2, destinado à realização do torneio após o término do processo de interação social, com o uso do  $Fitness_{Total}$  de cada um dos indivíduos; e, assim, (2) no passo 4.3.1, a seleção dos indivíduos é realizada a partir do resultado dos torneios (*mating pool*), conforme pode ser visto em destaque na figura 2.9. A parte anterior e posterior do pseudocódigo para os métodos Dilema do Prisioneiro Torneio são compostos exatamente dos mesmos passos.

O passo 4.2 que nos métodos DPR era responsável pela montagem da roleta, passa agora a ser composto por uma laço de repetição. Nele são selecionados aleatoriamente  $p$  pais para a disputa de um torneio, caracterizado pela simples comparação dos seus valores de  $Fitness_{Total}$ . E, assim, o indivíduo que possuir o melhor valor – maior ou menor, o que depende do problema a ser solucionado – é armazenado na área de cruzamento (*mating pool*). Os torneios são realizados enquanto a quantidade de indivíduos na área de cruzamento for diferente do total de indivíduos da população.

E no processo de reprodução, ao invés dos indivíduos serem selecionados com base na roleta montada, eles são selecionados aleatoriamente a partir da área de cruzamento (passo 4.3.1).

```

...
// Processo de Interação Social
  4.1. Repetir até d disputas:
    4.1.1. Selecionar dois indivíduos aleatoriamente;
    4.1.2. Repetir até r rodadas:
      4.1.2.1. Obter o comportamento de cada um dos indivíduos;
      4.1.2.2. Alterar a adaptabilidade dos indivíduos conforme o
        comportamento adotado por cada um, e a tabela de
        pagamentos do jogo;

// Método Torneio
  4.2. Repetir até p pais:
    4.2.1. Selecionar dois indivíduos aleatoriamente;
    4.2.2. Comparar o valor de fitness dos indivíduos selecionados no
      passo anterior;
    4.2.3. Selecionar o indivíduo de maior valor de fitness e armazená-
      lo na mating pool;

// Processo de Reprodução
  4.3. Repetir até o número de descendentes ser igual à quantidade desejada
    (% de cruzamento)
    4.3.1. Selecionar da mating pool dois indivíduos aleatoriamente;
...

```

Figura 2.9 – Parte do pseudocódigo do método DPT.

Para exemplificar o funcionamento dos métodos DPT foram utilizadas as mesmas configurações das simulações realizadas com os métodos DPR, sendo assim: (1) são descritas cinco iterações da população, onde a iteração zero é constituída pela população inicial, definida na figura 2.6, e as outras quatro iterações (1, 2, 3 e após I.S.) são resultado das disputas a partir da seleção aleatória dos seus participantes; (2) foram utilizados os mesmos indivíduos nas disputas.

Além disso, é importante observar que a única diferença entre os métodos DPR e DPT é o método de seleção utilizado para escolher os indivíduos que participarão do processo de reprodução, pois no primeiro é utilizada a roleta, enquanto no segundo os indivíduos são selecionados a partir da área de cruzamento após terem participado dos torneios.

Como consequência, os resultados obtidos no processo de interação social nas duas simulações a seguir são exatamente iguais aos resultados obtidos nas simulações dos métodos DPR. No entanto, é interessante visualizar como ocorre a integração com o método de seleção por torneio.

a.  $DPT_{(r=1)}$

Esta simulação considera que as disputas entre os indivíduos é composta por apenas uma única rodada, por isso  $r = 1$ . Dessa forma, são totalizadas quatro disputas com uma rodada cada, conforme pode ser visto na figura 2.10.

Na primeira disputa os indivíduos **dois** e **três** foram selecionados e as suas respectivas estratégias de comportamento foram obtidas, ou seja, **Sempre Trair** e **TFT**. Assim é configurado o confronto “Trair” vs “Cooperar”, pois é o primeiro encontro entre eles e, assim, o indivíduo age cooperativamente.

Como consequência os indivíduos obtêm valores de ganho iguais a 30 e 10 unidades de valores respectivamente. Estes valores são adicionados às suas aptidões e atualizados, conforme pode ser visto na configuração do estado da população na iteração um, onde o indivíduo dois passa a ter uma aptidão igual a 90 e o indivíduo três igual a 140.

Na sequência são realizados os torneios, a partir de indivíduos selecionados aleatoriamente. Para facilitar a simulação foram utilizados em cada uma das iterações os mesmos indivíduos para participarem dos torneios, conforme pode ser observado na figura 2.10. Nesse caso, aqueles indivíduos com maiores valores de *fitness* são selecionados para a área de cruzamento.

Dessa forma, o processo continua com a realização das disputas e dos torneios até a geração da quinta iteração, que apresenta o estado da população após a realização do processo de interação social e dos torneios.

E na parte inferior direita da figura 2.10, conforme destacado, é apresentada a alternância dos indivíduos que compõem a área de cruzamento, onde **i.0[s/d(s/t)]** significa

iteração 0, sem disputas e sem torneios; **i.1[d.1(t.1)]** significa iteração 1, após a realização da 1ª disputa e do 1º torneio, composta pelos indivíduos 3, 4, 3 e 1; depois da segunda e terceira iterações está a configuração **i.a.is [d.4(t.4)]** que significa a iteração após a realização da interação social após a 4ª disputa e do 4º torneio, composta pelos indivíduos 3, 1, 3 e 2.

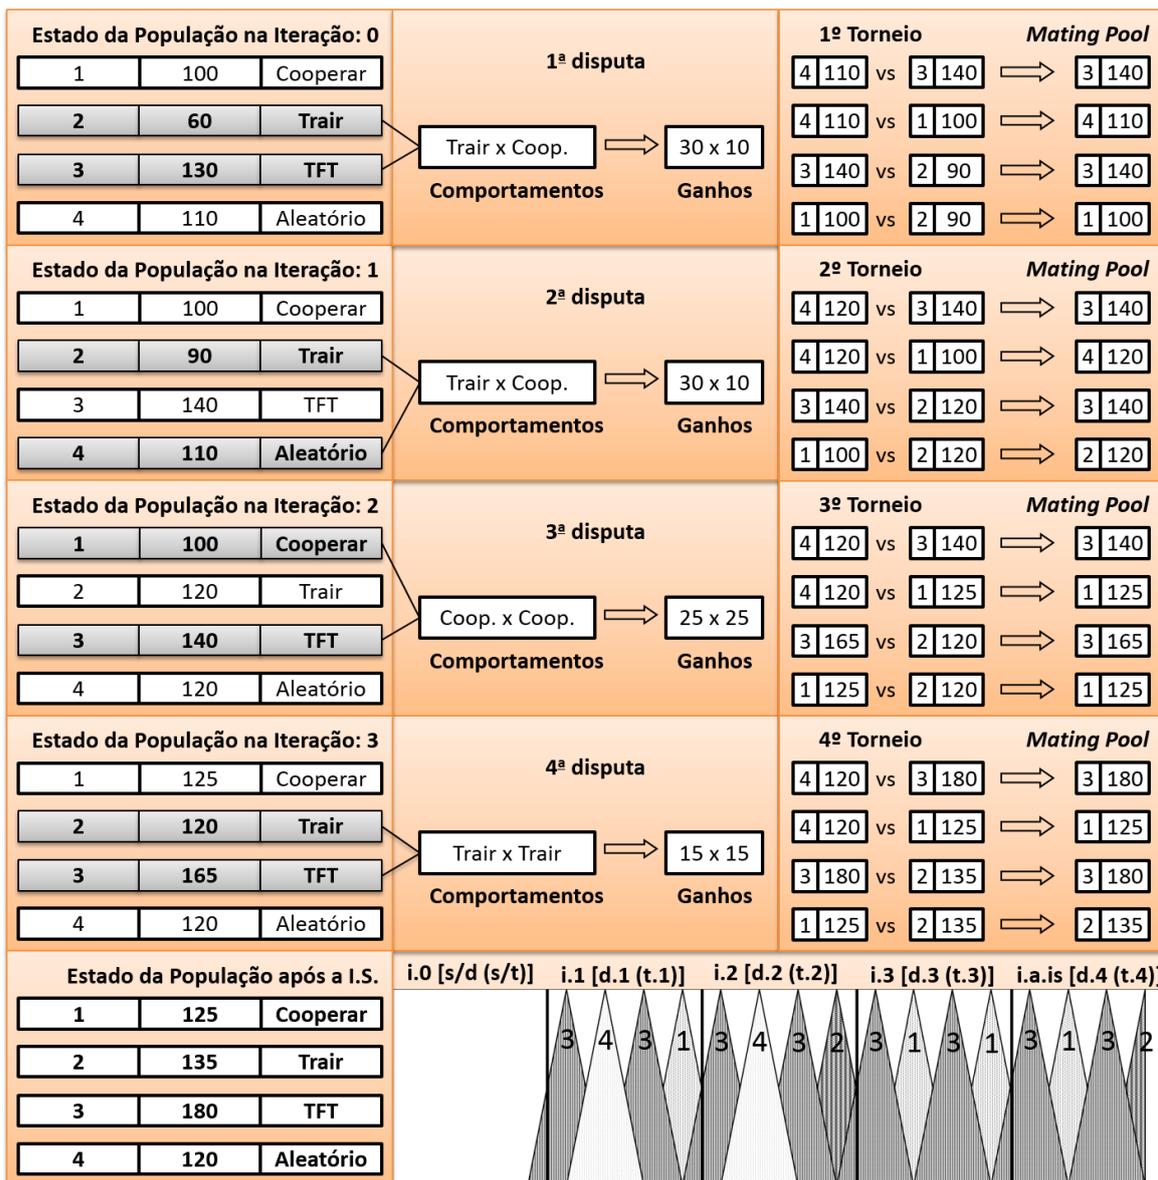


Figura 2.10 – Simulação do método  $DPT_{(r=1)}$ .

A distribuição das porções de participação de cada um dos quatro indivíduos no total da população, assim como a evolução de cada um no decorrer da realização dos

torneios são apresentados na gráfico 2.3. Nela é possível verificar a manutenção do indivíduo três como o portador da maior adaptabilidade, antes e depois da realização desses processos, enquanto que os indivíduos dois e quatro sofreram as maiores mudanças.

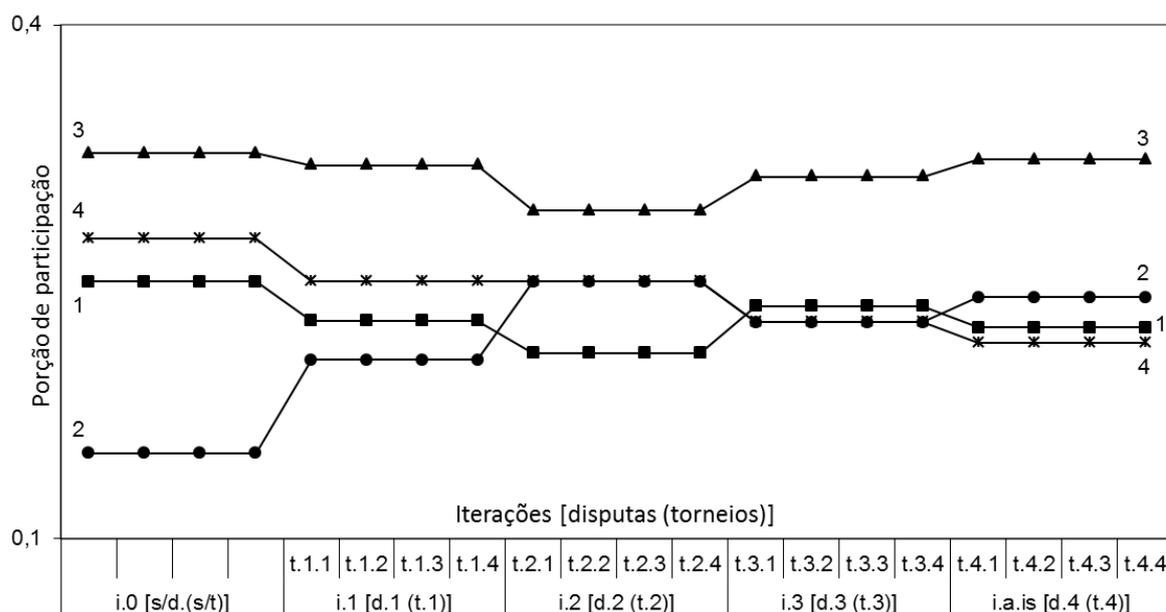


Gráfico 2.3 – Evolução dos indivíduos no processo de interação social do  $DPT_{(r=1)}$ .

O mais importante a se observar na evolução dos indivíduos é que cada um deles sofreu influência desse processo de formas diferentes, mas com o mesmo objetivo: tornarem-se mais adaptados na tentativa de aumentar as suas chances de seleção para participação no processo de reprodução.

Na tabela 2.3, por exemplo, o indivíduo dois sofreu a maior mudança, de forma que a sua participação proporcional subiu 9%, enquanto que os demais indivíduos obtiveram diminuições pequenas variando de menos de 1% a 6%.

Tabela 2.3 – Distribuição da roleta antes e depois da interação social via  $DPT_{(r=1)}$

Indivíduo	Fitness (i.0)	Fitness (i.a.IS)	% antes	% depois	Avaliação
1	100	125	25,0 %	22,3 %	↓
2	060	135	15,0 %	24,1 %	↑
3	130	180	32,5 %	32,2 %	↑↓
4	110	120	27,5 %	21,4 %	↓
<b>Totais</b>	<b>400</b>	<b>560</b>	<b>100,0 %</b>	<b>100,0 %</b>	-

b.  $DPT_{(r>1)}$

Esta simulação considera que as disputas entre os indivíduos é composta por quatro rodadas, por isso  $r > 1$ . Dessa forma, são totalizadas quatro disputas com quatro rodadas cada, conforme pode ser visto na figura 2.11.

Na primeira disputa os indivíduos **dois** e **três** foram selecionados e as suas respectivas estratégias de comportamento foram obtidas, ou seja, **Sempre Trair** e **TFT**. Assim é configurado o confronto “Trair” vs “Cooperar”, pois é o primeiro encontro entre eles e, assim, o indivíduo age cooperativamente.

Como consequência os indivíduos obtêm valores de ganho iguais a 30 e 10 unidades de valores respectivamente. Nas três rodadas seguintes, o indivíduo três passa a trair também, devido a sua estratégia TFT, o que configura uma traição mútua, logo eles obtêm ganhos iguais a 15 unidades de valor. A soma desses valores é adicionada às aptidões de cada um dos indivíduos, conforme pode ser visto na configuração do estado da população na iteração um, onde o indivíduo dois passa a ter uma aptidão igual a 135 e o indivíduo três igual a 185.

Na sequência são realizados os torneios, a partir de indivíduos selecionados aleatoriamente. Para facilitar a simulação foram utilizados em cada uma das iterações os mesmos indivíduos para participarem dos torneios, conforme pode ser observado na figura 2.11. Nesse caso, aqueles indivíduos com maiores valores de *fitness* são selecionados para a área de cruzamento.

Dessa forma, o processo continua com a realização das disputas e dos torneios até a geração da quinta iteração, que apresenta o estado da população após a realização do processo de interação social e dos torneios.

E na parte inferior direita da figura 2.11, conforme destacado, é apresentada a alternância dos indivíduos que compõem a área de cruzamento, onde **i.0[s/d(s/t)]** significa iteração 0, sem disputas e sem torneios; **i.1[d.1(t.1)]** significa iteração 1, após a realização da 1ª disputa e do 1º torneio, composta pelos indivíduos 3, 4, 3 e 2; depois da segunda e terceiras iterações está a configuração **i.a.is [d.4(t.4)]** que significa a iteração após a

realização da interação social após a 4ª disputa e do 4º torneio, composta pelos indivíduos 3, 1, 3 e 2.

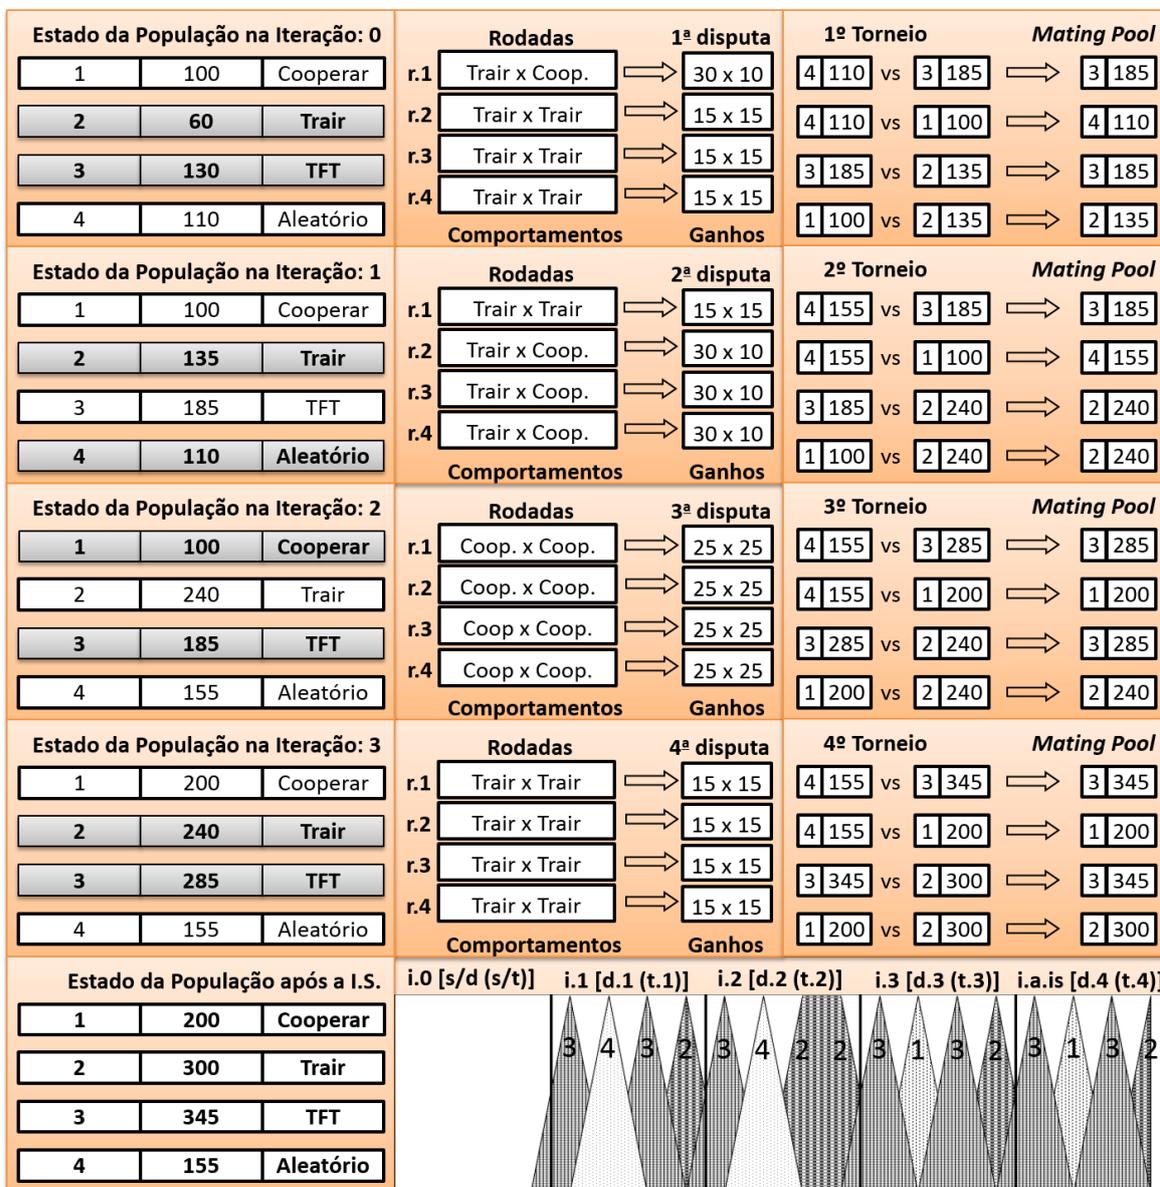


Figura 2.11 – Simulação do método  $DPR_{(r>1)}$ .

A distribuição das porções de participação de cada um dos quatro indivíduos no total da população, assim como a evolução de cada um no decorrer da realização dos torneios são apresentados na gráfico 2.4. Nela é possível verificar a manutenção do indivíduo três como o portador da maior adaptabilidade, antes e depois da realização desses processos, enquanto que os indivíduos dois e quatro sofreram as maiores mudanças.

O mais importante a se observar na evolução dos indivíduos é que cada um deles sofreu influência desse processo de formas diferentes, mas com o mesmo objetivo: tornarem-se mais adaptados na tentativa de aumentar as suas chances de seleção para participação no processo de reprodução.

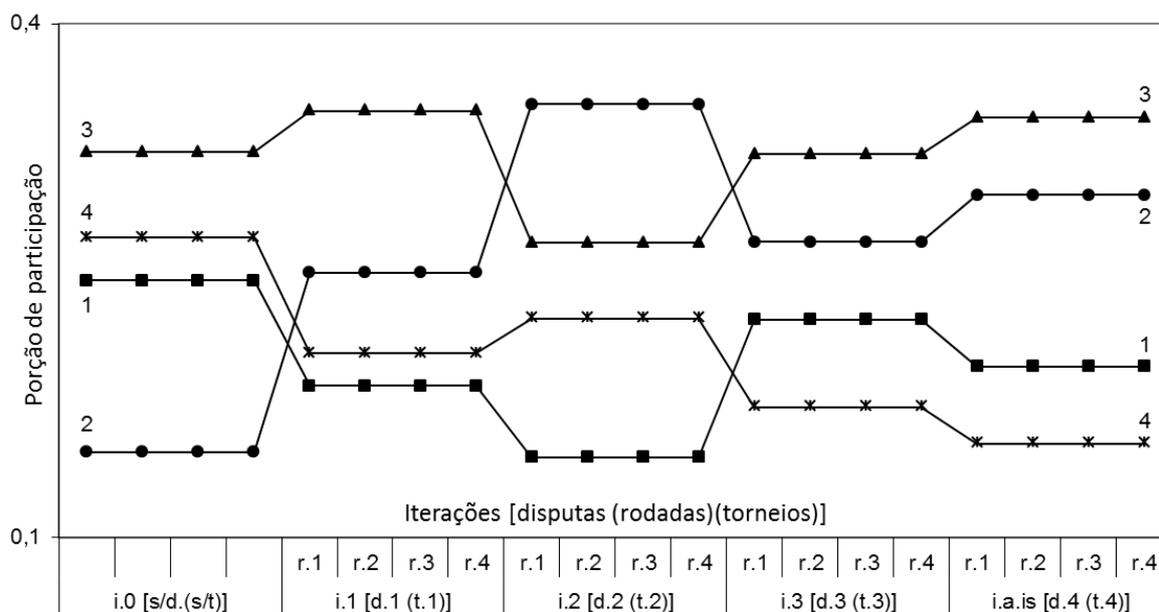


Gráfico 2.4 – Evolução dos indivíduos no processo de interação social do  $DPR_{(r>1)}$ .

Na tabela 2.4 é possível visualizar, por exemplo, os indivíduo dois e quatro são os que sofreram as maiores mudanças, onde o dois dobrou a sua participação, pois foi de 15% a 30%, enquanto que o quatro diminuiu a sua porção em 12%. O indivíduo um diminuiu em 5% e o indivíduo três obteve um aumento de apenas 2% em sua participação na roleta.

Tabela 2.4 – Distribuição das participações antes e depois da interação social via  $DPT_{(r>1)}$

Indivíduo	Fitness (i.0)	Fitness (i.5)	% antes	% depois	Avaliação
1	100	200	25,0 %	20,0 %	↓
2	060	300	15,0 %	30,0 %	↑↑
3	130	345	32,5 %	34,5 %	↑
4	110	155	27,5 %	15,5 %	↓↓
<b>Totais</b>	<b>400</b>	<b>1000</b>	<b>100,0 %</b>	<b>100,0 %</b>	-

É importante observar, após a realização dessas quatro simulações, a possibilidade de se aplicar outros métodos de seleção na estrutura do algoritmo SIGA, que são tão conhecidos ou até mesmo melhores do que os dois utilizados nessa exemplificação, tais

como: seleção por *rank*, por estado estacionário, por truncamento, entre outros (GOLDBERG, 1989; HAUPT e HAUPT, 2004). Isso além da possibilidade de aplicação de diferentes tipos de jogos também.

## 2.4. ALGORITMO NpSIGA

O **Algoritmo Genético com Interação Social N-Pessoas**<sup>21</sup> surge com a pretensão de se verificar o funcionamento do jogo Dilema do Prisioneiro com N-Pessoas aplicado ao contexto dos Algoritmos Genéticos. Além disso, possibilitar uma maior aproximação do modelo encontrado na natureza, pois a interação social entre humanos, por exemplo, não ocorre sempre e somente entre dois indivíduos, mas frequentemente em grupos com mais de dois indivíduos.

Dessa forma, o algoritmo NpSIGA utiliza a mesma estrutura do algoritmo SIGA, figura 2.3, no entanto as principais diferenças são: (1) a possibilidade de ser definida a quantidade (*i*) de indivíduos que serão selecionados para participar, ao mesmo tempo, do processo de interação social, através das disputas com um ou várias rodadas. E além disso, os ganhos obtidos nas interações com os outros indivíduos são atribuídos não mais pela tabela de pagamentos, mas sim, por duas funções de pagamento, conforme pode ser visto ao final da seção B.4, do anexo B, nas equações (77) e (78).

...
<i>// Processo de Interação Social</i>
4.1. Repetir até <i>d</i> disputas
4.1.1. Selecionar <i>i</i> indivíduos aleatoriamente, onde: $(i \subset N_j)$ ;
4.1.2. Repetir até <i>r</i> rodadas
a. Obter o comportamento de cada um dos indivíduos, a partir de suas estratégias de comportamento
b. Alterar as suas adaptabilidades, com base nos seus comportamentos e nas funções de pagamentos do jogo
...

Figura 2.12 – Parte do pseudocódigo do algoritmo NpSIGA.

<sup>21</sup> Em inglês: *N-Person Social Interaction Genetic Algorithm (NpSIGA)*.

Como forma de exemplificar o funcionamento do algoritmo NpSIGA, na figura 2.13 estão definidos os parâmetros necessários para a realização de uma simulação. Dessa forma, tem-se: (1) uma população inicial com dez indivíduos ( $N_j$ ), sendo estes compostos por: cromossomo, aptidão e estratégia de comportamento; (2) os recursos do jogo baseado nos valores dos parâmetros  $T = 30$  e  $R = 25$ , e nas funções de pagamento para a versão N-pessoas do Dilema do Prisioneiro; (3) quantidade de indivíduos em cada disputa ( $i = 6$ ); (4) a Taxa de Tolerância<sup>22</sup> ( $T.T = 35\%$ ); e, (5) a quantidade de disputas ( $d = 6$ ).

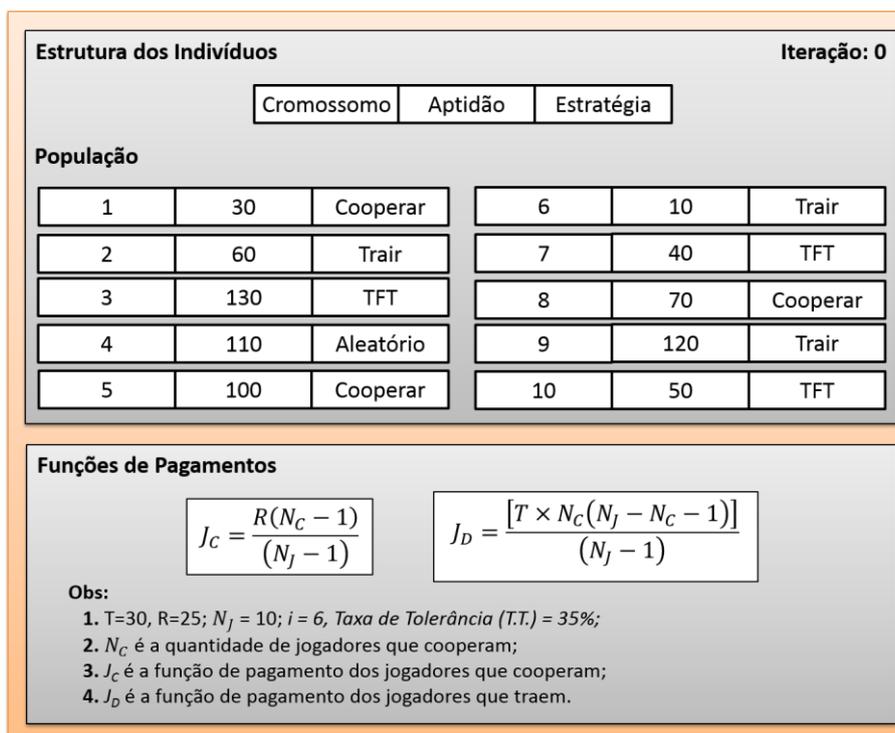


Figura 2.13 – Parâmetros para exemplificação do algoritmo NpSIGA.

<sup>22</sup> A **Taxa de Tolerância** ( $T.T.$ ) é utilizada pelos jogadores que possuem a estratégia TFT. Com base nesse fator é que definem o seu comportamento, cooperar ou trair, perante aos demais jogadores durante uma disputa, conforme pode ser visto na equação (2).

$$Comportamento_{jogador\_TFT} = \begin{cases} Cooperar, & \left(\frac{N_D}{N_J}\right) \leq T.T. \\ Trair, & \left(\frac{N_D}{N_J}\right) > T.T. \end{cases} \quad (2)$$

Onde:  $N_j$  é a quantidade de jogadores;  $N_D$  é a quantidade de jogadores traidores;  $N_C$  é a quantidade de jogadores cooperadores.

Na realização da primeira disputa foram selecionados aleatoriamente os indivíduos **dois, quatro, cinco, oito, nove e dez**, conforme em destaque no “estado da população na iteração: 0”. Dentre eles, apenas dois apresentam o comportamento trair. Logo a porcentagem de jogadores traidores ( $\% N_D$ ) é igual a 33,3 %, que é menor do que a *T.T.* Assim, o único jogador TFT decide pelo comportamento cooperar.

Na sequência, os valores de ganhos desses seis indivíduos são calculados a partir das funções de pagamento e as suas aptidões atualizadas, conforme pode ser visto no “estado da população após a 1ª disputa”, na figura 2.14.

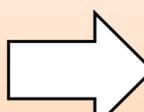
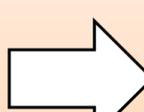
Estado da População na Iteração: 0			Comp.	Ganhos	 $N_C = 4$ $N_D = 2$ Antes de TFT decidir: $\% N_D = 33,3\% < T.T.$ Logo, $TFT = C$	Estado da População após 1ª disputa		
1	30,0	Cooperar	-	⇒ 0,0			1	30,0
2	60,0	Trair	T	⇒ 66,7		2	126,7	Trair
3	130,0	TFT	-	⇒ 0,0		3	130,0	TFT
4	110,0	Aleatório	C	⇒ 8,3		4	118,3	Aleatório
5	100,0	Cooperar	C	⇒ 8,3		5	108,3	Cooperar
6	10,0	Trair	-	⇒ 0,0		6	10,0	Trair
7	40,0	TFT	-	⇒ 0,0		7	40,0	TFT
8	70,0	Cooperar	C	⇒ 8,3		8	78,3	Cooperar
9	120,0	Trair	T	⇒ 66,7		9	186,7	Trair
10	50,0	TFT	C	⇒ 8,3		10	58,3	TFT
Estado da População na Iteração: 1			Comp.	Ganhos	 $N_C = 1$ $N_D = 5$ Antes de TFT decidir: $\% N_D = 50,0\% > T.T.$ Logo, $TFT = T$	Estado da População após 2ª disputa		
1	30,0	Cooperar	-	⇒ 0,0			1	30,0
2	126,7	Trair	T	⇒ 26,7		2	153,3	Trair
3	130,0	TFT	-	⇒ 0,0		3	130,0	TFT
4	118,3	Aleatório	T	⇒ 26,7		4	145,0	Aleatório
5	108,3	Cooperar	-	⇒ 0,0		5	108,3	Cooperar
6	10,0	Trair	-	⇒ 0,0		6	10,0	Trair
7	40,0	TFT	T	⇒ 26,7		7	66,7	TFT
8	78,3	Cooperar	C	⇒ 0,0		8	78,3	Cooperar
9	186,7	Trair	T	⇒ 26,7		9	213,3	Trair
10	58,3	TFT	T	⇒ 26,7		10	85,0	TFT

Figura 2.14 – Realização da iteração um e dois da simulação do algoritmo NpSIGA.

Na disputa seguinte foram selecionados os indivíduos **dois, quatro, sete, oito, nove e dez**. Dentre eles são dois com a estratégia trair; um aleatório, que escolheu o comportamento trair; um com a estratégia cooperar e os outros dois com a estratégia TFT.

Ao considerar os três comportamentos trair, a  $\% N_D$  é igual a 50%, logo é maior que a T.T. Dessa forma, os dois indivíduos TFT decidem pelo comportamento trair. E na sequência os seus ganhos são calculados e as suas aptidões atualizadas, conforme a figura 2.14.

Da mesma forma, as quatro disputas seguintes são realizadas conforme pode ser visto nas figuras 2.15 e 2.16. Em cada uma delas é possível visualizar a configuração antes e depois da aplicação do processo de interação social, a quantidade de jogadores traidores e cooperadores, a porcentagem de jogadores traidores e a sua relação com a taxa de tolerância, e a decisão dos jogadores TFT.

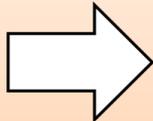
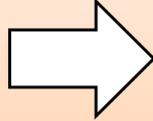
<b>Estado da População na Iteração: 2</b>			<b>Comp.</b>	<b>Ganhos</b>	 $N_c = 4$ $N_D = 2$ <b>Antes de TFT decidir:</b> $-\% N_D = 33,3\% < T.T.$ <b>Logo, TFT = C</b>	<b>Estado da População após 3ª disputa</b>		
1	30,0	Cooperar	C	⇒ 8,3		1	38,3	Cooperar
2	153,3	Trair	-	⇒ 0,0		2	153,3	Trair
3	130,0	TFT	C	⇒ 8,3		3	138,3	TFT
4	145,0	Aleatório	C	⇒ 8,3		4	153,3	Aleatório
5	108,3	Cooperar	-	⇒ 0,0		5	108,3	Cooperar
6	10,0	Trair	T	⇒ 66,7		6	76,7	Trair
7	66,7	TFT	-	⇒ 0,0		7	66,7	TFT
8	78,3	Cooperar	C	⇒ 8,3		8	86,7	Cooperar
9	213,3	Trair	T	⇒ 66,7		9	280,0	Trair
10	85,0	TFT	-	⇒ -	10	85,0	TFT	
<b>Estado da População na Iteração: 3</b>			<b>Comp.</b>	<b>Ganhos</b>	 $N_c = 5$ $N_D = 1$ <b>Antes de TFT decidir:</b> $-\% N_D = 16,7\% < T.T.$ <b>Logo, TFT = C</b>	<b>Estado da População após 4ª disputa</b>		
1	38,3	Cooperar	-	⇒ 0,0		1	38,3	Cooperar
2	153,3	Trair	-	⇒ 0,0		2	153,3	Trair
3	138,3	TFT	C	⇒ 11,1		3	149,4	TFT
4	153,3	Aleatório	T	⇒ 66,7		4	220,0	Aleatório
5	108,3	Cooperar	C	⇒ 11,1		5	119,4	Cooperar
6	76,7	Trair	-	⇒ 0,0		6	76,7	Trair
7	66,7	TFT	C	⇒ 11,1		7	77,8	TFT
8	86,7	Cooperar	C	⇒ 11,1		8	97,8	Cooperar
9	280,0	Trair	-	⇒ 0,0		9	280,0	Trair
10	85,0	TFT	C	⇒ 11,1	10	96,1	TFT	

Figura 2.15 – Realização da interação três e quatro da simulação do algoritmo NpSIGA.

Ao final do processo de interação social é possível observar a evolução da participação proporcional de cada um dos dez indivíduos, de acordo com os seus valores de aptidão/*fitness*, conforme o gráfico 2.5.

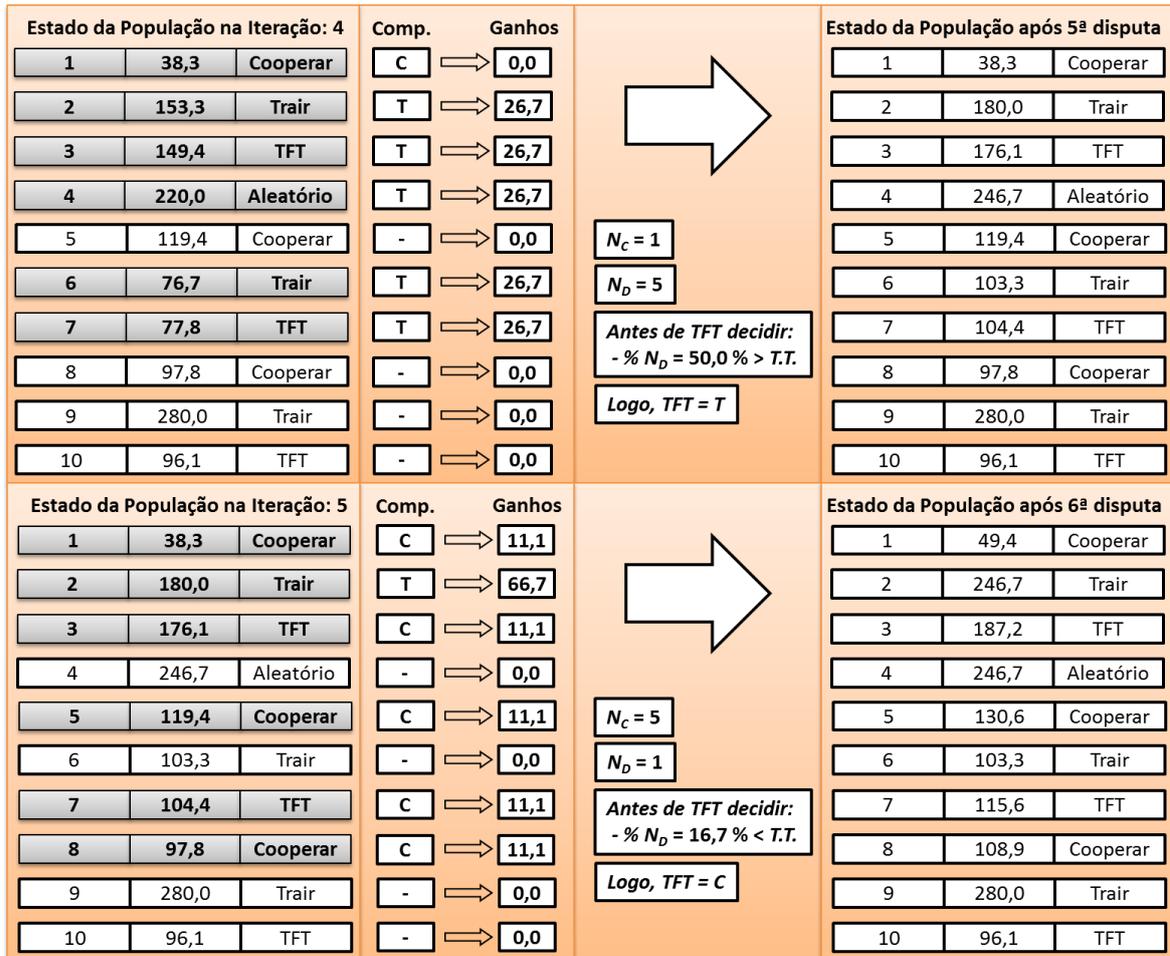


Figura 2.16 – Realização da iteração cinco da simulação do algoritmo NpSIGA.

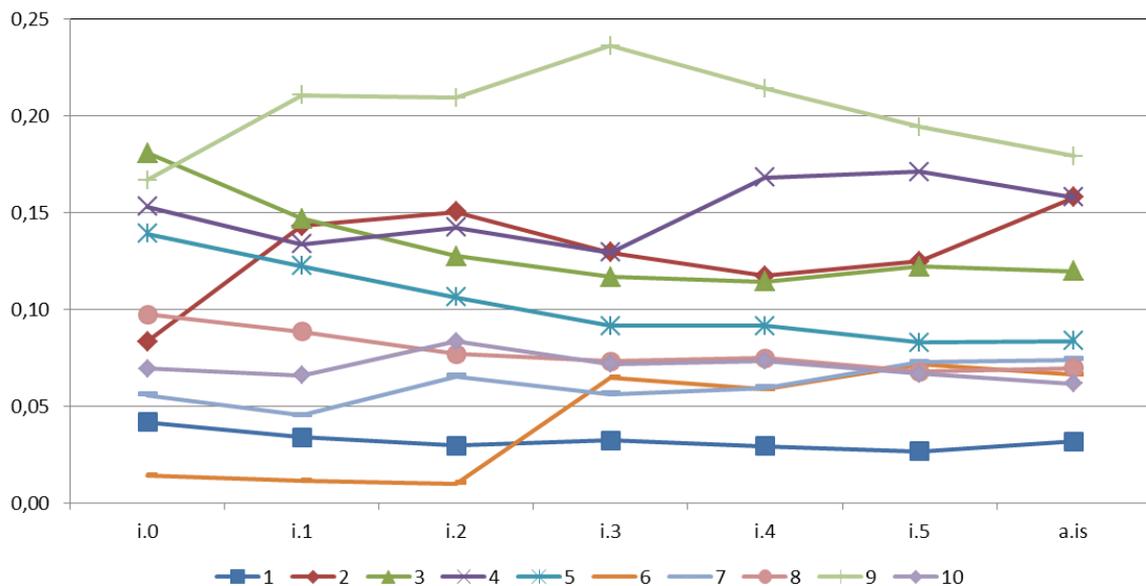


Gráfico 2.5 – Evolução dos indivíduos no processo de interação social do NpSIGA.

Na tabela 2.5 pode-se destacar, por exemplo, as evoluções dos indivíduos dois e seis, que passaram de 8% a 16% e 1% a 7%, respectivamente, em termos de participação proporcional. E, além disso, o valor da somatória dos valores de *fitness* quase dobrou com a realização do processo de interação social.

Tabela 2.5 – Distribuição das participações antes e depois da interação social via NpSIGA

<b>Indivíduo</b>	<b>Fitness (i.0)</b>	<b>Fitness (i.5)</b>	<b>% antes</b>	<b>% depois</b>	<b>Avaliação</b>
1	30,0	38,3	4 %	3 %	↓
2	60,0	180,0	8 %	16 %	↑↑
3	130,0	135,1	18 %	12 %	↓
4	110,0	137,8	15 %	16 %	↑
5	100,0	119,4	14 %	8 %	↓
6	10,0	103,3	1 %	7 %	↑↑↑
7	40,0	47,2	6 %	7 %	↑
8	70,0	97,8	10 %	7 %	↓
9	120,0	280,0	17 %	18 %	↑
10	50,0	55,1	7 %	6 %	↓
<b>Totais</b>	<b>720</b>	<b>1305,6</b>	<b>100,0 %</b>	<b>100,0 %</b>	-

Para os outros indivíduos esse processo não foi tão benéfico, pois sofreram pequenas variações em suas aptidões, positivas ou negativas, o que alterou as suas porções em termos de participação no total da somatória dos valores de *fitness*. Ao considerar o método de seleção roleta, por exemplo, é possível verificar mais claramente a influência sofrida pela população do processo de interação social, conforme o gráfico 2.6.

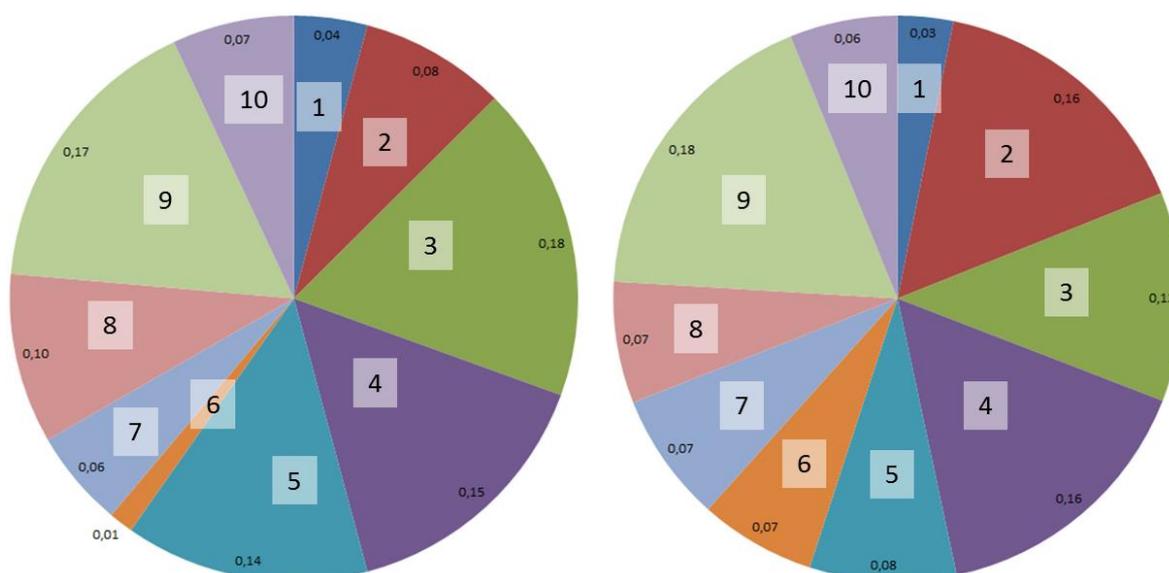


Gráfico 2.6 – Participação proporcional dos indivíduos antes e depois da interação social.

## 2.5. ALGORITMO F-SIGA

O **Algoritmo Genético com Interação Social Nebulosa**<sup>23</sup> surge como uma extensão do algoritmo SIGA, ao incorporar os conceitos referentes à Teoria dos Conjuntos e Sistemas Nebulosos (anexo C), mais especificamente nos dois comportamentos, cooperar e trair, presentes no Dilema do Prisioneiro. A seguir, na figura 2.17, é apresentada a sua estrutura e, em destaque os itens “a” e “b” que se diferenciam da estrutura do SIGA.

<ol style="list-style-type: none"> <li>1. Início;</li> <li>2. Gerar população inicial;</li> <li>3. Avaliar cada indivíduo da população inicial;</li> <li>4. Repetir até <math>m</math> gerações</li> </ol>
<p><b>// Processo de Interação Social Nebulosa</b></p> <ol style="list-style-type: none"> <li>4.1. Repetir até <math>d</math> disputas             <ol style="list-style-type: none"> <li>4.1.1. Selecionar aleatoriamente dois indivíduos;</li> <li>4.1.2. Repetir até <math>r</math> rodadas</li> </ol> </li> </ol>
<ol style="list-style-type: none"> <li>a. Para cada um dos indivíduos selecionados faça:             <ol style="list-style-type: none"> <li>a.1. Determinar os valores dos fatores <math>f_{q,j}^i</math>;</li> <li>a.2. Fuzzificação dos fatores <math>f_{q,j}^i</math>;</li> <li>a.3. Ativação das regras nebulosas que combinam com o fator (de acordo com a estratégia do jogador <math>S_{q,j}</math>);</li> <li>a.4. Geração da conclusão final a partir das conclusões parciais (<math>\mu_C^r, \mu_{DC}^r</math>);</li> <li>a.5. Desfuzzificação da conclusão final para determinar a ação <math>a_j^i</math> do jogador;</li> </ol> </li> <li>b. Alterar as suas adaptabilidades, com base nos seus comportamentos e na função de pagamentos do jogo</li> </ol>
<p><b>// Processo de reprodução</b></p> <ol style="list-style-type: none"> <li>4.2. Repetir até o número de descendentes ser igual à quantidade desejada (% de cruzamento)             <ol style="list-style-type: none"> <li>4.2.1. Selecionar dois indivíduos conforme o método de seleção;</li> <li>4.2.2. Realizar a operação de cruzamento nos indivíduos selecionados no passo anterior;</li> <li>4.2.3. Realizar a operação de mutação nos descendentes gerados no passo anterior;</li> <li>4.2.4. Avaliar os descendentes;</li> </ol> </li> <li>4.3. Substituir os indivíduos da população pelos novos indivíduos gerados na etapa de reprodução;</li> </ol> <ol style="list-style-type: none"> <li>5. O melhor indivíduo da população é a solução do problema;</li> <li>6. Fim.</li> </ol>

Figura 2.17 – Pseudocódigo do algoritmo F-SIGA

<sup>23</sup> Em inglês: *Fuzzy Social Interaction Genetic Algorithm (F-SIGA)*.

### 2.5.1. Abordagem Nebulosa do Dilema do Prisioneiro

Existem algumas abordagens nebulosas para o Dilema do Prisioneiro, tais como os trabalhos de BORGES (1996; 1997), SONG e KANDEL (1999), RAMAN (2002), MATHEW e KAIMAL (2003), e ARFI (2006). No entanto, a abordagem apresentada em BORGES (1996) foi tomada como base para a construção da proposta do F-SIGA.

Em seu trabalho, BORGES (1996) apresentou o **Dilema do Prisioneiro Iterado Nebuloso** (FIPD)<sup>24</sup>, que foi a primeira abordagem desenvolvida no sentido de integrar e aplicar o aspecto nebuloso ao contexto do jogo Dilema do Prisioneiro.

A principal diferença da sua abordagem em relação à versão clássica é o mapeamento do comportamento dos jogadores no intervalo  $[0, 1]$ , ou seja, variando da cooperação total (0) até a traição total (1), conforme o gráfico 2.7.

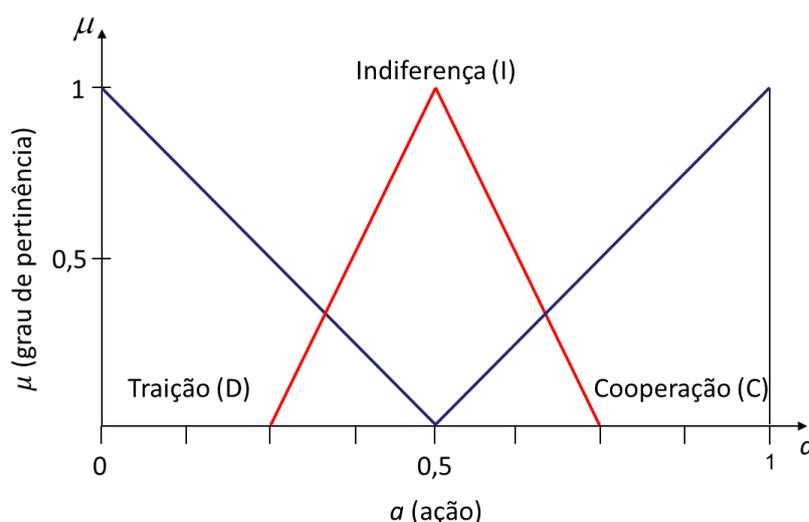


Gráfico 2.7 – Possíveis comportamentos dos indivíduos no FIPD.  
Fonte: BORGES (1996)

Dessa forma, o nível de cooperação/traição de um jogador é expresso através do grau de pertinência  $\mu_C(a)$  ou  $\mu_D(a)$  em um dos conjuntos definidos no universo de discurso de ação, que é a variável linguística considerada. Ele foi subdividido em dois conjuntos mutuamente exclusivos, **Traição (D)** e **Cooperação (C)**, expressos por funções

<sup>24</sup> Em inglês: *Fuzzy Iterated Prisoner's Dilemma (FIPD)*.

triangulares e com graus de pertinência de uma ação calculados a partir das equações (3) e (4), respectivamente. Ainda está definido o conjunto **Indiferença (I)**, que expressaria um comportamento de indiferença – “tanto faz!” – em relação à cooperação ou traição, porém não é considerado nesse estudo.

$$\mu_D(a) = \begin{cases} -2a + 1, & a \leq 0.5 \\ 0, & \text{caso contrário} \end{cases} \quad (3)$$

$$\mu_C(a) = \begin{cases} -2a - 1, & a \geq 0.5 \\ 0, & \text{caso contrário} \end{cases} \quad (4)$$

A partir dos graus de pertinência obtidos nessas equações pode-se calcular o valor da ação de cada um dos jogadores ( $a_j$ ), conforme expresso na equação (5).

$$a_j = \frac{\left( (1 - \mu_D(a)) \times \mu_D(a) + (1 - \mu_C(a)) \times \mu_C(a) \right)}{2(\mu_C + \mu_D)} \quad (5)$$

### 2.5.2. Função de Pagamento do Dilema do Prisioneiro Nebuloso

Em consequência à obtenção das ações dos jogadores é possível definir a função de pagamento do FIPD, que é a substituí à clássica tabela de pagamentos do Dilema do Prisioneiro, apresentada na tabela B.1. Ela é uma função linear de duas variáveis independentes ( $a_1$  e  $a_2$ ) e que o seu resultado gera o pagamento do jogador ( $j_1$ ) a partir da intercepção de dois planos, conforme destacado no gráfico 2.8.

Os valores de pagamento correspondem à combinação das ações extremas Cooperar (C) e Trair (D),  $\mu_C(a) = 1$  e  $\mu_D(a) = 0$ , e os valores de  $T=5$ ,  $R=3$ ,  $P=1$  e  $S=0$ , fixados e definidos arbitrariamente<sup>25</sup>. Sendo assim, os valores de ganhos dos dois jogadores podem ser obtidos através das equações (6) e (7), respectivamente.

---

<sup>25</sup> A função de pagamento é definida para quatro casos extremos: (1) os dois indivíduos cooperam; (2) um dos indivíduos coopera e o outro não; (3) o oposto de (2); e, (4) os dois indivíduos não cooperam.

$$p_{j_1} = \begin{cases} 1 - 2a_1 + 4a_2, & a_1 < a_2 \\ 1 - a_1 + 3a_2, & a_1 \geq a_2 \end{cases} \quad (6)$$

$$p_{j_2} = \begin{cases} 1 - 2a_2 + 4a_1, & a_2 < a_1 \\ 1 - a_2 + 3a_1, & a_2 \geq a_1 \end{cases} \quad (7)$$

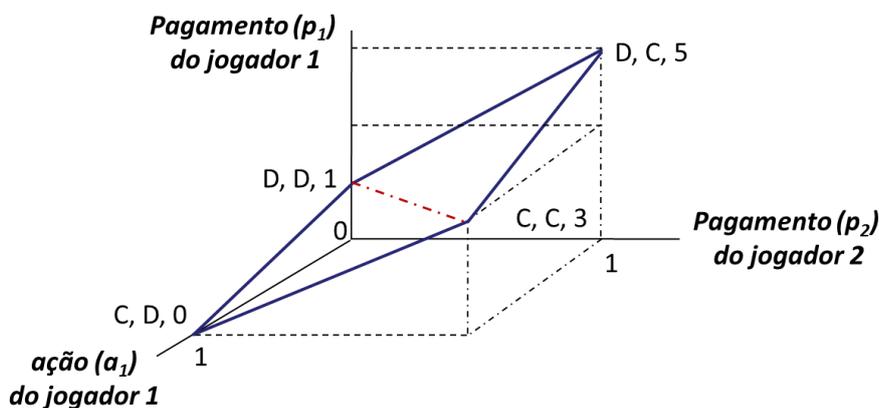


Gráfico 2.8 – Função de Pagamento do FIPD.  
Fonte: BORGES (1996)

### 2.5.3. Fatores de Decisão

Cada um dos jogadores é implementado como um sistema nebuloso, mais precisamente três, que são associados como entrada para um fator determinístico e, quando combinados, implicam na definição da ação dos jogadores.

Além disso, o universo de discurso de cada um dos fatores de entrada ( $f_1$ ,  $f_2$  e  $f_3$ ) é dividido em três conjuntos nebulosos e, assim, definem  $2^3 = 8$  diferentes estratégias. A quantidade total de estratégias para os três sistemas nebulosos é  $8^3 = 512$ , que corresponde às estratégias nebulosas. Dessa maneira, os jogadores definem e implementam

Na abordagem nebulosa, porém, é necessário que a função seja definida de forma contínua, uma vez que qualquer ponto no intervalo pode ser usado. E, definir funções contínuas que representem a função de pagamento é uma atividade complexa e que limita a capacidade de generalização da função.

Sendo assim, uma alternativa para este problema é o uso de técnicas de interpolação para obter um valor para determinado ponto baseado em outros pontos já conhecidos. E, no caso específico, a técnica de Interpolação Bilinear, que é uma interpolação linear, só que para funções de duas variáveis. (Nota importante: essa solução foi desenvolvida, porém não foi utilizada na produção dos testes e, respectivos, resultados do algoritmo aplicados aos problemas selecionados e, por essa razão, não está aqui expressa em detalhes).

qualitativamente as ações para o jogo, como as suas estratégias de comportamento. As suas ações são transformadas em valores numéricos e então aplicados como entrada nas funções de pagamento, apresentadas nas equações (6) e (7).

As estratégias dos jogadores foram modeladas a partir de três variáveis, os fatores de entrada, e denominados por BORGES (1996) de **Fatores de Decisão**, que são:

- $f_1$  é a relação entre o ganho acumulado do jogador em relação ao seu oponente;
- $f_2$  é baseado nas últimas iterações entre as partes;
- $f_3$  é a relação entre o ganho médio do jogador por iteração, com o ganho médio por iteração da população.

#### a. Fator $f_1$ : Relação entre as Riquezas Acumuladas

A criação do fator  $f_1$  é proveniente do jogo *Hawk-Dove* definido por SMITH (1980). Um dos seus elementos, denominado de *Resource Holding Power (RHP)*, mede a riqueza dos jogadores ( $w$ ), ou seja, a força, a quantidade de armas ou qualquer outro símbolo que represente poder de um indivíduo perante outros.

À medida que um jogador sabe que seu oponente possui uma riqueza mais elevada, ele tem a noção exata de que este fato pode influenciar nas suas decisões, e também nas decisões daquele que possui menos. Aquele que possui um fator  $f_1$  mais elevado pode ousar mais, sem se preocupar com eventuais perdas temporárias que possam ocorrer. Na equação (8) é considerada que a relação entre a riqueza de um jogador,  $w_1$ , e do seu oponente,  $w_2$ , com  $f_1 \in [0,1]$ ,  $\forall w_1, w_2$ .

$$f_1 = \frac{w_1}{w_1 + w_2} \quad (8)$$

Para o processo de fuzzificação do fator  $f_1$  são adotados três conjuntos nebulosos, que são: *Lower (LW)*, *Similar (SL)* e *Greater (GT)*, ou seja, quando o valor do fator for baixo, similar e alto, como no gráfico 2.9.

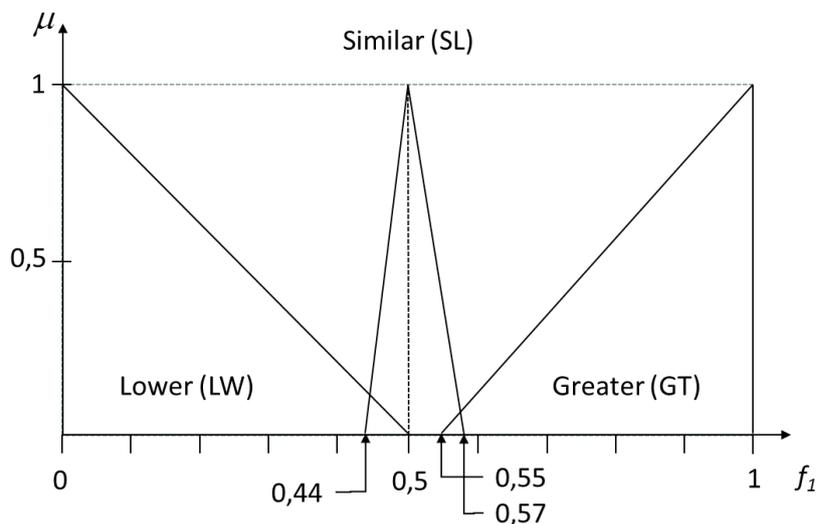


Gráfico 2.9 – Conjuntos nebulosos para o fator  $f_1$ .  
Fonte: BORGES (1996)

Nele é possível observar que os valores de LW e GT não se sobrepõem, e o conjunto SL possui uma interseção com ambos de forma assimétrica, pois os seus valores foram inicialmente definidos arbitrariamente, com início em  $f_1' = 0,44$  e fim em  $f_1'' = 0,57$ , para contemplar a assimetria encontrada usualmente na razão humana. Por razão similar o conjunto GT inicia em  $f_1' = 0,55$ . Sendo assim, o grau de pertinência para cada um dos conjuntos, LW, SL e GT, é dado respectivamente pelas equações (9), (10) e (11).

$$\mu_{LW}(f_1) = \begin{cases} -2f_1 + 1, & 0 \leq f_1 \leq 0,5 \\ 0, & \text{caso contrário} \end{cases} \quad (9)$$

$$\mu_{SL}(f_1) = \begin{cases} \frac{50}{3}f_1 - \frac{22}{3}, & 0,44 \leq f_1 \leq 0,5 \\ -\frac{100}{7}f_1 - \frac{57}{7}, & 0,5 \leq f_1 \leq 0,57 \\ 0, & \text{caso contrário} \end{cases} \quad (10)$$

$$\mu_{GT}(f_1) = \begin{cases} \frac{20}{9}f_1 - \frac{11}{9}, & 0,55 \leq f_1 \leq 1 \\ 0, & \text{caso contrário} \end{cases} \quad (11)$$

## b. Fator $f_2$ : Últimas Iterações entre os Jogadores

O fator  $f_2$  se refere ao histórico recente de disputas ocorrido entre dois jogadores. Ele está baseado na relação entre a média de ganho obtido no máximo nas últimas três iterações e no ganho máximo possível. Caso ainda não tenham ocorrido três iterações entre os jogadores, então uma das situações é empregada:

(1) se nenhuma iteração, equação (12);

$$f_2 = 0,4 \quad (12)$$

(2) se uma única iteração, equação (13);

$$f_2 = \frac{P_j^{t-1}}{5} \quad (13)$$

(3) se duas iterações, equação (14);

$$f_2 = 0,4 \times \frac{P_j^{t-2}}{5} + 0,6 \times \frac{P_j^{t-1}}{5} \quad (14)$$

(4) se três iterações, equação (15).

$$f_2 = 0,1 \times \frac{P_j^{t-3}}{5} + 0,3 \times \frac{P_j^{t-2}}{5} + 0,6 \times \frac{P_j^{t-1}}{5} \quad (15)$$

O termo  $\frac{P_j^{t-v}}{5}$  refere-se à relação entre o ganho obtido por um jogador  $j$  e o valor de ganho máximo possível em uma iteração prévia, onde  $v = 1, 2, 3$ .

Para o processo de fuzzificação do fator  $f_2$  também são utilizados três conjuntos nebulosos, que são: *Poor* (P), *Fair* (F) e *High* (H), ou seja, insignificante, justo e alto, pois referem-se aos ganhos obtidos. Os pontos  $f_2' = 0,2$  e  $f_2'' = 0,6$  foram determinados com um pagamento fixo de  $P_j = 1$  e  $P_j = 3$ , respectivamente. Esses valores correspondem à relação entre duas ações iguais dos jogadores na última iteração, ou seja, quando ocorre

Cooperar-Cooperar (CC) e Trair-Trair (DD). Já o ponto  $f_2 = 0,4$  foi calculado para  $P_j = 2$ , originado a partir de  $\mu_C(a) = \mu_D(a) = 0$  para os dois jogadores.

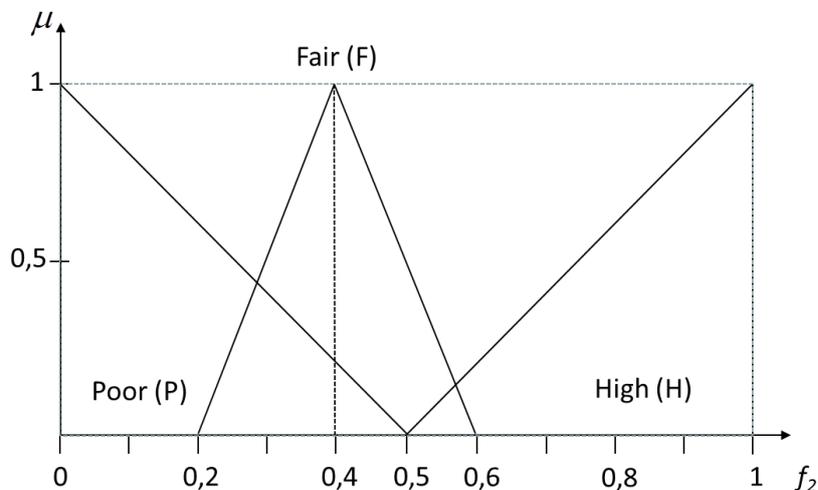


Gráfico 2.10 – Conjuntos nebulosos para o fator  $f_2$ .

Nas equações (16), (17) e (18) são apresentados os graus de pertinência para cada um dos conjuntos P, F e H, respectivamente.

$$\mu_P(f_2) = \begin{cases} -2,5f_2 + 1, & 0 \leq f_2 \leq 0,4 \\ 0, & \text{caso contrário} \end{cases} \quad (16)$$

$$\mu_F(f_2) = \begin{cases} 5f_2 - 1, & 0,2 \leq f_2 \leq 0,4 \\ -5f_2 + 3, & 0,4 \leq f_2 \leq 0,6 \\ 0, & \text{caso contrário} \end{cases} \quad (17)$$

$$\mu_H(f_2) = \begin{cases} \frac{5}{3}f_2 - \frac{2}{3}, & 0,4 \leq f_2 \leq 1 \\ 0, & \text{caso contrário} \end{cases} \quad (18)$$

### c. Fator $f_3$ : Relação entre as Tendências Globais de Riqueza

O fator  $f_3$  é uma relação linear entre as médias de ganhos de um jogador e a média de ganhos da população por iteração. Para calculá-lo é necessário:

- (1) calcular a média de ganhos por iteração de cada jogador até a última iteração completa, a partir da equação (19);

$$\bar{w}_r^k = \frac{\sum_{j=1}^k w_r^j}{k} \quad (19)$$

(2) calcular a média de ganhos da população, conforme a equação (20);

$$\bar{w}^n = \frac{\sum_{j=1}^n \sum_i w_i^j}{2n} \quad (20)$$

(3) fazer a relação entre essas duas médias calculadas, de acordo com a equação (21).

$$f_3 = \frac{\bar{w}_r^k}{\bar{w}_r^k + \bar{w}^n} \quad (21)$$

Onde:  $w_r^j$  é o ganho obtido por um jogador  $r$  na  $j$ -ésima iteração;  $\bar{w}_r^k$  é a média de ganhos por iteração que um jogador obteve até a iteração  $k$ ;  $k$  é a quantidade de iterações que o jogador  $r$  já participou;  $\bar{w}^n$  é a média de ganhos obtida pela população após  $n$  iterações;  $n$  é a quantidade total de iterações até o presente instante; e,  $i \in P$  é o conjunto de jogadores que participaram de disputas.

Os conjuntos nebulosos para este fator são similares aos conjuntos do fator  $f_1$ , ou seja, *Lower* (LW), *Similar* (SL) e *Greater* (GT), apresentados no gráfico 2.9. e as equações (22), (23) e (24) calculam os graus de pertinência para cada um dos conjuntos, respectivamente.

$$\mu_{LW}(f_3) = \begin{cases} -2f_3 + 1, & 0 \leq f_3 \leq 0,5 \\ 0, & \text{caso contrário} \end{cases} \quad (22)$$

$$\mu_{SL}(f_3) = \begin{cases} \frac{50}{3}f_3 - \frac{22}{3}, & 0,44 \leq f_3 \leq 0,5 \\ -\frac{100}{7}f_3 - \frac{57}{7}, & 0,5 \leq f_3 \leq 0,57 \\ 0, & \text{caso contrário} \end{cases} \quad (23)$$

$$\mu_{GT}(f_3) = \begin{cases} \frac{20}{9}f_3 - \frac{11}{9}, & 0,55 \leq f_3 \leq 1 \\ 0, & \text{caso contrário} \end{cases} \quad (24)$$

### 2.5.4. Conjunto de Regras Nebulosas

Cada fator é usado como antecedente no conjunto de regras de produção nebuloso e os consequentes são graus de cooperação ou traição. Esse mesmo mecanismo é empregado pelos outros dois fatores.

E, dessa forma, as conclusões parciais são obtidas separadamente através de cada um dos sistemas nebulosos relativos aos fatores, e a decisão final resulta da união dessas conclusões.

Assim, para cada um dos fatores  $f_1$ ,  $f_2$  e  $f_3$ , as possíveis combinações de regras e os possíveis consequentes (cooperar ou trair) são apresentados na tabela 2.6.

Tabela 2.6 – Conjunto de regras de produção nebulosas para os fatores  $f_1$ ,  $f_2$  e  $f_3$ .

<b>Estratégias (<math>S_{f_1}^s</math>: estratégias em relação ao fator <math>f_1</math>)</b>								
$f_1$	$S_{f_1}^1$	$S_{f_1}^2$	$S_{f_1}^3$	$S_{f_1}^4$	$S_{f_1}^5$	$S_{f_1}^6$	$S_{f_1}^7$	$S_{f_1}^8$
Lower (LW)	C	C	C	C	D	D	D	D
Similar (SL)	C	C	D	D	D	D	C	C
Greater (GT)	C	D	C	D	D	C	D	C

<b>Estratégias (<math>S_{f_2}^s</math>: estratégias em relação ao fator <math>f_2</math>)</b>								
$f_2$	$S_{f_2}^1$	$S_{f_2}^2$	$S_{f_2}^3$	$S_{f_2}^4$	$S_{f_2}^5$	$S_{f_2}^6$	$S_{f_2}^7$	$S_{f_2}^8$
Poor (P)	C	C	C	C	D	D	D	D
Fair (F)	C	C	D	D	D	D	C	C
High (H)	C	D	C	D	D	C	D	C

<b>Estratégias (<math>S_{f_3}^s</math>: estratégias em relação ao fator <math>f_3</math>)</b>								
$f_3$	$S_{f_3}^1$	$S_{f_3}^2$	$S_{f_3}^3$	$S_{f_3}^4$	$S_{f_3}^5$	$S_{f_3}^6$	$S_{f_3}^7$	$S_{f_3}^8$
Lower (LW)	C	C	C	C	D	D	D	D
Similar (SL)	C	C	D	D	D	D	C	C
Greater (GT)	C	D	C	D	D	C	D	C

Fonte: Adaptado de BORGES (1996).

A avaliação de cada um dos três fatores produz separadamente conclusões parciais sobre a intensidade da cooperação ou traição que será adotada pelo jogador  $j$ . A sua agregação é feita através de um procedimento que pega o máximo valor entre as saídas provenientes das regras relacionadas a cada fator ( $f_{q,j}^i$ , onde  $q$  corresponde a um dos três fatores; e,  $i$  é a quantidade de iterações).

### 2.5.5. Determinação da Ação do Jogador

São cinco passos necessários para a obtenção da ação de cada jogador, expressos a seguir e através do diagrama da figura 2.18.

- (1) determinar os valores dos fatores  $f_{q,j}^i$ ;
- (2) fuzzificação dos fatores  $f_{q,j}^i$ ;
- (3) ativação das regras nebulosas que combinam com o fator, de acordo com a estratégia do jogador  $S_{q,j}$ ;
- (4) geração da conclusão final a partir das conclusões parciais  $(\mu_C^r, \mu_{DC}^r)^{26}$ ;
- (5) desfuzzificação da conclusão final para determinar a ação  $a_j^i$ <sup>27</sup>.

### 2.5.6. Exemplificação

Como forma de exemplificar o funcionamento do jogo Dilema do Prisioneiro Nebuloso (DPN), considere-se dois jogadores selecionados aleatoriamente,  $J_{764}$  e  $J_{554}$ ; e, os respectivos parâmetros necessários expressos na figura 2.19:

Cada jogador é identificado pelo conjunto de estratégias de comportamento que adota, através das 9 regras que definem o que ele irá fazer de acordo com o valor de cada

---

<sup>26</sup> Cada jogador é caracterizado por um conjunto de nove regras nebulosas (três para cada  $S_{q,r}$ ,  $q = 1, 2, 3$ ). O processo de inferência irá disparar as regras que combinam com os fatores de decisão fuzzificados. Cada fator pode originar um ou qualquer par de conclusões parciais possível C ou D com seu respectivo grau de pertinência. A integração dos resultados dos fatores é feita através da união nebulosa, isso para cada classe de conclusão. Portanto, o resultado final a ser obtido, em termos de cooperação e traição, será um par único de conclusões, tomando como base o  $\max(\mu_C^{f^q})$  e  $\max(\mu_D^{f^q})$ , com  $q = 1, 2$  e  $3$  (BORGES, 1996).

<sup>27</sup> A conclusão final consistirá de um par de graus de pertinência em um ou nos dois conjuntos nebulosos cooperar ou trair. No entanto, a fim de encontrar os pagamentos em uma iteração, as ações dos jogadores não podem ser nebulosas. O processo de desfuzzificação utiliza o método *singleton*, que traduz as conclusões qualitativas em valores *crisp* para cada jogador (BORGES, 1996).

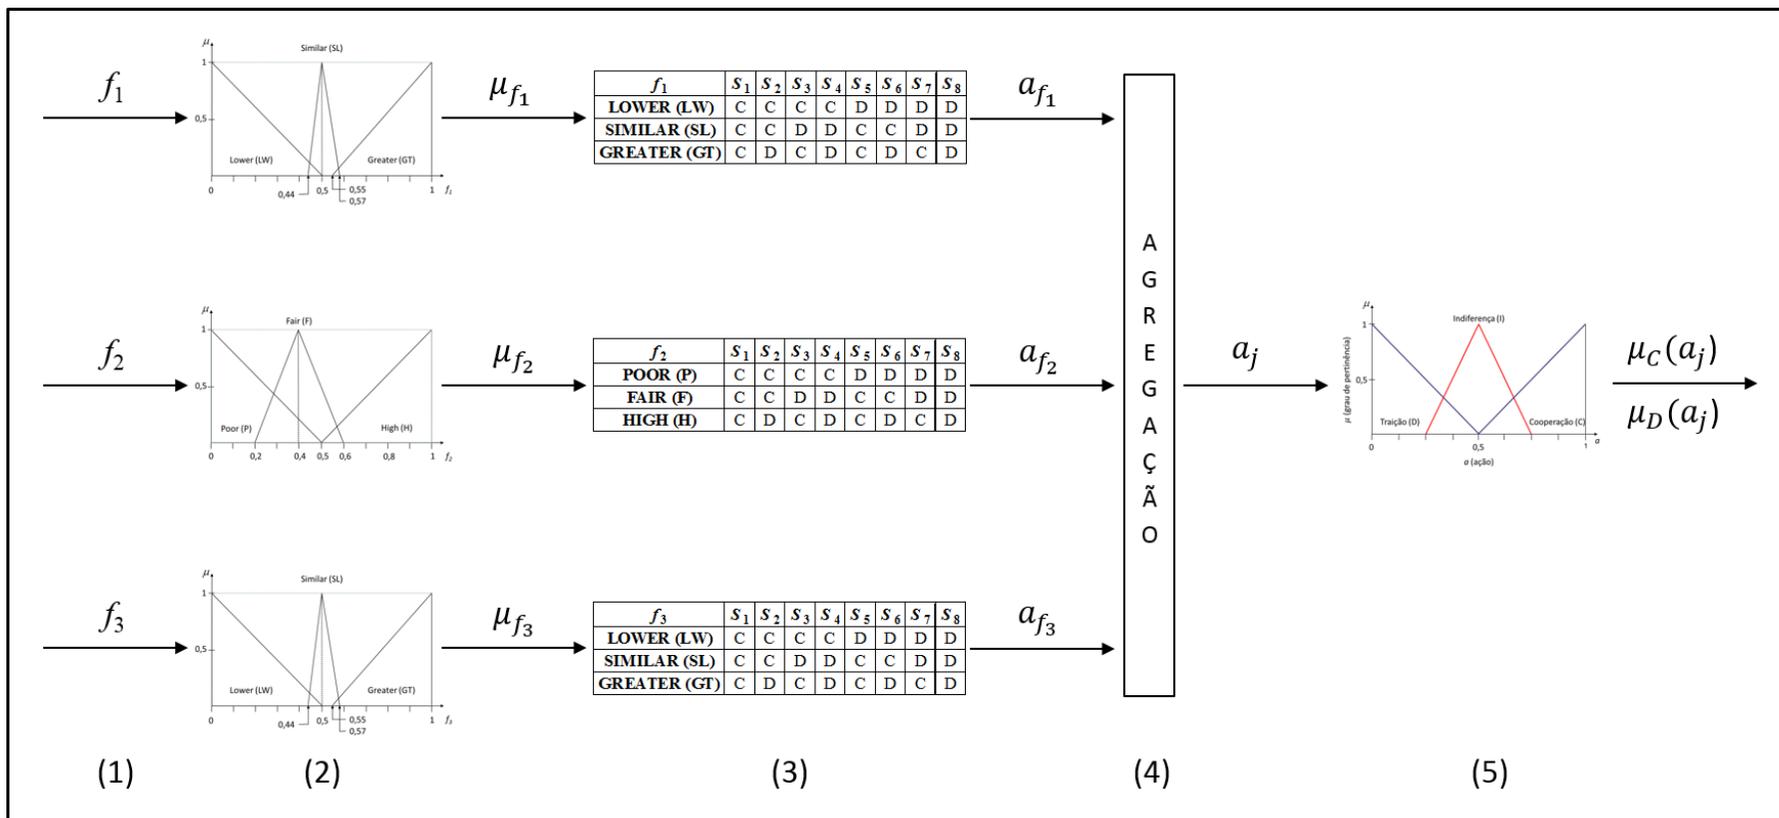


Figura 2.18 – Diagrama do processo de geração da ação do jogador a partir dos fatores de decisão.

um dos seus fatores de decisão. E, assim, por exemplo, para o jogador  $J_{764}$  são utilizadas as estratégias  $S_{f_1}^7$  para o fator  $f_1$ ,  $S_{f_2}^6$  para o fator  $f_2$  e  $S_{f_3}^4$  para o fator  $f_3$ . Assim, como para o jogador  $J_{554}$  são utilizadas as estratégias  $S_{f_1}^5$ ,  $S_{f_2}^5$  e  $S_{f_3}^4$ , respectivamente.

Jogadores				
$j_{764}$	$w_{764}^{24} = 36$	Ganhos obtidos após 24 disputas		
	$\bar{w}_{764}^{24} = 1,5$	Média de ganhos obtidos por disputa		
$j_{554}$	$w_{554}^{25} = 55$	Ganhos obtidos após 25 disputas		
	$\bar{w}_{554}^{25} = 2,2$	Média de ganhos obtidos por disputa		
$\bar{w}^n = 2,5$		Média de ganhos da população		
Interações prévias entre os jogadores (ação (a), pagamento (P))				
	1		2	
	a	P	a	P
$j_{764}$	0,5	3,2	0,2	2,6
$j_{554}$	0,8	1,7	0,5	1,1

Figura 2.19 – Parâmetros utilizados na simulação do DPN.

E, na sequência, para cada jogador são determinados qualitativamente os valores para cada um dos fatores, através dos conjuntos nebulosos correspondentes e as regras nebulosas ativadas.

Determinação da conclusão parcial  $f_1$ :

- Para o jogador  $j_{764}$

- $f_1 = \frac{36}{36+55} = \frac{36}{91} = 0,395$ .

- Conforme a equação (9):

$$\mu_{LW}(f_1) = -2 \times 0,395 + 1 = -0,79 + 1 = 0,210$$

- Regra ativada pela estratégia  $S_{f_1}^7$ :

Se  $f_1$  é LW então Defect  $\Rightarrow$  **Defect (0,210)**

- Para o jogador  $j_{554}$

- $f_1 = \frac{55}{55+36} = \frac{55}{91} = 0,604.$

- Conforme a equação (11):

$$\mu_{GT}(f_1) = \frac{20}{9} \times 0,604 - \frac{11}{9} = 1,342 - 1,222 = 0,120$$

- Regra ativada pela estratégia  $S_{f_1}^5$ :

Se  $f_1$  é GT então Defect  $\Rightarrow$  **Defect (0,120)**

Determinação da conclusão parcial  $f_2$ :

- Para o jogador  $j_{764}$

- $f_2 = \frac{0,4 \times 3,2}{5} + \frac{0,6 \times 2,6}{5} = \frac{1,28}{5} + \frac{1,56}{5} = 0,256 + 0,312 = 0,568.$

- Conforme a equação (17):

$$\mu_F(f_2) = -5 \times 0,568 + 3 = -2,840 + 3 = 0,160$$

- Conforme a equação (18):

$$\begin{aligned} \mu_H(f_2) &= \frac{5}{3} \times 0,568 - \frac{2}{3} = \frac{2,840}{3} - \frac{2}{3} = 0,946 - 0,666 \\ &= 0,280 \end{aligned}$$

- Regra ativada pela estratégia  $S_{f_2}^6$ :

Se  $f_2$  é F então Defect  $\Rightarrow$  **Defect (0,160)**

Se  $f_2$  é H então Cooperate  $\Rightarrow$  **Cooperate (0,280)**

- Para o jogador  $j_{554}$

- $f_2 = \frac{0,4 \times 1,7}{5} + \frac{0,6 \times 1,1}{5} = \frac{0,68}{5} + \frac{0,66}{5} = 0,136 + 0,132 = 0,268.$

- Conforme a equação (16):

$$\mu_P(f_2) = -2,5 \times 0,268 + 1 = -0,670 + 1 = 0,330$$

- Conforme a equação (17):

$$\mu_F(f_2) = 5 \times 0,268 - 1 = 1,340 - 1 = 0,340$$

- Regra ativada pela estratégia  $S_{f_2}^5$ :

Se  $f_2$  é P então Defect  $\Rightarrow$  **Defect (0,330)**

Se  $f_2$  é F então Defect  $\Rightarrow$  **Defect (0,340)**

Determinação da conclusão parcial  $f_3$ :

- Para o jogador  $j_{764}$

- $f_3 = \frac{1,5}{1,5+2,5} = \frac{1,5}{4} = 0,375.$

- Conforme a equação (22):

$$\mu_{LW}(f_3) = -2 \times 0,375 + 1 = -0,750 + 1 = 0,250$$

- Regra ativada pela estratégia  $S_{f_3}^4$ :

Se  $f_3$  é LW então Cooperate  $\Rightarrow$  **Cooperate (0,250)**

- Para o jogador  $j_{554}$

- $f_3 = \frac{2,2}{2,2+2,5} = \frac{2,2}{4,7} = 0,468.$

- Conforme a equação (22):

$$\mu_{LW}(f_3) = -2 \times 0,468 + 1 = -0,936 + 1 = 0,064$$

- Conforme a equação (23):

$$\mu_{SL}(f_3) = \frac{50}{3} \times 0,468 - \frac{22}{3} = 7,800 - 7,300 = 0,500$$

- Regra ativada pela estratégia  $S_{f_3}^4$ :

Se  $f_3$  é LW então Cooperate  $\Rightarrow$  **Cooperate (0,064)**

Se  $f_3$  é SL então Defect  $\Rightarrow$  **Defect (0,500)**

Após considerar os três fatores, o sistema nebuloso infere a ação final de cada um dos jogadores através das regras previamente ativadas.

Combinação das ações parciais e determinação a ação final de cada jogador:

- Para o jogador  $j_{764}$ 
  - $\mu_C = \max\{\text{Cooperate}(0,280), \text{Cooperate}(0,250)\} =$   
**Cooperate(0, 280).**
  - $\mu_D = \max\{\text{Defect}(0,210), \text{Defect}(0,160)\} =$  **Defect(0, 210).**

Logo:

$$\begin{aligned} a_{764} &= \frac{((1 - 0,210) \times 0,210 + (1 - 0,280) \times 0,280)}{2 \times (0,280 + 0,210)} \\ &= \frac{(0,790 \times 0,210) + (0,720 \times 0,280)}{2 \times 0,490} \\ &= \frac{0,166 + 0,201}{0,980} = \frac{0,367}{0,980} = \mathbf{0,375} \end{aligned}$$

- Para o jogador  $j_{554}$ 
  - $\mu_C = \max\{\text{Cooperate}(0,064)\} =$  **Cooperate(0, 064).**
  - $\mu_D = \max\{\text{Defect}(0,120), \text{Defect}(0,330), \text{Defect}(0,340),$   
 $\text{Defect}(0,500)\} =$  **Defect(0, 500).**

Logo:

$$\begin{aligned} a_{764} &= \frac{((1 - 0,500) \times 0,500 + (1 - 0,064) \times 0,064)}{2 \times (0,064 + 0,500)} \\ &= \frac{(0,500 \times 0,500) + (0,936 \times 0,064)}{2 \times 0,564} \\ &= \frac{0,250 + 0,059}{1,128} = \frac{0,309}{1,128} = \mathbf{0,274} \end{aligned}$$

E com as ações finais de cada jogador, os respectivos valores de pagamento são calculados através das funções de pagamentos expressas nas equações (6) e (7).

Determinação dos valores de pagamentos para cada um dos jogadores:

- Para o jogador  $j_{764}$ 
  - $p_{j_1} = 1 - 0,375 + 3 \times 0,274 = 0,625 + 0,822 = 1,447$ .
  
- Para o jogador  $j_{554}$ 
  - $p_{j_2} = 1 - 2 \times 0,274 + 4 \times 0,375 = 0,452 + 1,500 = 1,952$ .

Atualização da configuração dos parâmetros da população após a realização das disputas, conforme a figura 2.20.

Jogadores																													
$j_{764}$	$w_{764}^{25} = 37,447$ Ganhos obtidos após 25 disputas $\bar{w}_{764}^{25} = 1,497$ Média de ganhos obtidos por disputa																												
$j_{554}$	$w_{554}^{26} = 56,952$ Ganhos obtidos após 25 disputas $\bar{w}_{554}^{26} = 2,190$ Média de ganhos obtidos por disputa																												
$\bar{w}^n = 2,5$ Média de ganhos da população																													
Interações prévias entre os jogadores (ação (a), pagamento (P))																													
	<table border="1" style="margin-left: auto; margin-right: auto;"> <thead> <tr> <th></th> <th colspan="2">1</th> <th colspan="2">2</th> <th colspan="2">3</th> </tr> <tr> <th></th> <th>a</th> <th>P</th> <th>a</th> <th>P</th> <th>a</th> <th>P</th> </tr> </thead> <tbody> <tr> <td><math>j_{764}</math></td> <td>0,5</td> <td>3,2</td> <td>0,2</td> <td>2,6</td> <td>0,375</td> <td>1,447</td> </tr> <tr> <td><math>j_{554}</math></td> <td>0,8</td> <td>1,7</td> <td>0,5</td> <td>1,1</td> <td>0,274</td> <td>1,952</td> </tr> </tbody> </table>		1		2		3			a	P	a	P	a	P	$j_{764}$	0,5	3,2	0,2	2,6	0,375	1,447	$j_{554}$	0,8	1,7	0,5	1,1	0,274	1,952
	1		2		3																								
	a	P	a	P	a	P																							
$j_{764}$	0,5	3,2	0,2	2,6	0,375	1,447																							
$j_{554}$	0,8	1,7	0,5	1,1	0,274	1,952																							

Figura 2.20 – Configuração dos parâmetros da população após as disputas.

### 2.5.7. Codificação das Estratégias de Comportamento

Em seu estudo, BORGES (1996) realizou torneios computacionais de estratégias de comportamento, onde foram definidos 32 grupos contendo 19 estratégias cada, sendo 16

delas dentre as 512 originárias dos três sistemas nebulosos e , ainda, foram acrescentadas as estratégias TFT, TFT-g<sup>28</sup> e Pavlov<sup>29</sup>.

Na primeira fase, foram realizadas 30.000 iterações em cada um dos 32 grupos e, posteriormente, as estratégias foram classificadas a partir dos ganhos obtidos nessas iterações. O resultado obtido consagrou como campeãs de seus grupos 20 estratégias dentre as 512 e, nos outros 12 grupos, a estratégia Pavlov foi vencedora.

A segunda fase foi composta por 11 grupos contendo 19 estratégias cada. Dentre elas, 16 estratégias foram extraídas das oito primeiras posições de cada um dos 32 grupos, porém somente aquelas que neles apareciam simultaneamente.

Assim, foram totalizadas 176 estratégias nebulosas ainda participantes dos torneios. As outras três estratégias são as mesmas utilizadas na primeira fase. Como resultado a estratégia TFT tornou-se vencedora em 8 dos 11 grupos e, nos outros três, as estratégias vencedoras foram 556, 554 e 445.

Na terceira fase foram formados apenas 5 grupos, compostos também por 19 estratégias cada, sendo estas novamente as melhores estratégias da segunda fase, segundo o mesmo critério. Para cada um dos grupos a estratégia TFT foi vencedora.

E na última fase, o torneio foi composto pelas 16 melhores estratégias dentre as 512, acrescido das estratégias TFT, TFT-g e Pavlov. E, novamente, a estratégia TFT tornou-se a campeã.

A partir desses experimentos de BORGES (1996) foram definidos os critérios necessários para especificar as estratégias que seriam utilizadas na integração do Dilema do Prisioneiro Nebuloso ao contexto do algoritmo SIGA, com o objetivo de gerar o algoritmo F-SIGA. Esses critérios são dois:

---

<sup>28</sup> A estratégia TFT Generalizada (TFT-g) inicia o confronto cooperando e, nas próximas iterações repete o comportamento de seu oponente (BORGES, 1996; GRIM et al., 1998).

<sup>29</sup> A estratégia Pavlov coopera após a mútua cooperação ou mútua traição (GRIM et al., 1998).

- (1) codificação genética das estratégias, de forma que seja possível aplicar operações de cruzamento e mutação;
- (2) as melhores estratégias tem que estar em maior quantidade na população. Portanto, foi utilizada a seguinte distribuição na população inicial:  $\left(\frac{38}{100}\right)$  BORGES-20;  $\left(\frac{28}{100}\right)$  TFT;  $\left(\frac{28}{100}\right)$  Pavlov;  $\left(\frac{3}{100}\right)$  BORGES-492; e,  $\left(\frac{3}{100}\right)$  Aleatório.

Cada uma das estratégias foi codificada geneticamente através de um cromossomo composto por seis genes, que possuem alelos ternários (1, 2 e 3). A cada dois genes é representado geneticamente um fator de decisão. Na figura 2.21 é possível visualizar a composição do cromossomo estratégia utilizado para a sua codificação.

Sendo assim, foram definidos cinco grupos de estratégias de comportamento: (1) BORGES-20, que são as vinte melhores estratégias nebulosas obtidas nos torneios computacionais mencionados; (2) BORGES-492, que são as outras estratégias nebulosas; (3) estratégias TFT; (4) estratégias Pavlov; e, (5) estratégias Aleatórias, que escolhem aleatoriamente uma estratégia dentre as estratégias BORGES-20 e BORGES-492.

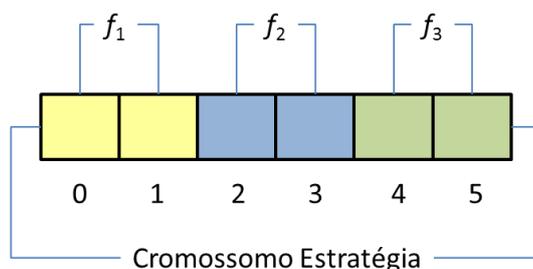


Figura 2.21 – Esquema do cromossomo para as estratégias utilizadas no algoritmo F-SIGA.

Além disso, no anexo D, na tabela D.2 é possível visualizar as 729 codificações genéticas de todas as estratégias. As 515 estratégias foram codificadas de acordo com o grupo pertencente e, assim, foi atribuída a seguinte proporção: 11/8/8/1/1, ou seja, cada estratégia BORGES-20 é codificada por onze diferentes cromossomos; a TFT por oito, a

Pavlov por oito; a aleatória por um; e, cada uma das 492 estratégias nebulosas restantes por um único cromossomo.

## 2.6. ALGORITMO ESIA

O **Algoritmo Evolucionário de Interação Social**<sup>30</sup> surge em decorrência dos estudos que originaram os algoritmos SIGA, NpSIGA e F-SIGA. Dessa forma, ele pode ser considerado como uma consequência natural, pois baseia-se plenamente na evolução social dos indivíduos.

Essa novo algoritmo evolucionário ocorre devido a quatro fatores:

- (1) a inclusão efetiva da caracterização fenotípica, através de um segundo cromossomo para codificação das estratégias de comportamento dos indivíduos;
- (2) a herança das estratégias pelos descendentes, através da aplicação dos operadores genéticos: cruzamento e/ou mutação;
- (3) a participação dos indivíduos no processo de interação social;
- (4) a alteração no cálculo de *fitness* dos indivíduos, ao considerar os valores de ganho obtidos nas interações sociais e, assim, apenas considerá-los para a seleção daqueles que participarão da etapa de reprodução.

No entanto, apesar da presença desses fatores, o papel desempenhado pelo processo de interação social ainda é secundário. E na busca da solução de um problema, ele apenas auxilia no processo evolutivo da população, de forma a manter a sua variabilidade e, assim tentar evitar a sua estagnação do processo evolutivo da população ao ficar preso em um ótimo local ou, até mesmo, a homogeneidade genotípica dos indivíduos.

---

<sup>30</sup> Em inglês: *Evolutionary Social Interaction Algorithms (ESIA)*.

Além disso, formaliza um mecanismo que permite a luta pela existência, o que possibilita aos indivíduos evoluir ao longo de sua existência, através de melhora de suas adaptabilidades (valor de *fitness*), sendo assim, um modelo mais próximo do encontrado na natureza.

Apesar dos benefícios advindos do processo de Interação Social, é importante lembrar que ajustes de configuração de parâmetros do Algoritmo Genético, ou a implementação de novos operadores de mutação e cruzamento, conforme já mencionados, podem proporcionar a manutenção da variabilidade.

E, nesse sentido, pode-se até afirmar que quaisquer Algoritmos Aproximativos tem a capacidade de realizar essa tarefa e, até com componentes a mais, como por exemplo, o algoritmo PSO (*Particle Swarm Optimization*), que possui mecanismos de memória para guiar o processo de busca da solução.

Nesse contexto, surgiu o seguinte questionamento: **como tornar o papel exercido pelo processo de Interação Social em principal, ou seja, passar a ser o principal moto de busca, ao invés de apenas auxiliar esse processo?**

É importante observar que a resposta a essa pergunta sempre esteve presente na estrutura dos três algoritmos anteriores, SIGA, NpSIGA e F-SIGA, porém a pergunta ainda não havia sido feita.

Dessa forma, para isso, basta considerar o valor do parâmetro  $\alpha$ , presente na função de *fitness*, equação (1), igual a zero ( $\alpha = 0$ ). E, assim, torna o valor da  $Fitness_{Solução}$  nulo para o processo de seleção na etapa de reprodução, e apenas o valor obtido nas interações sociais são considerados.

Como consequência, outro questionamento surgiu em decorrência do anterior e, que ajudou a respondê-la também: **há alguma influência no processo de busca o uso da experiência adquirida pelos indivíduos durante o processo de interação social? E este assim utilizado como diferencial em sua sobrevivência?**

### 2.6.1. Fator de Experiência

Esses questionamentos motivaram a concepção do que foi denominado de **Fator de Experiência** – característica a mais presente no algoritmo ESIA – que pode ser definido como uma função de duas variáveis: a idade do indivíduo, calculada a partir da quantidade de gerações já vividas pelo indivíduo até o momento na execução do algoritmo; e, a quantidade de disputas que ele participou no processo de interação social.

A estratégia para modelar esta função é separá-la em duas funções de uma variável cada e independentes e, posteriormente, multiplicá-las. Assim, são derivadas as funções:

#### a. Fator de experiência em relação à idade

A função relacionada com a idade pode ser modelada através de uma função Gaussiana, conforme a equação (25) e visualizada no gráfico 2.11.

Os valores de média da idade ( $\bar{i}$ ) e variância ( $\sigma_i^2$ ) podem ser definidos baseados na observação de experimentos prévios, ou podem ser adaptativos, a partir do monitoramento dessas variáveis durante a execução do algoritmo.

$$FE(i) = \left( \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(i-\bar{i})^2}{2\sigma_i^2}} \right) \quad (25)$$

Onde:  $i$  é a idade do indivíduo;  $\bar{i}$  é a média de idade dos indivíduos da população;  $\sigma$  é o desvio padrão; e,  $\sigma_i^2$  é a variância da idade dos indivíduos da população.

A escolha pela função Gaussiana foi feita baseada na ideia de que a capacidade de aprendizado e, o posterior, desenvolvimento de habilidades de um ser humano aumenta com a sua idade até atingir um pico, o seu apogeu, e depois diminui por motivos como, por exemplo, desatualização em termos de conhecimentos tecnológicos.

E, assim, apesar de não ocorrer a diminuição da sua experiência, o indivíduo fica menos adaptado a realidade do momento, o que faz com que a sua contribuição para a evolução da população como um todo diminua ao longo do tempo.

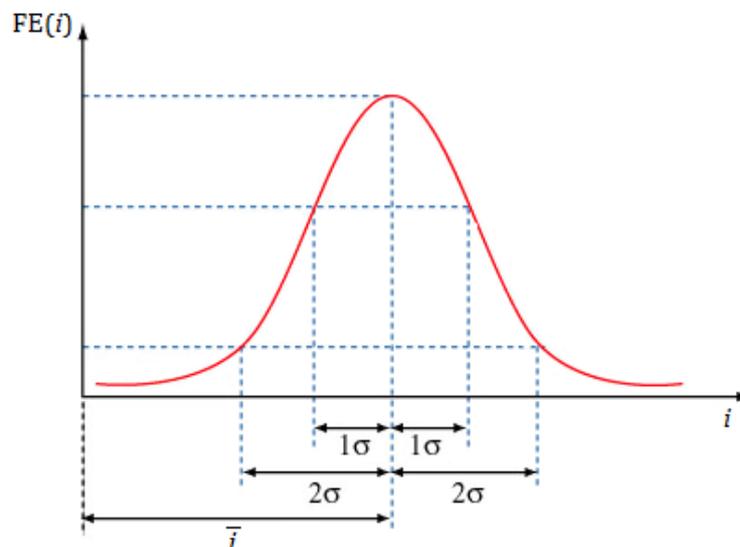


Gráfico 2.11 – Função Gaussiana para representar o FE(i).

#### b. Fator de experiência em relação à quantidade de disputas

A função em relação à quantidade de disputas é modelada como uma função de aproximação exponencial, conforme a equação (26) e visualizada no gráfico 2.12.

Essa escolha foi feita baseada na ideia de que a experiência de um ser humano aumentada de acordo com a repetição de uma atividade, porém atinge um máximo em determinado momento a partir do qual novas repetições da atividade não irão aumentar a experiência consideravelmente, podendo então desprezá-las.

$$FE(d) = \left(1 - e^{-\frac{d}{f_d}}\right) \quad (26)$$

Onde:  $d$  é a quantidade de disputas que o indivíduo  $i$  já participou; e,  $f_d$  é o fator de disputas, que define um limiar a partir do qual a quantidade de disputas não influenciará tanto na experiência de um indivíduo. Se  $d = f_d \Rightarrow FE_d = 63\%$  do valor máximo, que no caso é 1. Se  $d = 4 \times f_d \Rightarrow FE_d = 98\%$ . E, se  $d = 5 \times f_d \Rightarrow FE_d = 99\%$ .

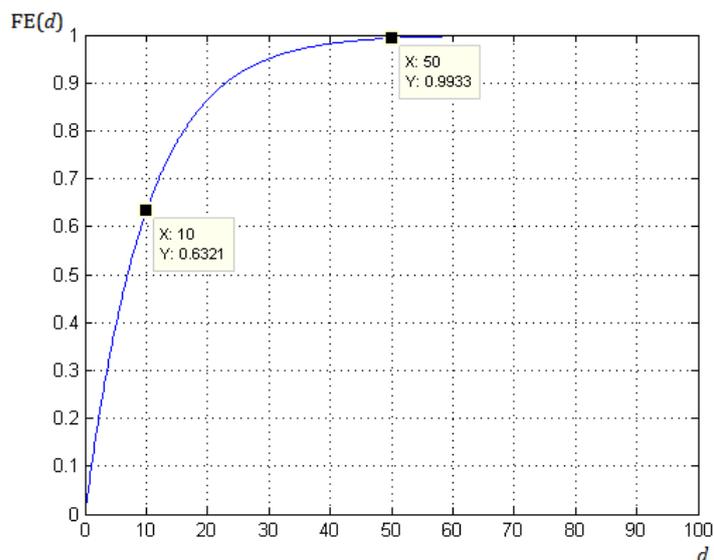


Gráfico 2.12 – Função aproximativa exponencial para representar o FE(d).

### c. Função Fator Experiência (idade, disputas)

Como dito anteriormente a função fator de experiência é então o resultado da multiplicação do fator de experiência em relação à idade (FE(i)) e do fator de experiência em relação às disputas (FE(d)), conforme a equação (27) e visualizada no gráfico 2.13.

$$FE(i, d) = [FE(i) \times FE(d)] \quad (27)$$

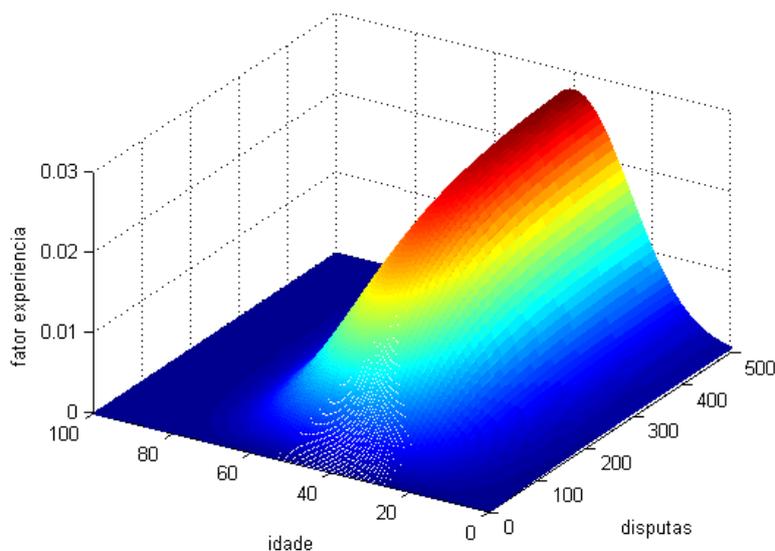


Gráfico 2.13 – Fator de experiência de um indivíduo em função da sua idade e da quantidade de disputas.

No gráfico 2.13 é possível observar, por exemplo, que o fator de experiência é maior quando o indivíduo se encontra com valor de idade entre 40 e 60. Além disso, a partir de aproximadamente 250 disputas, a experiência do indivíduo começa a se estabilizar, o que indica que as novas disputas não agregam tanto ao fator experiência.

### 2.6.2. Função Fitness com o Fator de Experiência

A partir da especificação do fator de experiência é possível redefinir a função de *fitness* apresentada na equação (1) e, assim, alterar o cálculo do termo  $Fitness_{Estratégia}$ , conforme a equação (26), onde o valor ganho nas disputas é multiplicado pela soma de uma unidade com o valor do fator de experiência do indivíduo e, assim, é conservado na íntegra o valor ganho nas disputas.

$$Fitness_{Estratégia} = [(Valor\_Ganho) \times (1 + FE(i, d))] \quad (26)$$

Ao considerar as equações (1) e (26), o cálculo da função *fitness* de um indivíduo no algoritmo ESIA é realizado através da equação (27).

$$Fitness_{Total} = (\alpha \times Fitness_{Solução}) \pm \{\beta \times [(Valor_{Ganho}) \times (1 + FE(i, d))]\} \quad (27)$$

E, assim, a partir do que foi exposto é possível pensar no algoritmo ESIA de maneira independente da estrutura genotípica do problema que se deseja resolver, pois é baseado caracteristicamente em fenótipo – comportamento dos indivíduos –, representado pelas estratégias de comportamento e o ambiente de Interação Social, representado pelo jogo.

### 2.6.3. Possibilidades de Extensão do Uso do ESIA

É importante observar a possibilidade de uso do ESIA acoplado a outras heurísticas ou metaheurísticas de busca baseadas em população, tais como: Programação Genética



com o objetivo de proporcionar aos indivíduos da população a possibilidade de lutarem pela sua sobrevivência e, assim, evoluírem ao longo de sua existência.

E, em termos práticos, isso significa a adição de um mecanismo auxiliar ao processo de reprodução – seleção, cruzamento e mutação – na busca por indivíduos mais evoluídos, o que representam soluções cada vez melhores para o problema considerado. Assim, explorar novas áreas do espaço de busca, e evitando a estagnação do processo evolutivo em ótimos locais, na busca do ótimo global.

Com a etapa de Interação foram definidas as estratégias de comportamento, assim como as suas respectivas codificações genéticas e que, inclusive, sofrem operações de cruzamento e mutação no processo de herança das estratégias pelos descendentes.

No mecanismo do SIGA foram utilizadas apenas quatro estratégias de comportamento. E a partir da estrutura do algoritmo F-SIGA, onde os indivíduos podem cooperar ou trair com graus de intensidade, a partir do cálculo de suas ações a partir dos três fatores de decisão.

Para isso, foram definidas e utilizadas 512 estratégias de comportamento codificadas geneticamente através de um cromossomo de 6 posições, com genes alelos ternários (0, 1 e 2). E, assim, foram gerados 729 genótipos e distribuídos entre as estratégias.

Os algoritmos SIGA foram exemplificados através de métodos baseados no jogo Dilema do Prisioneiro, como ambiente de Interação Social, acoplados aos métodos de seleção Roleta e Torneio; o NpSIGA utiliza a mesma estrutura do SIGA, porém aplica a versão N-pessoas do jogo Dilema do Prisioneiro e, o algoritmo F-SIGA utiliza a versão do Dilema do Prisioneiro Nebuloso como ambiente de Interação Social.

O SIGA, NpSIGA e o F-SIGA utilizam a mesma função de *Fitness* para avaliar os indivíduos da população, onde fazem uso da *Fitness* calculada a partir da solução do problema, acrescida dos ganhos obtidos nas disputas dos jogos das interações sociais; o que, posteriormente motivou a concepção do Fator de Experiência, que propiciou a definição do algoritmo ESIA e, assim, o cálculo de *fitness* com a adição dessa

característica e a possibilidade de apenas utilizar o valor de *fitness* obtido a partir das interações sociais e o fator de experiência como critério para guiar a busca de soluções.

No capítulo a seguir são apresentados os problemas utilizados para realizar as simulações realizadas para diferentes problemas de otimização global, com e sem restrições; e otimização combinatória, através do Problema do Caixeiro Viajante. E, assim, demonstrar a aplicabilidade dos algoritmos apresentados neste capítulo e os respectivos resultados obtidos.

# CAPÍTULO III

## 3. PROBLEMAS, SIMULAÇÕES E RESULTADOS

### 3.1. APRESENTAÇÃO

Como forma de avaliar os algoritmos propostos e apresentados no capítulo anterior, foram escolhidas três categorias de problemas de otimização comumente utilizadas nesse processo, tais como: (1) otimização global sem restrições; (2) otimização global com restrições; (3) otimização combinatória, através do seu exemplo mais clássico, que é o Problema do Caixeiro Viajante. Todos os problemas dessas categorias são problemas de minimização.

Dessa forma, para cada uma dessas categorias foram selecionados alguns problemas para os quais foram aplicados os quatro algoritmos propostos: SIGA, NpSIGA, F-SIGA e o ESIA; e, também, o AG Clássico para comparações.

É importante observar que o NpSIGA foi implementado apenas para as instâncias do Problema do Caixeiro Viajante, pois foi uma proposta que surgiu em paralelo ao desenvolvimento dos outros três algoritmos e, assim, esse problema foi o único utilizado como forma de exemplificar a sua aplicação.

Antes de apresentar em maiores detalhes cada uma das três categorias e os resultados obtidos nas suas respectivas simulações, é necessário abordar dois seguintes aspectos:

- (1) as adaptações realizadas nos algoritmos, mais especificamente ao tratamento dado às restrições da segunda categoria de problemas de otimização global;
- (2) os parâmetros utilizados nas configurações das simulações realizadas.

No que se refere às adaptações dos algoritmos, para todos foi necessário definir como tratar as restrições do problemas de otimização global com esta característica, tais como os apresentados na seção 3.3.

Com base nos trabalhos de COELLO (2002); COELLO e MONTES (2002), que abordam problemas restritivos, foram definidas três regras que influenciam o processo de seleção por torneio dos AG. As regras são:

1. Caso os indivíduos selecionados não violem nenhuma restrição, então vence o torneio aquele que tiver o melhor (maior ou menor) valor de *fitness*;
2. Caso os indivíduos selecionados violem alguma restrição, então vence o torneio aquele que tiver a menor quantidade de violações, independentemente do valor de *fitness*;
3. Caso sejam selecionados indivíduos que violem e que não violem alguma restrição, vence aquele que não possui violações.

Nesse sentido, a partir dessas três regras é configurado um segundo objetivo a ser minimizado, que é a diminuição na quantidade de restrições violadas. Ou seja, todos aqueles indivíduos que possuírem violações não podem ser considerados como soluções factíveis do problema em questão.

Assim, o AG é alterado de forma a trabalhar com dois objetivos: primeiro, minimizar a quantidade de restrições; atrelado ao segundo, que é a minimização do valor de *fitness*.

Os detalhes das configurações dos parâmetros das simulações estão apresentados no anexo E. Nele estão definidas 107 diferentes configurações, distribuídas entre os 11 problemas das 3 diferentes categorias, conforme a tabela 3.1. Sendo que, para cada configuração foram realizadas 50 execuções e, assim, totalizadas 5.350 execuções. Na tabela 3.1 tem-se essa distribuição.

Tabela 3.1 – Distribuição das configurações entre as categorias de problemas.

CATEGORIA	PROBLEMAS	QUANTIDADE DE CONFIGURAÇÕES	
		Por problema	Total
Otimização Global sem Restrições	$f_1, f_6$ e $f_8$	09	27
Otimização Global com Restrições	WBD, DPV, MWTCS, SRD	09	36
Otimização Combinatória (Problema do Caixeiro Viajante)	PCV-Simétrico(instâncias: <i>br26</i> , <i>kroa100</i> , <i>att532</i> e <i>pcb1173</i> )	11	44
<b>TOTAL DE CONFIGURAÇÕES</b>			<b>107</b>

### 3.2. PROBLEMAS DE OTIMIZAÇÃO GLOBAL SEM RESTRIÇÕES

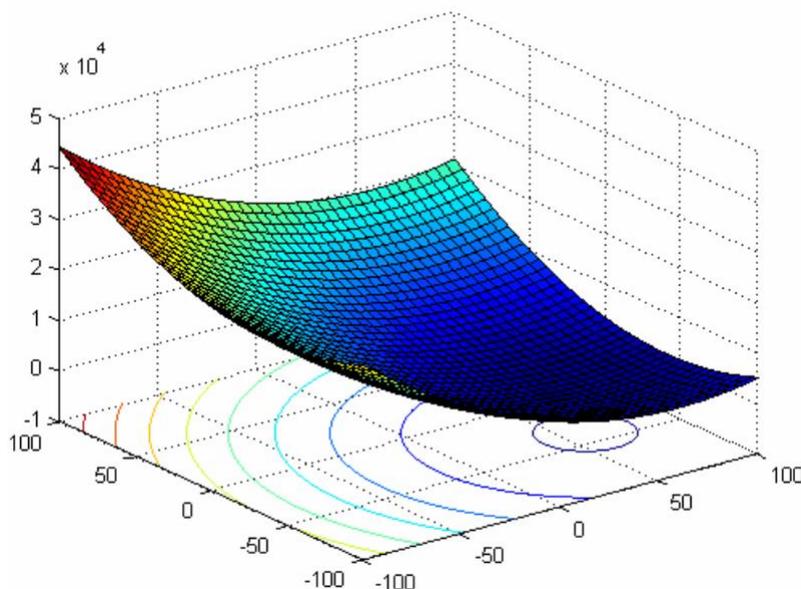
Os problemas desta categoria são também comumente conhecidos como problemas de otimização com parâmetros de valor real e representam um importante papel no processo de avaliação de algoritmos, pois testam a sua robustez e capacidade de solucionar problemas. Além disso, estes podem ser: **unimodais**, pois apresentam apenas um ótimo global; ou, **multimodais**, pois apresentam vários ótimos globais.

#### 3.2.1. Função $f_1$ - *Shifted Sphere Function*

Dentre as funções unimodais apresentadas em SUGANTHAN et al. (2005) foi escolhida apenas a função  $f_1$ , *Shifted Sphere Function*, que é expressa pela equação (28) e pode ser visualizada no gráfico 3.1.

$$f_1(x) = \sum_{i=1}^n x_i^2 \quad (28)$$

Onde:  $x \in [-100, 100]^n$ ,  $n = 30$ , e o ótimo global é igual a 0.

Gráfico 3.1 – Visualização da função  $f_1$ .

Fonte: SUGANTHAN et al. (2005)

Foram realizadas um total de 9 simulações para esta função, sendo cada uma delas executadas cinquenta vezes (e01 a e50), o que totalizaram 450 testes, conforme podem ser vistos os respectivos resultados nas tabelas F.1 (a), (b), (c), (d) e (e).

E a seguir, na tabela 3.2, são visualizados os melhores resultados, a média e o desvio padrão para cada uma das simulações, com destaque para o melhor resultado obtido,  $f_1(x) = 0,08214600$ , que está distante ao valor ótimo,  $f_1^*(x) = 0$ .

Tabela 3.2 – Melhor resultado, média e desvio padrão para o problema  $f_1$ .

Simulações	Melhor Resultado	Média	Desvio Padrão
1	0,08228921	0,27265686	0,09921225
2	0,09514862	0,25441689	0,09501601
3	0,08214600	0,33714237	0,12919724
4	0,11256760	0,26762890	0,10513934
5	0,12840235	0,37561113	0,16136356
6	0,13049785	0,25490154	0,08708166
7	0,10192173	0,34026147	0,14926831
8	0,13425780	0,27966635	0,09990585
9	0,10970589	0,33562826	0,12387249

No gráfico 3.2 estão dispostos os 450 resultados obtidos nas simulações. Nele é pode-se observar em destaque a melhor solução encontrada na 21ª execução da simulação 3, através do Algoritmo SIGA(0,1).

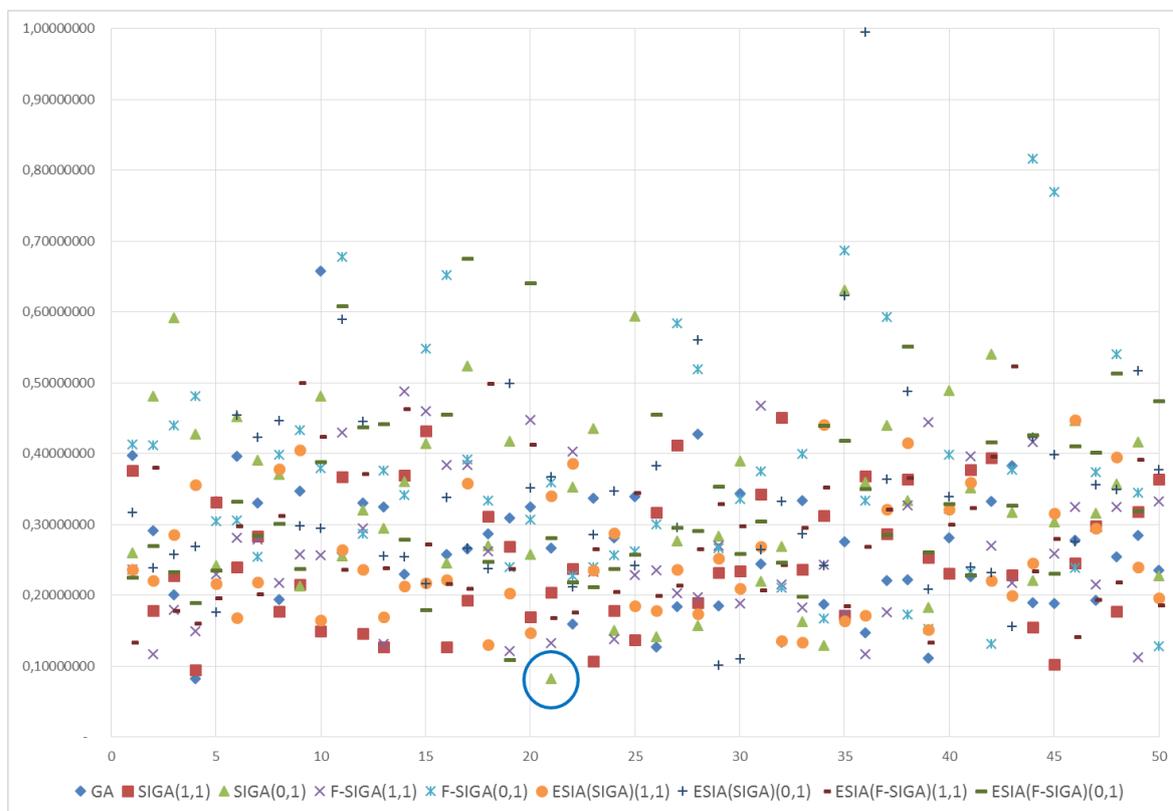


Gráfico 3.2 – Gráfico de dispersão para os resultados das simulações do problema  $f_1$ .

Todos os resultados foram organizados em ordem crescente e, assim, é possível observar a distribuição dos algoritmos vitoriosos em todos os 450 testes e distribuídos em dez faixas, de acordo com a tabela 3.3.

Tabela 3.3 – Distribuição dos algoritmos vitoriosos para o problema  $f_1$ .

Faixas de Testes		AG		SIGA				F-SIGA				ESIA(SIGA)				ESIA(F-SIGA)			
				(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)	
%	Ordem	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%								
[0, 10]	1 a 45	6	13%	9	20%	6	13%	8	18%	3	7%	5	11%	3	7%	4	9%	1	2%
[11, 20]	46 a 90	7	16%	8	18%	1	2%	6	13%	2	4%	10	22%	1	2%	7	16%	3	7%
[21, 30]	90 a 135	5	11%	4	9%	4	9%	6	13%	2	4%	9	20%	3	7%	8	18%	4	9%
[31, 40]	136 a 180	2	4%	7	16%	2	4%	5	11%	4	9%	7	16%	6	13%	5	11%	7	16%
[41, 50]	181 a 225	7	16%	2	4%	6	13%	7	16%	4	9%	2	4%	7	16%	5	11%	5	11%
[51, 60]	226 a 270	6	13%	6	13%	4	9%	2	4%	5	11%	4	9%	6	13%	5	11%	7	16%
[61, 70]	271 a 315	11	24%	3	7%	3	7%	5	11%	5	11%	3	7%	6	13%	4	9%	5	11%
[71, 80]	316 a 360	1	2%	8	18%	8	18%	3	7%	7	16%	6	13%	5	11%	5	11%	2	4%
[81, 90]	361 a 405	4	9%	2	4%	7	16%	5	11%	7	16%	4	9%	5	11%	3	7%	8	18%
[91, 100]	406 a 450	1	2%	1	2%	9	20%	3	7%	11	24%	0	0%	8	18%	4	9%	8	18%

Os resultados dos primeiros 20% melhores resultados, ou seja, os 90 primeiros testes podem ser visualizados também através do gráfico 3.3, Nele são apresentados os valores referentes à distribuição dos algoritmos vitoriosos.

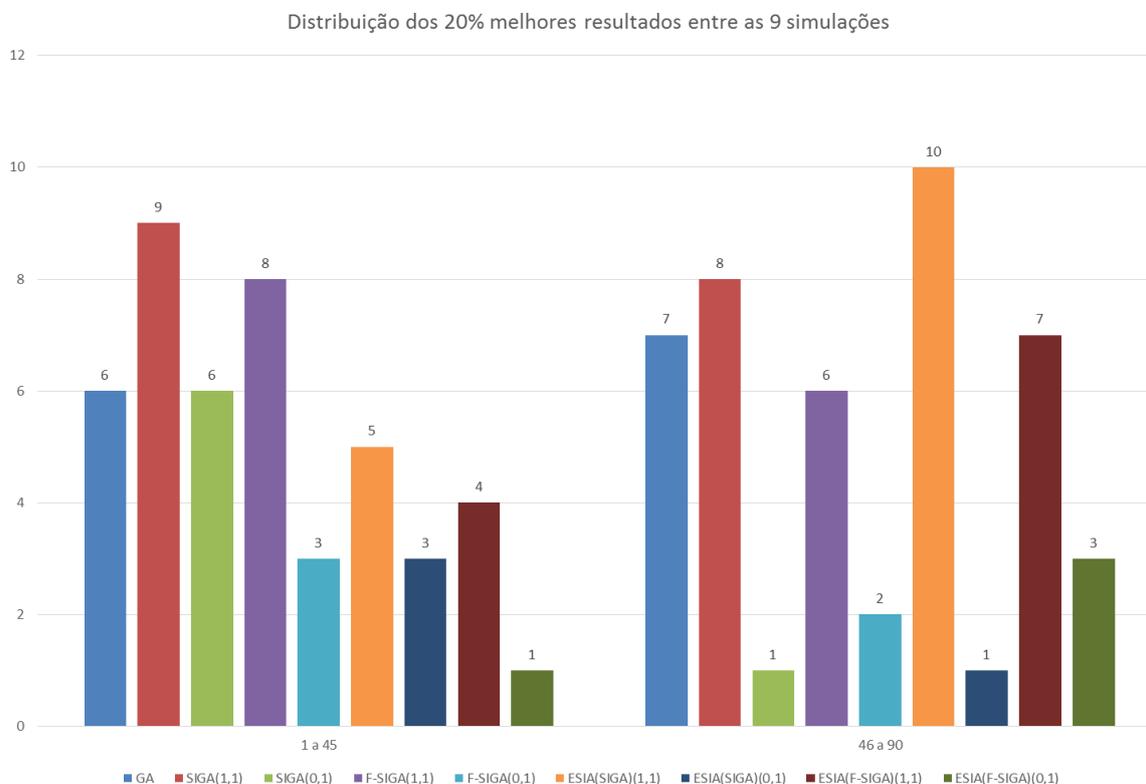


Gráfico 3.3 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema  $f_1$ .

A partir desses resultados é possível observar os seguintes fatos para os 45 melhores resultados, o que representam os 10% melhores:

- Os Algoritmos Genéticos obtiveram os melhores resultados em 6 testes, ou seja, 13,3% dos resultados;
- Os algoritmos de Interação Social obtiveram os melhores resultados nos 39 testes restantes, ou seja, 86,6% dos resultados;
- O algoritmo SIGA foi vitorioso em 15 testes, ou seja, 33,3% dos resultados;

- O algoritmo F-SIGA foi vitorioso em 11 testes, ou seja, 24,4% dos resultados;
- Os algoritmos (1,1) obtiveram os melhores resultados em 26 testes, ou seja, 57,7% dos resultados;
- Os algoritmos (0,1) obtiveram os melhores resultados em 13 testes, ou seja, 28,8% dos resultados;
- Os algoritmos ESIA obtiveram os melhores resultados também em 13 testes, ou seja, 28,8% dos resultados.

### 3.2.2. Função $f_6$ - *Shifted Rosenbrock's Function*

Dentre as funções multimodais foram escolhidas duas, sendo a primeira: a  $f_6$ , *Shifted Rosenbrock's Function*, que está expressa pela equação (29) e pode ser visualizada através do gráfico 3.4.

$$f_6(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2] \quad (29)$$

Onde:  $x \in [-100, 100]^n$ ,  $n = 30$ , e o ótimo global é igual a 0.

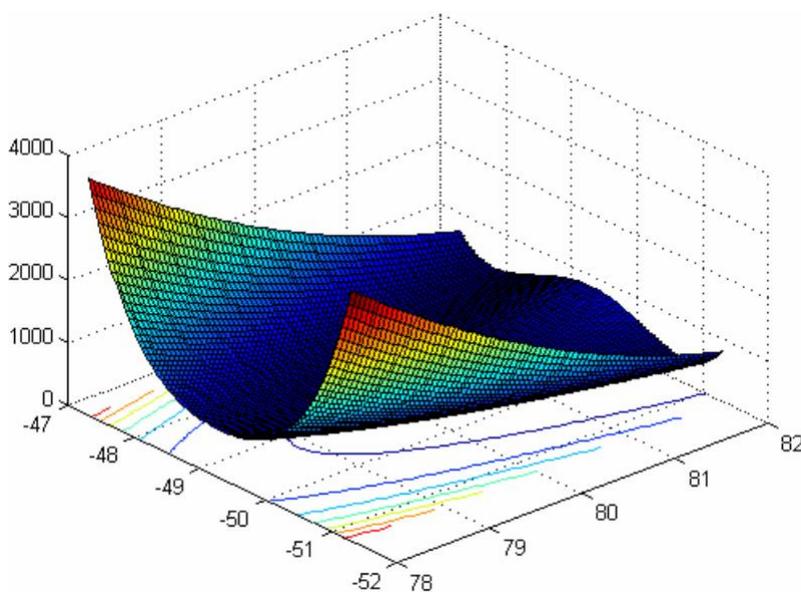


Gráfico 3.4 – Visualização da função  $f_6$ .  
Fonte: SUGANTHAN et al. (2005)

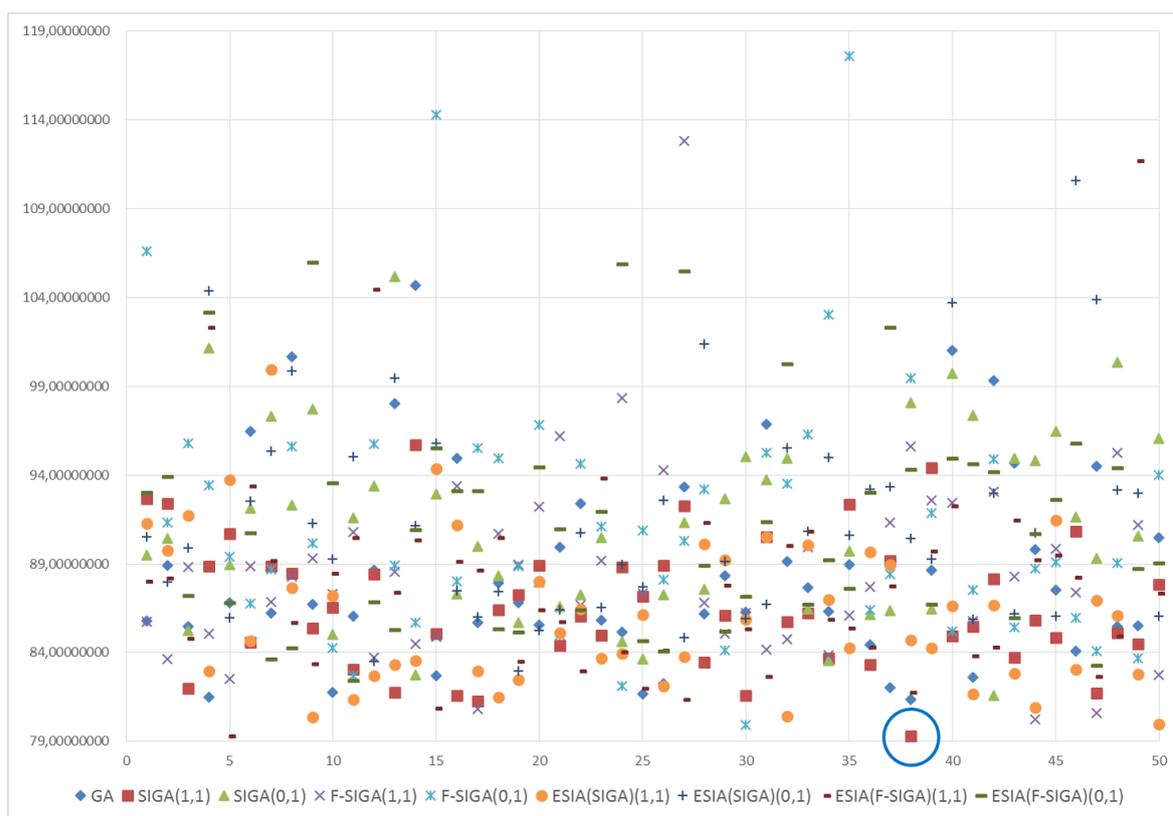
Foram realizadas um total de 9 simulações para esta função, sendo cada uma delas executadas cinquenta vezes (e01 a e50), o que totalizaram 450 testes, conforme podem ser vistos os respectivos resultados nas tabelas F.2 (a), (b), (c), (d) e (e).

E a seguir, na tabela 3.4, são visualizados os melhores resultados, a média e o desvio padrão para cada uma das simulações, com destaque para o melhor resultado obtido,  $f_6(x) = 79,30141381$ , que está distante ao valor ótimo,  $f_6^*(x) = 0$ .

Tabela 3.4 – Melhor resultado, média e desvio padrão para o problema  $f_6$ .

Simulações	Melhor Resultado	Média	Desvio Padrão
10	81,36248161	88,66510500	5,63206037
11	79,30141381	86,62738041	3,65806421
12	81,58001159	90,99369167	5,30224559
13	80,23655918	88,62017911	5,44060989
14	79,94684157	91,45310369	7,37373097
15	79,98617653	86,12414146	4,19369333
16	82,97751836	91,44914790	5,97079628
17	79,32592008	87,93814793	5,85465857
18	82,44587759	91,22491694	6,05544559

No gráfico 3.5 estão dispostos os 450 resultados obtidos nas simulações. Nele é pode-se observar em destaque a melhor solução encontrada na 38ª execução da simulação 11, através do Algoritmo SIGA(1,1).

Gráfico 3.5 – Gráfico de dispersão para os resultados das simulações do problema  $f_6$ .

Todos os resultados foram organizados em ordem crescente e, assim, é possível observar a distribuição dos algoritmos vitoriosos em todos os 450 testes e distribuídos em dez faixas, de acordo com a tabela 3.5.

Tabela 3.5 – Distribuição dos algoritmos vitoriosos para o problema  $f_6$ .

Faixas de Testes		AG		SIGA				F-SIGA				ESIA(SIGA)				ESIA(F-SIGA)			
				(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)	
%	Ordem	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%								
[0, 10]	1 a 45	8	18%	7	16%	2	4%	5	11%	3	7%	12	27%	0	0%	7	16%	1	2%
[11, 20]	46 a 90	2	4%	8	18%	2	4%	5	11%	4	9%	10	22%	2	4%	8	18%	4	9%
[21, 30]	90 a 135	7	16%	8	18%	4	9%	6	13%	4	9%	3	7%	2	4%	6	13%	5	11%
[31, 40]	136 a 180	7	16%	6	13%	5	11%	3	7%	2	4%	6	13%	10	22%	2	4%	4	9%
[41, 50]	181 a 225	5	11%	4	9%	5	11%	6	13%	4	9%	5	11%	4	9%	7	16%	5	11%
[51, 60]	226 a 270	6	13%	8	18%	2	4%	7	16%	7	16%	2	4%	4	9%	5	11%	4	9%
[61, 70]	271 a 315	3	7%	3	7%	7	16%	5	11%	4	9%	5	11%	7	16%	7	16%	4	9%
[71, 80]	316 a 360	2	4%	4	9%	7	16%	6	13%	4	9%	4	9%	8	18%	3	7%	7	16%
[81, 90]	361 a 405	3	7%	2	4%	6	13%	4	9%	10	22%	2	4%	6	13%	2	4%	10	22%
[91, 100]	406 a 450	7	16%	0	0%	10	22%	3	7%	8	18%	1	2%	7	16%	3	7%	6	13%

Os resultados dos primeiros 20% melhores resultados, ou seja, os 90 primeiros testes podem ser visualizados também através do gráfico 3.6. Nele são apresentados os valores referentes à distribuição dos algoritmos vitoriosos.

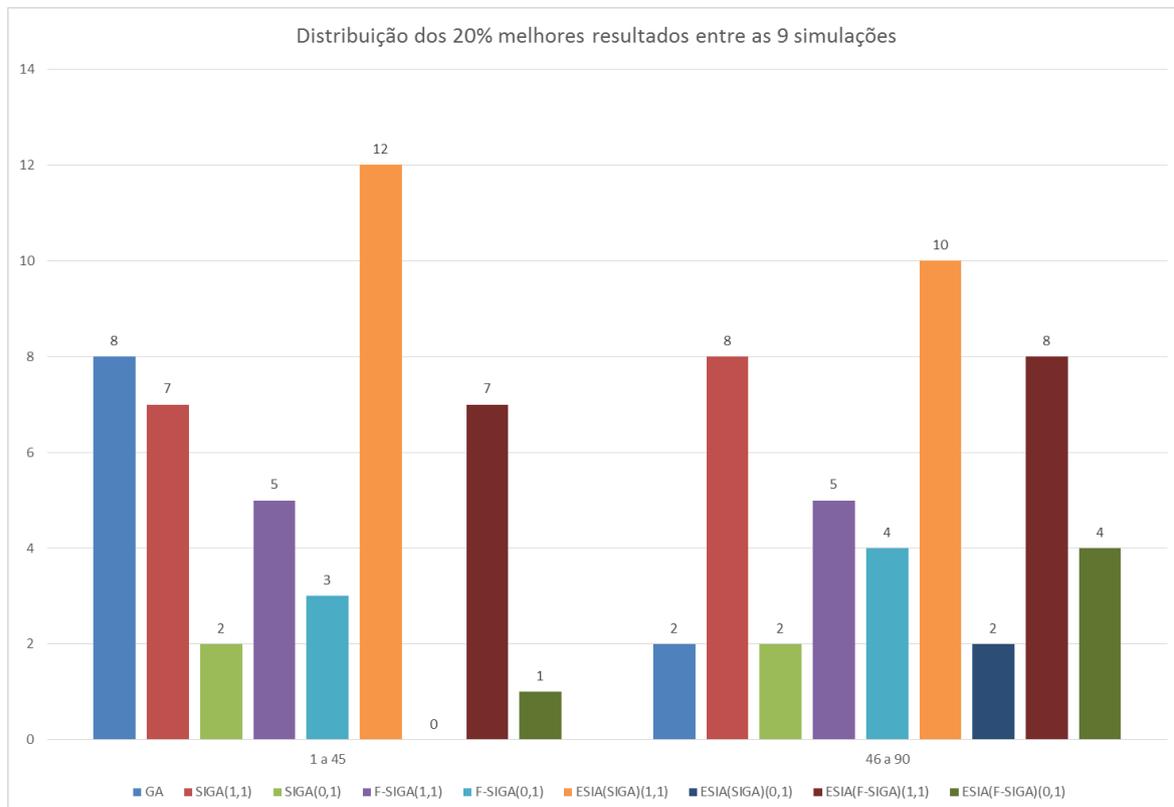


Gráfico 3.6 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema  $f_6$ .

A partir desses resultados é possível observar os seguintes fatos para os 45 melhores resultados, o que representam os 10% melhores:

- Os Algoritmos Genéticos obtiveram os melhores resultados em 8 testes, ou seja, 17,7% dos resultados;
- Os algoritmos de Interação Social obtiveram os melhores resultados nos 37 testes restantes, ou seja, 82,2% dos resultados;
- O algoritmo SIGA foi vitorioso em 9 testes, ou seja, 20% dos resultados;
- O algoritmo F-SIGA foi vitorioso em 8 testes, ou seja, 17,7% dos resultados;
- Os algoritmos (1,1) obtiveram os melhores resultados em 31 testes, ou seja, 68,8% dos resultados;
- Os algoritmos (0,1) obtiveram os melhores resultados em 6 testes, ou seja, 13,3% dos resultados;
- Os algoritmos ESIA obtiveram os melhores resultados também em 20 testes, ou seja, 44,4% dos resultados.

### 3.2.3. Função $f_8$ - Shifted Rotated Ackley's Function with Global Optimum on Bounds

O outro problema multimodal é a função  $f_8$ , *Shifted Rotated Ackley's Function with Global Optimum on Bounds*, que está expressa na equação (30) e pode ser visualizada através do gráfico 3.5.

$$f_8(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e \quad (30)$$

Onde:  $x \in [-32, 32]^n$ ,  $n = 30$ , e o ótimo global é igual a 0.

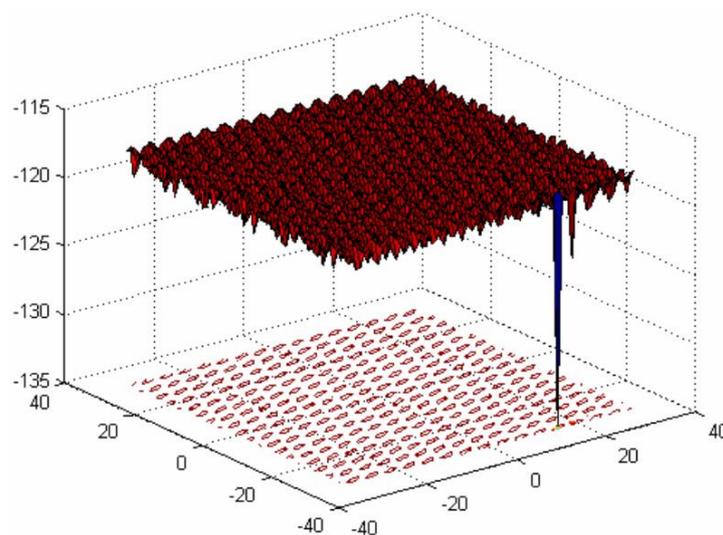


Gráfico 3.7 – Visualização da função  $f_8$ .

Fonte: SUGANTHAN et al. (2005)

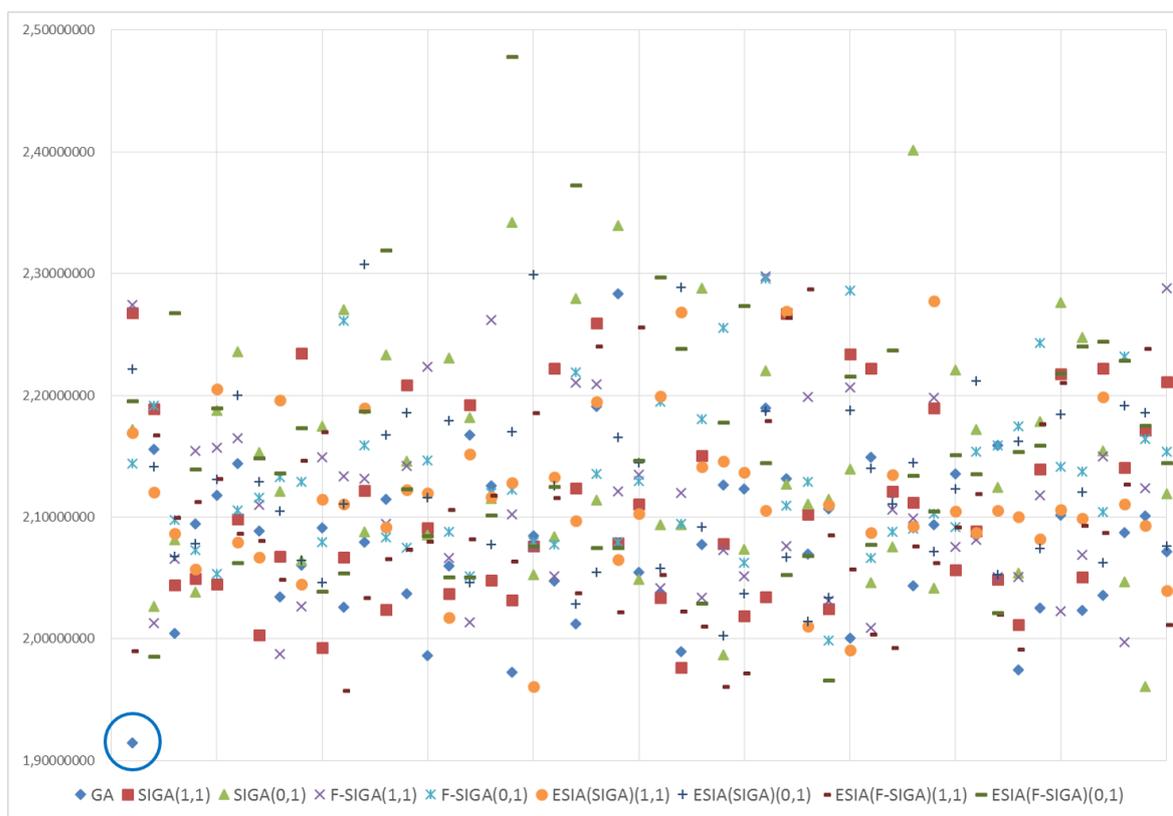
Foram realizadas um total de 9 simulações para esta função, sendo cada uma delas executadas cinquenta vezes (e01 a e50), o que totalizaram 450 testes, conforme podem ser vistos os respectivos resultados nas tabelas F.3 (a), (b), (c), (d) e (e).

E a seguir, na tabela 3.6, são visualizados os melhores resultados, a média e o desvio padrão para cada uma das simulações, com destaque para o melhor resultado obtido,  $f_8(x) = 1,91433695$ , que está distante ao valor ótimo,  $f_8^*(x) = 0$ .

Tabela 3.6 – Melhor resultado, média e desvio padrão para o problema  $f_8$ .

Simulações	Melhor Resolução	Média	Desvio Padrão
19	1,91433695	2,08006856	0,06652637
20	1,97660317	2,11219603	0,08224653
21	1,96103579	2,14462767	0,09566871
22	1,98740211	2,11288609	0,07843770
23	1,99871386	2,13321418	0,06407608
24	1,96109746	2,11681624	0,06511805
25	2,00251211	2,12485838	0,07219426
26	1,95723561	2,09333075	0,08158508
27	1,96604310	2,15097642	0,09912982

No gráfico 3.8 estão dispostos os 450 resultados obtidos nas simulações. Nele é pode-se observar em destaque a melhor solução encontrada na primeira execução da simulação 19, através do Algoritmo Genético.

Gráfico 3.8 – Gráfico de dispersão para os resultados das simulações do problema  $f_8$ .

Todos os resultados foram organizados em ordem crescente e, assim, é possível observar a distribuição dos algoritmos vitoriosos em todos os 450 testes e distribuídos em dez faixas, de acordo com a tabela 3.7.

Tabela 3.7 – Distribuição dos algoritmos vitoriosos para o problema  $f_8$ .

Faixas de Testes		AG		SIGA				F-SIGA				ESIA(SIGA)				ESIA(F-SIGA)			
				(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)	
%	Ordem	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%								
[0, 10]	1 a 45	9	20%	6	13%	2	4%	6	13%	1	2%	4	9%	2	4%	12	27%	3	7%
[11, 20]	46 a 90	8	18%	11	24%	6	13%	6	13%	0	0%	2	4%	5	11%	3	7%	4	9%
[21, 30]	90 a 135	5	11%	3	7%	4	9%	6	13%	5	11%	3	7%	9	20%	6	13%	4	9%
[31, 40]	136 a 180	5	11%	3	7%	5	11%	4	9%	8	18%	5	11%	3	7%	7	16%	5	11%
[41, 50]	181 a 225	7	16%	4	9%	2	4%	5	11%	8	18%	11	24%	2	4%	4	9%	2	4%
[51, 60]	226 a 270	6	13%	5	11%	7	16%	4	9%	3	7%	8	18%	6	13%	4	9%	2	4%
[61, 70]	271 a 315	3	7%	2	4%	3	7%	5	11%	9	20%	6	13%	6	13%	3	7%	8	18%
[71, 80]	316 a 360	4	9%	2	4%	7	16%	4	9%	7	16%	2	4%	8	18%	5	11%	6	13%
[81, 90]	361 a 405	2	4%	9	20%	5	11%	6	13%	4	9%	6	13%	6	13%	1	2%	6	13%
[91, 100]	406 a 450	1	2%	5	11%	9	20%	4	9%	5	11%	3	7%	3	7%	5	11%	10	22%

Os resultados dos primeiros 20% melhores resultados, ou seja, os 90 primeiros testes podem ser visualizados também através do gráfico 3.9. Nele são apresentados os valores referentes à distribuição dos algoritmos vitoriosos.

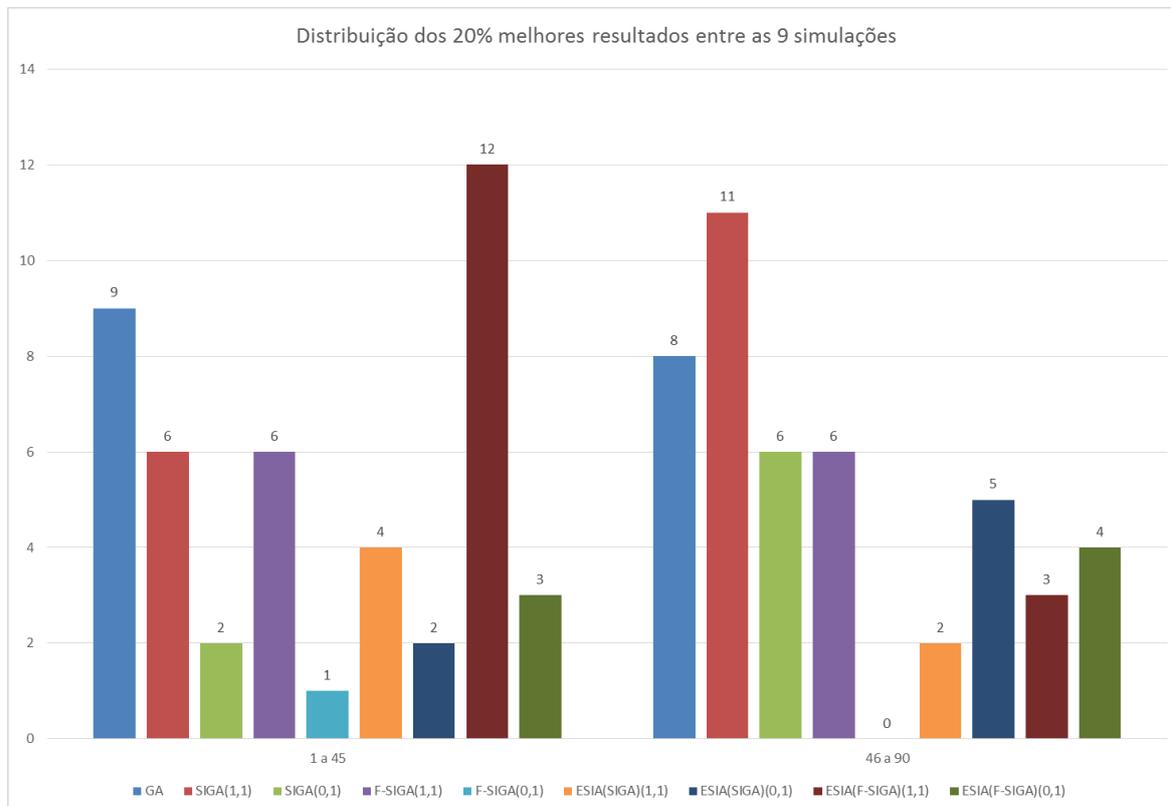


Gráfico 3.9 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema  $f_8$ .

A partir desses resultados é possível observar os seguintes fatos para os 45 melhores resultados, o que representam os 10% melhores:

- Os Algoritmos Genéticos obtiveram os melhores resultados em 9 testes, ou seja, 20% dos resultados;
- Os algoritmos de Interação Social obtiveram os melhores resultados nos 36 testes restantes, ou seja, 80% dos resultados;
- O algoritmo SIGA foi vitorioso em 8 testes, ou seja, 17,7% dos resultados;
- O algoritmo F-SIGA foi vitorioso em 7 testes, ou seja, 15,5% dos resultados;
- Os algoritmos (1,1) obtiveram os melhores resultados em 28 testes, ou seja, 62,2% dos resultados;
- Os algoritmos (0,1) obtiveram os melhores resultados em 8 testes, ou seja, 17,7% dos resultados;
- Os algoritmos ESIA obtiveram os melhores resultados também em 21 testes, ou seja, 46,6% dos resultados.

### 3.3. PROBLEMAS DE OTIMIZAÇÃO GLOBAL COM RESTRIÇÕES

Uma característica comumente encontrada em problemas de otimização na área de engenharia é a presença de restrições, que podem estar associadas ao intervalo que uma determinada variável pode adotar ou a relação existente entre as variáveis. Assim, um problema de otimização global com restrições pode ser formalizado da seguinte forma.

$$\text{Otimizar } f(x) \quad (31)$$

Sujeito a:

$$g(x) \leq 0 \quad (32)$$

$$h(x) = 0 \quad (33)$$

Onde  $x \in \mathbb{R}^n$  é referida como a solução;  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  é a função objetivo;  $g: \mathbb{R}^n \rightarrow \mathbb{R}$  e  $h: \mathbb{R}^n \rightarrow \mathbb{R}$  são respectivamente as funções com restrições de desigualdade e igualdade.

#### 3.3.1. Projeto de Viga de Aço<sup>31</sup>

Segundo RAO (1996), este problema objetiva minimizar o custo de fabricação de uma viga de aço, que está sujeita a algumas restrições, tais como: tensão do cisalhamento, esforços de flexão na viga, flambagem de carga na barra e, deflexão do feixe de extremidade e restrições laterais. Além disso, são definidas quatro variáveis: (1) espessura da solda ( $h$ ); (2) largura do feixe ( $t$ ); (3) espessura da viga ( $b$ ); (4) comprimento da junta soldada ( $l$ ), conforme pode ser visto na figura 3.1.

Este problema pode ser formalizado da seguinte forma:

$$\text{Minimizar } f(x) = 1.10471h^2t + 0.04811bl(14.0 + t) \quad (34)$$

---

<sup>31</sup> Em inglês: *Welded Beam Designer* (WBD).

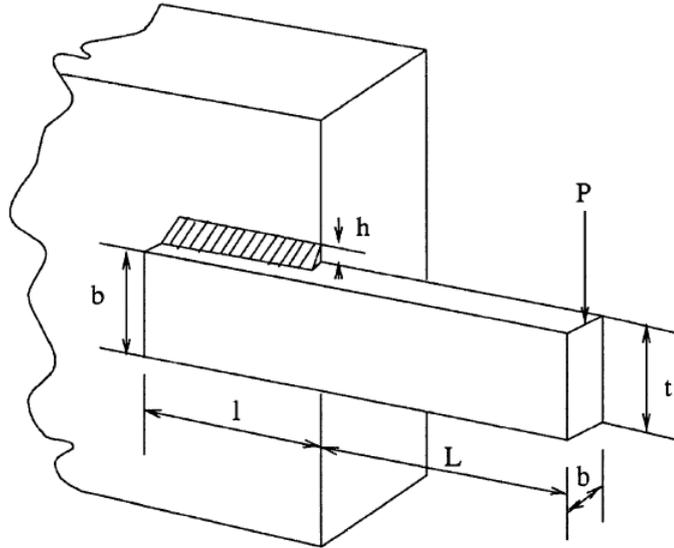


Figura 3.1 – Projeto de viga de aço.

Fonte: ALFARES e ESAT (2007)

Sujeito a:

$$g_1 = \tau - \tau_{max} \leq 0 \quad (35)$$

$$g_2 = \sigma - \sigma_{max} \leq 0 \quad (36)$$

$$g_3 = h - b \leq 0 \quad (37)$$

$$g_4 = 0.10471h^2 + 0.04811tb(14.0 + l) - 5.0 \leq 0 \quad (38)$$

$$g_5 = 0.125 - h \leq 0 \quad (39)$$

$$g_6 = \delta - \delta_{max} \leq 0 \quad (40)$$

$$g_7 = P - P_c \leq 0 \quad (41)$$

Onde:

$$\tau = \sqrt{(\tau')^2 + 2\tau'\tau'' \frac{1}{2R} + (\tau'')^2} \quad (42)$$

$$\tau' = \frac{P}{\sqrt{2}hl} \quad (43)$$

$$\tau'' = \frac{MR}{J} \quad (44)$$

$$M = P \left( L + \frac{1}{2} \right) \quad (45)$$

$$R = \sqrt{\frac{t^2}{4} + \left( \frac{h+t}{2} \right)^2} \quad (46)$$

$$J = 2 \left\{ \sqrt{2}hl \left[ \frac{t^2}{12} + \left( \frac{h+t}{2} \right)^2 \right] \right\} \quad (47)$$

$$\sigma = \frac{6PL}{bt^2} \quad (48)$$

$$\delta = \frac{4PL^3}{Eb^3} \quad (49)$$

$$P_c = \frac{4.013E \sqrt{\frac{t^2 b^6}{36}}}{L^2} + \left( 1 - \frac{t}{2L} \sqrt{\frac{E}{4G}} \right) \quad (50)$$

Além disso, os seguintes valores foram considerados:  $P = 6000lb$ ,  $L = 14in$ ,  $E = 30 \times 10^6 psi$ ,  $G = 12 \times 10^6 psi$ ,  $\tau_{max} = 13600 psi$ ,  $\sigma_{max} = 30000 psi$ ,  $\delta_{max} = 0.25in$  e os intervalos de valores para cada uma das quatro variáveis:  $0.1 \leq h \leq 2.0$ ;  $0.1 \leq l \leq 10.0$ ;  $0.1 \leq t \leq 10.0$ ;  $0.1 \leq b \leq 2.0$ .

Foram realizadas um total de 9 simulações para esta função, sendo cada uma delas executadas cinquenta vezes (e01 a e50), o que totalizaram 450 testes, conforme podem ser vistos os respectivos resultados nas tabelas G.1 (a), (b), (c), (d) e (e).

E a seguir, na tabela 3.8, são visualizados os melhores resultados, a média e o desvio padrão para cada uma das simulações, com destaque para o melhor resultado obtido,  $f(x) = 1,66437300$ .

Tabela 3.8 – Melhor resultado, média e desvio padrão para o problema *WBD*.

Simulações	Melhor Resultado	Média	Desvio Padrão
55	1,69687100	2,04494888	0,34321999
56	1,69090800	2,07288242	0,28189515
57	1,66437300	2,08438766	0,33920156
58	1,67052600	2,12128378	0,37559960
59	1,69178400	2,08878454	0,32196741
60	1,69287700	2,04614950	0,31755734
61	1,67616800	2,04341006	0,37748051
62	1,67614900	2,08517274	0,33739870
63	1,67032100	2,06626552	0,30756600

No gráfico 3.10 estão dispostos os 450 resultados obtidos nas simulações. Nele é pode-se observar em destaque a melhor solução encontrada na 7ª execução da simulação 57, através do Algoritmo SIGA(0,1).

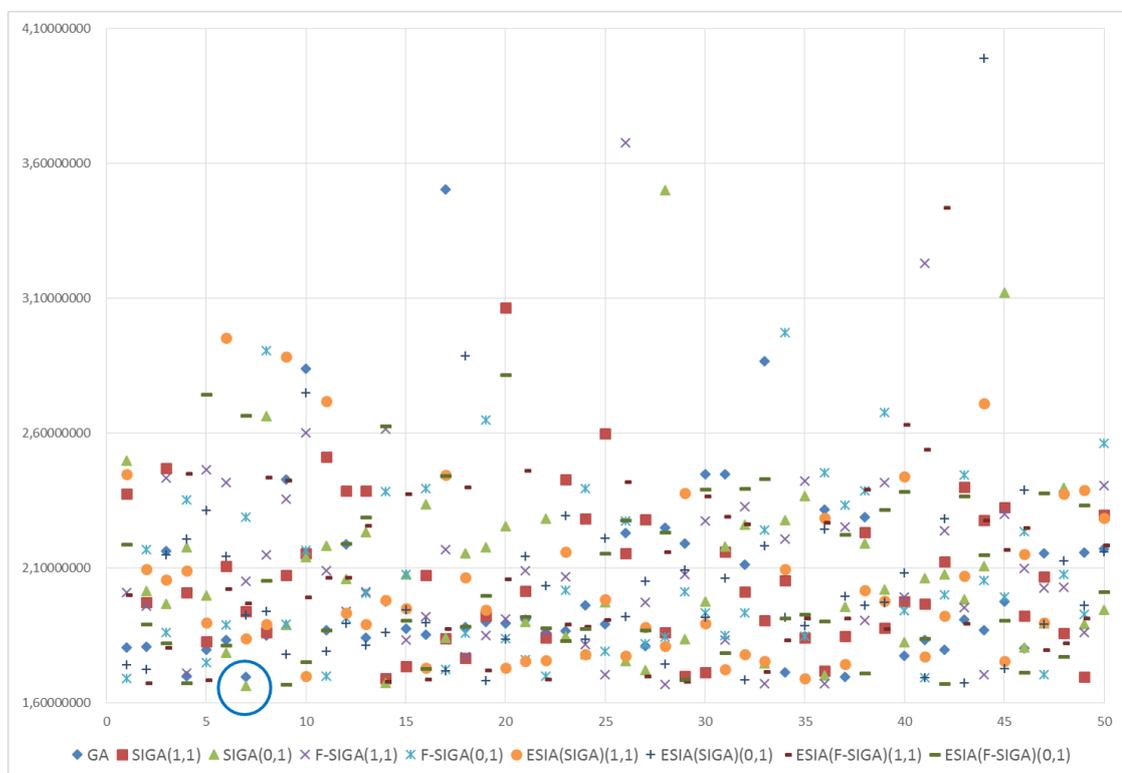


Gráfico 3.10 – Gráfico de dispersão para os resultados das simulações do problema *WBD*.

Todos os resultados foram organizados em ordem crescente e, assim, é possível observar a distribuição dos algoritmos vitoriosos em todos os 450 testes e distribuídos em dez faixas, de acordo com a tabela 3.9.

Tabela 3.9 – Distribuição dos algoritmos vitoriosos para o problema *WBD*.

Faixas de Testes		AG		SIGA				F-SIGA				ESIA(SIGA)				ESIA(F-SIGA)			
				(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)	
%	Ordem	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%								
[0, 10]	1 a 45	4	9%	5	11%	3	7%	6	13%	5	11%	2	4%	5	11%	9	20%	6	13%
[11, 20]	46 a 90	7	16%	2	4%	6	13%	1	2%	4	9%	13	29%	6	13%	2	4%	4	9%
[21, 30]	90 a 135	8	18%	8	18%	4	9%	6	13%	7	16%	1	2%	4	9%	2	4%	5	11%
[31, 40]	136 a 180	9	20%	2	4%	4	9%	2	4%	2	4%	6	13%	4	9%	7	16%	9	20%
[41, 50]	181 a 225	4	9%	6	13%	5	11%	5	11%	5	11%	6	13%	9	20%	3	7%	2	4%
[51, 60]	226 a 270	0	0%	7	16%	6	13%	7	16%	7	16%	5	11%	4	9%	6	13%	3	7%
[61, 70]	271 a 315	5	11%	5	11%	9	20%	6	13%	3	7%	5	11%	8	18%	2	4%	2	4%
[71, 80]	316 a 360	5	11%	5	11%	6	13%	5	11%	4	9%	2	4%	5	11%	7	16%	6	13%
[81, 90]	361 a 405	3	7%	6	13%	3	7%	7	16%	6	13%	3	7%	2	4%	7	16%	8	18%
[91, 100]	406 a 450	5	11%	4	9%	4	9%	5	11%	7	16%	7	16%	3	7%	5	11%	5	11%

Os resultados dos primeiros 20% melhores resultados, ou seja, os 90 primeiros testes podem ser visualizados também através do gráfico 3.11, Nele são apresentados os valores referentes à distribuição dos algoritmos vitoriosos.

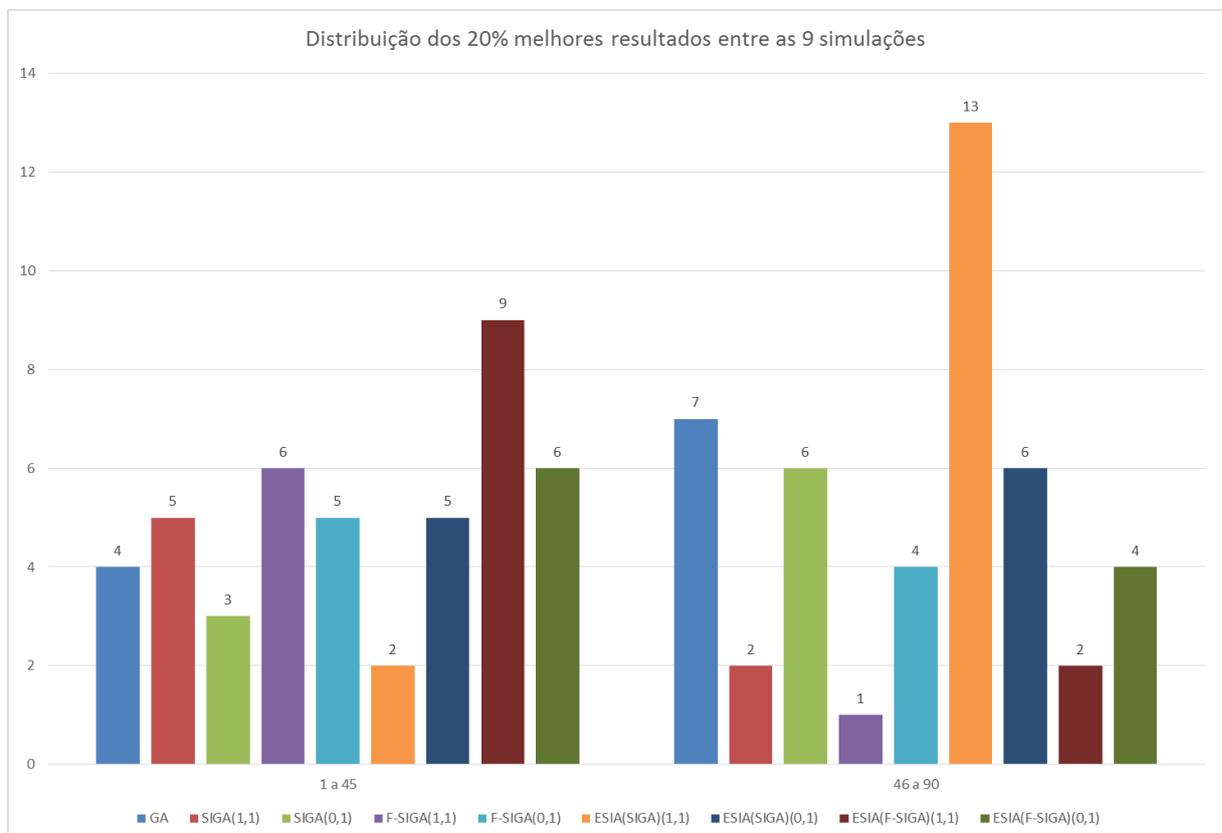


Gráfico 3.11 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema *WBD*.

A partir desses resultados é possível observar os seguintes fatos para os 45 melhores resultados, o que representam os 10% melhores:

- Os Algoritmos Genéticos obtiveram os melhores resultados em 4 testes, ou seja, 8,8% dos resultados;
- Os algoritmos de Interação Social obtiveram os melhores resultados nos 41 testes restantes, ou seja, 91,1% dos resultados;
- O algoritmo SIGA foi vitorioso em 8 testes, ou seja, 17,7% dos resultados;
- O algoritmo F-SIGA foi vitorioso em 11 testes, ou seja, 24,4% dos resultados;
- Os algoritmos (1,1) obtiveram os melhores resultados em 22 testes, ou seja, 48,8% dos resultados;
- Os algoritmos (0,1) obtiveram os melhores resultados em 19 testes, ou seja, 42,2% dos resultados;
- Os algoritmos ESIA obtiveram os melhores resultados também em 22 testes, ou seja, 48,8% dos resultados.

Além disso, é possível estabelecer uma comparação dos resultados obtidos nessas simulações com resultados presentes na literatura, mais especificamente em DEB (1991); COELLO (2000); COELLO e MONTES (2002); HE e WANG (2007), conforme pode ser visto na tabela 3.10. E, assim, o SIGA obteve o melhor resultado.

Tabela 3.10 – Resultados comparativos para o problema WBD.

Variáveis de Projeto	SIGA	HE e WANG (2007)	COELLO e MONTES (2002)	COELLO (2000)	DEB (1991)
$x_1(h)$	0,171937	0,202369	0,205986	0,208800	0,248900
$x_2(l)$	4,122129	3,544214	3,471328	3,420500	6,173000
$x_3(t)$	9,587429	9,048210	9,020224	8,997500	8,178900
$x_4(b)$	0,183010	0,205723	0,206480	0,210000	0,253300
$g_1(x)$	-8,067400	-12,839796	-0,074092	-0,337812	-5758,603777

Variáveis de Projeto	SIGA	HE e WANG (2007)	COELLO e MONTES (2002)	COELLO (2000)	DEB (1991)
$g_2(x)$	-39,336800	-1,247467	-0,266227	-353,902604	-255,576901
$g_3(x)$	-0,011070	-0,001498	-0,000495	-0,001200	-0,004400
$g_4(x)$	-3,467150	-3,429347	-3,430043	-3,411865	-2,982866
$g_5(x)$	-0,236390	-0,079381	-0,080986	-0,083800	-0,123900
$g_6(x)$	-16,024300	-0,235536	-0,235514	-0,235649	-0,234160
$g_7(x)$	-0,046940	-11,681355	-58,666440	-363,232384	-4465,270928
$f(x)$	<b>1,664373</b>	<b>1,728024</b>	<b>1,728226</b>	<b>1,748309</b>	<b>2,433116</b>

### 3.3.2. Projeto de Vaso de Pressão<sup>32</sup>

Este problema tem por objetivo minimizar o custo total, incluindo o custo do material, modelagem e soldagem, de um recipiente cilíndrico, que é limitado em suas extremidades por cabeças hemisféricas.

Ele é composto por quatro variáveis de projeto, que são: espessura da casca ( $T_s$ ,  $x_1$ ), espessura da cabeça ( $T_h$ ,  $x_2$ ), raio interno ( $R$ ,  $x_3$ ) e comprimento da seção cilíndrica do recipiente ( $L$ ,  $x_4$ ), não incluindo a cabeça, conforme pode ser visto na figura 3.2.

É importante observar que os valores para as variáveis  $T_s$  e  $T_h$  são múltiplos de 0.0625 polegadas, pois se referem às espessuras de chapas de aço laminadas; e,  $R$  e  $L$  são variáveis contínuas.

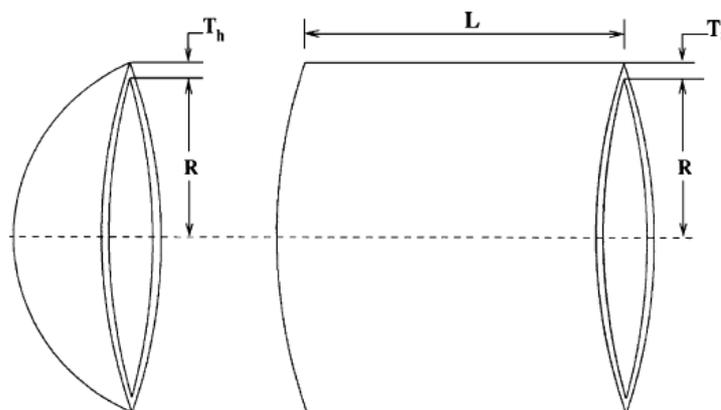


Figura 3.2 – Projeto de vaso de pressão.

Fonte: HE e WANG (2007)

<sup>32</sup> Em inglês: *Design of a Pressure Vessel (DPV)*.

Este problema pode ser formulado da seguinte forma:

$$\text{Minimizar } f(x) = 0.6224x_1x_3x_4 + 1.7781x_2x_3^2 + 3.1661x_1^2x_4 + 19.84x_1^2x_3 \quad (51)$$

Sujeito a:

$$g_1 = -x_1 + 0.0193x_3 \leq 0 \quad (52)$$

$$g_2 = -x_2 + 0.00954x_3 \leq 0 \quad (53)$$

$$g_3 = -\pi x_3^2 x_4 - \frac{4}{3} \pi x_3^3 + 1296000 \leq 0 \quad (54)$$

$$g_4 = x_4 - 240 \leq 0 \quad (55)$$

Além disso, os seguintes intervalos de valores foram utilizados para cada uma das quatro variáveis:  $1 \times 0.0625 \leq x_1 \leq 99 \times 0.0625$ ;  $1 \times 0.0625 \leq x_2 \leq 99 \times 0.0625$ ;  $10 \leq x_3 \leq 200$ ;  $10 \leq x_4 \leq 200$ .

Foram realizadas um total de 9 simulações para esta função, sendo cada uma delas executadas cinquenta vezes (e01 a e50), o que totalizaram 450 testes, conforme podem ser vistos os respectivos resultados nas tabelas G.2 (a), (b), (c), (d) e (e).

E a seguir, na tabela 3.11, são visualizados os melhores resultados, a média e o desvio padrão para cada uma das simulações, com destaque para o melhor resultado obtido,  $f(x) = 6.066,02936000$ .

Tabela 3.11 – Melhor resultado, média e desvio padrão para o problema *DPV*.

<b>Simulações</b>	<b>Melhor Resultado</b>	<b>Média</b>	<b>Desvio Padrão</b>
<b>28</b>	6.847,86491100	8.523,89713616	748,25551878
<b>29</b>	6.795,38158200	8.518,28001426	697,53316745
<b>30</b>	7.164,01994600	8.730,15512360	493,36825739
<b>31</b>	6.823,66228700	8.533,33908468	566,20234309
<b>32</b>	6.826,71964300	8.808,09940880	596,42543304
<b>33</b>	<b>6.066,02936000</b>	8.375,08067672	757,44573032
<b>34</b>	6.839,31443900	8.727,56833414	530,30538614
<b>35</b>	6.814,37506800	8.439,40942366	744,02994645
<b>36</b>	6.746,17890700	8.567,42237880	618,67355312

No gráfico 3.12 estão dispostos os 450 resultados obtidos nas simulações. Nele é pode-se observar em destaque a melhor solução encontrada na 46ª execução da simulação 33, através do Algoritmo ESIA(SIGA)(1,1).

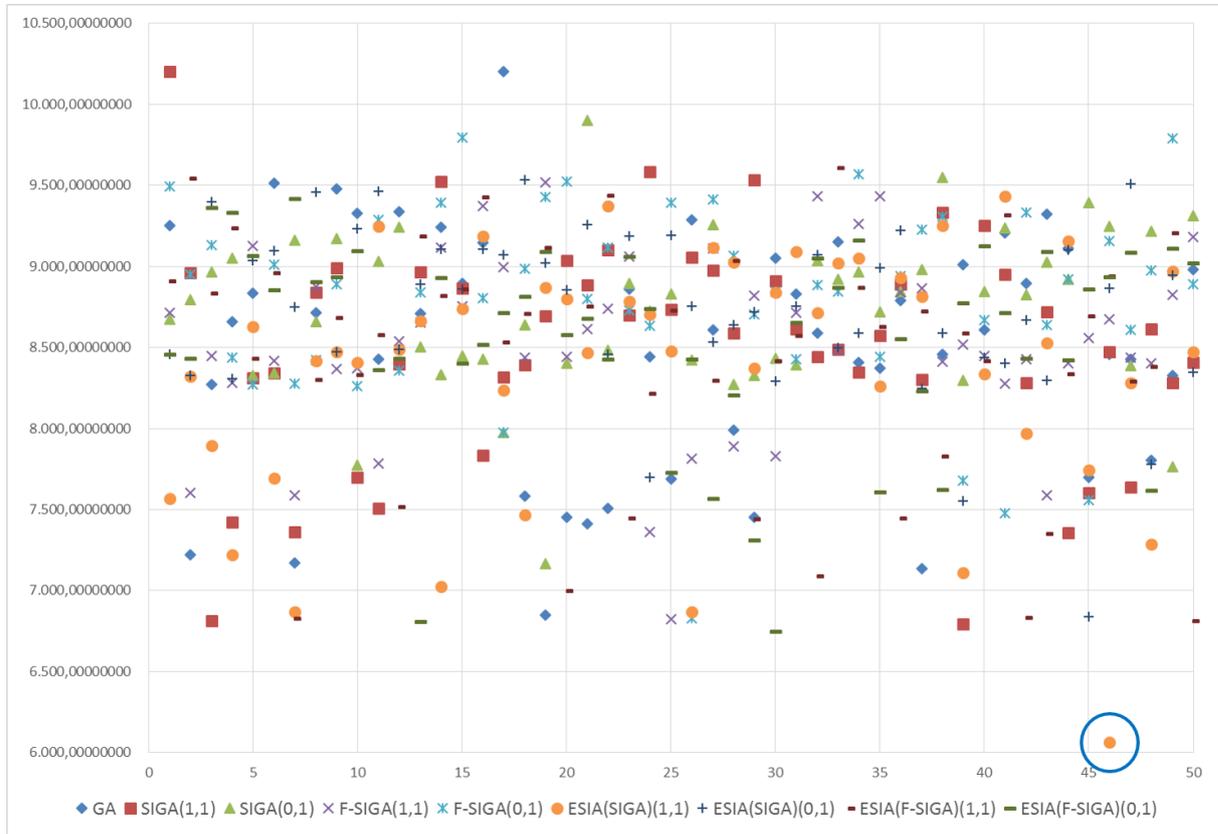


Gráfico 3.12 – Gráfico de dispersão para os resultados das simulações do problema DPV.

Todos os resultados foram organizados em ordem crescente e, assim, é possível observar a distribuição dos algoritmos vitoriosos em todos os 450 testes e distribuídos em dez faixas, de acordo com a tabela 3.12.

Tabela 3.12 – Distribuição dos algoritmos vitoriosos para o problema WBD.

Faixas de Testes		AG		SIGA				F-SIGA				ESIA(SIGA)				ESIA(F-SIGA)			
				(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)	
%	Ordem	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%								
[0, 10]	1 a 45	8	18%	6	13%	1	2%	2	4%	3	7%	9	20%	2	4%	10	22%	4	9%
[11, 20]	46 a 90	6	13%	4	9%	4	9%	8	18%	5	11%	7	16%	3	7%	2	4%	6	13%
[21, 30]	90 a 135	3	7%	10	22%	8	18%	5	11%	1	2%	4	9%	6	13%	6	13%	2	4%
[31, 40]	136 a 180	5	11%	2	4%	5	11%	9	20%	4	9%	5	11%	4	9%	4	9%	7	16%
[41, 50]	181 a 225	4	9%	5	11%	4	9%	6	13%	4	9%	4	9%	7	16%	6	13%	5	11%
[51, 60]	226 a 270	4	9%	4	9%	5	11%	6	13%	4	9%	6	13%	4	9%	7	16%	5	11%
[61, 70]	271 a 315	4	9%	6	13%	5	11%	3	7%	8	18%	3	7%	5	11%	4	9%	7	16%
[71, 80]	316 a 360	3	7%	7	16%	7	16%	2	4%	5	11%	5	11%	6	13%	2	4%	8	18%
[81, 90]	361 a 405	7	16%	1	2%	7	16%	5	11%	5	11%	5	11%	8	18%	4	9%	3	7%
[91, 100]	406 a 450	6	13%	5	11%	4	9%	4	9%	11	24%	2	4%	5	11%	5	11%	3	7%

Os resultados dos primeiros 20% melhores resultados, ou seja, os 90 primeiros testes podem ser visualizados também através do gráfico 3.13, Nele são apresentados os valores referentes à distribuição dos algoritmos vitoriosos.

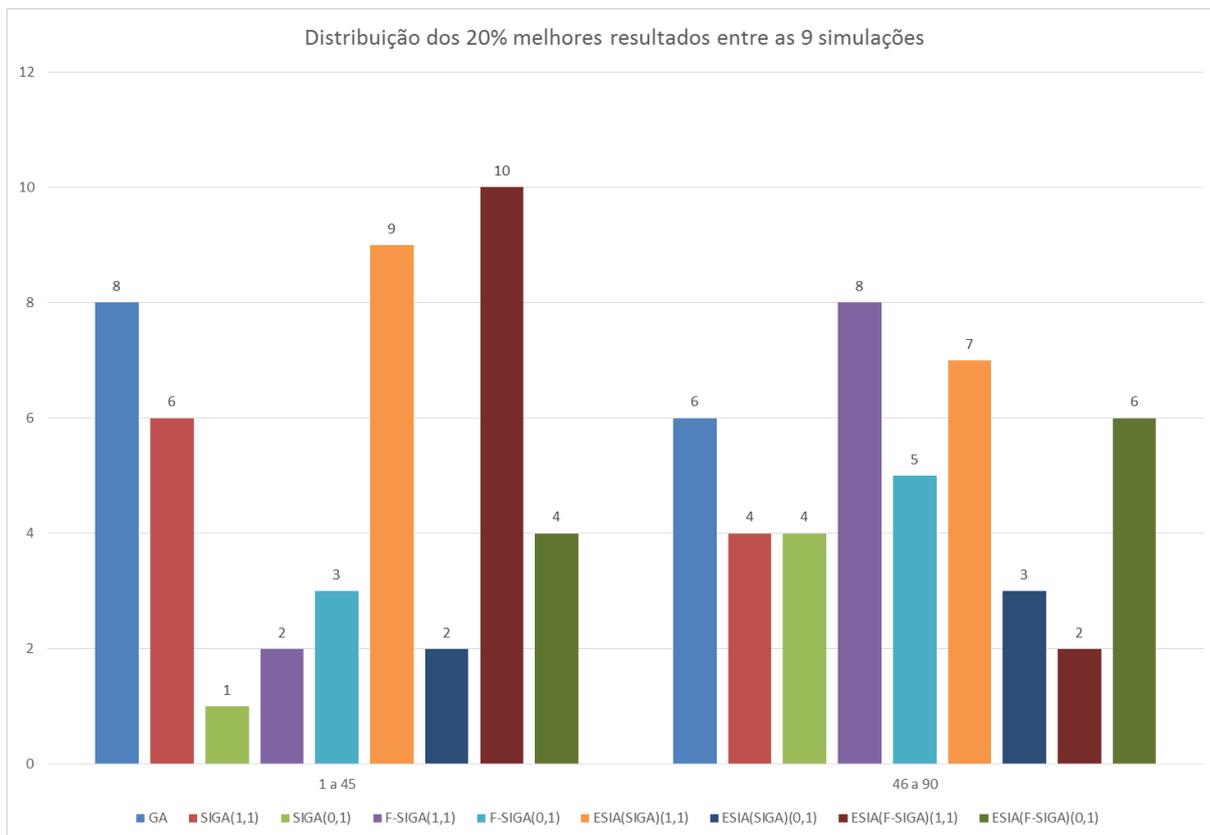


Gráfico 3.13 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema *WBD*.

A partir desses resultados é possível observar os seguintes fatos para os 45 melhores resultados, o que representam os 10% melhores:

- Os Algoritmos Genéticos obtiveram os melhores resultados em 8 testes, ou seja, 17,7% dos resultados;
- Os algoritmos de Interação Social obtiveram os melhores resultados nos 37 testes restantes, ou seja, 82,2% dos resultados;
- O algoritmo SIGA foi vitorioso em 7 testes, ou seja, 15,5% dos resultados;

- O algoritmo F-SIGA foi vitorioso em 5 testes, ou seja, 11,1% dos resultados;
- Os algoritmos (1,1) obtiveram os melhores resultados em 27 testes, ou seja, 60% dos resultados;
- Os algoritmos (0,1) obtiveram os melhores resultados em 10 testes, ou seja, 22,2% dos resultados;
- Os algoritmos ESIA obtiveram os melhores resultados também em 25 testes, ou seja, 55,5% dos resultados.

Além disso, é possível estabelecer uma comparação dos resultados obtidos nessas simulações com resultados presentes na literatura, mais especificamente em KANNAN e KRAMER (1994); DEB (1997); COELLO e MONTES (2002); HE e WANG (2007), conforme pode ser visto na tabela 3.13. O ESIA obteve o terceiro melhor resultado.

Tabela 3.13 – Resultados comparativos para o problema DPV.

Variáveis de Projeto	ESIA(SIGA)	HE e WANG (2007)	COELLO e MONTES (2002)	DEB (1997)	KANNAN e KRAMER (1994)
$x_1(Ts)$	0,812500	0,812500	0,812500	0,937500	1,125000
$x_2(Th)$	0,437500	0,437500	0,437500	0,500000	0,625000
$x_3(T)$	42,092732	42,091266	42,097398	48,329000	58,291000
$x_4(L)$	176,947780	176,746500	176,654050	112,679000	43,690000
$g_1(x)$	-0,000110	-0,000139	-0,000020	-0,004750	0,000016
$g_2(x)$	-0,035935	-0,035949	-0,035891	-0,038941	-0,068904
$g_3(x)$	-1337,994634	-116,382700	-27,886075	-3652,876838	-21,220104
$g_4(x)$	-63,052220	-63,253500	-63,345953	-127,321000	-196,310000
<b><math>f(x)</math></b>	<b>6066,029360</b>	<b>6061,077700</b>	<b>6059,946300</b>	<b>6410,381100</b>	<b>7198,042800</b>

### 3.3.3. Minimização do Peso da Tensão/Compressão sobre Mola<sup>33</sup>

Este problema tem por objetivo minimizar o peso da tensão/compressão sobre uma mola, que está sujeita a algumas restrições, tais como: deflexão mínima, tensão do

<sup>33</sup> Em inglês: *Minimization of Weight of Tension/Compression String (MWTCS)*.

cisalhamento, a frequência de onda, limites de diâmetro externo e variáveis de projeto, conforme pode ser visto em ARORA (1989) e BELEGUNDU (1982). As variáveis de projeto são: diâmetro do fio ( $d$ ,  $x_1$ ), a bobina de diâmetro médio ( $D$ ,  $x_2$ ) e o número de bobinas ativas ( $P$ ,  $x_3$ ), conforme pode ser visto na figura 3.3.

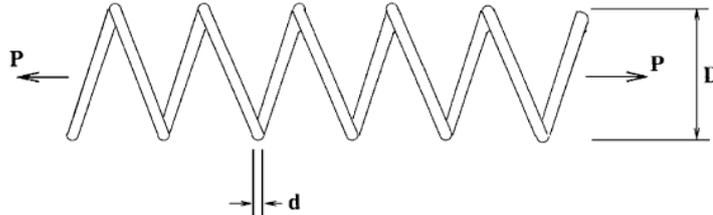


Figura 3.3 – Minimização do peso da tensão/compressão sobre mola.

Fonte: HE e WANG (2007)

Este problema pode ser formulado da seguinte forma:

$$\text{Minimizar } f(x) = (x_3 + 2)x_2x_1^2 \quad (56)$$

Sujeito a:

$$g_1 = 1 - \frac{x_2^3x_3}{71785x_1^4} \leq 0 \quad (57)$$

$$g_2 = \frac{4x_2^2 - x_1x_2}{12566(x_2x_1^3 - x_1^4)} + \frac{1}{5108x_1^2} - 1 \leq 0 \quad (58)$$

$$g_3 = 1 - \frac{140.45x_1}{x_2^2x_3} \leq 0 \quad (59)$$

$$g_4 = \frac{x_1 - x_2}{1.5} - 1 \leq 0 \quad (60)$$

Foram realizadas um total de 9 simulações para esta função, sendo cada uma delas executadas cinquenta vezes (e01 a e50), o que totalizaram 450 testes, conforme podem ser vistos os respectivos resultados nas tabelas G.3 (a), (b), (c), (d) e (e).

E a seguir, na tabela 3.14, são visualizados os melhores resultados, a média e o desvio padrão para cada uma das simulações, com destaque para o melhor resultado obtido,  $f(x) = 0.00283500$ .

Tabela 3.14 – Melhor resultado, média e desvio padrão para o problema *MWTCS*.

<b>Simulações</b>	<b>Melhor Resultado</b>	<b>Média</b>	<b>Desvio Padrão</b>
<b>37</b>	0,00283900	0,00290188	0,00007071
<b>38</b>	0,00283800	0,00289212	0,00004804
<b>39</b>	0,00283700	0,00288758	0,00003157
<b>40</b>	0,00283700	0,00288692	0,00005708
<b>41</b>	0,00283800	0,00289262	0,00006100
<b>42</b>	<b>0,00283500</b>	0,00288236	0,00005120
<b>43</b>	0,00284000	0,00289202	0,00005285
<b>44</b>	0,00283700	0,00289302	0,00005477
<b>45</b>	0,00283700	0,00287930	0,00005002

No gráfico 3.14 estão dispostos os 450 resultados obtidos nas simulações. Nele é pode-se observar em destaque a melhor solução encontrada na 25ª execução da simulação 42, através do Algoritmo ESIA(SIGA)(1,1).

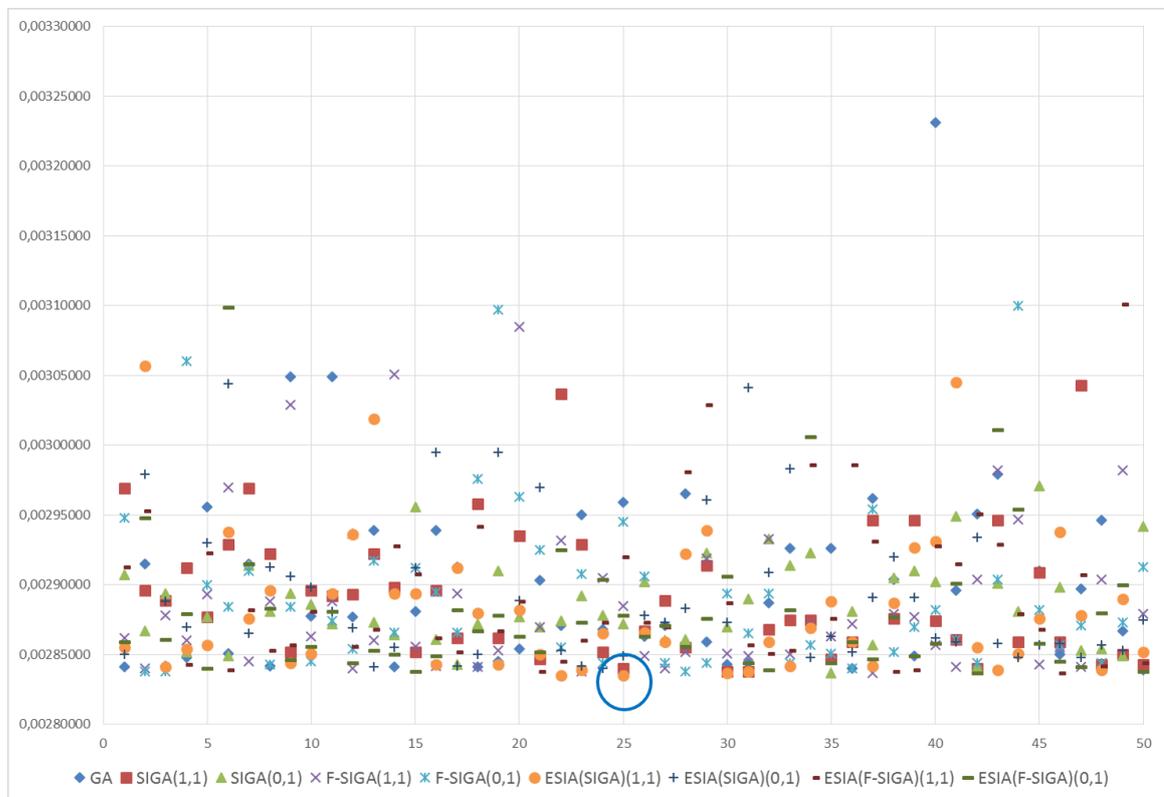


Gráfico 3.14 – Gráfico de dispersão para os resultados das simulações do problema *MWTCS*.

Todos os resultados foram organizados em ordem crescente e, assim, é possível observar a distribuição dos algoritmos vitoriosos em todos os 450 testes e distribuídos em dez faixas, de acordo com a tabela 3.15.

Tabela 3.15 – Distribuição dos algoritmos vitoriosos para o problema *MWTCS*.

Faixas de Testes		AG		SIGA				F-SIGA				ESIA(SIGA)				ESIA(F-SIGA)			
				(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)	
%	Ordem	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%								
[0, 10]	1 a 45	6	13%	4	9%	2	4%	8	18%	4	9%	8	18%	2	4%	5	11%	6	13%
[11, 20]	46 a 90	6	13%	4	9%	3	7%	4	9%	8	18%	5	11%	5	11%	4	9%	6	13%
[21, 30]	90 a 135	4	9%	5	11%	3	7%	6	13%	4	9%	7	16%	7	16%	4	9%	5	11%
[31, 40]	136 a 180	2	4%	6	13%	4	9%	7	16%	3	7%	4	9%	6	13%	6	13%	7	16%
[41, 50]	181 a 225	5	11%	3	7%	8	18%	3	7%	6	13%	3	7%	6	13%	6	13%	5	11%
[51, 60]	226 a 270	3	7%	4	9%	7	16%	4	9%	3	7%	5	11%	4	9%	5	11%	10	22%
[61, 70]	271 a 315	3	7%	8	18%	7	16%	5	11%	6	13%	7	16%	5	11%	2	4%	2	4%
[71, 80]	316 a 360	6	13%	5	11%	8	18%	4	9%	7	16%	2	4%	5	11%	5	11%	3	7%
[81, 90]	361 a 405	7	16%	6	13%	6	13%	3	7%	4	9%	6	13%	2	4%	8	18%	3	7%
[91, 100]	406 a 450	8	18%	5	11%	2	4%	6	13%	5	11%	3	7%	8	18%	5	11%	3	7%

Os resultados dos primeiros 20% melhores resultados, ou seja, os 90 primeiros testes podem ser visualizados também através do gráfico 3.15, Nele são apresentados os valores referentes à distribuição dos algoritmos vitoriosos.

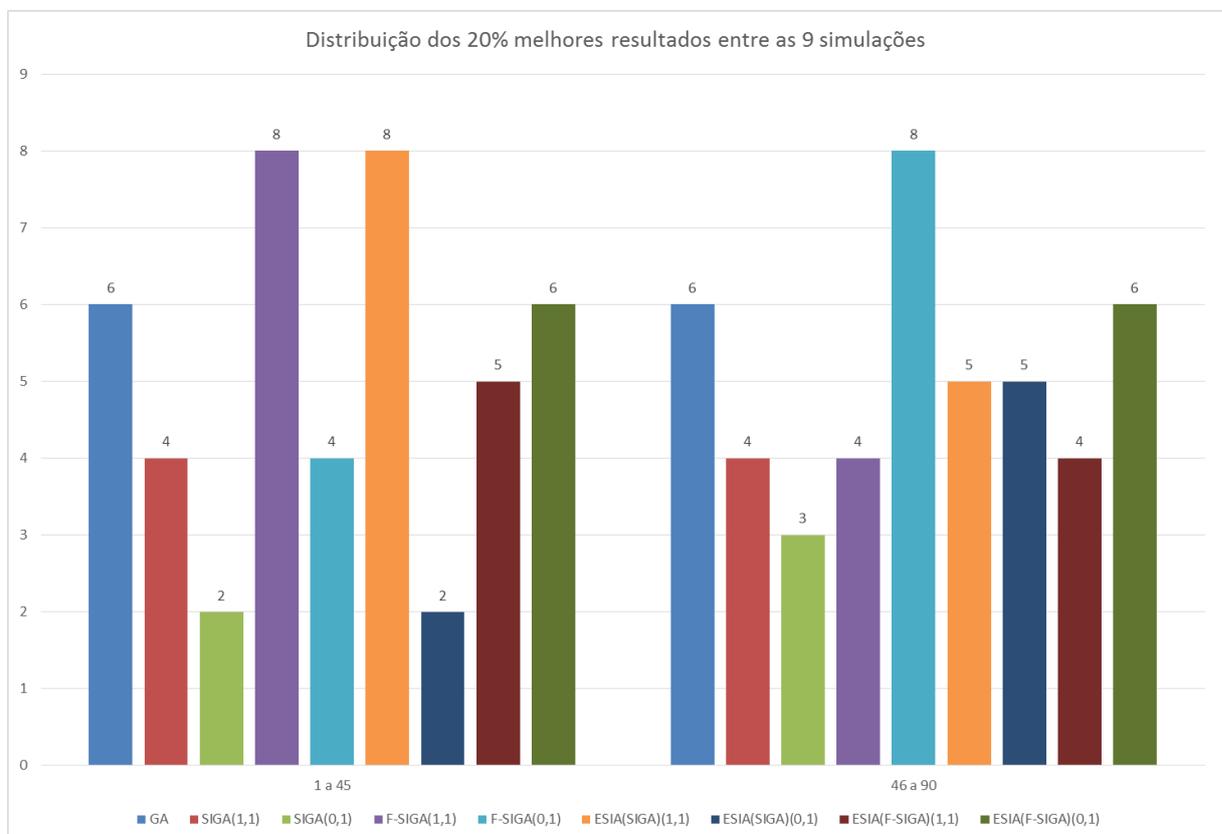


Gráfico 3.15 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema *MWTCS*.

A partir desses resultados é possível observar os seguintes fatos para os 45 melhores resultados, o que representam os 10% melhores:

- Os Algoritmos Genéticos obtiveram os melhores resultados em 6 testes, ou seja, 13,3% dos resultados;
- Os algoritmos de Interação Social obtiveram os melhores resultados nos 39 testes restantes, ou seja, 86,6% dos resultados;
- O algoritmo SIGA foi vitorioso em 6 testes, ou seja, 13,3% dos resultados;
- O algoritmo F-SIGA foi vitorioso em 12 testes, ou seja, 26,6% dos resultados;
- Os algoritmos (1,1) obtiveram os melhores resultados em 25 testes, ou seja, 53,3% dos resultados;
- Os algoritmos (0,1) obtiveram os melhores resultados em 14 testes, ou seja, 31,1% dos resultados;
- Os algoritmos ESIA obtiveram os melhores resultados também em 21 testes, ou seja, 46,6% dos resultados.

Além disso, é possível estabelecer uma comparação dos resultados obtidos nessas simulações com resultados presentes na literatura, mais especificamente em BELEGUNDU (1982); ARORA (1989); COELLO e MONTES (2002); HE e WANG (2007), conforme pode ser visto na tabela 3.16. O ESIA baseado no SIGA obteve o melhor resultado.

Tabela 3.16 – Resultados comparativos para o problema MWTCS.

Variáveis de Projeto	ESIA (SIGA)	HE e WANG (2007)	COELLO e MONTES (2002)	ARORA (1989)	BELEGUNDU (1982)
$x_1(d)$	0,500620	0,051728	0,051989	0,053396	0,050000
$x_2(D)$	0,282410	0,357644	0,363965	0,399180	0,315900
$x_3(P)$	2,005642	11,244543	10,890522	9,185400	14,250000
$g_1(x)$	-0,001950	-0,000845	-0,000013	0,000019	-0,000014
$g_2(x)$	-0,237140	-0,000012	-0,000021	-0,000018	-0,003782

Variáveis de Projeto	ESIA (SIGA)	HE e WANG (2007)	COELLO e MONTES (2002)	ARORA (1989)	BELEGUNDU (1982)
$g_3(x)$	-42,956200	-4,051300	-4,061338	-4,123832	-3,938302
$g_4(x)$	-0,778350	-0,727090	-0,722698	-0,698283	-0,756067
$f(x)$	<b>0,00283500</b>	<b>0,01267470</b>	<b>0,01268100</b>	<b>0,01273030</b>	<b>0,01283340</b>

### 3.3.4. Projeto de Redutor de Velocidade<sup>34</sup>

Na figura 3.4 é possível visualizar o projeto de redutor de velocidade, onde o seu peso deve ser minimizado, segundo algumas restrições, que são: flexão de estresse dos dentes da engrenagem, tensão superficial, desvios transversais das hastes e as tensões no eixo. Nesse problema são consideradas sete variáveis, que são: largura do rosto ( $x_1$ ), o módulo de dentes ( $x_2$ ), o número de dentes do pinhão ( $x_3$ ), o comprimento do primeiro eixo entre os rolamentos ( $x_4$ ), o comprimento do segundo eixo entre os rolamentos ( $x_5$ ), o diâmetro do primeiro eixo ( $x_6$ ) e o diâmetro do segundo eixo ( $x_7$ ).

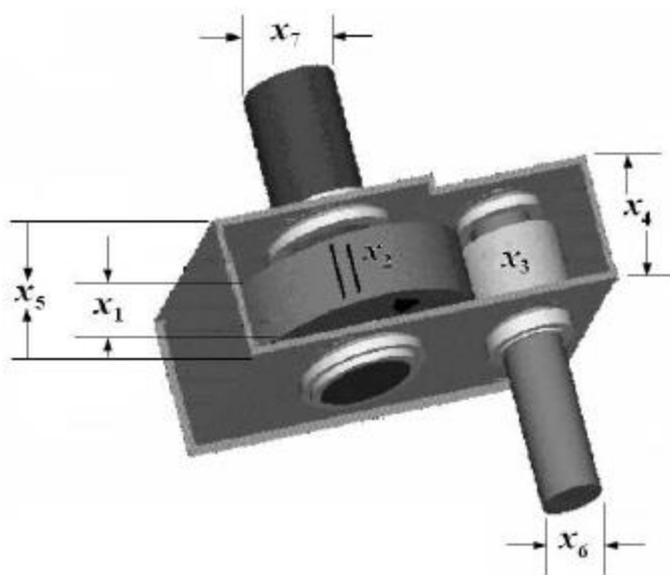


Figura 3.4 – Projeto de redutor de velocidade.

Fonte: BRAJEVIC et al. (2010)

<sup>34</sup> Em inglês: *Speed Reducer Design (SRD)*.

Este problema pode ser formulado da seguinte forma:

$$\begin{aligned} \text{Minimizar } f(x) = & 0.7854x_1x_2^2(3.3333x_3^2 + 14.933x_3 - 43.0934) \\ & -1.508x_1(x_6^2 + x_7^2) + 7.4777(x_6^2 + x_7^2) \\ & +0.78054(x_4x_6^2 + x_5x_7^2) \end{aligned} \quad (61)$$

Sujeito a:

$$g_1 = \frac{27}{x_1x_2^2x_3} - 1 \leq 0 \quad (62)$$

$$g_2 = \frac{397.5}{x_1x_2^2x_3} - 1 \leq 0 \quad (63)$$

$$g_3 = \frac{1.93x_4^3}{x_2x_3x_6^3} - 1 \leq 0 \quad (64)$$

$$g_4 = \frac{1.93x_5^3}{x_2x_3x_7^3} - 1 \leq 0 \quad (65)$$

$$g_5 = \frac{1.0}{110x_6^3} \sqrt{\left(\frac{750.0x_4}{x_2x_3}\right)^2 + 16.9 \times 10^6} - 1 \leq 0 \quad (66)$$

$$g_6 = \frac{1.0}{85x_7^3} \sqrt{\left(\frac{750.0x_5}{x_2x_3}\right)^2 + 157.5 \times 10^6} - 1 \leq 0 \quad (67)$$

$$g_7 = \frac{x_2x_3}{40} - 1 \leq 0 \quad (68)$$

$$g_8 = \frac{5x_2}{x_1} - 1 \leq 0 \quad (69)$$

$$g_9 = \frac{x_1}{12x_2} - 1 \leq 0 \quad (70)$$

$$g_{10} = \frac{1.5x_6 + 1.9}{x_4} - 1 \leq 0 \quad (71)$$

$$g_{11} = \frac{1.1x_7 + 1.9}{x_5} - 1 \leq 0 \quad (72)$$

Além disso, os seguintes intervalos de valores foram utilizados para cada uma das sete variáveis:  $2.6 \leq x_1 \leq 3.6$ ;  $0.7 \leq x_2 \leq 0.8$ ;  $17 \leq x_3 \leq 28$ ;  $7.3 \leq x_4 \leq 8.3$ ;  $7.3 \leq x_5 \leq 8.3$ ;  $2.9 \leq x_6 \leq 5.0$ ;  $7.3 \leq x_7 \leq 5.5$ .

Foram realizadas um total de 9 simulações para esta função, sendo cada uma delas executadas cinquenta vezes (e01 a e50), o que totalizaram 450 testes, conforme podem ser vistos os respectivos resultados nas tabelas G.4 (a), (b), (c), (d) e (e).

E a seguir, na tabela 3.17, são visualizados os melhores resultados, a média e o desvio padrão para cada uma das simulações, com destaque para o melhor resultado obtido,  $f(x) = 2.797,4246400$ .

Tabela 3.17 – Melhor resultado, média e desvio padrão para o problema *SRD*.

<b>Simulações</b>	<b>Melhor Resultado</b>	<b>Média</b>	<b>Desvio Padrão</b>
<b>46</b>	2.896,49951200	2.897,97325382	3,54877743
<b>47</b>	2.896,35329000	2.897,30583648	0,66885767
<b>48</b>	2.896,53140200	2.897,36944684	0,51616055
<b>49</b>	2.896,54161200	2.897,73798086	2,81814009
<b>50</b>	2.896,53804200	2.899,06758888	7,36905095
<b>51</b>	2.843,36672500	2.897,11126280	8,73042454
<b>52</b>	2.843,57889100	2.896,25171428	7,61552036
<b>53</b>	<b>2.797,42464600</b>	2.895,42623410	14,15209802
<b>54</b>	2.896,56914500	2.897,26359288	0,56446699

No gráfico 3.16 estão dispostos os 450 resultados obtidos nas simulações. Nele é pode-se observar em destaque a melhor solução encontrada na 49ª execução da simulação 53, através do Algoritmo ESIA(F-SIGA)(1,1).

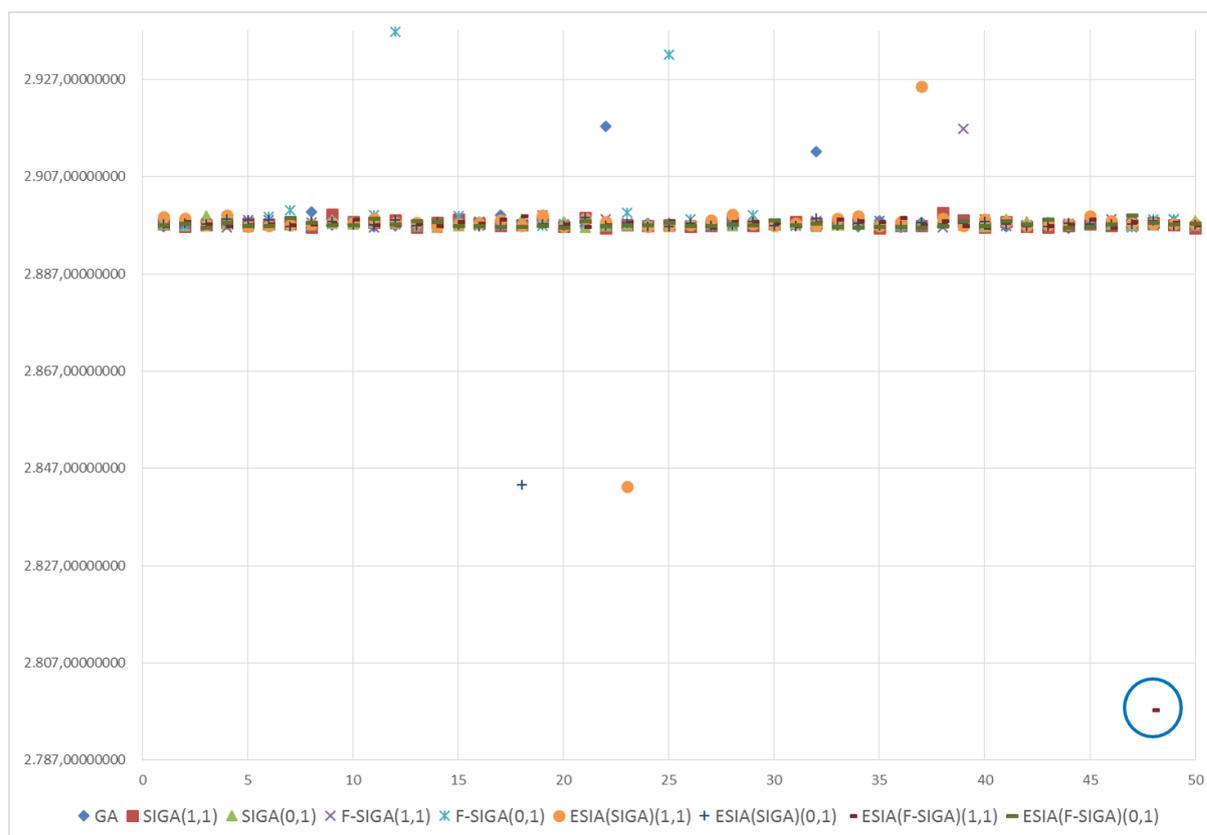


Gráfico 3.16 – Gráfico de dispersão para os resultados das simulações do problema *SRD*.

Todos os resultados foram organizados em ordem crescente e, assim, é possível observar a distribuição dos algoritmos vitoriosos em todos os 450 testes e distribuídos em dez faixas, de acordo com a tabela 3.18.

Tabela 3.18 – Distribuição dos algoritmos vitoriosos para o problema *SRD*.

Faixas de Testes		AG		SIGA				F-SIGA				ESIA(SIGA)				ESIA(F-SIGA)			
%	Ordem	Vitórias	%	(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)	
				Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%
[0, 10]	1 a 45	6	13%	9	20%	3	7%	4	9%	5	11%	2	4%	3	7%	5	11%	8	18%
[11, 20]	46 a 90	5	11%	5	11%	6	13%	6	13%	4	9%	7	16%	7	16%	0	0%	5	11%
[21, 30]	90 a 135	5	11%	5	11%	3	7%	5	11%	3	7%	3	7%	8	18%	7	16%	6	13%
[31, 40]	136 a 180	8	18%	2	4%	6	13%	6	13%	7	16%	2	4%	4	9%	3	7%	7	16%
[41, 50]	181 a 225	4	9%	5	11%	6	13%	5	11%	4	9%	5	11%	4	9%	8	18%	4	9%
[51, 60]	226 a 270	5	11%	5	11%	7	16%	4	9%	4	9%	4	9%	6	13%	6	13%	4	9%
[61, 70]	271 a 315	6	13%	6	13%	4	9%	5	11%	3	7%	6	13%	6	13%	4	9%	5	11%
[71, 80]	316 a 360	4	9%	6	13%	6	13%	3	7%	4	9%	5	11%	5	11%	9	20%	3	7%
[81, 90]	361 a 405	2	4%	4	9%	7	16%	9	20%	4	9%	4	9%	5	11%	5	11%	5	11%
[91, 100]	406 a 450	5	11%	3	7%	2	4%	3	7%	12	27%	12	27%	2	4%	3	7%	3	7%

Os resultados dos primeiros 20% melhores resultados, ou seja, os 90 primeiros testes podem ser visualizados também através do gráfico 3.17, Nele são apresentados os valores referentes à distribuição dos algoritmos vitoriosos.

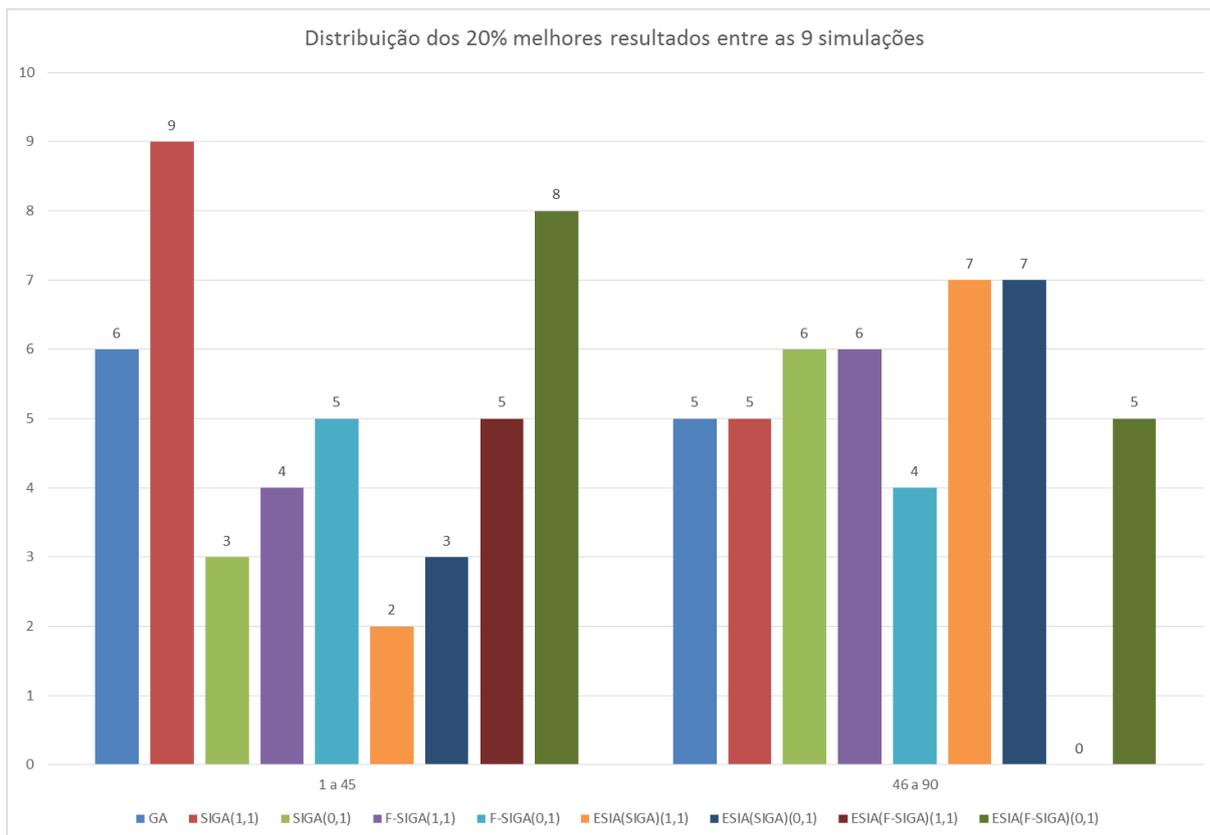


Gráfico 3.17 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema *SRD*.

A partir desses resultados é possível observar os seguintes fatos para os 45 melhores resultados, o que representam os 10% melhores:

- Os Algoritmos Genéticos obtiveram os melhores resultados em 6 testes, ou seja, 13,3% dos resultados;
- Os algoritmos de Interação Social obtiveram os melhores resultados nos 39 testes restantes, ou seja, 86,6% dos resultados;
- O algoritmo SIGA foi vitorioso em 12 testes, ou seja, 26,6% dos resultados;
- O algoritmo F-SIGA foi vitorioso em 9 testes, ou seja, 20% dos resultados;
- Os algoritmos (1,1) obtiveram os melhores resultados em 20 testes, ou seja, 44,4% dos resultados;

- Os algoritmos (0,1) obtiveram os melhores resultados em 19 testes, ou seja, 42,2% dos resultados;
- Os algoritmos ESIA obtiveram os melhores resultados também em 18 testes, ou seja, 40% dos resultados.

Além disso, é possível estabelecer uma comparação dos resultados obtidos nessas simulações com resultados presentes na literatura, mais especificamente em COELLO e MONTES (2002); HE e WANG (2007), conforme pode ser visto na tabela 3.19. O ESIA baseado no F-SIGA obteve o melhor resultado.

Tabela 3.19 – Resultados comparativos para o problema SRD.

Variáveis de Projeto	ESIA (F-SIGA)	HE e WANG (2007)	COELLO e MONTES (2002)
$x_1$	3,500459	3,500000	3,500000
$x_2$	0,700020	0,700000	0,700000
$x_3$	17,005030	17,000000	17,000000
$x_4$	7,300251	7,300000	7,300000
$x_5$	7,800195	7,800000	7,800000
$x_6$	2,900041	3,350215	3,350214
$x_7$	5,286863	5,286683	5,286683
$g_1(x)$	-0,074364	-0,073915	-0,073915
$g_2(x)$	-0,198624	-0,197996	-0,197998
$g_3(x)$	-0,108202	-0,499172	-0,499172
$g_4(x)$	-0,901443	-0,901471	-0,901471
$g_5(x)$	-1,000000	0,000000	0,000000
$g_6(x)$	-0,000102	0,000000	0,000000
$g_7(x)$	-0,702403	-0,702500	-0,702500
$g_8(x)$	-0,000103	0,000000	0,000000
$g_9(x)$	-0,795801	-0,583333	-0,583333
$g_{10}(x)$	-0,143857	-0,051326	-0,051325
$g_{11}(x)$	-0,011074	-0,010852	-0,010852
<b><math>f(x)</math></b>	<b>2.797,424646</b>	<b>2.996,348165</b>	<b>2.996,348165</b>

### 3.4. PROBLEMA DO CAIXEIRO VIAJANTE (PCV)

De acordo com RODRIGUES (2000), problemas de otimização combinatória são encontrados em diversas situações, tais como: problemas de alocação, roteamento e programação de horários. E segundo GOLDBARG (2000):

**O Problema do Caixeiro Viajante (PCV) é um dos mais tradicionais e conhecidos problemas de programação matemática, e os problemas de roteamento lidam em sua maior parte com passeios ou tours sobre pontos de demanda e oferta, que podem ser representados por cidades, postos de trabalho ou atendimento, depósitos e outros.**

Um PCV é definido por um grafo completo  $G = (V, A)$ , onde  $V$  é o conjunto de  $n$  vértices e  $A$  é o conjunto de arcos ou arestas que conectam cada par de cidades  $i, j \in V$ , com um custo  $c_{ij}$  associado. O problema consiste em encontrar a rota de menor custo, passando uma única vez pelos vértices, e o vértice inicial é também o final. Quando o custo  $c_{ij} = c_{ji}$  tem-se caracterizada a versão simétrica do PCV, o PCVS.

Uma forma de se obter a solução ótima para o PCV é avaliar todas as soluções possíveis, através de uma **Busca Exaustiva** e, posteriormente, escolher aquela que minimize a somatória das distâncias entre as cidades, por exemplo. Porém, um problema é constatado aqui, a chamada **Explosão Combinatória**.

Para exemplificar o problema da explosão combinatória, considere-se o próprio PCV, com  $n$  cidades. O número de soluções possíveis é da ordem de:

$$\frac{(n-1)!}{2} \quad (73)$$

Na tabela 3.20, é possível verificar para alguns exemplos do valor de  $n$ , o tempo necessário para processar todas as soluções possíveis, através de uma busca exaustiva, levando em consideração a possibilidade de se avaliar  $10^{12}$  soluções a cada segundo.

Tabela 3.20 – Tempo estimado para processar todas as soluções possíveis para  $n$  cidades.

$n$	$(n-1)!/2$	Dias	Anos	Bilhões de Anos
10	$1,81 \times 10^5$	$2,10 \times 10^{-13}$	$5,75 \times 10^{-16}$	$5,75 \times 10^{-23}$
100	$4,67 \times 10^{155}$	$5,40 \times 10^{137}$	$1,48 \times 10^{135}$	$1,48 \times 10^{128}$
1000	$2,01 \times 10^{2564}$	$2,33 \times 10^{2546}$	$6,38 \times 10^{2543}$	$6,38 \times 10^{2536}$

Fonte: GOLDBARG (2000)

Fica bastante evidente que, com a utilização da abordagem exaustiva, o tempo para o processamento das soluções possíveis para o PCV é impraticável. Desta forma, mecanismos mais apropriados, como por exemplo, os Algoritmos Genéticos, são utilizados na sua resolução.

Neste trabalho foram utilizadas sete instâncias do PCVS, conforme a tabela 3.21, onde três delas, *kroa100*, *att532* e *pcb1173*, estão disponibilizadas em REINELT (2001). A outra instância, *br26*, refere-se às distâncias entre as 26 capitais brasileiras interligadas por rodovias, foi definida por LEHRER (2000) e desde então sempre utilizadas nos estudos e simulações realizados.

Tabela 3.21 – Informações sobre as instâncias do PCVS utilizadas nas simulações.

Instância PCVS	Vértices ( $n$ )	Tempo Estimado (Busca exaustiva)			$f_{min}$ (ótimo global)
		Dias	Anos	Bilhões de anos	
<i>br26</i>	26	$8,97 \times 10^7$	$2,45 \times 10^5$	$2,45 \times 10^{-4}$	19.633
<i>kroa100</i>	100	$5,40 \times 10^{138}$	$1,47 \times 10^{136}$	$1,47 \times 10^{127}$	21.282
<i>att532</i>	532	$8,68 \times 10^{1201}$	$2,38 \times 10^{1199}$	$2,38 \times 10^{1190}$	27.686
<i>pcb1173</i>	1173	$3,06 \times 10^{3073}$	$8,39 \times 10^{3070}$	$8,39 \times 10^{3061}$	56.892

Outro detalhe importante refere-se aos valores do ótimo global para cada uma das instâncias, pois aquelas que são oriundas do *TSPLib* tem os valores já conhecidos, enquanto que para a instância *br26* o valor ótimo apresentado é o melhor dentre todos os resultados já obtidos nos mais diversos trabalhos que a utilizaram como função de *benchmark* (LEHRER, 2000; BRITO, 2004; BRITO et al., 2005; TEIXEIRA, 2005; BARREIRA e OLIVEIRA, 2006; BRITO et al., 2006b; 2006c; 2007a; 2007b; TEIXEIRA et al., 2006a; 2006b; 2006c; 2007; 2010a; 2010b).

### 3.4.1. Instância: *br26*

Foram realizadas um total de 11 simulações para esta função, sendo cada uma delas executadas cinquenta vezes (e01 a e50), o que totalizaram 550 testes, conforme podem ser vistos os respectivos resultados nas tabelas H.1 (a), (b), (c), (d) e (e).

E a seguir, na tabela 3.22, são visualizados os melhores resultados, a média e o desvio padrão para cada uma das simulações, com destaque para o melhor resultado obtido,  $f(x) = 17.097,00$ .

Tabela 3.22 – Melhor resultado, média e desvio padrão para o problema *br26*.

<b>Simulações</b>	<b>Melhor Resolução</b>	<b>Média</b>	<b>Desvio Padrão</b>
<b>64</b>	17.866,00	20.356,90	1.292,00
<b>65</b>	18.479,00	21.356,86	1.173,95
<b>66</b>	22.245,00	26.344,68	1.541,15
<b>67</b>	18.164,00	28.145,48	2.598,17
<b>68</b>	18.880,00	26.235,66	2.130,88
<b>69</b>	17.159,00	20.167,08	1.090,34
<b>70</b>	<b>17.097,00</b>	19.898,02	1.245,70
<b>71</b>	20.958,00	27.363,96	2.627,92
<b>72</b>	22.948,00	27.688,08	2.383,35
<b>73</b>	20.583,00	24.011,40	1.786,53
<b>74</b>	20.409,00	24.030,68	2.404,89

No gráfico 3.18 estão dispostos os 550 resultados obtidos nas simulações. Nele é pode-se observar em destaque a melhor solução encontrada na 3ª execução da simulação 70, através do Algoritmo ESIA(SIGA)(0,1).

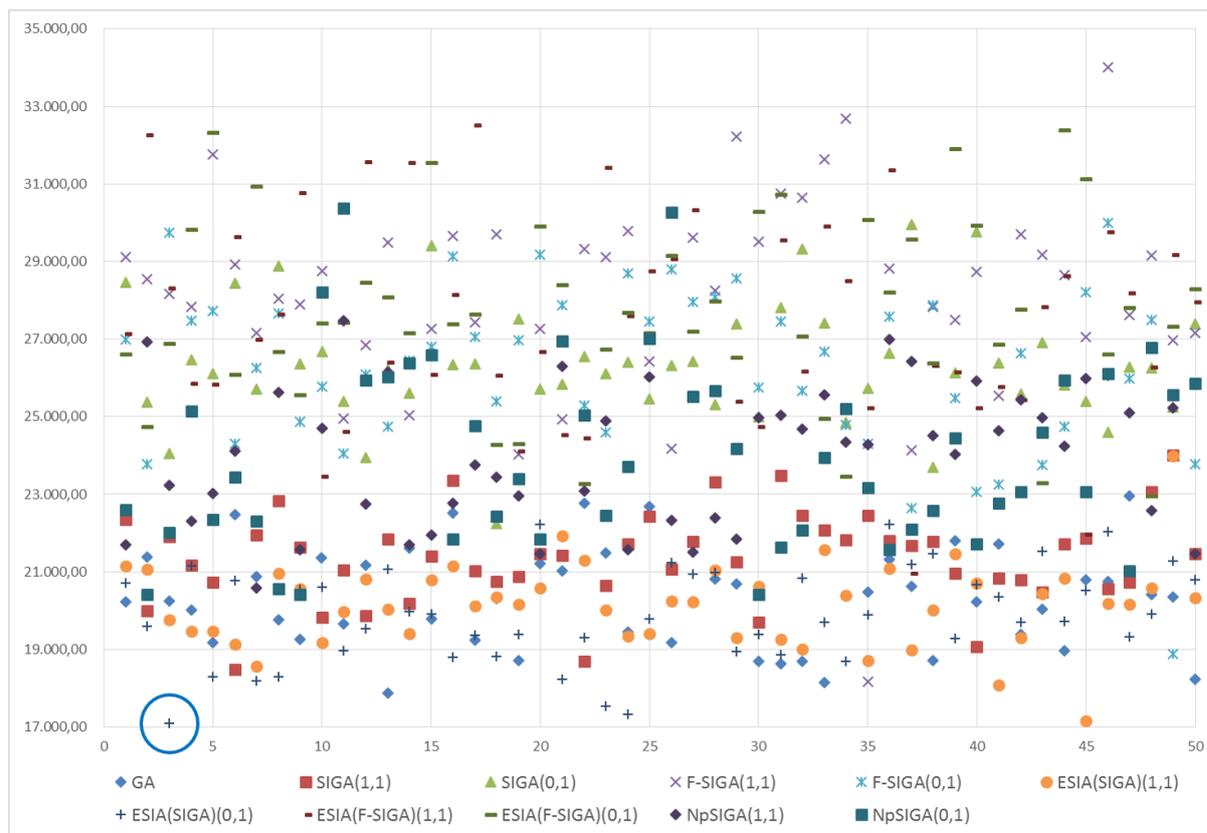


Gráfico 3.18 – Gráfico de dispersão para os resultados das simulações do problema *br26*.

Todos os resultados foram organizados em ordem crescente e, assim, é possível observar a distribuição dos algoritmos vitoriosos em todos os 550 testes e distribuídos em dez faixas, de acordo com a tabela 3.23.

Tabela 3.23 – Distribuição dos algoritmos vitoriosos para o problema *br26*.

Faixas de Testes		AG		SIGA				F-SIGA				ESIA(SIGA)				ESIA(F-SIGA)				NpSIGA			
%	Ordem	Vitórias	%	(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)		(1,1)		(0,1)	
				Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%
[0, 10]	1 a 55	15	27%	3	5%	0	0%	1	2%	1	2%	16	29%	19	35%	0	0%	0	0%	0	0%	0	0%
[11, 20]	56 a 110	13	24%	7	13%	0	0%	0	0%	0	0%	17	31%	13	24%	0	0%	0	0%	1	2%	4	7%
[21, 30]	111 a 165	12	22%	15	27%	0	0%	0	0%	0	0%	13	24%	13	24%	1	2%	0	0%	0	0%	1	2%
[31, 40]	166 a 220	5	9%	17	31%	1	2%	0	0%	0	0%	3	5%	5	9%	1	2%	0	0%	12	22%	11	20%
[41, 50]	221 a 275	5	9%	8	15%	3	5%	3	5%	7	13%	1	2%	0	0%	2	4%	4	7%	11	20%	11	20%
[51, 60]	276 a 330	0	0%	0	0%	9	16%	3	5%	10	18%	0	0%	0	0%	8	15%	4	7%	14	25%	7	13%
[61, 70]	331 a 385	0	0%	0	0%	18	33%	1	2%	6	11%	0	0%	0	0%	10	18%	3	5%	8	15%	9	16%
[71, 80]	386 a 440	0	0%	0	0%	10	18%	9	16%	10	18%	0	0%	0	0%	4	7%	15	27%	3	5%	4	7%
[81, 90]	441 a 495	0	0%	0	0%	5	9%	15	27%	12	22%	0	0%	0	0%	11	20%	10	18%	1	2%	1	2%
[91, 100]	496 a 550	0	0%	0	0%	4	7%	18	33%	4	7%	0	0%	0	0%	13	24%	14	25%	0	0%	2	4%

Os resultados dos primeiros 20% melhores resultados, ou seja, os 110 primeiros testes podem ser visualizados também através do gráfico 3.19, Nele são apresentados os valores referentes à distribuição dos algoritmos vitoriosos.

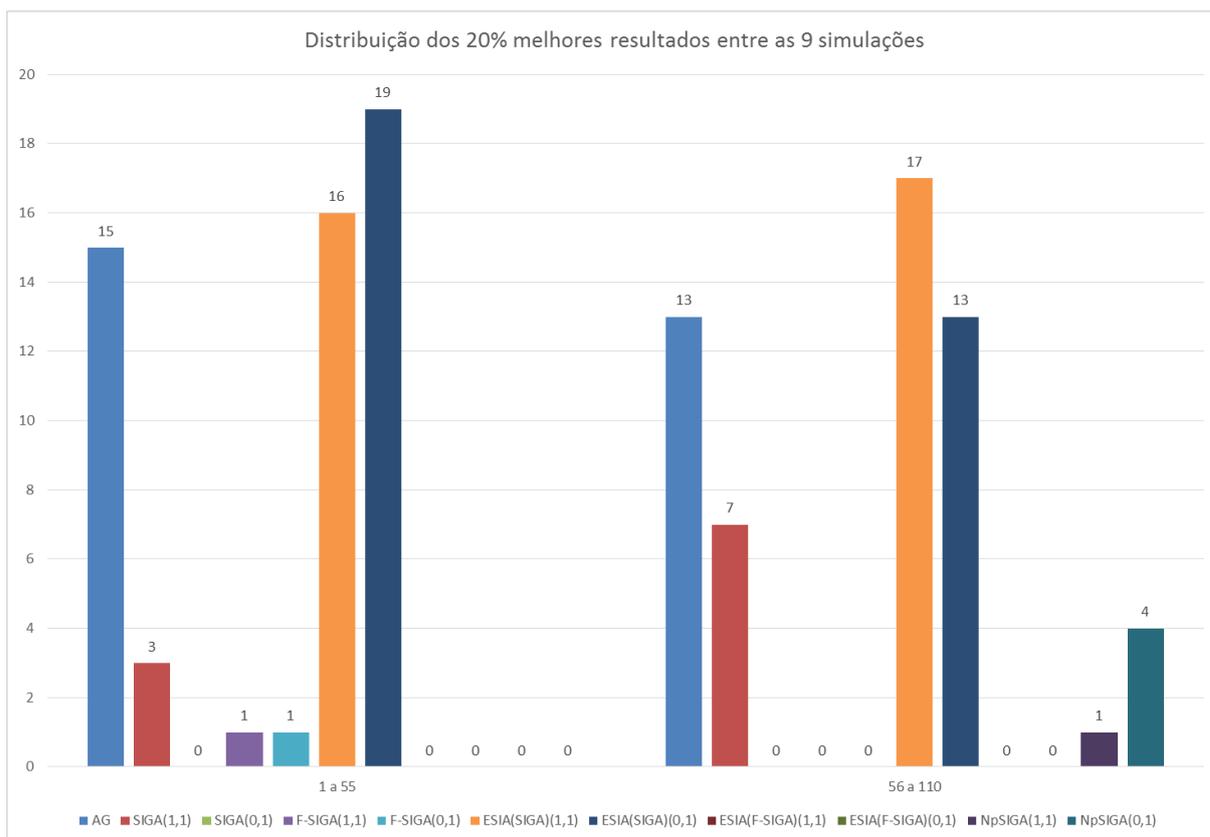


Gráfico 3.19 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema *br26*.

A partir desses resultados é possível observar os seguintes fatos para os 55 melhores resultados, que representam os 10% melhores:

- Os Algoritmos Genéticos obtiveram os melhores resultados em 15 testes, ou seja, 27,3% dos resultados;
- Os algoritmos de Interação Social obtiveram os melhores resultados nos 40 testes restantes, ou seja, 72,7% dos resultados;
- O algoritmo SIGA foi vitorioso em 3 testes, ou seja, 5,45% dos resultados;
- O algoritmo F-SIGA foi vitorioso em 2 testes, ou seja, 3,63% dos resultados;
- Os algoritmos (1,1) obtiveram os melhores resultados em 20 testes, ou seja, 36,3% dos resultados;

- Os algoritmos (0,1) obtiveram os melhores resultados em 20 testes, ou seja, 36,3% dos resultados;
- Os algoritmos ESIA obtiveram os melhores resultados também em 35 testes, ou seja, 63,6% dos resultados;
- Foi obtido um resultado melhor do que o até então ótimo global conhecido.

### 3.4.2. Instância: *kro100*

Foram realizadas um total de 11 simulações para esta função, sendo cada uma delas executadas cinquenta vezes (e01 a e50), o que totalizaram 550 testes, conforme podem ser vistos os respectivos resultados nas tabelas H.2 (a), (b), (c), (d) e (e).

E a seguir, na tabela 3.24, são visualizados os melhores resultados, a média e o desvio padrão para cada uma das simulações, com destaque para o melhor resultado obtido,  $f(x) = 45.506,00$ .

Tabela 3.24 – Melhor resultado, média e desvio padrão para o problema *kroa100*.

<b>Simulações</b>	<b>Melhor Resultado</b>	<b>Média</b>	<b>Desvio Padrão</b>
<b>75</b>	47.928,46	55.359,40	3.901,91
<b>76</b>	58.620,98	67.046,22	4.087,87
<b>77</b>	90.968,56	99.538,28	3.949,61
<b>78</b>	73.477,29	97.252,14	7.337,38
<b>79</b>	86.662,48	97.952,12	4.581,81
<b>80</b>	<b>45.506,02</b>	55.764,88	3.808,22
<b>81</b>	47.215,38	54.494,73	3.592,09
<b>82</b>	84.244,16	101.510,93	6.626,53
<b>83</b>	88.162,44	100.202,04	5.927,42
<b>84</b>	62.267,35	72.797,96	4.355,32
<b>85</b>	63.908,61	72.492,20	4.866,77

No gráfico 3.20 estão dispostos os 550 resultados obtidos nas simulações. Nele é pode-se observar em destaque a melhor solução encontrada na 2ª execução da simulação 80, através do Algoritmo ESIA(SIGA)(1,1).

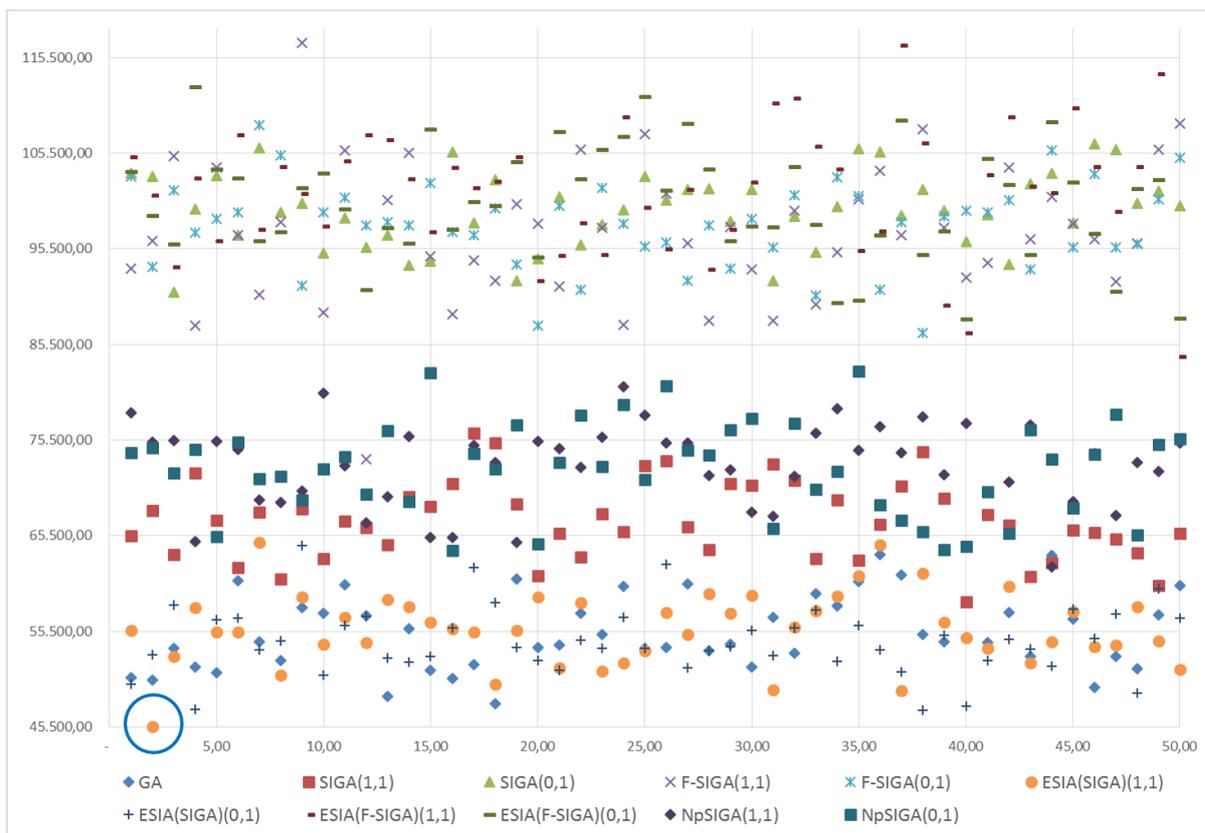


Gráfico 3.20 – Gráfico de dispersão para os resultados das simulações do problema *kroa100*.

Todos os resultados foram organizados em ordem crescente e, assim, é possível observar a distribuição dos algoritmos vitoriosos em todos os 550 testes e distribuídos em dez faixas, de acordo com a tabela 3.25.

Tabela 3.25 – Distribuição dos algoritmos vitoriosos para o problema *kroa100*.

Faixas de Testes		AG		SIGA			F-SIGA			ESIA(SIGA)			ESIA(F-SIGA)			NpSIGA							
%	Ordem	Vitórias	%	(1,1)	(0,1)	(0,0)	(1,1)	(0,1)	(0,0)	(1,1)	(0,1)	(0,0)	(1,1)	(0,1)	(0,0)	(1,1)	(0,1)	(0,0)					
[0, 10]	1 a 55	18	33%	0	0%	0	0%	0	0%	0	0%	13	24%	24	44%	0	0%	0	0%	0	0%	0	0%
[11, 20]	56 a 110	18	33%	0	0%	0	0%	0	0%	0	0%	19	35%	18	33%	0	0%	0	0%	0	0%	0	0%
[21, 30]	111 a 165	14	25%	14	25%	0	0%	0	0%	0	0%	16	29%	7	13%	0	0%	0	0%	1	2%	3	5%
[31, 40]	166 a 220	0	0%	24	44%	0	0%	0	0%	0	0%	2	4%	1	2%	0	0%	0	0%	14	25%	14	25%
[41, 50]	221 a 275	0	0%	11	20%	0	0%	1	2%	0	0%	0	0%	0	0%	0	0%	0	0%	23	42%	20	36%
[51, 60]	276 a 330	0	0%	1	2%	2	4%	10	18%	7	13%	0	0%	0	0%	4	7%	6	11%	12	22%	13	24%
[61, 70]	331 a 385	0	0%	0	0%	12	22%	15	27%	12	22%	0	0%	0	0%	7	13%	9	16%	0	0%	0	0%
[71, 80]	386 a 440	0	0%	0	0%	14	25%	7	13%	16	29%	0	0%	0	0%	8	15%	10	18%	0	0%	0	0%
[81, 90]	441 a 495	0	0%	0	0%	16	29%	6	11%	11	20%	0	0%	0	0%	11	20%	11	20%	0	0%	0	0%
[91, 100]	496 a 550	0	0%	0	0%	6	11%	11	20%	4	7%	0	0%	0	0%	20	36%	14	25%	0	0%	0	0%

Os resultados dos primeiros 20% melhores resultados, ou seja, os 110 primeiros testes podem ser visualizados também através do gráfico 3.21, Nele são apresentados os valores referentes à distribuição dos algoritmos vitoriosos.

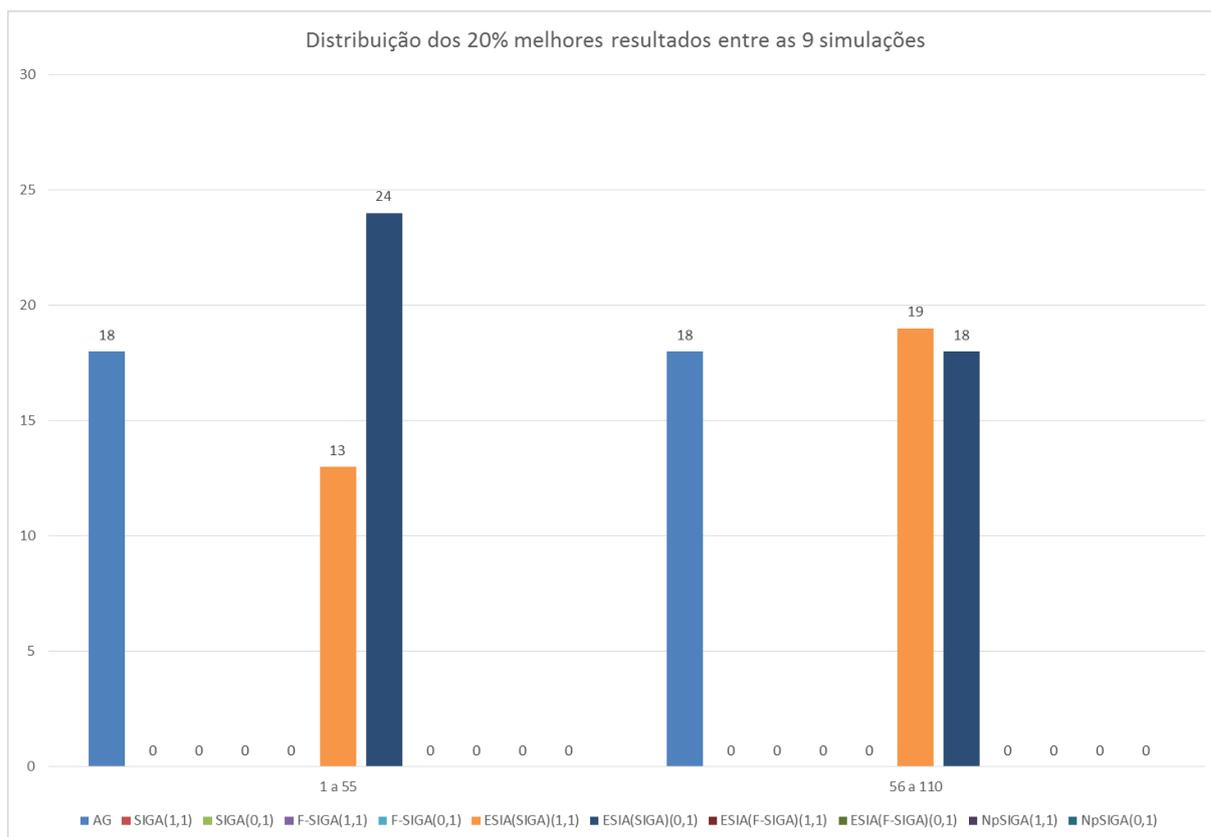


Gráfico 3.21 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema *kroa100*.

A partir desses resultados é possível observar os seguintes fatos para os 55 melhores resultados, que representam os 10% melhores:

- Os Algoritmos Genéticos obtiveram os melhores resultados em 18 testes, ou seja, 32,7% dos resultados;
- Os algoritmos de Interação Social obtiveram os melhores resultados nos 37 testes restantes, ou seja, 67,3% dos resultados;
- O algoritmo SIGA foi vitorioso em nenhum dos testes;
- O algoritmo F-SIGA foi vitorioso em nenhum dos testes;
- Os algoritmos (1,1) obtiveram os melhores resultados em 13 testes, ou seja, 23,6% dos resultados;

- Os algoritmos (0,1) obtiveram os melhores resultados em 24 testes, ou seja, 43,6% dos resultados;
- Os algoritmos ESIA obtiveram os melhores resultados também em 37 testes, ou seja, 67,3% dos resultados;
- O melhor valor obtido está distante do ótimo global conhecido.

### 3.4.3. Instância: *att532*

Foram realizadas um total de 11 simulações para esta função, sendo cada uma delas executadas cinquenta vezes (e01 a e50), o que totalizaram 550 testes, conforme podem ser vistos os respectivos resultados nas tabelas H.3 (a), (b), (c), (d) e (e).

E a seguir, na tabela 3.26, são visualizados os melhores resultados, a média e o desvio padrão para cada uma das simulações, com destaque para o melhor resultado obtido,  $f(x) = 898.484,36$  e o segundo melhor  $f(x) = 1.157.339,84$ .

Tabela 3.26 – Melhor resultado, média e desvio padrão para o problema *att532*.

Simulações	Melhor Resolução	Média	Desvio Padrão
86	1.157.339,84	1.262.422,95	43.436,93
87	1.171.518,37	1.253.993,05	40.458,20
88	1.172.176,46	1.247.646,32	34.106,65
89	1.174.405,41	1.248.474,54	41.082,24
90	1.238.285,84	1.283.212,40	19.728,85
91	1.176.750,67	1.255.463,08	30.291,18
92	1.186.232,53	1.243.966,50	31.937,64
93	1.180.867,66	1.260.905,03	34.722,93
94	1.162.166,54	1.246.037,67	34.609,86
95	898.484,36	996.764,84	35.165,50
96	902.461,82	994.075,71	38.361,76

No gráfico 3.22 estão dispostos os 550 resultados obtidos nas simulações. Nele é pode-se observar em destaque a melhor solução encontrada na 20ª execução da simulação 95, através do Algoritmo NpSIGA(1,1).

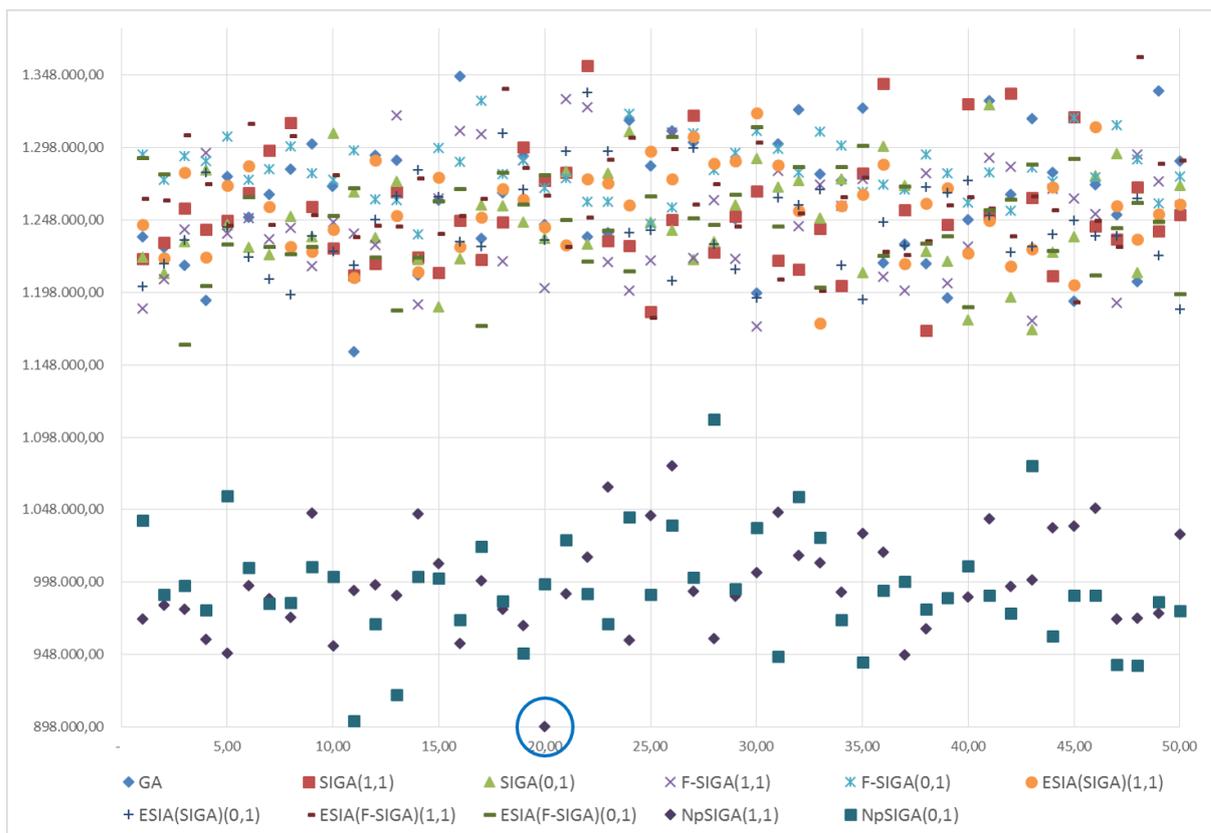


Gráfico 3.22 – Gráfico de dispersão para os resultados das simulações do problema *att532*.

Todos os resultados foram organizados em ordem crescente e, assim, é possível observar a distribuição dos algoritmos vitoriosos em todos os 550 testes e distribuídos em dez faixas, de acordo com a tabela 3.27.

Tabela 3.27 – Distribuição dos algoritmos vitoriosos para o problema *att532*.

Faixas de Testes	AG		SIGA				F-SIGA				ESIA(SIGA)				ESIA(F-SIGA)				NpSIGA				
	%	Ordem	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	
[0, 10]	1 a 55	0	0%	0	0%	0	0%	0	0%	0	0%	0	0%	0	0%	0	0%	0	0%	27	49%	28	51%
[11, 20]	56 a 110	1	2%	1	2%	2	4%	2	4%	0	0%	1	2%	0	0%	1	2%	2	4%	23	42%	22	40%
[21, 30]	111 a 165	8	15%	7	13%	5	9%	10	18%	0	0%	4	7%	11	20%	3	5%	7	13%	0	0%	0	0%
[31, 40]	166 a 220	3	5%	7	13%	9	16%	7	13%	0	0%	9	16%	8	15%	4	7%	8	15%	0	0%	0	0%
[41, 50]	221 a 275	5	9%	7	13%	9	16%	6	11%	1	2%	3	5%	10	18%	8	15%	6	11%	0	0%	0	0%
[51, 60]	276 a 330	5	9%	11	20%	5	9%	5	9%	3	5%	8	15%	4	7%	8	15%	6	11%	0	0%	0	0%
[61, 70]	331 a 385	4	7%	4	7%	4	7%	4	7%	8	15%	6	11%	8	15%	9	16%	8	15%	0	0%	0	0%
[71, 80]	386 a 440	5	9%	4	7%	8	15%	4	7%	14	25%	8	15%	3	5%	5	9%	4	7%	0	0%	0	0%
[81, 90]	441 a 495	8	15%	1	2%	4	7%	6	11%	14	25%	8	15%	3	5%	5	9%	6	11%	0	0%	0	0%
[91, 100]	496 a 550	11	20%	8	15%	4	7%	6	11%	10	18%	3	5%	3	5%	7	13%	3	5%	0	0%	0	0%

Os resultados dos primeiros 20% melhores resultados, ou seja, os 110 primeiros testes podem ser visualizados também através do gráfico 3.23, Nele são apresentados os valores referentes à distribuição dos algoritmos vitoriosos.



Gráfico 3.23 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema *att532*.

A partir desses resultados é possível observar os seguintes fatos para os 110 melhores resultados, que representam os 20% melhores:

- Os algoritmos NpSIGA obtiveram 100 dos melhores resultados, ou seja, 90,9%;
- As outras 9 simulações foram vitoriosas em apenas 10 testes, o que representam 9,1% dos melhores resultados;
- Desses 10 resultados, apenas 1 foi gerado pelo Algoritmo Genético; 3 pelo SIGA; 2 pelo F-SIGA; e, 4 pelo ESIA.

Ao considerar apenas os outros resultados obtidos a partir dos outros 9 algoritmos, ou seja, desconsiderando os resultados obtidos através dos algoritmos NpSIGA, a distribuição dos algoritmos vitoriosos pode ser visualizado no gráfico 3.24

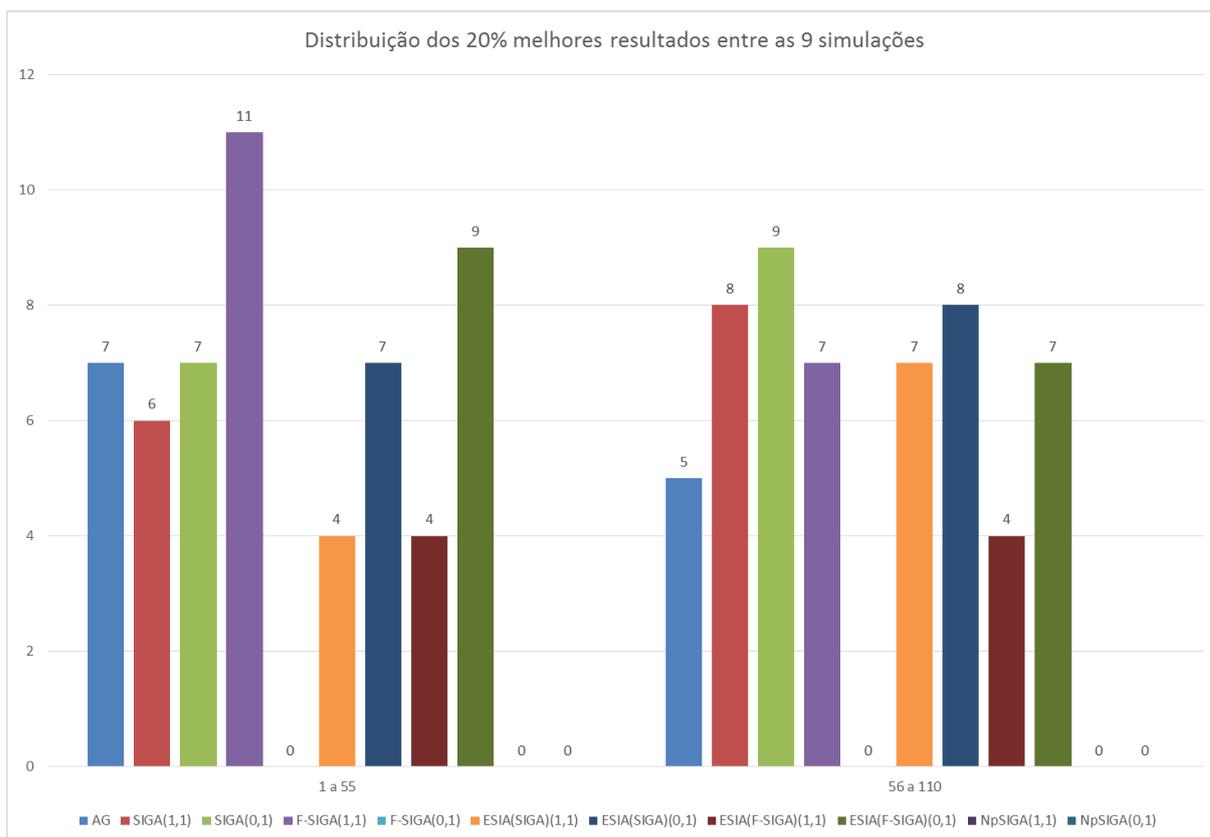


Gráfico 3.24 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema *att532* sem os resultados do algoritmo NpSIGA.

E, assim, é possível observar os seguintes fatos ao considerar apenas os 55 melhores resultados, ou seja, os 10% melhores:

- Os Algoritmos Genéticos obtiveram os melhores resultados em 7 testes, ou seja, 12,7% dos resultados;
- Os algoritmos de Interação Social obtiveram os melhores resultados nos 48 testes restantes, ou seja, 87,3% dos resultados;
- O algoritmo SIGA foi vitorioso em 13 testes, ou seja, 23,6% dos resultados;
- O algoritmo F-SIGA foi vitorioso em 11 testes, ou seja, 20% dos resultados;
- Os algoritmos (1,1) obtiveram os melhores resultados em 25 testes, ou seja, 45,4% dos resultados;

- Os algoritmos (0,1) obtiveram os melhores resultados em 23 testes, ou seja, 41,8% dos resultados;
- Os algoritmos ESIA obtiveram os melhores resultados também em 24 testes, ou seja, 43,6% dos resultados;

### 3.4.4. Instância: *pcp1173*

Foram realizadas um total de 11 simulações para esta função, sendo cada uma delas executadas cinquenta vezes (e01 a e50), o que totalizaram 550 testes, conforme podem ser vistos os respectivos resultados nas tabelas H.4 (a), (b), (c), (d) e (e).

E a seguir, na tabela 3.27, são visualizados os melhores resultados, a média e o desvio padrão para cada uma das simulações, com destaque para o melhor resultado obtido,  $f(x) = 984.707,21$  e o segundo melhor  $f(x) = 1.130.730,02$ .

Tabela 3.27 – Melhor resultado, média e desvio padrão para o problema *pcb1173*.

Simulações	Melhor Resultado	Média	Desvio Padrão
97	1.130.730,02	1.209.140,12	27.857,33
98	1.148.416,96	1.205.522,25	25.314,54
99	1.162.790,89	1.202.502,32	20.038,88
100	1.137.019,10	1.198.355,57	21.495,33
101	1.199.349,83	1.233.206,06	9.021,95
102	1.159.352,69	1.207.063,28	20.075,49
103	1.160.263,23	1.200.815,64	19.047,73
104	1.157.275,57	1.204.182,77	20.613,83
105	1.169.323,84	1.205.085,68	17.615,81
106	984.707,21	1.047.561,67	21.560,99
107	1.012.059,21	1.044.963,50	19.361,63

No gráfico 3.25 estão dispostos os 550 resultados obtidos nas simulações. Nele é pode-se observar em destaque a melhor solução encontrada na 19<sup>a</sup> execução da simulação 106, através do Algoritmo NpSIGA(1,1).

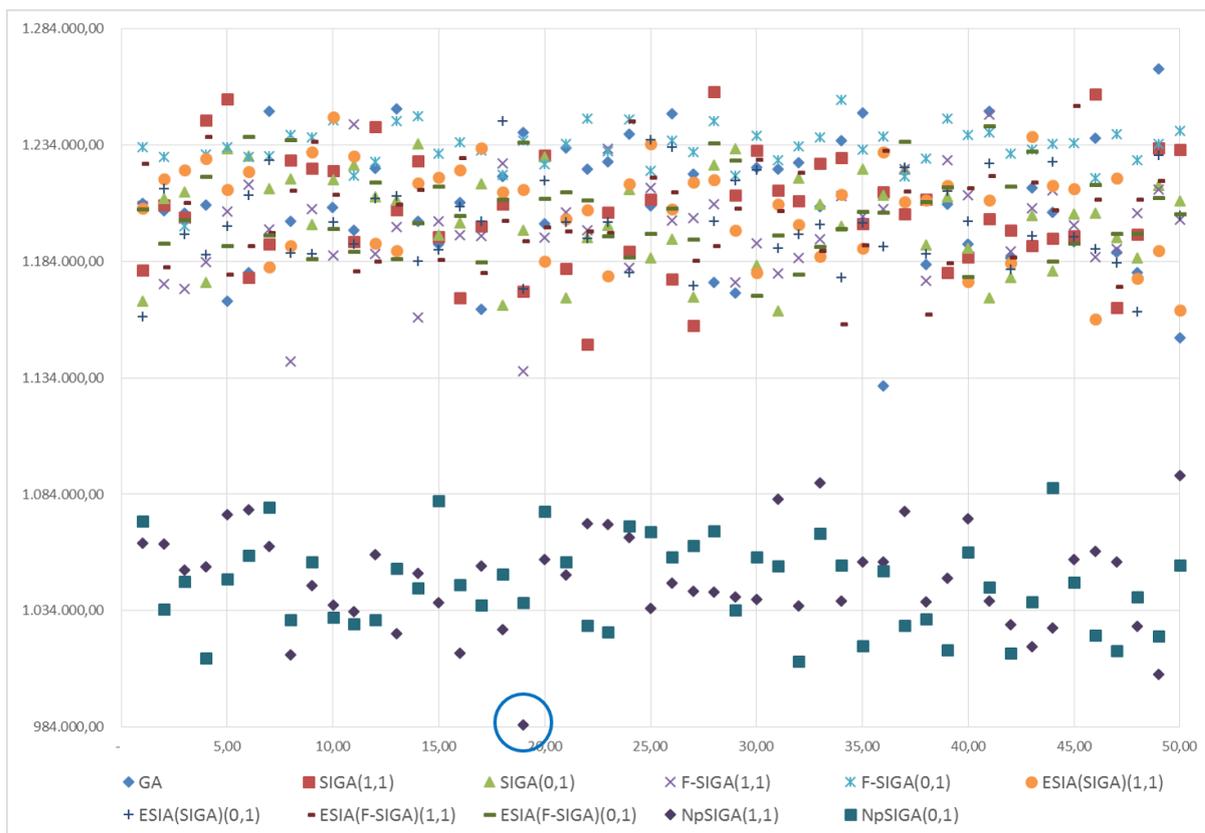


Gráfico 3.25 – Gráfico de dispersão para os resultados das simulações do problema *pcb1173*.

Todos os resultados foram organizados em ordem crescente e, assim, é possível observar a distribuição dos algoritmos vitoriosos em todos os 550 testes e distribuídos em dez faixas, de acordo com a tabela 3.28.

Tabela 3.28 – Distribuição dos algoritmos vitoriosos para o problema *pcb1173*.

Faixas de Testes	AG		SIGA				F-SIGA				ESIA(SIGA)				ESIA(F-SIGA)				NpSIGA				
	%	Ordem	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	Vitórias	%	
[0, 10]	1 a 55	0	0%	0	0%	0	0%	0	0%	0	0%	0	0%	0	0%	0	0%	0	0%	26	47%	29	53%
[11, 20]	56 a 110	2	4%	2	4%	0	0%	3	5%	0	0%	1	2%	1	2%	1	2%	0	0%	24	44%	21	38%
[21, 30]	111 a 165	7	13%	8	15%	10	18%	6	11%	0	0%	7	13%	7	13%	7	13%	3	5%	0	0%	0	0%
[31, 40]	166 a 220	4	7%	4	7%	4	7%	8	15%	0	0%	7	13%	10	18%	8	15%	10	18%	0	0%	0	0%
[41, 50]	221 a 275	3	5%	8	15%	9	16%	8	15%	1	2%	2	4%	8	15%	6	11%	10	18%	0	0%	0	0%
[51, 60]	276 a 330	10	18%	6	11%	3	5%	12	22%	0	0%	4	7%	8	15%	5	9%	7	13%	0	0%	0	0%
[61, 70]	331 a 385	4	7%	7	13%	10	18%	5	9%	0	0%	9	16%	5	9%	9	16%	6	11%	0	0%	0	0%
[71, 80]	386 a 440	6	11%	2	4%	9	16%	3	5%	7	13%	12	22%	4	7%	6	11%	6	11%	0	0%	0	0%
[81, 90]	441 a 495	4	7%	8	15%	5	9%	3	5%	18	33%	6	11%	5	9%	4	7%	2	4%	0	0%	0	0%
[91, 100]	496 a 550	10	18%	5	9%	0	0%	2	4%	24	44%	2	4%	2	4%	4	7%	6	11%	0	0%	0	0%

Os resultados dos primeiros 20% melhores resultados, ou seja, os 110 primeiros testes podem ser visualizados também através do gráfico 3.26, Nele são apresentados os valores referentes à distribuição dos algoritmos vitoriosos.

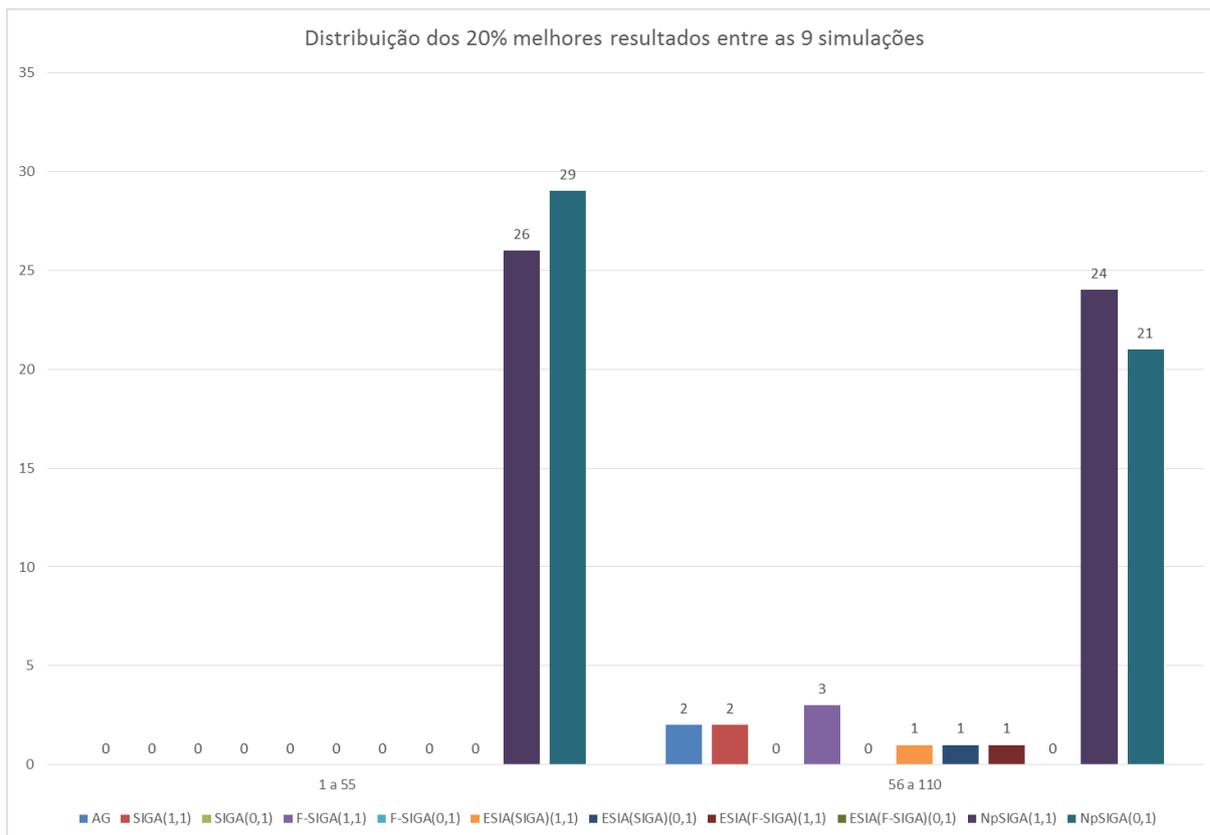


Gráfico 3.26 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema *pcb1173*.

A partir desses resultados é possível observar os seguintes fatos para os 110 melhores resultados, que representam os 20% melhores:

- Os algoritmos NpSIGA obtiveram 100 dos melhores resultados, ou seja, 90,9%;
- As outras 9 simulações foram vitoriosas em apenas 10 testes, o que representam 9,1% dos melhores resultados;
- Desses 10 resultados, apenas 2 foram gerados pelo Algoritmo Genético; 2 pelo SIGA; 3 pelo F-SIGA; e, 3 pelo ESIA.

Ao considerar apenas os outros resultados obtidos a partir dos outros 9 algoritmos, ou seja, desconsiderando os resultados obtidos através dos algoritmos NpSIGA, a distribuição dos algoritmos vitoriosos pode ser visualizado no gráfico 3.27

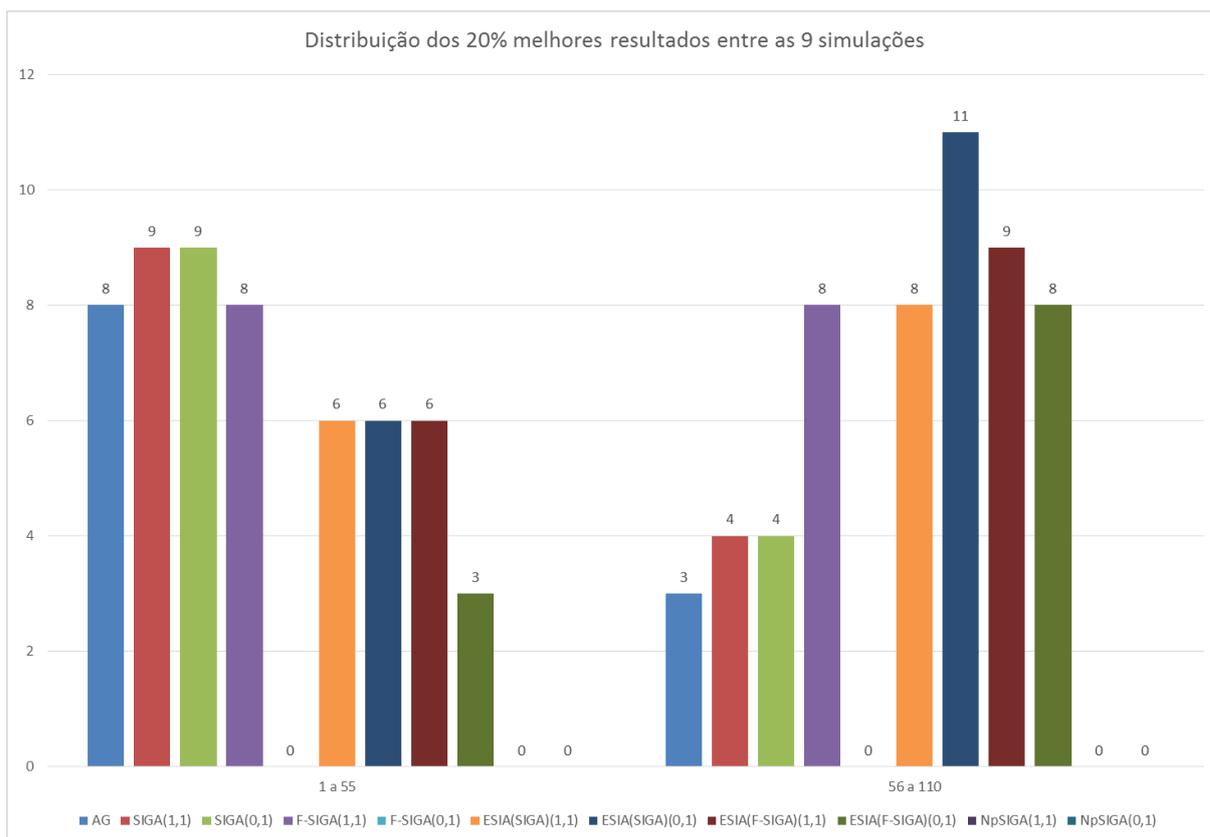


Gráfico 3.27 – Gráfico de distribuição dos algoritmos vitoriosos para os 20% melhores resultados das simulações do problema *pcb1173* sem os resultados do algoritmo NpSIGA.

E, assim, é possível observar os seguintes fatos ao considerar apenas os 55 melhores resultados, ou seja, os 10% melhores:

- Os Algoritmos Genéticos obtiveram os melhores resultados em 8 testes, ou seja, 14,6% dos resultados;
- Os algoritmos de Interação Social obtiveram os melhores resultados nos 47 testes restantes, ou seja, 85,4% dos resultados;
- O algoritmo SIGA foi vitorioso em 18 testes, ou seja, 32,7% dos resultados;
- O algoritmo F-SIGA foi vitorioso em 8 testes, ou seja, 14,6% dos resultados;
- Os algoritmos (1,1) obtiveram os melhores resultados em 29 testes, ou seja, 52,7% dos resultados;

- Os algoritmos (0,1) obtiveram os melhores resultados em 18 testes, ou seja, 32,7% dos resultados;
- Os algoritmos ESIA obtiveram os melhores resultados também em 21 testes, ou seja, 38,2% dos resultados;

### 3.5. CONSIDERAÇÕES FINAIS

Neste capítulo foram apresentados os critérios e as categorias de problemas utilizados, sendo todos problemas de otimização, com o objetivo de minimizar as funções para os problemas de otimização global com (4) e sem restrições (3); e, para instâncias (4) do Problema do Caixeiro Viajante.

Cada um desses problemas foi utilizado para a realização das simulações e testes para os métodos propostos no capítulo anterior. E, assim, foram realizados um total de 107 simulações, sendo cada um executado 50 vezes, e o que totaliza 5.350 testes.

Os resultados foram apresentados e brevemente descritos e, em resumo, pode-se observar na tabela 3.29 os seguintes resultados.

Tabela 3.29 – Resumo dos resultados obtidos nas 107 simulações.

Problema	Algoritmo	Melhor Resultado	Resultado Ótimo	Atingiu o Ótimo?	
Sem Restrições	$f_1$	SIGA(0,1)	0,08214600	0,00000000	Não
	$f_6$	SIGA(1,1)	79,30141381	0,00000000	Não
	$f_8$	GA	1,91433695	0,00000000	Não
Com Restrições	WBD	SIGA(0,1)	1,66437300	1,66437300	Sim
	DPV	ESIA(SIGA)(1,1)	6066,02936000	6059,94630000	Não
	MWTCS	ESIA(SIGA)(1,1)	0,00283500	0,00283500	Sim
	SRD	ESIA(F-SIGA)(1,1)	2797,42464000	2797,42464000	Sim
PCV	br26	ESIA(SIGA)(0,1)	17097,00000000	19633,00000000	Sim
	kroa100	ESIA(SIGA)(1,1)	45506,00000000	21282,00000000	Não
	att532	NpSIGA(1,1)	898484,36000000	27686,00000000	Não
		GA	1157339,84000000		Não
	pbc1173	NpSIGA(1,1)	984707,21000000	56892,00000000	Não
		GA	1130730,02000000		Não

No capítulo a seguir são apresentadas as considerações finais, através da sumarização e conclusões; e, as limitações da tese e trabalhos futuros.

# CAPÍTULO IV

## 4. CONSIDERAÇÕES FINAIS

### 4.1. SUMARIZAÇÃO E CONCLUSÕES

Este trabalho foi proposto com o objetivo de desenvolver uma nova metaheurística híbrida de busca inspirada na natureza, que foi denominada de **Algoritmo Genético com Interação Social Nebulosa** ou, simplesmente, algoritmo **F-SIGA**.

Como forma de cumprir esse objetivo, inicialmente foi realizada uma contextualização e um paralelo entre a abordagem clássica dos Algoritmos Genéticos, propostos por HOLLAND (1975), o Algoritmo Genético Simples de GOLDBERG (1989), aspectos relativos à Teoria da Evolução de DARWIN (1859), questões inerentes à Sociobiologia, à Teoria dos Jogos, à Teoria dos Conjuntos e Sistemas Nebulosos, e outros aspectos.

A partir dessa contextualização surgiu a motivação para a proposição e desenvolvimento dos algoritmos de interação social propostos no capítulo dois. É importante observar que o algoritmo SIGA e os métodos de seleção baseados no jogo Dilema do Prisioneiro foram objeto de estudo da dissertação de mestrado do autor (TEIXEIRA, 2005).

Antes da realização dessa dissertação, o trabalho de LEHRER (2000) foi estudado e, a partir dele, foi desenvolvido em BRITO (2004) uma versão do método de seleção baseado no jogo *Hawk-Dove* e, assim, surgiu o *Hawk-Dove* Torneio. Sendo que a única diferença foi o uso do método de seleção por torneio ao invés da roleta.

Posteriormente à dissertação de TEIXEIRA (2005), alguns experimentos foram realizados no intuito de aplicar os fundamentos da Teoria dos Jogos ao contexto de outras metaheurísticas, tais como: Sistemas Imunológicos Artificiais, Enxame de Partículas e Colônias de Formigas (BARREIRA e OLIVEIRA, 2006; BARREIRA et al., 2006a, 2006b, 2006c; SOUZA et al., 2006; FERREIRA et al., 2008a, 2008b; REGO et al., 2008;

TEIXEIRA et al., 2010a, 2010b). No entanto, essas abordagens não foram contempladas na tese, apesar de terem sido a princípio consideradas no material apresentado no exame de qualificação de tese em julho de 2007.

Na primeira metade de 2009, durante o desenvolvimento do trabalho de BRITO (2011), surgiu o termo ESIA, com o mesmo significado empregado neste trabalho, porém ainda faltava algo que o conectasse com a estrutura dos Algoritmos Genéticos, pois foi pensado primeiramente apenas como uma extensão.

A confirmação de que o desenvolvimento de metaheurísticas com aspectos de interação social entre os indivíduos população valeriam a pena, surgiu apenas no decorrer do GECCO, *Genetic and Evolutionary Computation Conference*, em julho de 2009, quando da apresentação do trabalho de LAHOZ-BELTRA et al. (2009).

Esse trabalho aborda o uso da teoria dos jogos como fundamento para a definição de uma etapa de interação social, que ocorreu anteriormente ao processo de reprodução dos indivíduos de um Algoritmo Genético, ou seja, exatamente a mesma abordagem definida em TEIXEIRA (2005), que fora publicado nesse mesmo congresso três anos antes (TEIXEIRA et al., 2006) e no mesmo evento foi publicado TEIXEIRA et al. (2009).

Após a semana do congresso foi feito um esboço do que viria a ser o algoritmo ESIA, porém continuava faltando alguma conexão, ainda não identificada. E, assim, no mesmo ano foi definitivamente concebido e definido o algoritmo F-SIGA, exatamente com as características apresentadas neste trabalho. Os primeiros resultados surgiram em YASOJIMA e LOBATO (2009).

Consequentemente iniciou-se o processo de desenvolvimento de um framework capaz de realizar as simulações necessárias para os algoritmos SIGA e F-SIGA. O seu desenvolvimento iniciou a partir do segundo semestre de 2010 e evoluir até às vésperas da defesa desta tese. Ou seja, um processo de desenvolvimento, não somente do software, mas também de concepção dos algoritmos que durou quase dois anos.

Durante esse período, surgiu a possibilidade de ser realizado um estudo inicial da aplicação da versão N-pessoas do jogo Dilema do Prisioneiro nos Algoritmos Genéticos e, assim, surgiu o algoritmo NpSIGA no trabalho de DIAS et al. (2010).

Com os resultados obtidos nesse trabalho, um questionamento foi feito: como poderia ser utilizada a experiência adquirida pelos indivíduos no decorrer das disputas dos jogos, de forma que ela trouxesse alguma vantagem no processo de seleção? Foi a partir desse questionamento que surgiu o termo Fator de Experiência e que, por conseguinte, definiu a conexão que faltava para o surgimento do algoritmo ESIA.

Porém, a visão de que o algoritmo ESIA poderia ser, de fato, considerado um primeiro passo para a constituição de uma nova classe de Algoritmos Evolucionários, denominada de Algoritmos Evolucionários de Interação Social (ESIA, sigla do termo em inglês), somente foi vislumbrada com a construção deste documento.

Isso se dá ao fato dos resultados obtidos nas 107 simulações realizadas, nos 11 problemas selecionados, nas 3 diferentes categorias de problemas de otimização abordadas no decorrer do capítulo anterior. O principal objetivo das simulações não era conseguir encontrar os valores ótimos já conhecidos para os problemas, ou encontrá-los mais rapidamente conforme expresso na apresentação dos problemas de otimização global sem restrições.

A principal motivação para a realização das simulações é a validação dos métodos propostos, através dos resultados obtidos, mas sim, e fundamentalmente como metaheurísticas híbridas de busca inspiradas na natureza. No total de 107 simulações, os algoritmos de interação social foram vitoriosos em 10 dos 11 problemas, ou seja, em 90,9% dos problemas.

Em cada um das categorias de problemas abordados neste trabalho, os algoritmos de interação social obtiveram os seguintes índices de sucesso, em termos de conseguir alcançar as melhores soluções dentre os limites estabelecidos através das configurações dos parâmetros das simulações: (1) para os três problemas de otimização global sem restrições, 66,7%; (2) para os quatro problemas de otimização global com restrições, 100%; e, (3) para as quatro instâncias do Problema do Caixeiro Viajante, 100%.

No entanto, é possível visualizar um longo caminho a ser percorrido no desenvolvimento dessa nova classe de algoritmos evolucionários, o ESIA, de forma que possam passar a ser reconhecidos pela comunidade mundial de Computação Evolucionária,

a partir do momento que apresentarem resultados práticos mais viáveis. E, também, quando os seus mecanismos forem mais bem abstraídos, como por exemplo, a quantidade de parâmetros que necessitam ser inicializados e, a definição e atribuição das estratégias de comportamento aos indivíduos.

Dessa forma, conclui-se que os objetivos estipulados para este trabalho foram cumpridos ao propor o algoritmo F-SIGA e, também, foram de certa forma extrapolados, com a apresentação do algoritmo NpSIGA, que juntos ao SIGA e F-SIGA, culminaram na especificação do algoritmo ESIA e o Fator de Experiência. Este a princípio e a partir dos resultados obtidos nas simulações mostrou-se bastante promissor, pois foi vitorioso em 45,4% dos problemas.

## **4.2. LIMITAÇÕES DA TESE E TRABALHOS FUTUROS**

Apesar da afirmação, na seção anterior, ao dizer que os objetivos deste trabalho foram alcançados, ainda há algumas limitações referentes ao que foi apresentado. E dentre elas, algumas são destacadas a seguir.

1. Há limitações ainda referentes ao embasamento teórico necessário para tornar os métodos propostos mais bem bio-inspirados, tais como conhecimentos sobre evolução social, Darwinismo Social, que foram sutilmente apresentados;
2. A dificuldade em definir os parâmetros das configurações das simulações acabou gerando certa limitação, no sentido de ser necessário focar o principal aspecto que se desejava validar, que no caso passou a ser o bom funcionamento dos algoritmos de interação social;
3. A quantidade de dados gerados na simulações gerou dificuldade no processo de descrição e análise. E, dessa forma, não foi contemplada um estudo estatístico mais aprofundado, no sentido de conseguir gerar fatos referentes ao comportamento, por exemplo, dos algoritmos em relação

às determinadas configurações de parâmetros ou, até mesmo, para quais categorias de problemas são mais adequados.

Essas limitações possibilitam vislumbrar a realização de trabalhos futuros e, assim, é possível pensar no sentido de integrar e possibilitar que novos alunos ingressem no universo da Computação Bio-inspirada, sejam eles de graduação ou pós-graduação. Sendo assim, a seguir estão listados alguns trabalhos futuros.

1. Realização de novas simulações para os mesmos problemas apresentados neste trabalho, de forma a explorar mais as diversas possibilidades de configurações de parâmetros e, assim, poder mapear o seu funcionamento;
2. Desenvolvimento de novas aplicações da etapa de Interação Social em outras metaheurísticas, para maior exploração dos mecanismos apresentados para o SIGA, F-SIGA, NpSIGA e ESIA;
3. Aprofundamento dos estudos relativos à Teoria dos Jogos e à Interação Social, que é matéria de estudo no Programa de Pós-Graduação em Teoria e Pesquisa do Comportamento, mais especificamente no Grupo de Estudos Avançados em Psicologia Evolucionista (GEAPE), com o objetivo de aprimorar a bio-inspiração do ESIA. E até mesmo visualizar novas aplicações em contextos diferentes da engenharia e computação;
4. Realizar publicações em periódicos classificados como Qualis A1, capítulos de livro e, até mesmo, livro;
5. Realizar a reconstrução do framework, que foi desenvolvido através da linguagem de programação JAVA, ao definir uma arquitetura de software, que permita a geração de uma API. E a migração para a linguagem C++;

6. Com a migração para a linguagem C++ objetiva-se passar a trabalhar com o paradigma de multi-CPU's e multi-GPU's, no intuito de tornar a execução desses algoritmos “quase em tempo real”;
7. Ampliar a aplicação do algoritmo ESIA em outras heurísticas ou metaheurísticas com abordagem populacional, conforme mencionado no decorrer do trabalho;
8. Avaliar os passos dados pelo Prof. Robert Reynolds, da Universidade de Wayne, no caminho feito pelos Algoritmos Culturais, de forma que passaram a ser reconhecidos como uma classe de algoritmos evolucionários.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ALFARES, F. S.; ESAT, I. I. **Real-Coded Quantum Inspired Evolution Algorithm Applied to Engineering Optimization Problems**. In: Proceedings of the IEEE Second International Symposium on Leveraging Applications and Formal Methods, Verification and Validation, p. 169-176, 2007.
- ANGELINE, Peter J.; POLLACK, Jordan B. **Competitive Environments Evolve Better Solutions for Complex Tasks**. In Proceedings of the 5<sup>th</sup> International Conference on Genetic Algorithms, pages 264-270, 1993.
- ANGELINE, Peter J. **An Alternate Interpretation of the Iterated Prisoner's Dilemma and the Evolution of Non-Mutual Cooperation**. In Artificial Life IV: Proceedings of the Fourth International Workshop on the Synthesis and Simulation of Living Systems, pages 350-352, R. A. Brooks and P. Maes, eds, A Bradford Book, The MIT Press, Cambridge, Massachusetts, USA, July 6-8 1994.
- ARFI, Badredine. **Linguistic Fuzzy-Logic Social Game of Cooperation**. In Journal of Rationality and Society, Volume 8, No. 4, pages 471-537, Sage Publications, 2006.
- ARORA, J. S. **Introduction to Optimum Design**. McGraw-Hill, New York, 1989.
- ASHLOCK, Daniel. **Evolutionary Computation for Modeling and Optimization**. Springer, 2006.
- AXELROD, Robert. **The Evolution of Cooperation**. Basic Books, 1984.
- AXELROD, Robert; HAMILTON, William D. **The Evolution of Cooperation**. In Science, Volume 211, pages 1390-1396, 27 March 1981.
- BÄCK, Thomas.; FOGEL, David. B.; MICHALEWICZ, Zbigniew. **Evolutionary Computation 1: Basic Algorithms and Operators**. Institute of Physics Publishing, 2000a.
- BÄCK, Thomas.; FOGEL, David. B.; MICHALEWICZ, Zbigniew. **Evolutionary Computation 2: Advanced Algorithms and Operators**. Institute of Physics Publishing, 2000b.
- BÄCK, Thomas; HOFFMEISTER, Frank. **Extended Selection Mechanisms in Genetic Algorithms**. In Proceedings of the 4th International Conference on Genetic Algorithms (ICGA'91), pages 92-99, San Diego, CA, USA, July 1991.
- BALLARD, D.H. **An Introduction to Natural Computation**. The MIT Press, 1997.
- BANERJEE, Amit. **A Dynamic Game-Theoretic Approach to the Modified Prisoner's Dilemma**. In Logic Journal of the IGPL, Volume 13, No. 5, pages 493-502,

September 2005.

- BANNISTER, Robert C. **Social Darwinism: Science and Myth in Anglo-American Social Thought**. Philadelphia: Temple University Press, 1979.
- BARREIRA, André Ferry; OLIVEIRA, Carlos Eduardo de Jesus Guimarães. **EAISO-GT: Uma Nova Meta-Heurística de Otimização Avançada Baseada na Técnica dos Sistemas Imunológicos Artificiais e na Teoria dos Jogos**. Trabalho de Conclusão de Curso, Bacharelado em Ciência da Computação, Centro Universitário do Pará, 2006.
- BARTZ-BEIELSTEIN, T.; PARSOPOULOS, K. E.; VRAHATIS, M. N. **Design and Analysis of Optimization Algorithms Using Computational Statistics**. In Journal of Applied Numerical Analysis and Computational Mathematics, Volume 1, Issue 2, pages 413-433, Wiley-VCH Verlag GmbH & Co. KGaA, Weinheim, 2004.
- BELEA, R.; CARAMAN, S.; PALADE, V. **Diagnosing the Population State in a Genetic Algorithm Distance**. **Proceedings of Knowledge-based and Intelligent Engineering Systems**, KES 2004, pp. 246-255, 2004.
- BELEGUNDU, A. D. **A Study of Mathematical Programming Methods for Structural Optimization**. Technical Report, Department of Civil and Environmental Engineering. Univeristy of Iowa, Iowa, USA, 1982.
- BÊRNI, D. de A. **Teoria dos Jogos: Jogos de Estratégia, Estratégia Decisória, Teoria de Decisão**. Rio de Janeiro: Reichmann & Affonso Ed., 2004.
- BLICKLE, Tobias; THIELE, Lothar. **A Comparison of Selection Schemes used in Genetic Algorithms**. Computer Engineering and Communication Networks Lab (TIK). Swiss Federal Institute of Technology (ETH). TIK Report Nr. 11. Version 2. 2nd Edition. Zurich, Switzerland, 1995.
- BLUM, Christian; ROLI, Andrea. **Metaheuristics in Combinatorial Optimization: Overview and Conceptual Comparison**. In ACM Computing Surveys (CSUR), Volume 35, No. 3, pages 268-308, September 2003.
- BORGES, P. S. S. **A Model Of Strategy Games Based on The Paradigm of the Iterated Prisoner's Dilemma Employing Fuzzy Sets**. 1996. Tese (Doutorado em Engenharia de Produção) – Universidade Federal de Santa Catarina, Florianópolis.
- BORGES, P. S. S.; PACHECO, Roberto C. S.; BARCIA, Ricardo M.; KHATOR, Suresh K. **A Fuzzy Approach to the Prisoner's Dilemma**. In Journal of BioSystems, 41, pages 127-137, Elsevier, 1997.
- BORNHOLDT, S; SNEPPEN, K. **Robustness as an Evolutionary Principle**. In Proceedings of The Royal Society of London, B 267, 2000. p. 2281 – 2286.
- BRAJEVIC, I.; TUBA, M.; SUBOTIC, M. **Improved Artificial Bee Colony Algorithm for Constrained Problems**. In: Proceedings of the 11<sup>th</sup> WSEAS International

Conference on Neural Networks, Fuzzy Systems and Evolutionary Computing, p. 185-190, 2010.

BREMBS, Björn. **Chaos, Cheating and Cooperation: Potential Solutions to the Prisoner's Dilemma**. In OIKOS 76, pages 14-24, Copenhagen, 1996.

BRITO, Felipe Houat. **Hawk-Dove Torneio: Um Novo Método de Seleção para os Algoritmos Genéticos Baseado na Teoria dos Jogos Evolucionários e Estratégias Evolucionárias**. 2004. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) – Centro Universitário do Estado do Pará – CESUPA.

BRITO, Felipe Houat. **G.A.I.A.: Uma Proposta de Agente Inteligente Acoplado a Algoritmos Evolucionários para Ajuste Dinâmico de Parâmetros através de Conceitos de Design Inteligente e Lógica Fuzzy**. 2011. Dissertação (Mestrado em Engenharia Elétrica – Computação Aplicada) – Universidade Federal do Pará – Belém.

BRITO, Felipe Houat de; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **A Introdução da Interação Fenotípica em Algoritmos Genéticos Através dos Jogos Evolucionários e da Codificação e Transmissão Genética do Comportamento**. In: SBAI/LARS - VII Simpósio Brasileiro de Automação Inteligente / Latin American IEEE Robotics Symposium, Maranhão, Brasil, 2005.

BRITO, Felipe Houat de; TEIXEIRA, Artur Noura ; TEIXEIRA, Otávio Noura ; OLIVEIRA, Roberto Célio Limão de. **Aplicando Datamining com Redes SOM em Base de Dados de Execuções de Algoritmos Genéticos Utilizando os Novos Métodos de Seleção Hawk-Dove Roleta e Hawk-Dove Torneio**. In Proceedings of Conferencia Latinoamericana de Informática, Santiago, Chile, 2006a.

BRITO, Felipe Houat; TEIXEIRA, Artur Noura; TEIXEIRA, Otávio Noura; DE OLIVEIRA, Roberto Célio Limão. **A Fuzzy Approach to Control Genetic Algorithm Parameters**. In Proceedings of the VIII Argentine Symposium on Artificial Intelligence, Mendoza, Argentina, 4-5 September 2006b.

BRITO, Felipe Houat; TEIXEIRA, Artur Noura; TEIXEIRA, Otávio Noura; DE OLIVEIRA, Roberto Célio Limão. **A Fuzzy Intelligent Controller for Genetic Algorithms' Parameters**. In: ICNC 2006 / FSKD 2006 – II International Conference on Natural Computation and III International Conference on Fuzzy Systems and Knowledge Discovery. Xi'an, China, 2006c.

BRITO, Felipe Houat; TEIXEIRA, Artur Noura; TEIXEIRA, Otávio Noura; DE OLIVEIRA, Roberto Célio Limão. **A Fuzzy Approach to Control Genetic Algorithm Parameters**. SADIO Electronic Journal of Informatics and Operations Research, Volume 7, no. 1, pages 12-33, 2 February 2007a.

BRITO, Felipe Houat; TEIXEIRA, Artur Noura; TEIXEIRA, Otávio Noura; DE OLIVEIRA, Roberto Célio Limão. **G.A.I.A.: A Fuzzy Intelligent Controller for Genetic Algorithms Parameters and Performance**. In Proceedings of Genetic and

Evolutionary Methods (GEM'07), Worldcomp'07 – World Congress in Computer Science, Computer Engineering and Applied Computing, Las Vegas, Nevada, USA, 25-28 June 2007b.

BRITO, Felipe Houat; TEIXEIRA, Otávio Noura; DE OLIVEIRA, Roberto Célio Limão. **Hawk-Dove Torneio: Um Novo Método de Seleção para os Algoritmos Genéticos Baseado na Teoria dos Jogos Evolucionários**. In: SEPAI 2006 – XX Semana Paraense de Informática e Telecomunicações. Belém, Pará, Brasil, 2006.

CANIGNA, L. C.; ESQUIVEL, S. C. **Solving Engineering Optimization Problems with the Simple Constrained Particle Swarm Optimizer**. *Informatica*, 32, p. 319-326, 2008.

CANTÚ-PAZ, Erick. **Order Statistics and Selection Methods of Evolutionary Algorithms**. In *Information Processing Letters, Special Issue on Evolutionary Computing*, Volume 82, No. 1, pages 15-22, Elsevier North-Holland Inc., April 2002.

CARTWRIGHT, H. M. **The Genetic Algorithm in Science**. Physical and Theoretical Chemistry Laboratory, Oxford University, UK, 1996 (não publicado). Disponível em: [http://www.dai.ed.ac.uk/groups/evalg/Local\\_Copies\\_of\\_Papers/Cartwright.The\\_GA\\_In\\_Science.ps.gz](http://www.dai.ed.ac.uk/groups/evalg/Local_Copies_of_Papers/Cartwright.The_GA_In_Science.ps.gz). Acessado em: 31 jul 2002.

CASTRO, Leandro Nunes de; VON ZUBEN, Fernando J. **Recent Developments in Biologically Inspired Computing**. Idea Group Publishing, 2005, 439 pages.

CHANG, Pei-Chan; WANG, Yen-Wen; LIU, Chen-Hao. **New Operators for Faster Convergence and Better Solution Quality in Modified Genetic Algorithm**. *Advances in Natural Computation. Lecture Notes in Computer Science*, v.3611, 2005.

CHONG, Siang Y.; YAO, Xin. **Behavioral Diversity, Choices and Noise in the Iterated Prisoner's Dilemma**. In *IEEE Transactions on Evolutionary Computation*, Volume 9, No. 6, pages 540-551, December 2005.

CHONG, Siang Y.; YAO, Xin. **Multiple Choices and Reputation in Multiagent Interactions**. In *IEEE Transactions on Evolutionary Computation*, 2007.

CHONG, Siang Yew; YAO, Xin. **Self-Adapting Payoff Matrices in Repeated Interactions**. In *Proceedings of the 2006 IEEE Symposium on Computational Intelligence and Games (CIG'06)*, pages 103-110, IEEE Press, Piscataway, NJ, USA, 22-24 May 2006, Reno/Lake Tahoe, Nevada, USA.

CHONG, Siang Yew; YAO, Xin. **The Impact of Noise on Iterated Prisoner's Dilemma with Multiple Levels of Cooperation**. In *Proceedings of the Congress on Evolutionary Computation (CEC'04)*, pages 348-355, IEEE Press, Piscataway, NJ, USA, 19-23 June 2004, Portland, Oregon, USA.

COELLO, Carlos A. C. **Use of a Self-Adaptive Penalty Approach for Engineering Optimization Problems**. *Computers in Industry*, 41, p. 113-127, 2000.

- COELLO, Carlos A. C. **Theoretical and Numerical Constraint-Handling Techniques Used with Evolutionary Algorithms: a Survey of the State of the Art.** Computer Methods in Applied Mechanics and Engineering, 191 (11-12), p. 1245-1287, 2002.
- COELLO, Carlos A. C.; MONTES, Efrén. M. **Constraint-Handling in Genetic Algorithms Through the Use of Dominance-Based Tournament Selection.** Advanced Engineering Informatics, 16 (11-12), p. 193-203, 2002.
- DARWEN, Paul J.; YAO, Xin. **Co-Evolution in Iterated Prisoner's Dilemma with Intermediate Levels of Cooperation: Application to Missile Defense.** In International Journal of Computational Intelligence and Applications, 2, p. 83-107, 2002.
- DARWEN, Paul J.; YAO, Xin. **Why More Choices Cause Less Cooperation in Iterated Prisoner's Dilemma.** In Proceedings of the 2001 IEEE Congress on Evolutionary Computation (CEC'01), pages 987-994, Seoul, Korea, 27-30 May 2001.
- DARWIN, Charles. **On the Origin of Species: by means Natural Selection, or preservation of favored races in the struggle for life.** London: John Murray, 1859.
- DARWIN, Charles. **The Descent of Man, and Selection in Relation to Sex.** London: John Murray, 1882.
- DAWKINS, Richard. **The Extended Phenotype: the long reach of the gene.** Oxford University Press, 1982.
- DAVIS, L. **Handbook of Genetic Algorithms.** Van Nostrand Reinhold, New York, 1991.
- DAY, Troy; TAYLOR, Peter D. **Unifying Genetic and Game Theoretic Models of Kin Selection for Continuous Traits.** In Journal of Theoretic Biology, Volume 194, pages 391-407, Academic Press, 1998.
- DE CASTRO, L. N. **Fundamentals of Natural Computing: Basic Concepts, Algorithms, and Applications.** Chapman and Hall/CRC, first edition, 2006.
- DE CASTRO, L. N. **Computação Natural: Uma Jornada Ilustrada.** São Paulo: Editora Livraria da Física, 2010.
- DE JONG, Kenneth Alan. **An Analysis of the Behavior of a Class of Genetic Adaptive Systems.** PhD Thesis. University of Michigan, Ann Arbor, 1975.
- DE JONG, Kenneth Alan. **Genetic Algorithms Are NOT Function Optimizers.** In Proceedings of Foundations of Genetic Algorithms (FOGA'92), pages 5-17, 1992.
- DE JONG, Kenneth Alan. **Two Grand Challenges for EC: Unification and Expansion.** In Frontiers of Evolutionary Computation, Anil Menin eds., pages 37-47, Kluwer Academic Publishers, 2004.

- DE JONG, Kenneth Alan. **Evolutionary Computation: An Unified Approach**. A Bradford Book. The MIT Press, Cambridge, Massachusetts, 2006.
- DEB, Kalyamon. **Optimal Design of a Welded Beam via Genetic Algorithms**. AIAA Journal, 29 (11), p. 2013-2015, 1991.
- DEB, Kalyamon. **GeneAS: a Robust Optimal Design Technique for Mechanical Component Design**. In: D. Dasgupta and Z. Michalewicz, editors, *Evolutionary Algorithms in Engineering Applications*, p. 497-514, Springer, 1997.
- DIAS, Lilian de J. C.; PINHEIRO, Pedro V. P.; FRANCO, Roberto Y. da S. **Algoritmo Genético com Interação Social N-Pessoas (NpSIGA)**. 2010. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) – Centro Universitário do Estado do Pará – CESUPA.
- DIGALAKIS, Jason G.; MARGARITIS, Konstantinos G. **An Experimental Study of Benchmarking Functions for Genetic Algorithms**. In *International Journal of Computer Mathematics*, Volume 79, No. 4, pages 403-416, 2002.
- DIGALAKIS, Jason G.; MARGARITIS, Konstantinos G. **On Benchmarking Functions for Genetic Algorithms**. In *International Journal of Computer Math*, Volume 77, pages 481-506, 2001.
- DUBOIS, Didier; PRADE, Henri. **Fuzzy Sets and Systems: Theory and Applications**. In *Mathematics in Science and Engineering*, Volume 144, Academic Press Inc., 1980.
- EBERHART, R.; SIMPSON, P.; DOBBINS, R. **Computational Intelligence PC Tools: an indispensable resource for the latest in fuzzy logic, neural network and evolutionary computing**. American Press Inc., 1996.
- FALCO, I. De; BALIO, R. Del; CIOPPA, A. Della; TARANTINO, E. **A Comparative Analysis of Evolutionary Algorithms for Function Optimization**. In *Proceedings of the Second Online Workshop on Evolutionary Computation*, pages 29-32, Nagoya, Japan, 1996.
- FIANI, R. **Teoria dos Jogos: Para Cursos de Administração e Economia**. 3ª Reimpressão. Rio de Janeiro: Elsevier, 2004.
- FICICI, Sevan G.; MELNIK, Ofer; POLLACK, Jordan B. **A Game-Theoretic Investigation of Selection Methods Used in Evolutionary Algorithms**. In *Proceedings of the Congress on Evolutionary Computation (CEC'00)*, Volume 2, pages 880-887, La Jolla, CA, USA, 16-19 July 2000.
- FICICI, Sevan G.; POLLACK, Jordan B. **A Game-Theoretic Approach to the Simple Coevolutionary Algorithm**. *Lecture Notes in Computer Science*, Volume 1917, *Proceedings of the 6th International Conference on Parallel Problem Solving from Nature*, pages 467-476, 2000.

- FICICI, Sevan G.; POLLACK, Jordan B. **Game Theory and the Simple Coevolutionary Algorithm: Some Preliminary Results on Fitness Sharing**. In Genetic and Evolutionary Computation Conference (GECCO'01), Workshop on Coevolution: Turning Adaptive Algorithms Upon Themselves, San Francisco, California, USA, July 7-11 2001.
- FOGEL, David. B. **Evolutionary Computation: Toward a New Philosophy of Machine Intelligence**. Second Edition. IEEE Press, 2000.
- FORBES, Nancy. **Imitation of Life: How Biology is Inspiring Computing**. The MIT Press, Cambridge, Massachusetts, 2005.
- FREAN, Marcus. **The Evolution of Degrees of Cooperation**. In Journal of Theoretical Biology, Volume 182, No. 4, pages 549-559, Academic Press, October 1996.
- FREISLEBEN, Bernd; MERZ, Peter. **New Genetic Local Search Operators for the Traveling Salesman Problem**. In H. M. Voigt, W Ebeing, I. Rechenberg and P. Schwefel, eds., Proceedings of the 4th Conference on Parallel Problem Solving from Nature (PPSN IV), pages 890-900, Springer, 1996.
- FUDENBERG, Drew; TIROLE, Jean. **Game Theory**. The MIT Press, 1991.
- FUTUYAMA, D. J. **Biologia Evolutiva**. 2<sup>a</sup> edição. Ribeirão Preto: FUNPEC-RP, 2002.
- GOLDBERG, David E. **Genetic Algorithms in Search, Optimization and Machine Learning**. Addison Wesley Longman, Inc., 1989.
- GOLDBERG, David E. **The Design of Innovation: Lessons from and for Competent Genetic Algorithms**. Kluwer Academic Publishers, 2002.
- GRIM, Patrick.; MAR, Gary; DENIS, Paul St. **The Philosophical Computer: Exploratory Essays in Philosophical Computer Modeling**. The MIT Press, 1998.
- HAUERT, C.; SCHUSTER, H. G. **Effects of Increasing the Number of Players and Memory Size in the Iterated Prisoner's Dilemma**. In Proceedings of the Royal Society B: Biological Sciences, Volume 264, pages 513-519, April 1997.
- HAUPT, Randy L.; HAUPT, Sue Ellen. **Practical Genetic Algorithms**. Second Edition, A Wiley-Interscience Publication, 2004.
- HE, Q.; WANG, L. **An Effective Co-evolutionary Particle Swarm Optimization for Constrained Engineering Design Problem**. Engineering Applications of Artificial Intelligence, Elsevier, 20 (1), p. 89-99, 2007.
- HO, Yu-Chi; PEPYNE, David, L. **Simple Explanation of the No Free Lunch Theorem of Optimization**. In Proceedings of the 40th IEEE Conference on Decision and Control, Volume 5, pages 4409-4414, Orlando, Florida, USA, 2001.

- HODGSON, Geoffrey M. **Social Darwinism in Anglophone Academic Journals: A Contribution to the History of the Term.** *Journal of Historical Sociology*, 17, p. 428 – 463, 2004.
- HOLLAND, John. **Adaptation in Natural and Artificial Systems.** University of Michigan Press, Ann Arbor, 1975.
- HUTTER, Marcus. **Fitness Uniform Selection to Preserve Genetic Diversity.** In *Proceedings of the Congress on Evolutionary Computation (CEC'02)*, Volume 1, pages 783-788, Honolulu, Hawaii, USA, 2002.
- JANG, Daniel; WHIGHAM, Peter A.; DICK, Grant. **On Evolving Fixed Pattern Strategies for Iterated Prisoner's Dilemma.** In *Proceedings of the 27th Australian Conference on Computer Science*, Volume 26, pages 241-247, Dunedin, New Zealand, 2004.
- KANDEL, Abraham; LANGHOLZ, Gideon. **Fuzzy Control Systems.** CRC Press, 1993.
- KANNAN, K; KRAMER, S. N. **An Augmented Lagrange Multiplier Based Method for Mixed Integer Discrete Continuous Optimization and its Applications to Mechanical Design.** *Transactions of the ASME Journal of Mechanical Design*, 116, p. 318-320, 1994.
- KERRE, Etienne E.; MORDESON, John N. **A Historical Overview of Fuzzy Mathematics.** In *Journal of New Mathematics and Natural Computation*, Volume 1, No. 1, pages 1-26, World Scientific Publishing Company, 2005.
- KUREICHICK, Victor M.; MIAGKIKH, Victor V.; TOPCHY, Alexander P. **Genetic Algorithm for Solution of the Traveling Salesman Problem with New Features Against Premature Convergence.** In *Proceedings of ECDC'96*, Plymouth, UK, 1996.
- LAHOZ-BELTRA, L. R.; OCHOA, G.; AICKELIN, U. **Cheating for Solving Problem: a Genetic Algorithm with Social Interactions.** In: *Proceedings of the 10<sup>th</sup> Annual Conference on Genetic and Evolutionary Computation*, p. 811-818, 2009.
- LARRAÑAGA, P.; KUIJPERS, C. M. H.; MURGA, R. H. INZA, I.; DIZDAREVICS, S. **Genetic Algorithms for the Traveling Salesman Problem: A Review of Representations and Operators.** In *Artificial Intelligence Review*, Volume 13, No. 2, pages 129-170, Springer, April 1999.
- LEFORT, Virginie; KNIBBE, Carole; BESLON, Guillaume; FAVREL, Joël. **A Bio-Inspired Genetic Algorithm with a Self-Organizing Genome: The RBF-Gene Model.** In Kalyanmoy Deb et al., *Genetic and Evolutionary Computation - GECCO 2004*, Part II, LNCS 3103, Springer, p. 406-407.
- LEHRER, Cristiano; BORGES, Paulo Sérgio da Silva (orientador). **Operador de Seleção**

**para Algoritmos Genéticos Baseado no Jogo Hawk-Dove.** 2000. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Santa Catarina – Florianópolis.

LESLIE, David. **Dynamics of Games: An Analysis of Strategy Evolution Using Genetic Algorithms.** Technical Report, Queens' College, Cambridge, June 1999.

LEWONTIN, R. C. **Evolution and The Theory of Games.** *J. theor. Biol.* 1, 382-403. 1961.

LI, Fa-Chao; SU, Lian-Qing; RAN, Hai-Chao. **The Fuzzy Genetic Algorithm Based on Rule.** In Proceedings of the Fourth International Conference on Machine Learning and Cybernetics, pages 2454-2459, Guangzhou, 18-21 August 2005.

LIANG, J. J.; SUGANTHAN, P. N.; DEB, K. **Novel Composition Test Function for Numerical Global Optimization.** In Proceedings of IEEE Swarm Intelligence Symposium (SIS'05), pages 68-75, 8-10 June 2005.

LUCE, R. D.; RAIFFA, H. **Games and Decisions: Introduction to a Critical Survey.** Dover Publications, Inc., 1985.

LUNACEK, M.; WHITLEY, D.; KNIGHT, J. **Measuring Mobility and the Performance of Global Search Algorithms.** In Proceedings of Genetic and Evolutionary Computation Conference (GECCO'05), pages 1209-1216, Washington DC, USA, 2005.

MACNISH, C. **Benchmarking Evolutionary Algorithms: The Huygens Suite.** In Proceedings of Genetic and Evolutionary Computation Conference (GECCO'05), Late-Breaking Papers Session, Washington DC, USA, June 2005.

MANHART, K. **Cooperation in 2- and N-Person Prisoner's Dilemma Games: A Simulation Study.** University Bern, Munich, Germany, 2007.

MATHEW, Raj; KAIMAL, M. R. **A Fuzzy Approach to the Prisoner's Dilemma Game Using Fuzzy Expected Value Models.** Proceedings of the Conference on Convergent Technologies for Asia-Pacific Region (TENCON'03), Volume 3, pages 1104-1108, Bangalore, India, 15-17 October 2003.

MELEAU, Nicolas; LATTAUD, Claude. **The Artificial Evolution of Cooperation.** Lecture Notes in Computer Science, Volume 1063, Proceedings of the European Conference on Artificial Evolution, pages 159-180, 1995.

MERZ, Peter; FREISLEBEN, Bernd. **Genetic Local Search for the Traveling Salesman Problem: New Results.** In Proceedings of the IEEE Conference on Evolutionary Computation, pages 159-164, Indianapolis, IN, USA, 13-16 April 1997.

MICHALEWICZ, Z. **Genetic Algorithms + Data Structures = Evolution Programs.** Springer-Verlag, 1999.

- MIRANDA, Vladimiro. **Computação Evolucionária Fenotípica: Versão 2.0**. Instituto de Engenharia de Sistemas e Computadores - INESC. Universidade do Porto, Portugal, 2005.
- MITCHELL, Melaine. **An Introduction to Genetic Algorithms**. 5th edition. A Bradford Book. The MIT Press, Cambridge, Massachusetts, 1999.
- MOREIRA, Renato Simões. **Algoritmo Genético Retroviral Iterativo**. 2010. Dissertação (Mestrado em Engenharia Elétrica – Computação Aplicada) – Universidade Federal do Pará – Belém.
- NASH, John Forbes. **Non-Cooperative Games**. PhD Thesis. Department of Mathematics, Princeton University, 1950.
- NASH, John Forbes. **Two-Person Cooperative Games**. In *Econometrica*, Volume 21, No. 1, pages 128-140, January 1953.
- NEUMANN, J. V.; MORGENSTERN, O. **Theory of Games and Economic Behavior**. Princeton University Press, 1944.
- NICOARĂ, E. S. **Mechanisms to Avoid the Premature Convergence of Genetic Algorithms**. *Petroleum - Gas University of Ploiești Bulletin, Math. - Info. - Phys. Series*, vol. LXI, 1/2009, pp.87-96.
- NOBREGA, C. **O Glorioso Acidente: a Ciência e o Acaso da Mente**. Rio de Janeiro: Editora Objetiva, 1998.
- O'RIORDAN, C. **Iterated Prisoner's Dilemma: A Review**. Technical Report NUIG-IT-260601. Department of Information Technology. National University of Ireland, Galway, 2001. Disponível em: <http://www.it.nuigalway.ie/TR/rep01/NUIG-IT-260601.ps.gz>. Acessado em: 11 ago 2002.
- OTMAN, Abdoun; JAAFAR, Abouchabaka. **A Comparative Study of Adaptive Crossover Operators for Genetic Algorithms to Resolve the Traveling Salesman Problem**. *International Journal of Computer Applications*, v. 31, No. 11, 2011.
- OTTO, E.; YAMAMOTO, M. E. **Psicologia Evolucionista**. Rio de Janeiro: Guanabara Koogan, 2009.
- POUNDSTONE, W. **Prisoner's Dilemma: John Von Neumann, Game Theory, and The Puzzle of the Bomb**. Anchor Books, 1992.
- RAMAN, Kalyan. **A Fuzzy Resolution of the Prisoner's Dilemma**. Technical Reports and Publications of the Center for Study of Complex Systems (CSCS-2002-001). University of Michigan, 2002.
- RAO, Singiresu. S. **Engineering Optimization: Theory and Practice**. John Wiley &

Sons, Inc. 3<sup>rd</sup> Edition, 1996.

RAPOPORT, Anatol. **Two-Person Game Theory**. Ann Arbor: University of Michigan Press, 1966.

RAPOPORT, Anatol. **N-Person Game Theory – Concepts and Applications**. The University of Michigan Press, Ann Arbor, 1970.

RAPOPORT, Anatol. **Lutas, Jogos e Debates**. Tradução de Sérgio Duarte. Brasília: Editora da Universidade de Brasília, 1980.

RASMUSEN, E. **Games and Information**. Basil and Blackwell Ltd. Oxford, Reino Unido, 1998.

REINELT, Gehard. **TSPLIB – Travelling Salesman Problem Library**. 2001. Disponível em: <http://comopt.ifi.uni-heidelberg.de/software/TSPLIB95/>. Acessado em: 10 Mai 2005.

ROBERTSON, Ian C.; ROBERTSON, Wilma G.; ROITBERG, Bernard D. **A Model of Mutual Tolerance and the Origin of Communal Associations Between Unrelated Females**. In Journal of Insect Behavior, Volume 11, No. 2, 1998.

RODRIGUES, M. A. P. **Problema do Caixeiro Viajante: um algoritmo para resolução de problemas de grande porte baseado em busca local dirigida**. 2000. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Santa Catarina – Florianópolis.

RUNARSSON, Thomas Philip. **Evolutionary Problem Solving**. 2000. PhD Thesis. Faculty of Engineering of the University of Iceland, Reykjavik, 29 January 2001.

SASTRY, Kumara; GOLDBERG, David; KENDALL, Graham. **Genetic Algorithms**. In Search Methodologies: Introductory Tutorials in Optimization and Decision Support Techniques, E. K. Burke and G. Kendall, eds., (Chapter 4), Springer, 2005.

SCHUMACHER, C.; VOSE, M. D.; WHITLEY, D. **The No Free Lunch and Problem Description Length**. In Proceedings of Genetic and Evolutionary Computation Conference (GECCO'01), pages 565-570, San Francisco, CA, USA, 7-11 July 2001.

SIM, Kwee-Bo; KIM, Ji-Yoon. **Solution to Multiobjective Optimization Problems: Coevolutionary Algorithm Based on Evolutionary Game Theory**. In Proceedings of the 8th International Symposium on Artificial Life and Robotics, page 174-185, Oita, Japan, January 24-26 2003.

SIM, Susan Elliott; EASTERBROOK, Steve; HOLT, Richard C. **Using Benchmarking to Advance Research: A Challenge to Software Engineering**. In Proceedings of the 25th International Conference on Software Engineering, pages 74-83, Portland, Oregon, USA, 3-10 May 2003.

- SIMÕES, Anabela; COSTA, Ernesto. **Transposition: A Biologically Inspired Mechanism to Use with Genetic Algorithms**. In Proceedings of the 4<sup>th</sup> International Conference on Neural Networks and Genetic Algorithms (ICANNGA'99), Slovenia, Springer-Velag, 1999.
- SIMÕES, Anabela; COSTA, Ernesto. **On Biologically Inspired Genetic Operators: Transformation in the Standard Genetic Algorithm**. In Proceedings of the 3rd Annual Conference on Genetic and Evolutionary Computation (GECCO'01), pages 584-591, San Francisco, California, USA, 2001.
- SMITH, John Maynard. **Evolution and the Theory of Games**. Cambridge University Press, 1982.
- SMITH, John Maynard; PRICE, G. R. **The Logic of Animal Conflict**. In Nature, Volume 246, pages 15-18, November 2 1973.
- SONG, Qian; KANDEL, Abraham. **A Fuzzy Approach to Strategic Games**. IEEE Transactions on Fuzzy Systems, Volume 7, No. 6, December 1999.
- SOUZA, Carlos Henrique R. de; LINHARES, Mateus Freire; LEITE, Fernando de Jesus. **EPSO-GT: um novo algoritmo híbrido de otimização baseado na técnica de enxame evolucionário de partículas e nos princípios da teoria dos jogos**. Trabalho de Conclusão de Curso, Bacharelado em Ciência da Computação, Centro Universitário do Pará, 2006.
- SUGANTHAN, P. N.; HANSEN, N.; LIANG, J. J.; DEB, K. CHEN, P. AUGER, A. TIWARI, S. **Problem Definitions and Evaluation Criteria for the CEC 2005 Special Session on Real-Parameter Optimization**. Technical Report, Nanyang Technological University, Singapore and KanGAL Report Number 2005005, Kanpur Genetic Algorithms Laboratory, IIT Kanpur, May, 2005.
- TEIXEIRA, O. N. **Proposta de Um Novo Algoritmo Genético Baseado na Teoria dos Jogos**. 2005. Dissertação (Mestrado em Engenharia Elétrica – Computação Aplicada) – Universidade Federal do Pará – Belém.
- TEIXEIRA, Otávio Noura; BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; OLIVEIRA, Roberto Célio Limão de. **Game Theory as a New Paradigm for Phenotype Characterization of Genetic Algorithms**. In Proceedings of the 8th Annual Conference on Genetic and Evolutionary Computation (GECCO'06), pages 1431-1432, Seattle, Washington, USA, 2006a.
- TEIXEIRA, Otávio Noura; BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; OLIVEIRA, Roberto Célio Limão de. **Genetic Algorithms with Social Interaction Phase as Phenotype Characterization**. In: Advances in Natural Computation and Datamining. ICNC 2006 / FSKD 2006 – II International Conference on Natural Computation and III International Conference on Fuzzy Systems and Knowledge Discovery. Xi'an, China, 2006b.

- TEIXEIRA, Otávio Noura; BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; OLIVEIRA, Roberto Célio Limão de. **O Paradigma do Dilema do Prisioneiro Aplicado ao Método de Seleção Roleta dos Algoritmos Genéticos**. In: CLEI 2006 – XXXII Conferencia Latino Americana de Informática. Santiago, Chile, 2006c.
- TEIXEIRA, Otávio Noura; BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; OLIVEIRA, Roberto Célio Limão de. **Genetic Algorithms with Social Interaction: A New Step for Phenotype Characterization Thru Game Theory**. In Proceedings of Genetic and Evolutionary Methods (GEM'07), Worldcomp'07 – World Congress in Computer Science, Computer Engineering and Applied Computing, Las Vegas, Nevada, USA, 25-28 June 2007.
- TEIXEIRA, Otávio Noura; LOBATO, Walter Avelino da Luz; YASOJIMA, Carlos Takeshi Kudo; BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; OLIVEIRA, Roberto Célio Limão de. **A New Hybrid Nature-Inspired Metaheuristic for Problem Solving Based on the Social Interaction Genetic Algorithm Employing Fuzzy Systems**. In Proceedings of the 10<sup>th</sup> International Conference on Hybrid Intelligent Systems, p. 31-36, Atlanta, GA, USA, 2010a.
- TEIXEIRA, Otávio Noura; LOBATO, Walter Avelino da Luz; YASOJIMA, Carlos Takeshi Kudo; BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; OLIVEIRA, Roberto Célio Limão de. **Fuzzy Social Interaction Genetic Algorithm**. In Proceedings of the 10<sup>th</sup> Annual Conference on Genetic and Evolutionary Computation Conference, p. 2113-2114, Portland, OR, USA, 2010b.
- TEIXEIRA, Otávio Noura; LOBATO, Walter Avelino da Luz; YANAGUIBASHI, Hitoshi Seki; CAVALCANTE, Rodrigo Vieira; SILVA, Deam James Azevedo da; OLIVEIRA, Roberto Célio Limão de. **Algoritmo Genético com Interação Social na Resolução de Problemas de Otimização Global com Restrições**. In: Lopes, Heitor Silvério; Takahashi, Ricardo Hiroshi Caldeira. (Eds.). *Computação Evolucionária em Problemas de Engenharia*. Omnipax Editora Ltda., 2011.
- TRIVERS, R. **Natural Selection and Social Theory: Selected Papers of Robert Trivers**. Oxford University Press, 2002.
- VALLURI, Annapurna. **Learning and Cooperation in Sequential Games**. In Journal of Adaptive Behavior, Volume 14, No. 3, pages 195-209, International Society of Adaptive Behavior, 2006.
- VAN BRAGT, David; VAN KEMENADE, Cees; LA POUTRÉ, Han. **The Influence of Evolutionary Selection Schemes on the Iterated Prisoner's Dilemma**. In Computational Economics, Volume 17, No. 2-3, pages 253-263, June 2001.
- WANG, L-X. **A Course in Fuzzy System and Control**. Prentice-Hall International, 1997.
- WATSON, Richard A.; POLLACK, Jordan B. **Hierarchically Consistent Test Problems for Genetic Algorithms**. In Proceedings of 1999 Congress on Evolutionary Computation (CEC'99), Angeline, Michalewicz, Schoenauer, Yao, Zalzal, eds. IEEE

Press, pages 1406-1413, 1999.

WEIKART, Richard. **A Recently Discovered Darwin Letter on Social Darwinism**. ISIS, The University of Chicago Press, v. 86, No. 4, p. 609 – 611, 1995.

WHITLEY, D.; MATHIAS, K.; RANA, S.; DZUBERA, J. **Evaluating Evolutionary Algorithms**. Journal of Artificial Intelligence, Volume 85, pages 245-276, 1996.

WHITLEY, D.; WATSON, J. P. **Complexity Theory and The No Free Lunch Theorem**. In Burke, E. K.; Kendall, G., eds.: Search Methodologies: Introductory Tutorials in Optimization and Decision Support Techniques, pages 317-339, Kluwer, Boston, USA, 2005.

WHITLEY, Darrel. **A Genetic Algorithm Tutorial**. Technical Report CS-93-103. Department of Computer Science. Colorado State University, Nov 1993.

WHITLEY, Darrel. **Modeling Hybrid Genetic Algorithms**. Genetic Algorithms in Engineering and Computer Science. Winter, Peiaux, Galan and Cuesta, eds. Pages 191-201, Wiley, 1995.

WHITLEY, Darrel; RANA, Soraya B. **Representation, Search and Genetic Algorithms**. In Proceedings of the 14th National Conference on Artificial Intelligence (AAAI'97). AAAI Press/MIT Press, 1997.

WILLIAMS, John. **The Compleat Strategyst**. Nova Iorque: McGraw-Hill, 1954.

WISE, Kay; GOODWIN, Scott D. **Overview of Selection Schemes and a Suggested Classification**. In Workshop on Evolutionary Computation, Canadian Artificial Intelligence Conference (AI'98), Vancouver, Canada, June 1998.

YAO, Xin; DARWEN, Paul. **An Experimental Study of N-Person Iterated Prisoner's Dilemma Games**. Australia: Informatica, 1994.

YAO, Xin; DARWEN, Paul. **Genetic Algorithms and Evolutionary Games**. In Commerce, Complexity and Evolution, William Barnett, Carl Chiarella, Steve Keen, Robert Marks, Hermann Schnabl (ed.), Cambridge University Press, Chapter 16, pp.313-333, 2000.

YAO, Xin; LIU, Yong. **Getting Most Out of Evolutionary Approaches**. In Proceedings of NASA/DoD Conference on Evolvable Hardware, pages 8-14, 2002.

YAO, Xin; LIU, Yong; LI, Jin; HE, Jun; FRAYN, Colin. **Current Developments and Future Directions of Bio-inspired Computation and Implications for Ecoinformatics**. In Journal of Ecological Informatics, No. 1, pages 9-22, Elsevier, 2006.

YAO, Xin; XU, Yong. **Recent Advances in Evolutionary Computation**. Journal of Computer Science and Technology, Volume 21, No. 1, pages 1-18, January 2006.

YASOJIMA, Carlos T. K.; LOBATO, Walter. A. da L. **Proposta de uma Nova Metaheurística Híbrida com Lógica Nebulosa Baseada em Algoritmos Genéticos com Interação Social**. 2009. Trabalho de Conclusão de Curso (Bacharelado em Ciência da Computação) – Centro Universitário do Estado do Pará – CESUPA.

ZADEH, Loft A. **Fuzzy Sets**. Information and Control, pages 338-353, 1965.

ZADEH, Loft A. **The Birth and Evolution of Fuzzy Logic**. In World Scientific Series in Advances in Fuzzy Systems, pages 811-819, World Scientific Publishing Co., Inc. River Edge, NJ, USA, 1996.

ZHU, Shinin. **Fuzzy Cultural Algorithms with Evolutionary Programming for Real-Valued Function Optimization**. 1998. PhD Thesis. Graduate School of Wayne State University, Detroit, Michigan.

## ANEXO A – ALGORITMOS GENÉTICOS: UMA VISÃO GERAL

### A.1. APRESENTAÇÃO

Os Algoritmos Genéticos (AG) são os algoritmos evolucionários mais utilizados da Computação Evolucionária e estão baseados nos princípios da Teoria da Evolução Biológica dos Seres Vivos. Normalmente, são aplicados em situações onde não existem soluções através de métodos algébricos ou estatísticos, tais como, problemas de otimização combinatória, que requerem uma busca através de um amplo espaço de soluções candidatas. (GOLDBERG, 1989; EBERHART et al., 1996).

Inspirados na Teoria da Origem das Espécies de Charles Darwin, onde uma população natural, durante várias gerações, desenvolve-se segundo os princípios da Seleção Natural e da “sobrevivência do mais apto”, os AG são capazes de desenvolver soluções para problemas do mundo real, tais como problemas de busca e otimização (GOLDBERG, 1989). O detalhe é que não há garantia de encontrar a melhor solução do problema (ótimo global) e, sim, a melhor solução possível – que pode ser um ótimo local, pois não fazem a varredura completa do espaço de busca.

Esta técnica de resolução de problemas foi desenvolvida por HOLLAND (1975), onde os principais objetivos de sua pesquisa eram: (1) abstrair e explicar os processos adaptativos dos sistemas naturais; (2) desenvolver *software* de sistemas artificiais capazes de simular a robustez dos mecanismos dos sistemas naturais. Dessa forma, ele apresentou os Algoritmos Genéticos como uma abstração da evolução biológica, proporcionando assim toda a sua base teórica.

Segundo GOLDBERG (1989), os AG são algoritmos de busca baseados nos mecanismos de seleção natural e genética, que tem a capacidade de evoluir uma população de indivíduos. Essa evolução ocorre através da utilização de um “tipo de seleção natural” em conjunto com outros operadores genéticos, tais como: **mutação**, onde um gene é substituído por um alelo<sup>35</sup> de forma aleatória; e, **recombinação** ou **cruzamento**, onde os

---

<sup>35</sup> Um alelo pode ser definido como os possíveis valores que um gene pode ter. Por exemplo, se tivermos um AG com representação binária, logo os valores {0, 1} são os alelos possíveis para os genes dos indivíduos.

indivíduos escolhidos trocam pedaços de seus cromossomos e, assim, geram novas soluções.

Um Algoritmo Genético busca produzir indivíduos melhores com base na combinação dos melhores existentes e, através da estratégia da sobrevivência do mais apto, elimina os menos aptos. Não são produzidas apenas boas soluções, mas sempre soluções melhores. Isso ocorre devido ao fato de combinarem as melhores características dos pais, na produção de filhos superiores (GOLDBERG, 1989; MITCHELL, 1999). A seguir é apresentada a sua estrutura.

## A.2. ESTRUTURA BÁSICA

Atualmente, apesar da teoria dos AG ter absorvido conceitos mais aprofundados de outras áreas, tais como a Biologia Evolutiva e a genética das populações, por exemplo; e, além disso, ter se aproximado mais ainda da simulação biológica, a estrutura proposta em HOLLAND (1975) ainda é válida e defendida por muitos autores, conforme pode ser visto na figura A.1.

```

1. Início;
2. Gerar população inicial;
3. Avaliar cada indivíduo da população inicial;
4. Repetir até  $m$  gerações
// Etapa de reprodução
4.1. Repetir até o número de descendentes ser igual à quantidade
    desejada (% de cruzamento)
4.1.1. Selecionar dois indivíduos conforme o método de seleção;
4.1.2. Realizar a operação de cruzamento nos indivíduos selecionados no
    passo anterior;
4.1.3. Realizar a operação de mutação nos descendentes gerados no passo
    anterior;
4.1.4. Avaliar os descendentes;
4.2. Substituir os indivíduos da população pelos novos indivíduos
    gerados na etapa de reprodução;
5. O melhor indivíduo da população é a solução do problema;
6. Fim.
```

Figura A.1 – Estrutura básica de um Algoritmo Genético.

Fonte: Adaptado de HOLLAND (1975) e GOLDBERG (1989).

É importante observar que a sua estrutura é bastante simplificada e composta por apenas três etapas fundamentais, que são: **geração da população inicial**; **avalição da população inicial**; e, a etapa de **reprodução**, dividida em: seleção, cruzamento e mutação basicamente. Apesar de sua simplicidade, o poder computacional inerente a essa estrutura permite a resolução de problemas complexos, pois justamente encontram a melhor solução possível enquanto o **critério de parada**<sup>36</sup> do algoritmo não for satisfeito.

### A.3. COMO IMPLEMENTAR UM ALGORITMO GENÉTICO

Segundo HAUPT e HAUPT (2004), esta técnica consiste em: (1) gerar uma população de soluções (cromossomos ou indivíduos) modeladas de acordo com o problema que se deseja resolver; (2) avaliar a adaptabilidade de cada solução, ou seja, o seu valor de *fitness*, que pode ser compreendida como a probabilidade de uma solução gerar novos descendentes com seu material genético; e, (3) aplicar os operadores de seleção, cruzamento e mutação sobre as soluções, repetindo o processo até que seja encontrado um resultado satisfatório ou número máximo de gerações seja atingido, por exemplo.

De acordo com LEHRER (2000), a operação de seleção é responsável por selecionar indivíduos da população, utilizando na maioria das vezes o valor de *fitness*, o que possibilita aos indivíduos mais aptos gerar um maior número de descendentes. Assim, é possível estabelecer uma relação direta desta operação com o processo de seleção natural definido por DAWIN (1859). E, como exemplo, é possível destacar os seguintes métodos.

**O Método da Roleta ou Seleção Proporcional ao *Fitness***, onde cada indivíduo tem uma porção da roleta relativa à sua adaptabilidade, que é calculada pela simples divisão de seu valor de *fitness* pela somatória dos valores de *fitness* de todos os indivíduos. E a partir daí, para selecionar um indivíduo basta sortear aleatoriamente um número entre zero e um. Indivíduos com porções maiores da roleta têm mais chances de serem selecionados.

---

<sup>36</sup> Como critério de parada, normalmente, é utilizada a quantidade de gerações ou então o algoritmo fica executando até encontrar um determinado valor de *fitness*.

O **Método Torneio**, onde são selecionados  $N$  indivíduos e, aquele que tiver o melhor valor de *fitness* – maior ou menor, o que depende do problema em questão, maximização ou minimização, respectivamente – é por fim copiado para uma piscina ou área de cruzamento (*Mating Pool*).

Quando a piscina estiver completa, ou seja, a quantidade de indivíduos for igual ao tamanho da população, os indivíduos são então selecionados aleatoriamente dois a dois para sofrerem a operação de cruzamento.

É importante observar que, e de acordo com HAUPT e HAUPT (2004), este é um dos mais refinados processos de seleção por permitir ajustar a pressão seletiva, o que evita a convergência rápida para um ótimo local e mantém a variabilidade genética na população de uma forma controlada. Além disso, é um dos métodos mais próximos de simular o processo natural de competição para obter a chance de reprodução;

O **Elitismo** foi introduzido por DE JONG (1975) e é visto como uma complementação junto a muitos métodos de seleção, pois sempre força o AG a reter, para a próxima geração, pelo menos uma cópia do melhor indivíduo até o momento encontrado. Dessa forma, evita-se a perda de muitos indivíduos caso não sejam selecionados para gerarem descendentes ou se destruídos pelas operações de cruzamento e mutação. A sua principal vantagem é a garantia de convergência, seja para um ótimo local ou global.

A **operação de cruzamento** é a principal característica que distingue os AG de outros métodos de busca, e é considerado o mais importante entre os operadores genéticos. É, pois, através dele que o algoritmo possibilita a exploração da superfície de busca dentro do material genético (alelos) que já se encontra nos indivíduos da população, o que o conduz à convergência de resultados (HAUPT e HAUPT 2004).

Esta operação consiste na troca de pedaços de cromossomos entre os indivíduos selecionados como pais para a criação de novos indivíduos melhores adaptados. Existem diversos métodos de cruzamento, e que dependem do tipo de informação armazenado no cromossomo dos indivíduos, tais como: números reais, números binários, sequências de

caracteres, entre outros. Entre os métodos têm-se os tradicionais: um ponto e dois pontos de corte, que estão exemplificados nas figuras A.2 e A.3.

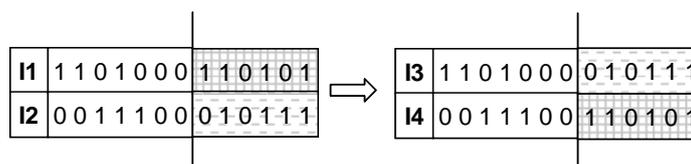


Figura A.2 - Operação de cruzamento com um ponto de corte.

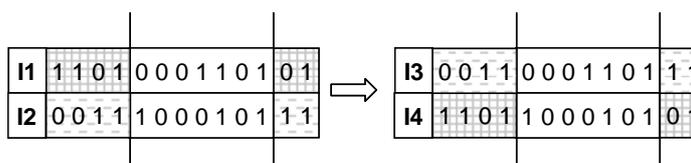


Figura A.3 - Operação de cruzamento com dois pontos de corte.

Na Figura A.2 o ponto de corte está entre os bits ou genes sete e oito dos indivíduos um e dois, e os bits posteriores restantes são então trocados e, assim, os indivíduos três e quatro são gerados. Já na figura A.3 os dois pontos de corte são gerados, entre os bits quatro e cinco e, entre os bits onze e doze, e somente os caracteres que estão nas extremidades foram trocados, preservando os bits centrais e, assim, foram gerados os indivíduos três e quatro.

O **operador de mutação** é a segunda maneira que um AG utiliza para explorar a superfície de busca do problema. Ele introduz pequenas alterações nos cromossomos dos indivíduos, ao alterar aleatoriamente, e com uma pequena probabilidade, o conteúdo de um gene por um elemento do conjunto de alelos (EBERHART et al., 1996). A figura A.4 apresenta um exemplo, onde o valor do sexto gene foi modificado de zero para um.

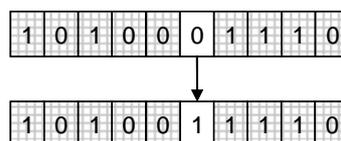


Figura A.4 – Exemplificação da operação de mutação.

É possível encontrar na literatura de Algoritmos Genéticos discussões relativas à definição de valores para os diversos parâmetros de inicialização do algoritmo e, nesse

sentido, uma série de estudos já foi realizada na tentativa de encontrar um conjunto de valores ótimos. Porém, não existem trabalhos conclusivos, apenas indicativos, tais como: BÄCK et al. (2000a; 2000b). Dessa forma, os parâmetros são normalmente definidos a partir de experiências anteriores e através de casos relatados ou, simplesmente, a realização de uma pre-testagem de valores para os parâmetros antes de aprofundar a execução de mais testes.

Os **principais parâmetros** de um AG são:

- (1) **Tamanho da População:** define a quantidade de indivíduos da população que serão gerados, em cada geração. Normalmente, este é de tamanho fixo;
  
- (2) **Quantidade de Gerações:** é uma das condições de parada do algoritmo mais utilizadas e define a quantidade máxima de execuções da etapa de reprodução da estrutura do AG, conforme pode ser visto no passo 4 da figura 2.1;
  
- (3) **Taxa de Cruzamento:** define a porcentagem de indivíduos que serão selecionados para gerarem descendentes através do cruzamento de seus cromossomos;
  
- (4) **Taxa de Mutação:** define a porcentagem de indivíduos que serão selecionados para sofrerem mutação em genes do seu cromossomo.

## ANEXO B – FUNDAMENTOS DA TEORIA DOS JOGOS

### B.1. APRESENTAÇÃO

Antes de serem abordados diretamente os fundamentos da Teoria dos Jogos, em DARWIN (1859) é apresentado um trecho sobre a Luta pela Existência que ocorre na natureza e diz o seguinte:

**[...] todos os seres vivos estão expostos a uma rigorosa competição. Nada mais fácil do que admitir a verdade da luta universal pela existência; por um lado, nada mais difícil do que trazer a mente, o tempo todo, esta conclusão. Contudo, se assim não se fizer, ou seja, se não se cogitar tanto essa ideia até que ela fique, assim por se dizer, arraigada em nossa mente, estou convencido de que nos parecerão obscuros ou serão inteiramente mal interpretados todos os fatos relacionados com a economia da natureza, com a distribuição, com a raridade, a abundância, a extinção e a variação. A natureza nos parece brilhante e jubilosa quando em situação de superabundância de alimentos, então não vemos, ou não nos passa pela ideia, que as aves cantando alegremente ao nosso redor vivem geralmente de insetos e sementes, e que assim estão constantemente destruindo a vida, ou comumente nos esquecemos de como é frequente serem esses pássaros canoros, e também seus ovos e filhotes, destruídos pelos animais predadores; tampouco trazemos continuamente na mente a lembrança de que embora o alimento esteja então abundante, nem sempre tal circunstância ocorre durante sucessivas estações do ano.**

A partir do que foi exposto é possível associar a luta pela existência com os aspectos pertinentes à Teoria dos Jogos que lida com **situações de conflito de interesses**, onde dois ou mais agentes racionais disputam entre si algum recurso limitado ou escasso presente no ambiente (NEUMANN e MORGENSTERN, 1944; LUCE e RAIFFA, 1957; FUDENBERG e TIROLE, 1991; BORGES, 1996).

Os **agentes racionais**, segundo RAPOPORT (1980), são indivíduos que agem racionalmente, ou seja, levam em consideração todas as possíveis consequências de seus atos e, a partir disso, estabelecem certo grau de preferência, baseado em seus próprios atos e na ação que gerou o seu melhor resultado. Isto é, ele age de forma a maximizar seus ganhos (RAPOPORT, 1966). E, em alguns casos, o resultado não depende única e exclusivamente da escolha feita por um único indivíduo, mas sim da ação escolhida pelos outros, sobre os quais o primeiro não possui qualquer controle.

É interessante observar que se os agentes forem humanos, dificilmente tomam decisões de acordo com o que é denominado de “racional”, objetivando a maximização de seus ganhos, pois agem através do que é conhecido como “comportamento de bom senso”. Dessa maneira, o método de maximização dos ganhos esperados é inadequado como explicação para o comportamento racional dos agentes. Assim, o que deve ser maximizado não é um valor de ganho e, sim, a utilidade, que é definida como uma função associada a um valor relativo às preferências de um indivíduo.

Sendo assim, é assumido que cada indivíduo tem preferências ordenadas para os possíveis resultados, e ainda reconhece as preferências dos outros jogadores. Estas são representadas numericamente através da **Função de Utilidade** de cada jogador, e tem como argumentos as variáveis que compõem os possíveis resultados de um jogo (LUCE e RAIFFA, 1957).

O estudo da Teoria dos Jogos foi matematicamente formalizado através dos artigos de John Von Neumann, publicados em 1928 e 1937. Entretanto, o livro *Theory of Games and Economic Behavior*, publicado com Oskar Morgenstern em 1944, é normalmente referenciado como a primeira abordagem completa e sistemática sobre o tema.

## **B.2. COMPONENTES DE UM JOGO ESTRATÉGICO**

Segundo LUCE e RAIFFA (1957), um jogo pode ser caracterizado como um ambiente formal que representa uma situação de conflito de interesses, com regras bem estabelecidas, onde agentes racionais comportam-se estrategicamente em busca de obter os maiores ganhos possíveis disponibilizados nesse ambiente, através de uma função ou tabela de pagamentos. A seguir cada um de seus componentes é brevemente apresentado.

- **Jogo:** é um modelo formal, o que significa que a Teoria dos Jogos envolve descrições e análises técnicas. É importante notar que os únicos tipos de jogos tratados por ela são os do tipo estratégicos;
- **Interações:** as ações individuais de cada um dos jogadores afetam os outros jogadores;

- **Jogadores:** qualquer indivíduo ou grupo de indivíduos tem capacidade de tomar decisões que afetam os outros;
- **Racionalidade:** assumindo que todos os jogadores são racionais, significa dizer que eles utilizam o método mais adequado na busca de satisfazer os seus desejos, ou seja, maximizar seus ganhos;
- **Comportamento Estratégico:** cada jogador leva em consideração o fato de que todos eles interagem entre si. Dessa maneira, a decisão tomada por um deles gerará consequências aos outros jogadores. Existem dois tipos de **estratégias de comportamento**, que são: as **estratégias puras**, onde os jogadores sempre agem através do mesmo comportamento, por exemplo, sempre cooperar; e, as **estratégias mistas**, onde os jogadores ora traem, ora cooperam, conforme a sua conveniência e, dessa forma, são definidas a partir da combinação de estratégias puras.

### B.3. TIPOS DE JOGOS

Quando dois jogadores participam de um **Jogo Estritamente Competitivo**, chamado também de **Jogo Não-Cooperativo** ou **Jogo de Soma-Zero**, o benefício obtido por cada um dos jogadores significa necessariamente o que o outro jogador perdeu. Do contrário, quando esta situação não ocorre é dito que o jogo não é mais estritamente competitivo e a soma das funções de utilidade dos jogadores não resulta mais em zero. Assim, tem-se um **Jogo de Soma-Não-Zero**, onde o benefício de um jogador não é mais necessariamente o que o outro jogador perdeu, e vice-versa (LUCE e RAIFFA, 1957).

BORGES (1996) afirma ainda que são muitas as diferenças nas análises desses dois tipos de jogos. Considerando o significado da informação obtida por um jogador sobre a estratégia a ser adotada por outro em um jogo estritamente competitivo, assumindo-se que ambos os jogadores são racionais, estes não devem anunciar a estratégia que utilizarão na

disputa, pois isto poderia ser utilizado pelo oponente para assegurar posições de vantagem e, assim, aumentar seus ganhos, diminuindo conseqüentemente o seu benéfico.

Entretanto, essa situação não ocorre nos jogos de soma-não-zero, pois a revelação antecipada da estratégia, por parte de um dos jogadores, pode resultar em ganhos mútuos, caso esta informação seja percebida pelo outro jogador como autêntica. Assim, induzindo-o a jogar de acordo com o anúncio prévio. Porém, caso a informação não seja autêntica, isso caracteriza o “blefe”. Nesse sentido é importante observar que isso não significa que os jogadores estejam em processo de negociação, o que caracterizaria os **Jogos Cooperativos** (RASMUSEN, 1998).

Os jogos cooperativos são aqueles onde os jogadores se comunicam antes do início da disputa e, assim, podem definir algum tipo de acordo em relação às estratégias que serão utilizadas no jogo. Pelo fato de não possuir as restrições dos jogos competitivos (estritamente ou não), o processo de análise desse tipo de jogo é mais complexo. Isso se deve, por exemplo, a influência que o número de jogadores exerce sobre a investigação, pois enquanto nos jogos competitivos os jogadores são isolados uns dos outros, e confiam simplesmente em seus raciocínios e intuições para tomar a decisão de sua jogada, os jogos cooperativos permitem a formação de coalizões, por exemplo, o que aumenta a complexidade do processo de tomada de decisão (RAPOPORT, 1980).

Algumas outras características pertinentes aos jogos são importantes de serem mencionadas, tais como: a quantidade de jogadores; a interação entre eles, onde nos jogos simultâneos a decisão de um jogador não é tomada em função das decisões dos outros e, ainda, não têm preocupação com desdobramentos futuros dessa interação; e os jogos sequenciais, onde os jogadores realizam suas jogadas em uma ordem predeterminada (LUCE e RAIFFA, 1957; RAPOPORT, 1966; 1970).

#### **B.4. O PARADIGMA DO DILEMA DO PRISIONEIRO**

O Dilema do Prisioneiro (DP) foi apresentado pela primeira vez em 1950 por *Melvin Dresher e Merrill Flood*, cientistas da *RAND Corporation* e é considerado o mais

famoso e mais conhecido jogo de duas pessoas de soma-não-zero não-cooperativo da Teoria dos Jogos. Ele define uma situação de conflito de interesses, onde dois indivíduos são presos e colocados em celas diferentes e sem comunicação entre eles (POUNDSTONE, 1992).

Alan Tucker, originalmente foi quem apresentou o DP nesse sentido e foi então proposto a cada preso que: (1) se um deles confessasse o crime e o outro não, o que tivesse confessado seria preso apenas três meses por sua cooperação e outro ficaria preso por dois anos; (2) se ambos confessassem o crime, então a cooperação individual perderia a força e ambos ficariam presos por um ano; (3) senão, caso nenhum deles confessasse o crime, eles seriam presos por apenas seis meses.

Na tabela B.1 é possível visualizar a tabela de pagamentos para o dilema do prisioneiro, que combina todos os possíveis pares de estratégias correlacionando todos os valores de pagamentos com cada um dos jogadores ( $J_A$  e  $J_B$ ). Cada jogador pode expressar dois comportamentos diferentes, que são: cooperar (C: *cooperate*) e trair (D: *defect*).

Tabela B.1 – Tabela de pagamentos do dilema do prisioneiro.

		$J_B$	
		Cooperar (C)	Trair (D)
$J_A$	Cooperar (C)	(R, R)	(S, T)
	Trair (D)	(T, S)	(P, P)

Fonte: Adaptado de BORGES (1996).

Além disso, para que seja configurado um Dilema do Prisioneiro, os valores  $T$ ,  $R$ ,  $P$  e  $S$  nas células da tabela devem obedecer às seguintes relações:

$$T > R > P > S \quad (74)$$

$$R > \frac{T + S}{2} \quad (75)$$

$$\frac{T + S}{2} > S \quad (76)$$

Para cada par de comportamentos possível, o pagamento de linha-coluna está listado na célula apropriada da tabela, onde cada parâmetro significa:  $T$  (*temptation*) é a tentação que cada jogador tem, caso traia sozinho;  $R$  (*reward*) é a recompensa que cada jogador recebe se ambos os jogadores cooperarem;  $P$  (*punishment*) é punição que cada um dos jogadores recebe quando ambos traem; e,  $S$  (*sucker*) é o “pagamento do otário”, que coopera sozinho.

Além disso, existem variações para este jogo, onde é possível flexibilizar as relações existentes entre esses quatro parâmetros ( $T$ ,  $R$ ,  $P$  e  $S$ ), considerando a equação (74), de forma a gerar diferentes configurações de jogos; e, também, no que se refere à quantidade de iterações ou disputas entre os mesmos jogadores. Na forma clássica do DP, os jogadores disputam em apenas um único encontro. Ao considerar somente a flexibilização dos valores desses parâmetros, é possível configurar os jogos expressos na tabela B.2, por exemplo.

Tabela B.2 – Outros jogos que podem ser gerados a partir da tabela de pagamento do DP.

<b>Sigla</b>	<b>Nome</b>	<b>Parâmetros</b>
<i>CG</i>	<i>Chicken Game</i>	$T > R > S > P$
<i>MP</i>	<i>Mixed Polymorphism</i>	$T > R > S > P = 0$
<i>FOF</i>	<i>Friend or Foe</i>	$T > R > P = S = 0$
<i>FD</i>	<i>Facultative Defection</i>	$T > R = P > S$
<i>BS</i>	<i>Battle of Sexes</i>	$R > P > T = S = 0$
<i>SH</i>	<i>Stag Hunt</i>	$R > T = P > S$

Fonte: Adaptado de LAHOZ-BELTRA et al. (2009).

As estratégias de comportamento dos jogadores, no caso do Dilema do Prisioneiro, podem ser de dois tipos: (1) puras, onde o jogador sempre coopera (**ALL-C**) ou trai (**ALL-D**); e, mistas, onde o jogador pode combinar cooperar e trair, de acordo com aquilo que no momento lhe atribua um maior ganho. Nesse caso é possível citar a estratégia **Aleatória**, onde ora o jogador coopera, ora trai, sem seguir um padrão pré-definido; e, também, a estratégia **TFT** (Tit-For-Tat), onde o jogador primeiramente coopera e, a partir do segundo encontro passa a agir com o mesmo comportamento que o seu adversário teve no encontro anterior (RAPOPORT, 1966).

De acordo com YAO e DARWEN (1994), apesar do jogo Dilema do Prisioneiro ter sido estudado extensivamente por mais de três décadas, existem muitos problemas do

mundo real que não podem ser modelados por ele, tais como problemas sociais e econômicos, tais como: conservação de energia, ecologia, superpopulação, entre outros. Dessa forma, a abordagem de N-Jogadores do Dilema do Prisioneiro é mais realista e mais abrangente e, assim, consegue modelar tais problemas.

O **Dilema do Prisioneiro N-Pessoas** (*N-person Prisoner's Dilemma*) é definido a partir de três propriedades: (1) cada jogador tem que escolher entre os comportamentos cooperar e trair; (2) o comportamento trair é dominante para cada jogador, ou seja, é melhor escolher trair do que cooperar não importando quantos jogadores escolham cooperar; (3) o resultado se todos os jogadores escolhem o comportamento não dominante cooperar é preferível do ponto de vista de cada jogador para aquele em que todo mundo escolhe trair, no entanto, ninguém é motivado a agir unilateralmente traindo (RAPOPORT, 1970; YAO e DARWIN, 1994). Na tabela B.3 é apresentada a sua tabela de pagamentos.

Tabela B.3 – Tabela de pagamentos para o Dilema do Prisioneiro N-Pessoas.

		Quantidade de outros jogadores, que escolheram o comportamento Cooperar (C)						
		0	1	2	3	...	N-2	N-1
C	$N_C = 1$	$N_C = 2$	$N_C = 3$	$N_C = 4$	...	$\frac{R(N_J - 2)}{(N_J - 1)}$	$R$	
	$S$	$\frac{3}{(N_J - 1)}$	$\frac{6}{(N_J - 1)}$	$\frac{9}{(N_J - 1)}$	...			
D	$N_C = 0$	$N_C = 1$	$N_C = 2$	$N_C = 3$	...	$\frac{(T(N_J - 2) + 1)}{(N_J - 1)}$	$T$	
	$P$	$\frac{(N_J + 3)}{(N_J - 1)}$	$\frac{(N_J + 7)}{(N_J - 1)}$	$\frac{(N_J + 11)}{(N_J - 1)}$	...			

Fonte: Adaptado de MANHART (2007).

A partir desta tabela de pagamentos é possível definir as funções de pagamento para os jogadores, que são: (1) aqueles que cooperam ( $J_C$ ); e, (2) aqueles que traem ( $J_D$ ). É importante observar que a cooperação e traição estão referenciadas somente ao comportamento dos indivíduos a partir de sua estratégia de comportamento.

$$J_c = \frac{R(N_c - 1)}{(N_j - 1)} \quad (77)$$

$$J_D = \frac{[T \times N_c(N_j - N_c - 1)]}{(N_j - 1)} \quad (78)$$

Onde: os valores de pagamento,  $R$  é a recompensa (*reward*); e,  $T$  é a tentação de trair (*temptation*);  $N_c$  é a quantidade de jogadores que cooperaram no confronto atual;  $N_j$  é a quantidade total de indivíduos que estão participando do processo de interação social.

Além disso, caso o valor de  $N_j$  seja igual a 2, logo tem-se a tabela B1, que representa a tabela de pagamentos da versão duas pessoas do jogo Dilema do Prisioneiro. Dessa forma, tem-se aqui a generalização do jogo Dilema do Prisioneiro para qualquer quantidade de jogadores.

## ANEXO C – CONJUNTOS E SISTEMAS NEBULOSOS

### C.1. APRESENTAÇÃO

No início dos anos 60, Lotfi A. Zadeh afirmou que a teoria de controle clássica havia posto muita ênfase na precisão e, assim, não conseguiria lidar com sistemas complexos. Dessa forma, surgiu a necessidade de um tipo de matemática radicalmente diferente, a matemática de quantidades nebulosas, que não fosse descrita em razão de distribuições de probabilidade. Mais tarde, em 1965, com o artigo intitulado *Fuzzy Sets*, Zadeh inspirou os matemáticos a “fuzzificarem” as estruturas matemáticas e, conseqüentemente, nasceu a Lógica *Fuzzy* ou Nebulosa (ZADEH, 1965; 1996).

A área teve um nascimento conturbado, onde alguns acadêmicos apoiaram essas ideias e, então, passaram a trabalhar no desenvolvimento da área, e outros a rejeitaram, pois a viam na contramão dos princípios científicos. Dentre estes, os matemáticos, especializados em estatística e probabilidade, acreditavam que: (1) a Teoria das Probabilidades era suficiente para caracterizar incerteza; (2) todo e qualquer problema resolvido pela teoria nebulosa poderia ser resolvido igualmente, ou melhor, através da Teoria das Probabilidades. Esta visão foi difícil de ser alterada, pois não haviam aplicações práticas reais, somente seus fundamentos filosóficos (WANG, 1997).

De acordo com KERRE et al. (2005), a evolução do processo de fuzzificação das estruturas matemáticas pode ser dividida em três estágios. Os anos 60 e 70 foram marcados pelo forte desenvolvimento das bases teóricas da área, tais como: a teoria dos conjuntos, conceitos de algoritmos, tomada de decisão, fundamentos de controle, e o estabelecimento do *framework* de controladores.

Os anos 80 foram de pouca evolução teórica na área, porém as aplicações em controle a salvaram, quando os engenheiros japoneses perceberam a simplicidade e a não necessidade de modelo matemático para resolver problemas onde a teoria de controle clássica não podia ser aplicada.

E nos anos 90, a sua bem sucedida aplicação no Japão, fez com que pesquisadores europeus e norte-americanos a olhassem com mais credibilidade e, assim, em 1992 foi

realizado o primeiro grande evento com a chancela do IEEE (*Institute of Electrical and Electronics Engineers, Inc.*), o *The First IEEE International Conference on Fuzzy Systems* e, em 1993, foi inaugurada a revista *IEEE Transactions on Fuzzy Systems*.

ZADEH (1965) apresentou as noções dos conjuntos nebulosos como uma extensão dos conceitos da teoria dos conjuntos clássica, onde uma afirmação só pode ser verdadeira ou falsa (0 ou 1). A proposta da lógica nebulosa, base para compreensão da teoria dos conjuntos nebulosos, é permitir a qualquer afirmação à atribuição de um valor verdade variando continuamente entre os valores 0 e 1.

A Lógica Nebulosa, dessa forma, representa uma classe distinta de incerteza, que não é em essência probabilística, ao lidar qualitativamente com as características de um objeto, que podem ser vagas ou imprecisas, tais como: alto, baixo, grande, pequeno, entre outros. E, dessa forma, pode ser utilizada para modelar o comportamento humano em processos de tomada de decisão (BORGES, 1996).

## C.2. CONJUNTOS NEBULOSOS

A **Teoria dos Conjuntos Nebulosos** é muito simples e intuitivamente interessante de ser aplicada na modelagem de situações e problemas do mundo real. Além disso, as suas vantagens são ainda maiores a partir do momento que se tenta imitar o comportamento humano no processo de tomada de decisão. Como exemplo, ao decidir sobre a compra de um produto, uma pessoa qualifica as variáveis numéricas presentes no processo e, assim, verifica se o produto é caro, confiável, bom ou ruim, de forma a tomar a sua decisão (KANDEL e LANGHOLZ, 1993; EBERHART, 1996; WANG, 1997).

Seja  $U$  o **Universo de Discurso** ou **Conjunto Universo** que contém todos os elementos possíveis referentes a um contexto em particular ou aplicação. Dessa forma, um conjunto clássico  $A$  no universo de discurso  $U$  pode ser definido das seguintes formas:

1. **Método da Lista:** os membros do conjunto são dispostos numa lista finita;

2. **Método da Regra:** o conjunto é especificado através de propriedades relativas aos seus membros, de forma a generalizar os seus componentes. Assim, o conjunto  $A$  é representado a seguir.

$$A = \{x \in U \mid x \text{ está sujeito a condições}\} \quad (79)$$

3. **Método da Pertinência:** este método introduz o conceito de função de pertinência zero-um do conjunto  $A$ , e é representado por  $\mu_A(x)$ , onde:

$$\mu_A = \begin{cases} 0, & \text{se } x \in A \\ 1, & \text{se } x \notin A \end{cases} \quad (80)$$

Dessa forma é possível definir que um conjunto nebuloso  $A$  no universo de discurso  $U$  é caracterizado pela função de pertinência  $\mu_A(x)$ , que pode assumir valores contínuos no intervalo  $[0,1]$ . Assim um conjunto nebuloso nada mais é do que uma generalização de um conjunto clássico.

Além disso, o conjunto  $A$  pode ser representado por um conjunto de pares ordenados, composto de um elemento genérico  $x$  e o seu grau de pertinência, da seguinte forma:

$$A = \{(x, \mu_A(x)) \mid x \in U\} \quad (81)$$

Alguns aspectos dos conjuntos nebulosos são importantes de se destacar, entre eles:

1. As propriedades caracterizadas por eles são nebulosas e, assim, diferentes funções de pertinência (triangular, trapezoidal e gaussiana, por exemplo) podem representá-las. Elas são funções matemáticas precisas e, a partir do momento que representam propriedades nebulosas, nada mais é nebuloso e, nesse sentido, o que ocorre na verdade é a “desfuzzificação” dessa propriedade;

2. Como determinar as funções de pertinência? Existem duas abordagens: (a) usar o conhecimento do especialista humano. Normalmente se faz necessária uma sintonia fina para ajustar as funções de pertinência, pois esta abordagem fornece o conhecimento bruto, não refinado; (b) usar dados coletados por sensores como sintonia fina para funções de pertinência previamente estabelecidas;
3. Um conjunto nebuloso tem uma referência de um para um com sua função de pertinência, ou seja, ela é única para cada conjunto.

### C.3. OPERAÇÕES E RELAÇÕES SOBRE CONJUNTOS NEBULOSOS

As **operações** para manipulação de conjuntos nebulosos foram definidas a partir das operações existentes na Teoria Clássica dos Conjuntos e, assim, há uma série de operações envolvendo-os. A partir de dois conjuntos nebulosos  $A$  e  $B$  é possível expressar as seguintes definições e operações.

- **Igualdade:**  $A$  e  $B$  são iguais, se e somente se,  $\mu_A(x) = \mu_B(x), \forall x \in U$ ;
- **Subconjuntos:**  $(A \subset B)$ , se e somente se,  $\mu_A(x) \leq \mu_B(x), \forall x \in U$ ;
- **Complemento:** o conjunto  $A$  tem como complemento  $\bar{A}$  e a sua função de pertinência é definido por  $\mu_{\bar{A}} = 1 - \mu_A$ , conforme a figura C.1.
- **União:** a união de  $A$  e  $B$  ( $A \cup B$ ) tem a função de pertinência definida por  $\mu_{A \cup B} = \max[\mu_A(x), \mu_B(x)]$ , ou seja, é o menor conjunto nebuloso que contém ambos os conjuntos  $A$  e  $B$ , conforme a figura C.2 apresenta.
- **Interseção:** a interseção de  $A$  e  $B$  ( $A \cap B$ ) tem a função de pertinência definida por  $\mu_{A \cap B} = \min[\mu_A(x), \mu_B(x)]$ , ou seja, é o maior conjunto nebuloso que contém ambos os conjuntos  $A$  e  $B$ , conforme a figura C.3.

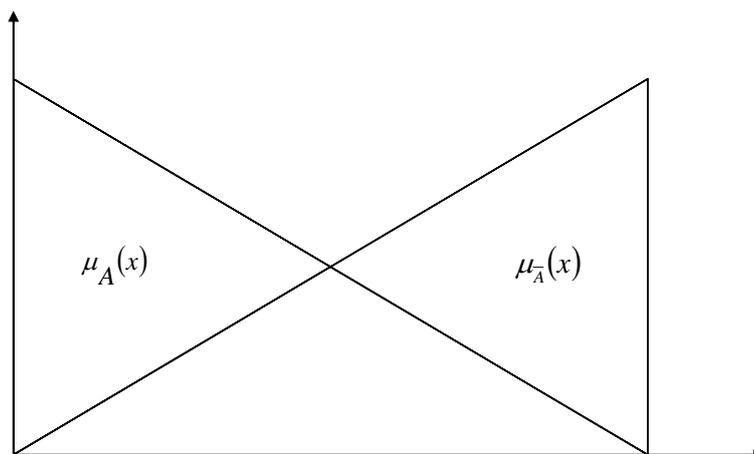


Figura C.1 – Exemplo do complemento de um conjunto nebuloso.

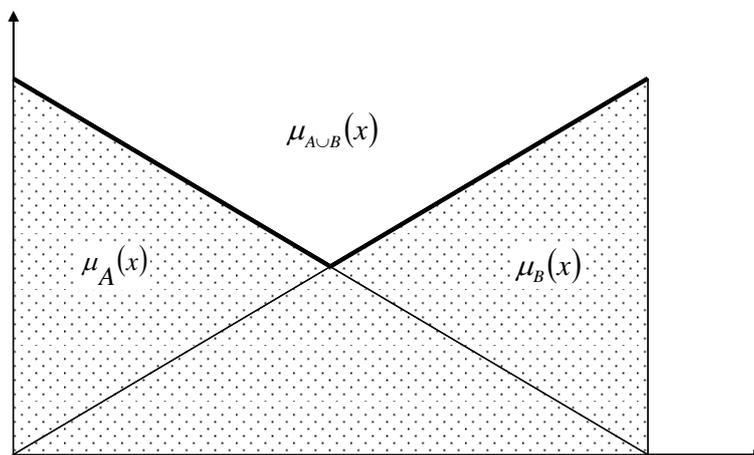


Figura C.2 – Exemplo de união de conjuntos.

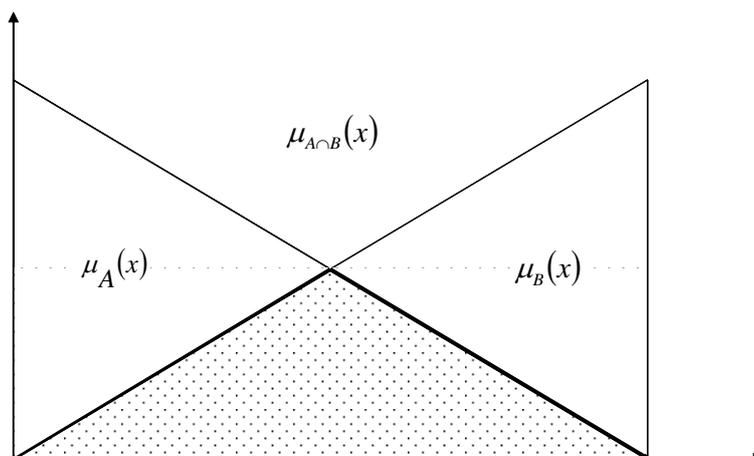


Figura C.3 – Exemplo de interseção de conjuntos.

De acordo com BORGES (1996), as operações de união e interseção, realizadas através dos operadores *max-min*<sup>37</sup>, tem um papel muito importante na teoria dos conjuntos nebulosos, e também importantes propriedades – apresentadas na tabela C.1. E, para exemplificá-las, sejam  $a$ ,  $b$  e  $c$  graus de pertinência de um elemento  $x \in U$ , aos respectivos conjuntos  $A$ ,  $B$  e  $C$ . Além dessas propriedades, tem-se que:  $\min(0, a) = 0, \forall a \neq 0$  e  $\max(1, a) = 1, \forall a \neq 1$ .

Tabela C.1 – Propriedades das operações de união e interseção.

Propriedade	Operações
Idempotência	$\min(a, a) = \max(a, a) = a, \forall a \neq 1$
Comutatividade	$\min(a, b) = \min(b, a)$ $\max(a, b) = \max(b, a)$
Associatividade	$\min[\min(a, b), c] = \min[a, \min(b, c)] = \min(a, b, c)$ $\max[\max(a, b), c] = \max[a, \max(b, c)] = \max(a, b, c)$
Distributividade	$\min(\min(a, b), c) = \min(a, \min(b, c)) = \min(a, b, c)$ $\max(\max(a, b), c) = \max(a, \max(b, c)) = \max(a, b, c)$
Absorção	$\min(a, \max(a, b)) = \max(a, \min(a, b)) = a$
Lei de De Morgan	$\max(a, b) = 1 - \min((1 - a), (1 - b))$

As operações de complemento, união e interseção apresentadas até aqui são consideradas operações básicas e, assim, não se adequam satisfatoriamente a toda e qualquer situação existente. Dessa forma, existem outros tipos de operações que são utilizados em situações onde, por exemplo, a união de  $A$  e  $B$  não contenha necessariamente o menor conjunto, como pode ser visto a seguir.

- **Complemento Nebuloso** (*Fuzzy Complement*): seja  $c: [0,1] \rightarrow [0,1]$  a função de mapeamento que transforma a função de pertinência de um

<sup>37</sup> Os operadores **max** e **min** representam respectivamente os conectivos “ou” ( $\vee$ ) e “e” ( $\wedge$ ) da Lógica Matemática Clássica, que por sua vez também representam as operações de união e interseção, presentes na Teoria Clássica dos Conjuntos. Logo, **união**  $\Leftrightarrow$  **ou**  $\Leftrightarrow$  **max** e **interseção**  $\Leftrightarrow$  **e**  $\Leftrightarrow$  **min**.

conjunto  $A$  na função de pertinência do seu conjunto complemento  $\bar{A}$ . ou seja:

$$c[\mu_A(x)] = \mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (82)$$

- **União Nebulosa: Norma-S** (*Fuzzy Union: The S-Norms*): seja  $s: [0,1] \times [0,1] \rightarrow [0,1]$  a função de mapeamento que transforma as funções de pertinência de dois conjuntos nebulosos  $A$  e  $B$ , na função de pertinência da união desses conjuntos, ou seja:

$$s[\mu_A(x), \mu_B(x)] = \mu_{A \cup B} = \max[\mu_A(x), \mu_B(x)] \quad (83)$$

- **Interseção Nebulosa: Norma-T** (*Fuzzy Intersection: The T-Norms*): seja  $t: [0,1] \times [0,1] \rightarrow [0,1]$  a função de mapeamento que transforma as funções de pertinência de dois conjuntos nebulosos  $A$  e  $B$ , na função de pertinência da união desses conjuntos, ou seja:

$$t[\mu_A(x), \mu_B(x)] = \mu_{A \cap B} = \min[\mu_A(x), \mu_B(x)] \quad (84)$$

Uma **relação** é classicamente definida a partir da presença ou ausência de uma associação ou interação entre elementos de dois ou mais conjuntos. Sendo assim, com base em dois conjuntos  $A$  e  $B$ , a relação  $R$  é definida por  $A \times B$  que, por sua vez, é um subconjunto do produto cartesiano de ambos os conjuntos, de forma que  $R: A \times B \rightarrow \{0,1\}$ . Caso algum elemento  $a \in A$  e  $b \in B$  estejam relacionados, então  $R(a,b)=1$ , senão  $R(a,b)=0$ , conforme demonstra a sua função de pertinência bivalente a seguir.

$$\mu_R(a,b) = \begin{cases} 1 & \text{se e somente se } (a,b) \in R \\ 0 & \text{em caso contrário} \end{cases} \quad (85)$$

A partir da definição de relação entre conjuntos clássicos, pode-se dizer que as relações nebulosas são a sua generalização também. E, assim, é definida como o produto



$$\mu_T(a, c) = \mu_{R \circ S}(a, c) = \max_{b \in S} t[\mu_R(a, b), \mu_S(b, c)] \quad (90)$$

Para todo  $(a, c) \in A \times C$ , onde  $t$  é qualquer Norma-T. No entanto, as duas mais comumente utilizadas para a realização da composição de relações nebulosas são as composições *max-min* e *max-produto*, conforme pode ser visto respectivamente a seguir em (91) e (92). No entanto, essas não são as únicas expressões possíveis.

$$\mu_T(a, c) = \mu_{R \circ S}(a, c) = \max_{b \in S} \min[\mu_R(a, b), \mu_S(b, c)] \quad (91)$$

$$\mu_T(a, c) = \mu_{R \circ S}(a, c) = \max_{b \in S} [\mu_R(a, b) \mu_S(b, c)] \quad (92)$$

#### C.4. VARIÁVEIS LINGUÍSTICAS

O conceito de variável linguística está intimamente relacionado à representação do conhecimento humano. Quando sensores são utilizados na obtenção de valores de uma variável, eles resultam em números precisos, porém, ao invés de sensores, se humanos forem utilizados, então os resultados seriam apresentados em palavras. Para exemplificar essa situação, a medição de temperatura através do uso de um termômetro, indicando precisamente 38,6° de febre ou, simplesmente, uma pessoa dizendo “muito quente”.

Assim, se uma variável permite palavras em linguagem natural como seus valores, então ela pode ser considerada como uma **variável linguística**. Cada uma das palavras é caracterizada por um conjunto nebuloso no universo de discurso em que é definida. Como exemplo, pode-se pensar na velocidade de um carro, onde os termos que a qualificam são expressos por baixa, média e alta, e o universo de discurso é definido no intervalo [0, 120]. A relação desses dois componentes (termos x universo de discurso) possibilita a geração das funções de pertinência dos conjuntos nebulosos, conforme a figura C.1.

Os valores atribuídos às variáveis linguísticas podem ser representados por apenas uma ou mais palavras. Assim, no exemplo, a variável velocidade poderia ter outros valores, tais como: “muito baixa”, “ligeiramente alta” e “mais ou menos média”.

Uma variável linguística é um termo composto, que é normalmente classificada em três grupos: (1) termos primários, que são os rótulos utilizados para nomear os conjuntos nebulosos, como: “baixa”, “média” e “alta”; (2) complemento “não” e os conectivos “e” e “ou”; (3) restrições, como: “muito”, “ligeiramente” e “mais ou menos”.

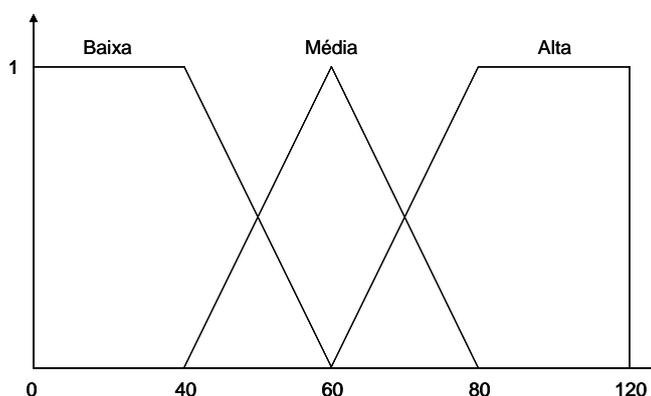


Figura C.1 – Funções de pertinência da variável linguística velocidade.

Os valores atribuídos às variáveis linguísticas podem ser representados por apenas uma ou mais palavras. Assim, no exemplo, a variável velocidade poderia ter outros valores, tais como: “muito baixa”, “ligeiramente alta” e “mais ou menos média”.

Uma variável linguística é um termo composto, que é normalmente classificada em três grupos: (1) termos primários, que são os rótulos utilizados para nomear os conjuntos nebulosos, como: “baixa”, “média” e “alta”; (2) complemento “não” e os conectivos “e” e “ou”; (3) restrições, como: “muito”, “ligeiramente” e “mais ou menos”.

Os conectivos e o complemento já foram apresentados na seção C.3 e, assim, falta ainda caracterizar as restrições. Estas podem ser consideradas como uma forma de “fuzzificar” os termos primários, expandindo as suas definições e, assim, aproximando-as ainda mais do real significado do conhecimento que se deseja representar.

As duas restrições mais comumente utilizadas são “muito” e “mais ou menos”, que também é conhecida como “moderada”. Nenhuma delas tem um significado muito claro, no entanto, “muito” é utilizado no sentido de intensificar o termo primário. As suas funções de pertinência foram convencionadas e são apresentadas a seguir em (93) e (94), respectivamente. E, na sequência, a sua representação gráfica é apresentada na figura C.2.

$$\mu_{\text{Muito}}(A(x)) = [\mu_A(x)]^2 \quad (93)$$

$$\mu_{\text{Mais ou menos}}(A(x)) = [\mu_A(x)]^{1/2} \quad (94)$$

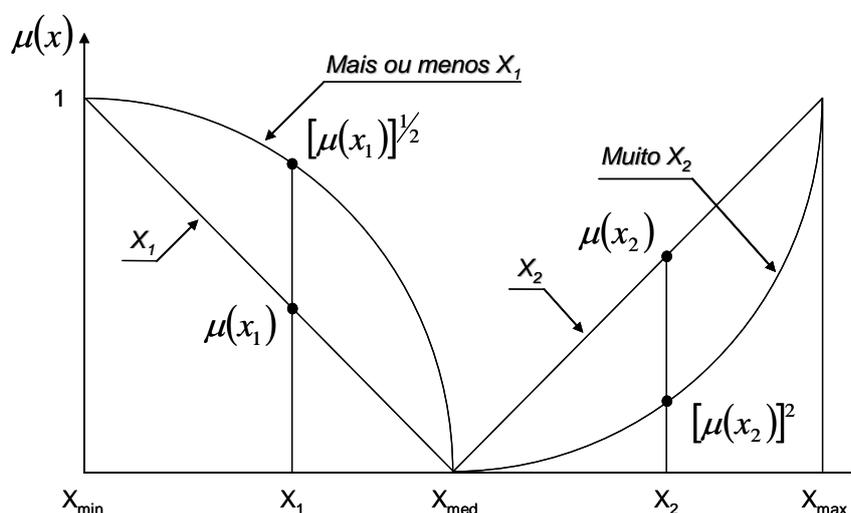


Figura C.2 – Funções de pertinência para as restrições “muito” e “mais ou menos”.

Fonte: Adaptado de BORGES (1996)

É importante observar que as restrições podem ter dois tipos de efeito quando aplicadas ao conceito original do termo, que são: (1) **Concentração**: é o que ocorre com a restrição “muito”, o que possibilita uma intensificação ou reforço ao termo principal; (2) **Dilatação**: é o que ocorre com a restrição “mais ou menos”, onde há uma expansão ou enfraquecimento do termo principal.

Além disso, os expoentes “2” e “1/2” são apenas convenções, porém é possível utilizar quaisquer valores, pois expoentes maiores que “um” ativam o efeito de

concentração ao gerar menores graus de pertinência e valores “menores que um”, possibilitam o aumento do grau de pertinência devido ao efeito de dilatação.

Não existe uma regra formal para a definição quantitativa exata para o grau de influência dos modificadores linguísticos sobre conjuntos nebulosos e, dessa forma, a associação de um valor numérico a um expoente para definir uma restrição é bastante subjetivo.

## C.5. LÓGICA NEBULOSA

Da mesma forma que a teoria dos conjuntos nebulosos é uma extensão da teoria clássica dos conjuntos, a lógica nebulosa é uma generalização da lógica clássica, onde muito de seus conceitos continuam válidos. E, assim, existem dois tipos de **Proposições Nebulosas (PN)**, que são:

1. As **atômicas**, que são representadas por apenas uma afirmação nebulosa  $x \text{ é } A$ , onde  $x$  é uma variável linguística e  $A$  é um valor linguístico de  $x$ ;
2. As **compostas**, que combinam proposições atômicas através dos conectivos lógicos “e”, “ou ” e “não”, que representam a interseção, união e o complemento, respectivamente.

É importante observar que as proposições nebulosas compostas devem ser compreendidas como **relações nebulosas**. Sendo assim, considerando  $x$  e  $y$  como variáveis linguísticas nos domínios físicos  $U$  e  $V$ , e  $A$  e  $B$  como conjuntos *fuzzy* nesses domínios, respectivamente, as suas funções de pertinência são definidas a seguir:

- **Conectivo “e”**: utiliza o conceito de interseção nebulosa e, assim, temos a proposição  $(x \text{ é } A \text{ e } y \text{ é } B)$ , que pode ser interpretado como a relação nebulosa  $A \cap B$  em  $U \times V$ , com a função de pertinência a seguir:

$$\mu_{A \cap B}(x, y) = t[\mu_A(x), \mu_B(y)] \quad (95)$$

Onde  $t: [0,1] \times [0,1] \rightarrow [0,1]$  é qualquer Norma-T.

- **Conectivo “ou”**: utiliza o conceito de união nebulosa e, assim, temos a proposição ( $x$  é  $A$  **ou**  $y$  é  $B$ ), que pode ser interpretado como a relação nebulosa  $A \cup B$  em  $U \times V$ , com a função de pertinência a seguir:

$$\mu_{A \cup B}(x, y) = s[\mu_A(x), \mu_B(y)] \quad (96)$$

Onde  $s: [0,1] \times [0,1] \rightarrow [0,1]$  é qualquer Norma-S.

- **Conectivo “não”**: utiliza o conceito de complemento nebuloso e, assim, a proposição ( $x$  é  $A$ ) tem o seu complemento ( $x$  **não** é  $A$ ), com função de pertinência conforme a operação expressa por (27), na seção C.3.

Além disso, no cálculo proposicional clássico, a **implicação lógica** ( $p \rightarrow q$ ) tem a função de definir as regras utilizadas no processo de inferência de um sistema lógico clássico. E, da mesma forma, a operação de **implicação nebulosa** é considerada a base para o processo de inferência de sistemas nebulosos, e também é representada por: *se p então q*, através de seu formalismo apresentado a seguir:

$$p \rightarrow q \Leftrightarrow \neg p \vee q \Leftrightarrow \neg p \vee (p \wedge q) \quad (97)$$

A implicação nebulosa também é chamada de **Regra Se-então** ou **Declaração Condicional Nebulosa**, onde o antecedente e o sucessor da regra são definidos a partir de proposições nebulosas, e também descreve a dependência do valor de uma variável linguística em relação ao valor de outra. Ela é representada por uma relação  $R_{A \rightarrow B}$ , expressa pela seguinte função de pertinência.

$$\mu_{A \rightarrow B}(x, y) = i(\mu_A(x), \mu_B(y)) \quad (98)$$

Caso uma condicional apresente mais de uma variáveis antecedentes, estas deverão ser separadas por vírgulas, da mesma forma que os argumentos presentes na lógica clássica e, assim, a relação expressa em (98) passará a ser representada da seguinte forma:

$$\mu_{A \rightarrow B}(x_1, x_2, \dots, x_n, y) = i(\mu_{A_1}(x_1), \mu_{A_2}(x_2), \dots, \mu_{A_n}(x_n), \mu_B(y)) \quad (99)$$

## C.6. SISTEMAS NEBULOSOS

Um **Sistema Nebuloso (SN)** é um sistema baseado em conhecimento ou baseado em regras, que tem as Regras Se-então como o seu núcleo principal, onde algumas das palavras que as compõem são caracterizadas por funções de pertinência contínuas. Como exemplo: **se a velocidade é alta, então aplicar menos força no acelerador.**

Para construir um sistema nebuloso são necessárias **três etapas**: (1) definir a base de regras Se-então, que são extraídas a partir do conhecimento de um especialista humano; (2) combinar todas as regras Se-então da base de regras em um único sistema; (3) escolher um modelo de sistema nebuloso<sup>38</sup>.

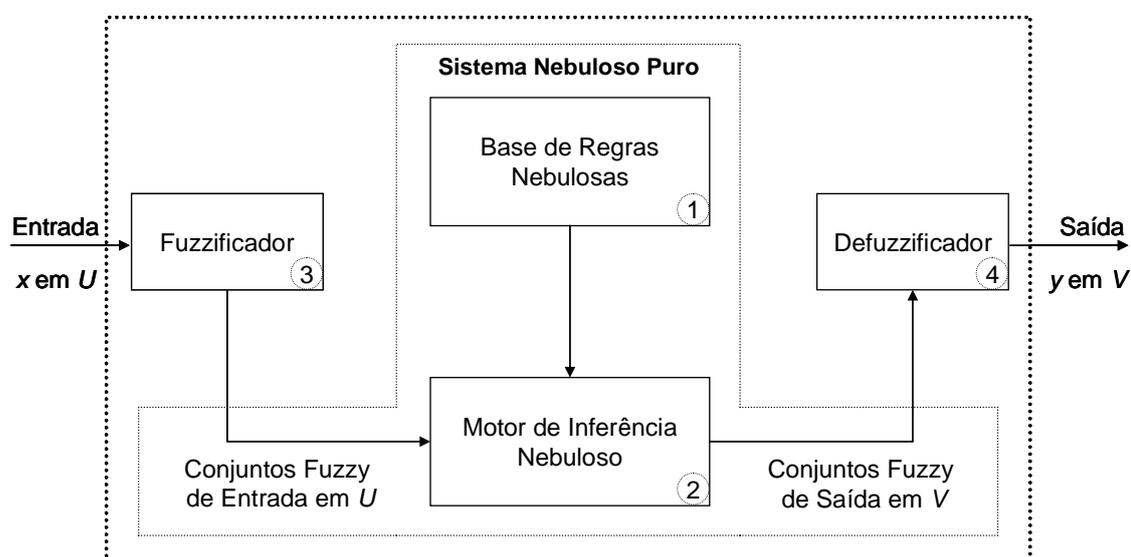


Figura C.3 – Sistema nebuloso de Mamdani com fuzzificador e defuzzificador.

<sup>38</sup> Os três principais modelos de sistemas nebulosos são: **Sistema Nebuloso Puro** (*Pure Fuzzy System*); **Sistema Nebuloso de Takagi-Sugeno-Kang** (*TKS Fuzzy System*), proposto para suprir a necessidade de variáveis de entrada e saída com valores reais, presente nos sistemas de engenharia; e, o **Sistema Nebuloso de Mamdani com Fuzzificador e Defuzzificador** (*Fuzzy System with Fuzzifier and Defuzzifier*).

O modelo de sistema nebuloso mais comumente utilizado é o de Mamdani, conforme a figura C.3, que é na verdade uma generalização do sistema nebuloso puro, de forma a permitir que as variáveis entradas e saídas sejam valores reais ( $R$ ), como no modelo de *Takagi-Sugeno-Kang*. Dessa forma, ele é mais adequado na construção de sistemas de engenharia.

É importante observar que os sistemas nebulosos são mapeadores de múltiplas entradas em uma única saída, ou seja, a partir de um vetor de valores reais ( $x_1, \dots, x_n \in U$ ) mapeia um escalar de valor real ( $y \in V$ ). Sendo assim, o sistema pode ser construído em partes, como sistemas individuais, e depois essas partes agrupadas em um único sistema. Cada um dos sistemas é composto basicamente de quatro partes, que são apresentadas a seguir em maiores detalhes.

- **Base de Regras Nebulosas:** consiste em um conjunto de regras Se-então, que são o núcleo principal de um sistema nebuloso, de forma que todos outros os componentes são utilizados para implementar essas regras de forma eficiente. Sendo assim, o seu formato pode ser visto a seguir, em sua forma canônica:

$$\text{Regra}^{(l)} : \text{Se } x_1 \text{ é } A_1^l \text{ e } \dots \text{ e } x_n \text{ é } A_n^l, \text{ então } y \text{ é } B^l \quad (100)$$

Onde:  $A_i^l$  e  $B^l$  são conjuntos nebulosos em  $U_i, V \subset R$ , respectivamente;  $x_1, \dots, x_n \in U$  são as entradas; e,  $y \in V$  é a saída.

A base de regras consiste em um conjunto de regras nebulosas e o relacionamento existente entre elas é muito importante para o desempenho do sistema como um todo, pois é possível que haja algum tipo de conflito em suas definições, como também, a má representação do conhecimento humano.

- **Motor de Inferência Nebuloso:** os princípios abordados da lógica nebulosa são utilizados na composição do motor de inferência nebuloso, onde nele são combinadas as regras Se-então presentes na base de regras, de forma a mapear um conjunto nebuloso  $A \in U$  em um conjunto nebuloso  $B \in V$ .

- **Fuzzificador:** são mapeadores de valores reais  $x^* \in U$  em conjuntos nebulosos  $A'$  em  $U$ .
- **Defuzzificador:** são mapeadores de conjuntos nebulosos  $B'$  em  $V$ , em valores discretos  $y^* \in V$ .

## ANEXO D – ESTRATÉGIAS DE COMPORTAMENTO

### D.1. ESTRATÉGIAS UTILIZADAS NO ALGORITMO SIGA

Tabela D.1 – Codificação genética das estratégias de comportamento usadas no SIGA.

Genótipo	Codificação	Fenótipo
C <sup>d</sup> C <sup>d</sup>	00	ALL-D
C <sup>d</sup> C <sup>c</sup>	01	TFT
C <sup>d</sup> c	02	ALL-D
C <sup>c</sup> C <sup>d</sup>	10	TFT
C <sup>c</sup> C <sup>c</sup>	11	ALL-C
C <sup>c</sup> c	12	ALL-C
C <sup>d</sup> c	20	ALL-D
C <sup>c</sup> c	21	ALL-C
cc	22	Aleatório

Fonte: Adaptado de BRITO (2004)

### D.2. ESTRATÉGIAS UTILIZADAS NO ALGORITMO F-SIGA

Tabela D.2 – Codificação genética das estratégias de comportamento usadas no F-SIGA.

ID	Genótipo						Fenótipo
	Cromossomo						
	f1		f2		f3		
	01	02	03	04	05	06	Estratégia
0001	0	0	0	0	0	0	Aleatório
0002	0	0	0	0	0	1	TFT
0003	0	0	0	0	0	2	TFT
0004	0	0	0	0	1	0	TFT
0005	0	0	0	0	1	1	TFT
0006	0	0	0	0	1	2	TFT
0007	0	0	0	0	2	0	TFT
0008	0	0	0	0	2	1	TFT
0009	0	0	0	0	2	2	TFT
0010	0	0	0	1	0	0	555
0011	0	0	0	1	0	1	446
0012	0	0	0	1	0	2	546
0013	0	0	0	1	1	0	456
0014	0	0	0	1	1	1	745
0015	0	0	0	1	1	2	566
0016	0	0	0	1	2	0	556
0017	0	0	0	1	2	1	454
0018	0	0	0	1	2	2	353
0019	0	0	0	2	0	0	476
0020	0	0	0	2	0	1	356
0021	0	0	0	2	0	2	355
0022	0	0	0	2	1	0	455
0023	0	0	0	2	1	1	453
0024	0	0	0	2	1	2	354
0025	0	0	0	2	2	0	553
0026	0	0	0	2	2	1	664
0027	0	0	0	2	2	2	554
0028	0	0	1	0	0	0	436
0029	0	0	1	0	0	1	515
0030	0	0	1	0	0	2	555
0031	0	0	1	0	1	0	446
0032	0	0	1	0	1	1	546
0033	0	0	1	0	1	2	456
0034	0	0	1	0	2	0	745
0035	0	0	1	0	2	1	566
0036	0	0	1	0	2	2	556

ID	Genótipo						Fenótipo
	Cromossomo						
	f1	f2	f3	Estratégia			
	01	02	03	04	05	06	
0037	0	0	1	1	0	0	454
0038	0	0	1	1	0	1	353
0039	0	0	1	1	0	2	476
0040	0	0	1	1	1	0	356
0041	0	0	1	1	1	1	355
0042	0	0	1	1	1	2	455
0043	0	0	1	1	2	0	453
0044	0	0	1	1	2	1	354
0045	0	0	1	1	2	2	553
0046	0	0	1	2	0	0	664
0047	0	0	1	2	0	1	554
0048	0	0	1	2	0	2	436
0049	0	0	1	2	1	0	515
0050	0	0	1	2	1	1	555
0051	0	0	1	2	1	2	446
0052	0	0	1	2	2	0	546
0053	0	0	1	2	2	1	456
0054	0	0	1	2	2	2	745
0055	0	0	2	0	0	0	566
0056	0	0	2	0	0	1	556
0057	0	0	2	0	0	2	454
0058	0	0	2	0	1	0	353
0059	0	0	2	0	1	1	476
0060	0	0	2	0	1	2	356
0061	0	0	2	0	2	0	355
0062	0	0	2	0	2	1	455
0063	0	0	2	0	2	2	453
0064	0	0	2	1	0	0	354
0065	0	0	2	1	0	1	553
0066	0	0	2	1	0	2	664
0067	0	0	2	1	1	0	554
0068	0	0	2	1	1	1	436
0069	0	0	2	1	1	2	515
0070	0	0	2	1	2	0	555
0071	0	0	2	1	2	1	446
0072	0	0	2	1	2	2	546
0073	0	0	2	2	0	0	456
0074	0	0	2	2	0	1	745
0075	0	0	2	2	0	2	566
0076	0	0	2	2	1	0	556
0077	0	0	2	2	1	1	454
0078	0	0	2	2	1	2	353
0079	0	0	2	2	2	0	476
0080	0	0	2	2	2	1	356
0081	0	0	2	2	2	2	355
0082	0	1	0	0	0	0	Pavlov

0083	0	1	0	0	0	1	455
0084	0	1	0	0	0	2	453
0085	0	1	0	0	1	0	354
0086	0	1	0	0	1	1	553
0087	0	1	0	0	1	2	664
0088	0	1	0	0	2	0	554
0089	0	1	0	0	2	1	436
0090	0	1	0	0	2	2	515
0091	0	1	0	1	0	0	555
0092	0	1	0	1	0	1	111
0093	0	1	0	1	0	2	112
0094	0	1	0	1	1	0	113
0095	0	1	0	1	1	1	114
0096	0	1	0	1	1	2	115
0097	0	1	0	1	2	0	116
0098	0	1	0	1	2	1	117
0099	0	1	0	1	2	2	118
0100	0	1	0	2	0	0	446
0101	0	1	0	2	0	1	121
0102	0	1	0	2	0	2	122
0103	0	1	0	2	1	0	123
0104	0	1	0	2	1	1	124
0105	0	1	0	2	1	2	125
0106	0	1	0	2	2	0	126
0107	0	1	0	2	2	1	127
0108	0	1	0	2	2	2	128
0109	0	1	1	0	0	0	546
0110	0	1	1	0	0	1	131
0111	0	1	1	0	0	2	132
0112	0	1	1	0	1	0	133
0113	0	1	1	0	1	1	134
0114	0	1	1	0	1	2	135
0115	0	1	1	0	2	0	136
0116	0	1	1	0	2	1	137
0117	0	1	1	0	2	2	138
0118	0	1	1	1	0	0	456
0119	0	1	1	1	0	1	141
0120	0	1	1	1	0	2	142
0121	0	1	1	1	1	0	143
0122	0	1	1	1	1	1	144
0123	0	1	1	1	1	2	145
0124	0	1	1	1	2	0	146
0125	0	1	1	1	2	1	147
0126	0	1	1	1	2	2	148
0127	0	1	1	2	0	0	745
0128	0	1	1	2	0	1	151
0129	0	1	1	2	0	2	152
0130	0	1	1	2	1	0	153
0131	0	1	1	2	1	1	154
0132	0	1	1	2	1	2	155

ID	Genótipo						Fenótipo
	Cromossomo						Estratégia
	f1		f2		f3		
01	02	03	04	05	06		
0133	0	1	1	2	2	0	156
0134	0	1	1	2	2	1	157
0135	0	1	1	2	2	2	158
0136	0	1	2	0	0	0	566
0137	0	1	2	0	0	1	161
0138	0	1	2	0	0	2	162
0139	0	1	2	0	1	0	163
0140	0	1	2	0	1	1	164
0141	0	1	2	0	1	2	165
0142	0	1	2	0	2	0	166
0143	0	1	2	0	2	1	167
0144	0	1	2	0	2	2	168
0145	0	1	2	1	0	0	556
0146	0	1	2	1	0	1	171
0147	0	1	2	1	0	2	172
0148	0	1	2	1	1	0	173
0149	0	1	2	1	1	1	174
0150	0	1	2	1	1	2	175
0151	0	1	2	1	2	0	176
0152	0	1	2	1	2	1	177
0153	0	1	2	1	2	2	178
0154	0	1	2	2	0	0	454
0155	0	1	2	2	0	1	181
0156	0	1	2	2	0	2	182
0157	0	1	2	2	1	0	183
0158	0	1	2	2	1	1	184
0159	0	1	2	2	1	2	185
0160	0	1	2	2	2	0	186
0161	0	1	2	2	2	1	187
0162	0	1	2	2	2	2	188
0163	0	2	0	0	0	0	Pavlov
0164	0	2	0	0	0	1	353
0165	0	2	0	0	0	2	476
0166	0	2	0	0	1	0	356
0167	0	2	0	0	1	1	355
0168	0	2	0	0	1	2	455
0169	0	2	0	0	2	0	453
0170	0	2	0	0	2	1	354
0171	0	2	0	0	2	2	553
0172	0	2	0	1	0	0	664
0173	0	2	0	1	0	1	211
0174	0	2	0	1	0	2	212
0175	0	2	0	1	1	0	213
0176	0	2	0	1	1	1	214
0177	0	2	0	1	1	2	215
0178	0	2	0	1	2	0	216

0179	0	2	0	1	2	1	217
0180	0	2	0	1	2	2	218
0181	0	2	0	2	0	0	554
0182	0	2	0	2	0	1	221
0183	0	2	0	2	0	2	222
0184	0	2	0	2	1	0	223
0185	0	2	0	2	1	1	224
0186	0	2	0	2	1	2	225
0187	0	2	0	2	2	0	226
0188	0	2	0	2	2	1	227
0189	0	2	0	2	2	2	228
0190	0	2	1	0	0	0	436
0191	0	2	1	0	0	1	231
0192	0	2	1	0	0	2	232
0193	0	2	1	0	1	0	233
0194	0	2	1	0	1	1	234
0195	0	2	1	0	1	2	235
0196	0	2	1	0	2	0	236
0197	0	2	1	0	2	1	237
0198	0	2	1	0	2	2	238
0199	0	2	1	1	0	0	515
0200	0	2	1	1	0	1	241
0201	0	2	1	1	0	2	242
0202	0	2	1	1	1	0	243
0203	0	2	1	1	1	1	244
0204	0	2	1	1	1	2	245
0205	0	2	1	1	2	0	246
0206	0	2	1	1	2	1	247
0207	0	2	1	1	2	2	248
0208	0	2	1	2	0	0	555
0209	0	2	1	2	0	1	251
0210	0	2	1	2	0	2	252
0211	0	2	1	2	1	0	253
0212	0	2	1	2	1	1	254
0213	0	2	1	2	1	2	255
0214	0	2	1	2	2	0	256
0215	0	2	1	2	2	1	257
0216	0	2	1	2	2	2	258
0217	0	2	2	0	0	0	446
0218	0	2	2	0	0	1	261
0219	0	2	2	0	0	2	262
0220	0	2	2	0	1	0	263
0221	0	2	2	0	1	1	264
0222	0	2	2	0	1	2	265
0223	0	2	2	0	2	0	266
0224	0	2	2	0	2	1	267
0225	0	2	2	0	2	2	268
0226	0	2	2	1	0	0	546
0227	0	2	2	1	0	1	271
0228	0	2	2	1	0	2	272

ID	Genótipo						Fenótipo
	Cromossomo						Estratégia
	f1	f2	f3				
	01	02	03	04	05	06	
0229	0	2	2	1	1	0	273
0230	0	2	2	1	1	1	274
0231	0	2	2	1	1	2	275
0232	0	2	2	1	2	0	276
0233	0	2	2	1	2	1	277
0234	0	2	2	1	2	2	278
0235	0	2	2	2	0	0	456
0236	0	2	2	2	0	1	281
0237	0	2	2	2	0	2	282
0238	0	2	2	2	1	0	283
0239	0	2	2	2	1	1	284
0240	0	2	2	2	1	2	285
0241	0	2	2	2	2	0	286
0242	0	2	2	2	2	1	287
0243	0	2	2	2	2	2	288
0244	1	0	0	0	0	0	Pavlov
0245	1	0	0	0	0	1	745
0246	1	0	0	0	0	2	566
0247	1	0	0	0	1	0	556
0248	1	0	0	0	1	1	454
0249	1	0	0	0	1	2	353
0250	1	0	0	0	2	0	476
0251	1	0	0	0	2	1	356
0252	1	0	0	0	2	2	355
0253	1	0	0	1	0	0	455
0254	1	0	0	1	0	1	311
0255	1	0	0	1	0	2	312
0256	1	0	0	1	1	0	313
0257	1	0	0	1	1	1	314
0258	1	0	0	1	1	2	315
0259	1	0	0	1	2	0	316
0260	1	0	0	1	2	1	317
0261	1	0	0	1	2	2	318
0262	1	0	0	2	0	0	453
0263	1	0	0	2	0	1	321
0264	1	0	0	2	0	2	322
0265	1	0	0	2	1	0	323
0266	1	0	0	2	1	1	324
0267	1	0	0	2	1	2	325
0268	1	0	0	2	2	0	326
0269	1	0	0	2	2	1	327
0270	1	0	0	2	2	2	328
0271	1	0	1	0	0	0	354
0272	1	0	1	0	0	1	331
0273	1	0	1	0	0	2	332
0274	1	0	1	0	1	0	333

0275	1	0	1	0	1	1	334
0276	1	0	1	0	1	2	335
0277	1	0	1	0	2	0	336
0278	1	0	1	0	2	1	337
0279	1	0	1	0	2	2	338
0280	1	0	1	1	0	0	553
0281	1	0	1	1	0	1	341
0282	1	0	1	1	0	2	342
0283	1	0	1	1	1	0	343
0284	1	0	1	1	1	1	344
0285	1	0	1	1	1	2	345
0286	1	0	1	1	2	0	346
0287	1	0	1	1	2	1	347
0288	1	0	1	1	2	2	348
0289	1	0	1	2	0	0	664
0290	1	0	1	2	0	1	351
0291	1	0	1	2	0	2	352
0292	1	0	1	2	1	0	353
0293	1	0	1	2	1	1	354
0294	1	0	1	2	1	2	355
0295	1	0	1	2	2	0	356
0296	1	0	1	2	2	1	357
0297	1	0	1	2	2	2	358
0298	1	0	2	0	0	0	554
0299	1	0	2	0	0	1	361
0300	1	0	2	0	0	2	362
0301	1	0	2	0	1	0	363
0302	1	0	2	0	1	1	364
0303	1	0	2	0	1	2	365
0304	1	0	2	0	2	0	366
0305	1	0	2	0	2	1	367
0306	1	0	2	0	2	2	368
0307	1	0	2	1	0	0	436
0308	1	0	2	1	0	1	371
0309	1	0	2	1	0	2	372
0310	1	0	2	1	1	0	373
0311	1	0	2	1	1	1	374
0312	1	0	2	1	1	2	375
0313	1	0	2	1	2	0	376
0314	1	0	2	1	2	1	377
0315	1	0	2	1	2	2	378
0316	1	0	2	2	0	0	515
0317	1	0	2	2	0	1	381
0318	1	0	2	2	0	2	382
0319	1	0	2	2	1	0	383
0320	1	0	2	2	1	1	384
0321	1	0	2	2	1	2	385
0322	1	0	2	2	2	0	386
0323	1	0	2	2	2	1	387
0324	1	0	2	2	2	2	388

ID	Genótipo						Fenótipo
	Cromossomo						
	f1		f2		f3		
	01	02	03	04	05	06	Estratégia
0325	1	1	0	0	0	0	Pavlov
0326	1	1	0	0	0	1	555
0327	1	1	0	0	0	2	446
0328	1	1	0	0	1	0	546
0329	1	1	0	0	1	1	456
0330	1	1	0	0	1	2	745
0331	1	1	0	0	2	0	566
0332	1	1	0	0	2	1	556
0333	1	1	0	0	2	2	454
0334	1	1	0	1	0	0	353
0335	1	1	0	1	0	1	411
0336	1	1	0	1	0	2	412
0337	1	1	0	1	1	0	413
0338	1	1	0	1	1	1	414
0339	1	1	0	1	1	2	415
0340	1	1	0	1	2	0	416
0341	1	1	0	1	2	1	417
0342	1	1	0	1	2	2	418
0343	1	1	0	2	0	0	476
0344	1	1	0	2	0	1	421
0345	1	1	0	2	0	2	422
0346	1	1	0	2	1	0	423
0347	1	1	0	2	1	1	424
0348	1	1	0	2	1	2	425
0349	1	1	0	2	2	0	426
0350	1	1	0	2	2	1	427
0351	1	1	0	2	2	2	428
0352	1	1	1	0	0	0	356
0353	1	1	1	0	0	1	431
0354	1	1	1	0	0	2	432
0355	1	1	1	0	1	0	433
0356	1	1	1	0	1	1	434
0357	1	1	1	0	1	2	435
0358	1	1	1	0	2	0	436
0359	1	1	1	0	2	1	437
0360	1	1	1	0	2	2	438
0361	1	1	1	1	0	0	355
0362	1	1	1	1	0	1	441
0363	1	1	1	1	0	2	442
0364	1	1	1	1	1	0	443
0365	1	1	1	1	1	1	444
0366	1	1	1	1	1	2	445
0367	1	1	1	1	2	0	446
0368	1	1	1	1	2	1	447
0369	1	1	1	1	2	2	448
0370	1	1	1	2	0	0	455

0371	1	1	1	2	0	1	451
0372	1	1	1	2	0	2	452
0373	1	1	1	2	1	0	453
0374	1	1	1	2	1	1	454
0375	1	1	1	2	1	2	455
0376	1	1	1	2	2	0	456
0377	1	1	1	2	2	1	457
0378	1	1	1	2	2	2	458
0379	1	1	2	0	0	0	453
0380	1	1	2	0	0	1	461
0381	1	1	2	0	0	2	462
0382	1	1	2	0	1	0	463
0383	1	1	2	0	1	1	464
0384	1	1	2	0	1	2	465
0385	1	1	2	0	2	0	466
0386	1	1	2	0	2	1	467
0387	1	1	2	0	2	2	468
0388	1	1	2	1	0	0	354
0389	1	1	2	1	0	1	471
0390	1	1	2	1	0	2	472
0391	1	1	2	1	1	0	473
0392	1	1	2	1	1	1	474
0393	1	1	2	1	1	2	475
0394	1	1	2	1	2	0	476
0395	1	1	2	1	2	1	477
0396	1	1	2	1	2	2	478
0397	1	1	2	2	0	0	553
0398	1	1	2	2	0	1	481
0399	1	1	2	2	0	2	482
0400	1	1	2	2	1	0	483
0401	1	1	2	2	1	1	484
0402	1	1	2	2	1	2	485
0403	1	1	2	2	2	0	486
0404	1	1	2	2	2	1	487
0405	1	1	2	2	2	2	488
0406	1	2	0	0	0	0	Pavlov
0407	1	2	0	0	0	1	664
0408	1	2	0	0	0	2	554
0409	1	2	0	0	1	0	436
0410	1	2	0	0	1	1	515
0411	1	2	0	0	1	2	555
0412	1	2	0	0	2	0	446
0413	1	2	0	0	2	1	546
0414	1	2	0	0	2	2	456
0415	1	2	0	1	0	0	745
0416	1	2	0	1	0	1	511
0417	1	2	0	1	0	2	512
0418	1	2	0	1	1	0	513
0419	1	2	0	1	1	1	514
0420	1	2	0	1	1	2	515

ID	Genótipo						Fenótipo
	Cromossomo						Estratégia
	f1	f2	f3				
01	02	03	04	05	06		
0421	1	2	0	1	2	0	516
0422	1	2	0	1	2	1	517
0423	1	2	0	1	2	2	518
0424	1	2	0	2	0	0	566
0425	1	2	0	2	0	1	521
0426	1	2	0	2	0	2	522
0427	1	2	0	2	1	0	523
0428	1	2	0	2	1	1	524
0429	1	2	0	2	1	2	525
0430	1	2	0	2	2	0	526
0431	1	2	0	2	2	1	527
0432	1	2	0	2	2	2	528
0433	1	2	1	0	0	0	556
0434	1	2	1	0	0	1	531
0435	1	2	1	0	0	2	532
0436	1	2	1	0	1	0	533
0437	1	2	1	0	1	1	534
0438	1	2	1	0	1	2	535
0439	1	2	1	0	2	0	536
0440	1	2	1	0	2	1	537
0441	1	2	1	0	2	2	538
0442	1	2	1	1	0	0	454
0443	1	2	1	1	0	1	541
0444	1	2	1	1	0	2	542
0445	1	2	1	1	1	0	543
0446	1	2	1	1	1	1	544
0447	1	2	1	1	1	2	545
0448	1	2	1	1	2	0	546
0449	1	2	1	1	2	1	547
0450	1	2	1	1	2	2	548
0451	1	2	1	2	0	0	353
0452	1	2	1	2	0	1	551
0453	1	2	1	2	0	2	552
0454	1	2	1	2	1	0	553
0455	1	2	1	2	1	1	554
0456	1	2	1	2	1	2	555
0457	1	2	1	2	2	0	556
0458	1	2	1	2	2	1	557
0459	1	2	1	2	2	2	558
0460	1	2	2	0	0	0	476
0461	1	2	2	0	0	1	561
0462	1	2	2	0	0	2	562
0463	1	2	2	0	1	0	563
0464	1	2	2	0	1	1	564
0465	1	2	2	0	1	2	565
0466	1	2	2	0	2	0	566

0467	1	2	2	0	2	1	567
0468	1	2	2	0	2	2	568
0469	1	2	2	1	0	0	356
0470	1	2	2	1	0	1	571
0471	1	2	2	1	0	2	572
0472	1	2	2	1	1	0	573
0473	1	2	2	1	1	1	574
0474	1	2	2	1	1	2	575
0475	1	2	2	1	2	0	576
0476	1	2	2	1	2	1	577
0477	1	2	2	1	2	2	578
0478	1	2	2	2	0	0	355
0479	1	2	2	2	0	1	581
0480	1	2	2	2	0	2	582
0481	1	2	2	2	1	0	583
0482	1	2	2	2	1	1	584
0483	1	2	2	2	1	2	585
0484	1	2	2	2	2	0	586
0485	1	2	2	2	2	1	587
0486	1	2	2	2	2	2	588
0487	2	0	0	0	0	0	Pavlov
0488	2	0	0	0	0	1	455
0489	2	0	0	0	0	2	453
0490	2	0	0	0	1	0	354
0491	2	0	0	0	1	1	553
0492	2	0	0	0	1	2	664
0493	2	0	0	0	2	0	554
0494	2	0	0	0	2	1	436
0495	2	0	0	0	2	2	515
0496	2	0	0	1	0	0	555
0497	2	0	0	1	0	1	611
0498	2	0	0	1	0	2	612
0499	2	0	0	1	1	0	613
0500	2	0	0	1	1	1	614
0501	2	0	0	1	1	2	615
0502	2	0	0	1	2	0	616
0503	2	0	0	1	2	1	617
0504	2	0	0	1	2	2	618
0505	2	0	0	2	0	0	446
0506	2	0	0	2	0	1	621
0507	2	0	0	2	0	2	622
0508	2	0	0	2	1	0	623
0509	2	0	0	2	1	1	624
0510	2	0	0	2	1	2	625
0511	2	0	0	2	2	0	626
0512	2	0	0	2	2	1	627
0513	2	0	0	2	2	2	628
0514	2	0	1	0	0	0	546
0515	2	0	1	0	0	1	631
0516	2	0	1	0	0	2	632

ID	Genótipo						Fenótipo
	Cromossomo						
	f1	f2	f3	Estratégia			
	01	02	03	04	05	06	
0517	2	0	1	0	1	0	633
0518	2	0	1	0	1	1	634
0519	2	0	1	0	1	2	635
0520	2	0	1	0	2	0	636
0521	2	0	1	0	2	1	637
0522	2	0	1	0	2	2	638
0523	2	0	1	1	0	0	456
0524	2	0	1	1	0	1	641
0525	2	0	1	1	0	2	642
0526	2	0	1	1	1	0	643
0527	2	0	1	1	1	1	644
0528	2	0	1	1	1	2	645
0529	2	0	1	1	2	0	646
0530	2	0	1	1	2	1	647
0531	2	0	1	1	2	2	648
0532	2	0	1	2	0	0	745
0533	2	0	1	2	0	1	651
0534	2	0	1	2	0	2	652
0535	2	0	1	2	1	0	653
0536	2	0	1	2	1	1	654
0537	2	0	1	2	1	2	655
0538	2	0	1	2	2	0	656
0539	2	0	1	2	2	1	657
0540	2	0	1	2	2	2	658
0541	2	0	2	0	0	0	566
0542	2	0	2	0	0	1	661
0543	2	0	2	0	0	2	662
0544	2	0	2	0	1	0	663
0545	2	0	2	0	1	1	664
0546	2	0	2	0	1	2	665
0547	2	0	2	0	2	0	666
0548	2	0	2	0	2	1	667
0549	2	0	2	0	2	2	668
0550	2	0	2	1	0	0	556
0551	2	0	2	1	0	1	671
0552	2	0	2	1	0	2	672
0553	2	0	2	1	1	0	673
0554	2	0	2	1	1	1	674
0555	2	0	2	1	1	2	675
0556	2	0	2	1	2	0	676
0557	2	0	2	1	2	1	677
0558	2	0	2	1	2	2	678
0559	2	0	2	2	0	0	454
0560	2	0	2	2	0	1	681
0561	2	0	2	2	0	2	682
0562	2	0	2	2	1	0	683

0563	2	0	2	2	1	1	684
0564	2	0	2	2	1	2	685
0565	2	0	2	2	2	0	686
0566	2	0	2	2	2	1	687
0567	2	0	2	2	2	2	688
0568	2	1	0	0	0	0	Pavlov
0569	2	1	0	0	0	1	353
0570	2	1	0	0	0	2	476
0571	2	1	0	0	1	0	356
0572	2	1	0	0	1	1	355
0573	2	1	0	0	1	2	455
0574	2	1	0	0	2	0	453
0575	2	1	0	0	2	1	354
0576	2	1	0	0	2	2	553
0577	2	1	0	1	0	0	664
0578	2	1	0	1	0	1	711
0579	2	1	0	1	0	2	712
0580	2	1	0	1	1	0	713
0581	2	1	0	1	1	1	714
0582	2	1	0	1	1	2	715
0583	2	1	0	1	2	0	716
0584	2	1	0	1	2	1	717
0585	2	1	0	1	2	2	718
0586	2	1	0	2	0	0	554
0587	2	1	0	2	0	1	721
0588	2	1	0	2	0	2	722
0589	2	1	0	2	1	0	723
0590	2	1	0	2	1	1	724
0591	2	1	0	2	1	2	725
0592	2	1	0	2	2	0	726
0593	2	1	0	2	2	1	727
0594	2	1	0	2	2	2	728
0595	2	1	1	0	0	0	436
0596	2	1	1	0	0	1	731
0597	2	1	1	0	0	2	732
0598	2	1	1	0	1	0	733
0599	2	1	1	0	1	1	734
0600	2	1	1	0	1	2	735
0601	2	1	1	0	2	0	736
0602	2	1	1	0	2	1	737
0603	2	1	1	0	2	2	738
0604	2	1	1	1	0	0	515
0605	2	1	1	1	0	1	741
0606	2	1	1	1	0	2	742
0607	2	1	1	1	1	0	743
0608	2	1	1	1	1	1	744
0609	2	1	1	1	1	2	745
0610	2	1	1	1	2	0	746
0611	2	1	1	1	2	1	747
0612	2	1	1	1	2	2	748

ID	Genótipo						Fenótipo
	Cromossomo						Estratégia
	f1		f2		f3		
	01	02	03	04	05	06	
0613	2	1	1	2	0	0	555
0614	2	1	1	2	0	1	751
0615	2	1	1	2	0	2	752
0616	2	1	1	2	1	0	753
0617	2	1	1	2	1	1	754
0618	2	1	1	2	1	2	755
0619	2	1	1	2	2	0	756
0620	2	1	1	2	2	1	757
0621	2	1	1	2	2	2	758
0622	2	1	2	0	0	0	446
0623	2	1	2	0	0	1	761
0624	2	1	2	0	0	2	762
0625	2	1	2	0	1	0	763
0626	2	1	2	0	1	1	764
0627	2	1	2	0	1	2	765
0628	2	1	2	0	2	0	766
0629	2	1	2	0	2	1	767
0630	2	1	2	0	2	2	768
0631	2	1	2	1	0	0	546
0632	2	1	2	1	0	1	771
0633	2	1	2	1	0	2	772
0634	2	1	2	1	1	0	773
0635	2	1	2	1	1	1	774
0636	2	1	2	1	1	2	775
0637	2	1	2	1	2	0	776
0638	2	1	2	1	2	1	777
0639	2	1	2	1	2	2	778
0640	2	1	2	2	0	0	456
0641	2	1	2	2	0	1	781
0642	2	1	2	2	0	2	782
0643	2	1	2	2	1	0	783
0644	2	1	2	2	1	1	784
0645	2	1	2	2	1	2	785
0646	2	1	2	2	2	0	786
0647	2	1	2	2	2	1	787
0648	2	1	2	2	2	2	788
0649	2	2	0	0	0	0	Pavlov
0650	2	2	0	0	0	1	745
0651	2	2	0	0	0	2	566
0652	2	2	0	0	1	0	556
0653	2	2	0	0	1	1	454
0654	2	2	0	0	1	2	353
0655	2	2	0	0	2	0	476
0656	2	2	0	0	2	1	356
0657	2	2	0	0	2	2	355
0658	2	2	0	1	0	0	455

0659	2	2	0	1	0	1	811
0660	2	2	0	1	0	2	812
0661	2	2	0	1	1	0	813
0662	2	2	0	1	1	1	814
0663	2	2	0	1	1	2	815
0664	2	2	0	1	2	0	816
0665	2	2	0	1	2	1	817
0666	2	2	0	1	2	2	818
0667	2	2	0	2	0	0	453
0668	2	2	0	2	0	1	821
0669	2	2	0	2	0	2	822
0670	2	2	0	2	1	0	823
0671	2	2	0	2	1	1	824
0672	2	2	0	2	1	2	825
0673	2	2	0	2	2	0	826
0674	2	2	0	2	2	1	827
0675	2	2	0	2	2	2	828
0676	2	2	1	0	0	0	354
0677	2	2	1	0	0	1	831
0678	2	2	1	0	0	2	832
0679	2	2	1	0	1	0	833
0680	2	2	1	0	1	1	834
0681	2	2	1	0	1	2	835
0682	2	2	1	0	2	0	836
0683	2	2	1	0	2	1	837
0684	2	2	1	0	2	2	838
0685	2	2	1	1	0	0	553
0686	2	2	1	1	0	1	841
0687	2	2	1	1	0	2	842
0688	2	2	1	1	1	0	843
0689	2	2	1	1	1	1	844
0690	2	2	1	1	1	2	845
0691	2	2	1	1	2	0	846
0692	2	2	1	1	2	1	847
0693	2	2	1	1	2	2	848
0694	2	2	1	2	0	0	664
0695	2	2	1	2	0	1	851
0696	2	2	1	2	0	2	852
0697	2	2	1	2	1	0	853
0698	2	2	1	2	1	1	854
0699	2	2	1	2	1	2	855
0700	2	2	1	2	2	0	856
0701	2	2	1	2	2	1	857
0702	2	2	1	2	2	2	858
0703	2	2	2	0	0	0	554
0704	2	2	2	0	0	1	861
0705	2	2	2	0	0	2	862
0706	2	2	2	0	1	0	863
0707	2	2	2	0	1	1	864
0708	2	2	2	0	1	2	865

ID	Genótipo						Fenótipo
	Cromossomo						
	f1		f2		f3		Estratégia
	01	02	03	04	05	06	
0709	2	2	2	0	2	0	866
0710	2	2	2	0	2	1	867
0711	2	2	2	0	2	2	868
0712	2	2	2	1	0	0	436
0713	2	2	2	1	0	1	871
0714	2	2	2	1	0	2	872
0715	2	2	2	1	1	0	873
0716	2	2	2	1	1	1	874
0717	2	2	2	1	1	2	875

0718	2	2	2	1	2	0	876
0719	2	2	2	1	2	1	877
0720	2	2	2	1	2	2	878
0721	2	2	2	2	0	0	515
0722	2	2	2	2	0	1	881
0723	2	2	2	2	0	2	882
0724	2	2	2	2	1	0	883
0725	2	2	2	2	1	1	884
0726	2	2	2	2	1	2	885
0727	2	2	2	2	2	0	886
0728	2	2	2	2	2	1	887
0729	2	2	2	2	2	2	888

## ANEXO E – CONFIGURAÇÕES DAS SIMULAÇÕES

<b>Id</b>	<b>Problema</b>	<b>Algoritmo</b>	<b>Gerações</b>	<b>Tam da População</b>	<b>Taxa de Cruzamento</b>	<b>Taxa de Mutação</b>	<b>Função de Fitness</b>	<b>Alfa</b>	<b>Beta</b>	<b>Jogos</b>	<b>Rodadas</b>	<b>R</b>	<b>T</b>	<b>P</b>	<b>S</b>	<b>Qtde. Jogadores</b>	<b>Tx. Tolerância</b>
01	F1	GA	5000	100	85%	5%	Eq. (1)	-	-	-	-	-	-	-	-	-	-
02	F1	SIGA	5000	100	85%	5%	Eq. (1)	1	1	100	10	5	3	1	0	2	-
03	F1	SIGA	5000	100	85%	5%	Eq. (1)	0	1	100	10	5	3	1	0	2	-
04	F1	F-SIGA	5000	100	85%	5%	Eq. (1)	1	1	100	10	5	3	1	0	2	-
05	F1	F-SIGA	5000	100	85%	5%	Eq. (1)	0	1	100	10	5	3	1	0	2	-
06	F1	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	1	1	100	10	5	3	1	0	2	-
07	F1	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	0	1	100	10	5	3	1	0	2	-
08	F1	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	1	1	100	10	5	3	1	0	2	-
09	F1	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	0	1	100	10	5	3	1	0	2	-
10	F6	GA	5000	100	85%	5%	Eq. (1)	-	-	-	-	-	-	-	-	-	-
11	F6	SIGA	5000	100	85%	5%	Eq. (1)	1	1	100	10	5	3	1	0	2	-
12	F6	SIGA	5000	100	85%	5%	Eq. (1)	0	1	100	10	5	3	1	0	2	-
13	F6	F-SIGA	5000	100	85%	5%	Eq. (1)	1	1	100	10	5	3	1	0	2	-
14	F6	F-SIGA	5000	100	85%	5%	Eq. (1)	0	1	100	10	5	3	1	0	2	-
15	F6	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	1	1	100	10	5	3	1	0	2	-
16	F6	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	0	1	100	10	5	3	1	0	2	-
17	F6	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	1	1	100	10	5	3	1	0	2	-
18	F6	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	0	1	100	10	5	3	1	0	2	-
19	F8	GA	5000	100	85%	5%	Eq. (1)	-	-	-	-	-	-	-	-	-	-
20	F8	SIGA	5000	100	85%	5%	Eq. (1)	1	1	100	10	5	3	1	0	2	-
21	F8	SIGA	5000	100	85%	5%	Eq. (1)	0	1	100	10	5	3	1	0	2	-
22	F8	F-SIGA	5000	100	85%	5%	Eq. (1)	1	1	100	10	5	3	1	0	2	-
23	F8	F-SIGA	5000	100	85%	5%	Eq. (1)	0	1	100	10	5	3	1	0	2	-
24	F8	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	1	1	100	10	5	3	1	0	2	-
25	F8	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	0	1	100	10	5	3	1	0	2	-
26	F8	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	1	1	100	10	5	3	1	0	2	-

<b>Id</b>	<b>Problema</b>	<b>Algoritmo</b>	<b>Gerações</b>	<b>Tam da População</b>	<b>Taxa de Cruzamento</b>	<b>Taxa de Mutação</b>	<b>Função de Fitness</b>	<b>Alfa</b>	<b>Beta</b>	<b>Jogos</b>	<b>Rodadas</b>	<b>R</b>	<b>T</b>	<b>P</b>	<b>S</b>	<b>Qtde. Jogadores</b>	<b>Tx. Tolerância</b>
27	F8	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	0	1	100	10	5	3	1	0	2	-
28	DPV	GA	5000	100	85%	5%	Eq. (1)	-	-	-	-	-	-	-	-	-	-
29	DPV	SIGA	5000	100	85%	5%	Eq. (1)	1	1	100	10	5	3	1	0	2	-
30	DPV	SIGA	5000	100	85%	5%	Eq. (1)	0	1	100	10	5	3	1	0	2	-
31	DPV	F-SIGA	5000	100	85%	5%	Eq. (1)	1	1	100	10	5	3	1	0	2	-
32	DPV	F-SIGA	5000	100	85%	5%	Eq. (1)	0	1	100	10	5	3	1	0	2	-
33	DPV	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	1	1	100	10	5	3	1	0	2	-
34	DPV	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	0	1	100	10	5	3	1	0	2	-
35	DPV	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	1	1	100	10	5	3	1	0	2	-
36	DPV	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	0	1	100	10	5	3	1	0	2	-
37	MWTCS	GA	5000	100	85%	5%	Eq. (1)	-	-	-	-	-	-	-	-	-	-
38	MWTCS	SIGA	5000	100	85%	5%	Eq. (1)	1	1	100	10	5	3	1	0	2	-
39	MWTCS	SIGA	5000	100	85%	5%	Eq. (1)	0	1	100	10	5	3	1	0	2	-
40	MWTCS	F-SIGA	5000	100	85%	5%	Eq. (1)	1	1	100	10	5	3	1	0	2	-
41	MWTCS	F-SIGA	5000	100	85%	5%	Eq. (1)	0	1	100	10	5	3	1	0	2	-
42	MWTCS	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	1	1	100	10	5	3	1	0	2	-
43	MWTCS	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	0	1	100	10	5	3	1	0	2	-
44	MWTCS	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	1	1	100	10	5	3	1	0	2	-
45	MWTCS	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	0	1	100	10	5	3	1	0	2	-
46	SRD	GA	5000	100	85%	5%	Eq. (1)	-	-	-	-	-	-	-	-	-	-
47	SRD	SIGA	5000	100	85%	5%	Eq. (1)	1	1	100	10	5	3	1	0	2	-
48	SRD	SIGA	5000	100	85%	5%	Eq. (1)	0	1	100	10	5	3	1	0	2	-
49	SRD	F-SIGA	5000	100	85%	5%	Eq. (1)	1	1	100	10	5	3	1	0	2	-
50	SRD	F-SIGA	5000	100	85%	5%	Eq. (1)	0	1	100	10	5	3	1	0	2	-
51	SRD	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	1	1	100	10	5	3	1	0	2	-
52	SRD	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	0	1	100	10	5	3	1	0	2	-
53	SRD	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	1	1	100	10	5	3	1	0	2	-
54	SRD	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	0	1	100	10	5	3	1	0	2	-

<b>Id</b>	<b>Problema</b>	<b>Algoritmo</b>	<b>Gerações</b>	<b>Tam da População</b>	<b>Taxa de Cruzamento</b>	<b>Taxa de Mutação</b>	<b>Função de Fitness</b>	<b>Alfa</b>	<b>Beta</b>	<b>Jogos</b>	<b>Rodadas</b>	<b>R</b>	<b>T</b>	<b>P</b>	<b>S</b>	<b>Qtde. Jogadores</b>	<b>Tx. Tolerância</b>
55	WBD	GA	5000	100	85%	5%	Eq. (1)	-	-	-	-	-	-	-	-	-	-
56	WBD	SIGA	5000	100	85%	5%	Eq. (1)	1	1	100	10	5	3	1	0	2	-
57	WBD	SIGA	5000	100	85%	5%	Eq. (1)	0	1	100	10	5	3	1	0	2	-
58	WBD	F-SIGA	5000	100	85%	5%	Eq. (1)	1	1	100	10	5	3	1	0	2	-
59	WBD	F-SIGA	5000	100	85%	5%	Eq. (1)	0	1	100	10	5	3	1	0	2	-
60	WBD	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	1	1	100	10	5	3	1	0	2	-
61	WBD	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	0	1	100	10	5	3	1	0	2	-
62	WBD	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	1	1	100	10	5	3	1	0	2	-
63	WBD	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	0	1	100	10	5	3	1	0	2	-
64	br26	GA	5000	100	85%	5%	Eq. (1)	-	-	-	-	-	-	-	-	-	-
65	br26	SIGA	5000	100	85%	5%	Eq. (1)	1	1	1000	100	30	25	15	10	2	-
66	br26	SIGA	5000	100	85%	5%	Eq. (1)	0	1	1000	100	30	25	15	10	2	-
67	br26	F-SIGA	5000	100	85%	5%	Eq. (1)	1	1	1000	100	30	25	15	10	2	-
68	br26	F-SIGA	5000	100	85%	5%	Eq. (1)	0	1	1000	100	30	25	15	10	2	-
69	br26	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	1	1	1000	100	30	25	15	10	2	-
70	br26	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	0	1	1000	100	30	25	15	10	2	-
71	br26	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	1	1	1000	100	30	25	15	10	2	-
72	br26	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	0	1	1000	100	30	25	15	10	2	-
73	br26	NpSIGA	5000	100	85%	5%	Eq. (1)	1	1	1000	100	30	25	15	10	16	25%
74	br26	NpSIGA	5000	100	85%	5%	Eq. (1)	0	1	1000	100	30	25	15	10	16	25%
75	kroa100	GA	5000	100	85%	5%	Eq. (1)	-	-	-	-	-	-	-	-	-	-
76	kroa100	SIGA	5000	100	85%	5%	Eq. (1)	1	1	1000	100	30	25	15	10	2	-
77	kroa100	SIGA	5000	100	85%	5%	Eq. (1)	0	1	1000	100	30	25	15	10	2	-
78	kroa100	F-SIGA	5000	100	85%	5%	Eq. (1)	1	1	1000	100	30	25	15	10	2	-
79	kroa100	F-SIGA	5000	100	85%	5%	Eq. (1)	0	1	1000	100	30	25	15	10	2	-
80	kroa100	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	1	1	1000	100	30	25	15	10	2	-
81	kroa100	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	0	1	1000	100	30	25	15	10	2	-
82	kroa100	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	1	1	1000	100	30	25	15	10	2	-

<b>Id</b>	<b>Problema</b>	<b>Algoritmo</b>	<b>Gerações</b>	<b>Tam da População</b>	<b>Taxa de Cruzamento</b>	<b>Taxa de Mutação</b>	<b>Função de Fitness</b>	<b>Alfa</b>	<b>Beta</b>	<b>Jogos</b>	<b>Rodadas</b>	<b>R</b>	<b>T</b>	<b>P</b>	<b>S</b>	<b>Qtde. Jogadores</b>	<b>Tx. Tolerância</b>
83	kroa100	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	0	1	1000	100	30	25	15	10	2	-
84	kroa100	NpSIGA	5000	100	85%	5%	Eq. (1)	1	1	1000	100	30	25	15	10	16	25%
85	kroa100	NpSIGA	5000	100	85%	5%	Eq. (1)	0	1	1000	100	30	25	15	10	16	25%
86	att532	GA	5000	100	85%	5%	Eq. (1)	-	-	-	-	-	-	-	-	-	-
87	att532	SIGA	5000	100	85%	5%	Eq. (1)	1	1	1000	100	30	25	15	10	2	-
88	att532	SIGA	5000	100	85%	5%	Eq. (1)	0	1	1000	100	30	25	15	10	2	-
89	att532	F-SIGA	5000	100	85%	5%	Eq. (1)	1	1	1000	100	30	25	15	10	2	-
90	att532	F-SIGA	5000	100	85%	5%	Eq. (1)	0	1	1000	100	30	25	15	10	2	-
91	att532	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	1	1	1000	100	30	25	15	10	2	-
92	att532	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	0	1	1000	100	30	25	15	10	2	-
93	att532	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	1	1	1000	100	30	25	15	10	2	-
94	att532	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	0	1	1000	100	30	25	15	10	2	-
95	att532	NpSIGA	5000	100	85%	5%	Eq. (1)	1	1	1000	100	30	25	15	10	16	25%
96	att532	NpSIGA	5000	100	85%	5%	Eq. (1)	0	1	1000	100	30	25	15	10	16	25%
97	pcb1173	GA	5000	100	85%	5%	Eq. (1)	-	-	-	-	-	-	-	-	-	-
98	pcb1173	SIGA	5000	100	85%	5%	Eq. (1)	1	1	1000	100	30	25	15	10	2	-
99	pcb1173	SIGA	5000	100	85%	5%	Eq. (1)	0	1	1000	100	30	25	15	10	2	-
100	pcb1173	F-SIGA	5000	100	85%	5%	Eq. (1)	1	1	1000	100	30	25	15	10	2	-
101	pcb1173	F-SIGA	5000	100	85%	5%	Eq. (1)	0	1	1000	100	30	25	15	10	2	-
102	pcb1173	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	1	1	1000	100	30	25	15	10	2	-
103	pcb1173	ESIA(SIGA)	5000	100	85%	5%	Eq. (27)	0	1	1000	100	30	25	15	10	2	-
104	pcb1173	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	1	1	1000	100	30	25	15	10	2	-
105	pcb1173	ESIA(F-SIGA)	5000	100	85%	5%	Eq. (27)	0	1	1000	100	30	25	15	10	2	-
106	pcb1173	NpSIGA	5000	100	85%	5%	Eq. (1)	1	1	1000	100	30	25	15	10	16	25%
107	pcb1173	NpSIGA	5000	100	85%	5%	Eq. (1)	0	1	1000	100	30	25	15	10	16	25%

Observação: para todas as simulações foram utilizados ainda os seguintes parâmetros referentes aos Algoritmos Genéticos: (1) Método de seleção por torneio; (2) Tamanho do Torneio: 2.

# ANEXO F – RESULTADOS PARA OS PROBLEMAS DE OTIMIZAÇÃO GLOBAL SEM RESTRIÇÕES

## F.1. Função $f_1$ – *Shifted Sphere Function*

Tabela F.1 (a) – Resultados obtidos nas simulações para o problema  $f_1$ .

Simulações	Algoritmo	e01	e02	e03	e04	e05	e06	e07	e08	e09	e10	
1	$f_1$	GA	0,39776146	0,29165158	0,20115233	0,08228921	0,33251615	0,39606519	0,33091955	0,19435904	0,34736105	0,65750801
2	$f_1$	SIGA(1,1)	0,37684682	0,17806652	0,22807657	0,09514862	0,33173727	0,24028435	0,28405919	0,17700882	0,21516041	0,14923375
3	$f_1$	SIGA(0,1)	0,25977119	0,48134034	0,59204739	0,42813986	0,24194484	0,45186598	0,39105891	0,37022068	0,21332193	0,48147601
4	$f_1$	F-SIGA(1,1)	0,23722087	0,11697375	0,17957823	0,14912186	0,23051743	0,28175950	0,27911239	0,21758248	0,25797237	0,25653904
5	$f_1$	F-SIGA(0,1)	0,41283514	0,41247635	0,44059273	0,48188299	0,30508404	0,30559718	0,25415703	0,39861898	0,43327332	0,37943080
6	$f_1$	ESIA(SIGA)(1,1)	0,23678520	0,22101266	0,28570165	0,35649008	0,21701818	0,16907418	0,21884149	0,37835964	0,40565143	0,16469021
7	$f_1$	ESIA(SIGA)(0,1)	0,31707929	0,23912534	0,25802100	0,26903540	0,17679881	0,45446386	0,42359458	0,44720071	0,29763729	0,29446254
8	$f_1$	ESIA(F-SIGA)(1,1)	0,13426322	0,38114959	0,17890565	0,16061573	0,19682539	0,29783209	0,20241299	0,31218557	0,50042613	0,42462594
9	$f_1$	ESIA(F-SIGA)(0,1)	0,22547377	0,26976706	0,23281459	0,19005891	0,23574229	0,33267505	0,28426380	0,30159391	0,23807946	0,38871672
<b>Média</b>			0,28867077	0,28795146	0,28854335	0,24586474	0,25202049	0,32551304	0,29649110	0,31079220	0,32320927	0,35518700
<b>Desvio Padrão</b>			0,09348100	0,11731839	0,13895428	0,14616636	0,05745531	0,09515551	0,07379201	0,09659659	0,10416728	0,16047014
<b>Melhor Solução</b>			0,13426322	0,11697375	0,17890565	0,08228921	0,17679881	0,16907418	0,20241299	0,17700882	0,21332193	0,14923375

Tabela F.1 (b) – Resultados obtidos nas simulações para o problema  $f_1$ .

Simulações	Algoritmo	e11	e12	e13	e14	e15	e16	e17	e18	e19	e20	
1	$f_1$	GA	0,26050340	0,33075444	0,32527061	0,22950414	0,43100650	0,25740308	0,26615535	0,28743962	0,30932811	0,32488763
2	$f_1$	SIGA(1,1)	0,36742163	0,14614940	0,12749635	0,36926288	0,43234896	0,12692057	0,19273495	0,31188283	0,26892252	0,17000488
3	$f_1$	SIGA(0,1)	0,25616192	0,32007837	0,29453233	0,36073799	0,41409232	0,24591966	0,52335397	0,27047889	0,41824001	0,25764733
4	$f_1$	F-SIGA(1,1)	0,42975971	0,29439824	0,13178496	0,48826017	0,46013216	0,38404464	0,38367828	0,26189143	0,12210500	0,44785277
5	$f_1$	F-SIGA(0,1)	0,67798981	0,28674508	0,37618422	0,34226504	0,54821190	0,65278023	0,39243063	0,33373104	0,23978961	0,30699608
6	$f_1$	ESIA(SIGA)(1,1)	0,26476602	0,23675021	0,16973587	0,21272770	0,21805291	0,22186668	0,35811226	0,13049785	0,20346233	0,14726384
7	$f_1$	ESIA(SIGA)(0,1)	0,58997188	0,44562028	0,25534856	0,25464511	0,21672466	0,33888467	0,26664175	0,23733020	0,49937961	0,35161420
8	$f_1$	ESIA(F-SIGA)(1,1)	0,23691555	0,37160417	0,23893479	0,46300271	0,27238630	0,21604393	0,21000185	0,49884821	0,23832169	0,41277362
9	$f_1$	ESIA(F-SIGA)(0,1)	0,60923489	0,43747021	0,44207260	0,27905909	0,17968630	0,45562780	0,67601568	0,24782620	0,10970589	0,64160352
<b>Média</b>			0,41030276	0,31884116	0,26237337	0,33327387	0,35251578	0,32216570	0,36323608	0,28665848	0,26769497	0,34007154
<b>Desvio Padrão</b>			0,17434593	0,09438099	0,10877761	0,09836279	0,13182105	0,15838113	0,15655341	0,09815787	0,12747585	0,15090267
<b>Melhor Solução</b>			0,23691555	0,14614940	0,12749635	0,21272770	0,17968630	0,12692057	0,19273495	0,13049785	0,10970589	0,14726384

Tabela F.1 (c) – Resultados obtidos nas simulações para o problema  $f_1$ .

Simulações	Algoritmo	e21	e22	e23	e24	e25	e26	e27	e28	e29	e30	
1	<i>f1</i>	GA	0,26630961	0,16012363	0,33751958	0,28095904	0,33897911	0,12709106	0,18436125	0,42812828	0,18510794	0,34372192
2	<i>f1</i>	SIGA(1,1)	0,20473702	0,23800395	0,10716475	0,17856943	0,13685652	0,31720878	0,41174077	0,18989604	0,23275223	0,23452238
3	<i>f1</i>	SIGA(0,1)	0,08214600	0,35344910	0,43536527	0,15012393	0,59433439	0,14169363	0,27742437	0,15780996	0,28309237	0,38962035
4	<i>f1</i>	F-SIGA(1,1)	0,13245229	0,40370289	0,23344969	0,13783400	0,22866888	0,23555602	0,20282961	0,19706277	0,26982566	0,18843288
5	<i>f1</i>	F-SIGA(0,1)	0,35915155	0,22744393	0,23994041	0,25710531	0,26265326	0,30008629	0,58457630	0,51989019	0,26696021	0,33563901
6	<i>f1</i>	ESIA(SIGA)(1,1)	0,34035423	0,38609114	0,23501635	0,28784873	0,18560225	0,17806763	0,23695206	0,17444320	0,25281634	0,20935812
7	<i>f1</i>	ESIA(SIGA)(0,1)	0,36690007	0,21247754	0,28632844	0,34721501	0,24242557	0,38305122	0,29553118	0,56082181	0,10192173	0,11008888
8	<i>f1</i>	ESIA(F-SIGA)(1,1)	0,16840988	0,17618384	0,26623235	0,20554828	0,34494214	0,19963892	0,21391669	0,26536878	0,32946083	0,29828017
9	<i>f1</i>	ESIA(F-SIGA)(0,1)	0,28126143	0,21912705	0,21263035	0,23733454	0,25816812	0,45571506	0,29540055	0,29193231	0,35358371	0,25951312
<b>Média</b>			0,24463579	0,26406701	0,26151635	0,23139314	0,28807003	0,25978985	0,30030364	0,30948370	0,25283567	0,26324187
<b>Desvio Padrão</b>			0,10333562	0,09192831	0,09000527	0,06943651	0,13235428	0,11232788	0,12659947	0,15490036	0,07515868	0,08782937
<b>Melhor Solução</b>			0,08214600	0,16012363	0,10716475	0,13783400	0,13685652	0,12709106	0,18436125	0,15780996	0,10192173	0,11008888

Tabela F.1 (d) – Resultados obtidos nas simulações para o problema  $f_1$ .

Simulações	Algoritmo	e31	e32	e33	e34	e35	e36	e37	e38	e39	e40	
1	<i>f1</i>	GA	0,24460900	0,13425592	0,33379434	0,18721152	0,27609167	0,14705367	0,22125403	0,22245812	0,11118464	0,28148516
2	<i>f1</i>	SIGA(1,1)	0,34292488	0,45128708	0,23631279	0,31278586	0,17219881	0,36807752	0,28676367	0,36434850	0,25345585	0,23157874
3	<i>f1</i>	SIGA(0,1)	0,21999396	0,26874584	0,16345833	0,12893882	0,63094654	0,35938144	0,44027505	0,33441530	0,18285218	0,48978388
4	<i>f1</i>	F-SIGA(1,1)	0,46803490	0,21546459	0,18315426	0,24298076	0,17296915	0,11738400	0,17651263	0,32706818	0,44400383	0,32289023
5	<i>f1</i>	F-SIGA(0,1)	0,37511363	0,21064931	0,39988859	0,16709053	0,68740943	0,33385853	0,59265598	0,17276383	0,15276097	0,39925161
6	<i>f1</i>	ESIA(SIGA)(1,1)	0,26874211	0,13664172	0,13396438	0,44064553	0,16389263	0,17231577	0,32144440	0,41542749	0,15122828	0,32158580
7	<i>f1</i>	ESIA(SIGA)(0,1)	0,26411979	0,33303467	0,28666926	0,24278302	0,62374830	0,99577590	0,36438135	0,48755155	0,20879060	0,33913057
8	<i>f1</i>	ESIA(F-SIGA)(1,1)	0,20792709	0,24339558	0,29553434	0,35295068	0,18473609	0,26894971	0,32189523	0,36639789	0,13425780	0,30069197
9	<i>f1</i>	ESIA(F-SIGA)(0,1)	0,30445466	0,24660684	0,19826392	0,43997803	0,41866078	0,35107354	0,28614831	0,55184748	0,26144897	0,32921577
<b>Média</b>			0,29954667	0,24889795	0,24789336	0,27948497	0,37007260	0,34598556	0,33459230	0,36025315	0,21110924	0,33506819
<b>Desvio Padrão</b>			0,08362814	0,09797628	0,08743011	0,11441566	0,22337359	0,26243957	0,12321542	0,11827963	0,10139796	0,07348488
<b>Melhor Solução</b>			0,20792709	0,13425592	0,13396438	0,12893882	0,16389263	0,11738400	0,17651263	0,17276383	0,11118464	0,23157874

Tabela F.1 (e) – Resultados obtidos nas simulações para o problema  $f_1$ .

Simulações	Algoritmo	e41	e42	e43	e44	e45	e46	e47	e48	e49	e50	
1	<i>fl</i>	GA	0,22693083	0,33254604	0,38269270	0,19010048	0,18910570	0,27757481	0,19312443	0,25442649	0,28516329	0,23564249
2	<i>fl</i>	SIGA(1,1)	0,37753620	0,39472400	0,22860428	0,15476717	0,10296969	0,24522146	0,29764983	0,17744784	0,31778774	0,36418351
3	<i>fl</i>	SIGA(0,1)	0,35207234	0,54068231	0,31760895	0,22140706	0,30355033	0,44694629	0,31634040	0,35790605	0,41684809	0,22747613
4	<i>fl</i>	F-SIGA(1,1)	0,39593510	0,26970801	0,21750121	0,41707874	0,25923892	0,32523418	0,21590591	0,32539240	0,11256760	0,33232038
5	<i>fl</i>	F-SIGA(0,1)	0,23289598	0,13180445	0,37776569	0,81617694	0,76919215	0,23837093	0,37404728	0,54115209	0,34478746	0,12840235
6	<i>fl</i>	ESIA(SIGA)(1,1)	0,35952516	0,22106171	0,19960928	0,24600327	0,31569467	0,44792007	0,29442624	0,39498063	0,23993450	0,19662284
7	<i>fl</i>	ESIA(SIGA)(0,1)	0,24032866	0,23215485	0,15645819	0,42348020	0,39832702	0,27597224	0,35668377	0,34958310	0,51662709	0,37713229
8	<i>fl</i>	ESIA(F-SIGA)(1,1)	0,32391139	0,39611120	0,52344155	0,23420456	0,28019387	0,14167944	0,19386075	0,21923885	0,39202610	0,18585642
9	<i>fl</i>	ESIA(F-SIGA)(0,1)	0,22894314	0,41662316	0,32750883	0,42683759	0,23087782	0,41045899	0,40221741	0,51414611	0,31897071	0,47497716
<b>Média</b>			0,30423098	0,32615731	0,30346563	0,34778400	0,31657224	0,31215316	0,29380623	0,34825262	0,32719029	0,28029040
<b>Desvio Padrão</b>			0,07100407	0,12484085	0,11530198	0,20540308	0,18892682	0,10483718	0,07815252	0,12356885	0,11403775	0,11224820
<b>Melhor Solução</b>			0,22693083	0,13180445	0,15645819	0,15476717	0,10296969	0,14167944	0,19312443	0,17744784	0,11256760	0,12840235

## F.2. Função $f_6$ – *Shifted Rosenbrock's Function*

Tabela F.2 (a) – Resultados obtidos nas simulações para o problema  $f_6$ .

Simulações	Algoritmo	e01	e02	e03	e04	e05	e06	e07	e08	e09	e10
10	$f_6$ GA	85,77590935	88,89973795	85,47896297	81,48051890	86,82558834	96,48901939	86,25230127	100,65877861	86,70928160	81,73629722
11	$f_6$ SIGA(1,1)	92,64731177	92,41692233	81,97115101	88,85190367	90,70732380	84,55882727	88,88984671	88,46896404	85,37414864	86,52742321
12	$f_6$ SIGA(0,1)	89,48059125	90,43148493	85,24655226	101,15209175	88,95490835	92,13685018	97,31394930	92,30925917	97,72412975	85,03332550
13	$f_6$ F-SIGA(1,1)	85,72272352	83,65093876	88,81514957	85,07900447	82,54284224	88,87225444	86,86800827	88,30946875	89,33289835	87,30605055
14	$f_6$ F-SIGA(0,1)	106,61041868	91,31371497	95,78563239	93,41019788	89,38571151	86,77682964	88,67054783	95,62435029	90,15489995	84,28571149
15	$f_6$ ESIA(SIGA)(1,1)	91,27827190	89,75916967	91,74805662	82,95318227	93,73162707	84,67495492	99,94931581	87,64700325	80,39707889	87,23455517
16	$f_6$ ESIA(SIGA)(0,1)	90,52520871	87,96063072	89,91159877	104,36235737	85,95051058	92,52774515	95,37027597	99,87485959	91,28430078	89,27140188
17	$f_6$ ESIA(F-SIGA)(1,1)	88,01032867	88,22118364	84,79077681	102,30330137	79,32592008	93,38399398	89,19643679	85,68441612	83,37001152	88,48203047
18	$f_6$ ESIA(F-SIGA)(0,1)	93,04599106	93,92397161	87,20703885	103,17586639	86,79610623	90,76772972	83,64502311	84,25534761	105,96763745	93,54574229
<b>Média</b>		91,45519499	89,61975051	87,88387992	93,64093601	87,13561536	90,02091163	90,68396723	91,42582749	90,03493188	87,04694864
<b>Desvio Padrão</b>		6,27903689	2,97388960	4,18439582	9,32547837	4,30607120	4,10370242	5,53396613	6,04313047	7,78729141	3,34470355
<b>Melhor Solução</b>		85,72272352	83,65093876	81,97115101	81,48051890	79,32592008	84,55882727	83,64502311	84,25534761	80,39707889	81,73629722

Tabela F.2 (b) – Resultados obtidos nas simulações para o problema  $f_6$ .

Simulações	Algoritmo	e11	e12	e13	e14	e15	e16	e17	e18	e19	e20
10	$f_6$ GA	86,06307092	88,63936633	98,04468078	104,67826430	82,71636097	94,94816792	85,67648859	87,95163640	86,80639311	85,55445229
11	$f_6$ SIGA(1,1)	83,07236128	88,40114563	81,78368371	95,71259698	85,07077450	81,58721768	81,25828758	86,42357267	87,27129195	88,92203807
12	$f_6$ SIGA(0,1)	91,59993731	93,37663095	105,17293314	82,72507818	92,95676315	87,32288163	89,97560595	88,31616885	85,71042506	87,98042652
13	$f_6$ F-SIGA(1,1)	90,77978253	83,74928317	88,56367044	84,51072259	84,88604129	93,40166328	80,83796039	90,69971863	88,93792921	92,21307259
14	$f_6$ F-SIGA(0,1)	82,71783470	95,77018561	88,91403131	85,70618742	114,30647899	88,00362632	95,54474741	94,94119160	88,85967122	96,82080641
15	$f_6$ ESIA(SIGA)(1,1)	81,34517953	82,70586678	83,32054869	83,57164390	94,38441358	91,17225885	82,94834948	81,50901136	82,45717177	88,03190508
16	$f_6$ ESIA(SIGA)(0,1)	95,02501536	83,50815094	99,44123471	91,16412189	95,77729119	87,48545978	86,02067932	87,43685674	82,97751836	85,24293609
17	$f_6$ ESIA(F-SIGA)(1,1)	90,49706960	104,49086712	87,39926442	90,35821116	80,88279117	89,12957822	88,66765818	90,46576071	83,50211778	86,40678406
18	$f_6$ ESIA(F-SIGA)(0,1)	82,44587759	86,85667834	85,27506213	90,92020628	95,52292053	93,11622549	93,11359131	85,32374261	85,16840008	94,46680756
<b>Média</b>		87,06068098	89,72201943	90,87945659	89,92744808	91,83375949	89,57411991	87,11592980	88,11862884	85,74343539	89,51546985
<b>Desvio Padrão</b>		4,99251382	7,09484429	8,07437973	7,01057549	10,24091588	4,10055316	5,14742267	3,76865003	2,42860626	4,08776167
<b>Melhor Solução</b>		81,34517953	82,70586678	81,78368371	82,72507818	80,88279117	81,58721768	80,83796039	81,50901136	82,45717177	85,24293609

Tabela F.2 (c) – Resultados obtidos nas simulações para o problema  $f_6$ .

Simulações	Algoritmo	e21	e22	e23	e24	e25	e26	e27	e28	e29	e30	
10	$f_6$	GA	89,94049559	92,41261411	85,81937875	85,15673794	81,68083855	82,27477301	93,34283866	86,20293137	88,31964437	86,26587872
11	$f_6$	SIGA(1,1)	84,41711809	86,03357434	84,97536056	88,84326861	87,15953998	88,93000148	92,25854368	83,43936749	86,11130623	81,58190164
12	$f_6$	SIGA(0,1)	86,61119672	87,24946921	90,48691095	84,63858437	83,61981555	87,27507559	91,30652329	87,59374667	92,68450158	95,04993678
13	$f_6$	F-SIGA(1,1)	96,17963716	86,67388444	89,16986153	98,35280017	87,33470938	94,29069215	112,83730409	86,81394171	85,07912473	86,22970889
14	$f_6$	F-SIGA(0,1)	84,98435254	94,64295143	91,11384690	82,14162845	90,88768996	88,12016496	90,28254860	93,22480783	84,11935518	79,94684157
15	$f_6$	ESIA(SIGA)(1,1)	85,13170290	86,46143725	83,67989430	83,95570606	86,12730514	82,13928895	83,79331457	90,10564547	89,20904174	85,88534484
16	$f_6$	ESIA(SIGA)(0,1)	86,39718395	90,75143761	86,55108216	88,95660071	87,70565551	92,56248227	84,83147131	101,37300425	89,12613680	85,92538840
17	$f_6$	ESIA(F-SIGA)(1,1)	85,73741779	82,97082272	93,81245459	84,04628189	81,96981030	84,13218874	81,34140382	91,33471401	87,79829607	85,33362188
18	$f_6$	ESIA(F-SIGA)(0,1)	90,96528773	86,42716800	91,93870404	105,92125919	84,68265923	84,06520045	105,48303836	88,90125917	85,21992618	87,16795694
<b>Média</b>			87,81826583	88,18037323	88,61638820	89,11254082	85,68533596	87,08776307	92,83077626	89,88771311	87,51859254	85,93184218
<b>Desvio Padrão</b>			3,85588909	3,66059890	3,49632274	7,94142963	2,98638767	4,35707892	10,29209426	5,19653300	2,68371224	4,18285518
<b>Melhor Solução</b>			84,41711809	82,97082272	83,67989430	82,14162845	81,68083855	82,13928895	81,34140382	83,43936749	84,11935518	79,94684157

Tabela F.2 (d) – Resultados obtidos nas simulações para o problema  $f_6$ .

Simulações	Algoritmo	e31	e32	e33	e34	e35	e36	e37	e38	e39	e40	
10	$f_6$	GA	96,88299728	89,13012494	87,64230615	86,31281679	88,94461620	84,46582308	82,02546081	81,36248161	88,62892244	101,04391512
11	$f_6$	SIGA(1,1)	90,50541661	85,73885498	86,23704070	83,69569441	92,35605222	83,31580095	89,18501342	79,30141381	94,41398111	84,92796025
12	$f_6$	SIGA(0,1)	93,74274475	94,93958897	86,45014243	83,53614532	89,69688323	86,13322105	86,38214386	98,08741447	86,44139663	99,74489754
13	$f_6$	F-SIGA(1,1)	84,17138585	84,73998000	89,95990576	83,84557730	86,10547275	87,72854773	91,32699604	95,62308080	92,58417652	92,44596825
14	$f_6$	F-SIGA(0,1)	95,27729350	93,51973658	96,29980593	103,05725284	117,61648900	86,41810153	88,41033507	99,46618654	91,87492676	85,19116536
15	$f_6$	ESIA(SIGA)(1,1)	90,51166634	80,43456612	90,09694908	86,98787086	84,28130254	89,67284222	88,93830805	84,69206987	84,25469662	86,62294478
16	$f_6$	ESIA(SIGA)(0,1)	86,72735725	95,52644331	90,84541962	94,98413664	90,62394211	93,22721290	93,34465872	90,44448066	89,28031258	103,71758100
17	$f_6$	ESIA(F-SIGA)(1,1)	82,64635267	90,05221749	90,85845366	85,89497918	85,36690810	84,33024996	87,76533287	81,77052989	89,72781097	92,26363147
18	$f_6$	ESIA(F-SIGA)(0,1)	91,37773195	100,27249401	86,71308610	89,20989262	87,61495137	93,03917650	102,30640247	94,34213130	86,73861616	94,96219448
<b>Média</b>			90,20477180	90,48377849	89,45590105	88,61381844	91,40073528	87,59233066	89,96496126	89,45442099	89,32720442	93,43558425
<b>Desvio Padrão</b>			4,87379074	6,21318679	3,19393410	6,49602079	10,16847317	3,67389188	5,59439983	7,81002183	3,24775589	7,02548137
<b>Melhor Solução</b>			82,64635267	80,43456612	86,23704070	83,53614532	84,28130254	83,31580095	82,02546081	79,30141381	84,25469662	84,92796025

Tabela F.2 (e) – Resultados obtidos nas simulações para o problema  $f_6$ .

Simulações	Algoritmo	e41	e42	e43	e44	e45	e46	e47	e48	e49	e50
10	$f_6$ GA	82,63297020	99,33366161	94,66699238	89,79766611	87,51734243	84,06458600	94,48754791	85,48276828	85,53161649	90,49922613
11	$f_6$ SIGA(1,1)	85,46103690	88,15662989	83,72955236	85,82043805	84,86318760	90,83443629	81,71652711	85,09784824	84,50728636	87,83807460
12	$f_6$ SIGA(0,1)	97,35479365	81,58001159	94,96018053	94,80404130	96,46341377	91,62941848	89,29906184	100,37229091	90,58641344	96,04462563
13	$f_6$ F-SIGA(1,1)	85,78362760	93,08607463	88,28634087	80,23655918	89,86443408	87,37867852	80,58495453	95,28284701	91,17595012	82,75755042
14	$f_6$ F-SIGA(0,1)	87,51710027	94,90916745	85,41335966	88,74512261	89,10248855	85,95884972	84,09033381	89,03292397	83,69075558	93,99682698
15	$f_6$ ESIA(SIGA)(1,1)	81,66701820	86,66151029	82,83425012	80,91452432	91,45277103	83,05419416	86,93331922	86,11301998	82,78882694	79,98617653
16	$f_6$ ESIA(SIGA)(0,1)	85,85813539	92,97346810	86,17329500	90,73570547	86,04681256	110,60257054	103,87539831	93,17190947	92,96845234	86,03150624
17	$f_6$ ESIA(F-SIGA)(1,1)	83,81950148	84,31245258	91,45749016	89,24037811	89,50389077	88,23879799	82,65390660	84,91382266	111,70086447	87,34431199
18	$f_6$ ESIA(F-SIGA)(0,1)	94,62116182	94,17739810	85,97488479	90,69093960	92,63560986	95,78098805	83,26934068	94,41698327	88,74644181	89,04299668
<b>Média</b>		87,19059395	90,57670825	88,16626065	87,88726386	89,71666118	90,83805775	87,43448778	90,43160153	90,18851195	88,17125502
<b>Desvio Padrão</b>		5,33881256	5,72088044	4,52397353	4,76257089	3,52417230	8,40158742	7,53967800	5,58722479	8,83644075	5,04707480
<b>Melhor Solução</b>		81,66701820	81,58001159	82,83425012	80,23655918	84,86318760	83,05419416	80,58495453	84,91382266	82,78882694	79,98617653

### F.3. Função $f_8$ – *Shifted Rotated Ackley's Function with Global Optimum on Bounds*

Tabela F.3 (a) – Resultados obtidos nas simulações para o problema  $f_8$ .

Simulações	Algoritmo	e01	e02	e03	e04	e05	e06	e07	e08	e09	e10	
19	$f_8$	GA	1,91433695	2,15565357	2,00462515	2,09425066	2,11760367	2,14368095	2,08845647	2,03456607	2,06078970	2,09079668
20	$f_8$	SIGA(1,1)	2,26770042	2,18876507	2,04425126	2,04943108	2,04458552	2,09861949	2,00332234	2,06745203	2,23488141	1,99244833
21	$f_8$	SIGA(0,1)	2,17191646	2,02680187	2,08137571	2,03832173	2,18758915	2,23576077	2,15305542	2,12118187	2,06411892	2,17444508
22	$f_8$	F-SIGA(1,1)	2,27429391	2,01286657	2,06604468	2,15412473	2,15698233	2,16490446	2,11034412	1,98740211	2,02674878	2,14938303
23	$f_8$	F-SIGA(0,1)	2,14376950	2,19137285	2,09792860	2,07286620	2,05333023	2,10567517	2,11570157	2,13312271	2,12918088	2,07943532
24	$f_8$	ESIA(SIGA)(1,1)	2,16972566	2,12051655	2,08635212	2,05724207	2,20527653	2,07912374	2,06690035	2,19605914	2,04518376	2,11457966
25	$f_8$	ESIA(SIGA)(0,1)	2,22155626	2,14125667	2,06795909	2,07801211	2,13109184	2,20018867	2,12891641	2,10484235	2,06468169	2,04636075
26	$f_8$	ESIA(F-SIGA)(1,1)	1,98988371	2,16718464	2,09936141	2,11279962	2,13181651	2,08650133	2,08041813	2,04866407	2,14631009	2,16983420
27	$f_8$	ESIA(F-SIGA)(0,1)	2,19577491	1,98533683	2,26756231	2,13932349	2,18990501	2,06267401	2,14870887	2,13586486	2,17340468	2,03895019
<b>Média</b>			2,14988420	2,10997274	2,09060670	2,08848574	2,13535342	2,13079207	2,09953596	2,09212836	2,10503332	2,09513703
<b>Desvio Padrão</b>			0,12175818	0,07997274	0,07263325	0,04013864	0,05741715	0,05926781	0,04654843	0,06342303	0,06963496	0,06278586
<b>Melhor Solução</b>			1,91433695	1,98533683	2,00462515	2,03832173	2,04458552	2,06267401	2,00332234	1,98740211	2,02674878	1,99244833

Tabela F.3 (b) – Resultados obtidos nas simulações para o problema  $f_8$ .

Simulações	Algoritmo	e11	e12	e13	e14	e15	e16	e17	e18	e19	e20	
19	$f_8$	GA	2,02568427	2,07934712	2,11454548	2,03698525	1,98629939	2,05960778	2,16721386	2,12553580	1,97236637	2,08467339
20	$f_8$	SIGA(1,1)	2,06724543	2,12203318	2,02394116	2,20876024	2,09142118	2,03723591	2,19218440	2,04843194	2,03199011	2,07590141
21	$f_8$	SIGA(0,1)	2,27053167	2,08761830	2,23302452	2,14567561	2,08526097	2,23059606	2,18146980	2,11527550	2,34198230	2,05288814
22	$f_8$	F-SIGA(1,1)	2,13361748	2,13147964	2,09465854	2,14222930	2,22383158	2,06647713	2,01331029	2,26181241	2,10214101	2,07562802
23	$f_8$	F-SIGA(0,1)	2,26133767	2,15874981	2,08344903	2,07498173	2,14639666	2,08800793	2,05152634	2,12003751	2,12223268	2,07914676
24	$f_8$	ESIA(SIGA)(1,1)	2,11084530	2,18982602	2,09169009	2,12249316	2,12006124	2,01731766	2,15178135	2,11686344	2,12838771	1,96109746
25	$f_8$	ESIA(SIGA)(0,1)	2,11079140	2,30742124	2,16726001	2,18559668	2,11605067	2,17915844	2,04626000	2,07733428	2,17033808	2,29910579
26	$f_8$	ESIA(F-SIGA)(1,1)	1,95723561	2,03396383	2,06586148	2,07373356	2,08005479	2,10618633	2,08233476	2,11790072	2,06376512	2,18542173
27	$f_8$	ESIA(F-SIGA)(0,1)	2,05405492	2,18701729	2,31935036	2,12343067	2,08493893	2,05084345	2,05101300	2,10170543	2,47867969	2,07619335
<b>Média</b>			2,11014930	2,14416183	2,13264230	2,12376513	2,10381282	2,09282563	2,10412153	2,12054412	2,15687590	2,09889512
<b>Desvio Padrão</b>			0,10285690	0,07982832	0,09238358	0,05509510	0,06310652	0,06981010	0,06859847	0,05857938	0,15863510	0,09411011
<b>Melhor Solução</b>			1,95723561	2,03396383	2,02394116	2,03698525	1,98629939	2,01731766	2,01331029	2,04843194	1,97236637	1,96109746

Tabela F.3 (c) – Resultados obtidos nas simulações para o problema  $f_8$ .

Simulações	Algoritmo	e21	e22	e23	e24	e25	e26	e27	e28	e29	e30	
19	$f_8$	GA	2,04754333	2,01242505	2,19115427	2,28317133	2,05485257	2,03741602	1,98973281	2,07746096	2,12633474	2,12301529
20	$f_8$	SIGA(1,1)	2,22247721	2,12357833	2,25910823	2,07903060	2,11052301	2,03390096	1,97660317	2,15018165	2,07809583	2,01893913
21	$f_8$	SIGA(0,1)	2,08373872	2,27931451	2,11375058	2,33988391	2,04861715	2,09407934	2,09345121	2,28791623	1,98688306	2,07351699
22	$f_8$	F-SIGA(1,1)	2,05159402	2,21039464	2,20918542	2,12102303	2,13485133	2,04159525	2,11974509	2,03398223	2,07270941	2,05171165
23	$f_8$	F-SIGA(0,1)	2,07775541	2,21908127	2,13530820	2,07955822	2,12950590	2,19482058	2,09474601	2,18052479	2,25570354	2,06231733
24	$f_8$	ESIA(SIGA)(1,1)	2,13307818	2,09675809	2,19480331	2,06520675	2,10293758	2,19932785	2,26857020	2,14113741	2,14571923	2,13691416
25	$f_8$	ESIA(SIGA)(0,1)	2,12557832	2,02855043	2,05444091	2,16531696	2,14466314	2,05803948	2,28895086	2,09164079	2,00251211	2,03687324
26	$f_8$	ESIA(F-SIGA)(1,1)	2,11598571	2,03797900	2,24040415	2,02178488	2,25599891	2,05257077	2,02243712	2,01054607	1,96104882	1,97165996
27	$f_8$	ESIA(F-SIGA)(0,1)	2,12511602	2,37299254	2,07476677	2,07511565	2,14675021	2,29700394	2,23829321	2,02891153	2,17788663	2,27340425
<b>Média</b>			2,10920744	2,15345265	2,16365798	2,13667681	2,12541109	2,11208380	2,12139219	2,11136685	2,08965482	2,08315022
<b>Desvio Padrão</b>			0,05329932	0,12475914	0,07239132	0,10753057	0,06081487	0,09493128	0,11884165	0,08862575	0,09679993	0,08723981
<b>Melhor Solução</b>			2,04754333	2,01242505	2,05444091	2,02178488	2,04861715	2,03390096	1,97660317	2,01054607	1,96104882	1,97165996

Tabela F.3 (d) – Resultados obtidos nas simulações para o problema  $f_8$ .

Simulações	Algoritmo	e31	e32	e33	e34	e35	e36	e37	e38	e39	e40	
19	$f_8$	GA	2,18983816	2,13153330	2,06958889	2,10706311	2,00068326	2,14944815	2,11899450	2,04363446	2,09397273	2,13542826
20	$f_8$	SIGA(1,1)	2,03450012	2,26721344	2,10231773	2,02462503	2,23386240	2,22251643	2,12119075	2,11204515	2,18956919	2,05646095
21	$f_8$	SIGA(0,1)	2,22021678	2,12683145	2,11062220	2,11490370	2,13922342	2,04644127	2,07558878	2,40127758	2,04174674	2,22075762
22	$f_8$	F-SIGA(1,1)	2,29792467	2,07636387	2,19883119	2,03137980	2,20641675	2,00878536	2,10644514	2,09878249	2,19829290	2,07580360
23	$f_8$	F-SIGA(0,1)	2,29578727	2,10969145	2,12884453	1,99871386	2,28634293	2,06619755	2,08771966	2,09049803	2,10316854	2,09173709
24	$f_8$	ESIA(SIGA)(1,1)	2,10520216	2,26887593	2,01014774	2,11037733	1,99093970	2,08749966	2,13454873	2,09223125	2,27773588	2,10494715
25	$f_8$	ESIA(SIGA)(0,1)	2,18687083	2,06736671	2,01415355	2,03349002	2,18792055	2,14030259	2,11083972	2,14464475	2,07174253	2,12292352
26	$f_8$	ESIA(F-SIGA)(1,1)	2,17906006	2,26411651	2,28711639	2,08556035	2,05698580	2,00403362	1,99288496	2,07620321	2,06271324	2,09211433
27	$f_8$	ESIA(F-SIGA)(0,1)	2,14444045	2,05258861	2,06843191	1,96604310	2,21590871	2,07773966	2,23691006	2,13433625	2,10507589	2,15131491
<b>Média</b>			2,18376005	2,15162014	2,11000602	2,05246181	2,14647595	2,08921825	2,10945803	2,13262813	2,12711307	2,11683194
<b>Desvio Padrão</b>			0,08439295	0,09021608	0,08817149	0,05392856	0,10655911	0,07091021	0,06356307	0,10511870	0,07771138	0,04883965
<b>Melhor Solução</b>			2,03450012	2,05258861	2,01014774	1,96604310	1,99093970	2,00403362	1,99288496	2,04363446	2,04174674	2,05646095

Tabela F.3 (e) – Resultados obtidos nas simulações para o problema  $f_8$ .

Simulações	Algoritmo	e41	e42	e43	e44	e45	e46	e47	e48	e49	e50
19	$f_8$ GA	2,08469883	2,15883339	1,97433515	2,02531903	2,10131177	2,02334834	2,03547920	2,08744240	2,10095498	2,07139493
20	$f_8$ SIGA(1,1)	2,08884989	2,04850634	2,01151644	2,13931153	2,21789102	2,05098569	2,22198513	2,14077843	2,17127653	2,21135914
21	$f_8$ SIGA(0,1)	2,17185772	2,12433234	2,05423986	2,17833645	2,27636170	2,24739857	2,15461734	2,04667520	1,96103579	2,11887771
22	$f_8$ F-SIGA(1,1)	2,08110083	2,05073790	2,05050150	2,11767939	2,02281618	2,06887712	2,14967656	1,99698909	2,12372962	2,28809839
23	$f_8$ F-SIGA(0,1)	2,15357625	2,15920614	2,17443602	2,24336289	2,14167382	2,13771695	2,10451899	2,23191793	2,16412015	2,15390843
24	$f_8$ ESIA(SIGA)(1,1)	2,08727708	2,10525639	2,10029695	2,08193895	2,10633948	2,09916423	2,19881377	2,11043426	2,09330517	2,03970429
25	$f_8$ ESIA(SIGA)(0,1)	2,21193578	2,05285911	2,16211012	2,07436319	2,18413231	2,12055586	2,06224962	2,19146869	2,18586703	2,07637361
26	$f_8$ ESIA(F-SIGA)(1,1)	2,11914970	2,01978675	1,99117931	2,17686501	2,21073560	2,09329014	2,08737356	2,12726233	2,23870335	2,01175627
27	$f_8$ ESIA(F-SIGA)(0,1)	2,13546481	2,02154203	2,15367455	2,15876419	2,21811015	2,24039992	2,24406408	2,22903338	2,17540918	2,14459596
<b>Média</b>		2,12599010	2,08234004	2,07469888	2,13288229	2,16437467	2,12019298	2,13986425	2,12911130	2,13493353	2,12400764
<b>Desvio Padrão</b>		0,04607896	0,05553152	0,07626036	0,06589615	0,07804762	0,07818729	0,07272830	0,07977995	0,07939361	0,08706667
<b>Melhor Solução</b>		2,08110083	2,01978675	1,97433515	2,02531903	2,02281618	2,02334834	2,03547920	1,99698909	1,96103579	2,01175627

# ANEXO G – RESULTADOS PARA OS PROBLEMAS DE OTIMIZAÇÃO GLOBAL COM RESTRIÇÕES

## G.1. Projeto de Viga de Aço

Tabela G.1 (a) – Resultados obtidos nas simulações para o problema WBD.

Simulações	Algoritmo	e01	e02	e03	e04	e05	e06	e07	e08	e09	e10
55	WBD GA	1,80575400	1,80771700	2,16249400	1,69942400	1,79837500	1,83281200	1,69791300	1,85152200	2,42896500	2,83714600
56	WBD SIGA(1,1)	2,37645800	1,97421200	2,47184000	2,00929500	1,82775100	2,10737900	1,94082100	1,86173600	2,07380700	2,15431400
57	WBD SIGA(0,1)	2,49866300	2,01707400	1,96952200	2,17704100	2,00028700	1,78587400	1,66437300	2,66395000	1,88948600	2,14173800
58	WBD F-SIGA(1,1)	2,00878000	1,95846200	2,43550600	1,71085900	2,46620000	2,41927600	2,05225300	2,15098900	2,35775200	2,60358400
59	WBD F-SIGA(0,1)	1,69178400	2,16988900	1,86334100	2,35302700	1,74948900	1,88928200	2,28950000	2,90587500	1,89186500	2,16756500
60	WBD ESIA(SIGA)(1,1)	2,44904400	2,09809800	2,05758100	2,09080000	1,89830300	2,95432000	1,83859600	1,89356600	2,88369500	1,70074700
61	WBD ESIA(SIGA)(0,1)	1,74181100	1,72592500	2,14869500	2,20712000	2,31443200	2,14547500	1,92576300	1,94020100	1,78011200	2,74937900
62	WBD ESIA(F-SIGA)(1,1)	2,00279500	1,67614900	1,80680500	2,45176100	1,68571800	2,02498200	1,97193700	2,43760400	2,42736000	1,99371900
63	WBD ESIA(F-SIGA)(0,1)	2,18824700	1,89308000	1,82209500	1,67595500	2,74580200	1,81382800	2,66676900	2,05529900	1,67032100	1,75260400
<b>Média</b>		2,08481511	1,92451178	2,08198656	2,04169800	2,05403967	2,10813644	2,00532500	2,19563800	2,15592922	2,23342178
<b>Desvio Padrão</b>		0,30866558	0,16518263	0,24804522	0,29038647	0,36883967	0,37671528	0,31036681	0,38574453	0,39419515	0,41217434
<b>Melhor Solução</b>		1,69178400	1,67614900	1,80680500	1,67595500	1,68571800	1,78587400	1,66437300	1,85152200	1,67032100	1,70074700

Tabela G.1 (b) – Resultados obtidos nas simulações para o problema WBD.

Simulações	Algoritmo	e11	e12	e13	e14	e15	e16	e17	e18	e19	e20	
55	WBD	GA	1,87023700	2,18872400	1,84146700	1,97631900	1,87599500	1,85379700	3,50378700	1,88273200	1,90195600	1,89580000
56	WBD	SIGA(1,1)	2,51325200	2,38641800	2,38714100	1,69090800	1,73599300	2,07344300	1,84027500	1,76651700	1,92476800	3,06547200
57	WBD	SIGA(0,1)	2,18468400	2,06090000	2,23421300	1,67445900	2,07692600	2,33741600	1,84359800	2,15547300	2,17730100	2,25544800
58	WBD	F-SIGA(1,1)	2,09191800	1,93978800	2,01366200	2,61589700	1,83275400	1,91933500	2,16948900	1,77188100	1,85069500	1,91265800
59	WBD	F-SIGA(0,1)	1,70089500	1,91566100	2,00843200	2,38502600	2,07627200	2,39469900	1,72655500	1,86010100	2,65043400	1,83962900
60	WBD	ESIA(SIGA)(1,1)	2,71833900	1,93590100	1,89372800	1,98195000	1,95009400	1,73088900	2,44712200	2,06552500	1,94718400	1,73050400
61	WBD	ESIA(SIGA)(0,1)	1,79348700	1,89503800	1,81544500	1,86258100	1,94514500	1,89932200	1,71995000	2,88675600	1,68251400	1,83622100
62	WBD	ESIA(F-SIGA)(1,1)	2,06611200	2,06685800	2,25882300	1,68124100	2,37527000	1,68882600	1,87723500	2,40064600	1,72288500	2,05984400
63	WBD	ESIA(F-SIGA)(0,1)	1,86926600	2,19067300	2,29076300	2,62806200	1,90790100	1,72743300	2,44182000	1,88384300	1,99973800	2,81685300
<b>Média</b>			2,08979889	2,06444011	2,08263044	2,05516033	1,97515000	1,95835111	2,17442567	2,07483044	1,98416389	2,15693656
<b>Desvio Padrão</b>			0,33908574	0,16506140	0,21376418	0,39011933	0,18507936	0,26004328	0,57332922	0,36713264	0,28943633	0,47345927
<b>Melhor Solução</b>			1,70089500	1,89503800	1,81544500	1,67445900	1,73599300	1,68882600	1,71995000	1,76651700	1,68251400	1,73050400

Tabela G.1 (c) – Resultados obtidos nas simulações para o problema WBD.

Simulações	Algoritmo	e21	e22	e23	e24	e25	e26	e27	e28	e29	e30	
55	WBD	GA	1,91004800	1,86297700	1,86696500	1,96329800	1,89200800	2,23206700	1,81221400	2,24923900	2,19222400	2,44998100
56	WBD	SIGA(1,1)	2,01438000	1,84388800	2,42927500	2,28455800	2,59840600	2,15592100	2,28079600	1,86317500	1,70089700	1,71411400
57	WBD	SIGA(0,1)	1,90195800	2,28423100	1,84728900	1,78242900	1,97412200	1,75467800	1,72321800	3,50081200	1,83558500	1,97521400
58	WBD	F-SIGA(1,1)	2,09091000	1,86191100	2,06895800	1,81607400	1,70505200	3,67736800	1,97258400	1,67052600	2,07701000	2,27559700
59	WBD	F-SIGA(0,1)	1,76134000	1,70075500	2,01895800	2,39650000	1,79254000	2,27422900	1,82112900	1,84664300	2,01209100	1,93338000
60	WBD	ESIA(SIGA)(1,1)	1,75614800	1,75732900	2,16010500	1,77977100	1,98593100	1,77551100	1,88165200	1,81216600	2,37797500	1,89463800
61	WBD	ESIA(SIGA)(0,1)	2,14443800	2,03631000	2,29472700	1,83695600	2,21010400	1,92130800	2,05308200	1,74426700	2,09283600	1,91777900
62	WBD	ESIA(F-SIGA)(1,1)	2,46333300	1,69009800	1,89153700	1,88481800	1,91029200	2,42020700	1,69976800	2,16125300	1,68142000	2,36770700
63	WBD	ESIA(F-SIGA)(0,1)	1,92155200	1,87761800	1,83098300	1,87605200	2,15421000	2,27807000	1,86929700	2,23326900	1,68828700	2,39388800
<b>Média</b>			1,99601189	1,87945744	2,04542189	1,95782844	2,02474056	2,27659544	1,90152667	2,12015000	1,96203611	2,10247756
<b>Desvio Padrão</b>			0,21913128	0,18472930	0,21350376	0,22594431	0,26718829	0,57544043	0,18036013	0,56086128	0,24917168	0,26900808
<b>Melhor Solução</b>			1,75614800	1,69009800	1,83098300	1,77977100	1,70505200	1,75467800	1,69976800	1,67052600	1,68142000	1,71411400

Tabela G.1 (d) – Resultados obtidos nas simulações para o problema WBD.

Simulações	Algoritmo	e31	e32	e33	e34	e35	e36	e37	e38	e39	e40	
55	WBD	GA	2,44813400	2,11312700	2,86699100	1,71486300	1,84681800	2,31659300	1,69687100	2,28919900	1,97420500	1,77516900
56	WBD	SIGA(1,1)	2,16197500	2,01175400	1,90748400	2,05403400	1,84277100	1,71818300	1,84944700	2,23402700	1,87792200	1,97670500
57	WBD	SIGA(0,1)	2,17984000	2,26067200	1,74755200	2,27869200	2,36856200	1,70346100	1,95786000	2,19061300	2,02246600	1,82696100
58	WBD	F-SIGA(1,1)	1,83538600	2,32780500	1,67083500	2,20866000	2,42360600	1,67294700	2,25311400	1,90673800	2,41846000	1,99395700
59	WBD	F-SIGA(0,1)	1,85100100	1,93334600	2,24242800	2,97516700	1,84796400	2,45523900	2,33487900	2,38668700	2,67736300	1,94423800
60	WBD	ESIA(SIGA)(1,1)	1,72654100	1,78151600	1,75489800	2,09556100	1,69287700	2,28717200	1,74431600	2,01932000	1,98076200	2,44069700
61	WBD	ESIA(SIGA)(0,1)	2,06229400	1,68560000	2,18393100	1,91773800	1,88722700	2,24582100	1,99645000	1,96228100	1,97410000	2,08205700
62	WBD	ESIA(F-SIGA)(1,1)	2,29117100	2,26426000	1,71608000	1,83493900	1,91645400	2,26916800	1,91553700	2,39268100	1,87623800	2,63395100
63	WBD	ESIA(F-SIGA)(0,1)	1,78565800	2,39508300	2,43125100	1,91465800	1,92985500	1,90460900	2,22619600	1,71022900	2,31876900	2,38457000
<b>Média</b>			2,03800000	2,08590700	2,05793889	2,11047911	1,97290378	2,06368811	1,99718556	2,12130833	2,12447611	2,11758944
<b>Desvio Padrão</b>			0,25126885	0,24971761	0,40641187	0,37029689	0,24972868	0,31018836	0,22807731	0,23464943	0,28029570	0,29800791
<b>Melhor Solução</b>			1,72654100	1,68560000	1,67083500	1,71486300	1,69287700	1,67294700	1,69687100	1,71022900	1,87623800	1,77516900

Tabela G.1 (e) – Resultados obtidos nas simulações para o problema WBD.

Simulações	Algoritmo	e41	e42	e43	e44	e45	e46	e47	e48	e49	e50	
55	WBD	GA	1,83480100	1,79716000	1,90828200	1,87038200	1,97752000	1,80307000	2,15604000	2,38368700	2,15761900	2,17295600
56	WBD	SIGA(1,1)	1,96822000	2,12426700	2,40079200	2,27749800	2,32525100	1,92362900	2,06989100	1,85798200	1,69723100	2,29784800
57	WBD	SIGA(0,1)	2,06260400	2,07786000	1,98399000	2,10857800	3,12238500	1,80676300	1,89468000	2,39981500	1,89163700	1,94643000
58	WBD	F-SIGA(1,1)	3,23035100	2,24011000	1,95368100	1,70482600	2,30059100	2,09974600	2,02636500	2,03092500	1,86187100	2,40648700
59	WBD	F-SIGA(0,1)	1,69479400	2,00210700	2,44704000	2,05475400	1,99370600	2,23552200	1,70687800	2,07682200	1,92971700	2,56268900
60	WBD	ESIA(SIGA)(1,1)	1,77340000	1,92347700	2,07297000	2,71060500	1,75535400	2,15149900	1,89897900	2,37500100	2,38975600	2,28556200
61	WBD	ESIA(SIGA)(0,1)	1,69339600	2,28433100	1,67616800	3,99073000	1,72840400	2,39023600	1,89308500	2,12649400	1,96222700	2,16075400
62	WBD	ESIA(F-SIGA)(1,1)	2,54177700	3,43838800	1,89695700	2,27900900	2,16848000	2,25142500	1,79917700	1,82375700	1,91647100	2,18571400
63	WBD	ESIA(F-SIGA)(0,1)	1,83968800	1,67316100	2,36801300	2,14916700	1,90559900	1,71314800	2,37787600	1,77348100	2,33475900	2,01392800
<b>Média</b>			2,07100344	2,17342900	2,07865478	2,34950544	2,14192111	2,04167089	1,98033011	2,09421822	2,01569867	2,22581867
<b>Desvio Padrão</b>			0,50723967	0,51382036	0,26736141	0,67679359	0,42515805	0,23782370	0,20255099	0,24829421	0,22979172	0,18923269
<b>Melhor Solução</b>			1,69339600	1,67316100	1,67616800	1,70482600	1,72840400	1,71314800	1,70687800	1,77348100	1,69723100	1,94643000

## G.2. Projeto de Vaso de Pressão

Tabela G.2 (a) – Resultados obtidos nas simulações para o problema DPV.

Simulações	Algoritmo	e01	e02	e03	e04	e05	e06	e07	e08	e09	e10
28	DPV GA	9.253,82789300	7.220,87703500	8.272,83288400	8.656,70405800	8.837,13236500	9.515,20139400	7.170,39956300	8.714,91283300	9.478,00006200	9.323,53810400
29	DPV SIGA(1,1)	10.201,67471300	8.959,75602700	6.813,52289400	7.419,96849300	8.313,02751900	8.342,23637300	7.362,57773900	8.841,37551200	8.988,83220200	7.698,59146900
30	DPV SIGA(0,1)	8.672,07800200	8.796,55500900	8.967,84363000	9.049,67689500	8.325,42722600	8.341,25002800	9.161,71799500	8.660,65629600	9.173,17160200	7.776,33800800
31	DPV F-SIGA(1,1)	8.714,38838500	7.602,30190000	8.446,56155000	8.281,96560400	9.125,71704500	8.420,18525500	7.586,98139100	8.876,93481100	8.369,20750000	8.374,97441200
32	DPV F-SIGA(0,1)	9.492,47315900	8.950,24299500	9.130,28505200	8.439,38989200	8.269,52365900	9.009,98174300	8.277,18546800	8.425,21145700	8.888,15134500	8.261,85031300
33	DPV ESIA(SIGA)(1,1)	7.565,94982000	8.323,29229100	7.897,00151500	7.219,67262600	8.629,87157300	7.692,27941400	6.871,35244900	8.417,10518500	8.471,31503000	8.408,93822800
34	DPV ESIA(SIGA)(0,1)	8.459,54333600	8.327,57638100	9.395,98237800	8.306,72104200	9.033,83731600	9.097,63002400	8.750,73568000	9.456,57842700	8.473,85279000	9.233,12505800
35	DPV ESIA(F-SIGA)(1,1)	8.911,74051000	9.545,32801800	8.833,94294600	9.237,41719900	8.431,81063700	8.960,07732500	6.828,28305100	8.301,64987400	8.682,90870000	8.333,68147500
36	DPV ESIA(F-SIGA)(0,1)	8.459,40807200	8.434,60212900	9.363,45259600	9.333,95119700	9.064,36095200	8.852,94125900	9.416,65668000	8.904,35926600	8.934,47425400	9.098,76827700
	<b>Média</b>	8.859,00932111	8.462,28130944	8.569,04727167	8.438,38522289	8.670,07869911	8.692,42031278	7.936,21000178	8.733,19818456	8.828,87927611	8.501,08948267
	<b>Desvio Padrão</b>	742,44568065	714,94715186	828,80596676	743,81346180	351,49588574	543,11131855	991,98113119	348,48580955	365,14465680	596,70377990
	<b>Melhor Solução</b>	7.565,94982000	7.220,87703500	6.813,52289400	7.219,67262600	8.269,52365900	7.692,27941400	6.828,28305100	8.301,64987400	8.369,20750000	7.698,59146900

Tabela G.2 (b) – Resultados obtidos nas simulações para o problema DPV.

Simulações	Algoritmo	e11	e12	e13	e14	e15	e16	e17	e18	e19	e20
28	DPV GA	8.425,80518600	9.338,96424500	8.710,52606900	9.239,94890300	8.894,70259100	9.148,19171000	10.204,24679400	7.584,40233500	6.847,86491100	7.453,10381500
29	DPV SIGA(1,1)	7.507,67034800	8.397,43792800	8.964,92909700	9.523,18463000	8.864,15203900	7.834,76004300	8.316,61306200	8.390,22478700	8.694,60688900	9.037,90052900
30	DPV SIGA(0,1)	9.029,80416600	9.241,65147600	8.503,08723200	8.329,77612200	8.447,04124000	8.428,19517500	7.975,17455300	8.638,99704600	7.164,01994600	8.402,63908500
31	DPV F-SIGA(1,1)	7.784,16011200	8.538,27503600	8.655,17785600	9.116,63067600	8.752,58738300	9.373,24127600	8.997,79549900	8.438,96379500	9.518,91420300	8.440,48726900
32	DPV F-SIGA(0,1)	9.286,83079900	8.358,92708700	8.841,94188900	9.390,95761100	9.796,60214000	8.804,67321000	7.976,99364000	8.984,21525000	9.430,88862000	9.525,98101000
33	DPV ESIA(SIGA)(1,1)	9.248,37546800	8.489,64046000	8.662,51138100	7.024,61641500	8.740,86493300	9.187,72364000	8.236,94851200	7.468,20826900	8.871,71104600	8.798,24520900
34	DPV ESIA(SIGA)(0,1)	9.462,63576500	8.486,50400600	8.890,10137900	9.107,82476800	8.862,67150400	9.106,54150200	9.073,25291500	9.535,27787600	9.023,04191000	8.853,73843100
35	DPV ESIA(F-SIGA)(1,1)	8.578,59988900	7.515,30652100	9.187,21296700	8.818,06795400	8.858,97908900	9.427,90686000	8.533,03391200	8.710,73923300	9.116,28451000	7.000,58870500
36	DPV ESIA(F-SIGA)(0,1)	8.360,76386600	8.434,54815200	6.808,79839300	8.929,24673600	8.402,13735800	8.516,27427900	8.714,31513800	8.812,81886100	9.092,38849200	8.580,55120900
	<b>Média</b>	8.631,62728878	8.533,47276789	8.580,47625144	8.831,13931278	8.846,63758633	8.869,72307722	8.669,81933611	8.507,09416133	8.639,96894744	8.454,80391800
	<b>Desvio Padrão</b>	685,45708535	530,31880249	694,10193536	761,75739617	400,42946337	523,82066640	700,01387580	650,58510816	963,27277951	782,73608146
	<b>Melhor Solução</b>	7.507,67034800	7.515,30652100	6.808,79839300	7.024,61641500	8.402,13735800	7.834,76004300	7.975,17455300	7.468,20826900	6.847,86491100	7.000,58870500

Tabela G.2 (c) – Resultados obtidos nas simulações para o problema DPV.

Simulações	Algoritmo	e21	e22	e23	e24	e25	e26	e27	e28	e29	e30
28	DPV GA	7.413,38280500	7.505,22584900	8.862,70789000	8.440,72561400	7.688,07860000	9.287,71384800	8.606,66397600	7.991,53752300	7.453,49162000	9.053,75026700
29	DPV SIGA(1,1)	8.886,98387800	9.101,87754300	8.701,47474100	9.583,91094000	8.734,90246600	9.057,60983200	8.975,63920000	8.588,47793100	9.532,35666400	8.912,31767900
30	DPV SIGA(0,1)	9.900,10558300	8.482,61583400	8.895,47424300	8.723,11680800	8.828,84865900	8.423,83790600	9.258,88348000	8.271,65645400	8.325,69987400	8.433,68806500
31	DPV F-SIGA(1,1)	8.614,88599600	8.741,16217400	9.063,43020000	7.362,76372300	6.823,66228700	7.814,97259700	9.109,93964200	7.887,72013600	8.822,06934900	7.827,17402700
32	DPV F-SIGA(0,1)	8.798,59550400	9.115,02800800	8.728,66608100	8.634,64436100	9.393,43927100	6.826,71964300	9.412,58118500	9.064,52717500	8.704,01839400	8.847,49515500
33	DPV ESIA(SIGA)(1,1)	8.469,09701400	9.373,09027700	8.784,30881300	8.703,62839500	8.477,67136700	6.869,99562800	9.115,55204900	9.026,49528000	8.372,46513300	8.838,43827200
34	DPV ESIA(SIGA)(0,1)	9.259,03948400	8.457,20599200	9.187,52743700	7.696,51695300	9.191,77254400	8.756,45023100	8.533,64262200	8.637,97869100	8.719,68951800	8.289,94886500
35	DPV ESIA(F-SIGA)(1,1)	8.755,38789400	9.436,68005600	7.445,09303000	8.214,55974200	8.730,43000500	8.427,25207700	8.297,47954100	9.033,77498500	7.443,68220300	8.419,42179600
36	DPV ESIA(F-SIGA)(0,1)	8.678,25154200	8.426,77565700	9.060,61870700	8.738,49834500	7.726,70950500	8.428,59587000	7.569,77629100	8.207,82688700	7.311,82830200	6.746,17890700
	<b>Média</b>	8.752,85885556	8.737,74015444	8.747,70012689	8.455,37387567	8.399,50163378	8.210,34973689	8.764,46199844	8.523,33278467	8.298,36678411	8.374,26811478
	<b>Desvio Padrão</b>	660,66266684	604,84697482	515,59917578	646,82654699	826,89959568	879,22895917	578,27872532	457,39715579	755,21992581	720,52557431
	<b>Melhor Solução</b>	7.413,38280500	7.505,22584900	7.445,09303000	7.362,76372300	6.823,66228700	6.826,71964300	7.569,77629100	7.887,72013600	7.311,82830200	6.746,17890700

Tabela G.2 (d) – Resultados obtidos nas simulações para o problema DPV.

Simulações	Algoritmo	e31	e32	e33	e34	e35	e36	e37	e38	e39	e40
28	DPV GA	8.831,61253300	8.588,90158400	9.153,75341600	8.407,33344700	8.370,96942500	8.788,38611900	7.137,55048900	8.459,66340900	9.009,03948600	8.610,87230100
29	DPV SIGA(1,1)	8.612,25969400	8.443,56772900	8.489,33804700	8.345,74087600	8.573,02564100	8.889,14794300	8.301,71079800	9.331,86422700	6.795,38158200	9.253,32483600
30	DPV SIGA(0,1)	8.394,72669300	9.038,28094000	8.921,00537600	8.964,40667800	8.719,57912200	8.844,28641200	8.980,06958500	9.547,13118300	8.297,95896500	8.842,77487200
31	DPV F-SIGA(1,1)	8.714,69644400	9.435,91871300	8.481,98866800	9.260,73628600	9.435,85407300	8.840,62015600	8.863,75189200	8.414,14869000	8.517,49339100	8.447,85138300
32	DPV F-SIGA(0,1)	8.425,96381000	8.883,12490200	8.843,64949700	9.568,95707900	8.441,55719900	8.939,83261000	9.227,35232500	9.308,56025200	7.676,55822900	8.668,39013700
33	DPV ESIA(SIGA)(1,1)	9.093,01834200	8.715,48333700	9.021,41282400	9.049,89848600	8.263,04467300	8.930,03528700	8.817,22358300	9.250,33651900	7.110,98499800	8.336,62101500
34	DPV ESIA(SIGA)(0,1)	8.753,60881300	9.072,95940800	8.498,21057900	8.587,29675600	8.990,66337900	9.221,81145800	8.245,05741000	8.589,51423600	7.551,81587300	8.439,52992300
35	DPV ESIA(F-SIGA)(1,1)	8.574,68976000	7.090,99202500	9.609,09218400	8.869,89109500	8.631,14320900	7.446,56126300	8.723,77752800	7.829,52815900	8.588,01310700	8.419,58512400
36	DPV ESIA(F-SIGA)(0,1)	8.653,18025100	9.053,76037500	8.869,23667100	9.162,06201800	7.605,91999100	8.555,28369100	8.234,16437300	7.623,99579100	8.776,49423800	9.128,92271400
	<b>Média</b>	8.672,63959333	8.702,55433478	8.876,40969578	8.912,92474678	8.559,08407911	8.717,32943767	8.503,40644256	8.706,08249622	8.035,97109656	8.683,09692278
	<b>Desvio Padrão</b>	212,72593032	672,77208646	368,49516836	406,20783648	503,92120638	506,98292032	619,84655172	694,34794703	779,32132928	327,68117360
	<b>Melhor Solução</b>	8.394,72669300	7.090,99202500	8.481,98866800	8.345,74087600	7.605,91999100	7.446,56126300	7.137,55048900	7.623,99579100	6.795,38158200	8.336,62101500

Tabela G.2 (e) – Resultados obtidos nas simulações para o problema DPV.

Simulações	Algoritmo	e41	e42	e43	e44	e45	e46	e47	e48	e49	e50
28	DPV GA	9.207,20517000	8.897,46086200	9.325,22542700	9.112,14117400	7.700,43863100	8.457,30277900	8.427,77007500	7.804,78499300	8.328,96545100	8.981,01929500
29	DPV SIGA(1,1)	8.948,35025400	8.284,07042400	8.721,70798500	7.357,18712000	7.605,30753900	8.475,07438900	7.637,08060300	8.613,52593200	8.281,53514500	8.406,20678200
30	DPV SIGA(0,1)	9.234,90094000	8.824,14881900	9.024,81993800	8.921,47943100	9.395,54148500	9.248,06557700	8.385,54885800	9.218,50241400	7.762,22295300	9.313,27830100
31	DPV F-SIGA(1,1)	8.276,33802400	8.428,80738900	7.587,18285500	8.400,74192600	8.557,72036200	8.673,59008600	8.435,91352400	8.402,14277300	8.825,43799400	9.182,78851600
32	DPV F-SIGA(0,1)	7.476,14563100	9.331,81749100	8.639,90981800	8.921,87776100	7.558,16445800	9.158,11590400	8.611,10089800	8.975,57959000	9.789,72389100	8.890,56784200
33	DPV ESIA(SIGA)(1,1)	9.435,86272300	7.969,82402700	8.529,50157200	9.155,23712900	7.742,42739200	6.066,02936000	8.280,17513400	7.285,85795600	8.970,96259300	8.473,73119400
34	DPV ESIA(SIGA)(0,1)	8.404,48672000	8.666,99106200	8.295,87126700	9.103,52179500	6.839,31443900	8.866,80512500	9.510,83774000	7.778,78732100	8.948,15217800	8.346,23640000
35	DPV ESIA(F-SIGA)(1,1)	9.318,27062000	6.832,93301000	7.352,32647000	8.335,31767700	8.696,57843800	8.938,72159800	8.290,40069100	8.382,32413700	9.208,62931600	6.814,37506800
36	DPV ESIA(F-SIGA)(0,1)	8.714,78513500	8.434,26082000	9.093,69918800	8.420,95594600	8.861,08634300	8.934,29226200	9.088,03529200	7.619,03538700	9.112,71962000	9.019,35165500
	<b>Média</b>	8.779,59391300	8.407,81265600	8.507,80494667	8.636,49555100	8.106,28656522	8.535,33300889	8.518,54031278	8.231,17116700	8.803,14990456	8.603,06167256
	<b>Desvio Padrão</b>	636,06656706	709,09994978	668,02144292	581,53666910	809,15698122	965,26590890	528,69369584	650,19460181	598,30181358	754,99480083
	<b>Melhor Solução</b>	7.476,14563100	6.832,93301000	7.352,32647000	7.357,18712000	6.839,31443900	6.066,02936000	7.637,08060300	7.285,85795600	7.762,22295300	6.814,37506800

### G.3. Minimização do Peso da Tensão / Compressão sobre Mola

Tabela G.3 (a) – Resultados obtidos nas simulações para o problema MWTCS.

Simulações	Algoritmo	e01	e02	e03	e04	e05	e06	e07	e08	e09	e10	
37	MWTCS	GA	0,00284100	0,00291500	0,00284200	0,00284800	0,00295600	0,00285100	0,00291500	0,00284200	0,00304900	0,00287700
38	MWTCS	SIGA(1,1)	0,00296900	0,00289600	0,00288900	0,00291200	0,00287700	0,00292900	0,00296900	0,00292200	0,00285200	0,00289600
39	MWTCS	SIGA(0,1)	0,00290700	0,00286700	0,00289400	0,00285200	0,00287700	0,00284900	0,00291400	0,00288100	0,00289400	0,00288600
40	MWTCS	F-SIGA(1,1)	0,00286200	0,00284000	0,00287800	0,00286000	0,00289300	0,00297000	0,00284500	0,00288800	0,00302900	0,00286300
41	MWTCS	F-SIGA(0,1)	0,00294800	0,00283800	0,00283800	0,00306000	0,00290000	0,00288400	0,00291000	0,00284300	0,00288400	0,00284500
42	MWTCS	ESIA(SIGA)(1,1)	0,00285500	0,00305700	0,00284100	0,00285400	0,00285700	0,00293800	0,00287600	0,00289600	0,00284400	0,00285100
43	MWTCS	ESIA(SIGA)(0,1)	0,00285000	0,00297900	0,00288800	0,00287000	0,00293000	0,00304400	0,00286500	0,00291300	0,00290600	0,00289800
44	MWTCS	ESIA(F-SIGA)(1,1)	0,00291300	0,00295300	0,00286100	0,00284300	0,00292300	0,00283900	0,00288200	0,00285300	0,00285700	0,00288100
45	MWTCS	ESIA(F-SIGA)(0,1)	0,00285900	0,00294800	0,00286100	0,00287900	0,00284000	0,00309900	0,00291500	0,00288300	0,00284600	0,00285600
<b>Média</b>			0,00288933	0,00292144	0,00286578	0,00288644	0,00289478	0,00293367	0,00289900	0,00288011	0,00290678	0,00287256
<b>Desvio Padrão</b>			0,00004662	0,00007127	0,00002229	0,00006838	0,00003687	0,00009104	0,00003648	0,00002899	0,00007823	0,00001955
<b>Melhor Solução</b>			0,00284100	0,00283800	0,00283800	0,00284300	0,00284000	0,00283900	0,00284500	0,00284200	0,00284400	0,00284500

Tabela G.3 (b) – Resultados obtidos nas simulações para o problema MWTCS.

Simulações	Algoritmo	e11	e12	e13	e14	e15	e16	e17	e18	e19	e20
37	MWTCS GA	0,00304900	0,00287700	0,00293900	0,00284100	0,00288100	0,00293900	0,00291300	0,00284100	0,00284500	0,00285400
38	MWTCS SIGA(1,1)	0,00289200	0,00289300	0,00292200	0,00289800	0,00285200	0,00289600	0,00286200	0,00295800	0,00286200	0,00293500
39	MWTCS SIGA(0,1)	0,00287200	0,00293700	0,00287300	0,00286400	0,00295600	0,00286100	0,00284300	0,00287200	0,00291000	0,00287700
40	MWTCS F-SIGA(1,1)	0,00288800	0,00284000	0,00286000	0,00305100	0,00285600	0,00284200	0,00289400	0,00284100	0,00285300	0,00308500
41	MWTCS F-SIGA(0,1)	0,00287400	0,00285400	0,00291700	0,00286600	0,00291200	0,00289500	0,00286600	0,00297600	0,00309700	0,00296300
42	MWTCS ESIA(SIGA)(1,1)	0,00289400	0,00293600	0,00301900	0,00289400	0,00289400	0,00284300	0,00291200	0,00288000	0,00284300	0,00288200
43	MWTCS ESIA(SIGA)(0,1)	0,00288100	0,00286900	0,00284100	0,00285500	0,00291200	0,00299500	0,00284200	0,00285000	0,00299500	0,00288900
44	MWTCS ESIA(F-SIGA)(1,1)	0,00288100	0,00285600	0,00286800	0,00292800	0,00290800	0,00286200	0,00285200	0,00294200	0,00286700	0,00288800
45	MWTCS ESIA(F-SIGA)(0,1)	0,00288100	0,00284400	0,00285300	0,00285000	0,00283800	0,00284900	0,00288200	0,00286700	0,00287800	0,00286300
<b>Média</b>		0,00290133	0,00287844	0,00289911	0,00289411	0,00288989	0,00288689	0,00287400	0,00289189	0,00290556	0,00291511
<b>Desvio Padrão</b>		0,00005587	0,00003676	0,00005645	0,00006497	0,00003716	0,00005150	0,00002763	0,00005250	0,00008599	0,00007243
<b>Melhor Solução</b>		0,00287200	0,00284000	0,00284100	0,00284100	0,00283800	0,00284200	0,00284200	0,00284100	0,00284300	0,00285400

Tabela G.3 (c) – Resultados obtidos nas simulações para o problema MWTCS.

Simulações	Algoritmo	e21	e22	e23	e24	e25	e26	e27	e28	e29	e30
37	MWTCS GA	0,00290300	0,00287100	0,00295000	0,00286800	0,00295900	0,00286300	0,00287100	0,00296500	0,00285900	0,00284300
38	MWTCS SIGA(1,1)	0,00284700	0,00303700	0,00292900	0,00285200	0,00284000	0,00286700	0,00288900	0,00285500	0,00291400	0,00283800
39	MWTCS SIGA(0,1)	0,00287000	0,00287400	0,00289200	0,00287800	0,00287200	0,00290200	0,00286000	0,00286100	0,00292300	0,00287000
40	MWTCS F-SIGA(1,1)	0,00287000	0,00293200	0,00283800	0,00290500	0,00288500	0,00284900	0,00284000	0,00285200	0,00291900	0,00285100
41	MWTCS F-SIGA(0,1)	0,00292500	0,00285500	0,00290800	0,00284400	0,00294500	0,00290600	0,00284400	0,00283800	0,00284400	0,00289400
42	MWTCS ESIA(SIGA)(1,1)	0,00285000	0,00283500	0,00283900	0,00286500	0,00283500	0,00286600	0,00285900	0,00292200	0,00293900	0,00283700
43	MWTCS ESIA(SIGA)(0,1)	0,00297000	0,00285300	0,00284200	0,00284000	0,00284900	0,00287800	0,00287300	0,00288300	0,00296100	0,00287300
44	MWTCS ESIA(F-SIGA)(1,1)	0,00283800	0,00284500	0,00286000	0,00287300	0,00292000	0,00287300	0,00287000	0,00298100	0,00302900	0,00288700
45	MWTCS ESIA(F-SIGA)(0,1)	0,00285200	0,00292500	0,00287300	0,00290400	0,00287800	0,00286300	0,00287100	0,00285600	0,00287600	0,00290600
<b>Média</b>		0,00288056	0,00289189	0,00288122	0,00286989	0,00288700	0,00287411	0,00286411	0,00289033	0,00291822	0,00286656
<b>Desvio Padrão</b>		0,00004386	0,00006406	0,00004116	0,00002341	0,00004514	0,00001872	0,00001524	0,00005285	0,00005632	0,00002566
<b>Melhor Solução</b>		0,00283800	0,00283500	0,00283800	0,00284000	0,00283500	0,00284900	0,00284000	0,00283800	0,00284400	0,00283700

Tabela G.3 (d) – Resultados obtidos nas simulações para o problema MWTCS.

Simulações	Algoritmo	e31	e32	e33	e34	e35	e36	e37	e38	e39	e40	
37	MWTCS	GA	0,00284400	0,00288700	0,00292600	0,00287300	0,00292600	0,00284000	0,00296200	0,00290400	0,00284900	0,00323100
38	MWTCS	SIGA(1,1)	0,00283800	0,00286800	0,00287500	0,00287500	0,00284700	0,00285900	0,00294600	0,00287600	0,00294600	0,00287400
39	MWTCS	SIGA(0,1)	0,00289000	0,00293300	0,00291400	0,00292300	0,00283700	0,00288100	0,00285700	0,00290500	0,00291000	0,00290200
40	MWTCS	F-SIGA(1,1)	0,00284900	0,00293300	0,00285000	0,00287200	0,00286300	0,00287200	0,00283700	0,00287900	0,00287700	0,00285700
41	MWTCS	F-SIGA(0,1)	0,00286500	0,00289400	0,00284400	0,00285700	0,00285100	0,00284000	0,00295400	0,00285200	0,00287000	0,00288200
42	MWTCS	ESIA(SIGA)(1,1)	0,00283800	0,00285900	0,00284200	0,00286900	0,00288800	0,00285900	0,00284200	0,00288700	0,00292700	0,00293100
43	MWTCS	ESIA(SIGA)(0,1)	0,00304100	0,00290900	0,00298300	0,00284800	0,00286300	0,00285200	0,00289100	0,00292000	0,00289100	0,00286200
44	MWTCS	ESIA(F-SIGA)(1,1)	0,00285700	0,00285100	0,00285300	0,00298600	0,00287600	0,00298600	0,00293100	0,00283800	0,00283900	0,00292800
45	MWTCS	ESIA(F-SIGA)(0,1)	0,00284400	0,00283900	0,00288200	0,00300600	0,00284400	0,00285900	0,00284700	0,00287700	0,00284900	0,00285800
<b>Média</b>			0,00287400	0,00288589	0,00288544	0,00290100	0,00286611	0,00287200	0,00289633	0,00288200	0,00288422	0,00292500
<b>Desvio Padrão</b>			0,00006474	0,00003446	0,00004745	0,00005788	0,00002764	0,00004477	0,00005219	0,00002595	0,00003731	0,00011819
<b>Melhor Solução</b>			0,00283800	0,00283900	0,00284200	0,00284800	0,00283700	0,00284000	0,00283700	0,00283800	0,00283900	0,00285700

Tabela G.3 (e) – Resultados obtidos nas simulações para o problema MWTCS.

Simulações	Algoritmo	e41	e42	e43	e44	e45	e46	e47	e48	e49	e50	
37	MWTCS	GA	0,00289600	0,00295100	0,00297900	0,00285000	0,00291000	0,00285000	0,00289700	0,00294600	0,00286700	0,00283900
38	MWTCS	SIGA(1,1)	0,00286100	0,00284000	0,00294600	0,00285900	0,00290900	0,00285900	0,00304300	0,00284300	0,00285000	0,00284300
39	MWTCS	SIGA(0,1)	0,00294900	0,00284100	0,00290100	0,00288100	0,00297100	0,00289800	0,00285300	0,00285400	0,00284900	0,00294200
40	MWTCS	F-SIGA(1,1)	0,00284100	0,00290400	0,00298200	0,00294700	0,00284300	0,00285500	0,00284100	0,00290400	0,00298200	0,00287900
41	MWTCS	F-SIGA(0,1)	0,00286100	0,00284400	0,00290400	0,00310000	0,00288200	0,00285700	0,00287100	0,00284400	0,00287300	0,00291300
42	MWTCS	ESIA(SIGA)(1,1)	0,00304500	0,00285500	0,00283900	0,00285100	0,00287600	0,00293800	0,00287800	0,00283900	0,00289000	0,00285200
43	MWTCS	ESIA(SIGA)(0,1)	0,00285900	0,00293400	0,00285800	0,00284800	0,00285700	0,00285800	0,00284800	0,00285700	0,00285300	0,00287500
44	MWTCS	ESIA(F-SIGA)(1,1)	0,00291500	0,00295100	0,00292900	0,00287900	0,00286800	0,00283700	0,00290700	0,00284200	0,00310100	0,00284400
45	MWTCS	ESIA(F-SIGA)(0,1)	0,00290100	0,00283700	0,00301100	0,00295400	0,00285800	0,00284500	0,00284100	0,00288000	0,00290000	0,00283800
<b>Média</b>			0,00290311	0,00288411	0,00292767	0,00290767	0,00288600	0,00286633	0,00288656	0,00286767	0,00290722	0,00286944
<b>Desvio Padrão</b>			0,00006303	0,00005039	0,00005794	0,00008268	0,00003912	0,00003174	0,00006332	0,00003633	0,00008358	0,00003683
<b>Melhor Solução</b>			0,00284100	0,00283700	0,00283900	0,00284800	0,00284300	0,00283700	0,00284100	0,00283900	0,00284900	0,00283800

## G.4. Projeto de Redutor de Velocidade

Tabela G.4 (a) – Resultados obtidos nas simulações para o problema SRD.

Simulações	Algoritmo	e01	e02	e03	e04	e05	e06	e07	e08	e09	e10	
46	SRD	GA	2.896,74154700	2.896,73963900	2.897,65606600	2.897,28718400	2.897,53973300	2.897,45779000	2.897,08584100	2.899,78935700	2.897,03236500	2.897,09507000
47	SRD	SIGA(1,1)	2.897,27437800	2.896,83108400	2.897,17426700	2.897,50772400	2.897,50021000	2.897,28081200	2.897,24610800	2.896,64357000	2.899,23799100	2.897,71705400
48	SRD	SIGA(0,1)	2.897,31241900	2.897,00633100	2.898,94494200	2.897,21545100	2.896,73696700	2.897,42607700	2.897,15573300	2.897,04850100	2.898,10490400	2.897,20064000
49	SRD	F-SIGA(1,1)	2.897,40950300	2.897,23458800	2.897,41741900	2.896,65454700	2.898,09123400	2.898,05951000	2.897,07119500	2.897,59270200	2.898,10248800	2.897,93315200
50	SRD	F-SIGA(0,1)	2.898,21854100	2.896,85988900	2.897,04276100	2.898,64220300	2.896,70061900	2.898,78751000	2.900,12881500	2.896,86949400	2.897,24512500	2.897,80866400
51	SRD	ESIA(SIGA)(1,1)	2.898,79885900	2.898,43536300	2.897,05864300	2.899,02678600	2.896,82581100	2.896,88498300	2.897,08911700	2.897,27007200	2.897,52859200	2.897,62851400
52	SRD	ESIA(SIGA)(0,1)	2.897,20558800	2.897,36805100	2.897,27660400	2.898,30219300	2.898,14748600	2.898,17070500	2.896,82743900	2.897,77898000	2.897,76716200	2.897,03819900
53	SRD	ESIA(F-SIGA)(1,1)	2.896,90541700	2.897,71623100	2.897,32261600	2.896,91219500	2.897,04208300	2.897,18265300	2.897,14145300	2.897,22976900	2.897,25994900	2.898,22251200
54	SRD	ESIA(F-SIGA)(0,1)	2.897,03896600	2.897,50731700	2.896,58578600	2.897,57361300	2.896,94455500	2.896,95746300	2.898,53591300	2.897,53509500	2.897,06249300	2.897,03539300
<b>Média</b>			2.897,43391311	2.897,29983256	2.897,38656711	2.897,68021067	2.897,28096644	2.897,57861144	2.897,58684600	2.897,52861556	2.897,70456322	2.897,51991089
<b>Desvio Padrão</b>			0,66014401	0,53944566	0,65482383	0,80459436	0,56264559	0,63181800	1,07261395	0,92074658	0,70513935	0,43984124
<b>Melhor Solução</b>			2.896,74154700	2.896,73963900	2.896,58578600	2.896,65454700	2.896,70061900	2.896,88498300	2.896,82743900	2.896,64357000	2.897,03236500	2.897,03539300

Tabela G.4 (b) – Resultados obtidos nas simulações para o problema SRD.

Simulações	Algoritmo	e11	e12	e13	e14	e15	e16	e17	e18	e19	e20	
46	SRD	GA	2.896,82832300	2.896,91127100	2.897,15672600	2.897,05555600	2.897,11800500	2.897,51833100	2.899,07842700	2.897,25362600	2.898,35383200	2.897,10625100
47	SRD	SIGA(1,1)	2.897,56361700	2.898,08770200	2.896,65306600	2.897,59941400	2.898,21690600	2.897,41128500	2.896,86811300	2.897,06279300	2.897,88632400	2.896,68151000
48	SRD	SIGA(0,1)	2.897,63075900	2.897,61088100	2.896,88372200	2.896,65557300	2.896,95707600	2.897,71067900	2.897,11374900	2.898,31460600	2.898,46713300	2.897,82683800
49	SRD	F-SIGA(1,1)	2.896,54161200	2.897,17683500	2.896,99008900	2.897,01065800	2.897,25680200	2.897,75126900	2.896,79011900	2.897,06194400	2.899,07200500	2.897,22129700
50	SRD	F-SIGA(0,1)	2.899,14061400	2.936,84925500	2.897,33513300	2.896,67510200	2.898,94437300	2.897,00021900	2.897,28693300	2.896,76993900	2.896,94706800	2.897,13455800
51	SRD	ESIA(SIGA)(1,1)	2.898,44559200	2.897,67822000	2.897,57627400	2.896,83026600	2.897,31525900	2.897,47696900	2.898,11211600	2.896,84641500	2.899,04329400	2.896,75825600
52	SRD	ESIA(SIGA)(0,1)	2.897,13477900	2.898,11590800	2.896,96074500	2.897,74676700	2.897,08446800	2.896,79839000	2.896,86815400	2.843,57889100	2.897,22430500	2.896,98559400
53	SRD	ESIA(F-SIGA)(1,1)	2.897,10541200	2.897,09971600	2.897,45714900	2.896,95859600	2.897,74343700	2.897,38753800	2.898,31933000	2.898,94358100	2.897,01868700	2.897,28022700
54	SRD	ESIA(F-SIGA)(0,1)	2.898,43330600	2.897,31268600	2.897,87681000	2.897,71947000	2.896,84558000	2.896,94598100	2.896,81823500	2.896,69933600	2.897,00769500	2.896,58093000
<b>Média</b>			2.897,64711267	2.901,87138600	2.897,20996822	2.897,13904467	2.897,49798956	2.897,33340678	2.897,47279733	2.891,39234789	2.897,89114922	2.897,06394011
<b>Desvio Padrão</b>			0,86182423	13,12344216	0,38495015	0,43567578	0,68868410	0,34060630	0,82859761	17,94626613	0,87645352	0,37740296
<b>Melhor Solução</b>			2.896,54161200	2.896,91127100	2.896,65306600	2.896,65557300	2.896,84558000	2.896,79839000	2.896,79011900	2.843,57889100	2.896,94706800	2.896,58093000

Tabela G.4 (c) – Resultados obtidos nas simulações para o problema SRD.

Simulações	Algoritmo	e21	e22	e23	e24	e25	e26	e27	e28	e29	e30	
46	SRD	GA	2.896,96132800	2.917,30805100	2.897,05027100	2.897,35240200	2.897,47737600	2.896,50818400	2.896,78765300	2.897,16139200	2.897,32494600	2.897,01965100
47	SRD	SIGA(1,1)	2.898,67159600	2.896,39639500	2.897,01454900	2.896,90295300	2.897,09716000	2.896,82316600	2.896,92140000	2.897,88341100	2.896,86435500	2.897,30486300
48	SRD	SIGA(0,1)	2.896,53140200	2.896,86544000	2.897,16964700	2.897,26722000	2.896,80879100	2.897,29309100	2.897,15914600	2.896,93860700	2.898,13472800	2.897,01090000
49	SRD	F-SIGA(1,1)	2.897,64354800	2.898,24166500	2.897,42142900	2.896,90342600	2.897,26838100	2.897,16351000	2.896,78398700	2.897,20404900	2.896,77810500	2.897,04164800
50	SRD	F-SIGA(0,1)	2.897,24225800	2.897,09260700	2.899,66566000	2.896,87156700	2.932,14882500	2.898,28835500	2.897,11737700	2.897,65517600	2.899,11882400	2.897,21527200
51	SRD	ESIA(SIGA)(1,1)	2.898,35504000	2.897,76172100	2.843,36672500	2.896,78082100	2.896,91534800	2.897,11591800	2.898,12448600	2.899,25972000	2.897,17924900	2.896,98213600
52	SRD	ESIA(SIGA)(0,1)	2.898,52354100	2.896,87176200	2.897,49014600	2.896,71378000	2.896,68731100	2.897,46911100	2.896,98131200	2.897,08819300	2.897,76150000	2.896,98151300
53	SRD	ESIA(F-SIGA)(1,1)	2.896,73450000	2.897,01289000	2.897,54875000	2.897,11403400	2.897,93874800	2.896,91112000	2.896,57406500	2.897,83578500	2.897,71262100	2.897,53708300
54	SRD	ESIA(F-SIGA)(0,1)	2.897,89414500	2.897,00149200	2.897,10473300	2.897,13743200	2.897,58172000	2.896,91861100	2.896,98639800	2.897,26983000	2.897,07666300	2.898,11542800
<b>Média</b>			2.897,61748422	2.899,39466922	2.891,53687889	2.897,00484833	2.901,10262889	2.897,16567400	2.897,04842489	2.897,58846256	2.897,55011011	2.897,24538822
<b>Desvio Padrão</b>			0,79717242	6,73921875	18,08239531	0,22149336	11,64917555	0,50579699	0,44192117	0,71151131	0,73759557	0,37631158
<b>Melhor Solução</b>			2.896,53140200	2.896,39639500	2.843,36672500	2.896,71378000	2.896,68731100	2.896,50818400	2.896,57406500	2.896,93860700	2.896,77810500	2.896,98151300

Tabela G.4 (d) – Resultados obtidos nas simulações para o problema SRD.

Simulações	Algoritmo	e31	e32	e33	e34	e35	e36	e37	e38	e39	e40	
46	SRD	GA	2.896,86063300	2.912,20005800	2.897,07376800	2.896,79996600	2.897,88625800	2.896,59051200	2.897,61333600	2.897,52066300	2.897,31773300	2.896,97717100
47	SRD	SIGA(1,1)	2.897,76957900	2.897,40974300	2.897,25917700	2.897,47497200	2.896,35329000	2.896,97494000	2.896,96650800	2.899,67571000	2.898,04888100	2.896,62004100
48	SRD	SIGA(0,1)	2.897,36795700	2.896,79643300	2.897,06762700	2.897,42252800	2.897,05899500	2.896,92370600	2.897,42641600	2.897,35382100	2.897,50314200	2.896,80156100
49	SRD	F-SIGA(1,1)	2.896,94442200	2.897,92576100	2.897,37551900	2.897,27627300	2.898,01112500	2.896,68542900	2.896,86889400	2.896,66331400	2.916,89034300	2.898,29677100
50	SRD	F-SIGA(0,1)	2.897,01950300	2.896,87084900	2.897,90004700	2.898,49653500	2.897,30442400	2.896,90468500	2.896,99925400	2.898,42595900	2.896,90913700	2.897,48870000
51	SRD	ESIA(SIGA)(1,1)	2.897,41488100	2.897,15759000	2.898,39096100	2.898,86990700	2.896,91321100	2.897,83856400	2.925,54551000	2.898,46634900	2.896,87315500	2.898,24087500
52	SRD	ESIA(SIGA)(0,1)	2.896,96760800	2.898,36562500	2.896,94046400	2.897,45389700	2.896,89414700	2.896,97660500	2.897,58247200	2.897,19870900	2.897,39929500	2.897,77528500
53	SRD	ESIA(F-SIGA)(1,1)	2.896,97918700	2.897,60596000	2.898,21808000	2.897,88031400	2.897,82821200	2.898,56022700	2.897,17501700	2.897,86885800	2.896,97503100	2.896,66186500
54	SRD	ESIA(F-SIGA)(0,1)	2.897,06487900	2.897,39717400	2.896,82376200	2.896,56914500	2.896,69358600	2.896,71345600	2.896,59293700	2.896,85388200	2.897,97637600	2.896,98890600
<b>Média</b>			2.897,15429433	2.899,08102144	2.897,44993389	2.897,58261522	2.897,21591644	2.897,12979156	2.900,30781600	2.897,78080722	2.899,54367700	2.897,31679722
<b>Desvio Padrão</b>			0,29876703	4,94423470	0,57656506	0,73894221	0,58107636	0,64717744	9,47023791	0,94745777	6,51905940	0,65733956
<b>Melhor Solução</b>			2.896,86063300	2.896,79643300	2.896,82376200	2.896,56914500	2.896,35329000	2.896,59051200	2.896,59293700	2.896,66331400	2.896,87315500	2.896,62004100

Tabela G.4 (e) – Resultados obtidos nas simulações para o problema SRD.

Simulações	Algoritmo	e41	e42	e43	e44	e45	e46	e47	e48	e49	e50	
46	SRD	GA	2.896,76964100	2.896,91812800	2.897,60880400	2.896,49951200	2.897,69620300	2.896,88798800	2.898,25958400	2.897,40805300	2.897,05511600	2.896,96337000
47	SRD	SIGA(1,1)	2.897,75306900	2.896,73726700	2.896,57156200	2.896,91316800	2.897,24297000	2.896,91362000	2.897,15159400	2.897,61575600	2.897,09808000	2.896,41812100
48	SRD	SIGA(0,1)	2.898,23990200	2.897,77888300	2.897,62352600	2.897,39883500	2.897,92866200	2.897,34320800	2.896,90229600	2.897,03639200	2.898,04666800	2.897,94983100
49	SRD	F-SIGA(1,1)	2.896,90631100	2.896,90332200	2.897,46265800	2.896,93369200	2.897,01830600	2.898,33223200	2.897,40757100	2.897,02340400	2.898,27246000	2.896,81252000
50	SRD	F-SIGA(0,1)	2.897,71974300	2.897,01419600	2.897,02120700	2.897,42946800	2.897,74761500	2.897,44448700	2.896,53804200	2.898,34761200	2.898,26542600	2.896,72981900
51	SRD	ESIA(SIGA)(1,1)	2.897,82988400	2.896,87522400	2.897,09581900	2.897,28739000	2.898,99107800	2.897,94754600	2.897,40796600	2.897,48735300	2.897,20507700	2.897,25423500
52	SRD	ESIA(SIGA)(0,1)	2.897,25210500	2.896,83692500	2.896,82758100	2.897,44510800	2.897,27641800	2.897,27632700	2.897,26183000	2.897,92528200	2.896,95348900	2.897,02796500
53	SRD	ESIA(F-SIGA)(1,1)	2.898,00024700	2.897,28425300	2.896,93823500	2.897,28463400	2.898,32060600	2.896,66298400	2.897,77929700	2.797,42464600	2.897,56251400	2.897,13339100
54	SRD	ESIA(F-SIGA)(0,1)	2.897,94110800	2.897,23222800	2.898,20442600	2.896,60860400	2.896,81121000	2.897,17920800	2.899,12114900	2.897,58317100	2.897,31631300	2.897,40504900
<b>Média</b>			2.897,60133444	2.897,06449178	2.897,26153533	2.897,08893456	2.897,67034089	2.897,33195556	2.897,53659211	2.886,42796322	2.897,53057144	2.897,07714456
<b>Desvio Padrão</b>			0,50847289	0,32237361	0,50438678	0,36222821	0,68388940	0,52895600	0,77045329	33,37876722	0,53100965	0,43931255
<b>Melhor Solução</b>			2.896,76964100	2.896,73726700	2.896,57156200	2.896,49951200	2.896,81121000	2.896,66298400	2.896,53804200	2.797,42464600	2.896,95348900	2.896,41812100

## ANEXO H – RESULTADOS DAS SIMULAÇÕES PARA O PROBLEMA DO CAIXEIRO VIAJANTE

### H.1. Instância:: br26

Tabela H.1 (a) – Resultados obtidos nas simulações para o problema br26.

Simulações	Algoritmo	e01	e02	e03	e04	e05	e06	e07	e08	e09	e10	
64	br26	GA	20.227,00	21.391,00	20.242,00	20.021,00	19.171,00	22.471,00	20.875,00	19.761,00	19.257,00	21.349,00
65	br26	SIGA(1,1)	22.358,00	20.001,00	21.911,00	21.179,00	20.734,00	18.479,00	21.948,00	22.833,00	21.627,00	19.834,00
66	br26	SIGA(0,1)	28.456,00	25.369,00	24.058,00	26.475,00	26.110,00	28.449,00	25.708,00	28.877,00	26.353,00	26.670,00
67	br26	F-SIGA(1,1)	29.115,00	28.551,00	28.165,00	27.842,00	31.766,00	28.924,00	27.157,00	28.034,00	27.894,00	28.767,00
68	br26	F-SIGA(0,1)	26.997,00	23.770,00	29.735,00	27.467,00	27.723,00	24.305,00	26.250,00	27.667,00	24.879,00	25.766,00
69	br26	ESIA(SIGA)(1,1)	21.140,00	21.065,00	19.767,00	19.475,00	19.463,00	19.141,00	18.567,00	20.970,00	20.559,00	19.165,00
70	br26	ESIA(SIGA)(0,1)	20.712,00	19.599,00	17.097,00	21.148,00	18.302,00	20.775,00	18.182,00	18.290,00	20.536,00	20.602,00
71	br26	ESIA(F-SIGA)(1,1)	27.148,00	32.271,00	28.314,00	25.864,00	25.839,00	29.635,00	27.000,00	27.641,00	30.764,00	23.460,00
72	br26	ESIA(F-SIGA)(0,1)	26.607,00	24.736,00	26.884,00	29.819,00	32.319,00	26.092,00	30.949,00	26.682,00	25.555,00	27.410,00
73	br26	NpSIGA(1,1)	21.689,00	26.930,00	23.230,00	22.304,00	23.017,00	24.114,00	20.583,00	25.620,00	21.563,00	24.710,00
74	br26	NpSIGA(0,1)	22.609,00	20.409,00	22.006,00	25.142,00	22.343,00	23.439,00	22.308,00	20.563,00	20.409,00	28.212,00
<b>Média</b>			24.278,00	24.008,36	23.764,45	24.248,73	24.253,36	24.165,82	23.593,36	24.267,09	23.581,45	24.176,82
<b>Desvio Padrão</b>			3.377,21	4.047,85	4.064,28	3.551,65	4.911,77	3.835,59	4.065,68	3.856,47	3.721,78	3.494,28
<b>Melhor Solução</b>			20.227,00	19.599,00	17.097,00	19.475,00	18.302,00	18.479,00	18.182,00	18.290,00	19.257,00	19.165,00

Tabela H.1 (b) – Resultados obtidos nas simulações para o problema br26.

Simulações		Algoritmo	e11	e12	e13	e14	e15	e16	e17	e18	e19	e20
64	br26	GA	19.649,00	21.162,00	17.866,00	21.608,00	19.778,00	22.518,00	19.240,00	20.307,00	18.718,00	21.215,00
65	br26	SIGA(1,1)	21.047,00	19.869,00	21.842,00	20.175,00	21.396,00	23.359,00	21.033,00	20.754,00	20.878,00	21.475,00
66	br26	SIGA(0,1)	25.404,00	23.953,00	26.212,00	25.605,00	29.406,00	26.348,00	26.362,00	22.245,00	27.508,00	25.706,00
67	br26	F-SIGA(1,1)	24.963,00	26.839,00	29.482,00	25.044,00	27.270,00	29.669,00	27.442,00	29.695,00	24.024,00	27.267,00
68	br26	F-SIGA(0,1)	24.047,00	26.093,00	24.736,00	26.451,00	26.803,00	29.141,00	27.050,00	25.391,00	26.967,00	29.176,00
69	br26	ESIA(SIGA)(1,1)	19.977,00	20.817,00	20.038,00	19.407,00	20.802,00	21.153,00	20.122,00	20.350,00	20.163,00	20.578,00
70	br26	ESIA(SIGA)(0,1)	18.970,00	19.523,00	21.067,00	19.978,00	19.905,00	18.800,00	19.367,00	18.810,00	19.381,00	22.225,00
71	br26	ESIA(F-SIGA)(1,1)	24.625,00	31.581,00	26.395,00	31.548,00	26.092,00	28.155,00	32.522,00	26.075,00	24.110,00	26.674,00
72	br26	ESIA(F-SIGA)(0,1)	27.434,00	28.457,00	28.076,00	27.165,00	31.553,00	27.391,00	27.649,00	24.280,00	24.295,00	29.910,00
73	br26	NpSIGA(1,1)	27.479,00	22.737,00	26.151,00	21.696,00	21.941,00	22.770,00	23.760,00	23.447,00	22.966,00	21.456,00
74	br26	NpSIGA(0,1)	30.369,00	25.949,00	26.020,00	26.390,00	26.582,00	21.849,00	24.766,00	22.422,00	23.402,00	21.842,00
<b>Média</b>			23.996,73	24.270,91	24.353,18	24.097,00	24.684,36	24.650,27	24.483,00	23.070,55	22.946,55	24.320,36
<b>Desvio Padrão</b>			3.699,84	3.868,59	3.629,80	3.810,57	4.081,12	3.634,34	4.227,42	3.155,29	2.900,56	3.484,90
<b>Melhor Solução</b>			18.970,00	19.523,00	17.866,00	19.407,00	19.778,00	18.800,00	19.240,00	18.810,00	18.718,00	20.578,00

Tabela H.1 (c) – Resultados obtidos nas simulações para o problema br26.

Simulações		Algoritmo	e21	e22	e23	e24	e25	e26	e27	e28	e29	e30
64	<i>br26</i>	GA	21.029,00	22.766,00	21.493,00	19.446,00	22.685,00	19.170,00	20.219,00	20.807,00	20.680,00	18.687,00
65	<i>br26</i>	SIGA(1,1)	21.418,00	18.699,00	20.645,00	21.720,00	22.422,00	21.061,00	21.781,00	23.317,00	21.253,00	19.697,00
66	<i>br26</i>	SIGA(0,1)	25.845,00	26.560,00	26.099,00	26.402,00	25.464,00	26.324,00	26.433,00	25.315,00	27.383,00	24.987,00
67	<i>br26</i>	F-SIGA(1,1)	24.941,00	29.333,00	29.114,00	29.794,00	26.431,00	24.167,00	29.626,00	28.251,00	32.225,00	29.519,00
68	<i>br26</i>	F-SIGA(0,1)	27.873,00	25.298,00	24.602,00	28.686,00	27.460,00	28.802,00	27.961,00	28.083,00	28.578,00	25.742,00
69	<i>br26</i>	ESIA(SIGA)(1,1)	21.923,00	21.287,00	20.013,00	19.332,00	19.402,00	20.250,00	20.224,00	21.048,00	19.307,00	20.628,00
70	<i>br26</i>	ESIA(SIGA)(0,1)	18.230,00	19.291,00	17.538,00	17.334,00	19.787,00	21.235,00	20.942,00	20.990,00	18.942,00	19.388,00
71	<i>br26</i>	ESIA(F-SIGA)(1,1)	24.529,00	24.458,00	31.419,00	27.610,00	28.755,00	29.080,00	30.335,00	25.739,00	25.401,00	24.739,00
72	<i>br26</i>	ESIA(F-SIGA)(0,1)	28.392,00	23.270,00	26.746,00	27.684,00	27.157,00	29.150,00	27.212,00	27.969,00	26.522,00	30.285,00
73	<i>br26</i>	NpSIGA(1,1)	26.304,00	23.087,00	24.900,00	21.571,00	26.016,00	22.330,00	21.508,00	22.399,00	21.834,00	24.968,00
74	<i>br26</i>	NpSIGA(0,1)	26.958,00	25.042,00	22.462,00	23.717,00	27.010,00	30.268,00	25.528,00	25.658,00	24.185,00	20.409,00
<b>Média</b>			24.312,91	23.553,73	24.093,73	23.936,00	24.780,82	24.712,45	24.706,27	24.506,91	24.210,00	23.549,91
<b>Desvio Padrão</b>			3.239,45	3.103,37	4.144,60	4.312,78	3.195,77	4.135,03	3.867,78	2.935,47	4.228,40	4.068,22
<b>Melhor Solução</b>			18.230,00	18.699,00	17.538,00	17.334,00	19.402,00	19.170,00	20.219,00	20.807,00	18.942,00	18.687,00

Tabela H.1 (d) – Resultados obtidos nas simulações para o problema br26.

Simulações		Algoritmo	e31	e32	e33	e34	e35	e36	e37	e38	e39	e40
64	<i>br26</i>	GA	18.633,00	18.695,00	18.150,00	21.811,00	20.472,00	21.319,00	20.618,00	18.720,00	21.795,00	20.224,00
65	<i>br26</i>	SIGA(1,1)	23.485,00	22.460,00	22.072,00	21.815,00	22.459,00	21.807,00	21.669,00	21.788,00	20.964,00	19.059,00
66	<i>br26</i>	SIGA(0,1)	27.806,00	29.322,00	27.407,00	24.853,00	25.729,00	26.628,00	29.947,00	23.682,00	26.129,00	29.773,00
67	<i>br26</i>	F-SIGA(1,1)	30.757,00	30.644,00	31.640,00	32.681,00	18.164,00	28.821,00	24.140,00	27.825,00	27.500,00	28.742,00
68	<i>br26</i>	F-SIGA(0,1)	27.461,00	25.662,00	26.685,00	24.795,00	24.311,00	27.590,00	22.638,00	27.872,00	25.474,00	23.057,00
69	<i>br26</i>	ESIA(SIGA)(1,1)	19.254,00	19.010,00	21.568,00	20.383,00	18.708,00	21.091,00	18.984,00	20.011,00	21.458,00	20.699,00
70	<i>br26</i>	ESIA(SIGA)(0,1)	18.855,00	20.824,00	19.693,00	18.696,00	19.886,00	22.224,00	21.185,00	21.458,00	19.282,00	20.674,00
71	<i>br26</i>	ESIA(F-SIGA)(1,1)	29.557,00	26.180,00	29.910,00	28.502,00	25.231,00	31.366,00	20.958,00	26.325,00	26.153,00	25.235,00
72	<i>br26</i>	ESIA(F-SIGA)(0,1)	30.728,00	27.074,00	24.950,00	23.469,00	30.087,00	28.208,00	29.581,00	26.380,00	31.902,00	29.928,00
73	<i>br26</i>	NpSIGA(1,1)	25.042,00	24.677,00	25.561,00	24.353,00	24.274,00	26.986,00	26.432,00	24.514,00	24.032,00	25.930,00
74	<i>br26</i>	NpSIGA(0,1)	21.630,00	22.069,00	23.955,00	25.216,00	23.157,00	21.574,00	22.101,00	22.580,00	24.452,00	21.713,00
<b>Média</b>			24.837,09	24.237,91	24.690,09	24.234,00	22.952,55	25.237,64	23.477,55	23.741,36	24.467,36	24.094,00
<b>Desvio Padrão</b>			4.746,87	3.981,16	4.154,78	3.860,72	3.523,93	3.695,51	3.662,20	3.122,25	3.558,59	4.035,57
<b>Melhor Solução</b>			18.633,00	18.695,00	18.150,00	18.696,00	18.164,00	21.091,00	18.984,00	18.720,00	19.282,00	19.059,00

Tabela H.1 (e) – Resultados obtidos nas simulações para o problema br26.

Simulações		Algoritmo	e41	e42	e43	e44	e45	e46	e47	e48	e49	e50
64	<i>br26</i>	GA	21.719,00	19.386,00	20.033,00	18.970,00	20.783,00	20.752,00	22.962,00	20.408,00	20.358,00	18.229,00
65	<i>br26</i>	SIGA(1,1)	20.839,00	20.800,00	20.471,00	21.725,00	21.855,00	20.561,00	20.721,00	23.061,00	24.017,00	21.470,00
66	<i>br26</i>	SIGA(0,1)	26.380,00	25.591,00	26.907,00	25.819,00	25.403,00	24.606,00	26.268,00	26.257,00	25.244,00	27.397,00
67	<i>br26</i>	F-SIGA(1,1)	25.552,00	29.710,00	29.174,00	28.646,00	27.048,00	34.010,00	27.614,00	29.165,00	26.963,00	27.167,00
68	<i>br26</i>	F-SIGA(0,1)	23.257,00	26.627,00	23.765,00	24.734,00	28.213,00	30.001,00	25.986,00	27.489,00	18.880,00	23.787,00
69	<i>br26</i>	ESIA(SIGA)(1,1)	18.077,00	19.306,00	20.438,00	20.824,00	17.159,00	20.193,00	20.166,00	20.590,00	23.979,00	20.323,00
70	<i>br26</i>	ESIA(SIGA)(0,1)	20.352,00	19.702,00	21.532,00	19.720,00	20.526,00	22.040,00	19.330,00	19.916,00	21.274,00	20.786,00
71	<i>br26</i>	ESIA(F-SIGA)(1,1)	25.770,00	25.429,00	27.832,00	28.639,00	21.966,00	29.768,00	28.192,00	26.275,00	29.183,00	27.949,00
72	<i>br26</i>	ESIA(F-SIGA)(0,1)	26.864,00	27.768,00	23.299,00	32.396,00	31.129,00	26.619,00	27.807,00	22.948,00	27.319,00	28.298,00
73	<i>br26</i>	NpSIGA(1,1)	24.630,00	25.432,00	24.976,00	24.237,00	25.977,00	26.075,00	25.102,00	22.578,00	25.226,00	21.456,00
74	<i>br26</i>	NpSIGA(0,1)	22.776,00	23.071,00	24.606,00	25.947,00	23.072,00	26.111,00	21.029,00	26.773,00	25.568,00	25.866,00
<b>Média</b>			23.292,36	23.892,91	23.912,09	24.696,09	23.921,00	25.521,45	24.107,00	24.132,73	24.364,64	23.884,36
<b>Desvio Padrão</b>			2.827,23	3.648,28	3.140,96	4.181,45	4.030,97	4.480,16	3.353,63	3.191,17	3.124,35	3.592,28
<b>Melhor Solução</b>			18.077,00	19.306,00	20.033,00	18.970,00	17.159,00	20.193,00	19.330,00	19.916,00	18.880,00	18.229,00

## H.2. Instância: kroa100

Tabela H.2 (a) – Resultados obtidos nas simulações para o problema kroa100.

Simulações	Algoritmo	e01	e02	e03	e04	e05	e06	e07	e08	e09	e10	
75	<i>kroa100</i>	GA	50.652,09	50.415,98	53.727,44	51.742,00	51.127,69	60.767,78	54.441,38	52.418,10	58.021,53	57.337,51
76	<i>kroa100</i>	SIGA(1,1)	65.458,86	68.159,84	63.496,51	72.074,12	67.120,30	62.163,22	67.919,00	60.930,20	68.328,93	63.070,76
77	<i>kroa100</i>	SIGA(0,1)	103.386,36	103.036,03	90.968,56	99.653,29	103.187,32	96.943,70	106.011,56	99.346,92	100.254,97	95.050,46
78	<i>kroa100</i>	F-SIGA(1,1)	93.436,04	96.298,94	105.213,86	87.495,15	103.985,51	96.924,03	90.715,29	98.298,79	117.002,34	88.814,20
79	<i>kroa100</i>	F-SIGA(0,1)	103.076,01	93.644,36	101.660,91	97.181,06	98.606,03	99.346,77	108.441,38	105.301,54	91.658,30	99.327,15
80	<i>kroa100</i>	ESIA(SIGA)(1,1)	55.557,02	45.506,02	52.853,65	57.993,67	55.445,54	55.456,85	64.829,06	50.887,55	59.118,47	54.129,83
81	<i>kroa100</i>	ESIA(SIGA)(0,1)	49.951,47	53.025,30	58.225,32	47.367,79	56.742,11	56.876,20	53.513,81	54.479,37	64.425,63	50.942,15
82	<i>kroa100</i>	ESIA(F-SIGA)(1,1)	105.083,71	101.143,06	93.648,37	102.930,69	96.332,52	107.403,25	97.548,42	104.106,24	101.262,69	97.882,34
83	<i>kroa100</i>	ESIA(F-SIGA)(0,1)	103.542,32	99.000,96	95.968,03	112.462,16	103.813,91	102.927,38	96.302,00	97.267,15	101.915,13	103.446,04
84	<i>kroa100</i>	NpSIGA(1,1)	78.360,24	75.280,33	75.494,63	64.883,06	75.357,58	74.490,53	69.211,13	69.004,00	70.168,18	80.414,00
85	<i>kroa100</i>	NpSIGA(0,1)	74.200,02	74.691,79	72.025,37	74.475,33	65.428,24	75.276,04	71.460,84	71.696,79	69.244,90	72.447,61
<b>Média</b>			80.245,83	78.200,24	78.480,24	78.932,57	79.740,61	80.779,61	80.035,81	78.521,51	81.945,55	78.442,00
<b>Desvio Padrão</b>			22.477,03	21.767,50	19.745,02	22.302,94	21.609,00	20.237,35	20.234,14	22.400,11	20.775,69	19.727,04
<b>Melhor Solução</b>			49.951,47	45.506,02	52.853,65	47.367,79	51.127,69	55.456,85	53.513,81	50.887,55	58.021,53	50.942,15

Tabela H.2 (b) – Resultados obtidos nas simulações para o problema kroa100.

Simulações	Algoritmo	e11	e12	e13	e14	e15	e16	e17	e18	e19	e20
75	<i>kroa100</i> GA	60.378,11	57.133,52	48.671,16	55.764,92	51.451,79	50.564,97	51.987,42	47.928,46	60.983,27	53.769,51
76	<i>kroa100</i> SIGA(1,1)	67.022,18	66.313,16	64.549,81	69.571,59	68.544,49	70.977,39	76.248,71	75.234,55	68.840,97	61.280,31
77	<i>kroa100</i> SIGA(0,1)	98.713,70	95.612,94	96.897,19	93.757,36	94.184,19	105.635,84	98.225,74	102.708,88	92.126,14	94.441,56
78	<i>kroa100</i> F-SIGA(1,1)	105.767,78	73.477,29	100.566,55	105.569,62	94.723,30	88.655,53	94.315,19	92.137,63	100.143,05	98.157,62
79	<i>kroa100</i> F-SIGA(0,1)	100.821,87	97.948,60	98.316,11	97.916,45	102.417,06	97.279,82	96.960,98	99.729,94	93.820,94	87.448,99
80	<i>kroa100</i> ESIA(SIGA)(1,1)	56.955,13	54.344,99	58.829,16	58.089,88	56.423,80	55.735,23	55.442,82	49.981,28	55.638,52	59.096,80
81	<i>kroa100</i> ESIA(SIGA)(0,1)	56.129,60	57.057,98	52.662,06	52.296,05	52.828,35	55.813,50	62.186,32	58.456,61	53.826,05	52.484,65
82	<i>kroa100</i> ESIA(F-SIGA)(1,1)	104.687,74	107.393,81	106.902,66	102.779,00	97.235,03	104.026,31	101.838,56	102.565,24	105.083,49	92.134,95
83	<i>kroa100</i> ESIA(F-SIGA)(0,1)	99.672,94	91.212,63	97.688,23	96.073,51	107.985,65	97.565,51	100.393,11	100.038,53	104.622,50	94.644,20
84	<i>kroa100</i> NpSIGA(1,1)	72.810,51	66.824,62	69.533,11	75.857,19	65.353,48	65.274,61	74.950,50	73.130,02	64.837,23	75.345,11
85	<i>kroa100</i> NpSIGA(0,1)	73.710,63	69.835,83	76.446,17	69.075,18	82.524,89	63.908,61	74.088,02	72.438,68	77.076,06	64.588,71
<b>Média</b>		81.515,47	76.105,03	79.187,47	79.704,61	79.424,73	77.767,03	80.603,40	79.486,35	79.727,11	75.762,95
<b>Desvio Padrão</b>		20.407,17	18.679,80	21.473,94	20.051,23	21.114,82	21.116,42	18.690,06	21.168,42	19.953,97	18.026,80
<b>Melhor Solução</b>		56.129,60	54.344,99	48.671,16	52.296,05	51.451,79	50.564,97	51.987,42	47.928,46	53.826,05	52.484,65

Tabela H.2 (c) – Resultados obtidos nas simulações para o problema kroa100.

Simulações	Algoritmo	e21	e22	e23	e24	e25	e26	e27	e28	e29	e30
75	<i>kroa100</i> GA	54.061,05	57.381,04	55.210,27	60.162,85	53.683,93	53.796,41	60.486,68	53.464,54	54.185,51	51.764,42
76	<i>kroa100</i> SIGA(1,1)	65.733,01	63.302,21	67.823,41	65.905,36	72.805,98	73.295,15	66.400,75	64.076,49	70.966,18	70.805,44
77	<i>kroa100</i> SIGA(0,1)	100.963,34	95.892,37	98.019,33	99.532,78	103.093,25	100.570,84	101.743,71	101.809,52	98.342,73	101.738,43
78	<i>kroa100</i> F-SIGA(1,1)	91.539,68	105.846,80	97.723,40	87.515,42	107.477,85	101.248,19	96.053,66	87.949,89	97.747,16	93.349,19
79	<i>kroa100</i> F-SIGA(0,1)	100.038,72	91.180,22	101.859,92	98.137,74	95.777,80	96.130,26	92.125,06	97.965,92	93.401,89	98.619,47
80	<i>kroa100</i> ESIA(SIGA)(1,1)	51.666,54	58.496,28	51.295,19	52.150,79	53.508,02	57.471,60	55.151,08	59.422,04	57.381,82	59.267,61
81	<i>kroa100</i> ESIA(SIGA)(0,1)	51.406,85	54.546,07	53.705,60	56.944,49	53.719,73	62.462,97	51.669,76	53.494,77	53.885,40	55.565,62
82	<i>kroa100</i> ESIA(F-SIGA)(1,1)	94.799,19	98.228,63	94.871,58	109.330,96	99.791,23	95.439,81	101.712,02	93.326,85	97.487,48	102.464,88
83	<i>kroa100</i> ESIA(F-SIGA)(0,1)	107.788,06	102.839,73	105.901,13	107.236,54	111.455,38	101.652,72	108.597,87	103.805,42	96.319,82	97.890,64
84	<i>kroa100</i> NpSIGA(1,1)	74.627,87	72.606,43	75.802,90	81.098,14	78.108,88	75.234,62	75.178,84	71.823,69	72.374,23	67.967,85
85	<i>kroa100</i> NpSIGA(0,1)	73.111,19	78.100,13	72.740,11	79.236,27	71.326,57	81.190,54	74.436,20	73.881,53	76.553,03	77.735,37
<b>Média</b>		78.703,23	79.856,36	79.541,17	81.568,31	81.886,24	81.681,19	80.323,24	78.274,60	78.967,75	79.742,63
<b>Desvio Padrão</b>		21.260,09	19.642,69	20.868,33	20.598,94	22.571,75	18.389,54	20.507,58	19.393,66	18.447,33	19.697,77
<b>Melhor Solução</b>		51.406,85	54.546,07	51.295,19	52.150,79	53.508,02	53.796,41	51.669,76	53.464,54	53.885,40	51.764,42

Tabela H.2 (d) – Resultados obtidos nas simulações para o problema kroa100.

Simulações	Algoritmo	e31	e32	e33	e34	e35	e36	e37	e38	e39	e40
75	<i>kroa100</i> GA	56.956,62	53.200,67	59.474,23	58.160,64	60.746,56	63.552,88	61.350,40	55.169,08	54.388,34	54.828,86
76	<i>kroa100</i> SIGA(1,1)	72.943,67	71.301,50	63.074,86	69.214,43	62.940,63	66.672,92	70.659,01	74.240,02	69.370,65	58.620,98
77	<i>kroa100</i> SIGA(0,1)	92.176,50	98.860,84	95.116,50	99.927,27	105.959,99	105.634,34	98.957,15	101.684,33	99.463,26	96.244,42
78	<i>kroa100</i> F-SIGA(1,1)	87.963,44	99.486,07	89.693,97	95.149,92	100.710,48	103.643,95	96.942,05	107.970,09	97.674,14	92.508,95
79	<i>kroa100</i> F-SIGA(0,1)	95.643,55	101.135,24	90.647,94	102.966,46	101.054,24	91.212,13	98.326,98	86.662,48	98.885,87	99.497,72
80	<i>kroa100</i> ESIA(SIGA)(1,1)	49.400,23	55.961,21	57.601,26	59.218,21	61.303,49	64.541,54	49.262,31	61.570,49	56.454,99	54.805,36
81	<i>kroa100</i> ESIA(SIGA)(0,1)	52.949,26	55.819,95	57.768,52	52.361,42	56.145,93	53.532,59	51.234,04	47.215,38	55.060,78	47.667,85
82	<i>kroa100</i> ESIA(F-SIGA)(1,1)	110.703,99	111.231,27	106.210,53	103.871,33	95.310,65	97.351,43	116.793,44	106.553,59	89.592,33	86.678,58
83	<i>kroa100</i> ESIA(F-SIGA)(0,1)	97.760,93	104.119,61	98.006,98	89.847,03	90.152,94	96.934,15	108.912,14	94.858,08	97.353,93	88.162,44
84	<i>kroa100</i> NpSIGA(1,1)	67.550,44	71.722,97	76.188,08	78.803,57	74.425,51	76.917,87	74.160,35	77.959,51	71.895,94	77.230,44
85	<i>kroa100</i> NpSIGA(0,1)	66.287,50	77.277,36	70.378,14	72.243,48	82.661,14	68.697,39	67.096,38	65.892,26	64.052,54	64.344,81
<b>Média</b>		77.303,28	81.828,79	78.560,09	80.160,34	81.037,41	80.790,11	81.244,93	79.979,57	77.653,89	74.599,13
<b>Desvio Padrão</b>		20.558,44	21.759,65	17.986,43	19.160,51	18.682,17	18.567,97	23.585,71	21.190,09	19.093,89	19.011,64
<b>Melhor Solução</b>		49.400,23	53.200,67	57.601,26	52.361,42	56.145,93	53.532,59	49.262,31	47.215,38	54.388,34	47.667,85

Tabela H.2 (e) – Resultados obtidos nas simulações para o problema kroa100.

Simulações	Algoritmo	e41	e42	e43	e44	e45	e46	e47	e48	e49	e50
75	<i>kroa100</i> GA	54.344,87	57.495,98	52.830,98	63.463,80	56.803,61	49.661,07	52.895,32	51.630,50	57.223,41	60.310,92
76	<i>kroa100</i> SIGA(1,1)	67.673,86	66.583,20	61.219,66	62.656,98	66.083,79	65.807,38	65.104,19	63.719,02	60.292,22	65.713,25
77	<i>kroa100</i> SIGA(0,1)	99.086,43	93.847,60	102.337,68	103.379,18	98.190,08	106.434,27	105.908,10	100.290,61	101.571,03	99.995,35
78	<i>kroa100</i> F-SIGA(1,1)	94.022,83	104.030,96	96.517,98	100.913,86	98.101,37	96.474,71	92.107,35	96.081,66	105.860,42	108.603,73
79	<i>kroa100</i> F-SIGA(0,1)	99.304,16	100.609,69	93.321,99	105.829,60	95.693,13	103.339,17	95.638,80	96.015,12	100.676,30	105.004,42
80	<i>kroa100</i> ESIA(SIGA)(1,1)	53.690,45	60.214,06	52.184,01	54.399,35	57.594,74	53.859,35	54.039,83	58.032,27	54.469,29	51.515,33
81	<i>kroa100</i> ESIA(SIGA)(0,1)	52.455,58	54.661,91	53.643,84	51.867,19	57.799,36	54.705,59	57.290,84	49.019,08	59.957,24	56.888,80
82	<i>kroa100</i> ESIA(F-SIGA)(1,1)	103.252,67	109.266,84	102.010,10	101.382,59	110.241,94	104.099,76	99.405,05	104.070,74	113.834,96	84.244,16
83	<i>kroa100</i> ESIA(F-SIGA)(0,1)	104.905,06	102.179,68	94.862,67	108.746,51	102.430,23	97.070,84	91.038,85	101.786,63	102.730,64	88.213,62
84	<i>kroa100</i> NpSIGA(1,1)	69.984,93	71.070,45	77.034,30	62.267,35	69.090,91	74.100,79	67.617,83	73.126,00	72.178,86	75.168,45
85	<i>kroa100</i> NpSIGA(0,1)	70.055,27	65.772,95	76.554,31	73.480,64	68.397,30	74.033,65	78.196,66	65.569,75	75.056,80	75.611,15
<b>Média</b>		78.979,65	80.521,21	78.410,68	80.762,46	80.038,77	79.962,42	78.112,98	78.121,94	82.168,29	79.206,29
<b>Desvio Padrão</b>		21.314,98	21.311,01	20.510,36	23.035,51	20.742,99	22.141,63	19.556,04	21.702,20	22.842,19	19.752,56
<b>Melhor Solução</b>		52.455,58	54.661,91	52.184,01	51.867,19	56.803,61	49.661,07	52.895,32	49.019,08	54.469,29	51.515,33

### H.3. Instância: att532

Tabela H.3 (a) – Resultados obtidos nas simulações para o problema att532.

Simulações	Algoritmo	e01	e02	e03	e04	e05	e06	e07	e08	e09	e10	
86	att532	GA	1.236.342,84	1.228.969,95	1.216.882,85	1.192.775,17	1.277.841,82	1.250.124,90	1.265.461,56	1.283.354,01	1.300.519,11	1.271.068,21
87	att532	SIGA(1,1)	1.221.339,52	1.232.281,28	1.256.023,45	1.241.656,66	1.247.909,12	1.266.946,55	1.296.170,16	1.315.056,40	1.257.340,19	1.228.573,16
88	att532	SIGA(0,1)	1.222.560,29	1.210.863,49	1.232.845,72	1.282.778,16	1.244.630,97	1.229.157,13	1.223.883,45	1.250.575,14	1.236.538,48	1.308.118,32
89	att532	F-SIGA(1,1)	1.186.905,07	1.207.333,12	1.241.720,17	1.294.685,13	1.238.452,63	1.249.616,56	1.234.688,41	1.242.661,39	1.216.145,53	1.246.748,23
90	att532	F-SIGA(0,1)	1.293.507,80	1.275.847,87	1.291.989,56	1.288.660,17	1.305.741,48	1.275.747,41	1.283.336,17	1.298.996,78	1.280.444,63	1.275.832,56
91	att532	ESIA(SIGA)(1,1)	1.244.877,60	1.221.664,22	1.280.873,96	1.222.340,33	1.271.636,08	1.285.389,22	1.257.155,42	1.229.808,72	1.226.490,60	1.241.423,90
92	att532	ESIA(SIGA)(0,1)	1.201.966,25	1.217.865,34	1.234.148,64	1.280.819,93	1.243.404,81	1.222.663,00	1.207.301,63	1.196.250,78	1.237.029,61	1.226.058,16
93	att532	ESIA(F-SIGA)(1,1)	1.262.759,28	1.261.985,31	1.306.904,46	1.273.271,76	1.244.491,71	1.314.892,10	1.244.779,95	1.306.286,39	1.251.551,51	1.279.027,41
94	att532	ESIA(F-SIGA)(0,1)	1.291.300,38	1.279.734,15	1.162.166,54	1.202.598,20	1.231.612,28	1.263.873,43	1.229.456,03	1.224.408,18	1.229.940,79	1.251.213,21
95	att532	NpSIGA(1,1)	972.353,54	981.886,05	979.288,44	958.439,73	948.820,06	995.761,24	986.470,54	973.743,80	1.045.810,30	953.990,97
96	att532	NpSIGA(0,1)	1.040.561,30	989.537,59	995.655,74	978.694,03	1.057.597,00	1.008.272,57	983.089,37	983.720,44	1.008.436,82	1.001.977,84
<b>Média</b>			1.197.679,44	1.191.633,49	1.199.863,59	1.201.519,94	1.210.194,36	1.214.767,65	1.201.072,06	1.209.532,91	1.208.204,32	1.207.639,27
<b>Desvio Padrão</b>			101.329,69	104.829,57	112.134,64	120.488,31	107.344,20	108.260,27	110.035,41	120.053,45	93.175,38	116.553,43
<b>Melhor Solução</b>			972.353,54	981.886,05	979.288,44	958.439,73	948.820,06	995.761,24	983.089,37	973.743,80	1.008.436,82	953.990,97

Tabela H.3 (b) – Resultados obtidos nas simulações para o problema att532.

Simulações	Algoritmo	e11	e12	e13	e14	e15	e16	e17	e18	e19	e20	
86	att532	GA	1.157.339,84	1.292.593,60	1.289.192,78	1.210.181,32	1.261.934,31	1.347.228,38	1.235.274,15	1.267.032,19	1.292.317,56	1.244.687,34
87	att532	SIGA(1,1)	1.209.938,88	1.217.650,93	1.267.631,70	1.222.492,98	1.211.973,73	1.247.555,63	1.220.785,45	1.246.327,12	1.298.138,53	1.275.175,03
88	att532	SIGA(0,1)	1.267.218,42	1.235.864,94	1.274.908,47	1.220.502,77	1.188.191,93	1.221.435,59	1.258.327,35	1.257.985,21	1.246.524,47	1.235.590,14
89	att532	F-SIGA(1,1)	1.238.450,50	1.231.032,66	1.320.433,47	1.189.638,40	1.263.069,46	1.309.434,12	1.307.580,98	1.219.560,44	1.289.597,25	1.200.808,41
90	att532	F-SIGA(0,1)	1.296.147,02	1.262.621,24	1.261.610,96	1.238.285,84	1.297.531,81	1.288.124,82	1.330.657,22	1.279.719,03	1.289.088,13	1.270.276,74
91	att532	ESIA(SIGA)(1,1)	1.208.186,47	1.289.226,73	1.250.910,87	1.212.279,17	1.277.500,46	1.229.861,10	1.249.995,41	1.269.573,86	1.262.605,44	1.243.064,13
92	att532	ESIA(SIGA)(0,1)	1.216.826,18	1.248.202,54	1.264.525,98	1.282.545,53	1.263.938,24	1.233.285,54	1.229.899,05	1.307.987,09	1.269.306,79	1.234.117,56
93	att532	ESIA(F-SIGA)(1,1)	1.236.304,28	1.244.199,82	1.243.895,79	1.277.248,07	1.238.452,15	1.250.833,89	1.262.904,98	1.338.965,53	1.284.077,71	1.265.046,52
94	att532	ESIA(F-SIGA)(0,1)	1.270.070,92	1.222.409,01	1.185.919,02	1.222.412,49	1.261.216,55	1.269.433,52	1.175.334,98	1.281.137,40	1.258.858,05	1.279.141,16
95	att532	NpSIGA(1,1)	992.393,07	996.324,71	988.997,08	1.045.111,98	1.010.974,25	955.849,81	998.740,90	979.333,15	968.089,49	898.484,36
96	att532	NpSIGA(0,1)	902.461,82	969.448,25	920.288,72	1.001.699,12	1.000.586,80	972.060,77	1.022.704,46	985.122,88	948.806,43	996.644,78
<b>Média</b>			1.181.394,31	1.200.870,40	1.206.210,44	1.192.945,24	1.206.851,79	1.211.373,01	1.208.382,27	1.221.158,54	1.218.855,44	1.194.821,47
<b>Desvio Padrão</b>			123.109,49	110.646,26	129.482,74	88.771,24	103.879,38	127.940,04	106.230,08	122.097,29	129.810,90	126.228,89
<b>Melhor Solução</b>			902.461,82	969.448,25	920.288,72	1.001.699,12	1.000.586,80	955.849,81	998.740,90	979.333,15	948.806,43	898.484,36

Tabela H.3 (c) – Resultados obtidos nas simulações para o problema att532.

Simulações	Algoritmo	e21	e22	e23	e24	e25	e26	e27	e28	e29	e30	
86	att532	GA	1.281.458,95	1.236.467,84	1.239.366,23	1.316.671,33	1.285.366,03	1.309.504,43	1.301.741,45	1.225.161,07	1.248.802,19	1.197.546,81
87	att532	SIGA(1,1)	1.280.782,07	1.354.658,08	1.233.615,59	1.230.353,96	1.184.716,22	1.248.203,39	1.320.422,82	1.225.720,22	1.250.291,76	1.268.171,35
88	att532	SIGA(0,1)	1.281.723,84	1.231.441,84	1.280.252,20	1.308.853,09	1.246.716,75	1.241.173,79	1.220.673,51	1.232.880,90	1.258.288,68	1.290.201,59
89	att532	F-SIGA(1,1)	1.331.688,17	1.325.765,62	1.219.246,27	1.199.135,84	1.220.198,23	1.308.348,21	1.221.826,19	1.261.568,52	1.221.258,58	1.174.405,41
90	att532	F-SIGA(0,1)	1.276.994,56	1.260.436,90	1.260.538,13	1.321.502,27	1.245.731,48	1.256.706,27	1.307.841,47	1.282.612,50	1.294.369,99	1.309.615,86
91	att532	ESIA(SIGA)(1,1)	1.230.661,73	1.276.693,69	1.273.499,68	1.258.426,15	1.295.471,23	1.276.376,99	1.305.826,30	1.287.358,61	1.288.906,05	1.321.835,04
92	att532	ESIA(SIGA)(0,1)	1.295.538,43	1.335.832,12	1.295.389,91	1.239.124,69	1.240.990,17	1.205.939,78	1.297.992,15	1.231.282,97	1.213.684,39	1.194.508,95
93	att532	ESIA(F-SIGA)(1,1)	1.229.534,89	1.250.103,79	1.289.905,92	1.304.944,23	1.180.867,66	1.297.249,78	1.258.814,01	1.272.992,97	1.243.789,92	1.301.938,97
94	att532	ESIA(F-SIGA)(0,1)	1.248.341,85	1.219.448,34	1.241.176,63	1.212.734,57	1.264.482,97	1.305.730,11	1.249.613,02	1.244.997,60	1.265.625,09	1.312.261,64
95	att532	NpSIGA(1,1)	989.902,28	1.015.082,81	1.063.694,05	957.775,00	1.043.936,68	1.078.085,31	991.696,52	958.927,76	988.390,70	1.004.723,31
96	att532	NpSIGA(0,1)	1.027.247,94	990.091,49	969.041,83	1.042.917,69	989.245,28	1.037.161,08	1.001.457,94	1.110.532,47	993.236,44	1.035.366,74
<b>Média</b>			1.224.897,70	1.226.911,14	1.215.066,04	1.217.494,44	1.199.792,97	1.233.134,47	1.225.264,12	1.212.185,05	1.206.058,53	1.219.143,24
<b>Desvio Padrão</b>			111.154,16	119.673,63	103.372,91	117.152,51	98.129,83	93.152,02	118.278,06	96.664,99	109.136,51	111.595,05
<b>Melhor Solução</b>			989.902,28	990.091,49	969.041,83	957.775,00	989.245,28	1.037.161,08	991.696,52	958.927,76	988.390,70	1.004.723,31

Tabela H.3 (d) – Resultados obtidos nas simulações para o problema att532.

Simulações	Algoritmo	e31	e32	e33	e34	e35	e36	e37	e38	e39	e40	
86	att532	GA	1.300.377,00	1.324.206,77	1.279.883,21	1.275.509,50	1.325.173,42	1.218.316,05	1.231.325,14	1.217.719,90	1.194.130,14	1.248.413,45
87	att532	SIGA(1,1)	1.220.036,71	1.214.153,87	1.241.935,58	1.202.668,55	1.280.131,65	1.342.140,31	1.255.241,74	1.171.518,37	1.245.058,72	1.328.050,58
88	att532	SIGA(0,1)	1.271.012,97	1.275.241,23	1.249.167,08	1.276.608,67	1.211.737,43	1.298.836,15	1.272.038,29	1.226.097,33	1.219.323,71	1.178.867,00
89	att532	F-SIGA(1,1)	1.282.263,58	1.244.053,76	1.272.464,09	1.257.697,39	1.276.557,54	1.208.905,57	1.199.377,37	1.280.401,33	1.204.610,68	1.229.620,96
90	att532	F-SIGA(0,1)	1.297.016,88	1.280.869,94	1.309.266,20	1.299.620,67	1.267.230,47	1.272.624,99	1.268.869,91	1.293.391,65	1.280.279,01	1.259.986,45
91	att532	ESIA(SIGA)(1,1)	1.285.923,61	1.254.197,06	1.176.750,67	1.257.654,65	1.265.996,82	1.286.732,12	1.218.019,81	1.259.682,30	1.270.423,06	1.225.432,96
92	att532	ESIA(SIGA)(0,1)	1.263.534,34	1.258.349,54	1.268.839,84	1.216.831,23	1.193.104,88	1.246.678,34	1.230.545,89	1.270.994,75	1.266.776,74	1.275.049,85
93	att532	ESIA(F-SIGA)(1,1)	1.207.452,44	1.252.745,62	1.199.521,77	1.264.138,88	1.277.578,42	1.226.191,96	1.223.897,45	1.233.868,60	1.258.455,84	1.264.002,77
94	att532	ESIA(F-SIGA)(0,1)	1.243.499,82	1.284.991,35	1.201.617,76	1.285.111,59	1.299.750,64	1.223.747,74	1.271.304,06	1.231.943,21	1.237.217,56	1.188.078,86
95	att532	NpSIGA(1,1)	1.046.317,20	1.016.370,30	1.011.291,49	991.191,09	1.031.897,17	1.018.838,20	947.555,49	965.895,71	986.817,75	987.555,22
96	att532	NpSIGA(0,1)	946.406,99	1.056.678,58	1.028.858,66	972.005,21	942.690,53	992.258,17	998.623,01	979.396,92	987.163,72	1.009.333,82
<b>Média</b>			1.214.894,69	1.223.805,27	1.203.599,67	1.209.003,40	1.215.622,63	1.212.297,24	1.192.436,20	1.193.719,10	1.195.477,90	1.199.490,18
<b>Desvio Padrão</b>			114.260,28	97.028,08	98.887,56	115.968,62	120.317,06	109.966,25	111.593,28	114.367,35	106.604,84	107.547,43
<b>Melhor Solução</b>			946.406,99	1.016.370,30	1.011.291,49	972.005,21	942.690,53	992.258,17	947.555,49	965.895,71	986.817,75	987.555,22

Tabela H.3 (e) – Resultados obtidos nas simulações para o problema att532.

Simulações	Algoritmo	e41	e42	e43	e44	e45	e46	e47	e48	e49	e50	
86	att532	GA	1.330.395,75	1.265.892,88	1.318.317,18	1.280.907,22	1.192.017,58	1.272.579,52	1.251.475,57	1.205.408,87	1.336.916,98	1.288.973,38
87	att532	SIGA(1,1)	1.251.308,46	1.335.544,07	1.263.742,58	1.209.696,44	1.319.231,36	1.243.964,28	1.234.574,57	1.270.628,48	1.240.599,42	1.251.524,73
88	att532	SIGA(0,1)	1.327.863,31	1.195.064,44	1.172.176,46	1.226.035,19	1.236.260,69	1.278.711,45	1.293.771,58	1.211.713,55	1.249.053,41	1.272.029,30
89	att532	F-SIGA(1,1)	1.291.030,86	1.284.684,35	1.178.435,05	1.269.486,59	1.262.989,72	1.252.233,83	1.190.794,41	1.293.427,39	1.274.985,17	1.257.704,24
90	att532	F-SIGA(0,1)	1.280.842,67	1.254.195,10	1.284.060,93	1.274.907,02	1.318.508,22	1.277.565,55	1.313.295,71	1.289.725,55	1.259.793,81	1.278.052,43
91	att532	ESIA(SIGA)(1,1)	1.247.645,22	1.216.293,58	1.228.150,86	1.271.028,63	1.203.360,14	1.312.291,00	1.257.737,62	1.234.513,58	1.252.423,62	1.258.977,45
92	att532	ESIA(SIGA)(0,1)	1.251.284,10	1.225.790,29	1.229.912,00	1.238.028,68	1.247.512,25	1.237.042,01	1.237.232,57	1.262.632,31	1.223.526,54	1.186.232,53
93	att532	ESIA(F-SIGA)(1,1)	1.255.882,19	1.237.139,44	1.264.767,30	1.255.068,26	1.191.333,80	1.247.672,59	1.229.755,53	1.360.969,67	1.287.315,36	1.289.472,78
94	att532	ESIA(F-SIGA)(0,1)	1.254.847,64	1.262.393,78	1.286.738,57	1.226.698,25	1.290.453,22	1.210.262,13	1.242.397,77	1.259.921,83	1.247.308,14	1.196.951,63
95	att532	NpSIGA(1,1)	1.041.544,29	995.033,74	999.796,02	1.035.839,96	1.036.680,98	1.048.837,30	972.767,62	973.311,94	976.403,84	1.031.218,69
96	att532	NpSIGA(0,1)	988.881,48	976.566,26	1.078.265,68	960.880,65	989.121,24	988.598,47	940.888,64	940.736,39	984.333,01	978.432,23
<b>Média</b>			1.229.229,63	1.204.417,99	1.209.487,51	1.204.416,08	1.207.951,75	1.215.432,56	1.196.790,14	1.209.362,69	1.212.059,94	1.208.142,67
<b>Desvio Padrão</b>			110.507,54	114.354,28	96.790,41	105.785,58	107.041,86	101.696,24	123.134,76	131.981,40	118.351,29	106.636,71
<b>Melhor Solução</b>			988.881,48	976.566,26	999.796,02	960.880,65	989.121,24	988.598,47	940.888,64	940.736,39	976.403,84	978.432,23

## H.4. Instância: pcb1173

Tabela H.4 (a) – Resultados obtidos nas simulações para o problema pcb1173.

Simulações	Algoritmo	e01	e02	e03	e04	e05	e06	e07	e08	e09	e10	
97	<i>pcb1173</i>	GA	1.208.901,93	1.205.948,20	1.204.756,26	1.208.299,82	1.166.921,87	1.179.391,31	1.248.616,24	1.201.264,99	1.231.068,22	1.207.017,83
98	<i>pcb1173</i>	SIGA(1,1)	1.180.323,47	1.208.469,88	1.202.901,60	1.244.858,24	1.253.790,44	1.177.301,85	1.191.511,08	1.227.491,46	1.224.158,97	1.223.121,09
99	<i>pcb1173</i>	SIGA(0,1)	1.166.819,04	1.211.238,57	1.214.082,07	1.175.214,57	1.232.506,04	1.229.327,77	1.215.207,40	1.219.687,51	1.200.071,73	1.219.235,41
100	<i>pcb1173</i>	F-SIGA(1,1)	1.208.140,45	1.174.488,12	1.172.260,24	1.183.926,63	1.205.588,83	1.216.985,59	1.197.702,64	1.140.954,01	1.206.455,23	1.186.745,36
101	<i>pcb1173</i>	F-SIGA(0,1)	1.233.172,47	1.229.047,57	1.199.349,83	1.230.139,71	1.233.172,47	1.228.917,38	1.229.488,48	1.238.466,93	1.237.333,29	1.244.838,93
102	<i>pcb1173</i>	ESIA(SIGA)(1,1)	1.206.960,72	1.219.399,27	1.223.388,71	1.228.244,49	1.214.816,86	1.222.630,46	1.181.535,84	1.190.960,16	1.230.952,79	1.246.171,92
103	<i>pcb1173</i>	ESIA(SIGA)(0,1)	1.160.263,23	1.215.449,92	1.195.541,30	1.187.107,20	1.199.209,92	1.212.684,54	1.227.623,72	1.187.524,99	1.187.209,91	1.201.041,14
104	<i>pcb1173</i>	ESIA(F-SIGA)(1,1)	1.226.264,28	1.181.691,16	1.209.227,59	1.237.821,55	1.178.479,61	1.190.968,75	1.196.465,72	1.214.499,31	1.235.562,40	1.213.045,84
105	<i>pcb1173</i>	ESIA(F-SIGA)(0,1)	1.206.422,36	1.191.790,31	1.201.869,16	1.220.751,99	1.190.788,76	1.237.809,49	1.195.243,94	1.236.216,45	1.185.128,51	1.198.031,90
106	<i>pcb1173</i>	NpSIGA(1,1)	1.062.901,90	1.062.587,98	1.051.372,98	1.052.893,39	1.075.200,66	1.077.479,95	1.061.553,35	1.015.005,19	1.044.863,81	1.036.494,76
107	<i>pcb1173</i>	NpSIGA(0,1)	1.072.549,71	1.034.685,89	1.046.429,99	1.013.444,71	1.047.671,94	1.057.560,87	1.078.502,20	1.029.901,85	1.055.068,95	1.031.035,96
<b>Média</b>			1.175.701,78	1.175.890,62	1.174.652,70	1.180.245,66	1.181.649,76	1.184.641,63	1.183.950,05	1.172.906,62	1.185.261,26	1.182.434,56
<b>Desvio Padrão</b>			57.997,94	65.240,04	63.451,73	76.705,91	64.821,81	61.493,35	59.813,38	79.342,43	69.479,90	75.720,45
<b>Melhor Solução</b>			1.062.901,90	1.034.685,89	1.046.429,99	1.013.444,71	1.047.671,94	1.057.560,87	1.061.553,35	1.015.005,19	1.044.863,81	1.031.035,96

Tabela H.4 (b) – Resultados obtidos nas simulações para o problema pcb1173.

Simulações	Algoritmo	e11	e12	e13	e14	e15	e16	e17	e18	e19	e20
97	<i>pcb1173</i> GA	1.197.599,46	1.223.937,84	1.249.735,83	1.201.468,13	1.191.402,09	1.209.364,50	1.163.386,03	1.220.432,85	1.239.591,40	1.200.416,53
98	<i>pcb1173</i> SIGA(1,1)	1.192.721,12	1.242.025,12	1.206.243,63	1.227.370,21	1.194.665,72	1.168.232,84	1.199.049,84	1.208.554,59	1.171.050,82	1.229.850,04
99	<i>pcb1173</i> SIGA(0,1)	1.225.587,48	1.211.910,88	1.210.541,41	1.234.643,66	1.195.231,37	1.200.478,48	1.217.549,08	1.165.206,84	1.197.378,22	1.229.098,06
100	<i>pcb1173</i> F-SIGA(1,1)	1.243.010,22	1.187.163,96	1.198.978,12	1.159.986,39	1.201.415,61	1.195.249,38	1.194.891,16	1.226.221,09	1.137.019,10	1.194.407,38
101	<i>pcb1173</i> F-SIGA(0,1)	1.220.845,32	1.226.769,82	1.244.258,33	1.246.579,66	1.230.540,31	1.235.213,74	1.231.759,10	1.221.114,50	1.235.858,60	1.225.663,54
102	<i>pcb1173</i> ESIA(SIGA)(1,1)	1.229.211,01	1.191.843,92	1.188.537,97	1.217.801,65	1.220.290,98	1.223.287,50	1.232.716,99	1.213.875,89	1.214.865,73	1.184.327,01
103	<i>pcb1173</i> ESIA(SIGA)(0,1)	1.191.619,83	1.211.038,29	1.212.168,27	1.184.104,33	1.189.053,78	1.207.738,76	1.201.235,54	1.244.218,65	1.172.324,20	1.218.894,80
104	<i>pcb1173</i> ESIA(F-SIGA)(1,1)	1.179.809,82	1.184.280,67	1.208.736,86	1.214.964,22	1.184.983,62	1.228.515,93	1.179.300,23	1.201.654,75	1.193.067,14	1.198.717,44
105	<i>pcb1173</i> ESIA(F-SIGA)(0,1)	1.188.379,22	1.218.156,37	1.185.038,23	1.200.628,01	1.216.421,69	1.203.643,79	1.183.938,60	1.210.690,11	1.235.397,17	1.210.970,21
106	<i>pcb1173</i> NpSIGA(1,1)	1.033.568,96	1.057.938,33	1.024.129,26	1.049.899,29	1.037.510,56	1.015.750,49	1.053.097,83	1.025.801,73	984.707,21	1.055.845,48
107	<i>pcb1173</i> NpSIGA(0,1)	1.028.130,89	1.030.085,71	1.052.124,01	1.043.870,88	1.081.239,28	1.045.094,87	1.036.235,61	1.049.635,72	1.037.304,24	1.076.536,03
<b>Média</b>		1.175.498,48	1.180.468,27	1.180.044,72	1.180.119,68	1.176.614,09	1.175.688,21	1.172.105,45	1.180.673,34	1.165.323,98	1.184.066,05
<b>Desvio Padrão</b>		74.228,55	69.988,22	73.198,85	70.053,65	60.479,38	74.316,94	66.545,05	73.447,39	83.394,85	60.318,75
<b>Melhor Solução</b>		1.028.130,89	1.030.085,71	1.024.129,26	1.043.870,88	1.037.510,56	1.015.750,49	1.036.235,61	1.025.801,73	984.707,21	1.055.845,48

Tabela H.4 (c) – Resultados obtidos nas simulações para o problema pcb1173.

Simulações	Algoritmo	e21	e22	e23	e24	e25	e26	e27	e28	e29	e30
97	<i>pcb1173</i> GA	1.232.694,48	1.223.683,35	1.226.881,25	1.238.671,68	1.208.116,36	1.247.404,63	1.221.703,51	1.175.063,84	1.170.395,09	1.224.356,71
98	<i>pcb1173</i> SIGA(1,1)	1.181.129,07	1.148.416,96	1.205.029,25	1.188.182,89	1.210.858,36	1.176.351,19	1.156.611,66	1.256.851,32	1.212.525,04	1.231.885,33
99	<i>pcb1173</i> SIGA(0,1)	1.168.334,95	1.194.314,19	1.199.473,36	1.215.035,46	1.185.681,30	1.193.734,74	1.168.777,76	1.225.563,62	1.232.567,81	1.182.440,41
100	<i>pcb1173</i> F-SIGA(1,1)	1.205.298,31	1.197.630,34	1.232.598,57	1.181.269,85	1.215.816,17	1.201.539,71	1.202.618,51	1.208.752,85	1.175.054,30	1.191.721,81
101	<i>pcb1173</i> F-SIGA(0,1)	1.234.741,75	1.245.311,26	1.231.560,81	1.245.119,42	1.222.993,63	1.236.074,67	1.231.077,67	1.244.344,77	1.221.080,42	1.238.126,01
102	<i>pcb1173</i> ESIA(SIGA)(1,1)	1.202.200,78	1.206.104,24	1.177.973,74	1.217.384,64	1.234.547,59	1.206.507,73	1.217.984,02	1.219.279,60	1.197.518,73	1.179.255,13
103	<i>pcb1173</i> ESIA(SIGA)(0,1)	1.201.008,34	1.194.043,13	1.200.861,72	1.179.276,78	1.236.181,62	1.233.220,07	1.173.528,40	1.201.358,17	1.218.810,66	1.223.446,23
104	<i>pcb1173</i> ESIA(F-SIGA)(1,1)	1.197.039,67	1.196.969,32	1.196.359,01	1.244.483,66	1.220.373,37	1.213.777,91	1.184.520,17	1.190.655,82	1.206.760,19	1.227.988,33
105	<i>pcb1173</i> ESIA(F-SIGA)(0,1)	1.213.968,06	1.210.254,78	1.195.002,73	1.185.839,32	1.196.207,31	1.207.055,23	1.193.450,23	1.234.958,88	1.227.632,35	1.169.323,84
106	<i>pcb1173</i> NpSIGA(1,1)	1.049.415,73	1.071.452,16	1.071.049,20	1.065.466,45	1.034.783,29	1.045.836,47	1.042.321,95	1.042.024,83	1.040.014,84	1.038.899,27
107	<i>pcb1173</i> NpSIGA(0,1)	1.055.052,55	1.027.753,04	1.024.756,71	1.070.413,64	1.068.034,92	1.057.175,21	1.062.068,29	1.068.343,30	1.034.104,26	1.056.982,94
<b>Média</b>		1.176.443,97	1.174.175,71	1.178.322,40	1.184.649,44	1.184.872,17	1.183.516,14	1.168.605,65	1.187.927,00	1.176.042,15	1.178.584,18
<b>Desvio Padrão</b>		64.384,89	66.601,49	67.454,04	62.816,12	68.039,51	68.345,76	62.172,07	69.942,66	71.507,20	68.925,43
<b>Melhor Solução</b>		1.049.415,73	1.027.753,04	1.024.756,71	1.065.466,45	1.034.783,29	1.045.836,47	1.042.321,95	1.042.024,83	1.034.104,26	1.038.899,27

Tabela H.4 (d) – Resultados obtidos nas simulações para o problema pcb1173.

Simulações	Algoritmo	e31	e32	e33	e34	e35	e36	e37	e38	e39	e40
97	<i>pcb1173</i> GA	1.223.622,74	1.226.642,35	1.207.612,58	1.235.814,44	1.247.993,12	1.130.730,02	1.204.116,82	1.182.637,35	1.208.552,49	1.191.421,67
98	<i>pcb1173</i> SIGA(1,1)	1.214.715,58	1.209.983,40	1.226.304,22	1.228.609,05	1.200.090,26	1.214.041,39	1.204.530,78	1.210.741,86	1.179.261,13	1.185.908,85
99	<i>pcb1173</i> SIGA(0,1)	1.162.790,89	1.219.832,50	1.208.504,42	1.199.122,97	1.223.785,72	1.212.461,24	1.223.559,03	1.191.099,99	1.211.737,75	1.189.713,09
100	<i>pcb1173</i> F-SIGA(1,1)	1.178.965,47	1.185.502,30	1.193.640,73	1.212.110,46	1.203.476,90	1.206.662,46	1.223.845,97	1.175.695,10	1.227.729,63	1.212.532,42
101	<i>pcb1173</i> F-SIGA(0,1)	1.227.541,56	1.233.442,49	1.237.443,00	1.253.478,02	1.232.112,18	1.237.753,23	1.220.718,59	1.228.265,72	1.245.348,10	1.238.386,09
102	<i>pcb1173</i> ESIA(SIGA)(1,1)	1.208.729,58	1.200.039,76	1.186.306,84	1.212.904,39	1.189.815,47	1.231.048,19	1.209.570,61	1.210.259,44	1.216.617,21	1.175.489,34
103	<i>pcb1173</i> ESIA(SIGA)(0,1)	1.189.817,22	1.195.656,97	1.199.969,39	1.177.146,95	1.200.734,79	1.190.583,27	1.224.350,65	1.187.294,43	1.214.319,81	1.201.447,07
104	<i>pcb1173</i> ESIA(F-SIGA)(1,1)	1.206.032,65	1.222.196,18	1.188.676,45	1.157.275,57	1.191.161,24	1.231.689,02	1.214.235,59	1.161.420,70	1.183.473,62	1.215.793,50
105	<i>pcb1173</i> ESIA(F-SIGA)(0,1)	1.195.522,02	1.178.694,44	1.190.300,72	1.198.240,09	1.205.668,12	1.205.130,68	1.235.542,40	1.209.779,64	1.216.017,68	1.177.331,58
106	<i>pcb1173</i> NpSIGA(1,1)	1.081.837,02	1.036.103,13	1.088.853,23	1.038.011,73	1.055.053,54	1.054.920,19	1.076.752,83	1.037.921,82	1.047.762,67	1.073.510,56
107	<i>pcb1173</i> NpSIGA(0,1)	1.053.287,67	1.012.059,21	1.067.156,20	1.053.429,63	1.018.763,39	1.051.123,15	1.027.542,83	1.030.510,56	1.017.164,40	1.058.977,23
<b>Média</b>		1.176.623,85	1.174.559,34	1.181.342,52	1.178.740,30	1.178.968,61	1.178.740,26	1.187.706,01	1.165.966,06	1.178.907,68	1.174.591,94
<b>Desvio Padrão</b>		57.508,73	76.525,34	53.708,82	70.976,82	72.881,81	68.515,97	68.563,57	67.816,69	74.959,05	56.710,16
<b>Melhor Solução</b>		1.053.287,67	1.012.059,21	1.067.156,20	1.038.011,73	1.018.763,39	1.051.123,15	1.027.542,83	1.030.510,56	1.017.164,40	1.058.977,23

Tabela H.4 (e) – Resultados obtidos nas simulações para o problema pcb1173.

Simulações	Algoritmo	e41	e42	e43	e44	e45	e46	e47	e48	e49	e50
97	<i>pcb1173</i> GA	1.248.512,86	1.185.523,11	1.215.517,70	1.205.266,59	1.192.467,83	1.236.949,75	1.188.046,14	1.179.284,71	1.266.663,61	1.151.138,18
98	<i>pcb1173</i> SIGA(1,1)	1.202.206,09	1.197.468,70	1.190.784,62	1.193.894,90	1.195.165,64	1.255.896,75	1.164.154,13	1.195.674,39	1.233.005,20	1.232.142,56
99	<i>pcb1173</i> SIGA(0,1)	1.168.327,73	1.177.317,11	1.203.795,90	1.180.099,55	1.204.584,52	1.204.707,73	1.194.344,28	1.185.647,27	1.216.627,35	1.210.117,97
100	<i>pcb1173</i> F-SIGA(1,1)	1.247.240,19	1.188.334,85	1.207.003,88	1.214.649,23	1.199.529,52	1.185.924,57	1.189.261,44	1.204.846,01	1.214.851,86	1.202.085,75
101	<i>pcb1173</i> F-SIGA(0,1)	1.239.322,04	1.230.461,99	1.232.309,07	1.234.725,86	1.234.811,49	1.219.892,64	1.238.827,62	1.227.657,73	1.234.649,54	1.240.195,82
102	<i>pcb1173</i> ESIA(SIGA)(1,1)	1.210.541,48	1.183.608,27	1.237.776,65	1.216.787,61	1.215.304,63	1.159.352,69	1.219.918,66	1.176.765,69	1.188.775,61	1.162.975,63
103	<i>pcb1173</i> ESIA(SIGA)(0,1)	1.226.219,35	1.180.479,57	1.195.033,98	1.226.939,93	1.194.540,98	1.189.454,47	1.183.352,36	1.162.481,97	1.229.514,30	1.203.657,15
104	<i>pcb1173</i> ESIA(F-SIGA)(1,1)	1.220.781,41	1.185.756,05	1.218.057,05	1.206.289,04	1.251.018,51	1.210.922,89	1.173.290,25	1.210.606,41	1.218.995,53	1.204.482,30
105	<i>pcb1173</i> ESIA(F-SIGA)(0,1)	1.242.321,67	1.216.316,36	1.231.580,11	1.184.083,51	1.191.767,45	1.216.924,42	1.195.889,00	1.196.119,36	1.211.447,93	1.204.597,89
106	<i>pcb1173</i> NpSIGA(1,1)	1.038.177,94	1.028.090,20	1.018.365,50	1.026.509,39	1.056.121,66	1.059.546,11	1.054.738,59	1.027.235,33	1.006.624,29	1.092.080,52
107	<i>pcb1173</i> NpSIGA(0,1)	1.043.958,60	1.015.545,73	1.037.629,89	1.086.762,99	1.046.133,38	1.023.559,72	1.016.569,32	1.039.726,08	1.023.139,74	1.053.341,36
<b>Média</b>		1.189.782,67	1.162.627,45	1.180.714,03	1.179.637,15	1.180.131,42	1.178.466,52	1.165.308,34	1.164.185,90	1.185.845,00	1.177.892,29
<b>Desvio Padrão</b>		77.167,28	71.502,40	77.118,00	64.453,47	66.544,29	72.823,59	67.820,34	67.039,90	86.711,99	58.606,80
<b>Melhor Solução</b>		1.038.177,94	1.015.545,73	1.018.365,50	1.026.509,39	1.046.133,38	1.023.559,72	1.016.569,32	1.027.235,33	1.006.624,29	1.053.341,36

## ANEXO I – LISTA DE PUBLICAÇÕES

- ANAIS DE CONGRESSOS

BRITO, Felipe Houat de; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **A Introdução da Interação Fenotípica em Algoritmos Genéticos Através dos Jogos Evolucionários e da Codificação e Transmissão Genética do Comportamento**. In: Proceedings of VII SBAI / II IEEE-LARS - Simpósio Brasileiro de Automação Inteligente / Latin American IEEE Robotics Symposium, 2005, São Luís.

BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **A Fuzzy Intelligent Controller for Genetic Algorithms' Parameters**. In: Proceedings of Second International Conference on Natural Computation (ICNC'06) and the Third International Conference on Fuzzy Systems and Knowledge Discovery (FSKD'06), 2006, Xi'an. v. 4221. p. 633-642.

TEIXEIRA, Otávio Noura; BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; OLIVEIRA, Roberto Célio Limão de. **Genetic Algorithms with Social Interaction Phase as Phenotype Characterization**. In: Second International Conference on Natural Computation (ICNC'06) and the Third International Conference on Fuzzy Systems and Knowledge Discovery (FSKD'06), 2006, Xi'an. Proceedings of Advance in Natural Computation and Data Mining. Xi'an: Xidian University Press, 2006.

BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **A Fuzzy Approach to Control Genetic Algorithm Parameters**. In: ASAI 2006 - Proceedings of VIII Argentine Symposium on Artificial Intelligence, 2006, Mendoza.

TEIXEIRA, Otávio Noura; BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; OLIVEIRA, Roberto Célio Limão de. **O Paradigma do Dilema do Prisioneiro Aplicado ao Método de Seleção Roleta dos Algoritmos Genéticos**. In: Proceedings of CLEI 2006 - Conferencia Latinoamericana de Informática, 2006, Santiago.

BRITO, Felipe Houat de; TEIXEIRA, Otávio Noura; TEIXEIRA, Artur Noura; OLIVEIRA, Roberto Célio Limão de. **Hawk-Dove Torneio: Um Novo Método de Seleção para os Algoritmos Genéticos Baseado na Teoria dos Jogos Evolucionários**. In: XX SEPAI - Semana Paraense de Informática / III CTIC -

Congresso de Tecnologia da Informação e Comunicação da Amazônia, 2006, Belém.

BARREIRA, André Ferry; OLIVEIRA, Carlos Eduardo de Jesus; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **Proposta de um novo Algoritmo Híbrido de Otimização baseado em Sistemas Imunológicos Artificiais e nos Princípios da Teoria dos Jogos.** In: XX SEPAI - Semana Paraense de Informática / III CTIC - Congresso de Tecnologia da Informação e Comunicação da Amazônia, 2006a, Belém.

BARREIRA, André Ferry; OLIVEIRA, Carlos Eduardo de Jesus; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **AISO-GT: Uma Nova Meta-Heurística de Otimização Baseada em Sistemas Imunológicos Artificiais e na Teoria dos Jogos.** In: II Encontro Regional da Computação de Minas Gerais, 2006, Formiga. II Encontro Regional de Computação de Minas Gerais, 2006b.

OLIVEIRA, Carlos Eduardo de Jesus; BARREIRA, André Ferry; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **AISO-GT: Um Novo Algoritmo Híbrido de Otimização Baseado nos Sistemas Imunológicos Artificiais e na Teoria dos Jogos.** In: X SEMINCO - Seminário de Computação, 2006, Blumenau. X SEMINCO - Seminário de Computação, 2006c.

BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **G.A.I.A.: A Fuzzy Intelligent Controller for Genetic Algorithms Parameters and Performance.** In: Worldcomp 2007 - World Congress in Computer Science, Computer Engineering and Applied Computing, 2007, Las Vegas. GEM 2007 - Genetic and Evolutionary Methods. Las Vegas Nevada: CSREA Press, 2007. p. 10-16.

TEIXEIRA, Otávio Noura; BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; OLIVEIRA, Roberto Célio Limão de. **Genetic Algorithms with Social Interaction: A New Step for Phenotype Characterization Thru Game Theory.** In: Worldcomp 2007 - World Congress in Computer Science, Computer Engineering and Applied Computing, 2007, Las Vegas. GEM 2007 - Genetic and Evolutionary Methods. Las Vegas Nevada: CSREA Press, 2007. p. 95-101.

BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **Darwin-less Evolutionary Algorithms: Less Randomness, More Intelligence.** In: 2009 International Conference on Genetic and Evolutionary Methods - GEM 2009, 2009, Las Vegas, Nevada. Proceedings of the 2009 International Conference on Genetic and Evolutionary Methods, 2009. p. 28-34.

BRITO, Felipe Houat de; TEIXEIRA, Otávio Noura; TEIXEIRA, Artur Noura; OLIVEIRA, Roberto Célio Limão de. **Hawk-Dove Tournament: A New Selection Technique for Genetic Algorithms Based on Evolutionary Game Theory**. In: 2009 International Conference on Genetic and Evolutionary Methods - GEM 2009, 2009, Las Vegas, Nevada. Proceedings of the 2009 International Conference on Genetic and Evolutionary Methods, 2009. p. 54-58.

TORRES, Mário Augusto; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **A New Approach to the Cultural Algorithm's Influence Function Based on Fuzzy Inference System**. In: 2009 International Conference on Genetic and Evolutionary Methods - GEM 2009, 2009, Las Vegas, Nevada. Proceedings of the 2009 International Conference on Genetic and Evolutionary Methods, 2009. p. 263-269.

TEIXEIRA, Otávio Noura; BARREIRA, André Ferry; OLIVEIRA, Carlos Eduardo de Jesus; OLIVEIRA, Roberto Célio Limão de. **EAIISO-GT: A New Artificial Immune System Optimization Algorithm Based in the Principles of Evolutionary Algorithms and Game Theory**. In: 2010 International Conference on Genetic and Evolutionary Methods - GEM 2010, 2010, Las Vegas, Nevada. Proceedings of the 2010 International Conference on Genetic and Evolutionary Methods, 2010a.

TEIXEIRA, Otávio Noura; LOBATO, Walter Avelino da Luz; YASOJIMA, Carlos Takeshi Kudo; BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; OLIVEIRA, Roberto Célio Limão de. **A New Hybrid Nature-Inspired Metaheuristic for Problem Solving Based on the Social Interaction Genetic Algorithm Employing Fuzzy Systems**. In: 10th International Conference on Hybrid Intelligent Systems, 2010, Atlanta, GA. Proceedings of the IEEE 10th International Conference on Hybrid Intelligent Systems, 2010b. p. 31-36.

MOREIRA, Renato Simões; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **Mixing Theory of Retroviruses and Genetic Algorithm to Build a New Nature-Inspired Meta-Heuristic for Real-Parameter Function Optimization Problems**. In: 10th International Conference on Hybrid Intelligent Systems, 2010, Atlanta, GA. Proceedings of the IEEE 10th International Conference on Hybrid Intelligent Systems, 2010. p. 181-184.

- **REVISTAS**

BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; TEIXEIRA, Otávio Noura;

OLIVEIRA, Roberto Célio Limão de. **A Fuzzy Intelligent Controller for Genetic Algorithms Parameters**. Lecture Notes in Computer Science, v. 4221, p. 633-642, 2006.

BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **A Fuzzy Approach to Control Genetic Algorithm Parameters**. SADIO Electronic Journal of Informatics and Operations Research, v. 7, p. 12-23, 2007.

FERREIRA, Fábio dos Santos; MONTEIRO, Glauber Duarte; TEIXEIRA, Otávio Noura. **Colônia Evolucionária de Formigas: Uma Proposta Inicial Aplicada ao Problema do Caixeiro Viajante**. Revista Eletrônica Hífen, v. 32, p. 01, 2008a.

FERREIRA, Fábio dos Santos; MONTEIRO, Glauber Duarte; TEIXEIRA, Otávio Noura. **EACO: Algoritmo de Otimização por Colônia de Formigas Evolucionária**. Revista de Informática Mater Dei, v. 4, p. 15, 2008b.

REGO, Antoniel da Silva; FERREIRA, Fábio dos Santos; MONTEIRO, Glauber Duarte; TEIXEIRA, Otávio Noura. **ACO-GT: Algoritmo de Otimização baseado em Colônia de Formigas e Teoria dos Jogos**. Revista de Informática Mater Dei, v. 4, p. 09, 2008.

MOREIRA, Renato Simões; TEIXEIRA, Otávio Noura; MONTEIRO, Glauber Duarte; SOARES, Átila Siqueira; OLIVEIRA, Roberto Célio Limão de. **Retroviral Iterative Genetic Algorithm for Real Parameter Function Optimization Problems**. Lecture Notes in Computer Science, v. 6382, p. 220-228, 2010.

MOREIRA, Renato Simões; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **Mixing Theory of Retroviruses and Genetic Algorithm to Build a New Nature-Inspired Meta-Heuristic for Real-Parameter Function Optimization Problems**. POLIBITS – Research Journal on Computer Science and Computer Engineering with Applications, v. 42, p. 65 – 69, 2010.

- **RESUMOS EXPANDIDOS**

BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **Aplicando Datamining com Redes SOM em Base de Dados de Execuções de Algoritmos Genéticos Utilizando os Novos Métodos de Seleção Hawk-Dove Roleta e Hawk-Dove Torneio**. In: CLEI 2006

- Conferencia Latinoamericana de Informática, 2006, Santiago. Proceedings of CLEI 2006 - Conferencia Latinoamericana de Informática.

TORRES, Mário Augusto; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **A Fuzzy-Controlled Influence Function for the Cultural Algorithm with Evolutionary Programming Applied to the Real-Valued Function Optimization.** In: ICINCO 2009 - 6th International Conference on Informatics in Control, Automation and Robotics, 2009, Milan - Italy. Proceedings of the 6th International Conference on Informatics in Control, Automation and Robotics, 2009. v. I.

- **RESUMOS**

TEIXEIRA, Otávio Noura; BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; OLIVEIRA, Roberto Célio Limão de. **Game Theory as a New Paradigm for Phenotype Characterization of Genetic Algorithms.** In: GECCO 2006 - Genetic and Evolutionary Computation Conference, 2006, Seattle-WA. Proceedings of GECCO 2006 - Genetic and Evolutionary Computation Conference. New York, NY : ACM Press, 2006. v. 2. p. 1431-1432.

TORRES, Mário Augusto; MAGNO e SILVA, Rodrigo Passos; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **A Fuzzy Inference System-Inspired Influence Function for the Cultural Algorithm with Evolutionary Programming Applied to Real-Valued Function Optimization.** In: GECCO 2009 - Genetic and Evolutionary Computation Conference, 2009, Montreal - QC. Proceedings of Genetic and Evolutionary Computation Conference. New York, NY : ACM, 2009. v. 1. p. 1825-1826.

BARREIRA, André Ferry; OLIVEIRA, Carlos Eduardo de Jesus; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **Evolutionary Artificial Immune Systems.** In: GECCO 2010 - Genetic and Evolutionary Computation Conference, 2010, Portland, Oregon. Proceedings of the 2010 Genetic and Evolutionary Computation Conference. Alpha, New Jersey : Sheridan Printing Company, Inc., 2010. p. 2065-2066.

TEIXEIRA, Otávio Noura; LOBATO, Walter Avelino da Luz; YASOJIMA, Carlos Takeshi Kudo; BRITO, Felipe Houat de; TEIXEIRA, Artur Noura; OLIVEIRA, Roberto Célio Limão de. **Fuzzy Social Interaction Genetic Algorithm.** In: GECCO 2010 - Genetic and Evolutionary Computation Conference, 2010, Portland, Oregon. Proceedings of the 2010 Genetic and Evolutionary Computation Conference. Alpha, New Jersey: Sheridan Printing Company, Inc.,

2010. p. 2113-2114.

BARREIRA, André Ferry; OLIVEIRA, Carlos Eduardo de Jesus; TEIXEIRA, Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **Evolutionary Artificial Immune Systems**. In: GECCO 2010 - Genetic and Evolutionary Computation Conference, 2010, Portland, Oregon. Proceedings of the 2010 Genetic and Evolutionary Computation Conference. Alpha, New Jersey: Sheridan Printing Company, Inc., 2010. p. 2065-2066.

SOUZA, Daniel Leal; MONTEIRO, Glauber Duarte; MARTINS, Tiago Carvalho; DMITRIEV, Victor Alexandrovich; TEIXEIRA, Otávio Noura. **PSO-GPU: Accelerating Particle Swarm Optimization in CUDA-Based Graphics Processing Units**. In: GECCO 2011 - Genetic and Evolutionary Computation Conference, 2011, Dublin, Ireland. Proceedings of the 2011 Genetic and Evolutionary Computation Conference. Alpha, New Jersey: Sheridan Printing Company, Inc., 2011. p. 837-838.

- **CAPÍTULOS DE LIVRO**

TEIXEIRA, Otávio Noura; LOBATO, Walter Avelino da Luz; YANAGUIBASHI, Hitoshi Seki; CAVALCANTE, Rodrigo Vieira; SILVA, Deam James Azevedo da; OLIVEIRA, Roberto Célio Limão de. **Algoritmo Genético com Interação Social na Resolução de Problemas de Otimização Global com Restrições**. In: Lopes, Heitor Silvério; Takahashi, Ricardo Hiroshi Caldeira. (Eds.). *Computação Evolucionária em Problemas de Engenharia*. Omnipax Editora Ltda., 2011.

MOREIRA, Renato Simões; Otávio Noura; LOBATO, Walter Avelino da Luz; YANAGUIBASHI, Hitoshi Seki; OLIVEIRA, Roberto Célio Limão de. **Using Retroviral Iterative Genetic Algorithm to Solve Constraint Global Optimization Problems**. In: Mahmut Caliskan. (Eds.). *Genetic Diversity in Microorganisms*. InTech Open Access Publisher, 2012, v. 1, p. 215 – 232.

SILVA, Deam James; Otávio Noura; OLIVEIRA, Roberto Célio Limão de. **Performance Study of Cultural Algorithms based on Genetic Algorithm with Single and Multi Population for the MKP**. In: Shangce Gao. (Eds.). *Bio-Inspired Computational Algorithms and Their Applications*. InTech Open Access Publisher, 2012, v. 1, p. 386 – 404.