



Programa Interdisciplinar de Pós-Graduação em

Computação Aplicada

Mestrado Acadêmico

Luan Carlos Nesi

Modelo Hipermídia para Geração de
Layouts de Interfaces de Aplicações

São Leopoldo, 2014

UNIVERSIDADE DO VALE DO RIO DOS SINOS — UNISINOS
UNIDADE ACADÊMICA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA
NÍVEL MESTRADO

LUAN CARLOS NESI

**MODELO HIPERMÍDIA PARA GERAÇÃO DE
LAYOUTS DE INTERFACES DE APLICAÇÕES**

São Leopoldo
2014

Luan Carlos Nesi

**MODELO HIPERMÍDIA PARA GERAÇÃO DE
LAYOUTS DE INTERFACES DE APLICAÇÕES**

Dissertação de mestrado apresentada como
requisito parcial para a obtenção do título de
Mestre pelo Programa de Pós-Graduação em
Computação Aplicada da Universidade do Vale
do Rio dos Sinos — UNISINOS

Orientador:
Prof. Dr. Arthur Tórgo Gómez

São Leopoldo
2014

Ficha catalográfica

N459m Nesi, Luan Carlos

Modelo hipermídia para geração de *layouts* de interfaces de aplicações / por Luan Carlos Nesi. – 2014.

219 f. : il., 30 cm.

Dissertação (mestrado) — Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, 2014.

Orientação: Prof. Dr. Arthur Tórgo Gómez.

1. Sistema de hipermídia adaptativa. 2. Metaheurísticas.
3. Redes de autômatos estocásticos. 4. Algoritmo memético.
5. *Layout*. I. Título.

CDU 004.4'27

Catálogo na Fonte:
Bibliotecária Vanessa Borges Nunes - CRB 10/1556

Luan Carlos Nesi

**MODELO HIPERMÍDIA PARA GERAÇÃO DE
LAYOUTS DE INTERFACES DE APLICAÇÕES**

Dissertação de mestrado apresentada como
requisito parcial para a obtenção do título de
Mestre pelo Programa de Pós-Graduação em
Computação Aplicada da Universidade do Vale
do Rio dos Sinos — UNISINOS

Orientador:
Prof. Dr. Arthur Tórgo Gómez

Aprovado em 27/03/2014

BANCA EXAMINADORA

Orientador Dr. Arthur Tórgo Gómez
Universidade do Vale do Rio dos Sinos — UNISINOS

Dr. João Carlos Gluz
Universidade do Vale do Rio dos Sinos — UNISINOS

Dr. Haroldo Fraga de Campos Velho
Instituto Nacional de Pesquisas Espaciais — INPE

São Leopoldo
2014

Dedico esta dissertação aos meus Pais e a Lorena, meu grande amor.

Com carinho, Luan.

*If I have seen farther than others,
it is because I stood on the shoulders of giants.*

— SIR ISAAC NEWTON

AGRADECIMENTOS

Este trabalho só foi possível graças ao apoio de diversas pessoas. Gostaria de transmitir meus sinceros agradecimentos...

...a meus Pais Rejane e Ademir, símbolos de perseverança,
pelo apoio incondicional e pela confiança depositada em mim;

...a minha namorada Lorena,
pela paciência, compreensão e ajuda nos momentos de dificuldades;

...aos amigos Lindomal e Alex,
pelos conselhos e envolvimento neste trabalho;

...ao meu orientador, Professor Dr. Arthur Tórgo Gómez,
pelos ensinamentos e por me mostrar que o mundo é NP-Hard,
Obrigado pela confiança, guias e ideias neste projeto;

...ao Programa de Pós-Graduação em Computação Aplicada da UNISINOS,
pelo apoio aos meus interesses de pesquisa.

...ao Projeto de pesquisa DIGICONV,
pelo espaço de pesquisa e convívio com os colegas, Márcio, Tana e James;

...a Fundação Pe. Milton Valente,
pela concessão da bolsa que tornou possível a realização do Curso de Mestrado.

...a todos os demais colegas acadêmicos, amigos e professores que enriqueceram meu
aprendizado e de uma forma ou outra contribuíram com opiniões, críticas e questionamentos
sobre esta pesquisa.

*“Tudo que o homem não conhece não existe para ele.
Por isso o mundo tem, para cada um,
o tamanho que abrange o seu conhecimento.”*
(Carlos Bernardo González Pecotche - Raumsol)

RESUMO

Nesse trabalho foi desenvolvido um modelo computacional de Hipermissão Adaptativa para geraço de *layouts* de interface de aplicaçes. A pesquisa partiu de uma reviso sobre Hipermissão Adaptativa, com um apanhado sobre os conceitos e caractersticas dos mtodos e tcnicas de adaptaço a fim de embasar seu desenvolvimento. Aps, avaliou-se o uso das metaheursticas Algoritmo Gentico, Busca Tabu e Algoritmo Memtico como as ferramentas de apoio no desenvolvimento do modelo. Na sequncia, as Redes de Autmatos Estocsticos nortearam a modelagem do formalismo utilizado para retenço de conhecimento. Dessas bases, foi desenvolvida a prova de conceito. Consequente, apresentam-se os experimentos realizados para validaço. Os resultados obtidos pelo modelo foram de boa qualidade, indo ao encontro dos objetivos da pesquisa. Como decorrncia deste trabalho, obteve-se um sistema capaz de gerar *layouts*, contemplando as caractersticas dos usurios e seus dispositivos, sendo capaz de acompanhar uma tendncia de consumo de contedos no s mercadolgica, mas tambm, social.

Palavras-chave: Sistema de Hipermissão Adaptativa. Metaheursticas. Redes de Autmatos Estocsticos. Algoritmo Memtico. *Layout*.

ABSTRACT

In this paper was developed a computational model of Adaptive Hypermedia for generation of interface layouts of applications. The research began with a review of Adaptive Hypermedia, with an overview of the concepts and characteristics of the methods and adaptation techniques in order to base its development. After, we evaluated the use of metaheuristic Genetic Algorithm, Tabu Search, and Memetic Algorithm as support tools in the development of the model. Following, the Stochastic Automata Networks guided the modeling of the formalism used for knowledge retention. These bases, the proof of concept were developed. Therefore, we present the experiments to validate. The obtained results by the model were of good quality, meeting the research objectives. As results of this work, we obtained a system capable to generate layouts, considering the characteristics of the users and their devices, being able to follow a trend of content consumption not only marketing, but also social.

Keywords: Adaptive Hypermedia Systems. Metaheuristic. Stochastic Automata Networks. Memetic Algorithm. Layout.

LISTA DE FIGURAS

1	Estrutura dos eixos de pesquisa	28
2	Ciclo clássico de adaptação do Modelo de Usuário em sistemas adaptativos .	34
3	Espaços de Adaptação	36
4	Métodos e Técnicas de Adaptação	37
5	Arquitetura do Modelo HAM	46
6	Arquitetura do Modelo Trellis	48
7	Arquitetura do Modelo Dexter	50
8	Arquitetura do Modelo Tower	51
9	Arquitetura do Modelo Amsterdam	52
10	Arquitetura do Modelo AHAM	54
11	Arquitetura do Modelo Munich	56
12	Representação Hipotética do Espaço de Busca	63
13	Fluxograma do Algoritmo Genético	68
14	Pseudocódigo canônico do Algoritmo Genético	69
15	Operador de cruzamento de 1 ponto	72
16	Operador de mutação uniforme	72
17	Componentes da estratégia da Busca Tabu	73
18	Fluxograma da Busca Tabu	74
19	Pseudocódigo canônico da Busca Tabu para maximização	75
20	Pseudocódigo canônico do Algoritmo Memético	79
21	Autômato de Aprendizagem	94
22	Arquitetura sistêmica do Projeto DIGICONV	100
23	Arquitetura do Servidor de Acesso	101
24	Arquitetura do MOHAI	104
25	Configurações do <i>grid</i>	106
26	Estrutura hierárquica da mochila	106
27	Detalhamento do Módulo de Serviço	107
28	Composição do Autômato $\mathcal{A}^{(1)}$ - Autômato de <i>Layout</i>	109
29	Composição do Autômato $\mathcal{A}^{(2)}$ - Autômato de Componentes Atômicos . . .	110
30	Composição do Autômato $\mathcal{A}^{(3)}$ - Autômato de Componente Composto . . .	110
31	Descrição da Aplicação em XML	113
32	Efeito Adaptativo	114
33	Fluxograma do Algoritmo Memético proposto	116
34	Estrutura do Cromossomo	117
35	<i>Strings</i> do cromossomo	117
36	Tríade da Solução	118
37	<i>Mock-up</i> de interface para PC	122
38	Convergência do modelo Primal	127
39	Convergência do modelo Primal Normalizado	128
40	Convergência do modelo Dual	129
41	Convergência do modelo Dual Normalizado	130
42	Convergência do modelo Primal com beta crescente (+1)	131
43	Convergência do modelo Primal com beta crescente (+1000)	131
44	Convergência do modelo Primal ($\beta = 55.000$)	132
45	Convergência do modelo Primal ($\beta = 85.000$)	132
46	Evolução do experimento com AG no Formato 1 com 15 usuários	137

47	Evolução do experimento com BT no Formato 1 com 15 usuários	138
48	Comparativo entre as soluções das MH no Formato 1 com 15 usuários . . .	139
49	Evolução do experimento com AG no Formato 2 com 15 usuários	140
50	Evolução do experimento com BT no Formato 2 com 15 usuários	141
51	Comparativo entre as soluções das MH no Formato 2 com 15 usuários . . .	142
52	Evolução do experimento com AG no Formato 3 com 15 usuários	143
53	Evolução do experimento com BT no Formato 3 com 15 usuários	144
54	Comparativo entre as soluções das MH no Formato 3 com 15 usuários . . .	145
55	Evolução do experimento com AG no Formato 4 com 15 usuários	146
56	Evolução do experimento com BT no Formato 4 com 15 usuários	147
57	Comparativo entre as soluções das MH no Formato 4 com 15 usuários . . .	148
58	Evolução do experimento com AG no Formato 5 com 15 usuários	149
59	Evolução do experimento com BT no Formato 5 com 15 usuários	150
60	Comparativo entre as soluções das MH no Formato 5 com 15 usuários . . .	151
61	Evolução do experimento com AG no Formato 1 com 50 usuários	152
62	Evolução do experimento com BT no Formato 1 com 50 usuários	153
63	Comparativo entre as soluções das MH no Formato 1 com 50 usuários . . .	154
64	Evolução do experimento com AG no Formato 2 com 50 usuários	155
65	Evolução do experimento com BT no Formato 2 com 50 usuários	156
66	Comparativo entre as soluções das MH no Formato 2 com 50 usuários . . .	157
67	Evolução do experimento com AG no Formato 3 com 50 usuários	158
68	Evolução do experimento com BT no Formato 3 com 50 usuários	159
69	Comparativo entre as soluções das MH no Formato 3 com 50 usuários . . .	160
70	Evolução do experimento com AG no Formato 4 com 50 usuários	161
71	Evolução do experimento com BT no Formato 4 com 50 usuários	162
72	Comparativo entre as soluções das MH no Formato 4 com 50 usuários . . .	163
73	Evolução do experimento com AG no Formato 5 com 50 usuários	164
74	Evolução do experimento com BT no Formato 5 com 50 usuários	165
75	Comparativo entre as soluções das MH no Formato 5 com 50 usuários . . .	166
76	Evolução do experimento com AG no Formato 1 com 100 usuários	167
77	Evolução do experimento com BT no Formato 1 com 100 usuários	168
78	Comparativo entre as soluções das MH no Formato 1 com 100 usuários . . .	169
79	Evolução do experimento com AG no Formato 2 com 100 usuários	170
80	Evolução do experimento com BT no Formato 2 com 100 usuários	171
81	Comparativo entre as soluções das MH no Formato 2 com 100 usuários . . .	172
82	Evolução do experimento com AG no Formato 3 com 100 usuários	173
83	Evolução do experimento com BT no Formato 3 com 100 usuários	174
84	Comparativo entre as soluções das MH no Formato 3 com 100 usuários . . .	175
85	Evolução do experimento com AG no Formato 4 com 100 usuários	176
86	Evolução do experimento com BT no Formato 4 com 100 usuários	177
87	Comparativo entre as soluções das MH no Formato 4 com 100 usuários . . .	178
88	Evolução do experimento com AG no Formato 5 com 100 usuários	179
89	Evolução do experimento com BT no Formato 5 com 100 usuários	180
90	Comparativo entre as soluções das MH no Formato 5 com 100 usuários . . .	181
91	Evolução do experimento com AG no Formato 1 com 1000 usuários	182
92	Evolução do experimento com BT no Formato 1 com 1000 usuários	183
93	Comparativo entre as soluções das MH no Formato 1 com 1000 usuários . .	184
94	Evolução do experimento com AG no Formato 2 com 1000 usuários	185

95	Evolução do experimento com BT no Formato 2 com 1000 usuários	186
96	Comparativo entre as soluções das MH no Formato 2 com 1000 usuários . .	187
97	Evolução do experimento com AG no Formato 3 com 1000 usuários	188
98	Evolução do experimento com BT no Formato 3 com 1000 usuários	189
99	Comparativo entre as soluções das MH no Formato 3 com 1000 usuários . .	190
100	Evolução do experimento com AG no Formato 4 com 1000 usuários	191
101	Evolução do experimento com BT no Formato 4 com 1000 usuários	192
102	Comparativo entre as soluções das MH no Formato 4 com 1000 usuários . .	193
103	Evolução do experimento com AG no Formato 5 com 1000 usuários	194
104	Evolução do experimento com BT no Formato 5 com 1000 usuários	195
105	Comparativo entre as soluções das MH no Formato 5 com 1000 usuários . .	196

LISTA DE TABELAS

1	Métodos de Conteúdo Adaptativo	38
2	Técnicas de Conteúdo Adaptativo	39
3	Relação de métodos e técnicas para Adaptação de Conteúdo	40
4	Métodos de Apresentação Adaptativa	40
5	Técnicas de Apresentação Adaptativa	41
6	Relação de métodos e técnicas para Adaptação da Apresentação	42
7	Métodos de Navegação Adaptativa	43
8	Técnicas de Navegação Adaptativa	44
9	Relação de métodos e técnicas para Adaptação da Navegação	45
10	Formatos para larguras de dispositivos	105
11	Número de colunas por formato	105
12	Lista das características dos dispositivos	125
13	Parametrização padrão	126
14	Normalização do modelo Primal	128
15	Normalização do modelo Dual	129
16	Experimentos de calibração	133
17	Etapas do processo de experimentação	133
18	Modelo de tabela de resultados para o AG	134
19	Modelo de tabela de resultados para a BT	135
20	Modelo de tabela de resultados do AM	136
21	Experimento com Algoritmo Genético no Formato 1 com 15 usuários	137
22	Experimento com Busca Tabu no Formato 1 com 15 usuários	138
23	Experimento com Algoritmo Memético no Formato 1 com 15 usuários	139
24	Experimento com Algoritmo Genético no Formato 2 com 15 usuários	140
25	Experimento com Busca Tabu no Formato 2 com 15 usuários	141
26	Experimento com Algoritmo Memético no Formato 2 com 15 usuários	142
27	Experimento com Algoritmo Genético no Formato 3 com 15 usuários	143
28	Experimento com Busca Tabu no Formato 3 com 15 usuários	144
29	Experimento com Algoritmo Memético no Formato 3 com 15 usuários	145
30	Experimento com Algoritmo Genético no Formato 4 com 15 usuários	146
31	Experimento com Busca Tabu no Formato 4 com 15 usuários	147
32	Experimento com Algoritmo Memético no Formato 4 com 15 usuários	148
33	Experimento com Algoritmo Genético no Formato 5 com 15 usuários	149
34	Experimento com Busca Tabu no Formato 5 com 15 usuários	150
35	Experimento com Algoritmo Memético no Formato 5 com 15 usuários	151
36	Experimento com Algoritmo Genético no Formato 1 com 50 usuários	152
37	Experimento com Busca Tabu no Formato 1 com 50 usuários	153
38	Experimento com Algoritmo Memético no Formato 1 com 50 usuários	154
39	Experimento com Algoritmo Genético no Formato 2 com 50 usuários	155
40	Experimento com Busca Tabu no Formato 2 com 50 usuários	156
41	Experimento com Algoritmo Memético no Formato 2 com 50 usuários	157
42	Experimento com Algoritmo Genético no Formato 3 com 50 usuários	158
43	Experimento com Busca Tabu no Formato 3 com 50 usuários	159
44	Experimento com Algoritmo Memético no Formato 3 com 50 usuários	160
45	Experimento com Algoritmo Genético no Formato 4 com 50 usuários	161
46	Experimento com Busca Tabu no Formato 4 com 50 usuários	162

47	Experimento com Algoritmo Memético no Formato 4 com 50 usuários . . .	163
48	Experimento com Algoritmo Genético no Formato 5 com 50 usuários . . .	164
49	Experimento com Busca Tabu no Formato 5 com 50 usuários	165
50	Experimento com Algoritmo Memético no Formato 5 com 50 usuários . . .	166
51	Experimento com Algoritmo Genético no Formato 1 com 100 usuários . . .	167
52	Experimento com Busca Tabu no Formato 1 com 100 usuários	168
53	Experimento com Algoritmo Memético no Formato 1 com 100 usuários . .	169
54	Experimento com Algoritmo Genético no Formato 2 com 100 usuários . . .	170
55	Experimento com Busca Tabu no Formato 2 com 100 usuários	171
56	Experimento com Algoritmo Memético no Formato 2 com 100 usuários . .	172
57	Experimento com Algoritmo Genético no Formato 3 com 100 usuários . . .	173
58	Experimento com Busca Tabu no Formato 3 com 100 usuários	174
59	Experimento com Algoritmo Memético no Formato 3 com 100 usuários . .	175
60	Experimento com Algoritmo Genético no Formato 4 com 100 usuários . . .	176
61	Experimento com Busca Tabu no Formato 4 com 100 usuários	177
62	Experimento com Algoritmo Memético no Formato 4 com 100 usuários . .	178
63	Experimento com Algoritmo Genético no Formato 5 com 100 usuários . . .	179
64	Experimento com Busca Tabu no Formato 5 com 100 usuários	180
65	Experimento com Algoritmo Memético no Formato 5 com 100 usuários . .	181
66	Experimento com Algoritmo Genético no Formato 1 com 1000 usuários . .	182
67	Experimento com Busca Tabu no Formato 1 com 1000 usuários	183
68	Experimento com Algoritmo Memético no Formato 1 com 1000 usuários . .	184
69	Experimento com Algoritmo Genético no Formato 2 com 1000 usuários . .	185
70	Experimento com Busca Tabu no Formato 2 com 1000 usuários	186
71	Experimento com Algoritmo Memético no Formato 2 com 1000 usuários . .	187
72	Experimento com Algoritmo Genético no Formato 3 com 1000 usuários . .	188
73	Experimento com Busca Tabu no Formato 3 com 1000 usuários	189
74	Experimento com Algoritmo Memético no Formato 3 com 1000 usuários . .	190
75	Experimento com Algoritmo Genético no Formato 4 com 1000 usuários . .	191
76	Experimento com Busca Tabu no Formato 4 com 1000 usuários	192
77	Experimento com Algoritmo Memético no Formato 4 com 1000 usuários . .	193
78	Experimento com Algoritmo Genético no Formato 5 com 1000 usuários . .	194
79	Experimento com Busca Tabu no Formato 5 com 1000 usuários	195
80	Experimento com Algoritmo Memético no Formato 5 com 1000 usuários . .	196
81	Consolidação dos experimentos	199
82	Porcentagens de melhora do AM em relação ao AG e a BT	199

LISTA DE ABREVIATURAS

AA	Anotação Adaptativa
ADIUBM	Ambientes de Desenvolvimento de Interfaces de Usuário Baseado em Modelos
AG	Algoritmo Genético
AM	Algoritmo Memético
AO	Ocultação Adaptativa
BD	Banco de Dados
BF	Baseado em <i>Frame</i>
BT	Busca Tabu
CA	Classificação Adaptativa
CF	Classificação de Fragmentos
CG	Condução Global
CL	Condução Local
CMC	Comunicação Mediada por Computador
CP	Customização Personalizada
CPU	<i>Central Processing Unit</i>
CT	Texto Condicional
EA	Explicação Adicional
EC	Explicação Comparativa
ER	Explicação Requerida
EV	Explicação Variante
FO	Função Objetivo
FR	<i>Frames</i>
FV	Fragmentos Variantes
HT	Hipertexto
IHC	Interação Humano-Computador
IU	Interface de Usuário
LDIU	Linguagens de Descrição de Interfaces de Usuário
LT	Lista Tabu
LV	<i>Layout</i> Variante
MA	Adaptação de Mapas
MI	Multi-Idioma
MU	Modelo de Usuário
NB	NBMax

NP	Navegação Passiva
OD	Orientação Direta
OG	Orientação Global
OL	Orientação Local
PV	Páginas Variantes
SAN	<i>Stochastic Automata Network</i>
SGIU	Sistemas Gerenciadores de Interfaces de Usuário
SHA	Sistemas de Hipermídia Adaptativa
ST	<i>Stretchtext</i>
TC	Taxa de Cruzamento
TM	Taxa de Mutação
VF	Variações de Fragmentos
VP	Variações de Páginas
WS	<i>Web Service</i>

LISTA DE SIGLAS

AHA	<i>Adaptive Hypermedia Architecture</i>
AHAM	<i>Adaptive Hypermedia Application Model</i>
AHAM-MI	<i>Adaptive Hypermedia Application Model for Multiple Inteligences</i>
AHM	<i>Amsterdam Hypermedia Model</i>
API	<i>Application Programming Interface</i>
DDM	Desenvolvimento Dirigidos por Modelos
DIGYMES	<i>Dynamically Generating Interfaces for Mobile and Embedded Systems</i>
DSL	Linguagens Específicas de Domínio
GI	Gerador de Interfaces
GIA	Geração de Interfaces Adaptativas
GUI	<i>Graphical User Interface</i>
HAM	<i>Hypertext Abstract Machine</i>
HTML	<i>HyperText Markup Language</i>
HTTP	<i>Hypertext Transfer Protocol</i>
IMML	<i>Interactive Message Modeling Language</i>
MACIA	Metodologia de Construção Automática de Interfaces Homem-Computador Adaptativas
MANTRA	<i>Model-bAsed eNginneering of multiple interfaces with TRAnsformations</i>
MOHAI	<i>Model of Hypermedia for Adaptive Interface</i>
MUI	<i>Mobile User Interface</i>
MUSA	<i>Multi User Interfaces Single Application</i>
NCL	<i>Nested Context Language</i>
OCL	<i>Object Constraint Language</i>
PC	<i>Personal Computer</i>
PMX	<i>Partially-Matched Crossover</i>
REST	<i>Representational State Transfer</i>
RHA	Retroalimentação em Hipermissão Adaptativa
SHASIM	Sistema Hipermissão Adaptativo baseado em Semiótica e Inteligências Múltiplas
TERESA	<i>Transformation Enviroment for Interactive Systems Representations</i>
UID	<i>User Identification</i>
UIIMT	Ferramenta para Modelagem de Interação e Interface de Usuário
UML	<i>Unified Modeling Language</i>
WUI	<i>Web User Interface</i>

SUMÁRIO

1	INTRODUÇÃO	25
1.1	OBJETIVOS	27
1.1.1	Objetivo Geral	27
1.1.2	Objetivos Específicos	28
1.2	ORGANIZAÇÃO DO TRABALHO	28
2	SISTEMAS HIPERMÍDIA: EVOLUÇÃO, CONCEITOS E CARACTERÍSTICAS	31
2.1	EVOLUÇÃO	31
2.2	SISTEMAS DE HIPERMÍDIA ADAPTATIVA	34
2.3	SISTEMAS DE HIPERMÍDIA ADAPTATIVA E ADAPTÁVEL	35
2.4	O QUE PODE SER ADAPTADO	35
2.5	MÉTODOS E TÉCNICAS DE ADAPTAÇÃO	37
2.5.1	Conteúdo Adaptativo	37
2.5.2	Apresentação Adaptativa	40
2.5.3	Navegação Adaptativa	42
2.6	MODELOS DE REFERÊNCIA EM HIPERMÍDIA ADAPTATIVA	45
2.6.1	<i>Hypertext Abstract Machine</i> – HAM	46
2.6.2	<i>Trellis Model of hypertext</i>	48
2.6.3	<i>Dexter Reference Model</i>	50
2.6.4	<i>Tower Model</i>	50
2.6.5	<i>Amsterdam Hypermedia Model</i> – AHM	51
2.6.6	<i>Adaptive Hypermedia Application Model</i> – AHAM	53
2.6.7	<i>Munich Reference Model</i>	54
2.6.8	Outros Trabalhos em SHA	57
2.7	GERAÇÃO DE INTERFACES	57
2.7.1	Trabalhos Relacionados	58
3	METAHEURÍSTICAS	61
3.1	OTIMIZAÇÃO COMBINATÓRIA	61
3.2	CLASSIFICAÇÃO DAS METAHEURÍSTICAS	63
3.3	FUNDAMENTAÇÃO AO USO DAS TÉCNICAS	65
3.4	ALGORITMO GENÉTICO	66
3.4.1	Adequabilidade e Avaliação da População	69
3.4.2	População Inicial	70
3.4.3	Cromossomo	70
3.4.4	Processo de Seleção	70
3.4.5	Operador de Cruzamento	71
3.4.6	Operador de Mutação	72
3.4.7	Critérios de Parada	72
3.5	BUSCA TABU	73
3.5.1	Solução Inicial e o Espaço de Soluções	76
3.5.2	Lista Tabu	76
3.5.3	Critério de Aspiração	76
3.5.4	Estratégia de Intensificação	77
3.5.5	Política de Diversificação	77
3.5.6	Critério de Parada	77

3.6	ALGORITMO MEMÉTICO	78
4	REDES DE AUTÔMATOS ESTOCÁSTICOS	83
4.1	DEFINIÇÃO INFORMAL	83
4.2	DEFINIÇÃO FORMAL	85
4.3	SAN BEM DEFINIDA	90
4.4	DESCRITOR MARKOVIANO	91
4.5	AUTÔMATOS ESTOCÁSTICOS DE APRENDIZAGEM	92
4.5.1	Autômato Estocástico	93
4.5.2	Ambiente	93
4.5.3	Autômato de Aprendizagem	94
4.5.4	Esquema de reforço	95
4.5.5	Trabalhos Anteriores em Autômatos Estocásticos de Aprendizagem	96
4.6	HIPERTÔMATO	97
5	MODELO PROPOSTO	99
5.1	PROJETO DIGICONV	99
5.1.1	Servidor de Acesso	100
5.2	ARQUITETURA DO MODELO	102
5.2.1	Estruturação da solução	104
5.2.2	Módulo de Serviço	107
5.2.3	Módulo de Interação de Dados	108
5.2.4	Módulo de Geração	112
5.2.5	Módulo de Conversão	121
5.3	<i>Pipeline</i>	121
6	VALIDAÇÃO E EXPERIMENTAÇÃO	123
6.1	GERAÇÃO DE PROGRAMAS DE TESTES	123
6.2	CALIBRAÇÃO DO MODELO	125
6.2.1	Experimentos de Calibração	126
6.3	PLANEJAMENTO DOS EXPERIMENTOS	133
6.3.1	Etapa de Experimentos 1	134
6.3.2	Etapa de Experimentos 2	135
6.3.3	Etapa de Experimentos 3	135
6.4	EXPERIMENTOS REALIZADOS	136
6.4.1	Experimentos em Micro Escala	136
6.4.2	Experimentos em Pequena Escala	152
6.4.3	Experimentos em Média Escala	167
6.4.4	Experimentos em Larga Escala	182
7	CONSIDERAÇÕES FINAIS	197
	REFERÊNCIAS	203

1 INTRODUÇÃO

A crescente influência das novas mídias e os avanços proporcionados pelas tecnologias não podem mais dissociar-se das condições inegavelmente apropriadas das quais o usuário usufrui, como a tendência consumista de tecnologias móveis e a conexão permanente – facilitada pelo uso de dispositivos móveis com acesso à rede. Essas condições, se ponderadas, nos dão pistas sobre a formação de um novo modelo de usuário, transformando atitudes que fazem parte dos processos de produção e distribuição de conteúdos normalmente adotados. A partir da noção de que o contexto tecnológico contemporâneo se complexifica ao passo que estas linhas são escritas, é possível, também, perceber que os usuários de toda essa tecnologia se renovam em velocidade elevada, dando a ver um perfil consumerista, com novas atitudes que instauram novos processos de distribuição e recepção de conteúdo.

Para a contextualização sobre a complexificação dos sistemas tecnológicos, toma-se como ponto de partida o ano de 1980. Desde então, a *Internet* levou aproximadamente 25 anos para atingir o desenvolvimento necessário para alcançar um leque de um bilhão de usuários. Apesar de esse número ser surpreendente, em apenas cinco anos, de 2005 a 2010, esse crescimento de número de usuários atingiu marcas maiores, de modo a alcançar dois bilhões de pessoas. Em outras palavras, levaram-se apenas cinco anos para que fosse alcançada a mesma marca resultante de 25 anos de desenvolvimento (WISER, 2013).

Esses números só ratificam que o contexto contemporâneo é embebido de tecnologia em que a cada segundo há uma ascensão considerável em termos de mercado, principalmente no que diz respeito à Tecnologia da Informação. Essa ênfase se dá pela grandiosidade que os sistemas de informação alcançaram, atualmente, a partir de novos modelos de distribuição e acesso a essa nova moeda: a informação. O modelo *smart* de tecnologia, em voga atualente, permite ao usuário romper a linearidade da programação, podendo decidir como suprirá suas demandas, sem mais depender do meio de acesso ou do distribuidor de conteúdo. Segundo Gartner (2012), 70% dos dispositivos vendidos em 2012 embutiam tecnologia *smart*. Além disso, de acordo com um artigo publicado em 4 de Abril de 2013¹, mais de 1,5 bilhões de dispositivos com acesso à *Internet* seriam vendidos em todo o mundo somente em 2013. Esses dados levam à consideração de hipóteses que expliquem esse fenômeno, permeando um olhar sobre o processo transicional e convergente que esses novos meios e mídias vêm tomando.

Deve-se ter em mente que a popularização e o acesso a tais dispositivos, se dão frente a iniciativas públicas e ao processo de manufatura que permeiam tal difusão. Paralelamente, observa-se a mudança de parte dos modelos sociais de informação, nos quais havia a presença do jornal, do rádio, do telefone, da TV e do computador no ambiente familiar (um dispositivo – múltiplos usuários), e que hoje vem migrando para a convergência de inúmeras funções em um único dispositivo (múltiplos dispositivos – um usuário). Cabe atentar que nesses processos de

¹WISER. **Global PC, Tablet, Smartphone Sales**. 2013. Disponível em: <<http://pt.wiser.org/article/61670dc8dd5c5a3adba285f39bbf8145>>. Acesso em: 10 de Maio de 2013.

mudanças muitas coisas surgiram, assim como diversas desapareceram ou unificaram-se, o que demonstra a forte tendência de convergência e multiplicidade dos dispositivos que se consolida no mercado consumidor.

De fato, essa necessidade está associada não só à disponibilização de conteúdos, vista a unicidade dos usuários mencionada anteriormente, mas também à necessidade da individualização dos modelos de produção e disponibilização de informações e conteúdos, resultando mais das demandas do que das necessidades de mercado. Portanto, têm-se transformações nos setores de telecomunicações, *design*, desenvolvimento de sistemas, entre outros, e no que diz respeito à própria informação, reapresentando o processo de comunicação sob uma nova roupagem, através de uma mudança de paradigmas, causada pela atenção que se faz necessária ao sujeito contemporâneo.

Frente as diferentes transformações propiciadas por estas mudanças, este trabalho foca-se no projeto de Interfaces Humano-Computador (IHC) pela fundamental importância para a qualidade do *software*. Além disso, segundo Libório (2005), *é a etapa que mais consome tempo no processo de desenvolvimento*, ainda mais se considerarmos o desenvolvimento especializado. Ao longo dos anos foram diversas as propostas de criação de geradores automáticos de interface, cada um com uma abordagem específica, seja sob modelos de interação, da visão do usuário, do dispositivo, das necessidades do projetista de interfaces, da ergonomia, do reaproveitamento de código, entre outros.

Com o ressurgimento da interatividade sob essa diferente perspectiva, faz-se necessária a criação de meios e formas que explorem a personalização dos serviços de acordo com os interesses e necessidades do usuário. A TV Digital pode ser vista como um desses processos migratórios e transicionais, impulsionado pela convergência e acesso a novas mídias e tecnologias. Assim como outras mídias digitais, a TV Digital permite inúmeros elementos interativos. Observando que a Televisão Digital não mais se restringe apenas ao dispositivo TV, mas a uma gama de dispositivos, como *smartphones*, *tablets*, computadores, entre outros. Essa nova idealização de interatividade proporciona entretenimento em conjunto ao fornecimento de uma maior quantidade de informações, aliando a tradicional forma de assistir televisão à interatividade dos computadores, constituindo assim a TV Digital Interativa como um ambiente hipermídia, tornando possível atender o consumidor onde, como e quando ele requerer, sem sobrecarregar sua interface. Frente a esta contextualização, indaga-se sobre **como gerar layouts de interfaces para aplicativos de forma hábil, tendo em vista as necessidades do usuário moderno?**

Diante da conjuntura apresentada e do contexto da TV Digital dentro Projeto DIGI-CONV² onde esta pesquisa iniciou e as incontáveis possibilidades de modelagem do processo de geração de interfaces de usuário, bem como à grande complexidade envolvida neste processo, já que ele exige conhecimento especializado devido às inúmeras combinações possíveis de elementos sob uma interface e as incertezas sobre as opções. Esse trabalho propõe o desen-

²Projeto de Desenvolvimento de uma Plataforma de Digital: TV Digital / IPTV / Dispositivos Móveis, financiado pelo FUNTTEL, Chamada Pública /FINEP/FUNTTEL - 02/2009

volvimento de um modelo computacional para geração de *layouts* de interface de aplicativos com base em características do dispositivo e do usuário. Inicialmente, o modelo gera uma Rede de Autômatos Estocásticos (SAN - *Stochastic Automata Network*) com dados probabilísticos descrevendo as características dos usuários e seus dispositivos. De uma solução base gerada por um algoritmo, um conjunto de metaheurísticas formado por Algoritmo Genético, Busca Tabu e Algoritmo Memético evolui a solução base com nas informações contidas na SAN. Como resultado do processo evolutivo, as metaheurísticas fornecem um efeito adaptativo que realimenta o histórico do usuário gerando conhecimento acerca do produto final. O efeito adaptativo também pode ser convertido em linguagem de gráfica, produzindo a interface final que o usuário usufrui.

O modelo desenvolvido é modular, a fim de delinear seus comportamentos, tendo em vista as possibilidades de reuso em outros domínios dadas às aplicabilidades que não a TV Digital. O uso desse conjunto múltiplo de técnicas visa demonstrar a efetividade do Algoritmo Memético proposto, diante da modelagem matemática para geração de *layout*, justificando-se pelo fato do ineditismo no uso de metaheurísticas no tratamento de problemas de geração de *layout* de interface para aplicações.

Como resultados esperados para este trabalho têm-se (1) a contribuição para a evolução da Televisão Digital Interativa por meio da individualização do modelo de acesso aos conteúdos interativos. Tendo em vista a individualidade do usuário que se evidencia, leva-se a considerar que a introdução dessa inovação pode resultar na (2) melhoria do processo produtivo de conteúdo, na (3) absorção dos conteúdos e (4) na forma como é atingido esse remodelado mercado consumidor. Além de possibilitar considerações conceituais a respeito desse novo modelo de usuário, visando atender suas atuais e futuras necessidades de consumo de informação e conteúdo televisivo.

Assim, acredita-se que, pela necessidade e importância que o usuário desenvolve no cenário atual, torna-se interessante a geração automatizada desse processo, a fim de aperfeiçoá-lo para a necessidade do usuário, dada a dinamicidade e multiplicidade de dispositivos com que ele interage em um sistema. De forma a contemplar o desenvolvimento deste trabalho, a fim de considerar tal necessidade, definiram-se os objetivos apresentados a seguir:

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Desenvolver um modelo de Hipermissão Adaptativa que una o formalismo das redes de autômatos estocásticos e metaheurísticas para geração de *layouts* de aplicações (Fig. 1);

Figura 1: Estrutura dos eixos de pesquisa



Fonte: Elaborado pelo autor

1.1.2 Objetivos Específicos

- Compor um modelo matemático para geração de *layout* de aplicações com base no perfil dos usuários e nas características dos dispositivos;
- Utilizar metaheurísticas como ambiente para interação com a rede de autômatos estocásticos, produzindo assim um modelo de aprendizagem e retenção de conhecimento;
- Demonstrar a efetividade do modelo, provando seu conceito, por meio da realização de experimentos com um protótipo computacional; e
- Verificar, a partir das experimentações, a dinâmica do modelo.

1.2 ORGANIZAÇÃO DO TRABALHO

O presente trabalho está organizado em sete capítulos, que refletem as fases do estudo desenvolvido para o tema que dá título ao trabalho, conforme o desenvolvimento das etapas que a pesquisa seguiu. O primeiro capítulo consiste na introdução, que descreve a área de estudo, fornecendo ao leitor a apresentação do objeto de pesquisa e sua contextualização, de modo a enaltecer a relevância do tema, bem como os objetivos a serem alcançados nesta pesquisa.

O segundo capítulo apresenta a revisão de literatura que versa a respeito de Hipermissão Adaptativa, apresentando-a e introduzindo conceitos de métodos e técnicas de adaptação, seguido dos principais modelos de referência para Sistemas de Hipermissão Adaptativa e trabalhos relacionados à geração de interfaces adaptativas.

O terceiro capítulo desenvolve-se sobre os conceitos de otimização combinatória, seguido da classificação das metaheurísticas que circundam a introdução dos métodos que serão utilizados no decorrer deste trabalho para solucionar o problema em questão.

O quarto capítulo consiste no aporte teórico sobre Redes de Autômatos Estocásticos, o qual incorpora as definições que o regem e o estabelecem, a fim de contribuir para a esfera dessa

questão. Assim, no desenvolvimento desse capítulo, aliado ao segundo e terceiro capítulos, foram estruturadas as bases que caracterizaram a composição do modelo proposto por meio de hipertômatos de aprendizagem.

O capítulo cinco sintetiza os resultados encontrados nos primeiros capítulos da pesquisa, relativos a Hipermissão Adaptativa, Metaheurísticas, Redes de Autômatos Estocásticos, Autômatos de Aprendizagem e Hipertômatos, os quais resultam na interface dos conteúdos. Os resultados são apresentados à luz da linguagem computacional do modelo, ou seja, apresenta-se a arquitetura e suas derivações, bem como a formulação matemática que regerá o modelo cunhado.

O processo de validação e experimentação realizado para corroborar a proposta é apresentado no capítulo seis. No capítulo sete estão as implicações e considerações finais, bem como a apresentação das potencialidades do modelo e os trabalhos futuros.

2 SISTEMAS HIPERMÍDIA: EVOLUÇÃO, CONCEITOS E CARACTERÍSTICAS

Este capítulo tem como foco o estudo das formas de adaptação hipermídia (modelos, técnicas e aplicativos) que podem ser empregados sob as mais diversas representações dos Sistemas de Hipermídia Adaptativa (SHA). Tais conceitos embasam o entendimento sob o qual o trabalho desenvolve-se, bem como delineiam o desenvolvimento do modelo proposto. As características expostas neste capítulo norteiam o entendimento dos conceitos e abstrações propostos pelas Redes de Autômatos Estocásticos no capítulo 4, onde se introduz o conceito de hipertômatos cuja abstração está intimamente ligada aos SHA.

O texto deste capítulo está organizado do seguinte modo:

- Na seção 2.1, são apresentados os fundamentos conceituais de hipermídia, bem como sua evolução histórica;
- A seção 2.2 introduz os Sistemas Hipermídia, abordando conceitos fundamentais aplicados a uma visão sobre as técnicas de adaptação, indo ao encontro da seção seguinte (seção 2.3), em que se diferem o adaptativo do adaptável;
- Na seção 2.4 é apresentado as formas de adaptação de conteúdo, apresentação e navegação;
- Na seção 2.5, de forma complementar, são apresentados os métodos e técnicas de adaptação;
- A seção 2.6 traz uma visão geral sobre os principais modelos de referência em SHA existentes, apresentando uma sequência evolutiva, destacando suas propriedades e características fundamentais;
- Por fim, na seção 2.7, é apresentada a geração de interfaces e as principais aplicações desenvolvidas.

2.1 EVOLUÇÃO

Para se compreender a evolução da representação e armazenamento de informações deve-se fazer uma retrospectiva da história da escrita, observando mudanças fundamentais que aconteceram na civilização quando o homem aprendeu a comunicar-se de novas maneiras. Com o desenvolvimento da fala, o homem tornou-se diferente dos outros animais, porque passou a transmitir ideias pela oralidade (LUPTON; MILLER, 1999). Quando a humanidade aprendeu a escrever, as ideias puderam ser armazenadas e preservadas para a posteridade, não ficando mais restritas à capacidade da memória pelo acúmulo e disseminação do conhecimento (CHARTIER, 2002; BURKE, 2004).

Historicamente, o primeiro registro escrito de que se tem conhecimento foi desenvolvido por volta do ano 3500 a.C. pelos sumérios na Mesopotâmia, sob forma de sulcos em blocos de argila. Posteriormente, foram diversos os suportes utilizados para facilitar a prática da escrita, tais como: peles de animais, cascas de árvores, papiros, folhas secas, entre outros. No entanto, foi somente a invenção do papel que promoveu a escrita, com sua manufatura por volta do século II a.C na China. Por volta do século VIII d.C. o papel foi difundido no Oriente Médio pelos árabes e sua produção deu-se pela primeira vez na Europa apenas no século XII (ONG, 1998).

Com a passagem da cultura oral para a escrita, as práticas foram modificadas devido às apropriações sociais e aos hábitos criados pelos indivíduos à medida que novos instrumentos foram surgindo (BUGAY; ULBRICHT, 2000; AQUINO, 2007). Aproximadamente, desde o século IX diversas alterações influenciaram as formas de ler, escrever, armazenar e recuperar informações, como livros, tabelas, sumários, etc. Nesse período, surgiram as primeiras manifestações de práticas hipertextuais, por meio da criação coletiva e não linear. Isso pode ser fortemente visualizado nos séculos XVI e XVII em manuscritos, *marginalia*¹, índices, notas de rodapé, etc. (LUPTON; MILLER, 1999; BURKE, 2004).

Nesse período, surgiram as primeiras manifestações de práticas hipertextuais, por meio da criação coletiva e não linear. Isso pode ser fortemente visualizado nos séculos XVI e XVII em manuscritos, *marginalia*¹, índices, notas de rodapé, etc. (LUPTON; MILLER, 1999; BURKE, 2004). Essas manifestações de escrita coletiva foram devidas aos copistas, que no processo de transcrição modificavam os textos, alterando, ordenando, inserindo e/ou removendo trechos. São esses processos individuais que conferem caráter não linear à leitura de cada indivíduo, já que cada um pode percorrer as anotações na ordem que desejar. A mesma possibilidade de leitura não linear das informações ocorre com índices, notas de rodapé e enciclopédias (LUPTON; MILLER, 1999; CHARTIER, 2002; BURKE, 2004).

Somente no século XVIII a invenção da imprensa permitiu a propagação de informações entre muitas pessoas, mas apenas por meio de transmissões de rádio difusão foi possível alcançar simultaneamente um amplo número de pessoas (BUGAY; ULBRICHT, 2000). Fragoso (2005, p. 1), afirma que o século XX foi o século da comunicação de massa, no qual a imprensa, o cinema, o rádio e a televisão desenvolveram-se sob o modelo irradiativo (um–muitos) de distribuição. No final dos anos 90 com a emergência da Comunicação Mediada por Computador (CMC), a popularização da Internet possibilitou a ocorrência de um modelo de comunicação muitos–muitos, estendendo-se a um número de pessoas sem precedentes.

As tentativas de organizar informações de forma conectada surgiram no século XX com a construção do *Memex* na publicação do ensaio *As We May Think*² de Vannevar Bush em 1945. Esse seria um dispositivo capaz de armazenar informações de forma conectada e que permitiria a inserção de dados pelos usuários. Após sua repercussão, diversos sistemas foram criados,

¹ Anotações feitas nas margens das páginas dos livros.

² BUSH, V. *As We May Think*. 1945. Disponível em: <<http://www.theatlantic.com/magazine/archive/1945/07/as-we-may-think/303881/>>. Acesso em: 15 de Fevereiro de 2013.

com destaque ao *Projeto Xanadu*³ proposto por Ted Nelson, que cunhou o termo Hipertexto. O *Projeto Xanadu*, tornou-se útil como sistema de representação e recuperação de informações, diferindo-se de outros sistemas semelhantes pela velocidade e interconexão.

Desde então, notórios foram os avanços em pesquisas e no desenvolvimento de sistemas e ferramentas de interação. Na década de 80, diversas alternativas surgiram, como o *Intermedia*⁴, o *Neptune*⁵, o *Guide*⁶, o *NoteCards*⁷, entre outros, que também possibilitavam aos leitores a inserção de anotações em seus registros. No entanto, somente em 1990, com a proposição da *web* por Tim Berners-Lee⁸, que o Hipertexto se consolidou em um ambiente propício para sua concretização nos moldes originais de criações coletivas e não lineares.

Como se pôde ver, a escrita hipertextual passou por diferentes momentos nas suas formas de construção com relação à participação do usuário: primeiro, com os textos impressos; depois, com o advento da *web*; e, atualmente, com a *web 2.0* (PRIMO; RECUERO, 2006). Com a evolução de interfaces físicas (*hardware*) e interfaces gráficas (*software*), áreas como a Computação Ubíqua e a Hipermedia Adaptativa convergem juntamente com o modelo hipertextual, fazendo uso da criação e colaboração coletiva, mas com olhar sobre a personalização individualizada por meio de modelos de usuário e de grupos.

Nos últimos anos, observa-se o crescente aumento em pesquisas relacionadas a hipertexto, multimídia e hipermedia, sendo a última, uma área fundamentalmente importante, com potencial revolucionário no desenvolvimento e sofisticação da usabilidade das aplicações. Os sistemas hipermedia são a base das pesquisas em Sistemas de Hipermedia Adaptativa, ambos com desenvolvimento fundamentado sobre o conceito de hipertexto, visam atender às novas exigências das aplicações e usuários em sua individualidade.

³NELSON, T. **Xanadu Project**. 1960. Disponível em: <<http://www.xanadu.com/>>. Acesso em: 20 de Setembro de 2012.

⁴MEYROWITZ, N. *Intermedia: The architecture and construction of an object-oriented hypemedia system and applications framework*. **SIGPLAN Not.**, ACM, New York, NY, EUA, v. 21, n. 11, p. 186–201, Junho 1986. ISSN 0362-1340. Disponível em: <<http://doi.acm.org/10.1145/960112.28716>>. Acesso em: 12 de Novembro de 2012., GARRETT, L. N.; SMITH, K. E.; MEYROWITZ, N. *Intermedia: issues, strategies, and tactics in the design of a hypermedia document system*. In: **Proceedings of the 1986 ACM conference on Computer-supported cooperative work**. New York, NY, EUA: ACM, 1986. (CSCW '86), p. 163–174. Disponível em: <<http://doi.acm.org/10.1145/637069.637090>>. Acesso em: 12 de Novembro de 2012.

⁵DELISLE, N.; SCHWARTZ, M. *Neptune: a hypertext system for cad applications*. **Tektronix Computer Research Laboratory**, p. 132 – 143, 1986. Disponível em: <<http://delivery.acm.org/10.1145/20000/16867/p132-delisle.pdf>>. Acesso em: 24 de Janeiro de 2013.

⁶BROWN, P. J. *Turning ideas into products: the guide system*. In: **Proceedings of the ACM conference on Hypertext**. New York, NY, EUA: ACM, 1987. (HYPERTEXT '87), p. 33–40. ISBN 0-89791-340-X. Disponível em: <<http://doi.acm.org/10.1145/317426.317430>>.

⁷HALASZ, F. G. *Reflections on notecards: seven issues for the next generation of hypermedia systems*. In: **Proceedings of the ACM conference on Hypertext**. New York, NY, EUA: ACM, 1987. (HYPERTEXT '87), p. 345–365. ISBN 0-89791-340-X. Disponível em: <<http://doi.acm.org/10.1145/317426.317451>>. Acesso em: 12 de Novembro de 2012.

⁸BERNERS-LEE, T. **Tim Berners-Lee**. 1990. Disponível em: <<http://www.w3.org/History/1989/proposal.html>>. Acesso em: 15 de Fevereiro de 2013.

2.2 SISTEMAS DE HIPERMÍDIA ADAPTATIVA

As primeiras pesquisas em Hipermissão Adaptativa iniciaram em meados dos anos 1990, compartilhando interesses das áreas de Hipermissão e Inteligência Artificial. Os Sistemas de Hipermissão Adaptativa (SHA) podem ser definidos como sistemas que proporcionam diferentes aspectos de adaptação e estabelecem um modelo individual de usuário. Estuda-se esse tema no desenvolvimento de técnicas e métodos que promovam a adaptação de diversos aspectos visíveis de hiperdocumentos e hipermissão. Tais processos são baseados na construção de perfis individuais feitos da coleta de informações sobre o usuário durante seu uso da aplicação (BRUSILOVSKY, 1996b; PALAZZO, 2000; WU; HOUBEN; BRA, 2004).


De acordo com Koch (2000, p.11), os Sistemas de Hipermissão Adaptativa devem minimamente satisfazer três critérios básicos:

- Ser um Sistema Hipertexto ou Hipermissão;
- Possuir um Modelo de Usuário (MU); e
- Poder adaptar o Sistema Hipermissão a partir desse modelo de usuário.

Pode-se ver na Figura 2 o ciclo clássico descrito por Brusilovsky (1996b, p. 88) e por Palazzo (2000, p. 31), em que o Sistema Hipermissão Adaptativo coleta informações sobre o comportamento do usuário, atualiza seu modelo individual e, com esses novos dados, gera o efeito de adaptação da apresentação e do conteúdo.

Com base no ciclo clássico de adaptação, desenvolve-se a arquitetura proposta neste trabalho. Tal construção é feita por meio de uma reconfiguração dos módulos, onde são reapresentados sob o conjunto das técnicas aqui estudadas.

Figura 2: Ciclo clássico de adaptação do Modelo de Usuário em sistemas adaptativos



Fonte: Adaptado de (PALAZZO, 2000, p. 31), (BRUSILOVSKY, 1996b, p. 88),

2.3 SISTEMAS DE HIPERMÍDIA ADAPTATIVA E ADAPTÁVEL

Koch (2000, p. 12) propõe uma clara distinção entre Sistemas Hipermissão que são personalizáveis – ditos Sistemas Adaptáveis – e Sistemas Hipermissão Adaptativos. Em ambos os casos, o usuário desempenha o papel central e seu objetivo é oferecer um sistema personalizado, no entanto diferem-se no modo como a adaptação é realizada.

O sistema hipermissão adaptável é a categoria de sistemas que permitem ao usuário configurá-lo definindo parâmetros e diretrizes, para que, então, o sistema adapte-se. Isso se dá pelo cadastramento inicial utilizado para inicializar o modelo ou pela ação direta do usuário. É uma adaptação externa, ou seja, o usuário decide quando seu modelo de usuário deve ser atualizado (KOCH, 2000; BUGAY, 2006; DE BRA, 1998).


Um sistema hipermissão adaptativo é uma categoria de sistemas hipermissão que se adapta de forma autônoma. Funcionam baseados no monitoramento do comportamento do usuário. Os dados obtidos são armazenados no modelo de usuário para assim o sistema adaptar-se de forma dinâmica de acordo com o estado atual do modelo de usuário. O sistema utiliza interações ativas e passivas para adquirir informações do usuário para alimentar o modelo e adaptar-se. Possuem, de certo modo, inteligência, no sentido da compreensão das necessidades do usuário e atuação no processo de customização da aplicação (KOCH, 2000; BUGAY, 2006; DE BRA, 1998).

Segundo De Bra (1998, p. 221), a maior parte dos Sistemas de Hipermissão Adaptativa possuem tanto características adaptáveis como adaptativas, seja pelo processo de inicialização do modelo do usuário por captação ativa, ou pela ação do sistema modificando o modelo de usuário quando julgar necessário. Atualmente, grande parte das aplicações de hipermissão adaptativa concentra-se na área de hipermissão educacional, dadas as facilidades de construção de modelos de usuário (PATERNO; MANCINI, 1999).

2.4 O QUE PODE SER ADAPTADO

Os Sistemas de Hipermissão Adaptativa estão distribuídos em seis grandes áreas de aplicação: (1) sistemas educacionais, (2) sistemas de informações *on-line*, (3) sistemas de ajuda *on-line*, (4) recuperação de informações, (5) sistemas institucionais e (6) personalização de visões em espaços de informações (BRUSILOVSKY, 1996b). Frente às diferentes áreas e seus diversos processos de adaptação, Brusilovsky (2001, p. 100) denominou tais possibilidades de adaptação como Espaços de Adaptação, caracterizando-os em duas classes: Apresentação Adaptativa (em nível de conteúdo) e Navegação Adaptativa (em nível de *link*). Na Figura 3, veem-se os métodos e técnicas de adaptação propostos pelo autor.

Figura 3: Espaços de Adaptação




Fonte: Adaptado de (BRUSILOVSKY, 2001, p. 100)

Brusilovsky (1996b) não efetua separação entre o conteúdo e sua apresentação, mas os mantém sob o mesmo Espaço de Adaptação. Já Koch (2000, p. 18) classifica as possibilidades de adaptação de forma independente, principalmente como os métodos e técnicas são usados em cada domínio de aplicação. Assim, Koch (2000) designou-os em três níveis, que são:

- **Conteúdo Adaptativo:** seleção de informações, textos, sons e imagens de acordo com o modelo de usuário utilizado;
- **Apresentação Adaptativa:** arranjo visual para apresentação do conteúdo na interface; e
- **Navegação Adaptativa:** orientação ao usuário quanto à sua localização no hiperespaço e direcionamento ou orientação quanto ao percurso a ser seguido.

A Figura 4 destaca os níveis de adaptação de conteúdo e apresentação propostos por Koch (2000), com os respectivos métodos e técnicas.

Figura 4: Métodos e Técnicas de Adaptação



Fonte: Adaptado de (VASQUEZ, 2006, p. 157)

* Métodos e técnicas equivalentes ao apresentado na Figura 3.

2.5 MÉTODOS E TÉCNICAS DE ADAPTAÇÃO

Os métodos de adaptação foram qualificados como abstrações de técnicas de adaptação definidos a nível conceitual. Já as técnicas de adaptação são definidas por uma representação do modelo de utilizador e um algoritmo de adaptação, fazendo parte do nível de implementação (VASQUEZ, 2006). Conceitualmente, afirma-se que um método de adaptação pode ser implementado por meio de diferentes técnicas, e uma técnica pode ser usada para implementar mais de um método (BRUSILOVSKY, 1996b).

Os métodos e técnicas definidos por Brusilovsky (1996a, 1996b, 1998, 2001) são referenciados similarmente por vários autores, como Palazzo (2000), Koch (2000), Bugay (2006), entre outros. A seguir, são descritos os métodos e técnicas em cada nível de adaptação (conteúdo, navegação e apresentação), a fim de distingui-los com base nas definições apresentadas *a priori*.

2.5.1 Conteúdo Adaptativo

O conteúdo adaptativo objetiva adaptar o conteúdo acessado por um determinado usuário aos conhecimentos e objetivos definidos em seu modelo de usuário. Por exemplo, um usuário avançado receberá informações mais profundas e detalhadas, enquanto um iniciante terá explicações adicionais sobre determinado assunto (PALAZZO, 2000).

2.5.1.1 Métodos de Conteúdo Adaptativo

Os métodos de adaptação de conteúdo (Tabela 1) permitem aumentar a usabilidade de uma aplicação para um grupo amplo de usuários com variados graus de experiência sobre o assunto (BUGAY, 2006). Esses métodos permitem fornecer conteúdos adicionais, comparativos ou alternativos ou mesmo ocultar partes dos conteúdos (KOCH, 2000).

Tabela 1: Métodos de Conteúdo Adaptativo

Métodos	Descrição
(EA) Explicação Adicional	Consiste em mostrar somente partes da informação e ocultar o que não é relevante de acordo com o nível de conhecimento do usuário: suas metas, interesses ou preferências.
(ER) Explicação Requerida	O sistema apresenta informações adicionais à informação requerida, em que a primeira informação apresentada é pré-requisito para a seguinte. Quando uma informação apresentar a explicação de um conceito, o sistema insere a explicação de todos os conceitos requeridos para o seu entendimento.
(EC) Explicação Comparativa	Na medida em que são apresentados conceitos similares aos de domínio do usuário, uma explicação comparativa é utilizada para apresentar o novo conceito.
(EV) Explicação Variante	O sistema armazena variantes do conteúdo de uma página, de forma que o usuário receba as informações mais adequadas a seu modelo de usuário.
(CF) Classificação de Fragmentos	Considerando as características armazenadas no modelo de usuário, o sistema ordena fragmentos de informação do conteúdo, de modo que informações mais relevantes sejam apresentadas primeiro.

Fonte: Elaborado pelo autor com base em Brusilovsky (1996b), Palazzo (2000), Koch (2000), Bugay (2000, 2006) e Puga (2008)

2.5.1.2 Técnicas de Conteúdo Adaptativo

As técnicas para adaptação de conteúdo (Tabela 2) permitem manipular o conteúdo de forma a adaptá-lo às características do usuário (BUGAY, 2006). No conteúdo de uma página, não só pode-se adaptar o texto, mas as técnicas também podem igualmente ser aplicadas a diferentes conteúdos multimídia (BRUSILOVSKY, 1996b).

Tabela 2: Técnicas de Conteúdo Adaptativo

Técnicas	Descrição
(CT) Texto Condicional	As informações são divididas em vários pedaços de texto e cada um está associado a uma condição de nível de conhecimento do usuário baseado em características armazenadas em seu MU, ou seja, o sistema apenas mostra partes onde a condição estabelecida é satisfeita.
(ST) <i>Stretchtext</i>	Organiza o conteúdo com base em uma variação de hipertexto, em que os <i>links</i> podem ser expandidos e/ou contraídos a partir de uma palavra ou frase-chave. A determinação por parte do sistema de qual elemento será alterado se dá com base no MU.
(FV) Fragmentos Variantes	Uma página pode apresentar vários conceitos, possuindo vários FV e exibindo-os na combinação que melhor satisfaça os conhecimentos do usuário, de acordo com suas características no MU.
(PV) Páginas Variantes	Essa técnica mantém mais de uma alternativa para cada conceito, exibindo-as de formas diferentes, adaptadas às classes de usuários.
(FR) <i>Frames</i>	Os <i>frames</i> são estruturas de atributos e valores armazenados em <i>slots</i> , que podem conter EV e/ou FV sobre o conceito, <i>links</i> para outros <i>frames</i> , exemplos, etc. Nessa técnica, permite-se a inclusão de toda informação relacionada em um <i>frame</i> . A seleção dos <i>slots</i> dá-se por meio de regras de apresentação armazenadas no MU, que decidem quais <i>slots</i> de um determinado frame serão apresentados e em que ordem.

Fonte: Elaborado pelo autor com base em Brusilovsky (1996b, 2001), Palazzo (2000), Koch (2000), Bugay (2000, 2006) e Puga (2008)

A Tabela 3 mostra quais técnicas podem ser combinadas e usadas para implementação de cada método de adaptação de conteúdo.

Tabela 3: Relação de métodos e técnicas para Adaptação de Conteúdo

		Técnicas				
		Texto Condicional	<i>Stretchtext</i>	Fragmentos Variantes	Páginas Variantes	<i>Frames</i>
Métodos	Explicação Adicional	X	X	X		X
	Explicação Requerida	X	X	X		X
	Explicação Comparativa	X	X	X		X
	Explicação Variante	X		X	X	X
	Classificação de Fragmentos	X		X	X	X

Fonte: Adaptado de (KOCH, 2000, p. 21)

2.5.2 Apresentação Adaptativa

Segundo Koch (2000, p. 24), o objetivo da adaptação ao nível de apresentação é ajustar o layout às preferências visuais ou necessidades do usuário e, usualmente, tais mudanças acontecem em conjunto com as adaptações de conteúdo.

2.5.2.1 Métodos de Apresentação Adaptativa

Os métodos de adaptação da apresentação efetuam modificações no *layout* e no conteúdo da aplicação mostrado ao usuário. Na Tabela 4, são apresentados os métodos descritos por (PALAZZO, 2000; KOCH, 2000; KOCH; ROSSI, 2002).

Tabela 4: Métodos de Apresentação Adaptativa

Métodos	Descrição
(MI) Multi-Idioma	Este método consiste em adaptar a página para um idioma, com base nas preferências ou no contexto do usuário.
(LV) <i>Layout</i> Variante	Este método consiste de possíveis e necessárias alternativas de apresentação, como cores, tipos e tamanhos de fontes, tamanhos de imagens, orientações de textos, ordenações dos fragmentos de conteúdos, etc. de acordo com as preferências do usuário.

Fonte: Elaborado pelo autor com base em Kock (2000), Bugay (2000, 2006) e Puga (2008)

2.5.2.2 Técnicas de Apresentação Adaptativa

De acordo com Brusilovsky (1996b, p. 100), as técnicas de apresentação adaptativa propõem ajustar o conteúdo de uma página de acordo com o conhecimento, objetivos e características do usuário. Apresentação Adaptativa é o termo geral para todas as técnicas que adaptam o conteúdo hipermídia de acordo com o Modelo do Usuário e que podem ser distinguidas como:

- **Apresentação Adaptativa de Texto:** em função do modelo de usuário, o conteúdo textual pode ser alterado, evitando termos complexos para iniciantes. Da mesma forma, para usuários avançados, detalhes adicionais podem ser fornecidos, pois estes estão capacitados para compreendê-los (BUGAY, 2006). Na Tabela 5, são apresentadas as técnicas de adaptação de texto.

Tabela 5: Técnicas de Apresentação Adaptativa

Técnicas	Descrição
(VP) Variações de Páginas	Essa técnica mantém mais de uma versão da página, ajustando o estereótipo do SHA quando sua variação é limitada.
(VF) Variações de Fragmentos	Uma página pode ter diferentes versões de fragmentos, que são exibidos quando melhor satisfaçam as necessidades do usuário de acordo com suas características no MU.
(BF) Baseado em <i>Frame</i>	Por meio de técnicas de linguagem natural, as páginas são montadas a partir de pequenos itens de informação como palavras e partes de sentenças.
(GE) Guia de Estilos	Consiste na definição de diferentes estilos que são usados alternadamente para diferentes <i>layouts</i> .

Fonte: Elaborado pelo autor com base em Brusilovsky (1996b) e Bugay (2006)

- **Apresentação Multimídia Adaptativa:** embora o termo sugira que a multimídia contenha elementos que possam ser adaptados, as atuais implementações limitam-se apenas à seleção da mídia. Diferentemente do texto, o conteúdo de animações, áudios ou fragmentos de vídeos não podem ser adaptados (BUGAY, 2006).

A Tabela 6 mostra quais técnicas podem ser combinadas e usadas para implementação de cada método de adaptação da apresentação.

Tabela 6: Relação de métodos e técnicas para Adaptação da Apresentação

		Técnicas			
		Variações de Páginas	Variações de Fragmentos	Baseado em Frame	Guia de Estilos
Métodos	Multi-Idioma	X	X	X	
	Layout Variante	X	X	X	X

Fonte: Adaptado de (KOCH, 2000, p. 25)

2.5.3 Navegação Adaptativa

A ideia por trás das técnicas de apoio à navegação adaptativa é auxiliar os usuários a encontrar seus caminhos no hiperespaço, adaptando a forma como os *links* são apresentados, de acordo com seus objetivos, conhecimentos e demais características definidas no modelo de usuário. Essa adaptação consiste em modificar as estruturas de navegação ou a forma como essa estrutura é apresentada ao usuário (BRUSILOVSKY, 1996b; KOCH, 2000).

2.5.3.1 Métodos de Navegação Adaptativa

Os métodos de navegação adaptativa (Tabela 7) auxiliam os usuários a encontrar caminhos no hiperespaço, por meio da adaptação da forma como são apresentados os *links* na rede hipermídia, de acordo com seus objetivos, conhecimentos e características armazenadas no MU (PALAZZO, 2000).

Tabela 7: Métodos de Navegação Adaptativa

Métodos	Descrição
(CG) Condução Global	Esse método objetiva auxiliar o usuário a encontrar o caminho mais curto para a informação desejada, minimizando possíveis desvios “indesejados”. Ocorre quando se possui algum objetivo global de informação, que se encontra em um ou mais nós, localizados em algum lugar do hiperespaço. A cada passo da navegação, os <i>links</i> mais apropriados para os nós seguintes são classificados por ordem de importância.
(CL) Condução Local	De forma similar a CG, esse método possui alcance menor e preocupa-se com um único passo de navegação, tentando sugerir ao usuário os <i>links</i> mais relevantes, com base em suas preferências, conhecimentos e experiências.
(OL) Orientação Local	Esse método auxilia o usuário a entender seu posicionamento na rede do hipertexto local, correspondente ao domínio do sistema.
(OG) Orientação Global	O objetivo desse método é auxiliar o usuário na compreensão da estrutura do hiperespaço, que constitui o domínio de navegação do sistema. O método mais amplamente utilizado é aumentar gradualmente o número de <i>links</i> visíveis à medida que cresce o domínio do usuário no hiperespaço considerado.
(CP) Customização Personalizada	Consiste na utilização de agentes capazes de gerar e atualizar visualizações personalizadas do hiperespaço, por meio da localização de <i>links</i> apropriados ao usuário, mantendo, dessa maneira, a visualização personalizada. Esses agentes executam pesquisas regulares na <i>web</i> , buscando novos <i>links</i> relevantes para cada usuário e verificando a expiração ou atualização ocorrida nos <i>links</i> coletados anteriormente.

Fonte: Elaborado pelo autor com base em Palazzo (2000), Bugay (2000, 2006) e Puga (2008)

2.5.3.2 Técnicas de Navegação Adaptativa

As técnicas de adaptação da navegação (Tabela 8) permitem manipular âncoras e *links* com o objetivo de adaptar a navegação dinamicamente às características do usuário, definidas pelo estado atual do modelo de usuário, ou seja, são usados para implementar os métodos acima mencionados (KOCH, 2000).

Tabela 8: Técnicas de Navegação Adaptativa

Técnicas	Descrição
(OD) Orientação Direta	Consiste na decisão em cada ponto da navegação, qual o melhor nó a ser visitado na sequência, considerando o MU. O sistema pode destacar visualmente o <i>link</i> para o melhor nó ou apresentar um <i>link</i> dinâmico adicional.
(CA) Classificação Adaptativa	Esta técnica classifica todos os <i>links</i> em ordem decrescente de relevância para o usuário, com base nos dados do seu MU. De acordo com Brusilovsky (1996b, p. 102), esta técnica deve ser empregada de forma limitada, pois funciona bem apenas em <i>links</i> não contextuais, pois cada vez que o usuário entrar na mesma página, a ordem dos <i>links</i> pode ser diferente de acordo com o estado atual do MU.
(AO) Ocultação Adaptativa	Esta técnica consiste em restringir o espaço de navegação, para evitar um excesso de <i>links</i> disponíveis para o usuário, desta forma o SHA oculta ou desativa <i>links</i> para nós não relevantes. A utilização desta técnica permite preservar o usuário da amplitude do hiperespaço, reduzindo desta forma a carga cognitiva que recai sobre ele.
(AA) Anotação Adaptativa	Os <i>links</i> podem ser comentados a fim de indicar sua relevância, oferecendo assim informações sobre o estado atual do que está por trás deles. As anotações de <i>links</i> podem ser fornecidas na forma textual ou na forma de sinais visuais, utilizando ícones, cores, tamanhos e tipos de fonte diferenciados.
(MA) Adaptação de Mapas	Esta técnica compreende diversas formas de adaptação de mapas de hipermídia global e local mostrados ao usuário. O mapa apresentado pode ser filtrado adaptativamente para apresentar uma visão geral manejável das partes do hiperdocumento relevantes para o usuário.
(NP) Navegação Passiva	Consiste na adição de <i>links</i> não explícitos (sem âncoras) que são utilizados pelo sistema para oferecer assistência ao usuário quando o sistema identifica um padrão de comportamento do usuário.

Fonte: Elaborado pelo autor com base em Brusilovsky (1996b, 2004), Kock (2000), Palazzo (2000), Bugay (2000, 2006) e Puga (2008)

A Tabela 9 mostra quais técnicas podem ser combinadas e usadas para implementação de cada método de adaptação da navegação.

Tabela 9: Relação de métodos e técnicas para Adaptação da Navegação

		Técnicas					
		Orientação Direta	Classificação Adaptativa	Ocultação Adaptativa	Anotação Adaptativa	Adaptação de Mapas	Navegação Passiva
Métodos	Condução Global	X	X			X	X
	Condução Local	X	X	X	X	X	X
	Orientação Local		X	X	X	X	
	Orientação Global			X	X	X	
	Visualização Personalizada	X	X	X	X	X	X

Fonte: Adaptado de (KOCH, 2000, p. 24)

2.6 MODELOS DE REFERÊNCIA EM HIPERMÍDIA ADAPTATIVA

Os modelos de referência são formalismos para representação de sistemas. No domínio da hipermídia, podem ser vistos como uma variação do paradigma de nós e *links*, em que a não linearidade na organização das informações compõe a essência dos ambientes (CONKLIN, 1987). Segundo Ullman (1989, p. 32), um modelo de dados pode ser definido como um formalismo matemático em duas partes: (1) uma notação para descrever os dados; e (2) um conjunto de operações para manipular os dados.

Diversas linguagens podem ser utilizadas para a descrição de modelos de dados por meio de métodos formais, como notação de conjuntos, grafos, diagrama de blocos, UML, etc. A gama de representações é tão diversa quanto os próprios modelos e comumente incluem primitivas básicas de edição, manipulação e visualização de dados e objetos de dados (BOONE, 1992).

Esta seção apresenta, em ordem cronológica de proposição, os principais modelos de referência da área de hipermídia adaptativa encontrados na literatura, os quais embasaram o desenvolvimento do modelo proposto nesta pesquisa, sendo eles:

- *Hypertext Abstract Machine - HAM* (1987);
- *Trellis Model of hypertext* (1989);
- *Dexter Reference Model* (1990);
- *Tower Model* (1992);
- *Amsterdam Hypermedia Model - AHM* (1994);


- *Adaptive Hypermedia Application Model - AHAM* (1998).
- *Munich Reference Model* (2000).

2.6.1 Hypertext Abstract Machine – HAM

Uma das primeiras abordagens sobre a implementação de modelos genéricos de hipertexto foi o *Hypertext Abstract Machine* (HAM), fundamentado na transação multiusuário e baseado no mecanismo abstrato do sistema *Neptune* (BUGAY, 2006).

Na Figura 5, pode-se observar a organização do modelo HAM, que gerencia e armazena todas as informações gráficas ou de banco de dados em sistemas de arquivos centralizados, que podem ser acessados em ambientes distribuídos. As aplicações normalmente se comunicam através da interface de usuário, que podem ser baseadas em janelas e altamente interativas, fornecendo um ambiente propício a um sistema de hipertexto (CAMPBELL; GOODMAN, 1987).

Figura 5: Arquitetura do Modelo HAM



Fonte: Tradução nossa de (CAMPBELL; GOODMAN, 1987, p. 22)

O modelo HAM é composto de cinco tipos de objetos: gráficos, contextos, nós, *links* e atributos. O modelo mantém um histórico para os objetos, o que permite acesso seletivo por meio de mecanismos de filtragem e de restrições de acesso via mecanismos de segurança de dados. Os objetos do HAM estão organizados hierarquicamente e possuem as seguintes características (CAMPBELL; GOODMAN, 1987):

- **Gráficos:** os gráficos são objetos de alto nível e normalmente contém toda a informação relativa a um tópico geral. Um objeto gráfico pode conter um ou mais contextos;
- **Contextos:** os contextos visam separar os dados dentro de um objeto gráfico. Cada contexto tem um contexto pai e zero ou mais contextos filhos. Quando um objeto gráfico é criado, um contexto raiz inicia a árvore. Um contexto contém zero ou mais nós e *links* e não depende da informação contida no contexto pai;

- **Nós:** os nós contêm dados arbitrários que podem ser armazenados como texto ou blocos binários de comprimento fixo. Quando um nó é atualizado, uma nova versão desse nó é criada, usando o novo conteúdo. Caso o nó já contenha dados, a versão anterior é armazenada para permitir uma futura recuperação, caso seja necessário. O conteúdo de um nó pode ser pesquisado e o mecanismo de busca permite que todas as versões do nó sejam pesquisadas (BUGAY, 2006);
- **Links:** os *links* definem a relação entre um nó fonte e um de destino e pode seguir em ambas as direções. Um *link* de contexto cruzado relaciona dois nós em diferentes contextos e é utilizado para o compartilhamento de dados entre dois contextos;
- **Atributos:** os atributos podem ser anexados a contextos, nós ou *links*. Os valores dos atributos podem ser *strings*, inteiros, decimais ou tipos definidos pelo usuário. Os pares atributo-valor fornecem a semântica dos objetos do HAM e podem representar propriedades específicas da aplicação dos objetos ou conter informações que o descrevam.

O Modelo HAM fornece um mecanismo automático de versionamento do histórico que atualiza cada vez que um objeto é alterado (CAMPBELL; GOODMAN, 1987). As diversas versões de um objeto podem ser acessadas e o sistema permite ainda eliminar versões indesejadas (BUGAY, 2006). Por meio de filtros, permite extrair subconjuntos de objetos a partir de grandes objetos gráficos, com base em parâmetros de procura especificados pelo usuário. O sistema de filtragem do HAM permite acessar os seguintes itens (CAMPBELL; GOODMAN, 1987):

- Contextos em um gráfico;
- Nós em um contexto;
- *Links* em um contexto;
- Instâncias de um nó em contextos especificados;
- Instâncias de um *link* em contextos especificados;
- Um conjunto de nós e *links* em contextos especificados baseados na ordenação de um *link* específico.


O mecanismo de segurança de dados define os usuários que tem acesso e seus níveis de permissão (acesso, anotação, atualização e remoção de objetos). Devido a seu mecanismo de hipertexto de propósito geral, esse modelo se aplica a muitos tipos de sistemas de hipertexto, sendo testado com sucesso em sistemas como *Guide*, *Intermedia* e *NoteCards* (BALASUBRAMANIAN, 1994).

2.6.2 Trellis Model of hypertext

O modelo Trellis de hipertexto foi desenvolvido com base em redes de Petri e aborda a semântica e estrutura da Interação Humano-Computador (IHC) no contexto dos Sistemas Hipertexto e Hipermídia, navegadores, programação visual e processo de modelagem (STOTTS; FURUTA, 1989a, 1993). Com base nesse sistema, foi deduzido um meta-modelo, nomeado de Modelo Trellis de Referência para Hipertexto, abreviadamente *Modelo-r* (FURUTA; STOTTS, 1990).

Esse modelo foi desenvolvido com cinco níveis lógicos, que possuem uma ou mais representações de parte ou de todo o hipertexto. Diferentemente de outros modelos, os níveis não representam componentes do sistema, mas níveis de abstração. Esses níveis de abstração foram agrupados em três categorias: abstrato, concreto e visível, como se pode observar na Figura 6 (STOTTS; FURUTA, 1993; BALASUBRAMANIAN, 1994).

Figura 6: Arquitetura do Modelo Trellis



Fonte: Tradução nossa de (FURUTA; STOTTS, 1990, p. 181)

- **Nível Abstrato:** esse nível é constituído de componentes abstratos definidos de maneira independente e que são interconectados da mesma forma. Não descreve os detalhes da apresentação;

- **Nível Concreto:** representações concretas em que as características da exibição do hipertexto foram estabelecidas. Isto é, o conteúdo de cada janela é especificado, mas não definido; e
- **Nível Visível:** esse nível é responsável pelo *layout* e apresentação da rede de hipertexto na visualização.

A descrição de um hipertexto abstrato especifica a estrutura lógica e a forma do hipertexto de seus componentes, no entanto, não descreve como o hipertexto será apresentado ao usuário (FURUTA; STOTTS, 1990).

- **Nível Abstrato do Componente:** a representação nesse nível apresenta os componentes que serão associados para formar o hipertexto. Dentro desse nível, as representações são independentes umas das outras e, como associações, serão feitas em níveis baixos de abstração. Em outras palavras, a estrutura é separada do conjunto de conteúdos que será apresentada ao usuário e do conjunto de elementos que serão selecionados pelo usuário durante a navegação;
- **Nível Abstrato do Hipertexto:** os elementos do Nível Abstrato do Componente não estão interconectados como necessário para formar o hipertexto. Essa associação é realizada no Nível Abstrato do Hipertexto. Entretanto, esse nível não descreve como essas associações serão apresentadas na visualização do hipertexto, o que ocorre no Nível Concreto do Contexto;
- **Nível Concreto do Contexto:** a descrição abstrata do hipertexto define a associação entre o conteúdo e a estrutura, mas não indica como os *links* serão exibidos no dispositivo. Tais considerações sobre o mapeamento da representação abstrata do hipertexto para sua representação física são abordadas nesse nível;
- **Nível Concreto do Hipertexto:** esse nível define um conjunto de elementos concretos nos quais a representação concreta do conteúdo foi fundida com representações concretas dos botões, mapeando-as em um grupo de janelas para serem visualizadas; e
- **Nível Visível do Hipertexto:** esse nível especifica os detalhes do mapeamento do hipertexto concreto para a apresentação do hipertexto para o usuário final, ou seja, determinam-se quais elementos serão exibidos ou não para o usuário.


Esse modelo está baseado na organização, categorização e relação dos componentes e funções do hipertexto, funcionalidades inerentes também a outros domínios, o que faz do Modelo Trellis um guia de alto nível, pois separa estrutura, conteúdo e contexto, permitindo reuso flexível do hipertexto (FURUTA; STOTTS, 1990).

2.6.3 *Dexter Reference Model*

O modelo Dexter foi o primeiro modelo de referência conceituado, desenvolvido com base em sistemas de hipertexto. Mesmo não contemplando a adaptatividade em sistemas hipermídia, embasou grande parte dos modelos atuais, pois foi precursor da orientação a objetos em metodologias para hipermídia (AMARAL, 2008).

Pode-se ver na Figura 7 que o modelo Dexter divide-se em três camadas. A camada de execução descreve os mecanismos de apoio à interação do usuário com o hipertexto. A camada de armazenamento descreve a rede de nós e *links*, a essência do hipertexto. A camada interna dos componentes abrange o conteúdo e estruturas dentro dos nós de hipertexto (HALASZ; SCHWARTZ, 1990).

Figura 7: Arquitetura do Modelo Dexter



Fonte: Tradução nossa de (HALASZ; SCHWARTZ, 1990, p. 4)

2.6.4 *Tower Model*

Em 1992, na Quarta Conferência de Hipertexto, Paul De Bra, G. J. Houben e Y. Kornatzky apresentaram um novo modelo de dados para hiperdocumentos orientados a objetos. Esse modelo foi denominado de *Extensible Data Model for Hyperdocuments*⁹ e se popularizou como *Tower Model*.

Usando construtores, o modelo *Tower* (Figura 8) oferece um nível de interface que suporta a integração de diferentes fontes de informação e, adicionalmente, a criação de estrutu-


⁹Tradução livre: Modelo de Dados Extensível para Hiperdocumentos

ras virtuais ou computacionais de descrições desses componentes. Esse modelo descreve os elementos conceituais que podem ser encontrados em um Sistema Hiperídia. Geralmente, a grande maioria adere a essa composição (GARCIA-CABRERA; RODRIGUEZ-FORTIZ; PARETS-LLORCA, 2001):

- a primeira camada, os nós, *links* e âncoras, são representados separadamente. Podem incluir também nós compostos, estruturas simples e compostas;
- a segunda camada mapeia o *front-end* ou os elementos do Sistema Hiperídia com os modelos, variáveis e cálculos do *back-end* ou objetos da aplicação; e
- por fim, o nível de representação da estrutura da Hiperídia por meio da interface do usuário.

Esse modelo de dados é baseado em programação orientada a objetos. Dessa forma, as entidades que compõem a aplicação hiperídia são compostas de objetos com um comportamento e estado associados (DE BRA; HOUBEN; KORNATZKY, 1992).

Figura 8: Arquitetura do Modelo Tower



Fonte: Tradução nossa de (DE BRA; HOUBEN; KORNATZKY, 1992, p. 226)


2.6.5 *Amsterdam Hypermedia Model – AHM*

Proposto por Hardman, Bulterman e Rossum, em 1994, o *Amsterdam Hypermedia Model* foi desenvolvido da combinação do modelo Dexter com o modelo *CMIF Multimedia Document Model*, adicionando restrições de temporização e contextualização de *links* (HARDMAN; BULTERMAN; ROSSUM, 1994).

Pode-se observar a estrutura de dados conceituais para um elemento atômico (Figura 9(a)) e para um componente composto (Figura 9(b)). O componente atômico contém meta-informações que referenciam um determinado bloco de informações, e o componente composto

é responsável pela definição de tais informações para uma coleção de componentes atômicos ou blocos de componentes compostos (HARDMAN; BULTERMAN; ROSSUM, 1994).

Figura 9: Arquitetura do Modelo Amsterdam



Fonte: Tradução nossa de (HARDMAN; BULTERMAN; ROSSUM, 1994, p. 59)

Os elementos do modelo são classificados em elementos estruturais e de apresentação, em que esses últimos incluem um *layout* espacial e temporal (HARDMAN; BULTERMAN, 1995).

- **Relações Estruturais:** são as âncoras que estabelecem os objetos de origem e destino para conexões dos elementos, além das relações temporais para que os itens de mídia possam ser sincronizados;
- **Relações Espaciais:** esse tipo de relação em uma apresentação pode ser estabelecida em relação a uma janela do aplicativo ou a outro item (ou grupo de itens);
- **Relações Temporais:** essas relações podem ser estabelecidas entre componentes atômicos e/ou componentes compostos. Dessa modo, permite a temporização da apresentação ser armazenada dentro da própria estrutura do documento.

A definição do componente permite coleções de componentes filhos por meio de uma lista, em que cada um pode ser um componente atômico ou composto (HARDMAN; BULTERMAN, 1995; KOCH, 2000).

Os canais do AHM são dispositivos abstratos de saída para visualizar o conteúdo de um componente e tem associados características padrões de apresentação para os tipos de mídias a serem visualizadas por meio deste canal, além de armazenar especificações dependentes e independentes dos tipos de mídia (HARDMAN; BULTERMAN, 1995; BUGAY, 2006).

Assim, esse modelo permite endereçar o conteúdo de elementos combinados, ocupando tempo e/ou espaço em uma representação multimídia consistente (HARDMAN; BULTERMAN, 1995).

2.6.6 *Adaptive Hypermedia Application Model – AHAM*

O modelo AHAM foi proposto por Wu, Houben e De Bra em 1998 e é uma extensão do modelo Dexter, porém, difere-se com relação ao detalhamento do mecanismo de adaptação (WU, 2002). A Camada de Armazenamento do modelo Dexter foi estendida a fim de contemplar modelos relacionados à área educacional e divide-se em Modelo de Domínio, Modelo de Usuário e Modelo de Adaptação.


O Modelo de Domínio contempla a visão dos autores sobre o domínio da aplicação. O modelo de Usuário possui a visão do sistema sobre o usuário, contendo as características utilizadas na adaptação. Já no Modelo de Adaptação há regras que definem como o MU é atualizado e a adaptação é feita, utilizando informações dos modelos de domínio, de usuário e da interação com o usuário (PUGA, 2008).

Na publicação do modelo, os autores destacaram cinco aspectos-chave, que são (WU; HOUBEN; BRA, 1998):

- A adaptação é baseada no Modelo de Domínio, no Modelo de Usuário e no Modelo de Ensino (que consiste de regras pedagógicas);
- Distinguem-se claramente as noções de conceito e página: em muitos SHA essas noções se confundem;
- O modelo fornece um formalismo que permite aos autores escreverem regras pedagógicas sobre os conceitos e como podem ser aplicadas automaticamente;
- O modelo foi projetado especificamente para facilitar o desenvolvimento de ferramentas de autoria para ele; e
- O AHAM suporta a construção de um Modelo de Usuário não apenas destinado à leitura e navegação, mas também com suporte a fontes externas.

Pode-se observar, na Figura 10, a caracterização arquitetural do AHAM, e onde, no modelo Dexter, inserem-se os submodelos acima citados.

Figura 10: Arquitetura do Modelo AHAM



Fonte: Tradução nossa de (WU, 2002, p. 41)

2.6.7 *Munich Reference Model*

Nora Koch (2000, p. 73), em sua tese de doutorado, propôs o *Munich Reference Model*, cujas especificações são baseadas em orientação a objetos por meio de UML (*Unified Modeling Language*¹⁰) e OCL (*Object Constraints Language*¹¹) para sua representação. Assim como o AHAM, o modelo Munich também foi desenvolvido a partir do modelo Dexter. De acordo com Koch (2000, p. 75-76) as seguintes extensões foram acrescentadas ao modelo base:

- O hipertexto no modelo Dexter é o domínio na abordagem do Munich;
- Os componentes não estão relacionados somente por relações navegacionais (*links*), mas também outras relações conceituais como "parte de", "pré-requisito de", "inibidor de", "variante de" e "na mesma página de";
- O Modelo do Domínio modela o nível conceitual da aplicação e a representação da hipermídia da aplicação;
- A semântica da composição é simplificada, como um conceito composto, só pode ter todos os filhos do tipo composto ou do tipo atômico;
- O Modelo do Usuário e o Modelo de Adaptação são adicionados à camada de armazenamento;
- O Modelo do Usuário inclui um gerenciador de usuário e um modelo para cada usuário composto de pares "atributo-valor";

¹⁰Tradução livre: Linguagem de Modelagem Unificada.

¹¹Tradução livre: Linguagem de Restrição de Objetos.

- O Modelo de Adaptação é definido por um conjunto de regras que são o núcleo da funcionalidade adaptativa;
- As regras são classificadas em regras de construção, regras de aquisição e regras de adaptação (adaptador de conteúdo, adaptador de *link* e adaptador de apresentação);
- O Modelo de Adaptação também modela o comportamento do usuário;
- O construtor de página garante a geração dinâmica das páginas;
- O modelo inclui um *User Identification*¹² (UID) para todos os componentes, não só para as páginas; e
- A camada de execução somente instancia as páginas.

Esse modelo conserva a estrutura básica de três camadas do Modelo Dexter para descrever nós, *links* e o mecanismo de navegação do SHA, acrescentando algumas funcionalidades a essas camadas a fim de incluir aspectos novos na modelagem do usuário e no processo de adaptação. Na Figura 11, observa-se a estrutura do *Munich Reference Model*, em que (KOCH; WIRSING, 2002):


- **Camada de Execução:** contém a descrição da apresentação, os nós e os *links*, e é responsável pelo gerenciamento das sessões, pela interação do usuário e aquisição do comportamento do usuário;
- **Camada de Armazenamento:** possui diversas funcionalidades além do armazenamento e foi segmentada em três submodelos, a fim de agrupar suas aplicações (KOCH, 2000);
 - **Meta-modelo de Domínio:** descreve a estrutura da aplicação e responsabiliza-se pelo gerenciamento da estrutura básica do sistema hipermídia em termos de *links* e nós e sua relação na composição da navegação;
 - **Meta-modelo de Usuário:** efetua o gerenciamento dos usuários, de seus atributos e os valores dos atributos, representantes das características e conhecimentos de cada usuário. Cabe ressaltar que os atributos podem ser classificados como dependentes ou independentes do domínio; e
 - **Meta-modelo de Adaptação:** consiste de um grupo de regras que implementam a funcionalidade adaptativa ao sistema, além de personalizar a aplicação. Tais regras são disparadas pelo comportamento do usuário quando monitorado e/ou por outras regras;
- **Camada Interna aos Componentes:** contém o conteúdo e a estrutura da hipermídia e dessa forma, depende da aplicação. Assim como nos modelos Dexter e AHAM, essa camada não foi modelada (BUGAY, 2006).

¹²Tradução livre: Identificação do usuário

Esse modelo também inclui duas interfaces, que são:

- **Interface de Especificação de Apresentação** – constrói páginas a partir dos fragmentos que as compõem baseado nos mecanismos de adaptação (KOCH; WIRSING, 2002);
- **Interface de Ancoragem**: mecanismos de endereçamento indireto que fornece um ponto fixo a ser usado pela Camada de Armazenamento, o qual é combinado com um campo variável usado pela Camada Interna aos Componentes (KOCH, 2000).

Figura 11: Arquitetura do Modelo Munich



2.6.8 Outros Trabalhos em SHA

Além dos trabalhos apresentados nesta seção e que fundamentam o desenvolvimento do modelo proposto, existem inúmeros trabalhos e pesquisas desenvolvidos na área de Hipermissão Adaptativa.

Quando falamos em Hipermissão Adaptativa, notória referência é feita a Peter Brusilovsky, um dos principais pesquisadores, com várias publicações e livros na área. Também se deve referir igualmente a Paul De Bra, que foi mencionado ao longo desta seção em diversas propostas de SHA.

Voltando nossos olhares para a academia, especialmente para o trabalho *Software Engineering for Adaptive Hypermedia Systems*, que foi a tese de Nora Koch (2000) autora do Modelo Munich, têm-se uma das maiores referências da literatura, embasando inúmeras pesquisas, especialmente trabalhos de brasileiros, bem como Hongjing Wu (1998-2002), com seus trabalhos sobre o Modelo AHAM.

No cenário nacional, as pesquisas em hipermissão iniciaram aproximadamente no ano de 2000, com os trabalhos de Palazzo (2000). Na sequência, outros pesquisadores ganharam destaque, como Edson Bugay (2006), com o modelo AHAM-MI, Marília Amaral (2008), com o modelo RHA, Sandra Puga (2008), com o modelo SHASIM, entre outros.

2.7 GERAÇÃO DE INTERFACES

Com o surgimento das primeiras interfaces de usuário gráficas, em meados dos anos 80, foram diversas as propostas de ferramentas com a finalidade de auxiliar o trabalho de desenvolvimento e *design*, visando à usabilidade do sistema. Segundo Lavor (2011), destacam-se nesse cenário duas categorias de ferramentas de *design* e desenvolvimento. Primeiramente, as ferramentas de programação visual como o Microsoft Visual Studio, Netbeans, Adobe Fireworks, entre outros. A segunda categoria engloba os baseados em modelos como Sistemas Gerenciadores de Interfaces de Usuário (SGIU), Ambientes de Desenvolvimento de Interfaces de Usuário Baseado em Modelos (ADIUBM) e ferramentas baseadas em Linguagens de Descrição de Interfaces de Usuário (LDIU).

Propostos na década de 80, os SGIUs foram as primeiras iniciativas de automatização do *design* de interface com base em modelos (SILVA; PATON, 2000, 2003). Já nos anos 90, os ADIUBMs foram criados para auxiliar os designers no desenvolvimento de Interface de Usuário (IU), por meio de modelos declarativos (SILVA, 2001). Com as diversas possibilidades de desenvolvimento de aplicações para múltiplas plataformas (PC, TV Digital, *Web*, dispositivos móveis, etc.), passou-se a utilizar os ADIUBMs a partir de modelos descritos em Linguagem de Descrição de Interface de Usuário (SOUCHON; VANDERDONCKT, 2003).

Foram bem-sucedidas algumas abordagens na geração de interfaces de usuário para múltiplas plataformas nos trabalhos de (BOTTERWECK, 2006) e (NETO et al., 2009), por meio de

processos em (CIRILO et al., 2010) e por meio de Linguagens Específicas de Domínio (DSL) em Vernazza (VERNAZZA, 2007). Esses trabalhos possuem em comum a geração automática visando reduzir os esforços no desenvolvimento da IU. Entretanto, tais modelos não geram aplicações completas, pois se limitam à representação exclusiva dos aspectos de interface, como *sketches* e protótipos (MICROSOFT, 2013), diálogo e interação usuário-sistema (MORI; PATTERNÒ; SANTORO, 2002), entre outros. Em suma, os aspectos funcionais são ignorados e devem ser codificados a parte (KRUCHTEN, 1995; HOFMEISTER; NORD; SONI, 2000).

Para se reduzir os esforços na construção de *software*, outras ferramentas e abordagens de Desenvolvimento Dirigidos por Modelos (DDM) têm sido utilizadas (OMG, 2013). Dentre eles, os principais casos de sucessos deram-se em sistemas de domínios específicos (KELLY; TOLVANEN, 2008), construídos com linguagens específicas de domínio (DSL - *Domain Specific Language*) (SADILEK, 2008).

2.7.1 Trabalhos Relacionados

O *Cameleon Reference Framework* define passos para o desenvolvimento de IU interativas sensíveis ao contexto (CALVARY et al., 2003). O contexto é formado pelo ambiente, plataforma e usuário. Foram identificados quatro passos durante o processo de geração da IU (LIBÓRIO et al., 2005):

1. **Tarefas e Conceitos:** descreve conceitos de domínio e tarefas a serem executadas, além de representar como os conceitos são requeridos pelas tarefas;
2. **Interface Abstrata:** representa as interações na interface alvo de forma independente, por meio de conjunto de abstrações de objetos concretos existentes;
3. **Interface Concreta:** consolida uma Interface Abstrata em Objetos de Interação independentes da representação da Interface Final; e
4. **Interface Final:** interface concreta codificada em alguma linguagem.

O MANTRA (*Model-bAsed eNginEering of multiple interfaces with TRAnsformations*) apresentado por Botterweck (2006), realiza a especificação da IU em diferentes níveis de abstração por meio de um processo de transformações entre modelos de geração de IU concretas para desktop (GUI - *Graphical User Interface*), Web (WUI - *Web User Interface*) e Mobile (MUI - *Mobile User Interface*).

O TERESA (*Transformation Enviroment for Interactive Systems Representations*) (TERESA, 2013) é um ambiente semiautomático para construção da IU baseado em transformações de modelos, útil para o designer de interfaces construir e analisar seus projetos em diferentes níveis de abstração e consequentemente gerar a interface concreta para plataformas específicas (LIBÓRIO et al., 2005).

Costa (2009) apresentou uma proposta para desenvolvimento de interfaces para múltiplas plataformas baseada em modelos, utilizando modelos da IMML (*Interactive Message Modeling Language*) com a tecnologia de DDM (LEITE, 2003).

Definido por Limbourg (2004a) o ambiente *TransformiXML* realiza mapeamentos, por meio de relacionamentos entre expressões matemáticas. Além disso, permite a definição e aplicação de regras de transformação que representa a associação entre diferentes modelos para geração de IU. As regras e associações do *TransformiXML* são feitas por meio do padrão UsiXML para modelos de IU (LIMBOURG et al., 2004b).

Baseado no conceito de interface abstrata por meio de linhas guia, foi proposto o TRIDENT, como um conjunto de ferramentas interativas que geram automaticamente IU para aplicações orientadas a negócios altamente interativos (TERESA, 2013). Em Furtado (1997), pode-se ver uma metodologia de construção automática de interfaces adaptativas, integrando fatores humanos relativos ao comportamento do usuário no processo de desenvolvimento de *software*.

Outro trabalho baseado em modelos e centrado no usuário foi proposto por Rodrigues (2005), denominado MEDITE+, como uma metodologia de concepção e desenvolvimento de IU variante da metodologia MEDITE (GUERRERO; LULA BERNARDO, 2002).

Tais trabalhos caracterizam-se pela geração por meio de transformações entre modelos baseados em linguagens de descrição e modelos de IU em diferentes níveis de abstração.

Visando proporcionar uma abordagem baseada em DSL, Vernazza (2007) apresentou uma ferramenta que permite a modelagem da IU em alto nível de abstração, sem que o designer necessite fazer qualquer forma de codificação. Um dos objetivos dessa ferramenta é que o designer acesse os padrões de *design* de forma imediata, evitando assim a consulta externa aos padrões definidos.

A arquitetura DIGYMES (*Dynamically Generating Interfaces for Mobile and Embedded Systems*) apresentada por Coninx (2003) é composta por um *framework* para criação e *design* de sistemas interativos para diferentes dispositivos. Esse modelo faz uso do conceito de separação entre camada lógica e de apresentação.

A proposta do MUSA (*Multi User Interfaces Single Application*) além de reduzir o tempo de desenvolvimento e os custos, visa à melhoria da manutenção e a flexibilidade de uso por meio de separação entre camadas de interface, de aplicação lógica e de comunicação. Uma das vantagens do MUSA é a diversidade de dispositivos suportados, além da gama de estratégias de adaptação (MENKHAUS, 2002).

A UIIMT (Ferramenta para Modelagem de Interação e Interface de Usuário) desenvolve um modelo que representa o processo de interação entre o usuário e o sistema, a partir do qual se pode analisar e encontrar possíveis problemas de usabilidade (LAVÔR; LEITE, 2011).

Foi proposta por Furtado (1999) uma Metodologia de Construção Automática de Interfaces Homem-Computador Adaptativas (MACIA) cuja característica principal é a integração de fatores humanos (e.g. comportamentos dos usuários, recomendações ergonômicas e modelos cognitivos) no processo de desenvolvimento, a fim de reduzir a complexidade e aumentar a

usabilidade.

Libório (2005) apresentou um modelo de geração de interfaces através de sistemas baseados em conhecimento, visando introduzir de forma mais incisiva o conhecimento do designer no processo de geração.

Becker (2009) propôs um aplicativo para geração de interfaces considerando critérios ergonômicos a partir de um diagrama de classes de domínio.

A ferramenta GI (Gerador de Interfaces) faz uso de especificações de interfaces armazenadas em uma base de dados para assim gerar o código posteriormente (PETTERMANN; BELLIN; KROTH, 2001).

O GIA (Geração de Interfaces Adaptativas), apresentado por Ito (2005), destaca-se frente aos demais trabalhos pela adaptação imediata na identificação do dispositivo, que acontece automaticamente e de forma simultânea.

Deve-se ter em mente que as aplicações aqui citadas compõem o leque dos principais trabalhos, mas que as alternativas não se limitam a essas.

3 METAHEURÍSTICAS

Existe uma grande variedade de problemas de otimização combinatória que são considerados difíceis de resolver, ou para os quais ainda não foi inventado algoritmo eficiente capaz de obter o ótimo global. Dessa forma, a dificuldade desses problemas é caracterizada pela teoria da complexidade computacional. Em muitos casos, uma solução satisfatória é suficiente para o problema tratado, no entanto, sem garantias de qualidade.

Os métodos de resolução heurísticos têm como finalidade encontrar soluções de boa qualidade em um tempo aceitável para os fins práticos a que se destinam. Grande parte das heurísticas é destinada a classes específicas de problemas. A sistematização dessas regras em métodos é denominada de metaheurísticas (COELHO, 2006).

Neste capítulo, são introduzidos os conceitos de otimização combinatória aliada às visões de otimização e de busca em um espaço de soluções. A seguir, apresenta-se uma classificação das metaheurísticas em que aspectos de cada grupo de técnicas são evidenciados. Por fim, argumenta-se sobre a escolha das metaheurísticas que são utilizadas no trabalho, bem como se apresentam suas características.

Este capítulo está estruturado da seguinte forma:

- A seção 3.1 apresenta uma breve introdução à otimização combinatória, trazendo os conceitos de busca e otimização conjuntamente à noção de espaço de busca;
- Na seção 3.2, é apresentada uma categorização das metaheurísticas de acordo com as bases de seus algoritmos;
- Na sequência, a seção 3.3 expõe a fundamentação da escolha das metaheurísticas utilizadas no trabalho; e
- Por fim, nas seções 3.4, 3.5 e 3.6 são apresentadas individualmente as técnicas, expondo suas características e aspectos particulares.

3.1 OTIMIZAÇÃO COMBINATÓRIA

Otimização é o processo de encontrar e comparar soluções factíveis até que nenhuma solução melhor possa ser encontrada. Essas soluções são ditas boas ou ruins em termos de um objetivo (DEB, 2001).

Krasnogor (2002, p. 7) define informalmente os problemas de otimização combinatória como problemas para os quais o espaço de soluções possíveis é finito, embora muito grande e discreto. A maioria dos problemas reais que surgem na indústria, na economia, na logística, etc., possui um problema de decisão *NP-Completo* associado, cuja versão de otimização é *NP-*

Difícil, sendo impossível resolvê-lo em tempo polinomial (a menos que $P^1 = NP^2$).

A versão de otimização de um problema *NP-Completo* possui um conjunto de requisitos e uma função que fornece um valor a uma solução específica, que é chamada de Função Objetivo (FO), que pode ser minimizada ou maximizada. A resposta para o problema, ou seja, o ótimo global, será o menor (ou maior) valor possível para a função, sem violar nenhuma restrição. Em muitos casos, encontram-se valores que não conduzem a melhores resultados, mas que também não são o ótimo global. Essas soluções são nomeadas de ótimos locais. Deve-se ressaltar que o espaço de soluções cresce exponencialmente com o aumento do tamanho do problema.

Grande parte dos problemas podem ser formulados como problemas de busca ou otimização, podendo ser vistos como uma *caixa preta* contendo entradas, saídas e conjuntos de parâmetros a serem determinados, em que se deseja determinar tais parâmetros por meio de uma função objetivo $f : \mathbb{R}^n \rightarrow \mathbb{R}^m$, na qual n é o número de entradas e m o número de saídas.

Considerando um problema de minimização, dada uma função $f : \mathbb{R}^n \rightarrow \mathbb{R}^m$ e um espaço de busca $S \subseteq \mathbb{R}^h$, o problema de otimização pode ser formulado como a Equação 3.1.

$$\text{minimizar } f(s) | s \in S \quad (3.1)$$

Em termos de busca, o mesmo problema pode ser descrito como a Equação 3.2.

$$\text{encontrar } s^* | f(s^*) \leq f(s), \forall s \in S \quad (3.2)$$

Desse modo, existe uma dualidade entre as duas soluções, de modo que um problema de busca possa ser considerado de otimização, e vice-versa. Ressalta-se que, no contexto deste trabalho, os dois termos são utilizados indistintamente.


O interessante dos problemas de busca ou de otimização é a diversidade na forma da função objetivo, que pode ser derivável ou não, uni- ou multidimensional e uni- ou multimodal, ou seja, com muitos vales e picos (CARDOSO, 1998).

A fim de ilustrar um problema de otimização, apresenta-se na Figura 12, uma representação hipotética de ótimos local e global, para o qual se deseja minimizar a função. Nessa figura, o ótimo local representa o ponto de mínimo encontrado em uma determinada região do espaço de soluções pesquisado. Já o ótimo global representa o menor valor assumido pela função objetivo, ou seja, a solução ótima do problema.

¹*Deterministic Polynomial time*. Tradução livre: Tempo polinomial determinístico

²*Non-Deterministic Polynomial time*. Tradução livre: Tempo polinomial não determinístico

Figura 12: Representação Hipotética do Espaço de Busca



Fonte: Elaborado pelo autor

3.2 CLASSIFICAÇÃO DAS METAHEURÍSTICAS

Um algoritmo é considerado um método heurístico³ quando não possui conhecimentos matemáticos completos sobre seu comportamento, ou seja, um algoritmo que tem como objetivo resolver problemas complexos utilizando uma quantidade pequena de recursos para encontrar soluções de boa qualidade (SUCUPIRA, 2004).

A importância dos métodos heurísticos advém do bom desempenho médio desses métodos, normalmente demonstrado de forma experimental, quando aplicados no tratamento de problemas para os quais não são conhecidos métodos eficientes ou que forneçam garantias de qualidade. Uma metaheurística é definida, formalmente, como um processo de geração interativo, que guia uma heurística subordinada, combinando de forma inteligente diferentes conceitos de exploração do espaço de busca (OSMAN; LAPORTE, 1996; BLUM; ROLI, 2003).

Nesta seção, será apresentada uma categorização das metaheurísticas, com base no trabalho de Brownlee (2011), que propõe a classificação das metaheurísticas em sete grupos distintos a partir de seus campos de estudo e de acordo com os princípios fundamentais de seus algoritmos.

- **Algoritmos Estocásticos:** esse grupo de algoritmos está baseado na introdução da aleatoriedade em métodos heurísticos. Grande parte dos algoritmos são constituídos de processos probabilísticos e estocásticos, porém, o que caracteriza esse grupo de algoritmos dos demais, apresentados na sequência, é a falta específica de um sistema inspirador e/ou uma explanação metafórica. Tanto “inspiração” e “metáfora” referem-se aos elementos utilizados na descrição padronizada dos algoritmos. Esses algoritmos são predominantemente algoritmos de otimização global e gerenciam procedimentos de exploração e busca local. São consideradas extensões de buscas *multistart*, fornecendo diferentes estratégias

³Uma heurística é um conjunto de regras e métodos que dirigem à descoberta de soluções, em geral, soluções satisfatórias, em um período de tempo razoável (AULETE, 2013).

para encontrar melhores pontos de partida para refinamento local, por meio de processos repetitivos de busca em áreas inexploradas (BROWNLEE, 2011);

- **Algoritmos Evolutivos:** os Algoritmos Evolutivos pertencem ao campo da Computação Evolucionária e são inspirados nos processos e mecanismos da evolução biológica por meio da seleção natural. O processo de evolução por meio da seleção natural foi proposto por Darwin para explicar a diversidade das espécies e sua adequação ao ambiente. Os mecanismos de evolução descrevem como ela ocorre por meio da modificação e propagação de material genético. Outras áreas se enquadram no âmbito da Computação Evolucionária, buscando explorar propriedades de áreas afins da genética de populações, ecologia populacional, biologia coevolutiva e de desenvolvimento (BROWNLEE, 2011; GABRIEL; DELBEM, 2008);
- **Algoritmos Físicos:** os Algoritmos Físicos são baseados em processos físicos, com inspirações variando da metalurgia, da música e até mesmo sistemas dinâmicos complexos, como avalanches. Normalmente, são algoritmos de otimização estocástica conjuntamente a outras técnicas de busca local e global (BROWNLEE, 2011);
- **Algoritmos Probabilísticos:** os Algoritmos Probabilísticos são aqueles que possuem um modelo de problema ou em que o espaço de busca do problema é definido utilizando-se um modelo probabilístico de soluções candidatas. Muitas metaheurísticas podem ser consideradas probabilísticas, embora a diferença seja o uso explícito das ferramentas de probabilidade na resolução de problema. Em suma, esses algoritmos são métodos que constroem modelos e distribuições de estimativa em domínios de pesquisa (BROWNLEE, 2011);
- **Swarm Algorithms:** esse grupo de algoritmos tem suas raízes na natureza, explorando as propriedades da inteligência coletiva. Emerge da cooperação de um grande número de agentes homogêneos no ambiente, dando um conjunto de regras simples para cada agente em um grupo, que se torna capaz de realizar tarefas complexas (BROWNLEE, 2011). Na natureza, esses sistemas servem para resolver problemas como busca por alimento, fuga de predadores, etc. Essa forma de inteligência é descentralizada, auto-organizada e distribuída pelo ambiente, tipicamente entre agentes que participam do processo, ou é armazenada ou comunicada no próprio ambiente, como os feromônios das formigas, a dança das abelhas, a proximidade dos peixes e aves, etc. (BERNSTEIN, 2013);
- **Algoritmos Imunitários:** os Algoritmos Imunitários, como o próprio nome sugere, são métodos inspirados nos processos e mecanismos do sistema imunológico biológico. É um sistema natural multifuncional e poderoso que trabalha em conjunto, fornecendo características como o reconhecimento de padrões, tolerância a ruído, autonomia, aprendizado, memória, auto-organização, etc. Esse conjunto de propriedades são encontradas individualmente em outros sistemas biológicos, porém não de forma integrada como nesta

categoria de algoritmos (BROWNLEE, 2011; CASTRO; TIMMIS, 2002; DASGUPTA, 2006);

- **Algoritmos Neurais:** os Algoritmos Neurais formam um grupo de técnicas que se preocupa com a investigação de modelos computacionais inspirados nas estruturas e funções das redes biológicas de células neurais no cérebro. Esses algoritmos são compostos por um conjunto de neurônios artificiais que estão interligados, a fim de computar padrões de entrada e criar padrões de saída. Caracteriza-se por serem sistemas adaptativos capazes de modificar sua estrutura interna, tipicamente os pesos entre os nós da rede, permitindo-os abranger uma gama de problemas (BROWNLEE, 2011; TATIBANA; KAETSU, 2013).

3.3 FUNDAMENTAÇÃO AO USO DAS TÉCNICAS

Durante o desenvolvimento de modelos adequados à otimização de problemas reais, é comum encontrar problemas onde se precisa otimizar mais de um objetivo, que, na grande maioria das vezes, são conflitantes. Nesses casos, não existe uma solução única apenas, mas um conjunto de soluções.

Tais soluções são aquelas em que a melhora de um objetivo não pode ser alcançada sem a degradação dos outros. Problemas com mais de um objetivo são denominados multiobjetivos e requerem algoritmos mais elaborados.

Os algoritmos que trabalham com uma única solução descrevem uma trajetória no espaço de busca durante sua execução. Contrariamente, as metaheurísticas baseadas em população, executam um processo de busca que descreve a evolução de um conjunto de soluções no espaço de busca.

As metaheurísticas não populacionais exploram o espaço de soluções por meio de movimentos. Esses movimentos são aplicados a cada iteração sobre a solução atual, produzindo, assim, em sua vizinhança, outra solução promissora. Como exemplos dessa categoria, temos o GRASP, a *Iterated Local Search*, o *Simulated Annealing*, a Busca Tabu (que será utilizada neste trabalho), entre outras.

Os algoritmos que trabalham com mais de uma solução, ou algoritmos populacionais, por sua vez, consistem em manter um conjunto de soluções boas e combiná-las a fim de produzir soluções ainda melhores. Como exemplos dessa categoria, têm-se os Algoritmos Evolutivos, em que se enquadram o Sistema Imunológico Artificial e o Algoritmo Genético (que será empregado neste trabalho).

Nesta pesquisa, foram eleitas duas metaheurísticas que fundamentarão o desenvolvimento de um terceiro algoritmo, o Algoritmo Memético, que é um processo de hibridização. Das técnicas escolhidas, uma é de busca populacional, e a outra, de busca local. São elas o Algoritmo Genético e a Busca Tabu, respectivamente.

Uma das vantagens do uso de técnicas de otimização evolucionárias em problemas multiobjetivos é o fato de que tais técnicas encontram de uma só vez um conjunto de soluções para

o problema. A escolha do Algoritmo Genético deu-se primariamente por ser considerada uma técnica robusta e por seu processo evolutivo levar em conta exclusivamente a carga genética das soluções e não a estrutura do problema a ser otimizado, sendo a única informação necessária o valor da Função Objetivo (CARDOSO, 1998).

Quando lidamos com problemas em que existam informações específicas, faz-se necessário considerar um Algoritmo Híbrido (AH). Os Algoritmos Genéticos podem ser combinados com inúmeras técnicas de busca local, de forma que o AH explore tanto a perspectiva global por meio do AG, aliado com a convergência local propiciada por técnicas de busca local. No contexto deste trabalho, optou-se pela Busca Tabu devido à agressividade com que a técnica explora o espaço de soluções (GLOVER, 1989, p. 192).

Ao desenvolver um Algoritmo Híbrido, combinam-se técnicas de busca global com técnicas de busca local. Cardoso (1998, p. 44) afirma que ao desenvolvermos uma técnica híbrida, sacrifica-se parte da generalidade das técnicas individuais para utilizar informações específicas do problema a fim de aumentar a eficiência do AH. O teste de diversas parametrizações em um Algoritmo Híbrido faz-se necessário para evitar e/ou minimizar a perda de generalidade inerente ao processo de hibridização. Pode-se ver em detalhes na seção 6 os testes e experimentações realizados com diversos conjuntos de parâmetros, visando melhorar a qualidade dos resultados expostos.

Nas sessões seguintes, são apresentados, em detalhes, cada uma das técnicas utilizadas no trabalho, conjuntamente a suas características e especificidades.

3.4 ALGORITMO GENÉTICO

Em meados de 1950, surgiram os primeiros trabalhos relacionados à computação evolucionária. No entanto, seu desenvolvimento factual iniciou somente a partir de 1970, com os trabalhos publicados por pesquisadores da Universidade de Michigan, sob a coordenação do professor John Holland⁴ – a quem é atribuído o título de criador da técnica dos Algoritmos Genéticos (HOLLAND, 1992; GOLDBERG, 1989). Desde então, diversas técnicas e metodologias surgiram embasadas em programação evolutiva, nicho dentro do qual os algoritmos genéticos se enquadram. Pode-se encontrar aplicações nas mais diversas áreas, como matemática, física, biologia, automação industrial e outras, abrangendo uma ampla classe de problemas, como otimização de sistemas, metodologias de tomada de decisão, simulação, sistemas de aprendizado, sistemas econômicos, etc.

Os Algoritmos Genéticos pertencem à classe de algoritmos evolucionários e constituem métodos de buscas embasados em mecanismos de seleção e evolução natural. Seu funcionamento é baseado em um procedimento iterativo que simula o processo evolutivo de uma popu-

⁴A formulação mais completa dos primeiros trabalhos de John Holland foi publicada em 1975, em seu livro “*Adaptation in Natural and Artificial Systems*”

lação, por meio de estruturas sujeitas às forças competitivas prescritas no princípio de Darwin⁵ da sobrevivência do melhor adaptado. Princípio segundo a qual os organismos de uma população que se adaptam melhor ao meio em que vivem têm mais chances de sobrevivência e reprodução, enquanto indivíduos menos adaptados têm chances menores de descendência. A combinação de boas características dos indivíduos a cada geração produz descendentes mais aptos e adaptados ao meio (GOLDBERG, 1989).

Esses algoritmos simulam o processo de evolução natural a partir de uma população de soluções iniciais. Em termos de otimização, cada indivíduo da população é uma solução codificada, que é projetada através de estruturas de dados composta por um conjunto de genes, chamada de cromossomo. Assim, cada cromossomo corresponde a um ponto no espaço de soluções, ou seja, representa uma possível solução para um dado problema.


A cada iteração do algoritmo, denominada neste contexto como geração, um novo conjunto de estruturas é criado quando as soluções são submetidas a operadores genéticos de cruzamento e mutação, que recombina suas estruturas, mas preservam informações cruciais. Após a troca de informação entre essas estruturas, as melhores soluções e mais adaptadas são selecionadas e servem de base para a próxima geração. O resultado desse processo será o aumento na adaptação global da população a cada nova geração.

Um Algoritmo Genético é, assim, qualquer modelo computacional baseado em população que utiliza operadores de cruzamento e mutação para gerar novos pontos amostrais em um espaço de busca. Analogamente ao processo evolutivo biológico das espécies, os Algoritmos Genéticos nutrem informações relevantes sobre o meio em que se encontram, retendo-a durante o período de adaptação. Essas informações, posteriormente, minimizam o espaço de busca e auxiliam na geração de novas e melhores soluções (LOBO, 2005).

A dinâmica do Algoritmo Genético pode ser observada na Figura 13, e na sequência seu pseudocódigo na Figura 14, que consiste na geração da população inicial e a avaliação da aptidão de seus indivíduos. O critério de parada garantirá o fim do algoritmo, dada uma condição. Após esses passos, realiza-se a seleção dos indivíduos que serão submetidos às etapas de cruzamento e mutação. Dados esses processos, cada indivíduo será novamente avaliado e a nova população criada é atualizada. Da mesma forma, faz-se necessário garantir que a nova população esteja completa antes de reavaliar o critério de parada.

⁵DARWIN, C.; BEER, G. **The Origin of Species**. [S.l.]: Oxford University Press, Incorporated, 1998. (Oxford world's classics). ISBN 9780192834386.

Figura 13: Fluxograma do Algoritmo Genético



Fonte: Adaptado de (GALAFASSI, 2011, p. 70)

Figura 14: Pseudocódigo canônico do Algoritmo Genético

Input: $Populacao_{tamanho}$, $Problema_{tamanho}$, $P_{cruzamento}$, $P_{mutacao}$
Output: S^*

```

 $Populacao \leftarrow IniciePopulacao(Populacao_{tamanho}, Problema_{tamanho});$ 
 $AvaliePopulacao(Populacao);$ 
 $S^* \leftarrow MelhorSolucao(Populacao);$ 
while  $\neg CondicaoParada()$  do
     $Pais \leftarrow SelecionePais(Populacao, Populacao_{tamanho});$ 
     $Filhos \leftarrow \emptyset;$ 
    foreach  $Pai_1, Pai_2 \in Pais$  do
         $Filho_1, Filho_2 \leftarrow Cruzamento(Pai_1, Pai_2, P_{cruzamento});$ 
         $Filhos \leftarrow Muta\c{c}{a}{o}(Filho_1, P_{mutacao});$ 
         $Filhos \leftarrow Muta\c{c}{a}{o}(Filho_2, P_{mutacao});$ 
    end
     $AvaliePopulacao(Filhos);$ 
     $S^* \leftarrow MelhorSolucao(Filhos);$ 
     $Populacao \leftarrow Substitua(Populacao, Filhos);$ 
end
return  $S^*;$ 

```

Fonte: Tradução nossa de (BROWNLEE, 2011, p. 93)

3.4.1 Adequabilidade e Avaliação da População

Uma das maiores complexidades na modelagem de problemas de otimização é o adequado desenvolvimento da função objetivo, que nesse contexto, atua como função de aptidão, avaliando a qualidade dos indivíduos da população (KNOSALA; WAL, 2001). Baeck e Fogel (2000, p. xxiv) definem aptidão como a propensão de um indivíduo a sobreviver e se reproduzir em um ambiente. Os valores da função de aptidão, em conjunto com as similaridades entre as estruturas de uma população são utilizados para dirigir o processo de busca (LOPES, 1995).

Em problemas de otimização sem restrições, o valor de aptidão de um indivíduo pode corresponder ao valor da função objetivo. Já nos problemas de otimização com restrições, a abordagem mais comum é a utilização da função de aptidão associada a uma função de penalidade (FALCÃO; BORGES, 2001).

É fundamental que a função de aptidão seja profundamente representativa e na correta proporção diferencie as soluções de baixa e alta qualidade. Quando a precisão da função de avaliação da aptidão for baixa, uma solução de boa qualidade pode ser descartada durante a execução do algoritmo, além do dispêndio de recursos computacionais em um espaço de solu-

ções pouco promissor (LOBO, 2005).

3.4.2 População Inicial

A população de um algoritmo genético é o conjunto de indivíduos cogitados como solução e que são a base para a criação de um novo conjunto de indivíduos filhos. Um fator determinante na parametrização do algoritmo genético é a definição do tamanho da população, pois ele pode afetar a eficiência do algoritmo, bem como o seu desempenho global. Na definição do tamanho da população, deve-se ter em mente que populações pequenas possuem grandes chances de perder diversidade, pois sua cobertura do espaço de busca é pequena. De outra forma, uma varredura grande do espaço de soluções produz uma grande população, que pode vir a prejudicar o desempenho computacional do algoritmo (LOBO, 2005).

Na maioria das vezes, a população inicial é criada de forma aleatória, ainda que em diversos casos seja mais adequada uma seleção heurística, introduzindo indivíduos potenciais logo no início, por exemplo, soluções aproximadas conhecidas que contenham alguma informação genética favorável. Várias pesquisas comprovam que a inicialização, geralmente, não é crítica, desde que a população inicial seja formada por cromossomos suficientemente variados (GOLDBERG, 1989).

3.4.3 Cromossomo

O Algoritmo Genético evolui com base em um conjunto de soluções iniciais, denominado de população inicial. Nesse contexto, cada indivíduo é chamado de cromossomo e representa um ponto no espaço de soluções, ou seja, uma possível solução para o problema. (WICKERT, 2012)

A forma de representação de possíveis soluções do espaço de busca de um problema possui grande influência no desempenho do algoritmo de busca, pois define a estrutura do cromossomo a ser empregado no algoritmo (SANGINETO, 2006). Existem diversas formas de representação das variáveis, através de números binários, inteiros ou reais (LOBO, 2005). A codificação do cromossomo deve representar as características do problema da forma mais simples possível. Cabe ressaltar que, na maioria dos trabalhos, a representação binária é a mais utilizada, dada suas facilidades de manipulação com os operadores genéticos de transformação em inteiro ou real (AURÉLIO; VELLASCO; LOPES, 1999).

3.4.4 Processo de Seleção

A seleção é responsável pela perpetuação de boas características na espécie, introduzindo a influência da função objetivo no processo de otimização do algoritmo genético (LUCAS, 2002; RODRIGUES, 2007). Seu funcionamento tem como base uma população em que a

cada indivíduo foi atribuído um valor de aptidão. O processo de seleção escolhe um subconjunto de indivíduos da população atual, criando assim uma população intermediária (LOBO, 2005). Em suma, indivíduos mais aptos possuem maior probabilidade de serem escolhidos, seja para serem pais de novos indivíduos ou para estarem presentes na próxima geração.

Existe uma grande diversidade de métodos de seleção de indivíduos. Como exemplos, pode-se citar a seleção elitista, seleção por torneio, ranqueamento, roleta, entre outros. Vale notar que, segundo Salvador (2000 apud LOBO, 2005, p. 18),


o princípio básico do funcionamento dos algoritmos genéticos é que um critério vai fazer com que, depois de muitas gerações, o conjunto inicial de indivíduos gere indivíduos mais aptos. Cada indivíduo tem uma probabilidade de ser selecionado proporcional à sua aptidão. A maioria dos métodos de seleção é projetada para escolher, preferencialmente, indivíduos com maiores notas de aptidão, embora não exclusivamente, a fim de manter a diversidade da população.

3.4.5 Operador de Cruzamento

Um dos principais mecanismos de geração de novos pontos no espaço de soluções é o cruzamento, que proporciona troca de informações genéticas entre indivíduos. A probabilidade de cruzamento controla a frequência de aplicação do operador de cruzamento, esta quando demasiadamente baixa resulta em pouco aproveitamento das informações genéticas. O contrário pode acarretar em convergência prematura (homogeneização rápida da população), pois o cruzamento associado à reprodução propicia a uniformização da população (SOARES, 1997).

Cada tipo de cruzamento tem maior adequação a determinados tipos de problemas, ou seja, um tipo de cruzamento pode ser adequado para um problema, mas não para outro (FALCONE, 2004). A Figura 15 apresenta a aplicação do operador de cruzamento de um ponto, em que se pode observar a faixa de corte determinando a carga genética dos pais que formará os filhos. Em suma, nesse exemplo os filhos serão formados por 50% da carga genética de cada pai. Ressalta-se que o cruzamento pode ocorrer entre dois ou mais indivíduos e não se restringe apenas a um ponto de corte como no exemplo, podendo variar a quantidade de pontos e as formas de recombinação.

Figura 15: Operador de cruzamento de 1 ponto




Fonte: Elaborado pelo autor

3.4.6 Operador de Mutação

De forma secundária, o operador de mutação objetiva manter a diversidade da população. Seu funcionamento baseia-se na modificação aleatória dos genes de um indivíduo, por meio de uma taxa/probabilidade de mutação. Esse processo insere aleatoriedade nas informações genéticas dentro da população, visando assim explorar espaços de soluções ainda não visitados, e escapar de ótimos locais. Em suma, o operador de mutação previne a perda prematura de informações (FALCONE, 2004).

A Figura 16 mostra o operador de mutação uniforme aplicado a um cromossomo, em que se pode observar a inversão de um dos bits. Cabe observar que, assim como o operador de cruzamento, existem inúmeras formas de operadores de mutação, uniformes ou não, que efetuam mutação intra ou extracromossômica, e/ou combinações desses.

Figura 16: Operador de mutação uniforme



Fonte: Elaborado pelo autor

3.4.7 Critérios de Parada

Em termos ideais, os algoritmos de otimização deveriam terminar assim que o ótimo global fosse descoberto. No entanto, não se pode afirmar com certeza que o ponto ótimo encontrado por um algoritmo seja o ótimo global. Consequência disso, comumente usa-se como critério para o término do algoritmo genético um número máximo de gerações ou um tempo limite de processamento. Outro critério empregado é a ideia de estagnação, ou seja, se nenhuma melhora for descoberta depois de várias gerações consecutivas o algoritmo é finalizado (TANOMARU, 1995; LOBO, 2005).

3.5 BUSCA TABU


A Busca Tabu (BT) foi proposta de forma independente por Glover, em 1986, e tem sua origem na solução de problemas de programação inteira. Hansen, em 1986, também propôs uma técnica similar, denominada SAMD (*Steepest Ascent, Mildest Descent*). Essa técnica é utilizada para a solução de problemas de satisfabilidade. Todavia, é atribuído a Glover o título de criador do algoritmo, por seus inúmeros trabalhos desenvolvidos (GLOVER, 1986; VIANA, 1998).

Posteriormente, Glover apresentou uma descrição do método, para uso geral em problemas da área de Pesquisa Operacional (otimização combinatória). O método é caracterizado por um procedimento iterativo que aceita movimentos de piora para tentar escapar de ótimos locais. Sua característica preponderante é o uso de estruturas de memória para organização da busca (GLOVER, 1989).

Essa técnica possui em sua concepção um cunho sociológico, sendo seu nome originado da língua nativa da ilha de Tonga na Polinésia e significa coisas que não podem ser tocadas por serem sagradas (POLTOSI, 2007). No dicionário Aulete encontra-se a seguinte definição: “*proibição de atos ou comportamentos considerados impuros, danosos etc., e que, quando praticados, podem resultar em castigos de origem sobrenatural*” (AULETE, 2013). O algoritmo da Busca Tabu proíbe alguns movimentos classificando-os como tabu. No entanto, assim como na sociedade, quando conveniente, o tabu pode ser quebrado.

De acordo com Costa (1994, p. 99), esse é um dos métodos mais eficientes para o tratamento de problemas de otimização de grande porte. Segundo Viana (1998, p. 111), a Busca Tabu foi criada para encontrar boas aproximações da solução ótima global em qualquer problema de otimização. Pode-se observar na Figura 17 a interação entre os componentes, sob os quais estão fundamentados os três princípios da técnica (GLOVER, 1986):

Figura 17: Componentes da estratégia da Busca Tabu




Fonte: Adaptado de (VIANA, 1998, p. 111)

- uso de estruturas de dados em forma de fila para guardar o histórico evolutivo do processo de busca;

- mecanismo de controle para balancear entre aceitação, ou não, de uma nova solução, baseado em informações registradas na lista tabu, referentes às restrições e aspirações desejadas; e
- incorporação de mecanismos de alternância entre estratégias de diversificação e intensificação.

A dinâmica da Busca Tabu pode ser observada na Figura 18, seguida do pseudocódigo na Figura 19, o processo consiste na geração da população inicial e na inicialização das funções e variáveis. O critério de parada garantirá o fim do algoritmo, dada uma condição. Após esses passos, realiza-se a geração de vizinhanças e obtém-se a melhor solução. Na sequência, as variáveis e funções são atualizadas e, novamente, o critério de parada avalia a condição atual do algoritmo.

Figura 18: Fluxograma da Busca Tabu



Fonte: Adaptado de (GALAFASSI, 2011, p. 64)

Figura 19: Pseudocódigo canônico da Busca Tabu para maximização

```

Input:  $S_0, BTmax$ 
Output:  $S^*$ 
 $S^* \leftarrow S;$ 
 $Iter \leftarrow 0;$ 
 $MelhorIter \leftarrow 0;$ 
 $ListaTabu \leftarrow \emptyset;$ 
InicializeFunçãoDeAspiração( $A$ );
while ( $Iter - MelhorIter \leq BTmax$ ) do
     $Iter \leftarrow Iter + 1;$ 
     $ListaDeCandidatos \leftarrow \emptyset;$ 
    for  $S' \in S_{vizinhanca}^*$  do
        if  $\neg \text{MovimentoN\~ao\~eTabu}(S', ListaTabu)$  then
             $ListaDeCandidatos \leftarrow S';$ 
        end
    end
    AtualizaListaTabu;
     $S \leftarrow S';$ 
    if  $f(S) > f(S^*)$  then
         $S^* \leftarrow S;$ 
         $MelhorIter \leftarrow Iter;$ 
    end
    AtualizeFunçãoDeAspiração( $A$ );
end
 $S \leftarrow S^*;$ 
return  $S^*;$ 

```

Fonte: Adaptado de (MARINHO, 2005, p. 25) e (BROWNLEE, 2011, p. 74)

O processo pelo qual a Busca Tabu procura a melhor solução ocorre por meio de uma exploração agressiva escolhendo a cada iteração o melhor movimento, independente se o movimento melhora a solução atual ou não (GLOVER, 1989; GLOVER; LAGUNA, 1997). Também pode ser definido como um método de busca em trajetória que tem por base a melhora da solução inicial, buscando novas soluções por meio da geração de vizinhanças (GLOVER; TAILLARD, 1993; GLOVER, 1990).

A seguir, são apresentados os conceitos relacionados à composição das estruturas e restrições da busca, que, segundo Glover (1990, p.5), são determinantes no processo de movimentação do algoritmo pelo espaço de busca.

3.5.1 Solução Inicial e o Espaço de Soluções

Com base em uma solução viável, a Busca Tabu inicia a busca de uma solução melhor no espaço de soluções. Essa solução viável pode ser gerada por um método exato, aleatoriamente ou através de outra heurística. O espaço de busca da BT é simplesmente o espaço de todas as possíveis soluções que podem ser consideradas durante a busca (GENDREAU; LAPORTE; POTVIN, 2001).

A definição de estrutura de vizinhança está intimamente ligada à definição de espaço de soluções. A cada iteração, a solução atual S muda para outra que seja sua vizinha no espaço de busca S' . A partir da solução inicial S_0 , a cada iteração da BT o algoritmo explora um subconjunto V da vizinhança $N(S)$ da solução corrente S . Formalmente, $N(S)$ é um subconjunto do espaço de busca (SOUZA, 2000).

Após a geração da vizinhança, cada membro S' de V é avaliado pela Função Objetivo (FO). O membro com o melhor valor nessa região segundo a FO $f(\cdot)$ torna-se a nova solução corrente ainda que S' seja pior que S , ou seja, que $f(S') > f(S)$ para um problema de minimização (SOUZA, 2000). Tal critério de escolha de uma solução pior que a solução atual tem por objetivo fazer com que a BT consiga sair de ótimos locais.

3.5.2 Lista Tabu

A Busca Tabu opera com estruturas de memória, dentre as quais a mais utilizada é a Lista Tabu (LT), uma memória de curto prazo. Nela ficam armazenados os últimos movimentos reversos realizados, a fim de evitar que a busca fique estagnada em pontos de ótimos locais (VIANA, 1998). Os movimentos armazenados na Lista Tabu ficam proibidos enquanto estiverem presentes nas próximas T iterações, onde T é a cardinalidade/tamanho atribuído a Lista Tabu (SIMAS, 2007). Geralmente, apenas uma pequena quantidade de movimentos é gravada, por questões de inviabilidade e de eficiência computacional. Mesmo assim, podem-se armazenar soluções completas, porém essa forma exige um grande espaço de armazenamento e torna a verificação de um movimento Tabu mais custoso (GENDREAU; LAPORTE; POTVIN, 2001).

3.5.3 Critério de Aspiração

Ao longo do processo de busca, a Lista Tabu pode tornar-se muito restritiva e proibir movimentos que podem levar à melhora do valor da Função Objetivo. Para a solução desse problema é necessária uma técnica que perdoe o status Tabu de um movimento. Tal técnica é conhecida como Critério de Aspiração (CA) e serve para relaxar a Lista Tabu, permitindo que um movimento Tabu seja realizado, desde que atenda a critérios pré-definidos. Existem inúmeras formas de definição de Critérios de Aspiração, por exemplo, melhora do valor da função objetivo, promoção da diversificação, etc. todos forçando movimentos Tabus a fim de

direcionar a busca para uma região do espaço de soluções ainda não explorado (GLOVER; LAGUNA, 1997).

3.5.4 Estratégia de Intensificação

Comumente, é utilizada em métodos de Busca Tabu a inclusão de estratégias de intensificação, que objetivam efetuar buscas mais refinadas em determinadas regiões do espaço de soluções consideradas promissoras, ou seja, que historicamente produziram bons resultados (GLOVER; LAGUNA, 1997).

O conceito por trás de uma política de intensificação consiste em explorar profundamente algumas regiões do espaço de soluções que parecem promissoras para tentar buscar a melhor solução nessa área. De modo geral, a intensificação está baseada em estruturas de memória, em que as configurações encontradas durante a pesquisa são armazenadas e sua vizinhança é explorada de forma mais sistemática.

As estratégias de intensificação podem fazer uso de memória de frequência, priorizando atributos que comumente façam parte de soluções de boa qualidade, evitando atributos que levem a soluções de baixa qualidade. A memória baseada em qualidade visa encontrar um ótimo local de boa qualidade. Já a memória baseada na influência dirige a um ótimo local mais rapidamente (SOUSA, 2009).

3.5.5 Política de Diversificação

Um dos principais problemas de todos os métodos baseados em Busca Local, nos quais a Busca Tabu se inclui, é que esses métodos tendem a ficar presos a ótimos locais, dispensando tempo de processamento em uma parte restrita do espaço de soluções (GENDREAU; LAPORTE; POTVIN, 2001). Para atender a esse problema, faz-se uso de estratégias de diversificação, cujo objetivo é impedir a convergência prematura do algoritmo, por meio do uso de estruturas de memórias de longo prazo, a fim de redirecionar a pesquisa para regiões não suficientemente exploradas do espaço de soluções, diversificando a busca (GLOVER; LAGUNA, 1997; TOTH; VIGO, 2002).

3.5.6 Critério de Parada

O critério de parada tem por objetivo a definição de até quando a BT será executada. Teoricamente, um processo de busca poderia ser executado infinitamente, se não conhecêssemos de antemão a solução ótima. No entanto, na prática, a busca deve terminar em algum momento. Geralmente, os critérios mais utilizados são (GLOVER; KOCHENBERGER, 2003; GENDREAU; LAPORTE; POTVIN, 2001):

- Depois de um número fixo de iterações (ou uma quantidade fixa de tempo de CPU);

- Após determinado número de iterações sem melhora (*NBmax*) no valor da função objetivo; e
- Quando a função objetivo atinge um valor determinado *a priori*.

3.6 ALGORITMO MEMÉTICO

Os Algoritmos Evolucionários são caracterizados pela exploração do espaço de busca, pelo aspecto global que os fazem ferramentas de buscas globais robustas e, ao mesmo tempo, pelo aspecto local, que os fazem efetivos no processo de busca de um ótimo global aproximado. A natureza exploratória dessa classe de algoritmos permite-os identificar regiões do espaço de busca promissoras. Por outro lado, prejudica a convergência e a precisão nos estágios finais do processo de busca (WANNER, 2006). Nos estágios finais, pouca informação nova é agregada pelos mecanismos de busca local, à medida que os mecanismos de busca global inserem informações com perturbações fortes, inviabilizando a convergência com alta precisão (JONG, 1993; MITCHELL, 1996).

Buscando acrescentar aos Algoritmos Evolucionários a capacidade da busca por todo o espaço de soluções a fim de permitir-lhes maior precisão, surgiram os algoritmos híbridos. Uma grande variedade desses pode ser encontrada na literatura, sob diversas designações, como, por exemplo, Algoritmos Meméticos, Algoritmos Lamarckianos, Algoritmos Baldwinianos, Algoritmos Culturais, Busca Local Genética, etc. (GOLDBERG; VOESSNER, 1999; DAVIS, 1991). Neste trabalho, utilizar-se-á a denominação de Algoritmos Meméticos, compreendendo as demais classificações.

Biologicamente inspirados, esses algoritmos utilizam a noção de memes apresentada por Richard Dawkins (1989), em que um meme é uma unidade de evolução cultural. Radcliffe e Surry (1994, p. 1) definem o termo meme como sendo uma unidade de informação, que se reproduz durante um processo argumentativo e de transmissão de conhecimento. Nesse contexto de otimização heurística, um meme representa uma estratégia de aprendizado, agregando ao indivíduo o equivalente à evolução cultural que ocorre em seu período de vida, possibilitando capturar informações que modelos puramente evolutivos não seriam hábeis (KRASNOGOR; SMITH, 2005). Deve-se ressaltar que esse processo não se limita simplesmente a transmitir a informação inalterada, ela também é processada e aumentada pela comunicação com os outros agentes (COELHO, 2006).

Segundo Moscato (1989, p. 20), Algoritmos Meméticos são uma definição mais apropriada para algoritmo genético híbrido. Em verdade, são uma hibridização de técnicas de otimização que nasceram da combinação dos algoritmos evolucionários e métodos de busca local, visando resultados mais refinados (MOSCATO, 1989). Como já apresentado anteriormente, o processo de hibridização contempla uma fase de busca global, normalmente realizada por algoritmos bioinspirados e de uma fase de busca local, responsável pelo aprendizado cultural individual (evolução memética), que pode ser observado no pseudocódigo na Figura 20. Esse

Figura 20: Pseudocódigo canônico do Algoritmo Memético

Input: $Tamanho_{Problema}$, $Populacao_{tamanho}$, $MemePop_{tamanho}$
Output: S^*
 $Populacao \leftarrow IniciePopulacao(Tamanho_{Problema}, Populacao_{tamanho});$
while $\neg CondicaoParada()$ **do**
 foreach $S_i \in Populacao$ **do**
 $S_{i_{custo}} \leftarrow f(S_i);$
 end
 $S^* \leftarrow MelhorSolucao(Populacao);$
 $Populacao \leftarrow BuscaGlobal(Populacao);$
 $PopulacaoMemetica \leftarrow SelecionePopulacaoMemes(Populacao,$
 $MemePop_{tamanho});$
 foreach $S_i \in PopulacaoMemetica$ **do**
 $S_i \leftarrow BuscaLocal(S_i);$
 end
end
return $S^*;$

Fonte: Tradução nossa de (BROWNLEE, 2011, p. 194)

casamento permite associar os benefícios dos algoritmos evolucionários (generalidade, robustez, busca global eficiente) aos mecanismos de busca local (exploração aplicada ao problema específico, convergência para mínimos locais) (SOUZA, 2007). Essa união de características conduziram importantes resultados, superando os obtidos através dos algoritmos puramente evolutivos.

Radcliffe e Surry (1994, p. 3) definem os Algoritmos Meméticos como Algoritmos Evolucionários, utilizando busca local para o aperfeiçoamento dos cromossomos. Em suma, objetivam combinar as habilidades dos operadores genéticos na determinação de boas regiões de busca (diversificação), com a eficiência da busca local em determinar soluções locais (intensificação) (MERZ; FREISLEBEN, 1999).

Os Algoritmos Meméticos são uma evolução dos Algoritmos Genéticos que fazem uso de busca local em seus operadores, a fim de agilizar sua execução. Devemos atentar para casos de grandes instâncias o uso de bons operadores de busca local, dado o tamanho da vizinhança associada. Como forma de contornar tal problema, Garcia (2001, p. 2) recomenda o emprego de técnicas de redução de vizinhança, ou o uso de técnicas que acelerem o processo de busca na vizinhança.

O processo de busca local visa encontrar melhores indivíduos em uma vizinhança, para assim tornar os indivíduos dessa população ótimos locais, evoluindo-os dentro de uma geração. Coelho (2006, p. 31) propõe a aplicação dos operadores de otimização local em diferentes fases da reprodução, como, por exemplo:

- antes dos operadores de recombinação e mutação;
- após a aplicação do operador de recombinação ou do operador de mutação;

- somente a um subconjunto dos agentes; e
- no final de cada ciclo reprodutivo.

Krasnogor (2006) amplia essa visão e estende os *hot-spots* de inserção da busca local além das posições/momentos propostas por Coelho, mas perfaz a inserção desde a geração da população e a delimitação dos operadores de intensificação e diversificação.

Entretanto, os modelos mais populares de hibridização são a aplicação monofásica ou multifásica da busca local, com base em algum parâmetro, seja este probabilístico ou não. Conforme será melhor esclarecido na seção 5.2.4.3, o algoritmo proposto neste trabalho será monofásico com parâmetros fixos.

Como os procedimentos de refinamento dos indivíduos são usados depois da aplicação dos operadores genéticos, implica dizer que os Algoritmos Meméticos são extensões dos Algoritmos Genéticos que aplicam a busca local separadamente para refinar a busca nos espaços de soluções, particularizando o aprendizado de cada indivíduo. Também se faz uso dos conceitos de cooperação denotando os processos de troca de informações entre os indivíduos e de competição denotando os processos de seleção em que os indivíduos competem entre si (MOSCATO, 1989).

Os Algoritmos Meméticos podem ser diferenciados dos Algoritmos Genéticos. O primeiro imita o processo da evolução cultural, em que a informação é transmitida pela comunicação entre os indivíduos. O segundo imita a evolução biológica, ou seja, a evolução se dá por meio de mecanismos de recombinação, responsáveis pela cooperação entre os agentes. Já a mutação é responsável por resgatar uma informação perdida ou mesmo a inclusão externa de informações e o cruzamento pela herança de informações (COELHO, 2006; GARCIA et al., 2001). Em suma, no Algoritmo Genético, os genes são transmitidos por meio das gerações, enquanto os memes (unidade replicante de informação cultural) são transmitidos de um indivíduo para outro, sem que uma geração decorra.

Os principais aspectos a serem considerados em um Algoritmo Memético, segundo a literatura, são: qual método de busca local será aplicado, sua periodicidade de aplicação, bem como a escolha de em quais soluções ou vizinhanças deve-se aplicar a busca local e com qual intensidade. Tais questões visam proporcionar equilíbrio entre a busca global e local, a fim de melhor conduzir o desempenho do Algoritmo Memético (KRASNOGOR; SMITH, 2005).

Uma grande preocupação quanto às decisões do projeto de um AM dizem respeito a um ou mais efeitos: o efeito Lamarckiano e o efeito Baldwiniano, que se preocupam com a preservação da diversidade versus a necessidade de encontrar regiões de boas soluções rapidamente.

Não existem ainda respostas bem definidas que garantam a qualidade desses algoritmos, pois as soluções são específicas para cada tipo de problema. O que se faz é tentar adaptar a técnica ao problema em questão (SOUZA, 2007). Supõe-se que a busca evolutiva provê uma ampla exploração do espaço de busca, enquanto a busca local pode, de alguma forma, focar em regiões de atração de soluções promissoras (KRASNOGOR; ARAGÓN; PACHECO, 2006).

Exemplos de aplicações bem sucedidas de Algoritmos Meméticos podem ser vistos em uma ampla gama de problemas, tais como otimização combinatória (MERZ, 2000), otimização de funções não estacionárias (VAVAK; FOGARTY; JUKES, 1996), otimização multiobjetivo (KNOWLES; CORNE, 2001), bioinformática (KRASNOGOR, 2004), etc.

Coelho e Mariani (2005) apresentam um algoritmo memético, que faz uso de otimização por nuvem de partículas para busca global em conjunto com um método conhecido por *Hooke-Jeeves* para busca local. Já Glover e Laguna (1997) expõem que o relacionamento do Algoritmo Genético aliado a Busca Tabu cria combinações híbridas potencialmente úteis.

4 REDES DE AUTÔMATOS ESTOCÁSTICOS

Este capítulo dedica-se ao estudo de Redes de Autômatos Estocásticos (*Stochastic Automata Network* - (SAN)), apresentando inicialmente uma definição informal por meio da descrição das primitivas utilizadas no formalismo apresentado na sequência. Esse formalismo embasa a construção do pensamento sobre autômatos de aprendizagem, criando o pensamento acerca da interação entre o autômato e o ambiente propiciado pelas metaheurísticas aliado aos conceitos de hipermídia. O uso de SAN nesta pesquisa faz-se adequado devido a sua hierarquia natural, organizando modularmente a estrutura da hipermídia da aplicação.

Este capítulo está organizado como se segue:

- A seção 4.1 apresenta a definição informal sobre SAN conjuntamente aos conceitos gerais que a definem;
- Na seção 4.2, introduz-se o formalismo de SAN e suas definições;
- A seção 4.3 expõe as características para uma SAN ser bem definida;
- Posteriormente, na seção 4.4, pode ser vista a definição do Descritor Markoviano;
- A seção 4.5 traz a definição dos conceitos que embasam a formação dos autômatos estocásticos de aprendizagem; e
- Ao fim deste capítulo, a seção 4.6 perfaz a definição de hipertômato que conjuntamente a hipermídia conduzem as bases deste trabalho.

4.1 DEFINIÇÃO INFORMAL

O formalismo de SAN foi inicialmente proposto por Plateau em 1984. Esse formalismo serve para a definição e solução de sistemas complexos por meio da modularização, em que se possui um grande espaço de estados. A ideia basal da SAN trata-se de uma alternativa para a descrição e modelagem de processos Markovianos com espaço de estados discretos. Diga-se que qualquer processo especificado como uma cadeia de Markov pode ser modelado por meio de SAN, seja sua cadeia finita ou infinita, redutível ou irredutível, periódica ou aperiódica, homogênea ou não, ergódica ou não, em tempo contínuo ou discreto (ESPINDOLA, 2011).

A SAN descreve um sistema completo por meio de um conjunto de subsistemas com comportamentos independentes (eventos locais) e com ocasional interdependência (taxas funcionais e eventos de sincronização). Os subsistemas são descritos por autômatos estocásticos, ou seja, um autômato que possui transições modeladas como um processo estocástico de tempo discreto ou contínuo definidos por distribuições geométricas ou exponenciais respectivamente (SALES, 2004). Em suma, os subsistemas são estados com regras e funções de probabilidade

que regem os movimentos entre os estados do autômato. O estado global de um modelo de SAN é definido pela combinação dos estados locais de cada autômato.

Cabe ressaltar que toda SAN pode ser representada por um único autômato estocástico que contenha todos os estados possíveis do sistema (BRENNER; FERNANDES; SALES, 2005). Esse único autômato, análogo à cadeia de Markov, equivale ao modelo em SAN, porém, a SAN reduz o problema da explosão do espaço de estados (DELAMARE, 2008).

Outra vantagem da utilização da SAN, é que essa gera automaticamente sua matriz de transição de forma implícita por meio de álgebra tensorial. A geração não explícita da matriz de transição constitui um ganho significativo de tempo, desempenho e uso de memória (FARINA, 2003).

- **Eventos:** são entidades do modelo responsáveis pela ocorrência de uma transição que modifica o estado global do modelo. Podem estar associados a uma transição que é disparada pela ocorrência de um evento associado a ela. Devem possuir uma taxa de ocorrência e uma probabilidade associadas, que podem ter valores constantes ou funcionais, diferentes de acordo com os estados dos demais autômatos do modelo. Dentro do formalismo de SAN, podem-se modelar dois tipos de eventos, classificados como: local ou sincronizante (BRENNER; FERNANDES; ALEGRETTI, 2002).

Segundo Chanin (2005, p. 40)

A classificação de um evento como local ou sincronizante é dada pela aparição do identificador do evento **e** no conjunto de eventos de um autômato. Caso o identificador do evento apareça apenas no conjunto de eventos de um único autômato, o evento é classificado como evento local. Se o mesmo identificador aparecer no conjunto de eventos de vários autômatos, o evento é classificado como evento sincronizante. (grifo nosso).

- **Evento Local:** altera o estado local de um único autômato sem ocasionar mudança alguma a outro autômato do modelo;
 - **Evento Sincronizante:** altera o estado local de mais de um autômato simultaneamente, fazendo com que haja interação entre eles.
- **Taxas e Probabilidades Funcionais:** permitem associar diferentes valores a um mesmo evento de acordo com o estado global do modelo. As taxas e probabilidades funcionais são expressas por funções que levam em consideração os estados atuais dos autômatos do modelo, assim, variando seus valores dado os estados que os autômatos envolvidos na função se encontram (FARINA, 2003).
 - **Função de Atingibilidade:** a definição de quais estados podem ser atingíveis ou alcançados em um modelo em SAN é dada pela função de atingibilidade. Essa se faz necessária,

pois o autômato global constitui-se modularmente pela combinação de todos os autômatos do modelo (BRENNER, 2004)

- **Funções de Integração:** avaliam a probabilidade do modelo em SAN encontrar-se em um determinado estado. Dessa forma, pode-se compor funções de integração que consideram a probabilidade do modelo se encontrar em um conjunto de estados, podendo assim se obter índices de desempenho e confiabilidade do modelo.

Via de regra, todas as funções da SAN são modeladas da mesma forma, o que as diferenciam é como elas são empregadas no modelo (CHANIN et al., 2005).

4.2 DEFINIÇÃO FORMAL

Será considerado neste trabalho a formalização de uma SAN compreendendo N autômatos $\mathcal{A}^{(i)} (i \in [1..N])$, e e eventos (locais e sincronizantes). A seguir descreve-se formalmente a conceituação da SAN, em que se propõe sua modelagem como uma quadrupla $SAN = (\mathcal{A}, \mathcal{E}, \mathcal{T}, \mathcal{F})$, com notação baseada nos trabalhos de Plateau (1991, 1996), Fernandes (1996), Ünsal (1997), Sales (2004), Webber (2004), Chanin (2005), Delamare (2008) e outros.

Definição 1. Um modelo SAN composto de N autômatos e E eventos, é definido por cada um dos autômatos $\mathcal{A}^{(i)} (i \in [1..N])$, cada um dos eventos $e \in \mathcal{E}$ e a função de atingibilidade $\mathcal{F}$.

Sejam

$\mathcal{A}$	conjunto de autômatos que compreende N autômatos, tal que $ \mathcal{A} = N$, nomeados $\mathcal{A}^{(i)}$, com $i \in [1..N]$;
$\mathcal{A}^{(i)}$	i -ésimo autômato, com seu conjunto de estados locais $\mathcal{S}^{(i)}$ e função de transição $\mathcal{Q}^{(i)}$ definidos, onde $\mathcal{A}^{(i)} \in \mathcal{A}$ e $i \in [1..N]$;
$\mathcal{A}^{(i)}(\mathcal{A}^{(\omega)})$	autômato $\mathcal{A}^{(i)}$ que possui como parâmetros os autômatos $\mathcal{A}^{(j)}$, onde $j \in \omega$;
$\mathcal{A}^{(i)}(x^{(\omega)})$	autômato $\mathcal{A}^{(i)}(\mathcal{A}^{(\omega)})$ com todos seus elementos funcionais avaliados para composição dos estados locais $x^{(\omega)}$.

Definição 2. Um autômato $\mathcal{A}^{(i)}$ tem como parâmetros a união dos parâmetros de todos os elementos funcionais contidos nos seus rótulos de transição. Um autômato $\mathcal{A}^{(i)}$ é definido por:

$\mathcal{S}^{(i)}$	conjunto de estados (locais) do autômato $\mathcal{A}^{(i)}$;
$\mathcal{Q}^{(i)}$	função de transição do autômato $\mathcal{A}^{(i)}$ definido de $\mathcal{S}^{(i)} \times \mathcal{S}^{(i)} \rightarrow \mathcal{T}^*$, a qual contém os rótulos de transição do autômato $\mathcal{A}^{(i)}$

Sejam

$\mathcal{E}$	conjunto de eventos do modelo compostos por E eventos, tal que $ \mathcal{E} = E$, nomeados e_j , onde $j \in [1..E]$;
e	evento do modelo, tal que $e \in \mathcal{E}$;
e_j	identificador de um evento (local ou sincronizante), tal que $j \in [1..E]$;
$e_j(\pi)$	identificador de um evento e_j com probabilidade de rotação constante π ;
$e_j(f)$	identificador de um evento e_j com probabilidade de rotação funcional definida pela função f .

As probabilidades (π ou f) são utilizadas quando um evento possui mais de uma alternativa de transição. Dessa maneira, probabilidades são utilizadas para indicar em que proporções o evento seguirá por uma transição ou outra. A probabilidade pode ser omitida caso esta seja igual a 1(100%). Outro ponto importante é que a soma das probabilidades de um evento deve ser sempre igual a 1(100%).

Definição 3. Cada evento sincronizante de uma SAN é identificado por:

e	identificador do evento, com $e \in \mathcal{E}$;
$\iota^{(e)}$	índice do seu autômato mestre, que possui a taxa do evento e , onde $\iota^{(e)} \in [1..N]$.

Definição 4. Seja um estado $x^{(i)} \in \mathcal{S}^{(i)}$. Define-se:

$\mathcal{O}_e$	conjunto dos índices de identificação dos autômatos nos quais o evento $x^{(i)}$ acontece, tal que $(i \in [1..N])$ e o autômato $\mathcal{A}^{(i)}$ possui ao menos um dos rótulos de $\mathcal{Q}^{(i)}$ numa tripla de sincronização com o identificador do evento e .
-----------------	---

Definição 5. Um evento e é classificado como:

se $ \mathcal{O}_e = 1$	evento local;
se $ \mathcal{O}_e > 1$	evento sincronizante.

A Definição 5 faz a classificação de cada evento, o qual pode ser um *evento local* ou um *evento sincronizante*. Essa diferenciação não é feita na definição do evento, mas é necessária para a construção dos tensores do *Descriptor Markoviano*, o qual é composto por uma parte local (eventos locais) e por outra parte sincronizante (eventos sincronizantes).

Definição 6. O conjunto de eventos locais $\mathcal{E}_l$ é definido como $\mathcal{E}_l = \{e \in \mathcal{E} \mid |\mathcal{O}_e| = 1\}$.

Definição 7. O conjunto de eventos sincronizantes $\mathcal{E}_s$ é definido como $\mathcal{E}_s = \{e \in \mathcal{E} \mid |\mathcal{O}_e| > 1\}$.

Um evento sincronizante e é *realizável* no estado global $\tilde{x}$, se e somente se $\forall i \in \mathcal{O}_e$ o conjunto de estados sucessores $y^{(i)} \in \text{succ}_e(x^{(i)})$ não for vazio.

Definição 8. O conjunto de eventos $\mathcal{E}$ é definido como $\mathcal{E} = \mathcal{E}_l \cup \mathcal{E}_s$ e $\mathcal{E}_l \cap \mathcal{E}_s = \emptyset$;

Sejam

$\mathcal{S}$	espaço de estados produto do modelo em SAN definido pelo produto cartesiano dos espaços de estados dos autômatos da rede, como $\prod_{i=1}^N \mathcal{S}^{(i)}$;
$\mathcal{S}^{(\omega)}$	espaço de estados produto do conjunto de estados locais dos autômatos $\mathcal{A}^{(i)}$, onde $i \in \omega$;
$ \mathcal{S}^{(\omega)} $	número de estados de $\mathcal{S}^{(\omega)}$, onde ω é o conjunto de índices dos autômatos ($\omega \subseteq [1..N]$).
$\mathcal{R}$	subconjunto de $\mathcal{S}$ que compreende todos os estados $\tilde{x}$ tais que $\mathcal{F}(\tilde{x}) = 1$;

Definição 9. O estado global $\tilde{x}$ (combinação dos estados locais) de uma SAN é obtido pela mudança dos estados locais dos N autômatos, $\tilde{x} = (x^{(i)}, \dots, x^{(N)})$, tal que $\tilde{x} \in \prod_{i=1}^N \mathcal{S}^{(i)}$.

Sejam

$x^{(i)}$	x -ésimo estado local do autômato $\mathcal{A}^{(i)}$, tal que $x^{(i)} \in \mathcal{S}^{(i)}$;
$\tilde{x}^{(\omega)}$	composição dos estados locais $x^{(i)}$, onde $i \in \omega$ e $\omega \subset [1..N]$.
$\tilde{x}(x^{(i)} \rightarrow y^{(i)})$	o estado global obtido pela substituição do estado local $x^{(i)}$ pelo estado local $y^{(i)}$ no autômato $\mathcal{A}^{(i)}$ ($y^{(i)} \in \text{succ}_{l(i)}(x^{(i)})$);
$\tilde{x}(x^{(i)} \xrightarrow{i \in \mathcal{O}_e} y^{(i)})$	o estado global obtido pela substituição de todos os estados locais $x^{(i)}$ por $y^{(i)}$ em todos os autômatos $\mathcal{A}^{(i)}$ ($i \in \mathcal{O}_e$ e $y^{(i)} \in \text{succ}_e(x^{(i)})$);

Note que a definição de um estado local do autômato ($x^{(i)}$) e a definição de um estado global ($\tilde{x}$) podem ser vistas como casos particulares de $x^{(\omega)}$. Um estado local $x^{(i)}$ é o caso onde $\omega = \{i\}$, ao passo que o estado global $\tilde{x}$ é o caso onde $\omega = \{1..N\}$.

Definição 10. Seja um estado $x^{(i)} \in \mathcal{S}^{(i)}$ e um evento $e \in \mathcal{E}$. Define-se:

$succ_e(x^{(i)})$	conjunto dos estados sucessores $y^{(i)}$, tais que o rótulo $Q^{(i)}(x^{(i)}, y^{(i)})$ possua uma tupla de transição com o identificador e e $\tau_e(x^{(i)}, y^{(i)}) \neq 0$, $\pi_e(x^{(i)}, y^{(i)}) \neq 0$ (elementos funcionais não identicamente nulos). O conjunto dos estados sucessores do evento e em $x^{(i)}$ a partir da ocorrência do evento e pode ser vazio, caso a transição não possa ser disparada em $x^{(i)}$ pelo evento e ;
$succ_{l(i)}(x^{(i)})$	conjunto dos estados sucessores $y^{(i)}$, tais que o rótulo $Q^{(i)}(x^{(i)}, y^{(i)})$ possua uma tupla de evento local com o identificador $l(i)$ e $\tau_{l(i)}(x^{(i)}, y^{(i)}) \neq 0$, $\pi_{l(i)}(x^{(i)}, y^{(i)}) \neq 0$ (elementos funcionais não identicamente nulos). O conjunto dos estados sucessores do evento local $l(i)$ em $x^{(i)}$ a partir da ocorrência do evento local $l(i)$ pode ser vazio, caso a transição não possa ser disparada em $x^{(i)}$ pelo evento local $l(i)$.

Seja

$\mathcal{F}$	função de atingibilidade é um elemento funcional que associa aos estados globais de $\prod_{i=1}^N \mathcal{S}^{(i)}$, definido de $\mathcal{S} \rightarrow [1..0]$, onde o $dom(\mathcal{S})$ representa todas as possibilidades de estados globais do modelo, e o $codom([0..1])$ fornece quais estados podem ser atingíveis em um modelo SAN, associando aos estados globais o valor 1 se eles são atingíveis e o valor 0 caso contrário.
---------------	--

Definição 11. A cada $e \in \mathcal{E}$ associa-se uma tupla de evento (e, τ) , onde:

e	identificador do evento;
τ	elemento funcional definido de $\mathcal{S} \rightarrow \mathbb{R}^+$, o qual define a taxa de ocorrência do evento e .

Definição 12. O conjunto $\mathcal{T}$ contém todas as tuplas de transição (e, π) , sendo ao menos uma para cada evento e no conjunto de eventos $\mathcal{E}$. Uma tupla de transição (e, π) é definida por:

e	identificador do evento;
π	elemento funcional definido de $\mathcal{S} \rightarrow [0, 1]$, o qual representa a probabilidade de uma transição quando da ocorrência do evento e .

Sejam

$\mathcal{T}$	conjunto de tuplas de transição local de um modelo SAN, tal que $\mathcal{T}^* = \mathcal{T} \cup \{\emptyset\}$;
$2^{\mathcal{T}}$	conjunto de partes (<i>powerset</i>) de $\mathcal{T}$. Uma parte de $\mathcal{T}$ é chamada de <i>elemento de transição</i> .

Definição 13. A $x^{(i)}, y^{(i)} \in \mathcal{S}^{(i)}$ associa-se uma tupla de transição local partindo de $x^{(i)}$ para $y^{(i)}$, denotada por $(e, \pi_e(x^{(i)}, y^{(i)}))$, onde:

e identificador do evento;
 $\pi_e(x^{(i)}, y^{(i)})$ probabilidade de roteamento, assumindo valores entre $[0, 1]$.

Sejam

$\tau_{l(i)}(x^{(i)}, y^{(i)})$ taxa de ocorrência do evento local e da tupla $(l(i), \tau_{l(i)}, \pi_{l(i)})$ associada ao rótulo de transição $\mathcal{Q}^{(i)}(x^{(i)}, y^{(i)})$;
 $\pi_{l(i)}(x^{(i)}, y^{(i)})$ probabilidade de rotação da tupla $(l(i), \tau_{l(i)}, \pi_{l(i)})$ associada ao rótulo de transição $\mathcal{Q}^{(i)}(x^{(i)}, y^{(i)})$;
 $\tau_e(x^{(i)}, y^{(i)})$ taxa de ocorrência do evento sincronizante e da tupla de sincronização (e, τ_e, π_e) associada ao rótulo de transição $\mathcal{Q}^{(i)}(x^{(i)}, y^{(i)})$;
 $\pi_e(x^{(i)}, y^{(i)})$ probabilidade de rotação da tupla de sincronização (e, τ_e, π_e) associada ao rótulo de transição $\mathcal{Q}^{(i)}(x^{(i)}, y^{(i)})$.

Definição 14. Um elemento funcional $f(\mathcal{S}^{(\omega)})$ é uma função de $\prod_{i \in \omega} \mathcal{S}^{(i)} \rightarrow \mathbb{R}^+$, onde $\omega \subseteq [1..N]$.

Os autômatos $\mathcal{A}^{(i)}$ com $i \in \omega$ são os parâmetros do elemento $f(\mathcal{S}^{(\omega)})$. Os elementos funcionais servem para definir as probabilidade e taxas funcionais conforme descritos a seguir.

Seja

$f(\tilde{x}^{(\omega)})$ elemento funcional $f(\mathcal{S}^{(\omega)})$ avaliado para a composição de estados $\tilde{x}^{(\omega)}$.

Elementos funcionais definem taxas de probabilidades funcionais. Todas as taxas e probabilidades funcionais são consideradas como elementos funcionais, mesmo aqueles que possuem valor constante. Obviamente, tal definição não representa uma restrição, visto que elementos constantes podem ser vistos como funções (constantes) com parâmetro em $\omega = \emptyset$. Dessa maneira, todos os elementos de um modelo em SAN podem ser considerados como funções de $\prod_{i=1}^N \mathcal{S}^{(i)} \rightarrow \mathbb{R}^+$.

Definição 15. A função de transição global $\tilde{\mathcal{Q}}$ é definida como $\mathcal{S} \rightarrow \mathcal{T}^*$, a qual contém os rótulos de transição do autômato global.

Sejam

$\mathcal{Q}^{(i)}(x^{(i)}, y^{(i)})$ rótulo de transição do estado local $x^{(i)}$ para $y^{(i)}$ em $\mathcal{Q}^{(i)}$, contendo uma lista de tuplas de transição (e, π) em $\mathcal{T}$;
 $\tilde{\mathcal{Q}}(\tilde{x}, \tilde{y})$ rótulo de transição do estado global $\tilde{x}$ para $\tilde{y}$ em $\tilde{\mathcal{Q}}$, contendo uma lista de tuplas de transição (e, π) em $\mathcal{T}$.

A função de transição $\mathcal{Q}^{(i)}$ de um autômato $\mathcal{A}^{(i)}$, informa a associação entre os estados do autômato e quais eventos podem dispará-lo. Essa associação é feita por meio das tuplas de transição (e, π) que compõem o conjunto de tuplas de transição $\mathcal{T}$. Cada tupla de transição define, além do identificador do evento, a probabilidade do evento para aquela transição. O número de tuplas de transição associadas a um rótulo de transição é igual ao número de eventos que podem disparar a transição.

4.3 SAN BEM DEFINIDA

Para se avaliar a solução estacionária de um modelo em SAN são necessárias algumas propriedades, e.g., vivacidade¹, irredutibilidade², ergodicidade³, etc. Para isso, algumas restrições devem ser respeitadas para assegurar tais propriedades. Os modelos descritos em SAN que obedecem a essas restrições são conhecidos como SAN bem definidas.

Restrição 1. Um autômato $\mathcal{A}^{(i)}$ é bem definido, *se e somente se*, para todo $\tilde{x} \in \mathcal{S}$, para todo $x^{(i)} \in \mathcal{S}^{(i)}$ e para todo $e \in \mathcal{E}$ tal que $\text{succ}_e(x^{(i)})$ for diferente de vazio:

$$\begin{aligned} &\forall y^{(i)}, z^{(i)} \in \text{succ}_e(x^{(i)}) \\ &\tau_e(x^{(i)}, y^{(i)})(\tilde{x}) = \tau_e(y^{(i)}, z^{(i)})(\tilde{x}) \\ &\left(\sum_{y^{(i)} \in \text{succ}_e(x^{(i)})} \pi_e(x^{(i)}, y^{(i)})(\tilde{x}) \right) = 1 \text{ ou um elemento funcional que vale 0 ou 1} \end{aligned}$$

Essa primeira restrição impõe que as tuplas de transição referentes a um mesmo evento e e referentes às transições de $\mathcal{A}^{(i)}$ saindo de um mesmo estado devam possuir a mesma taxa de transição. A soma das probabilidades de todas as transições saindo desse mesmo estado deve ser igual a 1 ou a um elemento funcional avaliado sobre $[0..1]$. Essas restrições têm por objetivo garantir a unicidade da definição das taxas de eventos em relação ao conjunto de transições em cada um dos autômatos.

Restrição 2. Um evento $e \in \mathcal{E}$ é bem definido, *se e somente se*:

$$\begin{aligned} &\forall \pi_1 \pi_2 \in [0, 1], \\ &\forall e_1 e_2 \in \mathcal{E}, \\ &\forall x^{(i)}, y^{(i)} \in \mathcal{S}^{(i)} \text{ tal que } y^{(i)} \in \text{succ}_e(x^{(i)}) \text{ e } x^{(i)} \neq y^{(i)}, \\ &\forall (e_1, \pi_1), (e_2, \pi_2) \in \mathcal{Q}^{(i)}(x^{(i)}, y^{(i)}) \\ &e_1 \neq e_2 \end{aligned}$$

A segunda restrição imposta aos eventos, afirma que uma tupla de transição (e, π) deve aparecer uma única vez no conjunto de tuplas de uma transição e o evento e deve pertencer ao conjunto de eventos $\mathcal{E}$.

¹O conceito de vivacidade está definido em função das possibilidades de disparo das transições. Uma transição é considerada viva se esta não é passível de um impasse ou *deadlock*.

²O conceito de irredutibilidade está definido quando todos os estados são possíveis de serem alcançados a partir de qualquer outro estado, isto é, a cadeia for fechada e não contiver subconjuntos fechados.

³A cadeia de Markov é dita ergódica se todos os seus estados são recorrentes, não periódicos e comunicantes.

Restrição 3. Um evento sincronizante $e \in \mathcal{E}$ é bem definido *se e somente se*, uma tripla de sincronização de autômato mestre aparece somente no autômato mestre ($\mathcal{A}^{(i)}$) e uma dupla de sincronização de autômato escravo só aparece no autômato escravo ($\mathcal{A}^{(i)}, i \in \mathcal{O}_e; i \neq e$).

Restrição 4. A função de atingibilidade $\mathcal{F}$ é bem definida, *se e somente se* o conjunto de estados atingíveis $\mathcal{R}$ é um grafo de transição fortemente conexo.

A quarta restrição assegura a irredutibilidade da cadeia de Markov correspondente ao modelo em SAN e permite empregar os teoremas padrões.

Restrição 5. Uma SAN é bem definida *se e somente se*:

- Todos os seus autômatos são bem definidos;
- Todos os seus eventos locais são bem definidos;
- Todos os seus eventos sincronizantes são bem definidos;
- Sua função de atingibilidade é bem definida.

Todas as restrições precedentes são indispensáveis para determinar uma SAN bem definida.

4.4 DESCRITOR MARKOVIANO

As vantagens do formalismo de SAN é a facilidade de descrever o gerador da Cadeia de Markov utilizando-se a fórmula matemática chamada Descritor Markoviano, apresentada na Equação 4.1. O descritor permite armazenar de forma compacta o gerador infinitesimal da cadeia de Markov associada a SAN.

- Dado um conjunto $\mathcal{E} \subset e$ de eventos sincronizantes. O comportamento de cada autômato $\mathcal{A}^{(i)}, i \in [1..N]$, é descrito por um conjunto de matrizes quadradas de dimensão n_i . Estas matrizes podem ser classificadas em duas famílias:
 - $\mathcal{Q}_l^{(i)}$ corresponde aos eventos locais de cada autômato $\mathcal{A}^{(i)}, i \in [1..N]$;
 - $\mathcal{Q}_{e^+}^{(i)}$ e $\mathcal{Q}_{e^-}^{(i)}$: $2\mathcal{E}$ matrizes contendo todas as tuplas de sincronização para cada evento $e \in \mathcal{E}$.

$$\mathcal{Q} = \bigoplus_{i=1}^N {}_g\mathcal{Q}_l^{(i)} + \sum_{e \in \mathcal{E}} \left(\bigotimes_{i=1}^N {}_g\mathcal{Q}_{e^+}^{(i)} + \bigotimes_{i=1}^N {}_g\mathcal{Q}_{e^-}^{(i)} \right) \quad (4.1)$$

Maiores detalhes sobre produto e soma tensorial podem se encontrados nos trabalhos de Plateau (1996) e Fernandes (1996).

4.5 AUTÔMATOS ESTOCÁSTICOS DE APRENDIZAGEM

Os autômatos são mecanismos de controle projetados para seguir automaticamente uma sequência predeterminada de operações ou responder a instruções codificadas. O termo estocástico enaltece a natureza adaptativa do autômato por não seguir regras pré-determinadas, mas por se adaptar às mudanças em seu ambiente.

A teoria de controle clássica tem seu processo baseado no completo conhecimento do sistema e/ou processo. Ou seja, o modelo matemático que o descreve é conhecido *a priori*. Durante a evolução desses sistemas, passou-se a considerar incertezas que se faziam presentes no sistema. A teoria do controle estocástico assume que algumas características das incertezas são conhecidas, mas podem, no entanto, não serem suficientes para o completo controle do sistema em caso de mudanças. Dessa maneira, torna-se necessário observar o processo para obter-se mais conhecimento. Isto é, devem-se adquirir informações adicionais, uma vez que as características iniciais não são suficientes, assim uma possível abordagem para tais problemas é vê-los como problemas de aprendizagem (NARENDRA; THATHACHAR, 1974; UNSAL, 1997).

Os sistemas baseados em regras, ainda que possuam bom desempenho, possuem como desvantagem a necessidade de modificações no espaço do problema, por não serem capazes de lidar com o imprevisto. O conceito por trás de um sistema de aprendizagem é garantir a robustez de seu comportamento sem o total conhecimento do meio ou do sistema em questão. Assim, observa-se como vantagem do sistema de aprendizagem por reforço em comparação a outras abordagens a não necessidade de informações sobre o sistema e/ou meio, exceto o sinal de reforço (NARENDRA; THATHACHAR, 1989; MARSH; GORDON; WU, 1993).

Em um sistema de aprendizagem por reforço, ainda que seja mais lento do que outras abordagens, na maioria das aplicações, as ações necessitam ser testadas um número significativo de vezes para que se tenha um desempenho satisfatório. Dessa forma, o processo de aprendizagem deve ser claramente mais rápido do que as modificações aconteçam no ambiente, ou a aprendizagem por reforço deve ser combinada a um modelo adaptativo que antecipe as mudanças no ambiente (PENG; WILLIAMS, 1993).

De acordo com Narendra (1974, p. 323), a aprendizagem é definida como qualquer alteração permanente no comportamento, resultante de uma experiência passada. Um sistema de aprendizagem deve possuir a capacidade de melhorar seu comportamento ao longo do tempo.

Quando não se possui qualquer informação sobre o sistema, o autômato estocástico é uma solução. Inicialmente, todas as suas ações e probabilidades são iguais. Quer dizer, uma ação é selecionada aleatoriamente e, com base em sua resposta, as probabilidades são atualizadas. Os autômatos que visam aprimorar seu desempenho são conhecidos como autômatos estocásticos de aprendizagem.

4.5.1 Autômato Estocástico

Na seção 4.2, foi introduzida a notação de SAN por meio de uma quadrupla, neste momento apresenta-se a notação apenas do autômato estocástico de aprendizagem, com base na notação proposta por Narendra (1974, p. 325) que é representada pela sêxtupla $\{\beta, \Phi, \alpha, c, A, G\}$, onde:

β	conjunto de entrada;
Φ	conjunto de estados internos do autômato, tal que $\phi = \phi_1, \phi_2, \dots, \phi_s$;
α	conjunto de ações, ou saídas do autômato, tal que $\alpha = \alpha_1, \alpha_2, \dots, \alpha_r, rs$;
c	vetor de probabilidades do estado que rege a escolha do estado em cada fase;
A	algoritmo do esquema de reforço que gera $p(n+1)$ de $p(n)$;
G	função de saída que pode ser determinística ou estocástica, onde $G : \phi \rightarrow \alpha$.

4.5.2 Ambiente

Os autômatos de aprendizagem podem ser demonstrados, por meio de um número finito de ações que podem ser realizadas de forma randômica. Ao realizar uma ação específica, o ambiente provê uma resposta aleatória que pode ser favorável ou não. A proposta do autômato é determinar como a escolha de uma ação em qualquer momento deve ser guiada por respostas e ações anteriores. É interessante notar que as decisões devem ser tomadas com pouco conhecimento sobre a “natureza” do ambiente. Além disso, a incerteza é devida ao fato de que a saída do ambiente é influenciada pela ação de outros agentes desconhecidos para o decisor (NARENDRA; THATHACHAR, 1974).

O ambiente onde o autômato “vive” responde às suas ações, por meio de respostas, que pertencem a um conjunto de respostas admissíveis e que são probabilisticamente relacionadas com suas ações. É de difícil definição o termo ambiente no contexto de autômatos de aprendizagem, pois tal definição contempla um ambiente aleatório desconhecido, onde o autômato deve operar. Matematicamente, um ambiente é representado por uma tripla α, c, β , onde α representa um recurso finito do conjunto de ações/saída, β representa um grupo (binário) de resposta/entrada do conjunto, e c é um conjunto de probabilidades de penalização, onde cada elemento c_i corresponde a um α_i do conjunto de ação α (UNSAL, 1997).

A ação/saída $\alpha(n)$ do autômato pertence a um conjunto α , e é aplicado ao ambiente no instante $t = n$. A entrada $\beta(n)$ do ambiente é um elemento do conjunto β que pode assumir os valores β_1 e β_2 . Em um caso mais simples, os valores de β_i podem ser 0 ou 1, onde 0 está associado com resposta de não penalidade e 1 com a resposta de falha/penalidade. Os elementos de c são definidos como (Equação 4.2):


$$Prob\{\beta(n) = 1 | \alpha(n) = \alpha_i\} = c_i, \quad (i = 1, 2, \dots) \quad (4.2)$$

Portanto c_i é a probabilidade da ação α_i resultar em penalidade de entrada do ambiente. Quando as probabilidades de penalidades c_i são constantes, ou seja, não dependem de n , o ambiente é definido como um *ambiente estacionário* (POZNYAK; NAJIM, 1997).

4.5.3 Autômato de Aprendizagem

Os autômatos de aprendizagem podem ser considerados como sistemas que modificam suas estratégias de controle com base em sua experiência para alcançar boas performances de controle, apesar das imprevisões das mudanças no ambiente em que está operando. Em outras palavras, os autômatos de aprendizado por meio da coleta e processamento de informações sobre o ambiente, devem ser capazes de mudar sua estrutura ao longo do tempo para assim alcançarem o objetivo a que se propõem.

Figura 21: Autômato de Aprendizagem



Fonte: Adaptado de (UNSAL, 1997, p. 32) e (NARENDRA; THATHACHAR, 1974, p. 325)

Na Figura 21, pode-se observar a conexão de realimentação do autômato estocástico e o ambiente. Nesse caso, as ações do autômato formam as entradas para o ambiente, e as respostas do ambiente, por sua vez, são as entradas do autômato, influenciando a atualização das probabilidades de ação. Como as respostas são aleatórias, o vetor de probabilidades de ação, denotado por $p(n)$, também é aleatório.

De acordo com Narendra (1974, p. 325), sob a perspectiva da psicologia, a experiência de aprendizagem de um organismo é dita quando se aumenta a probabilidade de respostas corre-

tas resultantes de sua interação com o ambiente. De forma similar, o autômato estocástico aqui abordado possui comportamento semelhante. Pode-se assim referir a esse como um autômato de aprendizagem. Em suma, um autômato de aprendizagem é um autômato estocástico que opera em um ambiente casual e atualiza suas probabilidades de ação, de acordo com as entradas que recebe do ambiente, de modo a melhorar seu desempenho.

Com base na natureza da entrada do autômato de aprendizagem, pode-se fazer a seguinte distinção:

- **Modelo-P:** o conjunto de entrada é binário, por exemplo $\beta = 0, 1$;
- **Modelo-Q:** o conjunto de entrada é um conjunto finito de símbolos distintos, por exemplo $\beta = \beta_1, \beta_2, \dots, \beta_r$; e
- **Modelo-S:** o conjunto de entrada é um intervalo, por exemplo $\beta = a, b$.

4.5.4 Esquema de reforço

O esquema de reforço é à base do processo de aprendizagem dos autômatos de aprendizagem. Os esquemas são classificados com base em sua linearidade. Narendra (1989) apresenta uma variedade de sistemas lineares, não lineares e híbridos existentes para as várias estruturas de autômatos de aprendizagem. A característica de linearidade de um esquema de reforço é definida pela linearidade das funções de atualização g_k e h_k .

As primeiras pesquisas em esquemas de reforço centraram-se nos sistemas lineares por razões de simplicidade analítica. Eventualmente, a necessidade de esquemas de reforço mais eficientes e complexos, elevaram as pesquisas para sistemas não lineares e híbridos (UNSAL, 1997).

A ideia básica por trás do esquema de reforço é simples. Se selecionada a ação α_i no instante n ocorre uma entrada de não penalidade, a probabilidade de ação $p_i(n)$ é aumentada e todos os componentes de $p(n)$ são diminuídos. No caso contrário, para uma entrada de penalidade, $p_i(n)$ é diminuído e os outros componentes são aumentados. As alterações em $p_i(n)$ são conhecidas como recompensas ou penalidades, respectivamente.

Neste trabalho, será utilizado um esquema de reforço linear, pois não se têm variação na estrutura/topologia do autômato a cada interação sua com o ambiente. A definição geral do esquema de reforço linear pode ser obtida pelas funções na Equação 4.3 como se segue:

$$\begin{aligned} g_k(p(n)) &= \alpha \cdot p_k(n) \\ h_k(p(n)) &= \frac{\beta}{|p| - 1} - \beta \cdot p_k(n) \\ 0 &< \alpha, \beta < 1 \end{aligned} \tag{4.3}$$

Portanto, o regime linear é generalizado como:

Se $\alpha(n) = \alpha_i$,

$$\text{quando } \beta = 0 \quad \begin{cases} p_j(n+1) = (1 - \alpha) \cdot p_j(n) & \forall j \neq i \\ p_i(n+1) = p_i(n) + \alpha \cdot [1 - p_i(n)] \end{cases} \quad (4.4)$$

$$\text{quando } \beta = 1 \quad \begin{cases} p_j(n+1) = \frac{\beta}{|P|-1} + (1 - \beta) \cdot p_j(n) & \forall j \neq i \\ p_i(n+1) = (1 - \beta) \cdot p_i(n) \end{cases} \quad (4.5)$$

Pode-se ver na definição que o parâmetro α está associado com a resposta de recompensa e o parâmetro β com resposta de penalidade. Se os parâmetros α e β são iguais, o sistema é denominado de sistema linear de recompensa e punição, denotado por L_{R-P} (BUSH; MOSTELLER, 1955). Para este caso, a velocidade de atualização do vetor de probabilidades é igual em cada instante, independente da resposta do ambiente (UNSAL, 1997).

4.5.5 Trabalhos Anteriores em Autômatos Estocásticos de Aprendizagem

As pesquisas iniciais em modelagens de Autômatos de Aprendizagem foram desenvolvidas no campo da psicologia matemática, sendo as primeiras pesquisas realizadas por Bush (1955) e Atkinson (1965). Entretanto, somente em 1973, Tsetlin introduziu de forma operacional o conceito de autômato determinístico em ambientes estocásticos como um modelo de aprendizagem.

Varshavski (1963) descreveu a utilização de autômatos estocásticos, utilizando probabilidades de ação, que resultam em redução do número de estados se comparado com autômatos determinísticos.

A introdução dos autômatos estocásticos na literatura de controle deu-se inicialmente por Fu (FU; MCLAREN; ENGINEERING, 1965a; FU; MCMURTRY; ENGINEERING, 1965b; FU, 1994), por meio de aplicações em reconhecimento de padrões, estimativa de parâmetros e teoria dos jogos.

McLaren (1966) explorou as propriedades de esquemas de atualização linear e o conceito de crescimento do autômato. Chandrasekaran e Shen (1966, 1968) estudaram aos esquemas de atualização não lineares, jogos de autômatos e ambientes não estacionários. Já Narendra e Thathachar (1989) estudaram os autômatos de aprendizagem, realizando estudos e simulações na área. Em 1989, Narendra e Thathachar apresentaram uma introdução à teoria da aprendizagem de autômatos, fazendo um apanhado das pesquisas realizadas sobre o tema até o final da década de 1980. Najum e Pznyak em 1994 desenvolveram um estudo sobre a teoria e aplicações de autômatos de aprendizagem, e desde então, foram diversos os avanços e inúmeras às áreas de aplicação de autômatos estocásticos de aprendizagem.

4.6 HIPERTÔMATO

Como abordado anteriormente, os Sistemas Hipermídia são conceituados a partir da relação entre o Hipertexto e a Multimídia. O hipertexto é um sistema de visualização de informações, cujos documentos possuem referências internas, nomeados como *links* ou nós de informação, onde os usuários navegam de forma não linear. A multimídia compreende a variedade dos meios que se pode utilizar na representação das informações, como textos, imagens, áudios, vídeos, etc. (CASTELLARI; FERREIRA, 2007). Assim, os Sistemas Hipermídia são sistemas computacionais com ligações interativas, não sequenciais entre os nós de informações, como os Sistemas de Hipertexto, mas com a multiplicidade de representação da Multimídia.

Diversos modelos formais foram desenvolvidos ao longo dos anos para definir a estrutura e o comportamento da navegação em hiperdocumentos, por meio da modelagem baseada em *links*, conjuntos, grafos (ARDOT; PUJOLLE; TESTE, 1989), redes semânticas (SOWA, 1984), redes de Petri (STOTTS; FURUTA, 1989b) e ainda os baseados em autômatos. Pode-se encontrar nos trabalhos de Almeida (1999a, 1999b, 1999c, 1999d e 1999e) uma extensão do modelo de hipermídia como autômato apresentada no trabalho de Pagano (PAGANO, 1992), cujo modelo objetiva agrupar o comportamento do usuário, segundo preferências de aprendizagem. O traçado do perfil do usuário permite a inclusão de características no sistema que possam facilitar a individualização da construção da experiência no sistema (ALMEIDA; BARRETO, 2000a).

Assim sendo, um hiperdocumento fundamentado na Teoria dos Autômatos, incorpora não somente os aspectos dinâmicos, por meio da evolução do autômato no tempo em resposta às entradas de dados, mas também pelos aspectos declarativos como o diagrama de transição (ALMEIDA; BARRETO, 2000b). Basicamente, o conceito é que *caminhos no hiperdocumento são strings em uma linguagem formal*. Desse modo, um modelo teórico de hipermídia foi desenvolvido baseado na Teoria dos Autômatos, denominado hipertômato (BARRETO, 1999; ALMEIDA; BARRETO, 2000b), que inclui aspectos dinâmicos, ampliando as capacidades de criação e exploração de um ambiente hipermídia (POZZEBON et al., 2002b).

Em suma, um hipertômato é um hiperdocumento H com um conjunto de caminhos P definidos em um conjunto C de elementos de conteúdo. Formalmente definido como $H = (C, P)$ onde (STOTTS; FURUTA, 2004):

$$\begin{aligned} C &= \{c_i \mid 0 \leq i \leq k\} && \text{um conjunto finito de elementos de conteúdo;} \\ P &= \{p \mid p \in C^*\} && \text{um conjunto possivelmente infinito de sequências finitas sobre } C. \end{aligned}$$

A criação da hipermídia por meio de autômatos vem ao encontro da necessidade de sistemas computacionais individualizados, com conteúdos e caminhos construídos especificamente para cada nível de habilidade e objetivo dos usuários. Como a criação do material multimídia é independente do autômato, é possível criar diversos autômatos sobre a mesma base de materiais, cada qual com seu objetivo (MACHADO et al., 1999).

Os autômatos podem ser considerados como particularizações de sistemas dinâmicos, ou seja, correspondem a um sistema funcional temporal, cujos estados variam com o tempo dependendo da entrada do sistema. Em suma, o sistema possui uma saída em função do estado, do tempo e do valor de entrada em determinado instante, que é a resposta do sistema dinâmico, cabe ressaltar que entradas passadas influenciam o futuro, mas o contrário não é verdadeiro.

O hipertômato possui como vantagem a visualização no sistema de todos os nós (estados) e ligações (transições) possíveis de ocorrerem durante a interação do usuário. De acordo com Pozzebon (2002a, p. 2), a vantagem de construção do sistema por meio desta modelagem é a garantia de que todos os estados sejam alcançáveis, reduzindo desta forma muitos dos problemas de navegação como, por exemplo, evitar que o usuário se perca no hiperespaço. Outra vantagem é a facilidade de mudança no grafo do hipertômato, o que facilita as atualizações.

O conceito de estado conduz ao aspecto dinâmico do hipertexto, por meio da possibilidade de apresentação simultânea dos nós do hipertexto. Já a função de transição pode ser vista como os *links* (ligações) que conectam o hiperdocumento como um todo. A função de transição conduz o usuário de um estado a outro do hiperdocumento, dada uma sequência de entrada em um estado. As possibilidades de apresentação dependerão da completude do alfabeto de saída do hipertômato que inclui todas as formas de representação da informação visíveis pelo usuário no hiperdocumento, como tamanhos, formas, posições das imagens, sons, vídeos, textos, etc. (POZZEBON et al., 2002b).

5 MODELO PROPOSTO

Este capítulo apresenta o modelo de hipermídia adaptativa proposto, onde sob diferentes perspectivas são expostos seus níveis arquiteturais. Conforme ver-se-á no decorrer do capítulo, o modelo é conduzido a partir de conceitos presentes nos modelos de referência encontrados na literatura, expostos na seção 2.6.

O modelo é desenvolvido sob as concepções basais do Projeto DIGICONV, que nortearam o desenvolvimento do modelo. Entretanto, ressalta-se que tal base não perfaz influência na dinâmica prevista para o modelo, uma vez que o domínio de Televisão Digital sob o qual desenvolve-se não o restringe, servindo apenas como cenário de aplicação e testes.

Este capítulo está estruturado da seguinte forma:

- A seção 5.1 realiza a macro contextualização do modelo dentro do Projeto DIGICONV onde se encontra o Servidor de Acesso que agrega o modelo proposto;
- A seção 5.2 apresenta o modelo, em que nas seções 5.2.2 a 5.2.5 configuram-se em detalhes os módulos componentes, sendo eles: o Módulo de Serviço, o Módulo de Interação de Dados, o Módulo de Geração e o Módulo de Conversão;
- A seção 5.3 demonstra o *pipeline* executado pelo modelo, com o propósito de melhor esclarecer o funcionamento e as estruturas internas.

5.1 PROJETO DIGICONV


O Projeto DIGICONV consiste em uma plataforma de convergência digital IPTV, TV Digital e Dispositivos Móveis com a finalidade de viabilizar a disponibilização e recepção de conteúdos audiovisuais interativos (áudio, vídeo e dados (aplicações)) para sistemas de TV Digital e IPTV. Está caracterizado dentro do contexto de distribuição da TV Digital por IPTV na plataforma, o acesso ao serviço por dispositivos móveis (E.g. PC, *tablet*, *smartphone*, etc.). Desta forma, o trabalho contextualiza-se dentro do Projeto DIGICONV, em objetivo à distribuição individualizada de áudio e vídeo da plataforma aliado à motivação exposta no capítulo 1, em que enaltece-se a necessidade que se desenvolve por parte do usuário, do mercado e da indústria como um todo.

Para entender o cenário propiciado pela plataforma, observa-se na Figura 22 sua modularidade vista em alto nível. A estrutura visa contemplar as características de acesso e distribuição de conteúdo a que se propõe. Assim, divide-se em quatro módulos, que são:

- **Servidor de Acesso:** servidor de controle da distribuição de conteúdo e do acesso de usuários;
- **Servidor Multimídia:** servidor de armazenamento, controle e recuperação de mídias (audio, vídeo e dados);

- **PLAT_CONV**: servidor de codificação e multiplexação de sinais de áudio, vídeo e dados; e
- **ADAP_IP**: servidor de adaptação de sinais de áudio, vídeo e dados para distribuição IPTV.

Figura 22: Arquitetura sistêmica do Projeto DIGICONV



Fonte: Elaborado pelo autor

Por razões de objetividade, apresentar-se-á de forma sucinta, na sequência, apenas a arquitetura do Projeto DIGICONV referente ao Servidor de Acesso, onde o trabalho proposto se insere.

5.1.1 Servidor de Acesso

O Servidor de Acesso (Figura 23) está dividido em dois grandes blocos: o bloco de entrada que é responsável pelo gerenciamento das características de conexão e o bloco de controle que atua por meio de *web services* (WS) nos módulos internos da plataforma (SERVIDOR MULTIMÍDIA, PLAT_CONV e ADAP_IP), através de interfaces REST (*Representational State Transfer*)¹.

O Bloco de Entrada é constituído de quatro gerenciadores, que são:


- **Gerenciador de Dispositivos**: responsável por receber e tratar conexões recebidas dos dispositivos clientes, autenticando-os e criando as sessões de uso. Após a conexão, o

¹Tradução Livre: Transferência Representacional de Estado

usuário é submetido ao agente de segmentação que o coloca em um grupo de formato² de acordo com suas características.

- **Gerenciador de Usuários:** tem a função de identificar o usuário e o dispositivo bem como recuperar e persistir seus dados;
- **Gerenciador de Aplicações:** dada às necessidades dos clientes provê conteúdos interativos ligados a programação requisitada;
- **Gerenciador de Requisições:** com base no conteúdo armazenado no Servidor Multimídia e nas informações vindas dos gerenciadores de Dispositivos, de Usuários e de Aplicações, gera uma requisição de fornecimento de conteúdo ao Bloco de Controle, com informações específicas para a transmissão.

Figura 23: Arquitetura do Servidor de Acesso



Fonte: Adaptado de (GÓMEZ et al., 2012, p. 5)

O Bloco de Controle é responsável por receber, analisar e tratar a requisição encaminhada pelo Gerenciador de Requisições, parametrizando as interfaces dos módulos internos da plataforma e monitorando os fluxos de dados e de controle.

²Para maiores informações sobre os formatos definidos ver seção 5.2.1

5.2 ARQUITETURA DO MODELO

A partir da dinâmica de comunicação do Servidor de Acesso e do Gerenciador de Aplicações, desenvolveu-se a arquitetura proposta, denominada de MOHAI (*Model of Hypermedia for Adaptive Interface*). Com a finalidade de individualizar as atribuições, a arquitetura foi dividida em quatro módulos: Módulo de Serviço, Módulo de Interação de Dados, Módulo de Geração e Módulo de Conversão. A modularidade da arquitetura visa isolar comportamentos inerentes a cada um dos processos, gerando algumas vantagens, tais como: gerenciabilidade, compreensibilidade e flexibilidade.

A gerenciabilidade diz respeito diretamente ao tempo de produção. Se formados grupos de desenvolvimento distribuídos, esses quando organizados de acordo com suas *expertises* trabalhando paralelamente cada qual em um módulo distinto, reduzem o tempo de desenvolvimento.

A compreensibilidade relaciona-se ao aprendizado por parte do implementador, sendo possível a este apenas especializar-se no funcionamento de um módulo sem ser necessário conhecer toda a dinâmica da arquitetura.

Quando fala-se em flexibilidade toca-se em um ponto-chave e até mesmo crítico do desenvolvimento de *software*. Esse fator diz respeito diretamente à manutenibilidade, ou seja, às possibilidades de correções e de mudanças drásticas em um módulo sem mudar e/ou afetar os demais módulos.

Desenvolveu-se o MOHAI, observando-se características presentes nos modelos de referência consagrados na literatura (seção 2.6). Com base nesses modelos, são definidas propriedades dentro do contexto das técnicas aqui em uso. Tendo o MOHAI em comum com o modelo Munich, em sua estrutura basal, o modelo Dexter. Devido às suas características, o modelo proposto pode ser comparado em termos de funcionalidades com o o modelu Munich. A fim de estabelecer um paralelo, são apresentadas características que possuem relação entre os modelos. Sendo elas:


- A camada de execução, representada pelo Módulo de Serviço, é responsável por produzir instâncias de geração da interface;
- O modelo de domínio, diferentemente do modelo Munich, que é unificado, teve suas atribuições individualizadas. Isso se justifica, pois a modelagem conceitual da aplicação agora faz parte do Módulo de Geração e a representação da hipermídia é atribuição do Módulo de Conversão;
- Os componentes não estão associados por relações navegacionais (*links*) e ou conceituais, do tipo “parte de”, “pré-requisito de”, “variante de”, etc., mas por relações probabilísticas de interdependência inerentes a SAN como “se, então” e “ação/reação”;

- A semântica de composição é fragmentada, ou seja, elementos compostos podem ser formados não apenas por elementos atômicos, mas também por outros elementos compostos;
- O modelo de usuário e de adaptação são atribuições do Módulo de Interação de Dados que realiza a persistência “física” do dados. A SAN também desempenha tal função pois suas relações probabilísticas tendem a conduzir o aprendizado e persistir de forma “lógica” as regras de adaptação e características do usuário;
- Cada usuário possui um modelo individual que compõe sua SAN, em que o usuário e os componentes de seu histórico são identificados através de UID; e
- O Módulo de Conversão garante a construção dinâmica das páginas dado o efeito adaptativo produzido pelo Módulo de Geração.

No âmbito da engenharia de *software*, uma arquitetura pode ser classificada de duas formas. A primeira são as arquiteturas *WhiteBox*, que exigem um conhecimento íntimo da estrutura interna da arquitetura. Em contraste, as arquiteturas *BlackBox* utilizam composição modular. Como resultado, as alterações são mais fáceis de serem realizadas. No entanto, seu desenvolvimento é mais complexo, pois deve-se prever um maior número de potenciais casos de uso. Logo, o MOHAI pode ser classificado como uma arquitetura *BlackBox*, pois possui comportamento intermodular rígido, já seus módulos são *WhiteBox* com fraco acoplamento. Em outras palavras, internamente o módulo pode ser alterado sem disfunção dos fluxos da arquitetura.

Com base no ciclo clássico de adaptação proposto na literatura, desenvolveu-se o modelo proposto. Observa-se, na Figura 24, a modularização da arquitetura do MOHAI que é explicada e detalhes acerca da flexibilidade de cada módulo são apresentados.

Figura 24: Arquitetura do MOHAI



Fonte: Elaborado pelo autor

Indiretamente, o MOHAI acaba se assemelhando ao Modelo Dexter, que é dividido em camadas. A arquitetura do MOHAI apresenta-se, na forma de módulos que miscigenam às características. A Camada de Execução do Dexter tornou-se em parte o Módulo de Geração e o Módulo de Conversão e o de Interação de Dados absorveu as Camadas de Armazenamento e Interna aos Componentes e o Módulo de Serviço, aparece aqui como um adendo às necessidades do cliente, o Servidor de Acesso, interagindo com a parte externa do modelo.

5.2.1 Estruturação da solução

Antes de adentrar nas particularidades dos módulos da arquitetura, faz-se necessário expor como estrutura-se a solução, descrevendo as características que compõem sua organização. Ou seja, os embasamentos que conduzem ao entendimento sobre o seu papel no modelo

Ao se projetar o *layout* é preciso ter em mente quais as resoluções mais comuns nos dispositivos, para fazer com que a diferença de adaptação entre dispositivos seja minimizada. Dada à diversidade de resoluções de tela presentes na gama de dispositivos atualmente no mercado, torna-se impraticável desenvolver um *layout* específico para cada um.

Devido à similaridade entre os conceitos de visualização e interatividade utilizados na *Internet* e na TV Digital, uma vez possuem em comum os dispositivos de acesso. Tomou-se como guia o trabalho de Guerrato (2013), em que os dispositivos são agrupados em 5 formatos de acordo com a largura das resoluções de suas telas. Os formatos definidos são apresentados na Tabela 10, conjuntamente aos intervalos de largura em *pixels* que definem a característica de cada formato:

Tabela 10: Formatos para larguras de dispositivos

Largura (px)	Formato	Largura (px)	Principais dispositivos da categoria
	Formato 1	≥ 1200	televisores e monitores <i>widescreen</i>
1200	$>$ Formato 2	≥ 960	<i>tablets</i> em formato paisagem e monitores antigos
960	$>$ Formato 3	≥ 768	<i>tablets</i> em formato retrato
768	$>$ Formato 4	≥ 480	<i>smartphones</i> em formato paisagem
480	$>$ Formato 5	≥ 320	<i>smartphones</i> em formato retrato

Fonte: Elaborado pelo autor

Partindo dos formatos definidos, definiu-se o princípio de desenvolvimento por meio de *grids*, que estão fundamentados na proporcionalidade dos elementos na tela do dispositivo. O desenvolvimento por meio de *grids* foi adotado por ser uma prática já consolidada no desenvolvimento de *layouts*.

O processo de criação do *grid* é feito divisão de sua estrutura em pedaços menores. Para se manter a simetria do *grid*, é ideal a definição de um número par de colunas que seja divisível por 2, 3 e/ou 4. Tendo já determinados tais conceitos de resolução e de simetria, foram designados (Tabela 11) para cada um dos formatos de tela os seguintes números de colunas:

Tabela 11: Número de colunas por formato


Formato	Colunas
Formato 1	12 colunas
Formato 2	10 colunas
Formato 3	8 colunas
Formato 4	6 colunas
Formato 5	4 colunas

Fonte: Elaborado pelo autor

Por questões estéticas, considera-se no *grid* uma margem de 3% da largura da tela entre cada coluna, desta forma a largura proporcional das colunas do *grid*, considerando as margens é estabelecida pela Equação 5.1:

$$LarguraColuna = \frac{100\% - (3\% \times (NumeroColunas + 1))}{NumeroColunas} \quad (5.1)$$

Para fins de brevidade, a Figura 25 apresenta apenas as configurações múltiplas de 2, 3 e 4 em um *layout* de 12 colunas. Salienta-se que a quantidade de colunas e combinações não se limita a essa, ou seja, qualquer combinação entre os múltiplos é uma configuração factível, dentro dos formatos definidos. O *layout* uma vez estruturado, é fixo e vai se adaptando ao longo do tempo. Quer dizer, no próximo acesso do usuário, suas características serão inseridas, contemplando o aprendizado desenvolvido durante a interação com a interface.

Figura 25: Configurações do *grid*


Fonte: Elaborado pelo autor

Cada célula do *grid* é vista como um espaço alocável para um objeto a ser colocado no *layout*. Analogamente, esse conceito de colocação de objetos no *grid* é realizado por meio de uma abstração do problema da mochila. Dessa abstração é feita a modelagem matemática, em que as metaheurísticas buscarão as soluções.

Deve-se ter em mente que os itens possíveis de serem colocados na mochila são conhecidos *a priori*, porém, não se sabe a ordem na qual chegarão, nem o tamanho do compartimento em que serão alocados, ou mesmo, se chegarão a compor a interface. Assim, essas adversidades caracterizam o problema da mochila como estocástico, da mesma forma ao referido na seção 3.1, o problema de decisão da mochila é determinado pela teoria da complexidade computacional como *NP-Completo*, no entanto, sua versão de otimização é caracterizada como *NP-Difícil*. Nessa modelagem tem-se ainda o complicador da estocasticidade a qual o modelo provê.

A Figura 26 mostra a estruturação hierárquica de uma solução de mochila hipotética, em que se pode entender cada um dos conceitos relacionados ao problema. Dessa maneira, identifica-se a noção de mochila, de compartimento como uma coleção de agrupamentos e de um agrupamento como um conjunto de itens. Os itens por si só são os elementos hipermídia.

Figura 26: Estrutura hierárquica da mochila



Fonte: Elaborado pelo autor


5.2.2 Módulo de Serviço

O Módulo de Serviço é responsável por efetuar a ligação entre o cliente que é externo, no caso o Gerenciador de Aplicações, que se vê em destaque na Figura 23 do Servidor de Acesso e os módulos internos da arquitetura. Esse módulo possui dois agentes com comportamentos estritos de interface, sendo eles o Agente Gerenciador e o Agente Controlador.

O Gerenciador de Aplicações quando obtiver demandas de geração para grupos específicos de usuários e de dispositivos, aciona de forma intermitente o Agente Gerenciador, como se vê na Figura 27. O Agente Gerenciador por sua vez, instancia o Agente Controlador para atender ao pedido. Nesse momento, têm-se paralelamente múltiplos Agentes Controladores trabalhando em prol da geração de cada uma das demandas individuais.

O Agente Controlador comunica-se com os módulos internos acionando e controlando os fluxos de dados e informações necessárias ao funcionamento desses, a fim de possuir um fluxo de informações rígido, em que o funcionamento de um módulo não interfira no outro. Ao final, ao obter a interface gerada, o Agente Controlador entrega a interface ao Agente Gerenciador que a encaminha ao Gerenciador de Aplicações para atender seus usuários.

Figura 27: Detalhamento do Módulo de Serviço



Fonte: Elaborado pelo autor

Referente à flexibilidade desse módulo, evidenciou-se previamente a figura do cliente, através do Gerenciador de Aplicações. Cabe esclarecer que esse não se limita exclusivamente ao domínio de TV Digital, separando assim o papel desempenhado pelo Servidor de Acesso dentro do modelo proposto.

Elevando-se o nível de abstração e expandindo-o a outros domínios que demandem geração de *layout*, como, por exemplo: geração de malhas de distribuição elétrica e hidro sanitária, geração de *layout* de placas eletrônicas em nível de trilhas e componentização, planejamento urbano e de malhas viárias, redes de telecomunicação e até mesmo na construção civil para ge-

ração de plantas baixas, entre inúmeras outras áreas. Assim, têm-se a configuração de diferentes formas de usuários, demonstrando o potencial da flexibilização desse módulo.

5.2.3 Módulo de Interação de Dados

O Módulo de Interação de Dados é responsável por efetuar a persistência de dados nos Bancos de Dados (BD). Gerenciá-los também é parte de suas atribuições: a geração da SAN, dada uma requisição do Módulo de Serviço. Desse módulo fazem parte, o Agente de SAN e as bases de dados contendo as informações dos usuários, dos componentes da interface, das características dos dispositivos e das regras de adaptação.

5.2.3.1 Agente de SAN

O Agente de SAN quando acionado pelo Agente Controlador recebe como parâmetros, um conjunto de usuários e de dispositivos agrupados de acordo com um formato pré-definido. Com base nesses parâmetros, o agente realiza a consulta nos bancos de dados, extraindo as informações necessárias a montagem da SAN, que é um hipertômato. Ou seja, um autômato de hipermídia em forma de rede estocástica.


Verifica-se as Figuras 28, 29 e 30 a topologia da SAN, que é fixa, em que o autômato $\mathcal{A}$ é uma composição de três subautômatos que não possuem funções de probabilidades em seus arcos, apenas taxas de probabilidades. Cabe enaltecer que os autômatos do modelo desenvolvido utilizam uma SAN de topologia fixa com taxas de probabilidades, mas o modelo não se limita a essa concepção, estendendo-se ao uso de topologias mistas, variáveis e com taxas funcionais. Como característica provinda do Modelo HAM, as probabilidades, sejam elas taxas ou funcionais, por estarem atribuídas aos arcos da rede, representam indiretamente os atributos que definem os objetos descritos na SAN.

O desenvolvimento e o conhecimento aprofundado das diversas formas de adaptação, forneceram embasamento para projetar um modelo que suportasse todas as três possibilidades de adaptação (conteúdo, apresentação e navegação). O escopo desta pesquisa contempla apenas o desenvolvimentno da SAN para o domínio da apresentação da hipermídia, efetuando a reestruturação do *layout* com base nas características do usuário. Em suma, o modelo apresentado é capaz de comportar a expansão da SAN, através da estruturação das redes que descreveriam os demais domínios.

Na Figura 28, evidencia-se o autômato que projeta o *layout* de uma aplicação, efetivando a separação entre a camada de apresentação (*layout*) e a camada de execução (componentes). Para que se entenda seu comportamento, deve-se saber como estrutura-se o *layout*, mais especificamente o *grid*, que é a sua base. O *grid* é uma composição formada pela *viewport* que contém um conjunto de linhas. Essas linhas comportam as colunas, que possuem as células, que são espaços alocáveis pelos itens da interface – elementos hipermídia. Tal estruturação hierárquica

reforça a concepção basal do modelo estar fundamentada em um problema da mochila.

Figura 28: Composição do Autômato $\mathcal{A}^{(1)}$ - Autômato de *Layout*



Fonte: Elaborado pelo autor

Para validação dos autômatos, fez-se uso de expressões regulares³, como a Equação 5.2 utilizada para validar o autômato de *layout*. Cabe notar que, as expressões regulares validam somente os autômatos e não cada uma das soluções geradas. Parte-se do princípio que, se o autômato estiver válido, todas as *strings* que por ele passarem serão válidas. Esta opção deu-se, devido a demora para validação por meio das expressões regulares, tornando o processo de otimização extremamente lento.

$$(((A\{1\})((B\{1\})((CD\{1,\})(D*))+)+)+) \quad (5.2)$$

A Figura 29 trabalha o conceito de atomicidade proposto pelo *Tower Model*, apresentado na seção 2.6.4, em que se têm os componentes de forma atômica, ou seja, os nós desse autômato são nós raiz e representam componentes passíveis de divisão ou não. De forma complementar, como uma herança do Modelo HAM, que introduziu o conceito de componente composto, a Figura 30 exibe o autômato de um componente composto, no caso, o componente de lista (*Estado S9*), encadeado do autômato da Figura 29.

³Detalhes adicionais sobre a sintaxe das expressões regulares pode ser encontrados em: ADDEDBYTES. **Regular Expressions Cheat Sheet (V2)**. 2013. Disponível em: <<https://www.addedbytes.com/cheat-sheets/regular-expressions-cheat-sheet/>>. Acesso em: 07 de Novembro de 2013.

Os autômatos de componentes atômicos e composto também foram validados por expressões regulares, sendo elas respectivamente as Equações 5.3 e 5.4.

$$(((I*)(E*)(F*)(G*)(H*)))+) \quad (5.3)$$

$$((J)|(K)|(L)) \quad (5.4)$$

Retomando o conceito de autômato de aprendizagem apresentado no capítulo anterior, o Módulo de Geração explicado a seguir, ao fim de seu processo, também fornecerá ao Agente de SAN o efeito adaptativo produzido para que este possa atualizar as bases de dados com a experiência do usuário. O Módulo de Geração faz o papel do ambiente estocástico no autômato de aprendizagem, e o efeito adaptativo é a saída desse ambiente, que, por meio do esquema de reforço, atualiza a SAN com o conhecimento gerado pelo ambiente. Desse modo, as novas experiências do usuário servem como memória, acelerando o processo de geração para futuras interações no sistema.

5.2.3.2 Bancos de Dados

Os Bancos de Dados (BD) são responsáveis pela persistência física dos dados e estão dividido em 4. Sendo eles:

O BD de Perfil de Usuário contém informações pessoais do usuário, como, por exemplo, *login*, senha, idade, etc., além do histórico de quantas vezes o usuário já utilizou o sistema e com quais dispositivos têm experiência.

O BD de Perfil de Componentes armazena o histórico de interação do usuário com cada componente ao longo de sua história no sistema. Inicialmente, quando do primeiro acesso do usuário, a base de dados se encontrará vazia. Assim, serão consideradas “neutras” as probabilidades que alimentarão a SAN, ou seja, a probabilidade de cada componente é igual. Outra possibilidade é a verificação de tendência nos modelos de usuários armazenados.

Para fins de delimitação do escopo, são considerados 5 componentes, sendo eles: áudio, vídeo, texto, imagem e lista, que podem ser vistos no autômato de componentes atômicos na Figura 29 exposta previamente. Esses componentes foram delimitados a fim de nortear as necessidades da pesquisa, mas não se restringem apenas a esse conjunto.

O BD de Perfil de Dispositivos comporta dados dos dispositivos e suas características. Sugere-se que esse banco de dados seja alimentado por dados provenientes de um DDR (*Device Description Repository*)⁴, como, por exemplo, o WURFL (*Wireless Universal Resource FiLe*)⁵, ou outro similar. Esse tipo de estrutura, além de armazenar informações e características de milhares de dispositivos, permite identificá-los durante suas solicitações HTTP (*Hypertext Trans-*

⁴Tradução livre: Repositório de Descrição de Dispositivos

⁵MOBILE, S. Disponível em: <<http://wurfl.sourceforge.net/>>. Acesso em: 24 de Junho de 2013.

*fer Protocol*⁶). Preconiza-se o uso do projeto WURFL, devido à quantidade de dispositivos cadastrados e às diversas APIs (*Application Programming Interface*⁷) – algumas distribuídas gratuitamente para acesso a sua base de dados.

Os experimentos realizados utilizaram um conjunto de 25 dispositivos com informações provenientes do WURFL. Esse conjunto de dispositivos está igualmente distribuído entre os 5 formatos definidos anteriormente na seção 5.2.1 e serão vistos em detalhes na seção 6.1.

O BD de Regras de Adaptação contém a definição das regras de adaptação, levando em consideração os aspectos de conteúdo, apresentação e navegação adaptativa como proposto por Kock (2000). Em termos de adaptação de conteúdo, ele contém informações de qual conteúdo será complementado e/ou substituído. Já quanto à apresentação, é definido como um elemento será representado ou até mesmo substituído por outro, ou seja, a inter-relação entre cada item. A navegação leva em consideração a presença do componente no dispositivo. Em resumo, esse banco de dados é constituído por um conjunto de tuplas que determinam aos pares a condição do tipo “se ..., então” e “ação/reação”. Esse banco de dados é basilar pois determina para o Módulo de Geração como os nós presentes no autômato dadas suas probabilidades serão inseridos na solução gerada.

Com relação à flexibilidade, esse é um módulo chave, pois contém as diretivas do domínio da aplicação. Quando da necessidade de alterar o objetivo do modelo de geração de *layout* para aplicações em outros domínios, cabe apenas alterar a estrutura da SAN e os bancos de dados, sem interferir nos demais módulos.

5.2.4 Módulo de Geração

O Módulo de Geração, quando acionado pelo Agente Controlador, inicia seu funcionamento, após o Módulo de Interação de Dados gerar a SAN. Esse módulo contém um agente que coordena as metaheurísticas, no processo de geração do *layout*. Recebe, também, a descrição/especificação da aplicação, como, por exemplo, a vista na Figura 31, que serve como guia para o agente consultar a inter-relação dos componentes no BD de Regras de Adaptação.

Dentre as diversas formas de descrição de dados, o modelo proposto faz uso do formalismo de SAN já evidenciado. Com base no conceito de composição de modelo de dados de Ullman (1989, p. 32), tem-se o Módulo de Interação de Dados como uma forma de descrição dos dados e o Módulo de Geração aqui apresentado, como operador e manipulador desses.

Deve-se ter em mente que o problema de geração de interfaces adaptativas por si só não é um problema de otimização, mas sob a ótica adotada neste trabalho, considera-se que seja. Isso se deve pelo fato de o problema é modelo com base em uma abstração do problema da mochila. Faz-se assim necessário o uso de técnicas de otimização, mais especificamente, o uso de metaheurísticas, pois esse problema traduz-se na teoria da complexidade computacional

⁶Tradução livre: Protocolo de Transferência de Hipertexto

⁷Tradução livre: Interface de Programação de Aplicativos

como um problema de complexidade NP-Difícil.

Figura 31: Descrição da Aplicação em XML

```

1    <application>
2        <image src="LOGO.png" />
3        <list>
4            <item>
5                <image src="imagem1.png" />
6                <text> Título 1 </text>
7                <text> Texto 1 </text>
8            </item>
9            <item>
10               <image src="imagem2.png" />
11               <text> Título 2 </text>
12               <text> Texto 2 </text>
13           </item>
14           <item>
15               <image src="imagem3.png" />
16               <tcxt> Título 3 </tcxt>
17               <text> Texto 3 </text>
18           </item>
19           <item>
20               <image src="imagem4.png" />
21               <text> Título 4 </text>
22               <text> Texto 4 </text>
23           </item>
24           <item>
25               <image src="imagem5.png" />
26               <text> Título 5 </text>
27               <text> Texto 5 </text>
28           </item>
29       </list>
30       <text> Rodapé </text>
31   </application>

```

Fonte: Elaborado pelo autor

A aplicação da Figura 31 serve apenas de ilustração, pois este trabalho não visa projetar uma linguagem de descrição de interface, visto já existirem modelos consolidados e em uso atualmente. A não adoção dessas linguagens deve-se a suas abrangências, o que para a prova de conceito desenvolvida nesta pesquisa não torna-se interessante.

A flexibilidade desse módulo refere-se às possibilidades de usos de diferentes metaheurísticas, pois o Agente Controlador comunica-se com os Agentes Otimizadores por meio de interfaces. Isso permite alternar livremente entre o ferramental disponível além do uso, ou da definição de linguagens de descrição próprias do domínio em questão.


5.2.4.1 Agente Coordenador

O Agente Coordenador visa acionar os agentes otimizadores para que executem as metaheurísticas. Ao final do processo, o Agente Coordenador possuirá os resultados provindos da etapa de otimização de cada metaheurística e repassará a melhor solução ao Módulo de Conversão, que recebe como entrada um efeito adaptativo, como o exposto na Figura 32, ou seja, um *layout*, que, nesse contexto de otimização, é a solução final vinda de uma das metaheurís-

ticas. Como dito, este entende a solução de entrada como um efeito adaptativo, para, então, convertê-la em uma interface (Figura 37), a ser fornecida aos usuários finais.

Pode-se observar na 32, uma representação visual da solução, que chama-se de efeito adaptativo. Este efeito adaptativo está baseado na aplicação descrita na Figura 31. Atentando-se a uma particularidade das células, veem-se os estados que compõem a solução, que está alicerçada nos autômatos de componentes vistos na seção 5.2.3.1. A partir desse momento, poder-se-á melhor compreender o fluxo presente entre os módulos, pois adota-se uma nomenclatura comum sempre sob a mesma aplicação.

Figura 32: Efeito Adaptativo



Fonte: Elaborado pelo autor

5.2.4.2 Agentes Otimizadores

As populações iniciais e/ou solução inicial das metaheurísticas serão geradas aleatoriamente. O agente otimizador do Algoritmo Genético utiliza como processo de seleção a seleção por torneio, pois segundo Wickert (2012, p. 78) a vantagem desse método é propiciar a indivíduos menos aptos cruzarem-se com indivíduos mais aptos, levando o algoritmo a áreas inexploradas e ao longo das gerações melhorar o valor da Função Objetivo.

O operador de cruzamento utilizado é o PMX (*Partially-Matched Crossover*⁸), pois preserva as informações. Esse operador gera novos filhos escolhendo uma subsequência de um pai e preservando a ordem e posição do maior número de informações possíveis do outro pai. A subsequência de uma possível solução é selecionada escolhendo-se aleatoriamente dois pontos de corte, que servirão como fronteira para a operação de troca (MICHALEWICZ, 1996).

O operador de mutação, tem como objetivo manter a diversidade da população e tem probabilidade variada, de acordo com o experimento. A mutação realizada é uniforme, sendo

⁸tradução livre: Cruzamento combinado parcialmente

feita por substituição de uma posição da solução. Como foram utilizadas letras para representação, o operador é aplicado em todo o cromossomo. Já o critério de parada definido é o número de gerações, estabelecido em 2500.


No agente otimizador da Busca Tabu, o critério de aspiração é por melhora da FO, ou seja, mesmo que o movimento seja tabu ele é perdoado se melhorar o valor da FO. A vizinhança da BT é gerada por meio de substituição aleatória de uma posição da solução, sendo que na posição sorteada é gerada uma nova solução aleatória viável. A cada iteração serão gerados 100 vizinhos, em que o melhor passa a ser a solução atual, a partir da qual, sucessivamente são gerados novos vizinhos. Como critério de parada, definiu-se o número máximo de interações sem melhora (NBmax). As parametrizações de cada um dos testes efetuados estão descritas na seção 6.3.

5.2.4.3 Algoritmo Memético proposto

Além dos agentes otimizadores mencionados, propõe-se um agente otimizador do Algoritmo Memético, oriundo da hibridização entre o Algoritmo Genético e a Busca Tabu. O processo de hibridização visa captar a essência de cada uma das técnicas para encontrar uma melhor configuração e agrupá-la sob um mesmo algoritmo. Sinteticamente, pode-se dizer que o Algoritmo Memético proposto alia o poder de diversificação do Algoritmo Genético com a capacidade de intensificação da Busca Tabu.

A Figura 33 exibe o fluxograma do Algoritmo Memético proposto, em que inicialmente é gerada a população inicial e avaliada a aptidão de seus indivíduos. Na sequência, avalia-se o critério de parada, que, caso seja satisfeito, finaliza o algoritmo e a solução encontrada é encaminhada ao Agente Coordenador. Caso contrário, inicia-se o processo do AG para guiar a busca para uma região promissora do espaço de soluções.

Figura 33: Fluxograma do Algoritmo Memético proposto



Fonte: Elaborado pelo autor


Nesse momento, aplica-se a BT sobre os 10% melhores indivíduos da população para refinar as soluções, melhorando-as ainda mais. Findados os processos de otimização, é avaliada novamente a condição de parada, que, caso não seja satisfeita, retorna ao início do ciclo. Assim, entra mais uma vez em cena o Algoritmo Genético, para, com suas estratégias, inserir e perpetuar boas características dessa região do espaço para outras regiões pouco ou nem mesmo exploradas.

5.2.4.4 Estrutura da solução

O conjunto de elementos que representam uma solução, presentes em um *layout*, são programados, através de uma estrutura composta por 4 *strings*. Sendo elas:

- **String de Layout:** descrita pelo autômato de *layout*, representa a *viewport*, as linhas, as colunas e as células;
- **String de Colunas:** esta *string* contém *chars* que representam a largura das colunas;

Figura 36: Tríade da Solução



Fonte: Elaborado pelo autor

5.2.4.5 Modelo Matemático

Nesta seção, apresentar-se-á a Função Objetivo (FO) e as restrições, onde para cada variável de decisão são definidos os intervalos de valores viáveis. A modelagem é uma adaptação desenvolvida a partir do trabalho de Morton (1998) e considera uma abstração do problema da mochila estocástica compartimentada e fragmentada, conforme já exposto. O fator estocástico diz respeito à imprevisibilidade dos itens e aos compartimentos da mochila, além das relações dos históricos dos usuários. O resultado da formulação objetiva maximizar qualitativamente a ocupação da mochila, vista nesse contexto como dois termos.

$$\text{Max } FO = \frac{(A\alpha - \frac{1}{B}\beta)}{|I||J||K|q} \quad (5.5)$$

$$A = \left(\sum_{g=1}^G \sum_{h=1}^H \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K (V_{ghijk} - E[c_{ghijk}]) Y_{ghijk} \right) \quad (5.6)$$

$$B = \left(\sqrt{\sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K F_{ijk_1} - F_{ijk_2}^2} \right) \quad (5.7)$$

Sujeito a:

$$V_{ghijk} = \sum_{g=1}^G \sum_{h=1}^H \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K E[v_{ijk}] X_{ghijk} \quad (5.8)$$

$$L_{jk} = \sum_{g=1}^G \sum_{h=1}^H \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K \text{Var}(w_{ijk}) X_{ghijk} \quad (5.9)$$

$$L \geq L_{jk} \quad (5.10)$$

$$L_{ghijk}^{\min} \leq L_{jk} + P_{ghijk} \leq L_{ghijk}^{\max} \quad (5.11)$$

$$z_{ijk} \geq \sum_{g=1}^G \sum_{h=1}^H \sum_{i=1}^I \sum_{j=1}^J \sum_{k=1}^K X_{ghijk} Y_{ghijk} \quad (5.12)$$

$$F_{ijk} > 0 \quad (5.13)$$

$$w_{ijk} > 0 \quad (5.14)$$

$$v_{ijk} > 0 \quad (5.15)$$

$$z_{ijk} \geq 0 \quad (5.16)$$

$$c_{ghijk} \geq 0 \quad (5.17)$$

$$L > 0 \quad (5.18)$$

$$L_{jk} > 0 \quad (5.19)$$

$$L_{ghijk}^{min} > 0 \quad (5.20)$$

$$L_{ghijk}^{max} > 0 \quad (5.21)$$

$$P_{ghijk} \geq 0 \quad (5.22)$$

$$X_{ghijk} \geq 0 \quad (5.23)$$

$$Y_{ghijk} \geq 0 \quad (5.24)$$

$$|G|, |H|, |I|, |J|, |K| > 0 \quad (5.25)$$

$$\alpha > 0 \quad (5.26)$$

$$\beta > 0 \quad (5.27)$$

Onde:

F_{ijk}	grau de experiência do componente i para o usuário j no dispositivo k ($F_{ijk} \in \mathbb{N}^* F_{ijk} \subset [0; 1]$);
w_{ijk}	peso do componente i para o usuário j no dispositivo k ($w_{ijk} \in \mathbb{N}^* w_{ijk} \subset]0; 1]$);
v_{ijk}	valor de utilidade do componente i para o usuário j no dispositivo k ($v_{ijk} \in \mathbb{N}^* v_{ijk} \subset]0; 1]$);
z_{ijk}	limite máximo de componentes i na mochila do usuário j no dispositivo k ($z_{ijk} \in \mathbb{N}^* z_{ijk} \subset [0; 1]$);
c_{ghijk}	custo do compartimento g com o agrupamento h de itens i na mochila do usuário j no dispositivo k ($c_{ghijk} \in \mathbb{N}^* c_{ghijk} \subset [0; 1]$);
L	capacidade geral da mochila ($L \in \mathbb{N}^* L \subset [0; 1]$);
L_{jk}	capacidade da mochila do usuário j com o dispositivo k ($L \in \mathbb{N}^* L \subset]0; 1]$);

L_{ghijk}^{min}	capacidade mínima do compartimento g para comportar o agrupamento h de componentes i na mochila do usuário j no dispositivo k ($L_{ghijk}^{min} \in \mathbb{N}^* L_{ghijk}^{min} \subset [0; 1]$);
L_{ghijk}^{max}	capacidade máxima do compartimento g para comportar o agrupamento h de componentes i na mochila do usuário j no dispositivo k ($L_{ghijk}^{min} < L_{ghijk}^{max} \leq L$) e ($L_{ghijk}^{max} \in \mathbb{N}^* L_{ghijk}^{max} \subset]0; 1]$);
P_{ghijk}	perda decorrente da inclusão de um novo compartimento g com agrupamento h , de itens i na mochila do usuário j no dispositivo k ($P_{ghijk} \in \mathbb{N}^* P_{ghijk} \subset [0; 1]$);
X_{ghijk}	número de itens no compartimento g no agrupamento h de itens do tipo i na mochila do usuário j com o dispositivo k ($X_{ghijk} \in \mathbb{N}^*$);
Y_{ghijk}	número de vezes que o compartimento g é alocado com o agrupamento h de itens i é repetido na mochila do usuário j com o dispositivo k ($X_{ghijk} \in \mathbb{N}^*$);
$G = \{1, \dots, g\}$	conjunto de compartimentos ($g \in \mathbb{N}^*$);
$H = \{1, \dots, h\}$	conjunto de agrupamentos ($h \in \mathbb{N}^*$);
$I = \{1, \dots, i\}$	conjunto de itens ($i \in \mathbb{N}^*$);
$J = \{1, \dots, j\}$	conjunto de usuários ($j \in \mathbb{N}^*$);
$K = \{1, \dots, k\}$	conjunto de dispositivos ($k \in \mathbb{N}^*$);
$q = \{2, 4, 6, 8, 10, 12\}$	quantidade de colunas por formato de <i>layout</i> ;
E	Denota o valor esperado de uma variável aleatória, também chamado de esperança matemática ou expectância;
Var	Denota a variância de uma variável aleatória, ou seja, é a medida da sua dispersão estatística, indicando quão longe em geral os seus valores se encontram do valor esperado.

A Função Objetivo (Equação 5.5) está dividida em dois termos, cada um responsável por um fator preponderante na FO. Cabe notar que o processo de otimização é delimitado pelas regras de adaptação e probabilidades da SAN. As Equações 5.6 e 5.7 expõem os termos A e B, respectivamente. O papel do termo A prepondera no volume ocupado por cada item, levando em consideração a diferença da expectância dos itens colocados na mochila e do compartimento por eles alocados em prol do número de vezes que esse é inserido na solução. Em suma, determina quais elementos são inseridos em cada compartimento dada sua conjuntura na SAN.

Já o termo B leva em consideração a diferença entre as experiências dos usuários com cada componente/item nos dispositivos de seu histórico, em outras palavras, a distância entre o *know-how* dos usuários. Esse, por ser um fator que se deseja minimizar, é apresentado sob a forma inversa, pois a modelagem realizada é de maximização. Esse fator se faz importante, a medida que considera as experiências dos usuários para constituir seus modelos. No entanto,

cabe esclarecer que tal fator não é determinante para a qualidade da solução, apenas na construção do modelo de usuário. Na seção 6.2.1.5, elucidar-se-á o critério de optimalidade com base nos termos descritos.

As restrições são garantidas pelas Equações 5.8 a 5.27 e estão divididas em dois grupos:

- **Grupo 1** – as restrições 5.8 a 5.12 visam restringir as capacidades das mochilas e de seus compartimentos;
- **Grupo 2** – as restrições 5.13 a 5.27 garantem a não nulidade das variáveis, sendo as restrições 5.26 a 5.27 os parâmetros responsáveis por equalizar a Função Objetivo de forma a não a deixar tendenciosa sob nenhum dos termos componentes da FO.

5.2.5 Módulo de Conversão

O Módulo de Conversão possui o Agente Conversor que funciona em conjunto com um perfil gráfico de linguagem (E.g. Perfil NCL (*Nested Context Language*), Perfil HTML (*Hyper-Text Markup Language*)). Os perfis de linguagem contêm informações de como são codificados os componentes indicados no efeito adaptativo produzido no Módulo de Geração. O Agente Conversor faz uso do perfil de linguagem e do efeito adaptativo, traduzindo as informações dos componentes em linguagem de marcação. Dependendo da demanda gerada pelos usuários, o Agente Conversor receberá diferentes efeitos adaptativos/*layouts*, gerando assim, diferentes interfaces.

Esse módulo possui grande flexibilidade, pois seu funcionamento é independente do perfil de linguagem. Dito de outra forma, é possível gerar interfaces para diferentes cenários e/ou dispositivos que usem outras linguagens ou possuam diferentes necessidades.

5.3 Pipeline

Sob o conjunto de figuras¹¹ que descrevem a solução em diferentes estágios do *pipeline* da arquitetura, cabe deter especial atenção na Figura 26, em que visualiza-se a estruturação do problema, isto é, a hierarquia criada na mochila hipotética, que de forma similar é vista nas demais figuras.

O fluxo inicia com a descrição da aplicação, como visto na Figura 31. Essa definição serve para geração de interfaces para qualquer um dos 5 formatos definidos, no entanto, o exemplo conferido no decorrer deste capítulo é base para o desenvolvimento de uma interface para o Formato 1.


Na sequência, observa-se o resultado do Agente Coordenador na Figura 32 o chamado efeito adaptativo ou *layout*, que nada mais é que uma solução vinda do Agente Otimizador.

¹¹Figuras 25, 26, 31, 32, 34 e 35.

As Figuras 26, 32 e 34, têm em comum, dentro de cada célula, a referência de um estado da SAN que comporá a interface final. Já na lateral esquerda dessas figuras, vê-se uma numeração sequencial indicando a equivalência das hierarquias em diferentes perspectivas do *pipeline*. Essa paridade de elementos, é descrita em 4 níveis, que podem ser entendidos como elementos da interface, sendo eles: (1) mochila e cromossomos uma *viewport*, (2) compartimentos e DNA as linhas, (3) agrupamentos e genes as colunas e os (4) itens e alelos representando os elementos.

Diante dessas formas de representação, apresenta-se na Figura 37 um exemplo de *mock-up* de interface equivalente às representações supracitadas, apenas em termos de elementos, não de conteúdo¹².

Figura 37: *Mock-up* de interface para PC



Fonte: Elaborado pelo autor

¹²No ANEXO ?? pode ser visto uma ilustração do *pipeline* do MOHAI

6 VALIDAÇÃO E EXPERIMENTAÇÃO

Neste capítulo estão descritas as etapas de validação do algoritmo memético proposto e das demais metaheurísticas para fins de comparação de efetividade entre elas. Cabe salientar que as soluções/interfaces geradas nesse trabalho não serão comparadas em termos qualitativos com outros sistemas de geração de interface de usuário, pois não existem dados e nem mesmo sistemas que façam a geração da IU, considerando os mesmos fatores apresentados nesta pesquisa.

A validação foi realizada com base nos 5 formatos definidos na concepção do modelo, sendo experimentadas em 4 tamanhos de instâncias de usuários. Vale ressaltar que trata-se de um problema de maximização. Dessa forma, considera-se os melhores resultados como sendo os de maior valor.

O texto deste capítulo está estruturado da seguinte forma:

- A seção 6.1 apresenta o gerador de programas de testes e seus parâmetros;
- A seção 6.2 explica o processo e os experimentos de calibração do modelo;
- Na seção 6.3, são apresentados os experimentos que serão realizados e suas formas de apresentação; e
- A seção 6.4 apresenta os resultados dos experimentos.

6.1 GERAÇÃO DE PROGRAMAS DE TESTES

Tendo em vista a inviabilidade de obtenção de dados de usuários para os experimentos, esses foram obtidos, por meio de um gerador que fornece como saída um programa teste de tamanho configurável, composto de um grupo de usuários, com históricos uniformes entre 1 a 25 dispositivos cada. A Tabela 12 apresenta os 25 dispositivos possíveis de comporem o histórico do usuário que estão uniformemente distribuídos entre os 5 formatos de dispositivos definidos anteriormente (seção 5.2.1). Esses dispositivos foram escolhidos empiricamente devido às suas representatividades no mercado, visando contemplar a maior gama possível dentro dos formatos pré-estabelecidos. Cabe lembrar que a escolha desses dispositivos serve apenas para efeitos de experimentação e não influenciam nem o comportamento, nem a dinâmica do modelo, ou seja, o comportamento verificado durante os experimentos visa refletir o comportamento dos formatos quando em cenários reais.

O método gerador de programas de testes basicamente obedece aos seguintes passos:

- Passo 1:** Recebe parâmetros de entrada.
 $\{ \text{Formato } q, \text{ Quantidade de usuários } | i | \}$
- Passo 2:** Gera parâmetros do usuário, definindo o tamanho do histórico do usuário i define o $| k | \forall i, i \in I$ e $k \in K$.
- Passo 3:** Atribui um dispositivo k para cada i_k pertencente ao histórico do usuário i $\forall i_k$ define $k, k \in K$ e $K = \{1, \dots, 25\}$.
- Passo 4:** Popula com taxas de probabilidade a SAN do dispositivo i_k .
- Passo 5:** Constrói a estrutura da dados.
- Passo 6:** Retorna o programa teste com os parâmetros gerados.

Passo 1) é fornecido o conjunto de parâmetros que contém o Formato do programa teste que se está gerando (q) e a quantidade de usuários presentes no programa teste ($| i |$); Passo 2) é definido para cada usuário a quantidade de dispositivos em seu histórico. Esta definição é realizada com base em uma distribuição uniforme; Passo 3) efetua a atribuição de um dos 25 dispositivos definidos para cada compor o histórico do usuário; Passo 4) são geradas as SAN individuais contendo as probabilidades que representam as experiências do usuário com o dispositivo (i_k); Passo 5) constrói-se efetivamente a estrutura de dados contendo os usuários, dispositivos e as respectivas SAN; e Passo 6) fornece ao MOHAI o programa teste desenvolvido com base nos parâmetros informados.

Tabela 12: Lista das características dos dispositivos

	Resolução (px)		Tamanho (px)		Dispositivos
	Largura	Altura	Largura	Altura	
Formato 1	1920	1200	518	324	Monitor 24
	1600	1200	429	215	Monitor 19
	1366	768	318	169	Monitor 14
	1280	800	218	137	Samsung SGH-T859 (Galaxy Tab 10.1 4G)
	1280	768	217	136	LG V900 (Optimus Pad - Paisagem)
Formato 2	1080	1920	63	111	Samsung GT-I9500 (Galaxy S4)
	1050	1680	503	252	Monitor 22
	1024	1280	384	193	Monitor 17
	1024	768	198	148	Apple iPad 1 - Paisagem
	960	640	74	50	Apple A1387 (iPhone 4S)
Formato 3	900	1600	228	454	Monitor 20
	800	1280	137	218	Samsung SGH-T859 (Galaxy Tab 10.1 4G)
	800	600	163	122	AOC MW0811 Breeze - Paisagem
	768	1280	55	92	BlackBerry Z10 - Retrato
	768	1024	148	198	Apple iPad 1 - Retrato
Formato 4	720	1280	60	107	Samsung GT-I9300 (Galaxy S III)
	640	960	50	74	Apple iPhone 4
	600	800	122	163	AOC MW0811 (Breeze - Retrato)
	480	800	50	84	Asus Galaxy6
	480	800	66	109	Dell Streak
Formato 5	320	480	44	67	HTC Hero - Paisagem
	240	320	40	53	Asus P526
	320	240	49	27	Nokia Asha 200
	176	144	40	32	Motorola EX109
	128	160	27	27	Samsung GT-C5010

Fonte: Elaborado pelo autor

6.2 CALIBRAÇÃO DO MODELO

O problema da otimização multiobjetivo consiste na obtenção de um conjunto de variáveis que satisfaçam algumas restrições e otimize uma função objetivo ou um conjunto de funções objetivo. À medida que um modelo multiobjetivo torna-se mais completo e específico, esse passa a exigir um maior número de parâmetros de entrada para caracterizar devidamente o sistema considerado. Alguns desses parâmetros não são mensuráveis ou são dificilmente determináveis em campo e precisam, portanto, serem estimados por meio de métodos de calibração.

Por meio da calibração, são atribuídos valores aos parâmetros, de maneira a promover o

ajuste às respostas esperadas do modelo. Esse ajuste é um processo complexo, cuja precisão está diretamente associada à qualidade dos resultados, pois modelos multiobjetivos normalmente envolvem objetivos conflitantes.

Devido às simplificações que naturalmente ocorrem no desenvolvimento de um modelo, quanto à representatividade dos parâmetros e às incertezas nos dados, na prática, não existirá um único conjunto de parâmetros capaz de representar os processos. Dessa forma, a calibração é um problema matemático com muitas soluções, podendo também ocasionar soluções que não representem a realidade do problema, nem mesmo os valores esperados. Das soluções aceitáveis tecnicamente, pode não ser possível distinguir a mais aceitável ou a melhor, ou seja, a medida de qualidade da solução não pode ser cegamente vista somente pelo valor da função objetivo, mas por sua adequação ao propósito a que o modelo se propõe. Em resumo, um critério de otimalidade deve ser definido.

6.2.1 Experimentos de Calibração

O modelo proposto no capítulo 5 foi implementado com a linguagem de programação C++, utilizando o Microsoft Visual Studio 2013. Todos os experimentos descritos neste trabalho foram executados no sistema operacional Windows 7 Professional SP1 64 bits, em um computador padrão modelo HP Z420, que possui um processador Xeon CPU E5-1620, modelo este com 8 núcleos de 3,6 GHz e 16 GB de memória RAM. Respeitando o Teorema Central do Limite e a Lei dos Grandes Números, os resultados contidos neste trabalho representam a média de 100 repetições de cada experimento.

Os experimentos de calibração foram executados com uma parametrização “padrão” (Tabela 13), formulados com base em experimentações apresentados na literatura (GALAFASSI, 2011; WICKERT, 2012), esta definição serve de guia para os experimentos, tendo em vista a inviabilidade técnica, computacional e temporal de realização de todos os conjuntos de parâmetros possíveis. Esta limitação vai ao encontro ao discutido no início desta seção, quando se fala em precisão da solução, no entanto, cabe enaltecer que a precisão da solução não altera o comportamento, nem a dinâmica das variáveis a ponto de influenciá-las.

Tabela 13: Parametrização padrão


Algoritmo	<i>Número de Gerações</i>	<i>Taxa de cruzamento</i>	<i>Taxa de mutação</i>	<i>População</i>
Genético	250	75	25	100
Busca	<i>NBmax</i>	<i>Lista Tabu</i>	<i>Vizinhança</i>	<i>População Memética</i>
Tabu	20	50	100	10

Fonte: Elaborado pelo autor

6.2.1.1 Experimento de Calibração 1

O primeiro experimento realizado com o algoritmo memético, visa observar o comportamento e a dinâmica das variáveis. Conforme se pode observar na Figura 38¹, os objetivos A e B são conflitantes e possuem comportamentos antagônicos, uma vez que o objetivo A tem o comportamento de crescimento, já esperado para um modelo de maximização. O objetivo B vai na contramão da proposta, diminuindo seu valor ao longo das gerações.

Figura 38: Convergência do modelo Primal



Fonte: Elaborado pelo autor

6.2.1.2 Experimento de Calibração 2

Visando minimizar a dominância de uma variável de decisão sobre a outra, o segundo experimento realizou a normalização da FO por meio das Equações 6.1 e 6.2 cujos valores podem ser conferidos na Tabela 14. O processo de normalização para determinação dos pesos foi realizado com base no resultado médio final obtido pelo experimento 1. Este experimento teve como objetivo equiparar a contribuição de cada uma das variáveis de decisão no resultado final.

$$\alpha = \frac{FO}{A} \quad (6.1)$$

$$\beta = \frac{FO}{B} \quad (6.2)$$

¹Observa-se na legenda uma terminologia que será utilizada em diversos gráficos, onde aparece um multiplicador para aproximar as escalas das variáveis de decisão no gráfico. Neste caso específico o multiplicador faz uso do prefixo Kilo (k)


Tabela 14: Normalização do modelo Primal

FO	0,245913155	Pesos	
A	0,245912627	α	1,000002148
B	0,000000528	β	465.454,9231

Fonte: Elaborado pelo autor

Na Figura 39, pode-se ver como resultado da calibração que houve uma inversão de comportamentos, catalisando o objetivo B, o que reforça a hipótese dos comportamentos antagônicos.

Figura 39: Convergência do modelo Primal Normalizado




Fonte: Elaborado pelo autor

6.2.1.3 Experimento de Calibração 3

Numa tentativa de dirimir o conflito entre as variáveis de decisão ou até mesmo reduzir a diferença entre essas, efetuou-se uma observação do modelo sob a perspectiva do modelo dual, tornando-o um modelo de minimização. Nesse experimento, pode-se na Figura 40, que o antagonismo entre as funções é mantido, mas os comportamentos individuais não são alterados.

Figura 40: Convergência do modelo Dual



Fonte: Elaborado pelo autor

6.2.1.4 Experimento de Calibração 4

Esse experimento visou normalizar o modelo dual de forma similar ao realizado no experimento 2. Em comparação, pode-se ver na Tabela 15 que a diferença entre os pesos em cada um dos parâmetros, em ambos os experimentos, demonstra que o modelo dual tem uma aproximação maior das escalas.


Tabela 15: Normalização do modelo Dual

FO	3,620884357	Pesos	
A	0,508649292	α	7,118626561
B	3,112235392	β	1,163435249

Fonte: Elaborado pelo autor

Na Figura 41, observa-se que o modelo dual, como dito anteriormente aproxima as escalas quando comparado ao experimento equivalente no modelo primal. Porém, o processo de normalização manteve os comportamentos divergentes de cada uma das funções, demonstrando mais uma vez a inadequação do processo de normalização para este tipo de problema.

Figura 41: Convergência do modelo Dual Normalizado



Fonte: Elaborado pelo autor


Visto que não foi encontrada uma boa relação no modelo dual, optou-se por não mais investigar os mesmos conceitos sobre este modelo.

6.2.1.5 Experimento de Calibração 5

De acordo com o observado nos experimentos de normalização anteriores, um dos pesos da equalização sempre se mantém próximo a 1, um multiplicador neutro. Nesse experimento, utilizou-se o modelo primal, onde a função divergente é o objetivo B que possui um peso grande de equalização. Esse experimento possui a finalidade de estimular apenas a função objetivo B para guiá-la em direção à maximização sem prejudicar o objetivo A. O estímulo foi introduzido aos poucos dentro do modelo híbrido, por meio do algoritmo genético no valor equalizador β . O algoritmo genético foi escolhido especificamente, pois esse valor afetaria igualmente toda a população de soluções. A estimulação do parâmetro β que inicia com valor 1, foi feita aumentando seu valor em 1 a cada geração.

Na Figura 42, pode-se ver que, se o objetivo B for estimulado adequadamente, produz o comportamento desejado para o modelo, ou seja, a maximização dos objetivos. Se atentarmos para a convergência apresentada por B, na figura ampliado 4000 vezes, vê-se platôs que são produzidos pela Busca Tabu, e alguns degraus abruptos entre os platôs gerados pelo crescimento de β ao longo das gerações, o que pode indicar uma falsa convergência.


Figura 42: Convergência do modelo Primal com beta crescente (+1)



Fonte: Elaborado pelo autor

Tendo em vista que esse experimento conduz ao caminho da otimalidade, maiores análises são feitas. Na Figura 43, vê-se a repetição do experimento de estímulo do β em maior escala, com β iniciando em 1.000 e sendo acrescido a cada geração em 1.000. Conclui-se assim que o estímulo produzido é benéfico até certo ponto, onde a variável de decisão B produz a relação de dominância sobre a variável de decisão A. Observando-se a região do intervalo entre 100 e 150 gerações onde acontece um “equilíbrio” antes de um curto crescimento conjunto até que seja estabelecida a relação de dominância, presume-se que o β nesse intervalo seja o responsável por um provável equilíbrio entre os objetivos.

Figura 43: Convergência do modelo Primal com beta crescente (+1000)



Fonte: Elaborado pelo autor


Nesse instante foram levantadas duas proposições possíveis para β , em dois momentos:

- Valor de beta no instante em que o objetivo B em crescimento está próximo ao valor de inicial do objetivo A ($\beta \approx 55.000$);

- Valor de beta no instante anterior ao objetivo B estabelecer a relação de dominância sobre o objetivo A ($\beta \approx 85.000$).


No experimento com β igual a 55.000 o comportamento antagônico permanece (Figura 44). Já com β igual a 85.000 a variável de decisão B já é iniciada com relação de dominância sobre a variável A (Figura 45). Desta forma, fixou-se o intervalo $55.000 < \beta < 85.000$ como espaço de investigação, onde foram conduzidos experimentos com espaçamento de 2.500.

Figura 44: Convergência do modelo Primal ($\beta = 55.000$)



Fonte: Elaborado pelo autor

Figura 45: Convergência do modelo Primal ($\beta = 85.000$)



Fonte: Elaborado pelo autor

Com base nos experimentos realizados, uma análise quanti-qualitativa das soluções foi empregada a fim de determinar o valor mais adequado em prol do objetivo do modelo. Podem-se observar na Tabela 16, os valores iniciais e finais dos experimentos, conjuntamente as porcentagens de melhora das variáveis de decisão e da Função Objetivo, em que se constata que β igual a 62.500 produz resultados satisfatórios do ponto de vista do critério de otimalidade, como se observa em negrito na tabela.

Se obtivermos duas soluções S_1 e S_2 , ambas com valores de aptidão iguais, deve-se avaliar a contribuição individual das variáveis de decisão, determinando suas prioridades. Nesse trabalho, determinou-se como critério de otimalidade que uma solução é melhor que outra, quando, uma variável de decisão degrada menos a outra. A definição desse critério, deu-se com base na influência da variável de decisão B sobre a variável A. O não equilíbrio e o antagonismo entre as variáveis mostrou que com β igual a 62.500 a variável B pode colaborar degradando menos a variável A e vice-versa.

Tabela 16: Experimentos de calibração

Experimento	A_i	B_i	FO_i	A_f	B_f	FO_f	A	B	FO	$A + B$
beta 55000	0,22301	0,05126	0,27428	0,26270	0,04350	0,30620	17,79664	-15,14150	11,64018	2,65515
beta 57500	0,19754	0,04073	0,23827	0,23536	0,03440	0,26976	19,14428	-15,54780	13,21435	3,59649
beta 60000	0,20635	0,04743	0,25378	0,25435	0,03824	0,29258	23,26273	-19,38990	15,29054	3,87287
beta 62500	0,19633	0,03351	0,22984	0,23537	0,03173	0,26710	19,88460	-5,32870	16,20827	14,55591
beta 65000	0,19298	0,04046	0,23345	0,23382	0,03374	0,26756	21,15937	-16,61070	14,61257	4,54872
beta 67500	0,19220	0,02379	0,21599	0,22958	0,02026	0,24984	19,44501	-14,82570	15,67024	4,61927
beta 70000	0,19359	0,04513	0,23872	0,23809	0,03671	0,27480	22,98484	-18,66400	15,11075	4,32086
beta 72500	0,19245	0,05643	0,24887	0,24118	0,04572	0,28690	25,32491	-18,97400	15,28115	6,35091
beta 75000	0,19110	0,07471	0,26581	0,24856	0,05743	0,30599	30,06336	-23,12450	15,11456	6,93890
beta 77500	0,20854	0,04038	0,24892	0,24889	0,03448	0,28337	19,34904	-14,61120	13,84029	4,73788
beta 80000	0,19567	0,10092	0,29659	0,24251	0,08137	0,32389	23,93900	-19,36850	9,20282	4,57047
beta 82500	0,19493	0,03087	0,22580	0,23046	0,02687	0,25733	18,22743	-12,96060	13,96330	5,26683
beta 85000	0,14180	0,25025	0,39205	0,11544	0,32250	0,43795	-18,58900	28,87253	11,70630	10,28351

Fonte: Elaborado pelo autor

6.3 PLANEJAMENTO DOS EXPERIMENTOS

Cada um dos experimentos foi realizado em três etapas distintas, considerando programas teste de micro, pequena, média e grande escala em cada um dos formatos pré-definidos na concepção do modelo. Como já mencionado no início deste capítulo, não foram encontradas na literatura programas de testes para esse tipo de problema, sendo os experimentos realizados com o auxílio do gerador de programas de testes.

Na Tabela 17, pode-se observar a composição das etapas de experimentos desenvolvidos.

Tabela 17: Etapas do processo de experimentação

Etapa 1	Processo de Algoritmo Genético Análise da variação das taxas de mutação e cruzamento.
Etapa 2	Processo de Busca Tabu Análise da variação do tamanho da Lista Tabu e do NBmax.
Etapa 3	Processo de Algoritmo Memético Análise da variação das taxas de cruzamento e mutação, e dos tamanhos da Lista Tabu e do NBmax.

Fonte: Elaborado pelo autor

Os experimentos objetivaram analisar o comportamento das metaheurísticas em seus processos de busca no espaço de soluções e a qualidade dos resultados obtidos, a fim de comparar as técnicas, demonstrando a efetividade do Algoritmo Memético proposto.

Os resultados apresentados serão valores médios de 100 execuções, obtidos pela Função Objetivo (FO), e os respectivos desvios padrão (σ), baseados nas parametrizações de cada etapa. Os resultados serão expostos em tabelas, cuja representação será de acordo com os modelos de apresentação de resultado das seções seguintes. Para facilitar o processo de análise, as tabelas estão divididas em quadrantes. As células da tabela terão os 5 maiores valores destacados em cinza, e o maior valor em negrito, visando facilitar sua compreensão. Além dessa análise, serão traçados comparativos entre as soluções obtidas por meio de gráficos relacionando os parâmetros de cada técnica.

6.3.1 Etapa de Experimentos 1

A primeira etapa de experimentos, visa estudar a influência da taxa de mutação e de cruzamento na obtenção de soluções de qualidade em populações de 100 indivíduos. Os resultados obtidos serão apresentados seguindo o padrão da Tabela 18, em que as colunas designarão as variações das taxas de mutação e as linhas as variações das taxas de cruzamento. A mesma tabela expõe os respectivos valores para cada parâmetro que serão combinados, gerando um total de 36 conjuntos de parâmetros para cada instância de teste aplicada ao problema.

Tabela 18: Modelo de tabela de resultados para o AG

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	1º Quadrante			2º Quadrante		
		σ						
	10	FO						
		σ						
	25	FO						
		σ						
	50	FO	3º Quadrante			4º Quadrante		
		σ						
	75	FO						
		σ						
	90	FO						
		σ						

Fonte: Elaborado pelo autor

6.3.2 Etapa de Experimentos 2

A segunda etapa de experimentos tem por finalidade estudar a influência do tamanho da Lista Tabu e do valor do NBmax na obtenção de soluções de qualidade. Analisar-se-á a combinação distinta dos valores para tamanho da Lista Tabu e do NBmax com vizinhanças de 100 indivíduos, gerando um total de 36 conjuntos de parâmetros em cada programa teste aplicado ao problema. Os resultados serão apresentados conforme o padrão da Tabela 19, onde as colunas demonstram as variações dos tamanhos de Lista Tabu e as colunas as variações do NBmax.

Tabela 19: Modelo de tabela de resultados para a BT

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	1º Quadrante			2º Quadrante		
		σ						
	25	FO						
		σ						
	50	FO	3º Quadrante			4º Quadrante		
		σ						
	75	FO						
		σ						
	100	FO						
		σ						
	200	FO						
		σ						

Fonte: Elaborado pelo autor

6.3.3 Etapa de Experimentos 3

A terceira e última etapa de experimentos, analisa a influência da variação dos parâmetros no Algoritmo Memético proposto. Com base na variação de parâmetros, almeja-se a obtenção de resultados de melhor qualidade em relação às demais metaheurísticas. Nesta etapa, analisar-se-á a variação das taxas de cruzamento e mutação, o tamanho da Lista Tabu e do NBmax. Esta etapa de testes versará apenas sobre as nove melhores parametrizações encontradas no quadrante da melhor solução em cada uma das fases de testes anteriores, gerando, assim, um conjunto de 81 parametrizações para este experimento. A escolha dos parâmetros será com base no quadrante de concentração da melhor solução.

Os resultados obtidos nesta etapa serão apresentados seguindo o padrão da Tabela 20, em que as linhas designarão o tamanho da variação da taxa de cruzamento e mutação, e as

colunas apresentam as variações da Lista Tabu e do NBmax.

Tabela 20: Modelo de tabela de resultados do AM

					Lista Tabu								
					LT 1			LT 2			LT 3		
					NBMax								
					NB 1	NB 2	NB 3	NB 1	NB 2	NB 3	NB 1	NB 2	NB 3
Taxa de Mutação	MT 1	Taxa de Cruzamento	CO 1	FO									
				σ									
			CO 1	FO									
				σ									
			CO 3	FO									
				σ									
	MT 2		CO 1	FO									
				σ									
			CO 2	FO									
				σ									
	CO 3		FO										
			σ										
	MT 3		CO 1				FO						
							σ						
			CO 2	FO									
				σ									
CO 3			FO										
			σ										

Fonte: Elaborado pelo autor

6.4 EXPERIMENTOS REALIZADOS

A seguir, são apresentados os experimentos realizados com os programas teste nos 5 formatos pré-definidos. Os experimentos estão agrupados de acordo com a escala do programa teste, sendo eles micro escala (15 usuários), pequena escala (50 usuários), média escala (100 usuários) e larga escala (1000 usuários).

6.4.1 Experimentos em Micro Escala

Nesta seção apresentam-se os resultados dos experimentos em micro escala.

6.4.1.1 Programa teste no Formato 1 em Micro Escala

Observa-se, na Tabela 21, os resultados obtidos pelo Algoritmo Genético no primeiro programa de testes. Como pode ser observado, há uma concentração de boas soluções nos quadrantes inferiores (Q3 e Q4), indicando que taxas de cruzamento e mutação altas produzem melhores resultados.


Tabela 21: Experimento com Algoritmo Genético no Formato 1 com 15 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12855	0,12764	0,12642	0,12514	0,12965	0,12543
		σ	0,00716	0,00836	0,00736	0,00759	0,00637	0,00711
	10	FO	0,1303	0,13117	0,1299	0,13018	0,13079	0,12965
		σ	0,00763	0,00767	0,00721	0,00818	0,00731	0,00713
	25	FO	0,136	0,13588	0,13482	0,13714	0,13715	0,1361
		σ	0,00886	0,00702	0,00772	0,00852	0,00727	0,00639
	50	FO	0,13866	0,13954	0,13919	0,13928	0,13859	0,13982
		σ	0,00629	0,00691	0,00556	0,0066	0,00701	0,00606
	75	FO	0,14024	0,13949	0,14105	0,14015	0,14151	0,1392
		σ	0,00646	0,00636	0,00551	0,00487	0,00615	0,00544
	90	FO	0,14112	0,14146	0,1405	0,14022	0,14073	0,14167
		σ	0,00675	0,00635	0,00553	0,00631	0,00617	0,00532

Fonte: Elaborado pelo autor

Ao analisar a Figura 46, verifica-se que taxas de mutação maiores que 25% tendem a estabilizar a diversificação quando em conjunto a altas taxas de cruzamento.

Figura 46: Evolução do experimento com AG no Formato 1 com 15 usuários



Fonte: Elaborado pelo autor

Na Tabela 22, vê-se os resultados da Busca Tabu para o programa de testes no Formato 1 com 15 usuários, em que as soluções concentram-se no quadrante 4, sugerindo que maiores valores para Lista Tabu e NBmax conduzem a soluções de melhor qualidade.


Tabela 22: Experimento com Busca Tabu no Formato 1 com 15 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,11216	0,12554	0,13242	0,13089	0,13201	0,13762
		σ	0,00781	0,00857	0,007	0,0082	0,00787	0,0082
	25	FO	0,11221	0,12794	0,13206	0,13306	0,13688	0,13686
		σ	0,01413	0,01136	0,00785	0,00677	0,00811	0,00461
	50	FO	0,12498	0,12579	0,13457	0,13786	0,13882	0,13966
		σ	0,00938	0,01656	0,00576	0,00653	0,00557	0,00545
	75	FO	0,1227	0,12141	0,13598	0,14059	0,14299	0,14075
		σ	0,00669	0,01789	0,00595	0,00489	0,00465	0,00519
	100	FO	0,123	0,13242	0,13328	0,13996	0,14158	0,14257
		σ	0,00622	0,00549	0,00623	0,00626	0,0056	0,00597
	200	FO	0,1209	0,1346	0,13627	0,14088	0,14316	0,14333
		σ	0,00896	0,00554	0,00554	0,0052	0,00438	0,00415

Fonte: Elaborado pelo autor

Na Figura 47, observa-se claramente a convergência com o aumento dos parâmetros, o que é apenas um indicador de qualidade, não um fator determinante. Se cogitada a elevação desses valores, ter-se-á um aumento significativo no tempo computacional, sem garantias de melhores soluções.

Figura 47: Evolução do experimento com BT no Formato 1 com 15 usuários



Fonte: Elaborado pelo autor

Têm-se, na Tabela 23, os resultados do agrupamento dos 3 principais valores de cada parâmetro com o AG e a BT, demonstrando que, quando aliadas sob a forma do Algoritmo Memético, o AG apresenta indicadores semelhantes de quando está isolado. Já a Busca Tabu aparece melhor definida com NBmax em 100 e Lista Tabu com tamanho 200, indicando que uma maior diversificação tenderia a melhores valores, porém com significativo aumento de consumo de recursos computacionais.


Tabela 23: Experimento com Algoritmo Memético no Formato 1 com 15 usuários

Taxa de Mutação			Taxa de Cruzamento		50		75		90		Lista Tabu																	
											75			100			200											
											NBMax																	
											75			100			200			75			100			200		
50	FO	0,20542	0,115	0,15097	0,16444	0,12299	0,10894	0,12395	0,20785	0,16672																		
	σ	0,00444	0,00385	0,00417	0,00476	0,00532	0,00521	0,00455	0,00384	0,00373																		
75	FO	0,20431	0,11602	0,15054	0,16492	0,12394	0,10942	0,12401	0,20953	0,1675																		
	σ	0,00417	0,00365	0,00426	0,00519	0,0057	0,00506	0,00472	0,00383	0,00371																		
90	FO	0,20578	0,11501	0,14896	0,16495	0,12329	0,1105	0,12554	0,20958	0,16516																		
	σ	0,00455	0,00381	0,00429	0,00555	0,0057	0,00494	0,00458	0,00376	0,00337																		
50	FO	0,20453	0,11587	0,15237	0,16328	0,12278	0,1096	0,12396	0,2096	0,16792																		
	σ	0,00439	0,00388	0,00382	0,00476	0,00577	0,0053	0,00412	0,00398	0,00388																		
75	FO	0,20392	0,11716	0,1499	0,16385	0,12404	0,10869	0,12293	0,20983	0,16588																		
	σ	0,00402	0,00385	0,0044	0,00547	0,00608	0,00495	0,00441	0,00348	0,00365																		
90	FO	0,20405	0,11409	0,1486	0,16632	0,1225	0,11154	0,12485	0,20756	0,1638																		
	σ	0,00498	0,00369	0,00411	0,00551	0,00544	0,00543	0,00457	0,0041	0,00312																		
50	FO	0,20357	0,11551	0,15266	0,16339	0,12333	0,10914	0,12487	0,20916	0,16856																		
	σ	0,00456	0,00351	0,00358	0,00504	0,0062	0,00483	0,00383	0,00382	0,00362																		
75	FO	0,20488	0,11806	0,15124	0,16482	0,12483	0,10831	0,12403	0,21088	0,16632																		
	σ	0,00436	0,00372	0,00475	0,00518	0,00642	0,00476	0,00466	0,00366	0,00383																		
90	FO	0,20428	0,115	0,14748	0,16711	0,12227	0,11133	0,12482	0,20798	0,16496																		
	σ	0,00514	0,00342	0,00374	0,00592	0,00582	0,00544	0,00494	0,00399	0,00291																		

Fonte: Elaborado pelo autor

Na comparação das técnicas sob o mesmo programa teste (Figura 48), o Algoritmo Memético se sobressai em relação às demais técnicas, quando analisado o valor de sua FO, que também é evidenciado com menor desvio padrão.

Figura 48: Comparativo entre as soluções das MH no Formato 1 com 15 usuários



Fonte: Elaborado pelo autor

6.4.1.2 Programa teste no Formato 2 em Micro Escala

Nesse experimento, verifica-se, na Tabela 24, que o Algoritmo Genético concentrou as soluções de melhor qualidade nos quadrantes inferiores (Q3 e Q4), onde se percebe que uma alta taxa de cruzamento está diretamente ligada à qualidade das soluções.


Tabela 24: Experimento com Algoritmo Genético no Formato 2 com 15 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,1225	0,1197	0,12139	0,12077	0,11935	0,12044
		σ	0,0056	0,00418	0,00641	0,00547	0,00397	0,00463
	10	FO	0,12236	0,12339	0,12488	0,12281	0,12141	0,12134
		σ	0,00419	0,00504	0,00631	0,00466	0,00485	0,00476
	25	FO	0,12457	0,12638	0,12711	0,12629	0,12718	0,12532
		σ	0,00516	0,00534	0,00563	0,00566	0,00489	0,0049
	50	FO	0,12706	0,12851	0,13037	0,12865	0,12814	0,12899
		σ	0,00439	0,00464	0,00591	0,00435	0,00512	0,00479
	75	FO	0,12877	0,12858	0,12939	0,12942	0,12923	0,12907
		σ	0,00397	0,0033	0,00455	0,00387	0,00464	0,00497
	90	FO	0,12874	0,12894	0,1299	0,13159	0,13144	0,12993
		σ	0,00345	0,00462	0,0048	0,00426	0,00414	0,00421

Fonte: Elaborado pelo autor

Na Figura 49, observa-se que baixas taxas de mutação aliadas a baixas taxas de cruzamento tendem a diminuir os valores da função de custo. Em contrapartida, taxas altas possuem comportamentos tangentes, ou seja, dentre as taxas experimentadas as variações foram pequenas.

Figura 49: Evolução do experimento com AG no Formato 2 com 15 usuários



Fonte: Elaborado pelo autor

A Busca Tabu apresenta na Tabela 25 comportamento promissor quando utiliza parâmetros elevados, reforçando a tendência de soluções de melhor qualidade, no quadrante 4.


Tabela 25: Experimento com Busca Tabu no Formato 2 com 15 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,12026	0,125	0,12289	0,12993	0,13103	0,13027
		σ	0,00533	0,00585	0,01454	0,00557	0,00591	0,00597
	25	FO	0,1198	0,12663	0,12994	0,13077	0,13338	0,13215
		σ	0,00533	0,00473	0,00499	0,00424	0,0046	0,00406
	50	FO	0,11521	0,12705	0,13373	0,12931	0,1344	0,13616
		σ	0,01482	0,0056	0,00434	0,00543	0,00397	0,00387
	75	FO	0,12553	0,1297	0,1325	0,13332	0,13611	0,13582
		σ	0,00687	0,005	0,005	0,0034	0,0043	0,00374
	100	FO	0,11921	0,12813	0,13349	0,13274	0,13687	0,13554
		σ	0,01047	0,0047	0,00395	0,00457	0,00394	0,00445
	200	FO	0,12078	0,12846	0,12546	0,13185	0,13721	0,13621
		σ	0,00958	0,00447	0,01038	0,00411	0,00304	0,00329

Fonte: Elaborado pelo autor

É constado, na Figura 50, que o aumento do NBmax e da Lista Tabu permitem que a busca explore regiões mais promissoras, em geral promovendo melhoras. Considerando a qualidade das soluções, verifica-se que, mesmo com NBmax de tamanho 50, foram obtidas soluções de boa qualidade. O aumento do NBmax permite que a busca seja realizada por um período maior de tempo, aceitando que se realize uma exploração mais abrangente do espaço de soluções. Em contrapartida, o aumento do NBmax produz considerável elevação do tempo computacional.

Figura 50: Evolução do experimento com BT no Formato 2 com 15 usuários



Fonte: Elaborado pelo autor

Nesse experimento com o Algoritmo Memético, vê-se, na Tabela 26, a tendência demonstrada pela Busca Tabu para seus parâmetros, onde concentram a Lista Tabu e o NBmax em 100, evidenciando que a técnica, quando em conjunto ao Algoritmo Genético, não necessita de parâmetros elevados. Relativo ao Algoritmo Genético, as taxas de mutação provocam boa diversificação da busca e as taxas de cruzamento elevadas sempre apresentam boas soluções.


Tabela 26: Experimento com Algoritmo Memético no Formato 2 com 15 usuários

Taxa de Mutação			50		Lista Tabu												
					75				100		200						
					NBMax												
					75	100	200	75	100	200	75	100	200				
Taxa de Cruzamento			50		FO	0,13409	0,17761	0,16652	0,12273	0,19618	0,11279	0,14719	0,17168	0,18791			
					σ	0,00265	0,00326	0,0031	0,00416	0,00352	0,00413	0,0031	0,0026	0,00307			
			75		FO	0,136	0,1802	0,16851	0,12125	0,19698	0,11372	0,14498	0,16942	0,18727			
					σ	0,0024	0,00352	0,00332	0,00396	0,0034	0,00407	0,00322	0,00249	0,00325			
			90		FO	0,1354	0,18053	0,17096	0,12213	0,19779	0,11326	0,14633	0,17169	0,18589			
					σ	0,00221	0,00353	0,00325	0,00378	0,00362	0,00412	0,00332	0,00244	0,00313			
			50		FO	0,13502	0,1777	0,16607	0,12295	0,19522	0,11321	0,14712	0,17271	0,18879			
					σ	0,00275	0,00344	0,00297	0,00406	0,00365	0,00441	0,00301	0,00268	0,00278			
			75		FO	0,13587	0,18123	0,16867	0,12043	0,1983	0,11293	0,14639	0,16799	0,18886			
					σ	0,00259	0,00327	0,00324	0,00411	0,00341	0,00424	0,00334	0,00254	0,00353			
			90		FO	0,13507	0,17889	0,16993	0,12205	0,19814	0,11254	0,14724	0,17308	0,1873			
					σ	0,00199	0,00331	0,00306	0,00354	0,00365	0,00445	0,00305	0,00224	0,00287			
			90			50		FO	0,13448	0,17891	0,1661	0,12317	0,19693	0,11253	0,14796	0,17277	0,18861
								σ	0,00257	0,00345	0,00271	0,00382	0,00331	0,00428	0,00306	0,0026	0,00278
						75		FO	0,13646	0,18228	0,16983	0,11997	0,19866	0,1129	0,14731	0,16746	0,19073
								σ	0,0027	0,00321	0,00357	0,00388	0,0033	0,00398	0,00337	0,0026	0,00354
						90		FO	0,13515	0,17887	0,17061	0,12248	0,19707	0,11346	0,14664	0,17194	0,18809
								σ	0,00205	0,00299	0,00279	0,00333	0,00337	0,00468	0,00285	0,00203	0,00308

Fonte: Elaborado pelo autor

Observa-se, na Figura 51, que o Algoritmo Memético se sobressai em termos da qualidade da solução em relação às demais técnicas. Cabe notar que a Busca Tabu possui sua qualidade muito próxima ao Algoritmo Genético, com leve vantagem. Dessa forma, levanta-se a hipótese de que nesse problema a agressividade da Busca Tabu predomina ainda que sutilmente sobre a exploração global do Algoritmo Genético.

Figura 51: Comparativo entre as soluções das MH no Formato 2 com 15 usuários



Fonte: Elaborado pelo autor

6.4.1.3 Programa teste no Formato 3 em Micro Escala

No experimento apresentado na Tabela 27, vê-se como uma tendência a concentração das soluções de melhor qualidade nos quadrantes inferiores (Q3 e Q4), indicando que a elevação da taxa de cruzamento permite que a busca seja intensificada em áreas promissoras.


Tabela 27: Experimento com Algoritmo Genético no Formato 3 com 15 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12181	0,12303	0,12418	0,12314	0,12297	0,12238
		σ	0,00622	0,00606	0,00574	0,00634	0,00558	0,00526
	10	FO	0,12412	0,12501	0,1258	0,12594	0,12561	0,12756
		σ	0,00647	0,00505	0,00695	0,0062	0,00556	0,0069
	25	FO	0,13012	0,1298	0,12877	0,13046	0,13139	0,13049
		σ	0,00728	0,0065	0,00569	0,00608	0,00541	0,00519
	50	FO	0,13406	0,13098	0,13192	0,13219	0,1332	0,13169
		σ	0,00702	0,00551	0,00535	0,00512	0,00715	0,00625
	75	FO	0,13323	0,13346	0,1321	0,13275	0,13285	0,13364
		σ	0,00517	0,00598	0,00525	0,00559	0,00498	0,00618
	90	FO	0,13381	0,13387	0,13347	0,13535	0,13491	0,13435
		σ	0,00485	0,00557	0,00581	0,00585	0,00583	0,00534

Fonte: Elaborado pelo autor

Pode-se verificar, na Figura 52, certa homogeneidade entre as taxas de mutação, o que indica uma população geneticamente apta, porém, com elevada inserção de novas estruturas durante a diversificação.

Figura 52: Evolução do experimento com AG no Formato 3 com 15 usuários



Fonte: Elaborado pelo autor

Analisando a Tabela 28, percebe-se que as melhores soluções estão contidas nos quadrantes do lado direito, especialmente no quadrante 4, com Lista Tabu entre 100 e 200 e NBmax entre 50 e 200. Semelhante ao experimento anterior, pode-se inferir que a diversificação provocada faz com que o processo de busca seja constantemente guiado para novas regiões, onde se pode intensificar a busca. Contudo, vale lembrar que um valor elevado de Lista Tabu pode impedir a intensificação adequada de uma região.


Tabela 28: Experimento com Busca Tabu no Formato 3 com 15 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,12076	0,12366	0,12938	0,12987	0,13339	0,13263
		σ	0,00519	0,0049	0,00534	0,00666	0,00523	0,00573
	25	FO	0,11978	0,13062	0,13128	0,13367	0,13497	0,13552
		σ	0,01208	0,00587	0,00472	0,00474	0,00445	0,00512
	50	FO	0,12686	0,13047	0,13201	0,13438	0,13752	0,13616
		σ	0,00581	0,00398	0,00414	0,00354	0,00441	0,00412
	75	FO	0,11146	0,12783	0,12469	0,13422	0,13675	0,13719
		σ	0,01722	0,00612	0,01968	0,00585	0,00312	0,00354
	100	FO	0,12257	0,13097	0,13486	0,13255	0,13878	0,13836
		σ	0,00631	0,00248	0,00469	0,0105	0,00369	0,00392
	200	FO	0,11971	0,13183	0,13168	0,13583	0,13903	0,13931
		σ	0,00748	0,00457	0,00959	0,00363	0,00267	0,00246

Fonte: Elaborado pelo autor

Constata-se, na Figura 53, que a diversificação, na maioria dos casos, cumpre seu papel. Porém, a Lista Tabu de tamanho 50 com NBmax 75 acaba sendo restritiva, não acompanhando a tendência de conversão conjunta dos demais parâmetros.

Figura 53: Evolução do experimento com BT no Formato 3 com 15 usuários



Fonte: Elaborado pelo autor

Ao analisar a Tabela 29, torna-se evidente a contribuição das parametrizações da Busca Tabu, concentrando-se na faixa do NBmax 75 e Lista Tabu 200. Já o Algoritmo Genético apresenta soluções de qualidade em toda a gama de taxas de mutação experimentada e dirige a intensificação com taxas entre 50 e 75%.


Tabela 29: Experimento com Algoritmo Memético no Formato 3 com 15 usuários

Taxa de Mutação		Taxa de Cruzamento		Lista Tabu								
				75			100			200		
				NBMax								
				75	100	200	75	100	200	75	100	200
50	50	FO	0,13246	0,1276	0,12683	0,19172	0,14502	0,11925	0,20284	0,15757	0,11694	
		σ	0,00538	0,00256	0,00313	0,00925	0,00316	0,00346	0,00298	0,00216	0,00211	
	75	FO	0,13414	0,12819	0,12864	0,19371	0,1472	0,11902	0,20382	0,15838	0,11544	
		σ	0,00562	0,00273	0,00315	0,00847	0,00314	0,00328	0,00277	0,0022	0,00221	
	90	FO	0,13344	0,12725	0,12908	0,19092	0,14823	0,1184	0,20198	0,15667	0,11509	
		σ	0,0052	0,00295	0,00323	0,00873	0,00317	0,00296	0,00268	0,0023	0,00206	
	50	FO	0,13158	0,12875	0,12763	0,18993	0,14383	0,11986	0,20414	0,15894	0,11715	
		σ	0,00523	0,00248	0,00283	0,00976	0,0034	0,00345	0,00292	0,00237	0,00191	
	75	FO	0,13366	0,12739	0,12813	0,19433	0,14581	0,11993	0,20294	0,15747	0,11502	
		σ	0,00594	0,00263	0,00308	0,00792	0,00292	0,0036	0,00265	0,00231	0,00238	
	90	FO	0,13335	0,12677	0,12995	0,19104	0,14768	0,11829	0,20061	0,15613	0,11606	
		σ	0,00562	0,00293	0,00318	0,00925	0,00331	0,00306	0,00256	0,00229	0,00188	
	75	50	FO	0,13155	0,12775	0,1274	0,189	0,14372	0,12096	0,20435	0,15923	0,11687
			σ	0,00534	0,0025	0,00301	0,00949	0,00324	0,00356	0,00279	0,00226	0,00204
		75	FO	0,13418	0,1271	0,12726	0,19515	0,14679	0,12081	0,20416	0,15817	0,11482
			σ	0,00613	0,00285	0,00331	0,00766	0,00287	0,00354	0,00274	0,00219	0,00226
		90	FO	0,133	0,12667	0,12889	0,19132	0,14845	0,11909	0,20161	0,15521	0,11562
			σ	0,00612	0,00296	0,0034	0,0093	0,00344	0,00305	0,00246	0,00212	0,00179

Fonte: Elaborado pelo autor

Quanto à comparação entre as técnicas empregadas no experimento (Figura 54), é notória a qualidade do Algoritmo Memético sobre as demais técnicas, ficando atrás a Busca Tabu e o Algoritmo Genético.

Figura 54: Comparativo entre as soluções das MH no Formato 3 com 15 usuários



Fonte: Elaborado pelo autor

6.4.1.4 Programa teste no Formato 4 em Micro Escala

Os resultados do programa teste no Formato 4 em micro escala, vistos na Tabela 30, apresentam a concentração dos resultados nos quadrantes inferiores (Q3 e Q4). Em outras palavras, melhores soluções foram obtidas durante o processo de intensificação. Isso acontece devido às altas taxas de cruzamento.


Tabela 30: Experimento com Algoritmo Genético no Formato 4 com 15 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12301	0,12744	0,12585	0,12508	0,12654	0,12735
		σ	0,00422	0,00757	0,00772	0,00795	0,0067	0,00651
	10	FO	0,12964	0,13089	0,1278	0,13042	0,13143	0,12955
		σ	0,00701	0,00731	0,00801	0,00906	0,00651	0,00738
	25	FO	0,13504	0,13543	0,13511	0,13492	0,13607	0,13532
		σ	0,00671	0,00659	0,00624	0,00737	0,00707	0,00615
	50	FO	0,13721	0,13738	0,137	0,13648	0,13809	0,13704
		σ	0,00756	0,00636	0,0054	0,00614	0,00684	0,00718
	75	FO	0,13923	0,13918	0,14031	0,13834	0,13654	0,14028
		σ	0,00719	0,00608	0,00686	0,00578	0,00696	0,00633
	90	FO	0,13887	0,13885	0,13899	0,14003	0,13901	0,14151
		σ	0,00602	0,00573	0,0053	0,00569	0,00557	0,0053

Fonte: Elaborado pelo autor

Na Figura 55, observa-se certa uniformidade entre as taxas de mutação, gerando pequenas variações, se comparado aos experimentos anteriores. Isso é devido à configuração do Formato 4, que possui um espaço menor de variação para o operador de mutação.

Figura 55: Evolução do experimento com AG no Formato 4 com 15 usuários



Fonte: Elaborado pelo autor

Concentradas no quadrante 4 da Tabela 31, as soluções de melhor qualidade indicam que o NBmax e Lista Tabu estão trabalhando em ritmos de cooperação, ou seja, seus aumentos conjuntos conduzem a regiões de melhores soluções.


Tabela 31: Experimento com Busca Tabu no Formato 4 com 15 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,12535	0,12836	0,1379	0,14063	0,14147	0,14174
		σ	0,00978	0,01272	0,00934	0,00566	0,00497	0,00572
	25	FO	0,12701	0,13962	0,14064	0,1438	0,14461	0,14486
		σ	0,01569	0,00632	0,00452	0,00593	0,00465	0,0047
	50	FO	0,13416	0,13874	0,1444	0,1437	0,1471	0,14657
		σ	0,00552	0,0061	0,00467	0,00641	0,00477	0,00447
	75	FO	0,13603	0,13727	0,14212	0,14423	0,14721	0,1474
		σ	0,00694	0,00905	0,00417	0,00665	0,00428	0,00348
	100	FO	0,12401	0,13491	0,14534	0,14539	0,14781	0,14879
		σ	0,01696	0,01422	0,00412	0,00434	0,00384	0,00306
	200	FO	0,13418	0,1364	0,1445	0,14741	0,14909	0,14927
		σ	0,00448	0,01344	0,00349	0,00365	0,00251	0,00259

Fonte: Elaborado pelo autor

Tal cooperação fica evidente na Figura 56, em que os tamanhos de Lista Tabu se tangenciam. A exceção é quando o NBmax é 10, demonstrando que indiferente dos valores de diversificação da Lista Tabu, sua intensificação é baixa.

Figura 56: Evolução do experimento com BT no Formato 4 com 15 usuários



Fonte: Elaborado pelo autor

É observado na Tabela 32 que a Busca Tabu apresenta duas frentes, a primeira, demonstrando grande diversificação com baixa intensificação, e a segunda, ao contrário, levando a crer que, para esse programa teste, que possui um espaço de diversificação reduzido, o comportamento inverso das taxas se completa indo ao encontro das soluções de qualidade.


Tabela 32: Experimento com Algoritmo Memético no Formato 4 com 15 usuários

Taxa de Mutação			Taxa de Cruzamento		Lista Tabu								
					75			100			200		
					NBMax								
					75	100	200	75	100	200	75	100	200
					75	100	200	75	100	200	75	100	200
50	50	FO	0,17374	0,13274	0,19829	0,15924	0,18399	0,20388	0,2022	0,1487	0,1913		
		σ	0,00574	0,00356	0,00286	0,00412	0,0032	0,00239	0,00327	0,00196	0,00196		
	75	FO	0,17624	0,13123	0,1992	0,16087	0,18395	0,20097	0,20307	0,15019	0,19262		
		σ	0,00571	0,00371	0,00314	0,0042	0,00341	0,00256	0,00329	0,00206	0,0021		
	90	FO	0,17788	0,13245	0,19663	0,1612	0,18305	0,19859	0,20411	0,15088	0,1899		
		σ	0,00532	0,00353	0,00288	0,00416	0,0034	0,0026	0,00328	0,00217	0,00219		
	50	FO	0,1737	0,133	0,19948	0,15966	0,18294	0,2046	0,20224	0,14955	0,18981		
		σ	0,00554	0,0033	0,00277	0,00406	0,00305	0,00222	0,0031	0,00211	0,00208		
	75	FO	0,17541	0,13224	0,19991	0,15945	0,18511	0,20269	0,20415	0,14935	0,19206		
		σ	0,00525	0,00344	0,00284	0,00427	0,00346	0,00276	0,00318	0,00203	0,00198		
	90	FO	0,17692	0,13115	0,19488	0,1623	0,1838	0,20014	0,20596	0,15004	0,19133		
		σ	0,00538	0,0038	0,00268	0,00391	0,00359	0,00262	0,0036	0,00229	0,00226		
	90	50	FO	0,17495	0,1338	0,1976	0,16084	0,18139	0,20523	0,20222	0,14964	0,18857	
			σ	0,00549	0,00335	0,00263	0,0041	0,00313	0,00225	0,00333	0,00204	0,00205	
		75	FO	0,17604	0,13246	0,20013	0,1594	0,18661	0,20103	0,20558	0,14922	0,19118	
			σ	0,00504	0,0031	0,00261	0,00449	0,00313	0,00284	0,00292	0,00191	0,00213	
		90	FO	0,17794	0,13117	0,19363	0,16142	0,18294	0,19908	0,20502	0,15044	0,19232	
			σ	0,00539	0,00366	0,00288	0,00364	0,00346	0,00278	0,00335	0,00232	0,00231	

Fonte: Elaborado pelo autor

Na Figura 57, como uma tendência que se repete, o Algoritmo Memético apresenta qualidade superior, através da função de avaliação e de seu desvio padrão, em relação às demais técnicas.

Figura 57: Comparativo entre as soluções das MH no Formato 4 com 15 usuários



Fonte: Elaborado pelo autor

6.4.1.5 Programa teste no Formato 5 em Micro Escala

No experimento com Formato 5, representando o grupo dos *smartphones*, que possui um espaço menor de diversificação, onde o *layout* é limitado a 4 colunas, fica evidente, na Tabela 33, com a taxa de mutação de 25%, a obtenção da melhor solução. Destacam-se nos quadrantes inferiores (Q3 e Q4) as melhores soluções, ligadas às altas taxas de cruzamento. Nota-se que, até o momento, somente este programa teste produziu a melhor solução fora do quadrante 4.


Tabela 33: Experimento com Algoritmo Genético no Formato 5 com 15 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12565	0,12296	0,12522	0,12411	0,1238	0,12526
		σ	0,00518	0,00566	0,00594	0,00666	0,00508	0,00617
	10	FO	0,12961	0,12838	0,12575	0,1251	0,12795	0,12634
		σ	0,00577	0,00644	0,00676	0,00507	0,00692	0,00528
	25	FO	0,13159	0,13161	0,13292	0,13334	0,13244	0,13284
		σ	0,00599	0,00629	0,00833	0,00694	0,00688	0,00558
	50	FO	0,13374	0,13506	0,13538	0,13379	0,13493	0,13364
		σ	0,00794	0,00614	0,00573	0,00651	0,00695	0,00575
	75	FO	0,13757	0,1354	0,13504	0,13474	0,13605	0,13703
		σ	0,00602	0,00599	0,00551	0,00685	0,00606	0,00582
	90	FO	0,13677	0,13696	0,13759	0,13656	0,13737	0,13746
		σ	0,00556	0,00563	0,00511	0,00529	0,0058	0,00537

Fonte: Elaborado pelo autor

Na Figura 58, fica evidente que a intensificação é responsável pela descoberta de regiões com melhores soluções, ou seja, as taxas de cruzamento conduzem a regiões de maior viabilidade.

Figura 58: Evolução do experimento com AG no Formato 5 com 15 usuários



Fonte: Elaborado pelo autor

Mais uma vez, durante a observação do experimento com a Busca Tabu, fica evidente que as melhores soluções concentram-se no quadrante 4 da Tabela 34, confirmando a hipótese dos parâmetros com valores altos.


Tabela 34: Experimento com Busca Tabu no Formato 5 com 15 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,11991	0,1269	0,12466	0,1303	0,13223	0,13324
		σ	0,01089	0,00873	0,00998	0,0077	0,00796	0,00721
	25	FO	0,12214	0,13084	0,13424	0,13232	0,13827	0,13602
		σ	0,01164	0,00628	0,00705	0,00698	0,00664	0,0065
	50	FO	0,11983	0,1341	0,13377	0,1342	0,13763	0,13976
		σ	0,0172	0,00514	0,00649	0,00662	0,00613	0,00602
	75	FO	0,12089	0,12842	0,12967	0,13092	0,13978	0,14002
		σ	0,00467	0,0088	0,01858	0,01393	0,0047	0,00506
	100	FO	0,12202	0,13348	0,1359	0,13593	0,14214	0,14013
		σ	0,00996	0,00723	0,00572	0,00681	0,0053	0,00427
	200	FO	0,12473	0,12878	0,13674	0,13763	0,14158	0,14295
		σ	0,00963	0,00658	0,00498	0,00516	0,00454	0,00311

Fonte: Elaborado pelo autor

A partir da evolução da Busca Tabu observada na Figura 59, conclui-se que a diversificação propiciada pela Lista Tabu guia constantemente o processo de intensificação caucionado pelo NBmax.

Figura 59: Evolução do experimento com BT no Formato 5 com 15 usuários



Fonte: Elaborado pelo autor

Verifica-se, na Tabela 35, o papel desempenhado pelo Algoritmo Genético, confirmando que as altas taxas de cruzamento fornecem os melhores resultados, e o aumento excessivo da taxa de mutação impede que a busca intensifique as regiões mais promissoras do espaço de soluções. Similar ao experimento anterior, constata-se que, com a redução do espaço de diversificação, os parâmetros da Busca Tabu acabam produzindo uma compensação entre a intensificação e a diversificação para melhor conduzir a pesquisa no espaço.


Tabela 35: Experimento com Algoritmo Memético no Formato 5 com 15 usuários

Taxa de Mutação		5		Taxa de Cruzamento		Lista Tabu								
						75			100			200		
						NBMax								
						75	100	200	75	100	200	75	100	200
25	10	50	FO	0,15847	0,12404	0,11777	0,14227	0,19312	0,12304	0,19157	0,18955	0,12425		
			σ	0,01269	0,00363	0,0042	0,00588	0,00408	0,00377	0,00486	0,00347	0,00275		
		75	FO	0,15656	0,12247	0,11674	0,14267	0,19441	0,12465	0,19419	0,18974	0,12322		
			σ	0,0122	0,00393	0,00437	0,00638	0,00416	0,00355	0,00516	0,00366	0,00297		
		90	FO	0,15679	0,12194	0,11756	0,14187	0,19723	0,1254	0,19382	0,1883	0,1233		
			σ	0,01302	0,00425	0,00439	0,00606	0,00444	0,0035	0,00508	0,00365	0,00292		
	25	50	FO	0,15878	0,12398	0,11863	0,14143	0,19451	0,12426	0,19038	0,19004	0,12316		
			σ	0,01303	0,00332	0,00419	0,00591	0,0037	0,00371	0,00484	0,00321	0,0027		
		75	FO	0,15659	0,1236	0,11722	0,14135	0,19599	0,12491	0,19613	0,18997	0,12392		
			σ	0,01179	0,00419	0,00452	0,00582	0,00401	0,00381	0,0056	0,00399	0,00268		
		90	FO	0,15546	0,12111	0,11851	0,14278	0,19855	0,12517	0,19378	0,18696	0,12348		
			σ	0,01208	0,00418	0,00465	0,00553	0,00454	0,00385	0,00459	0,00401	0,00268		
	50	25	50	FO	0,15754	0,12468	0,11929	0,14144	0,19428	0,1246	0,19084	0,1889	0,12248	
				σ	0,01396	0,00331	0,00409	0,00646	0,00379	0,00369	0,0046	0,00327	0,00285	
		75	FO	0,15745	0,12337	0,11682	0,14203	0,19466	0,12474	0,19637	0,18987	0,12338		
			σ	0,01278	0,0038	0,00451	0,00597	0,00412	0,00384	0,00509	0,00373	0,00252		
		90	FO	0,15518	0,12043	0,11954	0,14317	0,19722	0,12525	0,19528	0,1869	0,12255		
			σ	0,01328	0,0039	0,00453	0,00547	0,00454	0,00388	0,00485	0,00386	0,00284		

Fonte: Elaborado pelo autor

Por meio dos dados é possível notar que o Algoritmo Memético alido às boas características das demais técnicas, gera melhores soluções (Figura 60). Nelas, percebe-se uma elavação qualitativa. Entretanto, nesse caso, seu desvio padrão encontra-se atrás da Busca Tabu, que apresenta a segunda melhor solução.

Figura 60: Comparativo entre as soluções das MH no Formato 5 com 15 usuários



Fonte: Elaborado pelo autor

6.4.2 Experimentos em Pequena Escala

Nesta seção apresentam-se os resultados dos experimentos em pequena escala.

6.4.2.1 Programa teste no Formato 1 em Pequena Escala

Vê-se, na Tabela 36, a incidência das altas taxas de cruzamento na qualidade das soluções. Verifica-se também que além das taxas de mutação elevadas, a taxa de 5% apresenta bons resultados, agrupando esses movimentos de sucesso nos quadrantes 3 e 4.


Tabela 36: Experimento com Algoritmo Genético no Formato 1 com 50 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12409	0,12261	0,12439	0,12264	0,12184	0,12405
		σ	0,00677	0,00675	0,00554	0,00522	0,00545	0,00497
	10	FO	0,1244	0,12587	0,12642	0,12432	0,12888	0,12613
		σ	0,00584	0,00665	0,00674	0,0059	0,00746	0,00425
	25	FO	0,13273	0,13035	0,1298	0,13091	0,13155	0,13135
		σ	0,00574	0,00581	0,00526	0,00586	0,00677	0,00737
	50	FO	0,13297	0,13353	0,13358	0,13391	0,13445	0,13367
		σ	0,0056	0,00681	0,00642	0,00609	0,00627	0,00662
	75	FO	0,13714	0,13435	0,1352	0,1348	0,1348	0,13399
		σ	0,00639	0,00554	0,00523	0,00459	0,00627	0,00472
	90	FO	0,13667	0,13425	0,13508	0,13744	0,1365	0,13582
		σ	0,0051	0,00506	0,0059	0,00637	0,00501	0,00534

Fonte: Elaborado pelo autor

Na Figura 61, observa-se que o processo de intensificação é responsável por soluções de qualidade, em que as taxas mais elevadas tangenciam-se, principalmente, quando em contato com diversificação reduzida.

Figura 61: Evolução do experimento com AG no Formato 1 com 50 usuários



Fonte: Elaborado pelo autor

Concentradas novamente no quadrante 4, na Tabela 37, a Busca Tabu apresenta as melhores soluções com altos valores de intensificação e diversificação, pressupondo-se que sua elevação remete a regiões de maior viabilidade.


Tabela 37: Experimento com Busca Tabu no Formato 1 com 50 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,1178	0,11781	0,1261	0,12817	0,12822	0,13124
		σ	0,00879	0,01848	0,00578	0,00695	0,00673	0,00657
	25	FO	0,12198	0,12254	0,12521	0,13293	0,13148	0,13452
		σ	0,00772	0,01086	0,01627	0,00622	0,00587	0,00479
	50	FO	0,11181	0,1235	0,13031	0,13373	0,13619	0,13482
		σ	0,00758	0,01364	0,00787	0,00669	0,00664	0,00414
	75	FO	0,11535	0,12171	0,13291	0,13611	0,13681	0,13771
		σ	0,00793	0,01045	0,00451	0,00627	0,00545	0,00488
	100	FO	0,12049	0,12987	0,13416	0,1362	0,13752	0,13703
		σ	0,01226	0,00636	0,0058	0,00547	0,00444	0,00504
	200	FO	0,11485	0,1186	0,13111	0,1356	0,13833	0,13844
		σ	0,0159	0,02317	0,00719	0,00511	0,00466	0,00362

Fonte: Elaborado pelo autor

Constata-se, na Figura 62, que o crescimento conjunto do NBmax e da Lista Tabu permitem uma adequada exploração do espaço de soluções, exceto com NBmax 25 e Lista Tabu 100, quando uma pequena queda pode ser observada.

Figura 62: Evolução do experimento com BT no Formato 1 com 50 usuários



Fonte: Elaborado pelo autor

Vê-se no experimento com Algoritmo Memético, na Tabela 38, que a elevação dos parâmetros da Busca Tabu, quando aliada ao Algoritmo Genético, não conduz necessariamente a bons resultados, ficando localizado o NBmax em 75 e a Lista Tabu na faixa de 75 a 100. Ao se observar o papel do AG, constata-se que a taxa de cruzamento intensifica a busca e conduz a melhores soluções, e a diversificação apesar de apresentar bons resultados em todas as faixas analisadas, concentra o melhor resultado na faixa intermediária de 75%.


Tabela 38: Experimento com Algoritmo Memético no Formato 1 com 50 usuários

Taxa de Mutação			Taxa de Cruzamento			Lista Tabu								
						75			100			200		
						NBMax								
						75	100	200	75	100	200	75	100	200
50	50	FO	0,17227	0,15562	0,13481	0,17056	0,1305	0,11448	0,13121	0,14894	0,17095			
		σ	0,00478	0,00512	0,00454	0,00494	0,00369	0,00393	0,00419	0,00397	0,00337			
	75	FO	0,17271	0,15737	0,13297	0,17298	0,1317	0,11293	0,13199	0,15043	0,1723			
		σ	0,00454	0,00516	0,00479	0,00471	0,00353	0,00418	0,00404	0,00426	0,00331			
	90	FO	0,17413	0,15719	0,13302	0,17433	0,13303	0,1132	0,13152	0,15031	0,17159			
		σ	0,00418	0,00533	0,00513	0,00436	0,00338	0,00407	0,00375	0,00446	0,00316			
	50	FO	0,17161	0,15688	0,13612	0,17204	0,13016	0,11525	0,12997	0,1504	0,17198			
		σ	0,00477	0,00533	0,00437	0,00481	0,00391	0,00424	0,00425	0,00395	0,00369			
	75	FO	0,17238	0,15889	0,13245	0,17295	0,13052	0,11221	0,1326	0,1501	0,17063			
		σ	0,00463	0,00527	0,00468	0,00437	0,0035	0,00449	0,00417	0,00427	0,00364			
	90	FO	0,17491	0,15838	0,13417	0,17532	0,13226	0,11233	0,13223	0,14888	0,17134			
		σ	0,00446	0,00508	0,00496	0,00439	0,00349	0,00431	0,00402	0,00406	0,00298			
	90	50	FO	0,17267	0,15818	0,13721	0,17237	0,12946	0,11627	0,13027	0,15189	0,17063		
			σ	0,0052	0,00566	0,00404	0,00527	0,0039	0,00443	0,00438	0,00415	0,00347		
		75	FO	0,17225	0,15949	0,13256	0,17383	0,12975	0,11307	0,13215	0,1492	0,17157		
			σ	0,00494	0,00557	0,00435	0,00476	0,00372	0,00407	0,00418	0,0046	0,00367		
		90	FO	0,17498	0,15727	0,13524	0,17378	0,13169	0,11126	0,13317	0,14971	0,16976		
			σ	0,00409	0,00556	0,00457	0,00437	0,00315	0,00439	0,00382	0,00434	0,00321		

Fonte: Elaborado pelo autor

No comparativo entre as técnicas (Figura 63), o Algoritmo Memético se sobressai, vindo na sequência a Busca Tabu, que está tecnicamente empatada com o Algoritmo Genético, se considerado seu desvio padrão.

Figura 63: Comparativo entre as soluções das MH no Formato 1 com 50 usuários



Fonte: Elaborado pelo autor

6.4.2.2 Programa teste no Formato 2 em Pequena Escala

Na Tabela 39, vê-se os resultados do Algoritmo Genético para o programa teste no Formato 2 com 50 usuários, em que as soluções concentram-se nos quadrantes 3 e 4, sugerindo que um alto valor para taxa de cruzamento conduz a soluções de melhor qualidade.


Tabela 39: Experimento com Algoritmo Genético no Formato 2 com 50 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12254	0,1225	0,12366	0,12366	0,12368	0,12269
		σ	0,00616	0,00626	0,00571	0,0048	0,00514	0,00465
	10	FO	0,12454	0,12616	0,12552	0,12604	0,12595	0,12476
		σ	0,00516	0,0048	0,00456	0,00511	0,00549	0,00465
	25	FO	0,12976	0,12954	0,1297	0,12872	0,128	0,12804
		σ	0,00499	0,00459	0,00561	0,0042	0,00466	0,00465
	50	FO	0,13083	0,12998	0,13033	0,13051	0,13175	0,13
		σ	0,00497	0,00426	0,0042	0,00416	0,00419	0,00439
	75	FO	0,13317	0,1327	0,13205	0,13176	0,13279	0,1317
		σ	0,00463	0,00465	0,00433	0,00451	0,00397	0,00389
	90	FO	0,13321	0,13345	0,13319	0,13318	0,13268	0,13398
		σ	0,00401	0,0048	0,00458	0,00528	0,00444	0,00462

Fonte: Elaborado pelo autor

Na Figura 64, verificam-se comportamentos tangentes para os experimentos, indicando interação entre os parâmetros, expondo, na maioria dos casos, crescimentos conjuntos. Esse movimento não acontece apenas na taxa de cruzamento de 25%, pois quando se alia a essa, taxas de mutação maiores que esse valor (25%) há uma leve queda nos resultados.

Figura 64: Evolução do experimento com AG no Formato 2 com 50 usuários



Fonte: Elaborado pelo autor

A Tabela 40 apresenta o comportamento promissor da Busca Tabu com o uso de parâmetros elevados, representando a tendência de concentração de melhores soluções no 4º quadrante, como incidência da baixa diversidade propiciada pelo tamanho reduzido da vizinhança.


Tabela 40: Experimento com Busca Tabu no Formato 2 com 50 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,11577	0,1245	0,12334	0,12589	0,13003	0,13107
		σ	0,00655	0,00719	0,00655	0,00786	0,00578	0,00699
	25	FO	0,11795	0,1228	0,12925	0,13342	0,1345	0,1321
		σ	0,00601	0,00725	0,00649	0,00629	0,0056	0,00597
	50	FO	0,12252	0,13077	0,13225	0,13158	0,13496	0,13577
		σ	0,00613	0,00677	0,00534	0,00639	0,0049	0,00548
	75	FO	0,11983	0,12713	0,126	0,13166	0,13763	0,13747
		σ	0,01095	0,00511	0,01174	0,01375	0,00396	0,00396
	100	FO	0,11814	0,12857	0,13457	0,13449	0,13897	0,1394
		σ	0,01292	0,00419	0,00427	0,00538	0,00554	0,00399
	200	FO	0,11914	0,1293	0,12973	0,13652	0,1403	0,13911
		σ	0,00724	0,00552	0,0036	0,00485	0,00353	0,00399

Fonte: Elaborado pelo autor

Constata-se, na Figura 65, que o aumento do tempo de busca, elevando-se o NBmax, apresenta tendências de dirigir a busca para regiões de viabilidade.

Figura 65: Evolução do experimento com BT no Formato 2 com 50 usuários



Fonte: Elaborado pelo autor

Pode-se observar, na Tabela 41, que a otimização das soluções feita pela Busca Tabu nesse experimento é conduzida por meio de baixa diversificação e média intensificação. Quanto ao papel desempenhado pelo Algoritmo Genético, a qualidade das soluções é conduzida principalmente por alta intensificação e distribui a diversificação entre as 3 faixas analisadas.


Tabela 41: Experimento com Algoritmo Memético no Formato 2 com 50 usuários

Taxa de Mutação			Taxa de Cruzamento		Lista Tabu								
					75			100			200		
					NBMax								
					75	100	200	75	100	200	75	100	200
50	50	FO	0,11022	0,17253	0,15492	0,18561	0,16122	0,13527	0,10975	0,10997	0,13804		
		σ	0,01174	0,00336	0,00363	0,00478	0,00511	0,00334	0,00386	0,00312	0,00323		
	75	FO	0,10918	0,17137	0,15705	0,18788	0,16061	0,13671	0,10822	0,10848	0,13664		
		σ	0,01082	0,00338	0,00378	0,00491	0,00521	0,00332	0,00408	0,00284	0,00347		
	90	FO	0,11057	0,17115	0,15848	0,18998	0,15949	0,13702	0,10746	0,1097	0,13526		
		σ	0,00985	0,00318	0,00363	0,00442	0,00493	0,00349	0,00385	0,00262	0,00314		
	50	FO	0,11109	0,17121	0,15354	0,18743	0,15987	0,13633	0,11029	0,10913	0,13864		
		σ	0,01283	0,00327	0,00386	0,00435	0,00477	0,00356	0,00347	0,00289	0,00307		
	75	FO	0,10936	0,17142	0,15778	0,18716	0,15994	0,13546	0,10765	0,10888	0,13594		
		σ	0,01109	0,00336	0,00352	0,00488	0,00495	0,00325	0,0039	0,00308	0,00361		
	90	FO	0,11047	0,17036	0,15863	0,1901	0,15917	0,13787	0,1065	0,10919	0,13426		
		σ	0,00911	0,00306	0,00368	0,00454	0,00516	0,00333	0,00422	0,00236	0,00288		
	75	50	FO	0,11055	0,1715	0,15217	0,18906	0,15928	0,13754	0,11035	0,10851	0,1376	
			σ	0,01369	0,00324	0,00416	0,00453	0,00445	0,00371	0,00382	0,00294	0,00322	
		75	FO	0,10958	0,17223	0,15921	0,18896	0,15991	0,13557	0,1075	0,10785	0,13532	
			σ	0,01079	0,00347	0,00339	0,00524	0,00448	0,00298	0,00421	0,00306	0,00394	
		90	FO	0,10949	0,16935	0,15824	0,1909	0,15799	0,1387	0,1075	0,10859	0,13542	
			σ	0,00993	0,00335	0,00336	0,00468	0,00563	0,00356	0,00436	0,00226	0,00302	

Fonte: Elaborado pelo autor

Na Figura 66, comparando-se o Algoritmo Memético com as demais técnicas, vê-se qualidade superior por meio da função de avaliação e de seu desvio padrão, expondo, assim, a qualidade da técnica.

Figura 66: Comparativo entre as soluções das MH no Formato 2 com 50 usuários



Fonte: Elaborado pelo autor

6.4.2.3 Programa teste no Formato 3 em Pequena Escala

Concentradas nos quadrantes 3 e 4 da Tabela 42, as soluções de boa qualidade demonstram-se novamente, quando se têm elevadas taxas de intensificação.


Tabela 42: Experimento com Algoritmo Genético no Formato 3 com 50 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12318	0,12224	0,12255	0,12264	0,12154	0,12287
		σ	0,00535	0,00547	0,00477	0,0061	0,006	0,00557
	10	FO	0,12397	0,12353	0,12469	0,12254	0,12369	0,12341
		σ	0,00456	0,00418	0,00513	0,00382	0,00627	0,00525
	25	FO	0,1275	0,12711	0,12852	0,12713	0,12894	0,12794
		σ	0,00535	0,0054	0,00551	0,00503	0,00518	0,00564
	50	FO	0,1307	0,13122	0,13053	0,13011	0,13174	0,12937
		σ	0,00559	0,00545	0,00583	0,00482	0,00551	0,00476
	75	FO	0,13204	0,13225	0,13096	0,13214	0,13277	0,13298
		σ	0,00465	0,00504	0,00358	0,00561	0,00436	0,00425
	90	FO	0,13268	0,13271	0,13354	0,13373	0,13245	0,132
		σ	0,00533	0,00415	0,00557	0,00491	0,00504	0,00541

Fonte: Elaborado pelo autor

Pode-se observar na Figura 67 que as melhores relações das altas taxas de intensificação concentram-se aliadas às taxas de mutação de 25 e 50%, nos demais casos, tal relação não apresenta soluções com tanta qualidade.

Figura 67: Evolução do experimento com AG no Formato 3 com 50 usuários



Fonte: Elaborado pelo autor

Ao analisar a Tabela 43, observa-se que as melhores soluções encontram-se no quadrante 4, com Lista Tabu entre 75 e 200 e NBmax entre 100 e 200, indicando que a diversificação conduz à busca para novas regiões. Porém, deve-se ter em mente que uma região pode não ser adequadamente explorada caso tenha-se um valor elevado de Lista Tabu.


Tabela 43: Experimento com Busca Tabu no Formato 3 com 50 usuários

		Lista Tabu						
			10	25	50	75	100	200
NBmax	10	FO	0,11743	0,12144	0,12714	0,1267	0,13054	0,12889
		σ	0,00634	0,00579	0,00663	0,00654	0,00616	0,00593
	25	FO	0,11453	0,12344	0,12866	0,13033	0,13123	0,13018
		σ	0,01546	0,00665	0,00678	0,00599	0,0053	0,00451
	50	FO	0,11722	0,12677	0,12827	0,13122	0,13423	0,13331
		σ	0,00506	0,00656	0,00694	0,00645	0,00523	0,00441
	75	FO	0,11404	0,12711	0,1219	0,13155	0,13483	0,13487
		σ	0,00792	0,00453	0,02083	0,00583	0,00401	0,00454
	100	FO	0,11764	0,12624	0,12926	0,13584	0,13615	0,13544
		σ	0,01414	0,005	0,00422	0,00406	0,00534	0,00361
	200	FO	0,11765	0,12583	0,13311	0,13253	0,13811	0,1372
		σ	0,00313	0,00493	0,00533	0,00492	0,00334	0,00371

Fonte: Elaborado pelo autor

Na Figura 68, constata-se que a diversificação na maioria dos casos, cumpre seu papel. Porém, quando se tem a Lista Tabu de tamanho 75, vê-se uma atenuação no crescimento, não acompanhando a convergência observada ao longo dos demais parâmetros.

Figura 68: Evolução do experimento com BT no Formato 3 com 50 usuários



Fonte: Elaborado pelo autor

Quando se analisa a Tabela 44, vê-se que altos valores nos parâmetros da Busca Tabu conduzem qualitativamente à busca local. Visto sob a perspectiva do Algoritmo Genético, a busca global está dividida entre as faixas de valores experimentadas, encontrando boas regiões de busca.


Tabela 44: Experimento com Algoritmo Memético no Formato 3 com 50 usuários

Taxa de Mutação			Taxa de Cruzamento			Lista Tabu								
						75			100			200		
						NBMax								
						75	100	200	75	100	200	75	100	200
50	50	FO	0,14934	0,16164	0,17295	0,14483	0,16102	0,1776	0,15319	0,18874	0,16882			
		σ	0,00501	0,00338	0,00362	0,0038	0,00419	0,00324	0,00445	0,00262	0,00298			
	75	FO	0,14978	0,16301	0,17532	0,14623	0,16142	0,1763	0,15181	0,18676	0,16631			
		σ	0,0052	0,00358	0,00346	0,00346	0,00452	0,00293	0,00487	0,00269	0,00317			
	90	FO	0,14988	0,16239	0,17609	0,14735	0,16346	0,17849	0,1524	0,18747	0,16672			
		σ	0,0056	0,00364	0,00353	0,00348	0,0047	0,00308	0,00456	0,00273	0,00331			
	75	50	FO	0,14878	0,16138	0,17262	0,14581	0,15962	0,17806	0,15336	0,18755	0,16777		
			σ	0,00501	0,00334	0,00338	0,00371	0,00455	0,00351	0,00455	0,00244	0,00296		
		75	FO	0,1499	0,16269	0,17687	0,14518	0,16102	0,17468	0,15128	0,18534	0,16714		
			σ	0,00524	0,00383	0,00334	0,00353	0,00439	0,00294	0,00464	0,00253	0,00335		
		90	FO	0,14846	0,16083	0,17453	0,14696	0,16372	0,17811	0,15197	0,18914	0,16787		
			σ	0,00532	0,00391	0,00346	0,00318	0,00479	0,00304	0,00455	0,00293	0,00339		
90		50	FO	0,14876	0,16161	0,17173	0,14659	0,1601	0,17939	0,15208	0,18866	0,1694		
			σ	0,00521	0,00325	0,00364	0,00377	0,00453	0,00346	0,00433	0,00222	0,00316		
		75	FO	0,15096	0,16378	0,17511	0,14443	0,16068	0,17498	0,15219	0,18521	0,16667		
			σ	0,00474	0,00415	0,00333	0,00331	0,00447	0,00276	0,00463	0,00252	0,00311		
		90	FO	0,14965	0,16091	0,17512	0,14724	0,16458	0,17735	0,15199	0,18827	0,16655		
			σ	0,00528	0,00369	0,00362	0,00336	0,00498	0,00329	0,00438	0,00269	0,00321		

Fonte: Elaborado pelo autor

Aliando as boas características da Busca Tabu e do Algoritmo Genético, o Algoritmo Memético produz melhores soluções, que são vistas no comparativo da Figura 69, onde qualitativamente vê-se a dominância do AM sobre as demais técnicas.

Figura 69: Comparativo entre as soluções das MH no Formato 3 com 50 usuários



Fonte: Elaborado pelo autor

6.4.2.4 Programa teste no Formato 4 em Pequena Escala

Ao se observar, na Tabela 45, o experimento com o Algoritmo Genético, nota-se a concentração das soluções nos quadrantes 3 e 4, indicando, novamente, que o processo de intensificação explora adequadamente as regiões promissoras, por outro lado a taxa da mutação elevada diversifica a população, inserindo novas estruturas que se confirmam promissoras.


Tabela 45: Experimento com Algoritmo Genético no Formato 4 com 50 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12742	0,12521	0,12441	0,12535	0,12537	0,12502
		σ	0,00654	0,00555	0,00571	0,00492	0,00505	0,00544
	10	FO	0,12703	0,12554	0,12732	0,12623	0,12585	0,12614
		σ	0,00654	0,00505	0,00593	0,00539	0,00596	0,00555
	25	FO	0,12949	0,13049	0,13066	0,13146	0,13207	0,12888
		σ	0,00495	0,00528	0,0056	0,00536	0,00511	0,00554
	50	FO	0,13177	0,13228	0,13192	0,13359	0,13177	0,13245
		σ	0,00437	0,00497	0,0043	0,00557	0,00466	0,00507
	75	FO	0,13426	0,13373	0,13408	0,13432	0,13367	0,13561
		σ	0,00523	0,00406	0,00507	0,00551	0,00491	0,00489
	90	FO	0,13496	0,13528	0,13385	0,13596	0,13585	0,13538
		σ	0,00552	0,00449	0,00427	0,0048	0,00522	0,00563

Fonte: Elaborado pelo autor

Observando-se a Figura 70 nota-se que baixas taxas de cruzamento não são capazes de descobrir regiões de qualidade, como no caso das taxas de 5 e 10% que se conservam próximas em todo o espaço de diversificação. Também se percebe que não existe grande aumento na qualidade das soluções em taxas de mutação maiores do que 50%.

Figura 70: Evolução do experimento com AG no Formato 4 com 50 usuários



Fonte: Elaborado pelo autor

No experimento observado na Tabela 46, as soluções concentram-se no quadrante 4, onde destaca-se no NBmax a faixa que vai de 75 a 200, e na Lista Tabu o intervalo de 100 a 200, como uma inclinação que vem aparecendo nos demais experimentos até então.


Tabela 46: Experimento com Busca Tabu no Formato 4 com 50 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,1191	0,12386	0,12811	0,1273	0,12846	0,12765
		σ	0,00577	0,00632	0,0059	0,00632	0,00503	0,00504
	25	FO	0,11014	0,12593	0,12755	0,12834	0,1313	0,13118
		σ	0,01142	0,00458	0,00581	0,00524	0,00554	0,00519
	50	FO	0,11553	0,12525	0,12918	0,12985	0,13322	0,13293
		σ	0,00963	0,0038	0,0047	0,00534	0,00404	0,00403
	75	FO	0,12201	0,12653	0,13035	0,13109	0,1346	0,13333
		σ	0,00467	0,00383	0,00388	0,00471	0,00383	0,004
	100	FO	0,11937	0,12408	0,12865	0,13132	0,1353	0,13513
		σ	0,00575	0,00751	0,00623	0,00372	0,00375	0,00373
	200	FO	0,11553	0,12408	0,12625	0,13303	0,13487	0,13536
		σ	0,01167	0,00769	0,01058	0,00449	0,00312	0,00314

Fonte: Elaborado pelo autor

Ao se observar a Figura 71, é notória a interação entre o NBmax e a Lista Tabu através do crescimento conjunto, onde valores de NBmax aliados a Lista Tabu maiores que 75 demonstram crescimentos tangenciais.

Figura 71: Evolução do experimento com BT no Formato 4 com 50 usuários



Fonte: Elaborado pelo autor

Apresentado na Tabela 47, o experimento do Algoritmo Memético no Formato 4 com 50 usuários, permite observar que as regiões promissoras do espaço de soluções são encontradas com altos valores para a busca local, proporcionada pela BT e para a busca global propiciado pelo AG. Nesse mesmo experimento, com uma instância menor conjecturou-se sobre a inversão de comportamentos dos parâmetros devido ao reduzido espaço de variação do processo de diversificação, o que não se concretiza neste programa teste, levando a crer que o pequeno espaço de diversificação passa a ser compensado pela multiplicidade de usuários.


Tabela 47: Experimento com Algoritmo Memético no Formato 4 com 50 usuários

Taxa de Mutação		Taxa de Cruzamento		Lista Tabu								
				75			100			200		
				NBMax								
				75	100	200	75	100	200	75	100	200
50	50	FO	0,16538	0,15493	0,16171	0,15619	0,11564	0,14392	0,10986	0,18515	0,18446	
		σ	0,00427	0,00324	0,0034	0,00301	0,00336	0,00333	0,00416	0,00273	0,00284	
	75	FO	0,16669	0,15721	0,15936	0,15402	0,11426	0,14577	0,10898	0,18511	0,18433	
		σ	0,00465	0,00325	0,0033	0,00283	0,00349	0,00304	0,0043	0,00263	0,00256	
	90	FO	0,16536	0,1564	0,16087	0,1526	0,11466	0,14595	0,11046	0,18455	0,18488	
		σ	0,0046	0,00338	0,00324	0,00292	0,00378	0,00329	0,0045	0,00271	0,00239	
	50	FO	0,1655	0,15411	0,16174	0,15689	0,11609	0,14255	0,11004	0,1848	0,18474	
		σ	0,00466	0,00309	0,00328	0,00305	0,00314	0,00355	0,00418	0,0025	0,00285	
	75	FO	0,16616	0,15659	0,16038	0,15462	0,1144	0,14555	0,10845	0,18635	0,18466	
		σ	0,00458	0,0033	0,00316	0,0026	0,00374	0,00301	0,00466	0,00255	0,00263	
	90	FO	0,16589	0,15647	0,16054	0,15336	0,1152	0,14544	0,10983	0,1854	0,18374	
		σ	0,00484	0,00339	0,00345	0,00273	0,00349	0,00362	0,00414	0,00281	0,00258	
	90	50	FO	0,16664	0,15391	0,16319	0,15608	0,11588	0,14335	0,10996	0,18574	0,18586
			σ	0,00432	0,00312	0,0035	0,00295	0,00334	0,00342	0,00381	0,0024	0,00257
		75	FO	0,16503	0,15647	0,16036	0,15539	0,11433	0,14628	0,10848	0,18739	0,18636
			σ	0,00451	0,00342	0,00321	0,00282	0,00349	0,00327	0,00451	0,0028	0,00244
		90	FO	0,16529	0,15571	0,16083	0,15363	0,11632	0,14436	0,11048	0,18726	0,18219
			σ	0,00499	0,00335	0,00374	0,00282	0,00355	0,00358	0,00426	0,00283	0,00266

Fonte: Elaborado pelo autor

Ao se comparar as melhores soluções de cada uma das metaheurística, a Figura 72 evidencia a qualidade do Algoritmo Memético. Contrário ao que vêm se expondo, neste experimento o AG fica à frente da BT. Por outro lado, se levamos em conta seus respectivos desvios padrão, estão tecnicamente empatados.

Figura 72: Comparativo entre as soluções das MH no Formato 4 com 50 usuários



Fonte: Elaborado pelo autor

6.4.2.5 Programa teste no Formato 5 em Pequena Escala

Como já evidenciado, o experimento no Formato 5 possui um espaço de diversificação reduzido. Dessa forma, as melhores soluções são encontradas nos quadrantes inferiores (Q3 e Q4) da Tabela 48, na qual se vê o melhor resultado com a taxa de mutação de 5%, enquanto na intensificação observa-se a incidência das altas taxas na qualidade dos resultados.


Tabela 48: Experimento com Algoritmo Genético no Formato 5 com 50 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12762	0,12419	0,12614	0,12457	0,12551	0,12652
		σ	0,00597	0,0067	0,00538	0,00553	0,00573	0,00667
	10	FO	0,12686	0,1267	0,12699	0,12713	0,12812	0,12753
		σ	0,00575	0,00466	0,00542	0,00542	0,00538	0,0063
	25	FO	0,13285	0,12955	0,13128	0,12969	0,13142	0,13256
		σ	0,00603	0,00418	0,00554	0,00484	0,00614	0,00626
	50	FO	0,13185	0,13296	0,13243	0,13259	0,13291	0,13186
		σ	0,00481	0,00525	0,00408	0,00516	0,00529	0,005
	75	FO	0,13406	0,13436	0,13606	0,13234	0,13379	0,13502
		σ	0,0043	0,00424	0,00472	0,00453	0,005	0,00482
	90	FO	0,13624	0,13549	0,13416	0,13418	0,13478	0,13444
		σ	0,00497	0,00532	0,00388	0,0042	0,00479	0,00435

Fonte: Elaborado pelo autor

Na Figura 73, fica evidente que a intensificação é responsável pelas soluções de maior qualidade, pois ao se observar a convergência do processo as taxas de cruzamento sofrem pouca influência das taxas de mutação, sendo este um forte indicador de que o processo de diversificação encontra regiões promissoras, ou seja, conduz a regiões de maior viabilidade em termos de qualidade das soluções.

Figura 73: Evolução do experimento com AG no Formato 5 com 50 usuários



Fonte: Elaborado pelo autor

Verifica-se, na Tabela 49, a concentração dos resultados com maior qualidade no quadrante 4, o que leva a crer que os valores de NBmax e Lista Tabu atuam melhor nos processos de intensificação e diversificação com valores elevados.


Tabela 49: Experimento com Busca Tabu no Formato 5 com 50 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,11742	0,12436	0,126	0,126	0,13159	0,13239
		σ	0,00559	0,00727	0,00753	0,0056	0,00625	0,00572
	25	FO	0,10971	0,12505	0,1296	0,13074	0,13122	0,13375
		σ	0,01501	0,00556	0,00517	0,00556	0,00467	0,00597
	50	FO	0,12169	0,12716	0,13164	0,13412	0,13659	0,1356
		σ	0,00633	0,0052	0,00599	0,00464	0,00452	0,00393
	75	FO	0,12165	0,12628	0,12955	0,13483	0,13586	0,13682
		σ	0,00943	0,00567	0,00532	0,00428	0,00397	0,00472
	100	FO	0,11965	0,13041	0,13074	0,13382	0,13795	0,13749
		σ	0,01061	0,00583	0,00419	0,00437	0,00485	0,00466
	200	FO	0,12414	0,13167	0,13469	0,13443	0,13836	0,13988
		σ	0,01003	0,0046	0,0046	0,00536	0,00372	0,00401

Fonte: Elaborado pelo autor

A Figura 74, reafirma o processo de cooperação, onde o aumento conjunto dos parâmetros da Busca Tabu direciona qualitativamente os resultados. Essa evolução conjunta pode ser vista como um forte indicador de que seus aumentos tenderiam a melhores regiões, o que não se demonstra no experimento seguinte, quando em conjunto ao Algoritmo Genético.

Figura 74: Evolução do experimento com BT no Formato 5 com 50 usuários



Fonte: Elaborado pelo autor

Como já mencionado, a Busca Tabu no processo de mutualismo com o Algoritmo Genético nem sempre apresenta o mesmo comportamento de quando está isolada, isso pode ser verificado na Tabela 50, onde os melhores resultados são encontrados em uma faixa exclusiva. Ao observarmos o Algoritmo Genético constata-se que alta intensificação produz bons resultados aliada a faixa intermediária de diversificação, apontando que a população memética possui um espaço menor de busca e sua população uma genética rica dirigindo o processo a regiões de maior viabilidade.


Tabela 50: Experimento com Algoritmo Memético no Formato 5 com 50 usuários

Taxa de Mutação			5		Taxa de Cruzamento		10		25		Lista Tabu								
											75			100			200		
											NBMax								
											75	100	200	75	100	200	75	100	200
50	FO	0,15779	0,18606	0,14008	0,12053	0,1515	0,13098	0,11793	0,1697	0,14065									
	σ	0,00329	0,00369	0,00391	0,00404	0,00436	0,00418	0,00505	0,00328	0,00309									
75	FO	0,15692	0,18502	0,14144	0,12088	0,14979	0,13224	0,11689	0,16774	0,14149									
	σ	0,00356	0,00336	0,00392	0,00426	0,00426	0,00378	0,00476	0,00306	0,00326									
90	FO	0,15868	0,18558	0,14257	0,12124	0,15162	0,13083	0,11591	0,166	0,14177									
	σ	0,0035	0,00324	0,00403	0,00423	0,00452	0,00365	0,00483	0,00293	0,00337									
50	FO	0,15833	0,1879	0,1411	0,12042	0,15	0,13076	0,11791	0,16807	0,1416									
	σ	0,0035	0,0037	0,00424	0,00413	0,00471	0,00458	0,0049	0,00345	0,00324									
75	FO	0,15827	0,18678	0,14239	0,12017	0,14961	0,13143	0,11782	0,16935	0,14136									
	σ	0,00365	0,0035	0,00371	0,00419	0,0044	0,00413	0,00512	0,00277	0,00344									
90	FO	0,15896	0,18626	0,14139	0,12242	0,15097	0,13143	0,11562	0,16472	0,14095									
	σ	0,00324	0,00334	0,00384	0,00403	0,00409	0,00395	0,00449	0,00294	0,00304									
50	FO	0,15722	0,18952	0,13978	0,12123	0,1491	0,13143	0,11743	0,16686	0,14278									
	σ	0,00347	0,00383	0,00427	0,00399	0,00514	0,00464	0,00476	0,00362	0,00301									
75	FO	0,15686	0,18812	0,14257	0,12047	0,14964	0,13155	0,11894	0,16842	0,14064									
	σ	0,00338	0,00332	0,00403	0,00453	0,00479	0,00422	0,00528	0,00292	0,00323									
90	FO	0,15871	0,18773	0,14143	0,12353	0,15026	0,13073	0,11615	0,16545	0,13954									
	σ	0,00295	0,00331	0,00401	0,00415	0,00438	0,0038	0,00409	0,00308	0,00323									

Fonte: Elaborado pelo autor

No comparativo da Figura 69, apura-se que as soluções de melhor qualidade são encontradas no Algoritmo Memético devido à união das técnicas, onde na sequência estão a Busca Tabu e o Algoritmo Genético em ordem qualitativa dos resultados.

Figura 75: Comparativo entre as soluções das MH no Formato 5 com 50 usuários



Fonte: Elaborado pelo autor

6.4.3 Experimentos em Média Escala

Nesta seção apresentam-se os resultados dos experimentos em média escala.

6.4.3.1 Programa teste no Formato 1 em Média Escala

Concentrados nos quadrantes 3 e 4 da Tabela 51 estão os resultados do AG. Neste experimento demonstra-se que altos valores das taxas de cruzamento recaem na qualidade das soluções, já a diversidade encontra-se nos valores centrais da gama parâmetros avaliada.


Tabela 51: Experimento com Algoritmo Genético no Formato 1 com 100 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12225	0,12229	0,12413	0,12266	0,12052	0,12318
		σ	0,00529	0,00675	0,00508	0,00418	0,00415	0,00511
	10	FO	0,12353	0,12553	0,12422	0,12541	0,12399	0,12538
		σ	0,00426	0,00595	0,00527	0,00615	0,00492	0,00589
	25	FO	0,12804	0,12958	0,12806	0,12702	0,12841	0,12879
		σ	0,00505	0,00671	0,00455	0,00433	0,00469	0,00507
	50	FO	0,1329	0,13292	0,13129	0,13372	0,13374	0,13062
		σ	0,00598	0,00533	0,00592	0,00697	0,00639	0,00629
	75	FO	0,13117	0,133	0,13202	0,1327	0,13281	0,13141
		σ	0,00452	0,00516	0,00529	0,00587	0,00536	0,00458
	90	FO	0,13335	0,13409	0,13371	0,1332	0,13414	0,13256
		σ	0,00539	0,00503	0,00554	0,00458	0,00464	0,00456

Fonte: Elaborado pelo autor

Observa-se, na Figura 76, que o processo de intensificação da busca é o agente determinador da qualidade das soluções, verificando que valores altos de cruzamento não são largamente influenciados pelas taxas de mutação, o que ocorre com as taxas menores de cruzamento. Desta maneira, pode-se entender que o processo de intensificação quando elevado explora adequadamente as regiões do espaço de soluções, o que não ocorre com valores baixos de cruzamento, gerando maior dependência do operador de diversificação.

Figura 76: Evolução do experimento com AG no Formato 1 com 100 usuários



Fonte: Elaborado pelo autor

Neste experimento, com a Busca Tabu, na Tabela 52, encontram-se nos quadrantes da direita as gamas de parâmetros promissores, com soluções de qualidade, indicando a adequação entre a diversificação e a da intensificação.


Tabela 52: Experimento com Busca Tabu no Formato 1 com 100 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,11389	0,122	0,12605	0,12854	0,1289	0,12689
		σ	0,00887	0,0068	0,00634	0,00595	0,00578	0,00613
	25	FO	0,11937	0,12408	0,1243	0,12541	0,13171	0,13133
		σ	0,00853	0,00674	0,0119	0,00657	0,00518	0,00421
	50	FO	0,11933	0,12485	0,12895	0,13205	0,1344	0,13308
		σ	0,0053	0,00568	0,00556	0,00598	0,00472	0,00429
	75	FO	0,1216	0,12433	0,13065	0,12963	0,13337	0,13281
		σ	0,01089	0,00402	0,00448	0,00946	0,00405	0,00374
	100	FO	0,11958	0,12717	0,12267	0,1319	0,135	0,13401
		σ	0,0024	0,00401	0,01703	0,00515	0,00371	0,00411
	200	FO	0,12023	0,12462	0,12773	0,13346	0,13555	0,13512
		σ	0,00435	0,0036	0,00711	0,00438	0,00367	0,00285

Fonte: Elaborado pelo autor

Tem-se, na Figura 77, um transcurso de *coopetição* entre o processo de intensificação e o de diversificação, indicando em alguns pontos a cooperação por meio do crescimento tangencial e em outros a competição vista pelo valor da FO. Isso é elucidado pelas linhas do NBmax 25, 50 e 75, em que se elevam sobre as demais ou andam lado a lado.

Figura 77: Evolução do experimento com BT no Formato 1 com 100 usuários



Fonte: Elaborado pelo autor

No experimento com o Algoritmo Memético da Tabela 53 uma tendência não revelada com a Busca Tabu salta aos olhos, onde o NBmax de 75 não visto antes, agora aparece como um indicador das soluções de qualidade desta técnica. O Algoritmo Genético se reafirma com a maioria de seus parâmetros, no entanto, aflora com uma alta taxa de mutação que antes não era vista.


Tabela 53: Experimento com Algoritmo Memético no Formato 1 com 100 usuários

Taxa de Mutação		50		Taxa de Cruzamento		Lista Tabu								
						75			100			200		
						NBMax								
						75	100	200	75	100	200	75	100	200
						75	100	200	75	100	200	75	100	200
90	75	50	FO	0,15467	0,11086	0,18401	0,13005	0,12122	0,13883	0,187	0,15297	0,12639		
			σ	0,00829	0,00345	0,00328	0,00437	0,00311	0,00311	0,00391	0,00314	0,00254		
		75	FO	0,15515	0,10993	0,18263	0,12901	0,12242	0,13878	0,18861	0,15415	0,12495		
			σ	0,00774	0,00371	0,00323	0,00422	0,00283	0,00322	0,00379	0,00289	0,00274		
		90	FO	0,15599	0,10893	0,18452	0,12882	0,12226	0,13699	0,18725	0,15358	0,12534		
			σ	0,00822	0,00404	0,00353	0,00461	0,0026	0,00354	0,00357	0,00265	0,00289		
	75	50	FO	0,15315	0,11157	0,18441	0,13073	0,12136	0,13807	0,18588	0,15346	0,12614		
			σ	0,00904	0,00339	0,00306	0,00408	0,00341	0,00335	0,00423	0,00329	0,00259		
		75	FO	0,15605	0,10897	0,18416	0,12831	0,12149	0,13756	0,18804	0,15384	0,1243		
			σ	0,007	0,00348	0,00321	0,00447	0,00283	0,00324	0,00389	0,0029	0,00276		
		90	FO	0,15711	0,10903	0,18596	0,12929	0,12121	0,13564	0,18733	0,15384	0,12476		
			σ	0,00881	0,00392	0,00332	0,00501	0,00279	0,00356	0,00387	0,00245	0,00293		
	90	50	FO	0,15272	0,11136	0,18389	0,13077	0,12177	0,13811	0,18739	0,15369	0,12691		
			σ	0,00964	0,00349	0,00293	0,00443	0,00344	0,00366	0,00382	0,00356	0,00238		
		75	FO	0,15536	0,10849	0,18508	0,1279	0,12065	0,13738	0,18865	0,15409	0,12519		
			σ	0,00651	0,00361	0,00294	0,00473	0,00276	0,00305	0,00352	0,00292	0,00253		
		90	FO	0,15783	0,10951	0,18435	0,12933	0,12117	0,13429	0,1889	0,15377	0,12384		
			σ	0,00924	0,00421	0,00352	0,00499	0,00263	0,00381	0,00423	0,0025	0,0031		

Fonte: Elaborado pelo autor

Novamente impondo-se, o Algoritmo Memético demonstra na, Figura 78, sua superioridade quando comparado com as demais metaheurísticas em termos do valor de aptidão. Já ao se observar os desvios padrão, essa vem em segundo lugar, atrás da Busca Tabu. Mesmo assim, ao se verificar a medida de dispersão as demais técnicas nem chegam próximas ao AM.

Figura 78: Comparativo entre as soluções das MH no Formato 1 com 100 usuários



Fonte: Elaborado pelo autor

6.4.3.2 Programa teste no Formato 2 em Média Escala

Na Tabela 54, observa-se nos quadrantes inferiores (Q3 e Q4) a concentração das soluções de qualidade do Algoritmo Genético, verificadas pelas elevadas taxas de cruzamento. O processo de diversificação, em contrapartida, apresenta valores intermediários, demonstrando que regiões muito distantes não são as mais promissoras.


Tabela 54: Experimento com Algoritmo Genético no Formato 2 com 100 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12204	0,12322	0,12193	0,12157	0,12127	0,12377
		σ	0,00605	0,00503	0,00499	0,00517	0,0058	0,00572
	10	FO	0,12655	0,1254	0,12455	0,12636	0,12656	0,12537
		σ	0,00814	0,00635	0,00722	0,00683	0,00553	0,00565
	25	FO	0,13133	0,12972	0,1295	0,13056	0,12926	0,13134
		σ	0,00554	0,00563	0,00522	0,00676	0,00553	0,00704
	50	FO	0,13239	0,13225	0,13436	0,13327	0,13244	0,13282
		σ	0,00489	0,00576	0,00548	0,00591	0,00542	0,00579
	75	FO	0,13463	0,13476	0,13486	0,13645	0,13307	0,13511
		σ	0,00665	0,00534	0,00515	0,00555	0,00593	0,00571
	90	FO	0,13593	0,13513	0,13609	0,13599	0,13566	0,13461
		σ	0,00535	0,0058	0,00545	0,00553	0,00488	0,00592

Fonte: Elaborado pelo autor

Evidencia-se, na Figura 54, o papel da diversificação em altas taxas de cruzamento, indicando que o processo de intensificação vai ao encontro de soluções geneticamente melhores.

Figura 79: Evolução do experimento com AG no Formato 2 com 100 usuários



Fonte: Elaborado pelo autor

No experimento exposto na Tabela 55, observam-se as soluções de qualidade agrupadas no quadrante 4, refletindo que os processos de intensificação e diversificação da busca se configuram como uma simbiose trófica, ou seja, estão mutuamente coordenados. Em suma, o NBmax fornece espaço adequado para a Lista Tabu diversificar a busca e essa fornece espaço para intensificação, estabelecendo assim este processo simbiótico.


Tabela 55: Experimento com Busca Tabu no Formato 2 com 100 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,1133	0,12315	0,12753	0,1237	0,13261	0,13086
		σ	0,00642	0,00889	0,007	0,00664	0,00892	0,00781
	25	FO	0,12134	0,12178	0,12814	0,13059	0,13412	0,13429
		σ	0,00769	0,01727	0,00912	0,00709	0,00513	0,00635
	50	FO	0,11022	0,1248	0,1306	0,13651	0,13647	0,13526
		σ	0,00664	0,00979	0,00702	0,00597	0,00459	0,0056
	75	FO	0,11934	0,12935	0,13452	0,13355	0,13866	0,13694
		σ	0,01275	0,00546	0,00454	0,00601	0,00494	0,00494
	100	FO	0,12182	0,13229	0,13189	0,1358	0,13817	0,13894
		σ	0,0081	0,00725	0,00434	0,00482	0,0051	0,00443
	200	FO	0,12232	0,12933	0,13173	0,13812	0,13974	0,13969
		σ	0,0123	0,00558	0,00749	0,00458	0,00352	0,00516

Fonte: Elaborado pelo autor

Na Figura 80, verifica-se que os processos cooperam em diferentes níveis, principalmente no que diz respeito a níveis altos de intensificação, onde por vez ocorre competição sobre a mesma região do espaço de busca.

Figura 80: Evolução do experimento com BT no Formato 2 com 100 usuários



Fonte: Elaborado pelo autor

Observa-se, na Tabela 56, um escopo bem definido para os parâmetros da Busca Tabu, pois se concentram apenas em uma região dos parâmetros experimentados. Relativo ao Algoritmo Genético verifica-se que a manutenção elevada da diversidade não necessariamente conduz a boas regiões, sendo a taxa de 75% a mais promissora, já o processo de intensificação encontra-se dividido entre a série avaliada com inclinação a taxa intermediária de 50%.


Tabela 56: Experimento com Algoritmo Memético no Formato 2 com 100 usuários

Taxa de Mutação			Taxa de Cruzamento			Lista Tabu								
						75			100			200		
						NBMax								
						75	100	200	75	100	200	75	100	200
50	50	FO	0,1146	0,10695	0,14317	0,12473	0,12009	0,12505	0,18762	0,16696	0,11755			
		σ	0,00513	0,00387	0,00421	0,00447	0,00459	0,00403	0,00426	0,00289	0,00445			
	75	FO	0,11577	0,1082	0,14296	0,12534	0,11963	0,12503	0,18706	0,1693	0,11824			
		σ	0,00562	0,00421	0,00395	0,00469	0,00483	0,0041	0,00429	0,00262	0,00415			
	90	FO	0,11415	0,1081	0,14149	0,12463	0,12047	0,12687	0,18599	0,1672	0,11749			
		σ	0,00581	0,00462	0,0043	0,00488	0,00492	0,00425	0,00444	0,0028	0,00441			
	50	FO	0,11354	0,10694	0,14365	0,12471	0,12118	0,12418	0,18794	0,16681	0,11711			
		σ	0,0048	0,00364	0,00386	0,00446	0,00419	0,00374	0,00385	0,00264	0,00424			
	75	FO	0,11472	0,10918	0,14302	0,12522	0,11957	0,12532	0,18825	0,16837	0,11804			
		σ	0,00553	0,00386	0,00372	0,00459	0,00527	0,00419	0,00432	0,00256	0,00377			
	90	FO	0,11316	0,10784	0,14143	0,12416	0,11946	0,12565	0,18785	0,16693	0,11832			
		σ	0,00594	0,00469	0,00398	0,00519	0,00492	0,00461	0,0041	0,00301	0,00449			
	75	50	FO	0,1139	0,10761	0,1431	0,12461	0,12145	0,12329	0,18768	0,16583	0,11716		
			σ	0,00492	0,00388	0,00357	0,00443	0,00427	0,00383	0,00419	0,00279	0,00403		
		75	FO	0,11357	0,10847	0,14367	0,12492	0,119	0,12517	0,18645	0,16919	0,11888		
			σ	0,00557	0,00407	0,0038	0,00478	0,0051	0,00387	0,00448	0,0025	0,00414		
		90	FO	0,11205	0,10887	0,14088	0,12535	0,119	0,12559	0,18746	0,1674	0,11842		
			σ	0,00549	0,00473	0,00425	0,00471	0,00516	0,00426	0,00389	0,00296	0,00474		
90		50	FO	0,1139	0,10761	0,1431	0,12461	0,12145	0,12329	0,18768	0,16583	0,11716		
			σ	0,00492	0,00388	0,00357	0,00443	0,00427	0,00383	0,00419	0,00279	0,00403		
		75	FO	0,11357	0,10847	0,14367	0,12492	0,119	0,12517	0,18645	0,16919	0,11888		
			σ	0,00557	0,00407	0,0038	0,00478	0,0051	0,00387	0,00448	0,0025	0,00414		
	90	FO	0,11205	0,10887	0,14088	0,12535	0,119	0,12559	0,18746	0,1674	0,11842			
		σ	0,00549	0,00473	0,00425	0,00471	0,00516	0,00426	0,00389	0,00296	0,00474			

Fonte: Elaborado pelo autor

Evidenciado pela Figura 81, o Algoritmo Memético eleva-se em relação às demais metaheurísticas produzindo melhores soluções e corroborando a dominância da técnica.

Figura 81: Comparativo entre as soluções das MH no Formato 2 com 100 usuários



Fonte: Elaborado pelo autor

6.4.3.3 Programa teste no Formato 3 em Média Escala

No experimento da Tabela 57, vê-se a concentração das soluções de melhor qualidade nos quadrantes inferiores (Q3 e Q4), indicando que altos valores de intensificação conduzem a regiões de grande viabilidade do espaço de busca.


Tabela 57: Experimento com Algoritmo Genético no Formato 3 com 100 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12509	0,12492	0,12385	0,12379	0,12677	0,12454
		σ	0,00605	0,00466	0,00584	0,00438	0,00588	0,00519
	10	FO	0,12735	0,12871	0,12754	0,12697	0,12841	0,12762
		σ	0,00534	0,00574	0,00526	0,00535	0,00671	0,00556
	25	FO	0,13031	0,13102	0,12916	0,13015	0,12993	0,1314
		σ	0,00516	0,00449	0,0041	0,00521	0,0047	0,00469
	50	FO	0,1328	0,13312	0,13362	0,13412	0,13345	0,13315
		σ	0,00439	0,0038	0,00494	0,00442	0,00528	0,00476
	75	FO	0,13515	0,13519	0,13405	0,13475	0,13517	0,13501
		σ	0,0045	0,00548	0,00424	0,00435	0,0054	0,00513
	90	FO	0,13413	0,13533	0,13422	0,13485	0,13532	0,1362
		σ	0,00413	0,00443	0,00439	0,00402	0,00487	0,00451

Fonte: Elaborado pelo autor

Na Figura 82, pode-se observar que as maiores contribuições das taxas de mutação concentram-se em 10, 75 e 90%, onde visivelmente percebem-se as contribuições do processo de diversificação.

Figura 82: Evolução do experimento com AG no Formato 3 com 100 usuários



Fonte: Elaborado pelo autor

A Tabela 58 concentra as soluções de maior qualidade nos quadrantes 2 e 4, demonstrando que valores elevados de Lista Tabu percorrem o espaço de busca adequadamente, em contrapartida o NBmax interage habilmente com valores elevados e também reduzidos.


Tabela 58: Experimento com Busca Tabu no Formato 3 com 100 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,12044	0,12258	0,12681	0,12966	0,13033	0,1283
		σ	0,00822	0,00525	0,006	0,0071	0,00594	0,00624
	25	FO	0,12146	0,12736	0,12683	0,12988	0,1352	0,13408
		σ	0,00631	0,00701	0,00664	0,00472	0,00621	0,00536
	50	FO	0,11385	0,12752	0,13044	0,13401	0,13532	0,13387
		σ	0,00973	0,00517	0,00657	0,00538	0,00506	0,00375
	75	FO	0,12284	0,12841	0,13173	0,13003	0,13516	0,13467
		σ	0,0067	0,0078	0,00723	0,00744	0,00406	0,00452
	100	FO	0,12217	0,12893	0,13355	0,13479	0,13603	0,13683
		σ	0,00615	0,00437	0,00621	0,0047	0,00407	0,00453
	200	FO	0,113	0,1298	0,13407	0,13232	0,13751	0,13936
		σ	0,01153	0,00352	0,0038	0,00508	0,00333	0,00386

Fonte: Elaborado pelo autor

Por meio da observação do NBmax, na Figura 83, constata-se que, no valor de 200, atinge-se o melhor resultado. No entanto, quando aliado a uma Lista Tabu pequena com tamanho 10, tem-se a deterioração da qualidade de suas soluções, indicando que alta intensificação não opera adequadamente com baixa diversificação. A queda observada na convergência do NBmax 75 e 100 quando, em conjunto, a Lista Tabu de 75, é considerada dentro da normalidade do processo, comprovado pelos respectivos desvios padrão.

Figura 83: Evolução do experimento com BT no Formato 3 com 100 usuários



Fonte: Elaborado pelo autor

Observando-se, na Tabela 59, o experimento com o Algoritmo Memético, vê-se que a Busca Tabu como já vem se apresentando ao longo dos demais experimentos, define-se em uma estreita faixa. Ou seja, os altos valores são indicadores de que o processo de evolução cultural poderia ser estendido pelo processo de diversificação dessa técnica. Ao se ver o papel da busca global, o Algoritmo Genético apresenta-se dividido entre as faixas de intensificação e diversificação investigadas, fazendo crer que a população possui uma diversidade genética reduzida.


Tabela 59: Experimento com Algoritmo Memético no Formato 3 com 100 usuários

Taxa de Mutação		Taxa de Cruzamento		50		75		90		Lista Tabu								
										75			100			200		
										NBMax								
										75			100			200		
										75			100			200		
50	FO	0,11633	0,13021	0,167	0,13136	0,12623	0,14833	0,13429	0,17946	0,11643								
	σ	0,0065	0,00313	0,00358	0,00393	0,00318	0,00376	0,00413	0,00315	0,00357								
75	FO	0,11696	0,12909	0,16862	0,12946	0,12443	0,14859	0,13494	0,17782	0,11593								
	σ	0,00596	0,00323	0,00349	0,00363	0,00317	0,00359	0,00372	0,00336	0,00353								
90	FO	0,11703	0,12997	0,16825	0,12851	0,12277	0,14987	0,13361	0,1801	0,11573								
	σ	0,00542	0,00338	0,00334	0,00341	0,00336	0,00394	0,00356	0,00335	0,00378								
50	FO	0,11566	0,13068	0,16799	0,1311	0,12715	0,14729	0,13354	0,17877	0,11665								
	σ	0,00683	0,00311	0,00378	0,00363	0,003	0,00385	0,00377	0,00318	0,00344								
75	FO	0,11597	0,12906	0,1692	0,12894	0,12529	0,1474	0,13395	0,17718	0,11543								
	σ	0,0059	0,00352	0,0032	0,00364	0,00318	0,00352	0,0035	0,00337	0,00326								
90	FO	0,11793	0,13006	0,16894	0,12927	0,12299	0,14903	0,1338	0,18136	0,11549								
	σ	0,00537	0,00348	0,00356	0,00365	0,00355	0,00405	0,00377	0,00357	0,00402								
50	FO	0,11503	0,12986	0,16674	0,13155	0,1283	0,14758	0,13459	0,17727	0,11781								
	σ	0,00723	0,00292	0,00399	0,00393	0,00319	0,00363	0,00351	0,00303	0,00323								
75	FO	0,11669	0,12829	0,16955	0,12858	0,12432	0,14863	0,13295	0,1755	0,11626								
	σ	0,00606	0,00323	0,00337	0,00331	0,00347	0,00348	0,00362	0,0037	0,00338								
90	FO	0,11762	0,12882	0,16786	0,13041	0,12221	0,14856	0,13343	0,17982	0,11599								
	σ	0,00578	0,00344	0,00377	0,00368	0,00359	0,00445	0,00343	0,00384	0,00365								

Fonte: Elaborado pelo autor

Ao se observar a Figura 84, o Algoritmo Memético eleva-se em relação às demais técnicas investigadas, evidenciando suas qualidades da união do Algoritmo Genético com a Busca Tabu.

Figura 84: Comparativo entre as soluções das MH no Formato 3 com 100 usuários



Fonte: Elaborado pelo autor

6.4.3.4 Programa teste no Formato 4 em Média Escala

Na Tabela 60, atenta-se para a concentração das soluções do Algoritmo Genético nos quadrantes inferiores (Q3 e Q4), indicando uma possível riqueza de material genético no processo de cruzamento. Quanto à mutação, observam-se elevadas taxas com uma mudança no valor de 10%, o que faz acreditar que todo o espaço de diversificação conduz a regiões promissoras.


Tabela 60: Experimento com Algoritmo Genético no Formato 4 com 100 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12147	0,12284	0,12144	0,12362	0,12113	0,12106
		σ	0,00455	0,00623	0,00501	0,0054	0,00468	0,00475
	10	FO	0,12405	0,12429	0,12443	0,12562	0,12321	0,12285
		σ	0,00498	0,00548	0,00578	0,00479	0,00428	0,00605
	25	FO	0,12894	0,1298	0,12845	0,12841	0,12819	0,12777
		σ	0,00484	0,00609	0,00609	0,00608	0,00547	0,00528
	50	FO	0,13216	0,13214	0,13135	0,13207	0,13089	0,1311
		σ	0,00569	0,00655	0,0062	0,00621	0,00641	0,00664
	75	FO	0,13187	0,13324	0,13146	0,13197	0,13198	0,13343
		σ	0,0047	0,0055	0,00628	0,00433	0,00522	0,00565
	90	FO	0,13243	0,13316	0,13223	0,13389	0,13521	0,13315
		σ	0,00545	0,00504	0,00556	0,005	0,00597	0,0045

Fonte: Elaborado pelo autor

Na Figura 85, observa-se o tangenciamento das soluções, quando com baixa intensificação, já em valores elevados contata-se maior uniformidade quando com baixos níveis de diversificação.

Figura 85: Evolução do experimento com AG no Formato 4 com 100 usuários



Fonte: Elaborado pelo autor

Têm-se, na Tabela 61, a concentração dos resultados no quadrante 4, o que leva a acreditar na mutualidade entre o NBmax e a Lista Tabu, os quais cooperam nos processos de intensificação e diversificação.


Tabela 61: Experimento com Busca Tabu no Formato 4 com 100 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,11926	0,12387	0,12744	0,13076	0,1323	0,13032
		σ	0,00694	0,0094	0,00712	0,00831	0,00726	0,00553
	25	FO	0,11818	0,12639	0,12376	0,12871	0,13544	0,13226
		σ	0,00991	0,00744	0,01296	0,0083	0,00644	0,00557
	50	FO	0,1247	0,1265	0,1313	0,13562	0,13706	0,1358
		σ	0,00531	0,00725	0,00733	0,00647	0,0059	0,00425
	75	FO	0,12102	0,12766	0,13253	0,1357	0,13745	0,13752
		σ	0,00602	0,00892	0,00695	0,00557	0,00486	0,00427
	100	FO	0,12035	0,12795	0,1316	0,13215	0,13716	0,13606
		σ	0,00968	0,00407	0,0047	0,00485	0,00402	0,00432
	200	FO	0,12043	0,12946	0,1357	0,13532	0,13864	0,14012
		σ	0,00854	0,0074	0,00411	0,00549	0,00438	0,00384

Fonte: Elaborado pelo autor

Na Figura 86, pode-se ver que o aumento conjunto dos parâmetros da Busca Tabu conduzem os resultados qualitativamente para melhores regiões do espaço de busca, o que no experimento seguinte não se corrobora.

Figura 86: Evolução do experimento com BT no Formato 4 com 100 usuários



Fonte: Elaborado pelo autor

Como já mencionado, a Tabela 62 confirma que a Busca Tabu aliada ao Algoritmo Genético tem uma grande interação, em que os processos de busca local e global acabam se complementando. Essa grande interação deve-se à concentração das boas soluções em faixas de parâmetros não tão elevados, como claramente nota-se no caso da BT.


Tabela 62: Experimento com Algoritmo Memético no Formato 4 com 100 usuários

			Lista Tabu										
			75			100			200				
			NBMax										
			75	100	200	75	100	200	75	100	200		
Taxa de Mutação	50	Taxa de Cruzamento	50	FO	0,11304	0,20327	0,10945	0,14888	0,18478	0,12855	0,12658	0,15303	0,1755
				σ	0,00488	0,00427	0,00357	0,00415	0,00342	0,00342	0,00496	0,00336	0,00311
			75	FO	0,11315	0,20404	0,10964	0,14718	0,18335	0,12759	0,1262	0,15386	0,17644
				σ	0,00492	0,004	0,00335	0,00399	0,00357	0,00348	0,00539	0,00348	0,00291
			90	FO	0,11382	0,20192	0,11062	0,14686	0,18554	0,12909	0,12616	0,15337	0,17503
				σ	0,00536	0,00402	0,00325	0,00395	0,00335	0,00331	0,00524	0,00358	0,00314
	75	Taxa de Cruzamento	50	FO	0,11282	0,20311	0,11005	0,1494	0,18455	0,12947	0,12596	0,15441	0,17553
				σ	0,0052	0,00404	0,00367	0,0044	0,00339	0,0032	0,00529	0,00356	0,00302
			75	FO	0,1132	0,20512	0,11042	0,14863	0,18416	0,12699	0,12708	0,15278	0,17704
				σ	0,0045	0,00361	0,00327	0,00407	0,00337	0,00347	0,0055	0,00322	0,00295
			90	FO	0,11369	0,20046	0,11096	0,14557	0,18695	0,12862	0,12579	0,15346	0,17621
				σ	0,0053	0,00408	0,00315	0,00399	0,00347	0,0035	0,00538	0,0038	0,00325
	90	Taxa de Cruzamento	50	FO	0,11306	0,20459	0,11075	0,14831	0,18498	0,12927	0,12608	0,15423	0,17415
				σ	0,00486	0,00393	0,00378	0,0047	0,00336	0,00346	0,00557	0,00359	0,00297
			75	FO	0,11225	0,20543	0,11052	0,14794	0,18342	0,12801	0,12665	0,15336	0,17701
				σ	0,00431	0,00334	0,00357	0,00398	0,00323	0,00354	0,00552	0,00325	0,00307
			90	FO	0,11412	0,19886	0,11001	0,14433	0,18698	0,12903	0,12597	0,15314	0,17753
				σ	0,0054	0,00374	0,00307	0,00433	0,00359	0,00383	0,00501	0,00347	0,00356

Fonte: Elaborado pelo autor

A qualidade do Algoritmo Memético pode ser observada na Figura 90, no valor da função de avaliação e de seu desvio padrão, expondo sua qualidade sobre as demais técnicas utilizadas nos experimentos.

Figura 87: Comparativo entre as soluções das MH no Formato 4 com 100 usuários



Fonte: Elaborado pelo autor

6.4.3.5 Programa teste no Formato 5 em Média Escala

Os quadrantes 3 e 4, da Tabela 63, concentram os resultados de maior qualidade do Algoritmo Genético, demonstrando que valores altos para as taxas de cruzamento refletem na qualidade das soluções. Quanto à diversidade, encontra-se nos valores laterais da gama avaliada, indicando que esse experimento com o Formato 5 é bem conduzido por taxas baixas por possuir um pequeno espaço de variação do *layout* com apenas 4 colunas. Em contrapartida, as altas taxas podem indicar a possível perda de diversidade da população.


Tabela 63: Experimento com Algoritmo Genético no Formato 5 com 100 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12531	0,12527	0,12366	0,12374	0,12473	0,12376
		σ	0,00529	0,00598	0,00569	0,00455	0,00371	0,00406
	10	FO	0,12593	0,12522	0,12717	0,12648	0,12625	0,12627
		σ	0,00496	0,00436	0,00505	0,00445	0,00604	0,00564
	25	FO	0,12955	0,12927	0,12947	0,13067	0,1305	0,12993
		σ	0,00489	0,00436	0,00479	0,00531	0,00473	0,00498
	50	FO	0,1322	0,1302	0,13244	0,12971	0,13283	0,13166
		σ	0,00456	0,0043	0,00522	0,00372	0,00484	0,00506
	75	FO	0,13406	0,13338	0,13317	0,13285	0,13403	0,13211
		σ	0,00475	0,00427	0,00507	0,00505	0,00496	0,00401
	90	FO	0,13536	0,13445	0,13355	0,13366	0,13402	0,13518
		σ	0,00429	0,00437	0,00526	0,00406	0,00457	0,00431

Fonte: Elaborado pelo autor

Pode-se inferir, com base na Figura 90, que em determinados pontos houve coopetição entre as etapas de intensificação e de diversificação, o que em outros momentos leva a crer que a perturbação gerada pela mutação acabou por deteriorar a região inserindo excessivo ruído.

Figura 88: Evolução do experimento com AG no Formato 5 com 100 usuários



Fonte: Elaborado pelo autor

A Tabela 64 apresenta o comportamento da Busca Tabu com o uso de parâmetros de valores elevados, representando a tendência de agrupamento das melhores soluções no 4º quadrante.


Tabela 64: Experimento com Busca Tabu no Formato 5 com 100 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,12036	0,12177	0,12584	0,12797	0,12869	0,12919
		σ	0,00608	0,00955	0,0072	0,00622	0,00573	0,00652
	25	FO	0,11968	0,12382	0,1289	0,12887	0,13327	0,13416
		σ	0,00516	0,00496	0,00518	0,00532	0,00601	0,00527
	50	FO	0,11239	0,12489	0,13045	0,1323	0,13639	0,13554
		σ	0,00731	0,0122	0,00747	0,0054	0,00553	0,00417
	75	FO	0,11819	0,12833	0,13052	0,13167	0,13671	0,1352
		σ	0,0072	0,00405	0,0051	0,00641	0,00464	0,00475
	100	FO	0,12389	0,12872	0,13112	0,13496	0,1369	0,13576
		σ	0,00558	0,00514	0,00392	0,00395	0,00449	0,0042
	200	FO	0,11164	0,12556	0,13014	0,13317	0,13829	0,13775
		σ	0,01211	0,00386	0,00567	0,00614	0,0041	0,00448

Fonte: Elaborado pelo autor

Pode-se constatar, na Figura 89, que a elevação do tempo de busca no processo de intensificação conduz a regiões de alta viabilidade, apesar de acrescer significativamente a duração da operação da metaheurística, um fator que deve ser levado em consideração quando se fala sobre a qualidade das soluções e o tempo hábil para seus desenvolvimentos.

Figura 89: Evolução do experimento com BT no Formato 5 com 100 usuários



Fonte: Elaborado pelo autor

No experimento com Algoritmo Memético demonstrado na Tabela 65, observa-se que os parâmetros do processo de busca global encontram-se divididos entre as faixas investigadas, já a busca local demonstra crescimento com o aumento dos parâmetros, indicando melhores soluções. Em compensação, tem-se a elevação do tempo e custo computacional, como já se mencionou ao longo da análise dos experimentos.


Tabela 65: Experimento com Algoritmo Memético no Formato 5 com 100 usuários

Taxa de Mutação		5		Taxa de Cruzamento		Lista Tabu								
						75			100			200		
						NBMax								
						75	100	200	75	100	200	75	100	200
	50	FO	0,12922	0,17942	0,10781	0,166	0,16116	0,1376	0,1137	0,17857	0,1891			
		σ	0,00535	0,00402	0,00425	0,00331	0,00402	0,00324	0,00481	0,00328	0,00378			
		75	FO	0,12815	0,17964	0,1063	0,16531	0,16153	0,13685	0,11535	0,17757	0,1863		
			σ	0,00545	0,00405	0,00463	0,00343	0,00432	0,00341	0,00467	0,00304	0,00371		
		90	FO	0,12644	0,18203	0,10767	0,16655	0,15967	0,13858	0,11667	0,17551	0,18824		
			σ	0,00564	0,00375	0,00508	0,00323	0,00428	0,00336	0,00421	0,00315	0,00335		
	10	50	FO	0,13002	0,17869	0,1079	0,16524	0,16269	0,13799	0,11312	0,1791	0,18997		
			σ	0,00583	0,00386	0,00441	0,00343	0,0041	0,00351	0,00522	0,00356	0,00354		
		75	FO	0,12759	0,17867	0,10553	0,16483	0,16098	0,13821	0,11437	0,17585	0,18535		
			σ	0,00575	0,00441	0,00508	0,00357	0,00426	0,00328	0,00457	0,00304	0,00344		
		90	FO	0,12615	0,18104	0,10849	0,16596	0,16076	0,13989	0,11636	0,17584	0,18771		
			σ	0,006	0,00387	0,00549	0,00322	0,00457	0,00319	0,00419	0,00343	0,00308		
	25	50	FO	0,13097	0,17745	0,10758	0,1642	0,16136	0,13666	0,114	0,18082	0,19166		
			σ	0,00608	0,00363	0,0041	0,00356	0,00449	0,0035	0,00508	0,00376	0,00339		
		75	FO	0,12863	0,17726	0,10578	0,16392	0,16167	0,13851	0,11472	0,17432	0,18654		
			σ	0,00626	0,00408	0,00523	0,00363	0,0046	0,00315	0,00454	0,00306	0,00361		
		90	FO	0,1249	0,18072	0,10939	0,16679	0,16103	0,1391	0,1159	0,17421	0,18861		
			σ	0,00597	0,00412	0,0057	0,00307	0,00453	0,00339	0,00457	0,00323	0,00283		

Fonte: Elaborado pelo autor

Dentre as técnicas empregadas, a Figura 90 mostra o Algoritmo Memético com resultado elevado em comparação às outras técnicas empregadas neste teste.

Figura 90: Comparativo entre as soluções das MH no Formato 5 com 100 usuários



Fonte: Elaborado pelo autor

6.4.4 Experimentos em Larga Escala

Nesta seção apresentam-se os resultados dos experimentos em grande escala.

6.4.4.1 Programa teste no Formato 1 em Larga Escala

Nos quadrantes 3 e 4 da Tabela 51, encontram-se as soluções de melhor qualidade, demonstrando que valores elevados de taxas de mutação e cruzamento incidem diretamente na qualidade dos resultados.


Tabela 66: Experimento com Algoritmo Genético no Formato 1 com 1000 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12173	0,12496	0,12331	0,12532	0,12243	0,12449
		σ	0,00583	0,00661	0,00492	0,00714	0,00509	0,00605
	10	FO	0,12596	0,12742	0,12466	0,12642	0,12582	0,12499
		σ	0,00561	0,00593	0,0061	0,00548	0,00553	0,00744
	25	FO	0,12996	0,1288	0,13107	0,12978	0,12928	0,12938
		σ	0,00625	0,00529	0,00561	0,00529	0,00548	0,00625
	50	FO	0,13238	0,13217	0,13129	0,13279	0,13197	0,13269
		σ	0,00621	0,00513	0,00597	0,00606	0,00615	0,00599
	75	FO	0,13147	0,13346	0,13377	0,13546	0,1332	0,13463
		σ	0,00527	0,00567	0,00566	0,00535	0,00527	0,00574
	90	FO	0,13354	0,13385	0,13344	0,13332	0,13455	0,13427
		σ	0,0056	0,0051	0,00513	0,00555	0,00508	0,00529

Fonte: Elaborado pelo autor

Observa-se, na Figura 91, que o processo de intensificação da busca é o principal contribuinte para a qualidade das soluções, verificando os valores mais elevados das taxas de cruzamento, vê-se que esses não são largamente influenciados pelo processo de diversificação. Esse comportamento não acontece em valores pequenos, que acabam tendo suas deficiências de intensificação supridas por meio da mutação.

Figura 91: Evolução do experimento com AG no Formato 1 com 1000 usuários



Fonte: Elaborado pelo autor

Vê-se, na Tabela 67, as soluções de maior qualidade agrupadas no quadrante 4, cogitando que os valores de seus processos de diversificação e intensificação, se elevados, podem fornecer adequados espaços a condução da busca por melhores regiões.


Tabela 67: Experimento com Busca Tabu no Formato 1 com 1000 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,12404	0,11731	0,12199	0,12811	0,12911	0,13024
		σ	0,00404	0,00405	0,00552	0,00567	0,00597	0,0007
	25	FO	0,11871	0,12189	0,12303	0,1281	0,13447	0,13459
		σ	0,00389	0,00357	0,0027	0,00316	0,00073	0,0045
	50	FO	0,12208	0,12113	0,1297	0,12399	0,13679	0,13548
		σ	0,00372	0,00548	0,00535	0,0061	0,00451	0,00487
	75	FO	0,11731	0,11895	0,12912	0,13115	0,13633	0,1396
		σ	0,00414	0,0032	0,00203	0,00531	0,00564	0,00547
	100	FO	0,11922	0,122	0,12302	0,13141	0,1373	0,13771
		σ	0,00542	0,00339	0,00145	0,0062	0,00375	0,0048
	200	FO	0,11912	0,12505	0,12815	0,14132	0,13904	0,13981
		σ	0,00199	0,00237	0,00512	0,00332	0,00372	0,00372

Fonte: Elaborado pelo autor

Verifica-se, na Figura 92, que os processos cooperam em diferentes intensidades, sobretudo no que diz respeito ao nível elevado de intensificação, onde o NBmax de 200 expõe uma convergência mais acentuada em relação aos demais, indicando que o processo de intensificação poderia se prolongar.

Figura 92: Evolução do experimento com BT no Formato 1 com 1000 usuários



Fonte: Elaborado pelo autor

Apura-se, na Tabela 68, que o Algoritmo Memético apresenta regiões promissoras com o uso de parâmetros elevados, o que é um forte apontador de que em experimentos com programas de testes em larga escala, torna-se apropriado o uso de populações com mais indivíduos. Tal estratégia visa cobrir uma região maior do espaço de busca, evitando a possível convergência prematura, além do prolongamento do processo de intensificação da busca.


Tabela 68: Experimento com Algoritmo Memético no Formato 1 com 1000 usuários

Taxa de Mutação			Taxa de Cruzamento			Lista Tabu								
						75			100			200		
						NBMax								
						75	100	200	75	100	200	75	100	200
						75	100	200	75	100	200	75	100	200
50	50	FO	0,13206	0,14419	0,16674	0,14467	0,14318	0,1514	0,16225	0,14958	0,17661			
		σ	0,00448	0,00477	0,00418	0,00538	0,00303	0,00451	0,00291	0,00316	0,00321			
	75	FO	0,13231	0,14486	0,16587	0,14368	0,14481	0,15031	0,16211	0,1499	0,17876			
		σ	0,00404	0,00488	0,00387	0,0055	0,00282	0,00426	0,00319	0,00303	0,00302			
	90	FO	0,13052	0,14451	0,16503	0,14405	0,14582	0,1484	0,15982	0,14896	0,18114			
		σ	0,00415	0,00535	0,00403	0,00558	0,00279	0,00456	0,00324	0,00297	0,00279			
	50	FO	0,13164	0,14375	0,16742	0,14576	0,14331	0,15256	0,16253	0,14965	0,17641			
		σ	0,00415	0,00444	0,00419	0,00485	0,00304	0,00453	0,00296	0,00295	0,00344			
	75	FO	0,133	0,14583	0,16488	0,14439	0,14384	0,14889	0,16318	0,15014	0,17928			
		σ	0,00394	0,0046	0,00388	0,00572	0,00275	0,00448	0,00289	0,00324	0,00303			
	90	FO	0,13011	0,14497	0,16384	0,14327	0,14454	0,14898	0,15976	0,14939	0,17938			
		σ	0,00385	0,00585	0,00402	0,00571	0,00263	0,00438	0,00306	0,00275	0,00302			
	75	50	FO	0,13153	0,14357	0,16649	0,14453	0,14432	0,15279	0,16399	0,14958	0,17558		
			σ	0,00422	0,00448	0,00382	0,00462	0,00332	0,00483	0,00318	0,00292	0,00331		
		75	FO	0,13349	0,14689	0,16399	0,14376	0,14341	0,14875	0,16246	0,15076	0,17953		
			σ	0,00388	0,00471	0,0042	0,00545	0,00273	0,00433	0,00278	0,00319	0,00322		
		90	FO	0,13009	0,1453	0,16385	0,14343	0,14334	0,14819	0,15889	0,15009	0,17981		
			σ	0,00417	0,0062	0,00419	0,00593	0,00243	0,00465	0,00292	0,00256	0,00311		

Fonte: Elaborado pelo autor

Ao se comparar a qualidade das técnicas empregadas, a Figura 93 demonstra a elevação do Algoritmo Memético em relação ao Algoritmo Genético e a Busca Tabu, que é evidenciado no aumento do valor da FO e pelo reduzido desvio padrão.

Figura 93: Comparativo entre as soluções das MH no Formato 1 com 1000 usuários



Fonte: Elaborado pelo autor

6.4.4.2 Programa teste no Formato 2 em Larga Escala

Verifica-se, na Tabela 69, a concentração de soluções produzidas pelo Algoritmo Genético nos quadrantes inferiores (Q3 e Q4), e percebe-se que as altas taxas de cruzamento levam a soluções de maior qualidade.


Tabela 69: Experimento com Algoritmo Genético no Formato 2 com 1000 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12295	0,1215	0,12185	0,12203	0,12229	0,12251
		σ	0,00604	0,00571	0,00511	0,00548	0,00418	0,00528
	10	FO	0,12543	0,12472	0,12638	0,12469	0,12524	0,12652
		σ	0,00603	0,00639	0,00647	0,00498	0,00566	0,00695
	25	FO	0,13064	0,12888	0,12986	0,12999	0,1293	0,13036
		σ	0,00546	0,00497	0,0057	0,00549	0,00603	0,00473
	50	FO	0,13295	0,13121	0,13126	0,1318	0,13209	0,13038
		σ	0,00675	0,00535	0,00516	0,00511	0,0065	0,00529
	75	FO	0,13204	0,13118	0,13364	0,13188	0,13297	0,13313
		σ	0,00527	0,00426	0,00617	0,00586	0,005	0,00513
	90	FO	0,13334	0,13282	0,13407	0,13354	0,1349	0,13435
		σ	0,00504	0,00555	0,00611	0,00499	0,00519	0,00528

Fonte: Elaborado pelo autor

Constata-se, na Figura 94, que o processo de intensificação, como já mencionado, possivelmente está explorando de forma adequada a região em que sem encontra, enquanto a mutação com baixa intensificação, acaba ficando distante, a ponto de decair os resultados em alguns pontos.

Figura 94: Evolução do experimento com AG no Formato 2 com 1000 usuários



Fonte: Elaborado pelo autor

Observa-se, na Tabela 70, que as melhores soluções encontram-se no quadrante 4, com Lista Tabu e NBmax de tamanhos 200, indicando que a diversificação administra boas regiões para intensificação, que podem não ser adequadamente exploradas devido ao breve período de permanência na região ou a uma estrutura de memória curta, fazendo com que a busca gire em torno de uma área pequena.


Tabela 70: Experimento com Busca Tabu no Formato 2 com 1000 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,12203	0,12511	0,13223	0,1363	0,1286	0,13159
		σ	0,00414	0,0046	0,00402	0,00642	0,00593	0,00644
	25	FO	0,12715	0,12701	0,12298	0,13529	0,13438	0,13228
		σ	0,00357	0,0022	0,00528	0,00628	0,00616	0,0054
	50	FO	0,12107	0,12336	0,12394	0,13223	0,13565	0,13464
		σ	0,00297	0,00527	0,0025	0,00554	0,00527	0,00524
	75	FO	0,12108	0,12336	0,13122	0,13122	0,1371	0,13724
		σ	0,00313	0,0041	0,00538	0,00619	0,0058	0,00508
	100	FO	0,11821	0,118	0,12512	0,12918	0,13723	0,1376
		σ	0,00265	0,00339	0,0051	0,00614	0,00291	0,00436
	200	FO	0,12105	0,12003	0,13529	0,13529	0,13847	0,13929
		σ	0,00157	0,00169	0,00112	0,00506	0,00374	0,00424

Fonte: Elaborado pelo autor

Na Figura 95, constata-se regiões de sombra, verificados por platôs no gráfico, onde em alguns pontos a diversificação torna-se pequena fazendo do processo de intensificação o administrador de melhores resultados.

Figura 95: Evolução do experimento com BT no Formato 2 com 1000 usuários



Fonte: Elaborado pelo autor

Verifica-se, na Tabela 71, assim como no experimento anterior, que o desenvolvimento de regiões promissoras se dá principalmente com a elevação dos parâmetros. Para o Algoritmo Genético, constata-se que os níveis de intensificação têm um leve decaimento, em contrapartida de uma sutil elevação da intensificação da Busca Tabu, demonstrando que o AG encontrou uma região promissora no processo de busca global que a BT poderia explorar por um período maior de tempo, durante a fase local da busca.


Tabela 71: Experimento com Algoritmo Memético no Formato 2 com 1000 usuários

Taxa de Mutação		Taxa de Cruzamento		Lista Tabu								
				75			100			200		
				NBMax								
				75	100	200	75	100	200	75	100	200
50	FO	0,12316	0,10858	0,15541	0,15879	0,1129	0,11393	0,13076	0,13509	0,1676		
		σ	0,00543	0,00528	0,00449	0,00494	0,0027	0,00412	0,00431	0,00323	0,00375	
	75	FO	0,12375	0,10837	0,15677	0,15728	0,11308	0,11226	0,12914	0,13358	0,16517	
		σ	0,00563	0,00554	0,00417	0,00457	0,00283	0,00389	0,00437	0,00339	0,00363	
	90	FO	0,12279	0,10951	0,15554	0,15878	0,1147	0,11171	0,13078	0,13254	0,1638	
		σ	0,00572	0,00564	0,00441	0,00436	0,0031	0,00391	0,00417	0,00335	0,00384	
	50	FO	0,12197	0,10759	0,15642	0,15874	0,11378	0,11325	0,13077	0,13604	0,16685	
		σ	0,00503	0,00506	0,00419	0,0051	0,00252	0,004	0,00432	0,00338	0,00348	
	75	FO	0,12316	0,1093	0,15746	0,15854	0,11406	0,11312	0,12952	0,13234	0,16649	
		σ	0,00519	0,00531	0,00408	0,00445	0,00268	0,00374	0,0041	0,0037	0,00334	
	90	FO	0,12324	0,10858	0,15435	0,16025	0,11567	0,11108	0,13011	0,1329	0,16229	
		σ	0,0062	0,00528	0,00477	0,00452	0,00299	0,00423	0,00415	0,00328	0,00418	
	75	50	FO	0,12274	0,10712	0,15518	0,15973	0,11413	0,11288	0,12968	0,13505	0,16675
			σ	0,00459	0,00517	0,00441	0,00522	0,00269	0,00383	0,00433	0,00327	0,00373
		75	FO	0,12206	0,10935	0,15608	0,15708	0,11321	0,11304	0,12864	0,13232	0,16816
			σ	0,00491	0,00555	0,00447	0,0043	0,00275	0,00396	0,00443	0,0038	0,0032
		90	FO	0,12335	0,1088	0,15406	0,15998	0,11677	0,11021	0,12948	0,13355	0,1616
			σ	0,00662	0,00563	0,00444	0,00455	0,00271	0,00424	0,00402	0,00314	0,00418

Fonte: Elaborado pelo autor

Comparando-se as técnicas nesse experimento (Figura 54), nota-se a sobreposição do Algoritmo Memético em relação às demais técnicas, ficando atrás a BT e o AG, que podemos considerar tecnicamente empatados devido aos desvios padrão.

Figura 96: Comparativo entre as soluções das MH no Formato 2 com 1000 usuários



Fonte: Elaborado pelo autor

6.4.4.3 Programa teste no Formato 3 em Larga Escala

Observando-se, na Tabela 72, os resultados do Algoritmo Genético, as boas soluções concentram-se nos quadrantes inferiores (Q3 e Q4), indicando que elevadas taxas de mutação e cruzamento geram melhores resultados.


Tabela 72: Experimento com Algoritmo Genético no Formato 3 com 1000 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12353	0,12413	0,12312	0,1227	0,12526	0,12276
		σ	0,00584	0,00633	0,00578	0,00509	0,00684	0,00522
	10	FO	0,12833	0,12552	0,12599	0,12745	0,12519	0,12636
		σ	0,0062	0,00654	0,00633	0,00816	0,00563	0,00636
	25	FO	0,1293	0,12957	0,13095	0,13153	0,1312	0,12914
		σ	0,00671	0,00546	0,00619	0,00703	0,00682	0,00487
	50	FO	0,13153	0,13212	0,13212	0,13178	0,13237	0,1319
		σ	0,00675	0,00543	0,00612	0,00477	0,00534	0,00559
	75	FO	0,13495	0,13451	0,13194	0,13352	0,13347	0,13506
		σ	0,00675	0,00611	0,00494	0,00529	0,00508	0,00491
	90	FO	0,13423	0,13482	0,13416	0,13352	0,13491	0,13536
		σ	0,00509	0,00534	0,00523	0,00534	0,00533	0,00501

Fonte: Elaborado pelo autor

Ao analisarmos a Figura 97, verifica-se que as faixas com taxas de cruzamento elevadas como 75 e 90%, além de possuírem os melhores resultados, encontram-se próximas, sugerindo que um refinamento poderia apurar esse parâmetro se a faixa fosse fragmentada em valores intermediários. Ao se observar a mutação, sugere-se que os valores elevados estariam produzindo uma possível perda de diversidade, pois valores menores também apresentam regiões de viabilidade.

Figura 97: Evolução do experimento com AG no Formato 3 com 1000 usuários



Fonte: Elaborado pelo autor

A Tabela 73 apresenta o comportamento da Busca Tabu por meio de parâmetros de valores elevados, indicando o quadrante 4 como concentrador das melhores soluções, causados por uma estrutura de vizinhança possivelmente desfavorecida.


Tabela 73: Experimento com Busca Tabu no Formato 3 com 1000 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,12096	0,11893	0,12552	0,13056	0,12837	0,12943
		σ	0,00385	0,00419	0,00558	0,00639	0,00496	0,00597
	25	FO	0,1169	0,12744	0,13045	0,13113	0,13468	0,13453
		σ	0,00211	0,00339	0,00273	0,00381	0,00545	0,0052
	50	FO	0,12449	0,12765	0,12865	0,13418	0,13695	0,13676
		σ	0,00299	0,00323	0,00537	0,00615	0,00565	0,00594
	75	FO	0,12808	0,12361	0,12604	0,12851	0,13787	0,13838
		σ	0,00438	0,00384	0,00151	0,00226	0,00494	0,00505
	100	FO	0,12401	0,12569	0,12665	0,12909	0,1371	0,13855
		σ	0,00225	0,0034	0,00608	0,00187	0,0035	0,0049
	200	FO	0,12503	0,12198	0,11998	0,11974	0,13887	0,13901
		σ	0,00205	0,0025	0,00113	0,00495	0,00402	0,00397

Fonte: Elaborado pelo autor

Por meio da observação da Figura 98, constata-se que o aumento da diversificação, sobretudo no caso com NBmax 200 e Lista Tabu 100, gera-se um aumento significativo a partir desse ponto, demonstrando que o processo de intensificação é melhor conduzido quando aliado a larga diversificação.

Figura 98: Evolução do experimento com BT no Formato 3 com 1000 usuários



Fonte: Elaborado pelo autor

Nos resultados do Algoritmo Memético apresentados na estreita faixa da Tabela 74, constata-se que a Busca Tabu poderia ter elevado seu valor de diversificação e/ou o tamanho de sua vizinhança, conduzindo a investigação sobre um conjunto de soluções mais amplo.


Tabela 74: Experimento com Algoritmo Memético no Formato 3 com 1000 usuários

Taxa de Mutação			Taxa de Cruzamento			Lista Tabu								
						75			100			200		
						NBMax								
						75	100	200	75	100	200	75	100	200
50	50	FO	0,13749	0,16923	0,16418	0,16125	0,16124	0,169	0,15442	0,19113	0,16569			
		σ	0,0018	0,00443	0,004	0,00165	0,00281	0,00385	0,0016	0,00341	0,00351			
	75	FO	0,13673	0,16728	0,16235	0,16246	0,16215	0,16884	0,15421	0,19024	0,1654			
		σ	0,00173	0,00447	0,00382	0,00157	0,00271	0,00391	0,00173	0,00363	0,00385			
	90	FO	0,13747	0,1657	0,16375	0,16464	0,16179	0,17098	0,15601	0,19111	0,16727			
		σ	0,00175	0,00452	0,00348	0,0016	0,00254	0,00374	0,00158	0,00328	0,00358			
	50	FO	0,13871	0,16998	0,16449	0,16054	0,16066	0,1677	0,15518	0,19295	0,1653			
		σ	0,00168	0,00416	0,00396	0,00165	0,00284	0,00395	0,00168	0,00317	0,0035			
	75	FO	0,1379	0,1669	0,16105	0,16243	0,16249	0,16921	0,15498	0,19001	0,16387			
		σ	0,00182	0,00436	0,00416	0,00167	0,00282	0,004	0,00177	0,00353	0,00377			
	90	FO	0,13849	0,16468	0,16301	0,1659	0,16174	0,1723	0,15701	0,19084	0,16766			
		σ	0,00189	0,00469	0,00355	0,00151	0,00247	0,00362	0,00157	0,00336	0,00353			
	75	50	FO	0,13905	0,17142	0,16284	0,15934	0,15978	0,16722	0,15605	0,1915	0,16439		
			σ	0,00183	0,00396	0,00397	0,0015	0,00266	0,00386	0,00182	0,00297	0,00383		
		75	FO	0,13864	0,16828	0,15967	0,16204	0,16189	0,16772	0,15592	0,19168	0,16449		
			σ	0,00187	0,00469	0,00415	0,00152	0,0027	0,00406	0,00188	0,00371	0,00404		
		90	FO	0,13719	0,16487	0,16326	0,16745	0,16192	0,17102	0,15784	0,19056	0,16925		
			σ	0,00188	0,00459	0,00351	0,00156	0,00255	0,00329	0,00159	0,0033	0,00346		

Fonte: Elaborado pelo autor

Na comparação das melhores soluções de cada uma das técnicas, a Figura 99 demonstra a qualidade do Algoritmo Memético em relação aos resultados obtidos pelas demais metaheurísticas, ilustrando a qualidade de sua solução na união da Busca Tabu com o Algoritmo Genético.

Figura 99: Comparativo entre as soluções das MH no Formato 3 com 1000 usuários



Fonte: Elaborado pelo autor

6.4.4.4 Programa teste no Formato 4 em Larga Escala

Nota-se pelos quadrantes 3 e 4 da Tabela 75 que os melhores resultados do Algoritmo Genético são obtidos por meio de taxas de cruzamento elevadas, incidindo na qualidade das soluções, já a diversidade encontra-se nos valores laterais da faixa de valores avaliada.


Tabela 75: Experimento com Algoritmo Genético no Formato 4 com 1000 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12258	0,12128	0,1246	0,12324	0,12396	0,12319
		σ	0,00496	0,00532	0,00781	0,00642	0,00714	0,0061
	10	FO	0,12516	0,12616	0,12662	0,1263	0,12367	0,12388
		σ	0,00667	0,0057	0,00564	0,00654	0,00422	0,00553
	25	FO	0,12878	0,12876	0,13077	0,12954	0,132	0,12977
		σ	0,00552	0,0064	0,00573	0,00542	0,00593	0,00576
	50	FO	0,13313	0,13137	0,13275	0,13046	0,13286	0,13119
		σ	0,00556	0,00563	0,00529	0,00582	0,0059	0,00646
	75	FO	0,13189	0,13295	0,13154	0,13278	0,13299	0,13353
		σ	0,00403	0,00539	0,00531	0,00585	0,00526	0,00563
	90	FO	0,13386	0,13362	0,13252	0,13268	0,13517	0,13475
		σ	0,00512	0,00488	0,00537	0,00566	0,00487	0,00489

Fonte: Elaborado pelo autor

Na Figura 100, pode-se verificar novamente que o aumento da intensificação promove, de modo geral, a melhora dos resultados obtidos. Além disso, observa-se que baixas taxas de mutação obtiveram soluções de boa qualidade, como é o caso de 5 e 10%, o que indica uma população com genética favorável, em contrapartida das taxas elevadas onde são inseridas mais estruturas aleatórias.

Figura 100: Evolução do experimento com AG no Formato 4 com 1000 usuários



Fonte: Elaborado pelo autor

No experimento observado na Tabela 76, as soluções de qualidade estão concentradas no quadrante 4, repetindo o comportamento que vem ocorrendo nas demais experimentações, de que a elevação dos parâmetros, bem como do tamanho da vizinhança auxiliaria o processo de busca local.


Tabela 76: Experimento com Busca Tabu no Formato 4 com 1000 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,11712	0,11813	0,12674	0,1298	0,13033	0,13226
		σ	0,00342	0,00389	0,00611	0,00594	0,0058	0,00587
	25	FO	0,11918	0,1188	0,1273	0,12831	0,13384	0,13494
		σ	0,00269	0,00265	0,00291	0,00578	0,00614	0,0053
	50	FO	0,12266	0,12432	0,11632	0,12526	0,13707	0,13689
		σ	0,00243	0,00352	0,00479	0,00233	0,00452	0,00622
	75	FO	0,11712	0,11728	0,123	0,12967	0,13746	0,13668
		σ	0,00318	0,00374	0,00175	0,0062	0,00445	0,00498
	100	FO	0,12017	0,11823	0,12872	0,12491	0,13835	0,13722
		σ	0,00337	0,00343	0,00153	0,00598	0,00474	0,00413
	200	FO	0,11915	0,12934	0,13341	0,13239	0,13717	0,13905
		σ	0,00094	0,00177	0,00153	0,00626	0,00384	0,00354

Fonte: Elaborado pelo autor

Ao se ver a Figura 101, é notória a interação entre o NBmax e a Lista Tabu, em que o NBmax de tamanho 200 com Lista Tabu pequena apresenta um crescimento maior, que só se demonstra nos demais valores de NBmax durante o aumento do tamanho da Lista Tabu.

Figura 101: Evolução do experimento com BT no Formato 4 com 1000 usuários



Fonte: Elaborado pelo autor

Observando-se na Tabela 77 o experimento com o Algoritmo Memético, vê-se a presença da Busca Tabu em duas faixas de diversificação, diferentemente de como vem se configurando durante grande parte dos outros experimentos, indicando diferentes níveis de diversificação. Vendo-se o papel da busca global, representada pelo Algoritmo Genético, crê-se que existe uma carga genética relevante, em parte introduzida pelas elevadas taxas de cruzamento, em parte pelo processo de diversificação.


Tabela 77: Experimento com Algoritmo Memético no Formato 4 com 1000 usuários

Taxa de Mutação			Taxa de Cruzamento		Lista Tabu								
					75			100			200		
					NBMax								
					75	100	200	75	100	200	75	100	200
					75	100	200	75	100	200	75	100	200
75	50	FO	0,13754	0,17428	0,14808	0,1502	0,14282	0,16625	0,16151	0,17286	0,14912		
		σ	0,00585	0,00408	0,00457	0,00143	0,00422	0,00327	0,00119	0,00313	0,00269		
	75	FO	0,13937	0,175	0,15005	0,14807	0,14366	0,16826	0,16104	0,17393	0,15001		
		σ	0,00608	0,00445	0,00477	0,00134	0,00387	0,00307	0,00108	0,00337	0,00246		
	90	FO	0,13758	0,17493	0,15071	0,14597	0,14178	0,16986	0,16138	0,17581	0,14857		
		σ	0,00548	0,00404	0,00511	0,00137	0,00413	0,00323	0,00105	0,00323	0,00256		
	50	FO	0,13713	0,17526	0,14944	0,15073	0,14173	0,16695	0,16165	0,17389	0,14939		
		σ	0,00565	0,00414	0,00494	0,00147	0,00439	0,00298	0,00119	0,0034	0,00248		
	75	FO	0,1405	0,17445	0,15113	0,14752	0,14391	0,16887	0,16118	0,17466	0,15084		
		σ	0,00631	0,00431	0,0045	0,00143	0,00406	0,00327	0,00101	0,00323	0,00266		
	90	FO	0,13663	0,17647	0,15092	0,14654	0,14198	0,16996	0,16081	0,17428	0,14906		
		σ	0,00571	0,00378	0,00477	0,00135	0,00446	0,00347	0,00115	0,00346	0,00254		
	90	50	FO	0,13645	0,17608	0,14923	0,15147	0,14154	0,16558	0,16154	0,17217	0,14988	
			σ	0,00585	0,00444	0,00471	0,00148	0,00427	0,00307	0,00108	0,00319	0,00264	
		75	FO	0,14056	0,17447	0,15198	0,14783	0,1426	0,16973	0,16046	0,17424	0,14981	
			σ	0,00573	0,00464	0,00451	0,00132	0,00379	0,00317	0,00104	0,00324	0,00287	
		90	FO	0,1378	0,17752	0,15109	0,14759	0,14145	0,1716	0,16102	0,17562	0,14824	
			σ	0,0053	0,00413	0,00503	0,00133	0,00454	0,00346	0,00117	0,00353	0,00261	

Fonte: Elaborado pelo autor

A qualidade do Algoritmo Memético pode ser vista na Figura 102, em que, pela comparação entre as melhores soluções obtidas pelas metaheurísticas, o AM configura-se qualitativamente por sua elevada FO.

Figura 102: Comparativo entre as soluções das MH no Formato 4 com 1000 usuários



Fonte: Elaborado pelo autor

6.4.4.5 Programa teste no Formato 5 em Larga Escala

Ao longo dos experimentos realizados com o Formato 5 verificou-se que as melhores soluções do Algoritmo Genético sempre são encontradas nos quadrantes 3 e 4, como se vê na Tabela 63. A melhor solução consecutivamente é encontrada no 3º quadrante, reforçando a suposição de que as baixas taxas de mutação se dão devido ao reduzido espaço de diversificação que o Formato 5 provê, ou seja, uma mochila pequena, com apenas 4 colunas.


Tabela 78: Experimento com Algoritmo Genético no Formato 5 com 1000 usuários

			Taxa de Mutação					
			5	10	25	50	75	90
Taxa de Cruzamento	5	FO	0,12441	0,12355	0,1226	0,12261	0,12515	0,12042
		σ	0,00601	0,00627	0,0051	0,00566	0,0063	0,0041
	10	FO	0,12351	0,12793	0,12348	0,12687	0,12425	0,12711
		σ	0,00496	0,00609	0,00457	0,00592	0,00473	0,00663
	25	FO	0,12959	0,12979	0,12876	0,12951	0,13104	0,13037
		σ	0,00612	0,00648	0,00475	0,00574	0,00598	0,005
	50	FO	0,13127	0,13353	0,13134	0,13186	0,13136	0,1333
		σ	0,00508	0,00637	0,00529	0,00624	0,00529	0,00538
	75	FO	0,13444	0,13344	0,13466	0,13197	0,13191	0,13385
		σ	0,00564	0,00594	0,00579	0,00534	0,00588	0,00491
	90	FO	0,1334	0,1359	0,13549	0,13453	0,13403	0,13384
		σ	0,00447	0,00587	0,00534	0,0049	0,00565	0,00556

Fonte: Elaborado pelo autor

Ao se observar a Figura 103, tal suposição é elucidada, visto que com o aumento das taxas de mutação com elevada intensificação tem-se decaimento da qualidade das soluções.

Figura 103: Evolução do experimento com AG no Formato 5 com 1000 usuários



Fonte: Elaborado pelo autor

Na Tabela 79, observa-se a tendência já estabelecida, de agrupamento das soluções de maior qualidade no quadrante 4. Neste caso, com base na melhor solução, indicando que uma maior intensificação propende a melhores resultados, com o implicador da elevação do tempo de busca.


Tabela 79: Experimento com Busca Tabu no Formato 5 com 1000 usuários

			Lista Tabu					
			10	25	50	75	100	200
NBmax	10	FO	0,12215	0,12826	0,13538	0,13201	0,13125	0,13088
		σ	0,00368	0,00477	0,00434	0,00545	0,00079	0,00635
	25	FO	0,11811	0,12693	0,13152	0,12724	0,13592	0,13394
		σ	0,00299	0,00421	0,00254	0,00299	0,00596	0,00628
	50	FO	0,11926	0,11928	0,13131	0,13233	0,13719	0,13631
		σ	0,00303	0,00284	0,00626	0,00619	0,006	0,00483
	75	FO	0,11906	0,12097	0,13008	0,13029	0,13646	0,13743
		σ	0,00243	0,00391	0,00196	0,00638	0,00566	0,00408
	100	FO	0,1191	0,13029	0,11716	0,14047	0,13877	0,13754
		σ	0,0022	0,0042	0,0012	0,0065	0,00419	0,00473
	200	FO	0,1191	0,11653	0,12113	0,13843	0,13958	0,13965
		σ	0,00275	0,00268	0,00487	0,00659	0,00371	0,00374

Fonte: Elaborado pelo autor

Vê-se, na Figura 104, uma disposição do aumento de valores das soluções, principalmente durante o processo de elevada intensificação, em que se configura um tangenciamento da convergência.

Figura 104: Evolução do experimento com BT no Formato 5 com 1000 usuários



Fonte: Elaborado pelo autor

Nesse experimento, apresentado na Tabela 80, verifica-se que, além da faixa definida pelos parâmetros da Busca Tabu, o Algoritmo Genético desenvolve-se na área central, demonstrando especialmente elevados níveis de intensificação com baixa diversificação.


Tabela 80: Experimento com Algoritmo Memético no Formato 5 com 1000 usuários

Taxa de Mutação			5		Taxa de Cruzamento		10		25		Lista Tabu								
											75			100			200		
											NBMax								
											75	100	200	75	100	200	75	100	200
50	FO	0,15784	0,155	0,15235	0,12467	0,14307	0,13601	0,11802	0,18371	0,1662									
	σ	0,00504	0,00447	0,00341	0,00581	0,00327	0,00419	0,00549	0,00345	0,00301									
75	FO	0,1559	0,15632	0,15187	0,12319	0,14471	0,13485	0,11653	0,183	0,16497									
	σ	0,00467	0,00425	0,00342	0,00561	0,00323	0,00389	0,00578	0,00339	0,00324									
90	FO	0,15808	0,15863	0,15282	0,12266	0,14403	0,1364	0,11556	0,18462	0,16499									
	σ	0,00505	0,00409	0,00361	0,00536	0,00316	0,00355	0,00627	0,00344	0,00323									
50	FO	0,15822	0,15573	0,15101	0,12543	0,14384	0,13472	0,11764	0,18344	0,1675									
	σ	0,00512	0,00441	0,00308	0,00636	0,0032	0,00397	0,00509	0,00361	0,00283									
75	FO	0,15484	0,15713	0,15179	0,12246	0,14552	0,13619	0,11767	0,18287	0,16481									
	σ	0,00484	0,00386	0,00346	0,00526	0,00304	0,0037	0,00615	0,00361	0,00314									
90	FO	0,15887	0,15722	0,15236	0,12353	0,14279	0,13629	0,11613	0,1849	0,1635									
	σ	0,0055	0,00383	0,00397	0,00503	0,00306	0,00364	0,00664	0,00377	0,00352									
50	FO	0,15723	0,15539	0,15168	0,12553	0,14515	0,13398	0,11812	0,18278	0,1687									
	σ	0,00501	0,0048	0,00316	0,00699	0,00317	0,00425	0,00524	0,00353	0,00309									
75	FO	0,15477	0,15745	0,15038	0,12345	0,14682	0,135	0,11718	0,18382	0,16393									
	σ	0,0046	0,00424	0,00337	0,00572	0,00293	0,00386	0,00584	0,00381	0,00298									
90	FO	0,16041	0,15662	0,1538	0,1227	0,14175	0,13668	0,11547	0,18416	0,162									
	σ	0,00584	0,0039	0,00436	0,00477	0,00299	0,00342	0,00627	0,00342	0,00349									

Fonte: Elaborado pelo autor

Como se corroborou ao longo de todos os experimentos, na Figura 80, tem-se mais uma vez o Algoritmo Memético a frente da Busca Tabu e do Algoritmo Genético. Nesse caso, destacando-se pelo desvio padrão muito menor.

Figura 105: Comparativo entre as soluções das MH no Formato 5 com 1000 usuários



Fonte: Elaborado pelo autor

7 CONSIDERAÇÕES FINAIS

Como contribuições deste trabalho, tem-se a importância do desenvolvimento de um modelo computacional para geração de layout construído com base nos fundamentos de hipermídia, que viabiliza uma gama de aplicações capaz de abarcar novas e diversas possibilidades de adaptação nos mais diversos domínios. Outra contribuição interessante diz respeito aos avanços no estudo dos Algoritmos Meméticos e na determinação e análise de seus parâmetros de controle para a aplicação em questão. Não menos importante, satisfatoriamente, destacam-se no uso de SAN de aprendizagem com as metaheurísticas no papel do ambiente de interação constituição de uma nova possibilidade de investigação para a construção de soluções de qualidade com retenção de conhecimento.

Lembrando dos objetivos a que este trabalho se propôs, pode-se considerá-los alcançados, sendo que por meio da prova de conceito desenvolvida mostrou-se a efetividade do uso das metaheurísticas aliadas ao formalismo das redes de autômatos estocásticos no processo de geração de *layouts*. Sendo os objetivos atingidos, foi-se diretamente ao encontro da problematização exposta, auxiliando os processos de individualização do acesso à informação em atenção às singularidades do usuário que se fazem presentes na atualidade.

Este trabalho foi desenvolvido com o objetivo de estudar os processos de geração de *layouts* dentro do contexto da adaptação da hipermídia. Fundamentalmente, o trabalho visa criar uma estrutura para alocação de elementos hipermídia, que se apresenta como interface para atender a um conjunto de usuários e seus dispositivos. Devido à grande quantidade de características que podem ser incorporadas ao problema, podem-se encontrar na literatura diversas abordagens para sua resolução. Neste trabalho, foi desenvolvida uma modelagem com base no problema da mochila estocástica, que é constituída por fatores probabilísticos, em que se aliou o formalismo das redes de autômatos estocásticos para sua estruturação. Para a resolução do problema da mochila foi empregado, neste trabalho, o Algoritmo Memético, que utiliza Algoritmo Genético como representante da busca global e Busca Tabu no processo de busca local. Para atender a necessidade de geração de layout para aplicações, este trabalho desenvolveu um modelo construído, de forma modular em que se verificaram as possibilidades de flexibilidade na integração de outras tecnologias. Das formas de flexibilidade dos módulos podem-se destacar: a simples integração do Módulo de Serviço para atender novos tipos de clientes, a fácil modificação e inserção de bancos de dados e topologias de SAN no Módulo de Interação de Dados, a possibilidade de adição de metaheurísticas no Módulo de Geração e a inserção de novos perfis de linguagem no Módulo de Conversão, dentre as formas mais basilares, ainda pode-se criar abstrações que visem atender novas necessidades na geração de *layouts*.

Geralmente, a validação de problemas NP-Difícil é realizada, através da comparação dos resultados obtidos com os apresentados por outros autores. Na ausência de programas de testes na literatura, foi definido um modelo de programa teste, no qual um gerador forneceu os dados para alimentação do modelo. Esse gerador fornece instâncias com dados distribuídos

uniformemente dentro das faixas delimitadas pelos seus parâmetros de entrada, apresentando um comportamento normal, em observância ao teorema do Limite Central e a Lei dos Grandes Números. Desta forma, os experimentos, por apresentarem os resultados médios de 100 execuções, expressam-se dentro dos fatores de normalidade.

Foram desenvolvidos, durante a concepção do modelo, 5 formatos de grupos de dispositivos, contemplando parte das características da gama de dispositivos atualmente disponíveis. Com base nesses 5 formatos, definiu-se 4 tamanhos de programas de testes em micro escala (15 usuários), pequena escala (50 usuários), média escala (100 usuários) e larga escala (1000 usuários), para abranger grupos de usuários de baixa até alta diversidade.

Utilizando o modelo computacional desenvolvido, foram realizados diversos experimentos para que fosse possível mostrar a efetividade da modelagem matemática no contexto de geração de *layout*, corroborando a estrutura idealizada para o modelo. A experimentação teve como objetivo analisar os melhores resultados de cada técnica em relação às suas parametrizações, mostrando a robustez do modelo na geração de soluções de qualidade.

Por meio dos experimentos, foi possível estudar as implicações acarretadas pelo uso de cada um dos parâmetros das metaheurísticas sob as variáveis de decisão na constituição de soluções de qualidade. Sendo assim, os experimentos foram divididos em 3 etapas que tiveram como finalidade: 1ª etapa) analisar a relação dos operadores de cruzamento e mutação na qualidade dos resultados; 2ª etapa) analisar os melhores resultados com relação ao valor do NBmax e do tamanho da Lista Tabu; 3ª etapa) analisar a contribuição dos parâmetros do AG e da BT para o Algoritmo Memético proposto.

As 3 etapas de experimentos foram aplicadas em todos os programas de testes, em cada um dos 5 formatos definidos, nos 4 tamanhos testados, totalizando 60 experimentos. Na Tabela 81, pode-se ver a consolidação dos melhores resultados obtidos em cada experimento, confirmando a supremacia do Algoritmo Memético em relação ao Algoritmo Genético e a Busca Tabu. Essa tabela dá base para a construção da Tabela 82, em que são apresentados os percentuais de melhora do Algoritmo Memético em relação às técnicas em cada um dos formatos e dos tamanhos, também pode-se observar a consolidação das médias por formato e por tamanho, onde os programas de teste em formatos menores e com menos usuários apresentaram os maiores percentuais. Verificou-se, no geral, o Algoritmo Memético apresenta em relação ao Algoritmo Genético uma melhora de 40,148% da FO com uma redução do desvio padrão de 29,505%, já em relação à Busca Tabu apresentou um percentual de melhora de 36,282% da FO com desvio padrão 7,661% menor.

Durante o processo de análise dos experimentos, foram observados alguns comportamentos com relação aos parâmetros adotados e aos resultados por eles obtidos. Essa análise levou à consideração de algumas conjecturas sobre o comportamento dos parâmetros do Algoritmo Genético e da Busca Tabu, que, na maioria das vezes, se mostraram favoráveis na análise dos resultados. São elas:

Tabela 81: Consolidação dos experimentos

		Tamanho do programa teste											
		15			50			100			1000		
		AG	BT	AM	AG	BT	AM	AG	BT	AM	AG	BT	AM
Formato 1	FO	0,141669	0,143326	0,210877	0,137437	0,138444	0,175323	0,134143	0,135555	0,188901	0,135463	0,141322	0,181140
	σ	0,005316	0,004150	0,003661	0,006373	0,003623	0,004395	0,004644	0,004107	0,004228	0,005353	0,005471	0,002791
Formato 2	FO	0,131586	0,137215	0,198658	0,133983	0,140299	0,190895	0,136454	0,139741	0,188255	0,134897	0,139286	0,168158
	σ	0,004262	0,004451	0,003302	0,004624	0,003991	0,004682	0,005555	0,004428	0,004318	0,005194	0,004243	0,003204
Formato 3	FO	0,135345	0,139314	0,204347	0,133727	0,138109	0,189137	0,136199	0,139356	0,181360	0,135358	0,139009	0,192950
	σ	0,005851	0,002460	0,002793	0,004913	0,003613	0,002929	0,004512	0,003862	0,003572	0,005007	0,003970	0,003174
Formato 4	FO	0,141510	0,149267	0,205965	0,135964	0,135363	0,187394	0,135214	0,140117	0,205429	0,135169	0,139051	0,177524
	σ	0,005295	0,002591	0,003599	0,004805	0,003138	0,002799	0,005969	0,003844	0,003337	0,004866	0,003535	0,004135
Formato 5	FO	0,137593	0,142947	0,198554	0,136241	0,139879	0,189520	0,135355	0,138286	0,191659	0,135904	0,140473	0,184901
	σ	0,005109	0,003114	0,004537	0,004974	0,004008	0,003833	0,004285	0,004205	0,003393	0,005867	0,005657	0,003768

Fonte: Elaborado pelo autor

Tabela 82: Porcentagens de melhora do AM em relação ao AG e a BT

		Tamanhos								Média / tamanho	
		15		50		100		1000		AM-AG	AM-BT
		AM-AG	AM-BT	AM-AG	AM-BT	AM-AG	AM-BT	AM-AG	AM-BT		
Formato 1	FO	48,851	47,131	27,566	26,638	40,820	39,354	33,720	28,175	37,739	35,325
	σ	-31,142	-11,790	-31,042	21,313	-8,959	2,934	-47,860	-48,990	-29,751	-9,133
Formato 2	FO	50,972	44,779	42,478	36,064	37,962	34,717	24,657	20,729	39,017	34,072
	σ	-22,542	-25,826	1,249	17,309	-22,266	-2,485	-38,303	-24,482	-20,465	-8,871
Formato 3	FO	50,982	46,681	41,435	36,947	33,157	30,141	42,548	38,804	42,031	38,143
	σ	-52,256	13,562	-40,375	-18,918	-20,823	-7,495	-36,607	-20,050	-37,515	-8,225
Formato 4	FO	45,547	37,984	37,826	38,438	51,929	46,612	31,335	27,668	41,659	37,676
	σ	-32,033	38,893	-41,758	-10,819	-44,096	-13,187	-15,026	16,954	-33,228	7,960
Formato 5	FO	44,305	38,901	39,106	35,489	41,597	38,596	36,052	31,627	40,265	36,153
	σ	-11,197	45,712	-22,950	-4,388	-20,817	-19,294	-35,765	-33,383	-22,682	-2,838
Média / formato	FO	48,132	43,095	37,682	34,715	41,093	37,884	33,662	29,401		
	σ	-29,834	12,110	-26,975	0,899	-23,392	-7,906	-34,712	-21,990		

Fonte: Elaborado pelo autor

- **Tamanho da população:** a utilização do Algoritmo Genético com população de tamanho igual a 100 mostra-se desfavorável em espaços de busca grandes, como no caso do Formato 1. Essa observação foi realizada com base na obtenção de soluções de maior qualidade durante o uso de taxas de mutação elevadas, indicando que o aumento da população pode cobrir melhor o espaço de busca, não dependendo tanto do processo de diversificação. Em suma, a diversidade será um elemento da população e não um mecanismo que opera sobre ela inserindo informações com o intuito de modificá-la, levando a novas regiões do espaço de soluções.
- **Taxa de mutação:** com base na observação anterior, constatou-se que formatos menores – como o Formato 5 – por possuírem uma área menor de *layout*, e, consequentemente, menor espaço de diversificação, lidam mais adequadamente com taxas de mutação menores. Em suma, quanto menor o formato, menor a taxa de mutação e quanto maior o formato maior a taxa de mutação;
- **Taxa de cruzamento:** pôde-se verificar durante os experimentos que as melhores soluções encontradas no processo de intensificação estão ligadas a altas taxas de cruzamento, indicando que a população, mesmo pequena, contém material genético diverso;

- **Tamanho da vizinhança:** a Busca Tabu com vizinhança de tamanho 100, assim como o tamanho da população do AG, apresenta-se desapropriada, pois se verificou que a maioria das melhores soluções está sempre ligada à Lista Tabu de tamanhos grandes, indicando uma forte dependência do processo de diversificação. Cabe lembrar que o aumento no tamanho da vizinhança acarreta na elevação do consumo de recursos computacionais, aumentando o processamento;
- **Lista Tabu:** fundamentado sob a necessidade de uma vizinhança maior, a Lista Tabu apresentou as melhores soluções durante o uso de alta diversificação, a fim de suprir a demanda de maior cobertura do espaço de busca. Como consequência do aumento do tamanho da Lista Tabu, tem-se um consumo maior de memória para armazenamento dos movimentos tabus. Dessa forma, constata-se a necessidade de um aprofundamento sobre a relação do tamanho da vizinhança e da Lista Tabu, para que se possa distribuir o papel da diversificação sob esses dois mecanismos, sem acarretar na elevação do consumo de apenas um recurso computacional, seja do processador ou da memória;
- **NBmax:** o fato de a Busca Tabu ter encontrado as melhores soluções nos limites dos parâmetros experimentados indica que se está buscando soluções em um espaço de busca grande. Na maior parte dos casos, verificou-se que a busca é estendida até o limite, sugerindo que as regiões buscadas não são adequadamente exploradas por falta de tempo. Ao se elevar o valor do NBmax, permite-se que a busca se prolongue por um período maior de tempo. Esse parâmetro pode ser melhor moldado – encontrando um equilíbrio – se forem adequados os tamanhos da vizinhança e da Lista Tabu, reduzindo o tamanho das regiões buscadas e aumentando a quantidade de regiões.

Ao observar-se o comportamento desempenhado pelo Algoritmo Memético durante os experimentos, constatou-se que a tendência dos parâmetros acima mencionada, em parte, se repete. Em outros momentos, verificou-se que o déficit populacional acaba sendo absorvido pelo processo de evolução cultural, demonstrando que o aumento da população memética supre as necessidades de população e vizinhança maiores. Em contrapartida, a elevação no número de memes acarreta em maior consumo de tempo e de recursos computacionais.

Como as técnicas que compõe o Algoritmo Memético podem ser utilizadas tanto para fins de intensificação como de diversificação, não se pode afirmar categoricamente qual seu processo de dominância. No entanto, há indicadores de que a intensificação seja realizada pela Busca Tabu e a intensificação pelo Algoritmo Genético.

Assim, conclui-se que o Algoritmo Memético é habilmente empregável na resolução do problema de geração de *layout* sob a modelagem da mochila estocástica. Ao mesmo tempo, faz considerar que seu uso em um ambiente real demande um refinamento dos parâmetros em prol da minimização do uso de recursos computacionais. Além de comprovar a qualidade da técnica, pode-se considerar que o modelo desenvolvido é capaz de gerar *layouts* de aplicações com base em características probabilísticas, corroborando o propósito deste trabalho na facilitação dos

processos de desenvolvimento de interfaces, bem como atendendo as demandas de atenção individualizada dos usuários.

Como trabalhos futuros, inúmeras ideias despontam. Como o desenvolvimento e a demonstração de maiores potencialidades do modelo de geração de *layout* pela inserção de mais regras de adaptação e um conjunto maior de elementos hipermídia. Sugere-se o refinamento e a expansão dos estudos sobre algoritmos meméticos, tendo em vista as potencialidades verificadas com o seu emprego neste trabalho. O aprofundamento dos processos de retenção de conhecimento com o uso de estruturas de SAN como memória externa, estabelecendo um ambiente probabilístico de aprendizado baseado em metaheurísticas.

REFERÊNCIAS

- ADDEDBYTES. **Regular Expressions Cheat Sheet (V2)**. 2013. Disponível em: <<https://www.addedbytes.com/cheat-sheets/regular-expressions-cheat-sheet/>>. Acesso em: 07 de Novembro de 2013.
- ALMEIDA, M.; BARRETO, J. Implementação de um sistema hipermídia como autômato para ensino de inteligência artificial. **I Simpósio Catarinense de Computação**, 2000b.
- ALMEIDA, M. A. F. **Aprender, atividade inteligente: e se esta inteligência for parcialmente artificial?** Dissertação (Mestrado) — Universidade Federal de Santa Catarina, Florianópolis, Setembro 1999a.
- ALMEIDA, M. A. F.; BARRETO, J. M. Formação continuada por simulação em ambiente virtual usando redes de computadores. **Pesquisa Naval - Suplemento Especial da Revista Marítima Brasileira**, Rio de Janeiro, n. 12, p. 271–287, Outubro 1999b. ISSN 1414-8595.
- ALMEIDA, M. A. F.; BARRETO, J. M. Modelagem de um sistema hipermídia como autômato para ensino de inteligência artificial. In: **Anais do Congresso Nacional da Sociedade Brasileira de Computação SBC 2000-VI WIE-Workshop de Informática na Escola**. [S.l.: s.n.], 2000a. v. 1, p. 95.
- ALMEIDA, M. A. F.; M., B. J. Apoio ao ensino de redes neurais artificiais via computador. In: UNIVERSIDADE DE FAVALORO. **XXII Congreso Argentino de Bioingeniería - SABI99**. Buenos Aires, Argentina, 1999c. p. CD-ROM(101/3).
- ALMEIDA, M. A. F.; M., B. J.; SANTOS, M. M. D. Um ambiente computacional para ensino de redes neurais artificiais. In: PUC-RS. **51a Reunião Anual da SBPC**. Porto Alegre - RS, 1999d.
- ALMEIDA, M. A. F. et al. Aprendizado cooperativo utilizando construtivismo e redes de computadores no ensino a distância. In: PUC-RS. **51a Reunião Anual da SBPC**. Porto Alegre - RS, 1999e.
- AMARAL, M. A. **Modelo RHA - Retroalimentação em Hipermídia Adaptativa**. Tese (Doutorado) — Universidade Federal de Santa Catarina (UFSC), 2008. Disponível em: <<http://btd.egc.ufsc.br/wp-content/uploads/2010/06/Mar\\%C3\\%ADlia-A.-Amaral.pdf>>. Acesso em: 5 de Dezembro de 2012.
- AQUINO, M. C. **O Hipertexto como Potencializador da Memória Coletiva: Um estudo dos Links na Web 2.0**. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Sul (UFRGS), 2007. Disponível em: <<http://hdl.handle.net/10183/12761>>. Acesso em: 5 de Dezembro de 2012.
- ARDOT, J.; PUJOLLE, G.; TESTE, A. Une interface relationnelle de type hypertexte. **INFORSDID'89**, p. 223–244, maio 1989.
- ATKINSON, R.; BOWER, G.; CROTHERS, E. **An introduction to mathematical learning theory**. [S.l.]: Wiley, 1965.
- AULETE, C. **Dicionário Eletrônico Aulete Digital**. 2013. Disponível em: <<http://aulete.uol.com.br>>. Acesso em: 05 de Maio de 2013.

AURÉLIO, M.; VELLASCO, M.; LOPES, C. H. **Descoberta de Conhecimento e Mineração de Dados**. [S.l.], 1999. Disponível em: <<http://www.valdick.com/files/Apostila\\%20de\\%20DataMining.pdf>>. Acesso em: 25 de Maio de 2013.

BAECK, T.; FOGEL, D.; MICHALEWICZ, Z. **Evolutionary Computation 2: Advanced Algorithms and Operators**. [S.l.]: Taylor & Francis, 2000. (Evolutionary computation). ISBN 9780750306652.

BALASUBRAMANIAN, V. **State of the Art Review on Hypermedia Issues and Applications**. 1994. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.36.2631&rep=rep1&type=pdf>>. Acesso em: 7 de Fevereiro de 2013.

BARRETO, J. M. Inteligência artificial no limiar do século xxi. **Florianópolis: PPP edições**, v. 97, 1999.

BECKER, A. L. **Ferramenta para Construção de Interfaces de Software a Partir de Diagrama de Classes**. [S.l.], 2009.

BERNERS-LEE, T. **Tim Berners-Lee**. 1990. Disponível em: <<http://www.w3.org/History/1989/proposal.html>>. Acesso em: 15 de Fevereiro de 2013.

BERNSTEIN, J. **Project Swarm**. 2013. Disponível em: <<http://www.projectswarm.net>>. Acesso em: 06 de Maio de 2013.

BLUM, C.; ROLI, A. Metaheuristics in combinatorial optimization: Overview and conceptual comparison. **ACM COMPUTING SURVEYS**, p. 268–308, 2003. Disponível em: <[http://www.inf.ucv.cl/\\$sim\\$b Crawford/MII-748/Metaheuristics_Overview_Blum.pdf](http://www.inf.ucv.cl/simb Crawford/MII-748/Metaheuristics_Overview_Blum.pdf)>. Acesso em: 4 de Abril de 2013.

BOONE, J. **A Survey of Data Models for Hypermedia**. Chapel Hill, NC, EUA, 1992. Disponível em: <<http://www.cs.unc.edu/techreports/92-021.pdf>>. Acesso em: 4 de Fevereiro de 2013.

BOTTERWECK, G. A model-driven approach to the engineering of multiple user interfaces. In: **Proceedings of the 2006 international conference on Models in software engineering**. Berlin, Heidelberg: Springer-Verlag, 2006. (MoDELS'06), p. 106–115. ISBN 978-3-540-69488-5. Disponível em: <<http://dl.acm.org/citation.cfm?id=1762828.1762847>>.

BRENNER, L. Agregação de redes de autômatos estocásticos. **Escola Regional de Redes**, Janeiro 2004. Disponível em: <http://www.inf.pucrs.br/peg/pub/thesis/IBrenner_m.pdf>. Acesso em: 24 de Abril de 2013.

BRENNER, L.; FERNANDES, P.; ALEGRETTI, C. G. P. **Redes de Autômatos Estocásticos: Um formalismo para avaliação de desempenho e confiabilidade de sistemas**. Porto Alegre, RS, Brasil, 2002. Disponível em: <<http://www3.pucrs.br/pucrs/files/uni/poa/facin/pos/relatoriostec/tr025.pdf>>. Acesso em: 16 de Abril de 2013.

BRENNER, L.; FERNANDES, P.; SALES, A. The need for and the advantages of generalized tensor algebra for kronecker structured representations. **International Journal of Simulation: Systems, Science & Technology**, Nottingham, v. 6, n. 3-4, p. 52–60, Fevereiro 2005. Disponível em: <<http://www.lsis.org/brennerl/data/BFS05.pdf>>. Acesso em: 15 de Junho de 2013.

BROWN, P. J. Turning ideas into products: the guide system. In: **Proceedings of the ACM conference on Hypertext**. New York, NY, EUA: ACM, 1987. (HYPERTEXT '87), p. 33–40. ISBN 0-89791-340-X. Disponível em: <<http://doi.acm.org/10.1145/317426.317430>>.

BROWNLEE, J. **Clever Algorithms: Nature-inspired Programming Recipes**. Lulu Enterprises Incorporated, 2011. ISBN 9781446785065. Disponível em: <<http://www.lulu.com/shop/jason-brownlee/clever-algorithms-nature-inspired-programming-recipes/ebook/product-20200704.html>>. Acesso em: 2 de Abril de 2013.

BRUSILOVSKY, P. Adaptive hypermedia: An attempt to analyze and generalize. In: BRUSILOVSKY, P.; KOMMERS, P.; STREITZ, N. (Ed.). **Multimedia, Hypermedia, and Virtual Reality Models, Systems, and Applications**. Springer Berlin Heidelberg, 1996a, (Lecture Notes in Computer Science, v. 1077). p. 288–304. ISBN 978-3-540-61282-7. Disponível em: <[http://www.sis.pitt.edu/\\$\sim\\$peterb/papers/MHVR96.pdf](http://www.sis.pitt.edu/$\sim$peterb/papers/MHVR96.pdf)>. Acesso em: 08 de Setembro de 2012.

BRUSILOVSKY, P. Methods and techniques of adaptive hypermedia. **User Modeling and User-Adapted Interaction**, Kluwer Academic Publishers, v. 6, n. 2-3, p. 87–129, 1996b. ISSN 0924-1868. Disponível em: <<http://dx.doi.org/10.1007/BF00143964>>. Acesso em: 03 de Setembro de 2012.

BRUSILOVSKY, P. Adaptive educational systems on the world-wide-web: A review of available technologies. In: 4TH INTERNATIONAL CONFERENCE ON INTELLIGENT TUTORING SYSTEMS (ITS'98). **Workshop "WWW-Based Tutoring**. 1998. p. 291–300. Disponível em: <[http://www1.cs.columbia.edu/\\$\sim\\$locasto/projects/web-education/papers/brusilovsky98adaptive.pdf](http://www1.cs.columbia.edu/$\sim$locasto/projects/web-education/papers/brusilovsky98adaptive.pdf)>. Acesso em: 06 de Junho de 2013.

BRUSILOVSKY, P. Adaptive hypermedia. **User Modeling and User-Adapted Interaction**, Kluwer Academic Publishers, Hingham, MA, EUA, v. 11, n. 1-2, p. 87–110, Março 2001. ISSN 0924-1868. Disponível em: <<http://dx.doi.org/10.1023/A:1011143116306>>. Acesso em: 03 de Setembro de 2012.

BRUSILOVSKY, P. Adaptive navigation support: From adaptive hypermedia to the adaptive web and beyond. **PsychNology Journal**, v. 2, p. 7–23, 2004. Disponível em: <<http://www.compassproject.net/Sadhana/teaching/readings/brusilovskyhypertext.pdf>>. Acesso em: 06 de Junho de 2013.

BUGAY, E. L. **O MODELO AHAM - MI: Modelo de Hipermedia Adaptativa utilizando Inteligências Múltiplas**. 2006. Disponível em: <<http://repositorio.ufsc.br/xmlui/bitstream/handle/123456789/88215/225285.pdf>>. Acesso em: 17 de Outubro de 2012.

BUGAY, E. L.; ULBRICHT, V. R. **Hipermedia**. 1. ed. [S.l.]: Visual Books, 2000. ISBN 9788575020029.

BURKE, P. **Uma História Social do Conhecimento 1: De Gutenberg a Diderot**. [S.l.]: Zahar, 2004. ISBN 9788537808771.

BUSH, R.; MOSTELLER, F. **Stochastic models for learning**. [S.l.]: Wiley, 1955. (Wiley publications in statistics).

BUSH, V. **As We May Think**. 1945. Disponível em: <<http://www.theatlantic.com/magazine/archive/1945/07/as-we-may-think/303881/>>. Acesso em: 15 de Fevereiro de 2013.

CALVARY, G. et al. A unifying reference framework for multi-target user interfaces. **INTERACTING WITH COMPUTERS**, v. 15, p. 289–308, 2003.

CAMPBELL, B.; GOODMAN, J. M. Ham: a general-purpose hypertext abstract machine. In: **Proceedings of the ACM conference on Hypertext**. New York, NY, EUA: ACM, 1987. (HYPERTEXT '87), p. 21–32. ISBN 0-89791-340-X. Disponível em: <<http://www.adammikeal.com/courses/ht/files/readings/feb9-campbell.pdf>>. Acesso em: 3 de Fevereiro de 2013.

CARDOSO, F. A. C. M. **Algoritmos Genéticos para Interpolação Não-Linear de Imagem e Decodificação de Códigos Lineares**. Dissertação (Mestrado) — Universidade Estadual de Campinas (Unicamp), 1998. Disponível em: <[http://www.decom.fee.unicamp.br/\\$\sim\\$cardoso/dissertacao\\%20de\\%20mestrado.pdf](http://www.decom.fee.unicamp.br/$\sim$cardoso/dissertacao\\%20de\\%20mestrado.pdf)>. Acesso em: 24 de Maio de 2013.

CASTELLARI, S. P.; FERREIRA, H. S. Sistema hipermídia adaptativo no ensino de sensoriamento remoto a distância. **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**, p. 1417–1421, 21-26 Abril 2007.

CASTRO, L. N. de; TIMMIS, J. Artificial immune systems: A novel paradigm to pattern recognition. In: **University of Paisley**. Springer Verlag, University of Paisley, UK, 2002. p. 67–84. Disponível em: <<http://www-users.cs.york.ac.uk/jtimmis/papers/pattern-ais.pdf>>. Acesso em: 6 de Maio de 2013.

CHANDRASEKARAN, B.; SHEN, D. W. C. On expediency and convergence in variable structure automata. In: **Adaptive Processes, 1966. Fifth Symposium on**. [S.l.: s.n.], 1966. v. 5, p. 845–850.

CHANDRASEKARAN, B.; SHEN, D. W. C. Stochastic automata games. In: **Adaptive Processes, 1968. Seventh Symposium on**. [S.l.: s.n.], 1968. v. 7, p. 63–63.

CHANIN, R. et al. **Avaliação Quantitativa de Sistemas**. Porto Alegre, RS, Brasil, 2005. Disponível em: <[http://www.inf.pucrs.br/\\$\sim\\$paolof/ads/AQS-tudo.pdf](http://www.inf.pucrs.br/$\sim$paolof/ads/AQS-tudo.pdf)>. Acesso em: 11 de Abril de 2013.

CHARTIER, R. **Os desafios da escrita**. [S.l.]: UNESP, 2002. ISBN 9788571393905.

CIRILO, C. et al. Model driven richubi - a model-driven process to construct rich interfaces for context-sensitive ubiquitous applications. In: **Software Engineering (SBES), 2010 Brazilian Symposium on**. [S.l.: s.n.], 2010. p. 100–109.

COELHO, A. M. **Uma abordagem via algoritmos meméticos para a solução do problema de horário escolar**. Dissertação (Mestrado) — Centro Federal de Educação Tecnológica de Minas Gerais CEFET/MG, 2006. Disponível em: <http://www.riopomba.ifsudestemg.edu.br/portal/sites/default/files/arq_paginas\\1Dissertacao_AlessandraMartinsCoelho2006.pdf>. Acesso em: 4 de Abril de 2013.

COELHO, L. S.; MARIANI, V. C. Conceção híbrida de otimização por nuvem de partículas aplicada ao problema de weber. **INFOCOMP Journal of Computer Science**, v. 4, n. 3, p. 24–31, 2005. Disponível em: <<http://www.dcc.ufla.br/infocomp/artigos/v4.3/art04.pdf>>. Acesso em: 02 de Junho de 2013.

CONINX, K. et al. Dygimes: Dynamically generating interfaces for mobile computing devices and embedded systems. In: **IN HUMAN-COMPUTER INTERACTION WITH MOBILE DEVICES AND SERVICES, 5TH INTERNATIONAL SYMPOSIUM, MOBILE HCI 2003**. [S.l.]: Springer, 2003. p. 256–270.

CONKLIN, J. Hypertext: An introduction and survey. **SURVEY & TUTORIAL SERIES: Computer**, v. 20, n. 9, p. 17 – 41, Setembro 1987. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=1663693>>. Acesso em: 2 de Fevereiro de 2013.

COSTA, D. A tabu search algorithm for computing an operational timetable. **European Journal of Operational Research**, v. 76, p. 98–110, 1994. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0377221794900094>>. Acesso em: 22 de Maio de 2013.

DARWIN, C.; BEER, G. **The Origin of Species**. [S.l.]: Oxford University Press, Incorporated, 1998. (Oxford world's classics). ISBN 9780192834386.

DASGUPTA, D. Advances in artificial immune systems. **Computational Intelligence Magazine, IEEE**, v. 1, n. 4, p. 40 – 49, Novembro 2006. ISSN 1556-603X. Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=4129847&tag=1>>. Acesso em: 11 de Fevereiro de 2013.

DAVIS, L. **Handbook of Genetic Algorithms**. [S.l.]: Van Nostrand Reinhold, 1991. (VNR computer library). ISBN 9780442001735.

DAWKINS, R. **The Selfish Gene**. [S.l.]: Oxford University Press, 1989. (Oxford paperbacks). ISBN 9780192860927.

DE BRA, P. Adaptive hypermedia on the web: Methods, techniques and applications. **AACE WebNet'1998**, Orlando, Florida, EUA, p. 220–225, 1998. Disponível em: <[http://www.wis.win.tue.nl/~sim\\$debra/webnet98/invited.ps](http://www.wis.win.tue.nl/~sim$debra/webnet98/invited.ps)>. Acesso em: 05 de Novembro de 2012.

DE BRA, P.; HOUBEN, G.-J.; KORNAZKY, Y. An extensible data model for hyperdocuments. In: **Proceedings of the ACM conference on Hypertext**. New York, NY, EUA: ACM, 1992. (EHT '92), p. 222–231. ISBN 0-89791-547-X. Disponível em: <http://delivery.acm.org/10.1145/170000/168530/p222-de_bra.pdf>. Acesso em: 8 de Fevereiro de 2013.

DEB, K. **Multi-objective optimization using evolutionary algorithms**. [S.l.]: John Wiley & Sons, 2001. 497 p. (Wiley-Interscience series in systems and optimization). ISBN 9780471873396.

DELAMARE, F. L. **Análise de padrões de mobilidade utilizando redes de autômatos estocásticos**. Dissertação (Mestrado) — Pontifícia Universidade Católica do Rio Grande do Sul (PUCRS), Porto Alegre, RS, Brasil, 2008. Disponível em: <http://tede.pucrs.br/tde/_busca/arquivo.php?codArquivo=1447>. Acesso em: 16 de Abril de 2013.

DELISLE, N.; SCHWARTZ, M. Neptune: a hypertext system for cad applications. **Tektronix Computer Research Laboratory**, p. 132 – 143, 1986. Disponível em: <<http://delivery.acm.org/10.1145/20000/16867/p132-delisle.pdf>>. Acesso em: 24 de Janeiro de 2013.

ESPINDOLA, L. da S. **Proposta de uma Representação Tensorial para Modelos Markovianos Ocultos**. Dissertação (Mestrado) — Pontifícia Universidade Católica do Rio Grande do Sul (PUCRS), Porto Alegre, RS, Brasil, Março 2011. Disponível em: <http://tede.pucrs.br/tde/_busca/arquivo.php?codArquivo=3547>. Acesso em: 16 de Abril de 2013.

FALCÃO, A. O.; BORGES, J. G. Designing an evolution program for solving integer forest management scheduling models: An application in portugal. **Forest Science**, v. 47, n. 2, p. 158–168, 2001. Disponível em: <[http://www.di.fc.ul.pt/\\$\sim\\$afalcao/docs/falcao-borges-fs2001.pdf](http://www.di.fc.ul.pt/$\sim$afalcao/docs/falcao-borges-fs2001.pdf)>. Acesso em: 30 de Maio de 2013.

FALCONE, M. A. G. **Estudo comparativo entre Algoritmos Genéticos e Evolução Diferencial para Otimização de um Modelo de Cadeia de Suprimento Simplificada**. Dissertação (Mestrado) — Pontifícia Universidade Católica do Paraná (PUCPR), 2004. Disponível em: <<http://www.produtronica.pucpr.br/Publico/ppgeps/conteudo/dissertacoes/pdf/MarcoFalcone.pdf>>. Acesso em: 25 de Maio de 2013.

FARINA, A. G. **Aplicação de Redes de Autômatos Estocásticos no Teste Estatístico de Software**. Dissertação (Mestrado) — Pontifícia Universidade Católica do Rio Grande do Sul (PUCRS), Porto Alegre, RS, Brasil, Fevereiro 2003. Disponível em: <http://www.inf.pucrs.br/peg/pub/thesis/aFarina_m.pdf>. Acesso em: 16 de Abril de 2013.

FERNANDES, P.; PLATEAU, B.; STEWART, W. J. **Efficient Descriptor-V ector Multiplications in Stochastic Automata Networks**. [S.l.], 1996. Disponível em: <<http://hal.archives-ouvertes.fr/docs/00/07/37/64/PDF/RR-2935.pdf>>. Acesso em: 18 de Abril de 2013.

FRAGOSO, S. Quem procura, acha? o impacto dos buscadores sobre o modelo distributivo da world wide web. **Encontro Anual da Associação Nacional dos Programas de Pós-Graduação**, Santos, SP, Brasil, 2005. Disponível em: <http://www.compos.org.br/data/biblioteca_177.pdf>. Acesso em: 12 de Novembro de 2012.

FU, K.; MCLAREN, R.; ENGINEERING, P. U. S. of E. **An Application of Stochastic Automata to the Synthesis of Learning Systems**. [S.l.]: Purdue University School of Electrical Engineering, 1965a.

FU, K.; MCMURTRY, G.; ENGINEERING, P. U. S. of E. **A Study of Stochastic Automata as Models of Adaptive and Learning Controllers**. [S.l.]: Purdue University School of Electrical Engineering, 1965b.

FU, K. S. A prelude to neural networks. In: MENDEL, J. M. (Ed.). Upper Saddle River, NJ, USA: Prentice Hall Press, 1994. cap. Stochastic automata as models of learning systems, p. 393–431. ISBN 0-13-147448-0.

FURTADO, E. Integrando fatores humanos no processo de desenvolvimento de interfaces homem-computador adaptativas. **IHC 99 - II Workshop sobre Fatores Humanos em Sistemas Computacionais**, 1999.

FURTADO, M. **Mise en oeuvre d’une méthode de conception d’interfaces adaptatives pour des systèmes de supervision à partir des spécifications conceptuelles**. Tese (Doutorado) — Univ. d’Aix-Marseille 3, 1997.

FURUTA, R.; STOTTS, P. D. A functional meta-structure for hypertext models and systems. **Electronic Publication**, John Wiley and Sons Ltd., Chichester, UK, v. 3, n. 4, p. 179–205, Novembro 1990. ISSN 0894-3982. Disponível em: <<http://cajun.cs.nott.ac.uk/compsci/epo/papers/volume3/issue4/ep032rf.pdf>>. Acesso em: 7 de Fevereiro de 2013.

GABRIEL, P. H. R.; DELBEM, A. C. B. **Fundamentos de Algoritmos Evolutivos**. [S.l.], 2008. Disponível em: <[http://www2.icmc.usp.br/\\$sim\\$biblio/BIBLIOTECA/not_did/ND\075.pdf](http://www2.icmc.usp.br/simbiblio/BIBLIOTECA/not_did/ND\075.pdf)>. Acesso em: 6 de Abril de 2013.

GALAFASSI, C. **Aplicação de Metaheurísticas na Abordagem do Problema de Roteamento de Veículos Capacitado com Janelas de Tempo**. Dissertação (Mestrado) — Universidade do Vale do Rio dos Sinos (UNISINOS), 2011. Disponível em: <<http://biblioteca.asav.org.br/vinculos/tede/CristianoGalafassi.pdf>>. Acesso em: 10 de Maio de 2013.

GARCIA-CABRERA, L.; RODRIGUEZ-FORTIZ, M. J.; PARETS-LLORCA, J. **Hypermedia Systems: the Need for Cognitive Hypermedia Models**. 2001. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.98.9320&rep=rep1&type=pdf>>. Acesso em: 8 de Fevereiro de 2013.

GARCIA, V. J. et al. **Algoritmo Memético Paralelo Aplicado a Problemas de Sequenciamento em Máquina Simples**. [S.l.], 2001. Disponível em: <[http://www.cs.newcastle.edu.au/\\$sim\\$mendes/papers/SOBR-01.pdf](http://www.cs.newcastle.edu.au/simmendes/papers/SOBR-01.pdf)>. Acesso em: 02 de Junho de 2013.

GARRETT, L. N.; SMITH, K. E.; MEYROWITZ, N. Intermedia: issues, strategies, and tactics in the design of a hypermedia document system. In: **Proceedings of the 1986 ACM conference on Computer-supported cooperative work**. New York, NY, EUA: ACM, 1986. (CSCW '86), p. 163–174. Disponível em: <<http://doi.acm.org/10.1145/637069.637090>>. Acesso em: 12 de Novembro de 2012.

GARTNER. **Gartner Says 821 Million Smart Devices Will Be Purchased Worldwide in 2012; Sales to Rise to 1.2 Billion in 2013**. 2012. Disponível em: <<http://www.gartner.com/newsroom/id/2227215>>. Acesso em: 10 de Maio de 2013.

GENDREAU, M.; LAPORTE, G.; POTVIN, J. Y. The vehicle routing problem. In: TOTH, P.; VIGO, D. (Ed.). **The vehicle routing problem**. Philadelphia, PA, EUA: Society for Industrial and Applied Mathematics, 2001. cap. Metaheuristics for the capacitated VRP, p. 129–154. ISBN 0-89871-498-2. Disponível em: <<http://dl.acm.org/citation.cfm?id=505847.505853>>.

GLOVER, F. Future paths for integer programming and links to artificial intelligence. **Computer Operations Research**, Elsevier Science Ltd., Oxford, UK, UK, v. 13, n. 5, p. 533–549, Maio 1986. ISSN 0305-0548. Disponível em: <<http://leeds-faculty.colorado.edu/glover/TS\%20-\%20Future\%20Paths\%20for\%20Integer\%20Programming.pdf>>. Acesso em: 23 de Maio de 2013.

GLOVER, F. Tabu search – part i. **ORSA Journal on Computing**, v. 1, n. 3, p. 190–206, 1989. Disponível em: <<http://leeds-faculty.colorado.edu/glover/TS\%20-\%20Part\%20I-ORSA-aw.pdf>>. Acesso em: 23 de Maio de 2013.

GLOVER, F. Tabu search – part ii. **ORSA Journal on Computing**, v. 2, n. 1, p. 4–32, 1990. Disponível em: <<http://leeds-faculty.colorado.edu/glover/TS\%20-\%20Part\%20II-ORSA-aw.pdf>>. Acesso em: 23 de Maio de 2013.

GLOVER, F.; KOCHENBERGER, G. **Handbook in Metaheuristics**. [S.l.]: Kluwer Academic Publishers, 2003. (International Series in Operations Research & Management Science, 57). ISBN 9781402072635.

GLOVER, F.; LAGUNA, M. **Tabu Search**. Norwell, MA, EUA: Kluwer Academic Publishers, 1997. ISBN 079239965X.

GLOVER, F.; TAILLARD, E. A user's guide to tabu search. **Annals of Operations Research**, Baltzer Science Publishers, Baarn/Kluwer Academic Publishers, v. 41, n. 1, p. 1–28, 1993. ISSN 0254-5330. Disponível em: <<http://link.springer.com/content/pdf/10.1007\\%2F02078647.pdf>>. Acesso em: 23 de Maio de 2013.

GOLDBERG, D. E. **Genetic Algorithms in Search, Optimization and Machine Learning**. 1. ed. Boston, MA, EUA: Addison-Wesley Longman Publishing Co., Inc., 1989. Hardcover. ISBN 0201157675.

GOLDBERG, D. E.; VOESSNER, S. Optimizing global-local search hybrids. In: **PROCEEDINGS OF THE GENETIC AND EVOLUTIONARY COMPUTATION CONFERENCE, 220–228. (ALSO ILLIGAL)**. Morgan Kaufmann, 1999. p. 220–228. Disponível em: <[http://www.cs.bham.ac.uk/\\$sim\\$wbl/biblio/gecco1999/GA-882.pdf](http://www.cs.bham.ac.uk/simwbl/biblio/gecco1999/GA-882.pdf)>. Acesso em: 31 de Maio de 2013.

GÓMEZ, A. T. et al. **Especificação Preliminar da Arquitetura de Integração do Protótipo do Servidor de Canal de Retorno para TVD, WEB e Dispositivos Móveis**. São Leopoldo, RS, Brasil, 2012.

GUERRATO, D. **Design Responsivo na pratica: do rascunho ao digital**. 2013. Disponível em: <<http://tableless.com.br/design-responsivo-na-pratica-do-rascunho-ao-digita/#.UimT9Tafgkr>>. Acesso em: 20 de Fevereiro de 2013.

GUERRERO, C.; LULA BERNARDO, J. A model-guided and task-based approach to user interface design centered in a unified interaction and architectural model. In: KOLSKI, C.; VANDERDONCKT, J. (Ed.). **Computer-Aided Design of User Interfaces III**. Springer Netherlands, 2002. p. 119–129. ISBN 978-94-010-3915-4. Disponível em: <http://dx.doi.org/10.1007/978-94-010-0421-3_11>.

HALASZ, F. G. Reflections on notecards: seven issues for the next generation of hypermedia systems. In: **Proceedings of the ACM conference on Hypertext**. New York, NY, EUA: ACM, 1987. (HYPERTEXT '87), p. 345–365. ISBN 0-89791-340-X. Disponível em: <<http://doi.acm.org/10.1145/317426.317451>>. Acesso em: 12 de Novembro de 2012.

HALASZ, F. G.; SCHWARTZ, M. The dexter hypertext reference model. **Presented at the NIST Hypertext Standardization Workshop**, Janeiro 1990. Disponível em: <<http://media.inhatc.ac.kr/papers/hypermedia/Dexter90.pdf>>. Acesso em: 10 de Janeiro de 2013.

HARDMAN, L.; BULTERMAN, D. C. A. Using the amsterdam hypermedia model for abstracting presentation behavior. In: **In Electronic Proceedings of the ACM Workshop on Effective Abstractions in Multimedia**. [s.n.], 1995. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.52.8495&rep=rep1&type=pdf>>. Acesso em: 9 de Fevereiro de 2013.

HARDMAN, L.; BULTERMAN, D. C. A.; ROSSUM, G. van. The amsterdam hypermedia model: adding time and context to the dexter model. **Commun. ACM**, ACM, New York, NY, EUA, v. 37, n. 2, p. 50 – 62, Fevereiro 1994. ISSN 0001-0782. Disponível em: <<http://delivery.acm.org/10.1145/180000/175239/p50-hardman.pdf>>. Acesso em: 8 de Fevereiro de 2013.

HOFMEISTER, C.; NORD, R.; SONI, D. **Applied software architecture**. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 2000. ISBN 0-201-32571-3.

HOLLAND, J. H. **Adaptation in natural and artificial systems**. Cambridge, MA, EUA: MIT Press, 1992. ISBN 0-262-58111-6.

ITO, G. C. et al. Geração de interfaces adaptativas para dispositivos móveis. In: SILVA, J. D. S. d. et al. (Ed.). São José dos Campos: Instituto Nacional de Pesquisas Espaciais, 2005. Disponível em: <<http://urlib.net/dpi.inpe.br/hermes2@1905/2005/10.03.16.14>>. Acesso em: 05 set. 2013.

JONG, K. A. D. Genetic algorithms are not function optimizers. **Foundations of genetic algorithms**, v. 2, p. 5–17, 1993.

KELLY, S.; TOLVANEN, J. **Domain-Specific Modeling: Enabling Full Code Generation**. [S.l.]: Wiley, 2008. ISBN 9780470249253.

KNOSALA, R.; WAL, T. A production scheduling problem using genetic algorithm. **Journal of Materials Processing Technology**, v. 109, n. 12, p. 90 – 95, 2001. ISSN 0924-0136. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0924013600007809>>. Acesso em: 27 de Maio de 2013.

KNOWLES, J. D.; CORNE, D. W. A comparative assessment of memetic, evolutionary and constructive algorithms for the multi-objective d-msat problem. In: **2001 Genetic and Evolutionary Computation Workshop Proceeding**. [S.l.: s.n.], 2001.

KOCH, N. **Software Engineering for Adaptive Hypermedia Systems Reference Model, Modeling Techniques and Development Process**. Tese (Doutorado) — Ludwig-Maximilians-Universität München, 2000. Disponível em: <[http://www.pst.informatik.uni-muenchen.de/\\$\sim\\$sim\\$kochn/PhDThesisNoraKoch.pdf](http://www.pst.informatik.uni-muenchen.de/$\sim$sim$kochn/PhDThesisNoraKoch.pdf)>. Acesso em: 7 de Fevereiro de 2013.

KOCH, N.; ROSSI, G. Patterns for adaptive web applications. **7th European Conference on Pattern Languages of Programms (EuroPLOP '2002)**, Irsee, Alemanha, 3-7 de Julho 2002. Disponível em: <<http://www.pst.informatik.uni-muenchen.de/personen/kochn/EuroPLOP2002-Koch.pdf>>. Acesso em: 08 de Junho de 2013.

KOCH, N.; WIRSING, M. The munich reference model for adaptive hypermedia applications. In: **2nd International Conference on Adaptive Hypermedia and Adaptive Web-based Systems**. Springer Verlag, 2002. p. 213 – 222. Disponível em: <<http://www.pst.informatik.uni-muenchen.de/personen/kochn/munich-koch-wirsing-final.pdf>>. Acesso em: 8 de Fevereiro de 2013.

KRASNOGOR, N. **Studies on the Heory and Design Space of Memetic Algorithms**. Tese (Doutorado) — University of the West of England, 2002. Disponível em: <[http://www.cs.nott.ac.uk/\\$\sim\\$sim\\$nxk/PAPERS/thesis.pdf](http://www.cs.nott.ac.uk/$\sim$sim$nxk/PAPERS/thesis.pdf)>. Acesso em: 4 de Abril de 2013.

KRASNOGOR, N. Self generating metaheuristics in bioinformatics: The proteins structure comparison case. **Genetic Programming and Evolvable Machines**, Kluwer Academic Publishers, v. 5, n. 2, p. 181–201, 2004. ISSN 1389-2576. Disponível em: <<http://dx.doi.org/10.1023/B%3AGENP.0000023687.41210.d7>>.

KRASNOGOR, N.; ARAGÓN, A.; PACHECO, J. Memetic algorithms. In: ALBA, E.; MARTÍ, R. (Ed.). **Metaheuristic Procedures for Training Neural Networks**. Springer US, 2006, (Operations Research/Computer Science Interfaces Series, v. 36). p. 225–248. ISBN 978-0-387-33415-8. Disponível em: <http://dx.doi.org/10.1007/0-387-33416-5_11>.

KRASNOGOR, N.; SMITH, J. A tutorial for competent memetic algorithms: model, taxonomy, and design issues. **Evolutionary Computation, IEEE Transactions on**, v. 9, n. 5, p. 474–488, 2005. ISSN 1089-778X. Disponível em: <<http://ieeexplore.ieee.org/ielx5/4235/32437/01514472.pdf>>. Acesso em: 31 de Maio de 2013.

KRUCHTEN, P. The 4+1 view model of architecture. **Software, IEEE**, v. 12, n. 6, p. 42–50, 1995. ISSN 0740-7459.

LAVÔR, R. B.; LEITE, J. C. Ferramenta para modelagem de interação e interface de usuário. In: **Congresso Ibero-Americano em Engenharia de Software**. [S.l.: s.n.], 2011.

LEITE, J. C. Specifying the user interface as an interactive message. In: **Proceedings of Human-Computer Interaction International (HCII'2003)**. Heraklion, Creta: Lawrence Erlbaum Associates, 2003. v. 2, p. 716–720.

LIBÓRIO, A. et al. Geração de interfaces através de sistemas baseados em conhecimento: uma abordagem centrada em explicações de modelos de resolução de problemas. In: **Proceedings of the 2005 Latin American conference on Human-computer interaction**. New York, NY, USA: ACM, 2005. (CLIHC '05), p. 332–337. ISBN 1-59593-224-0. Disponível em: <<http://doi.acm.org/10.1145/1111360.1111397>>.

LIMBOURG, Q.; VANDERDONCKT, J. Addressing the mapping problem in user interface design with usixml. In: **Proceedings of the 3rd annual conference on Task models and diagrams**. New York, NY, USA: ACM, 2004a. (TAMODIA '04), p. 155–163. ISBN 1-59593-000-0. Disponível em: <<http://doi.acm.org/10.1145/1045446.1045474>>.

LIMBOURG, Q. et al. Usixml: A user interface description language for context-sensitive user interfaces. In: **IN PROCEEDINGS OF THE ACM AVI'2004 WORKSHOP; DEVELOPING USER INTERFACES WITH XML: ADVANCES ON USER INTERFACE DESCRIPTION LANGUAGES**. [S.l.]: Press, 2004b. p. 55–62.

LOBO, E. L. M. **Uma Solução do Problema de Horário Escolar Via Algoritmo Genético Paralelo**. Dissertação (Mestrado) — Centro Federal de Educação Tecnológica de Minas Gerais, 2005. Disponível em: <<http://www.mmc.cefetmg.br/info/downloads/D006-EduardoLuizMirandaLobo2005.pdf>>. Acesso em: 24 de Maio de 2013.

LOPES, L. de S. **Uma Heurística Baseada em Algoritmos Genéticos Aplicada ao Problema de Cobertura de Conjuntos**. Dissertação (Mestrado) — Instituto Nacional de Pesquisas Espaciais, 1995. Disponível em: <[http://www.lac.inpe.br/\\$\sim\\$lorena/luciana/tese-luciana.pdf](http://www.lac.inpe.br/$\sim$lorena/luciana/tese-luciana.pdf)>. Acesso em: 24 de Maio de 2013.

LUCAS, D. C. **Algoritmos Genéticos: uma Introdução**. [S.l.], 2002. Disponível em: <[http://www.inf.ufrgs.br/\\$\sim\\$alvares/INF01048IA/ApostilaAlgoritmosGeneticos.pdf](http://www.inf.ufrgs.br/$\sim$alvares/INF01048IA/ApostilaAlgoritmosGeneticos.pdf)>. Acesso em: 26 de Maio de 2013.

LUPTON, E.; MILLER, J. **Design writing research: writing on graphic design**. [S.l.]: Phaïdon, 1999. ISBN 9780714838519.

MACHADO, J. P. et al. Autômatos finitos: um formalismo para cursos na web. **XIII Simpósio Brasileiro de Engenharia de Software, Florianópolis**, p. 213–223, 1999.

MARINHO, E. H. **Heurísticas Busca Tabu para o Problema de Programação de Tripulações de Ônibus Urbano**. Dissertação (Mestrado) — Universidade Federal Fluminense (UFF), 2005. Disponível em: <<http://www.decom.ufop.br/prof/marcone/Orientacoes/dissEulerFinal.pdf>>. Acesso em: 23 de Maio de 2013.

Stochastic Optimal Control of Active Vehicle Suspensions Using Learning Automata, v. 207. 143-152 p.

MCLAREN, R. W. A stochastic automaton model for synthesis of learning systems. **IEEE Transactions on System Science and Cybernetics**, SSC-2, p. 109–114, 1966.

MENKHAUS, G. **Adaptive User Interface Generation in a Mobile Computing Environment**. Tese (Doutorado) — University of Salzburg, Austria, 2002.

MERZ, P. **Memetic Algorithms for Combinatorial Optimization Problems: Fitness Landscapes and Effective Search Strategies**. Tese (Doutorado) — Department of Electrical Engineering and Computer Science, University of Siegen, Germany, 2000.

MERZ, P.; FREISLEBEN, B. A comparison of memetic algorithms, tabu search, and ant colonies for the quadratic assignment problem. In: **Proceedings of the 1999 Congress on Evolutionary Computation (CEC 99)**. [s.n.], 1999. v. 3, p. 2063–2070. Disponível em: <<http://ieeexplore.ieee.org/ielx5/6342/16970/00785529.pdf>>. Acesso em: 31 de Maio de 2013.

MEYROWITZ, N. Intermedia: The architecture and construction of an object-oriented hypemedia system and applications framework. **SIGPLAN Not.**, ACM, New York, NY, EUA, v. 21, n. 11, p. 186–201, Junho 1986. ISSN 0362-1340. Disponível em: <<http://doi.acm.org/10.1145/960112.28716>>. Acesso em: 12 de Novembro de 2012.

MICHALEWICZ, Z. **Genetic Algorithms + Data Structures = Evolution Programs (3rd Ed.)**. London, UK, UK: Springer-Verlag, 1996. ISBN 3-540-60676-9.

MICROSOFT. **Microsoft Expression Changes**. 2013. Disponível em: <<http://www.microsoft.com/expression/eng/>>.

MITCHELL, M. **An introduction to genetic algorithms**. Cambridge, MA, EUA: MIT Press, 1996. ISBN 0-262-13316-4. Disponível em: <<https://svn-d1.mpi-inf.mpg.de/AG1/MultiCoreLab/papers/ebook-fuzzy-mitchell-99.pdf>>. Acesso em: 30 de Maio de 2013.

MOBILE, S. Disponível em: <<http://wurfl.sourceforge.net/>>. Acesso em: 24 de Junho de 2013.

MORI, G.; PATERNÒ, F.; SANTORO, C. Ctte: support for developing and analyzing task models for interactive system design. **IEEE Trans. Softw. Eng.**, IEEE Press, Piscataway, NJ, USA, v. 28, n. 8, p. 797–813, ago. 2002. ISSN 0098-5589. Disponível em: <<http://dx.doi.org/10.1109/TSE.2002.1027801>>.

MORTON, D. P.; WOOD, R. K. Advances in computational and stochastic optimization, logic programming, and heuristic search. In: WOODRUFF, D. L. (Ed.). Norwell, MA, USA: Kluwer Academic Publishers, 1998. cap. On a Stochastic Knapsack Problem and Generalizations, p. 149–168. ISBN 0-7923-8078-9. Disponível em: <<http://dl.acm.org/citation.cfm?id=285322.285327>>.

MOSCATO, P. **On Evolution, Search, Optimization, Genetic Algorithms and Martial Arts - Towards Memetic Algorithms**. 1989. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.27.9474&rep=rep1&type=pdf>>. Acesso em: 31 de Maio de 2013.

NAJIM, K.; POZNYAK, A. **Learning Automata: Theory Applications**. Pergamon Press, 1994. ISBN 9780080420240. Disponível em: <<http://books.google.com.br/books?id=u2RQAAAAMAAJ>>.

NARENDRA, K.; THATHACHAR, M. Learning automata - a survey. **Systems, Man and Cybernetics, IEEE Transactions on**, SMC-4, n. 4, p. 323–334, 1974. ISSN 0018-9472.

NARENDRA, K. S.; THATHACHAR, M. A. L. **Learning Automata: An Introduction**. Upper Saddle River, NJ, EUA: Prentice-Hall, Inc., 1989. ISBN 9780134855585.

NELSON, T. **Xanadu Project**. 1960. Disponível em: <<http://www.xanadu.com/>>. Acesso em: 20 de Setembro de 2012.

NETO, M. A. C. et al. Desenvolvendo interfaces de usuario multiplataformas utilizando mda. **1a Conferencia Sul-Americana de Design de Interação**, v. 1, p. 26–35, 2009.

OMG, O. M. G. **MDA Specifications**. 2013. Disponível em: <<http://www.omg.org/mda/specs.htm>>.

ONG, W. **Oralidade e cultura escrita: a tecnologização da palavra**. [S.l.]: Papyrus, 1998. ISBN 9788530805197.

OSMAN, I.; LAPORTE, G. Metaheuristics: A bibliography. **Annals of Operations Research**, Baltzer Science Publishers, Baarn/Kluwer Academic Publishers, v. 63, n. 5, p. 511–623, 1996. ISSN 0254-5330. Disponível em: <<http://dx.doi.org/10.1007/BF02125421>>. Acesso em: 4 de Abril de 2013.

PAGANO, R. L. **Computer Simulation as an educational tool**. Tese (Doutorado) — Université catholique de Louvain, B'lgica, 1992.

PALAZZO, L. A. M. **Modelos Proativos para Hipermídia Adaptativa**. Tese (Doutorado) — Universidade Federal do Rio Grande do Sul (UFRGS), 2000. Disponível em: <<http://hdl.handle.net/10183/24148>>. Acesso em: 15 de Novembro de 2012.

PATERNO, F.; MANCINI, C. **Designing Web User Interfaces Adaptable to Different Types of Use**. 1999. Disponível em: <<http://www.museumsandtheweb.com/mw99/papers/paterno/paterno.html>>. Acesso em: 10 de Dezembro de 2012.

PENG, J.; WILLIAMS, R. J. Efficient learning and planning within the dyna framework. In: **IEEE International Conference on Neural Networks**. [S.l.: s.n.], 1993. v. 1, p. 168–174.

PETTERMANN, R. J.; BELLIN, F.; KROTH, E. Uma ferramenta para geração de interfaces de sistemas de informação em ambiente web. In: **XV Simposio Brasileiro de Engenharia de Software**. [S.l.: s.n.], 2001.

PLATEAU, B. **De l'évaluation du parallélisme et de la synchronisation**. Tese (Doutorado) — Paris-Sud, Orsay, France, 1984.

PLATEAU, B.; ATIF, K. Stochastic automata network of modeling parallel systems. **Software Engineering, IEEE Transactions on**, v. 17, n. 10, p. 1093–1108, 1991. ISSN 0098-5589. Disponível em: <http://ieeexplore.ieee.org/xpls/abs/_all.jsp?arnumber=99196&tag=1>. Acesso em: 3 de Abril de 2013.

PLATEAU, B.; STEWART, W. J. **Stochastic Automata Networks: Product Foorms and Iterative Solutions**. [S.l.], 1996. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.42.9710&rep=rep1&type=pdf>>. Acesso em: 18 de Abril de 2013.

POLTOSI, M. R. **Elaboração de Escalas de Trabalho de Técnicos de Emfermagem com Busca Tabu e Algoritmos Genéticos**. Dissertação (Mestrado) — Universidade do Vale do Rio dos Sinos (UNISINOS), 2007. Disponível em: <<http://biblioteca.asav.org.br/vinculos/tede/elaboracao\\%20de\\%20escalas.pdf>>. Acesso em: 22 de Maio de 2013.

POZNYAK, A.; NAJIM, K. **Learning automata and stochastic optimization**. [S.l.]: Springer, 1997. (Lecture notes in control and information sciences). ISBN 9783540761549.

POZZEBON, E. et al. Ensino de neurofisiologia baseado no modelo hipertômato. **XIII ENCTRL DE INFORM ATICA IMESA, Assis-SP Vol. CD-Rom**, 2002a.

POZZEBON, E. et al. Hipertômato controla os itens da matéria ensinada num tutorial de neurofisiologia. **CBCOMP - II WORKSHOP DE INFORMÁTICA APLICADA ã SAUDE**, Agosto 2002b.

PRIMO, A.; RECUERO, R. da C. A terceira geração da hipertextualidade: cooperação e conflito na escrita coletiva de hipertextos com links multidirecionais. **Líbero**, v. 9, n. 17, 2006. Disponível em: <<http://www.revistas.univerciencia.org/index.php/libero/article/view/6107/5567>>. Acesso em: 13 de Novembro de 2012.

PUGA, S. G. **Sistemas Hipermídia adaptativos para a educação baseada na web: uma visão semiótica**. Tese (Doutorado) — Escola Politécnica da Universidade de São Paulo (USP), São Paulo, Brasil, 23 de Setembro 2008. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/3/3141/tde-18112008-151113/es.php>>. Acesso em: 12 de Novembro de 2012.

RADCLIFFE, N. J.; SURRY, P. D. Formal memetic algorithms. **Evolutionary Computing: AISB Workshop**, Springer Verlag, p. 1–16, 1994. Disponível em: <<http://users.breathe.com/njr/papers/aisb94.pdf>>. Acesso em: 30 de Maio de 2013.

RODRIGUES, A. P. de S. P. **Parametrização e Simulação Numérica da Turbina Hidrocinética– Otimização via Algoritmos Genéticos**. Dissertação (Mestrado) — Universidade de Brasília (UnB), 2007. Disponível em: <<http://bdtd.bce.unb.br/>>

tedesimplificado/tde_busca/arquivo.php?codArquivo=2829>. Acesso em: 26 de Maio de 2013.

RODRIGUES, C. E. C. L. **MEDITE+: Utilizando o Processo de Roteirização para a Obtenção do Modelo de Interação EDITOR Estendido**. Dissertação (Mestrado) — Universidade Federal de Campina Grande, Junho 2005.

SADILEK, D. A. Prototyping domain-specific language semantics. In: **Companion to the 23rd ACM SIGPLAN conference on Object-oriented programming systems languages and applications**. New York, NY, USA: ACM, 2008. (OOPSLA Companion '08), p. 895–896. ISBN 978-1-60558-220-7. Disponível em: <<http://doi.acm.org/10.1145/1449814.1449896>>.

SALES, A. H. C. **Formalismos Estruturados de Modelagem para Sistemas Markovianos Complexos**. Dissertação (Mestrado) — Pontifícia Universidade Católica do Rio Grande do Sul (PUCRS), Junho 2004. Disponível em: <http://www.inf.pucrs.br/peg/pub/thesis/aSales_m.pdf>. Acesso em: 24 de Abril de 2013.

SALVADOR, O. **Introdução a Algoritmos Genéticos**. 2000.

SANGINETO, M. L. T. **Um Algoritmo Genético para a Programação de Transferência em um Poliduto**. Dissertação (Mestrado) — Universidade Federal do Rio de Janeiro (UFRJ), 2006. Disponível em: <<http://www.petroleo.ufrj.br/lorde/?q=bitcache/d017747f0b0d2605c5ca2f8e5cabd3d6a3993c8\&b&vid=&disposition=attachment&op=download>>. Acesso em: 10 de Maio de 2013.

SANTOS, T. C. W. dos. **Alternativas para o Tratamento Numérico Otimizado da Multiplicação Vetor-Descritor**. Porto Alegre, Brasil: [s.n.], 2004. Disponível em: <http://www.inf.pucrs.br/peg/pub/thesis/tWebber_m.pdf>. Acesso em: 24 de Abril de 2013.

SILVA, P. P. D. User interface declarative models and development environments: a survey. In: **Proceedings of the 7th international conference on Design, specification, and verification of interactive systems**. Berlin, Heidelberg: Springer-Verlag, 2001. (DSV-IS'00), p. 207–226. ISBN 3-540-41663-3. Disponível em: <<http://dl.acm.org/citation.cfm?id=1756227.1756245>>.

SILVA, P. P. D.; PATON, N. W. User interface modelling with uml. In: **In Proceedings of the 10th European-Japanese Conference on Information Modelling and Knowledge Representation**. [S.l.]: IOS Press, 2000. p. 203–217.

SILVA, P. P. D.; PATON, N. W. Improving uml support for user interface design: A metric assessment of umli. In: **Proc. Workshop on Bridging the Gaps Between Software Engineering and Human-Computer Interaction at International Conference on Software Engineering (ICSE '03)**. [S.l.: s.n.], 2003. p. 76–83.

SIMAS, E. P. L. **Utilizando a busca Tabu na resolução do problema de roteamento de veículos**. Dissertação (Mestrado) — Universidade do Vale do Rio dos Sinos (UNISINOS), 2007. Disponível em: <<http://www.dominiopublico.gov.br/download/texto/cp029183.pdf>>. Acesso em: 19 de Maio de 2013.

SOARES, G. L. **Algoritmos Genéticos: Estudo, Novas Técnicas e Aplicações**. Dissertação (Mestrado) — Escola de Engenharia da Universidade Federal de Minas Gerais (UFMG), 1997. Disponível em: <http://pessoal.utfpr.edu.br/mariano/arquivos/VAS1997_1.pdf>. Acesso em: 24 de Maio de 2013.

SOUCHON, N.; VANDERDONCKT, J. A review of xml-compliant user interface description languages. In: JORGE, J.; NUNES, N. J.; CUNHA, J. Falcão e (Ed.). **Interactive Systems. Design, Specification, and Verification**. Springer Berlin Heidelberg, 2003, (Lecture Notes in Computer Science, v. 2844). p. 377–391. ISBN 978-3-540-20159-5. Disponível em: <http://dx.doi.org/10.1007/978-3-540-39929-2_26>.

SOUSA, A. S. **Tomada de Decisão Fuzzy e Busca Tabu Aplicadas ao Planejamento da Expansão de Sistemas de Transmissão**. Dissertação (Mestrado) — Escola de Engenharia de São Carlos - USP, 2009. Disponível em: <<http://www.teses.usp.br/teses/disponiveis/18/18154/tde-27052009-142518/publico/Aldir.pdf>>. Acesso em: 16 de Maio de 2013.

SOUZA, B. B. e. **Projeto de Redes de Distribuição de Energia com Incertezas na Evolução de Carga Utilizando Algoritmos Meméticos**. Dissertação (Mestrado) — Universidade Federal de Minas Gerais (UFMG), 2007. Disponível em: <http://www.bibliotecadigital.ufmg.br/dspace/bitstream/handle/1843/RHCT-7AUS6D/bruno_baeta_e_souza.pdf>. Acesso em: 28 de Maio de 2013.

SOUZA, M. J. F. **Programação de horários em escolas: uma aproximação por metaheurísticas**. Tese (Doutorado) — COPPE - Universidade Federal do Rio de Janeiro (UFRJ), 2000. Disponível em: <[http://www2.ic.uff.br/\\$\sim\\$satoru/conteudo/artigos/Tese\%20doutorado\%20Marcone.pdf](http://www2.ic.uff.br/$\sim$satoru/conteudo/artigos/Tese\%20doutorado\%20Marcone.pdf)>. Acesso em: 18 de Maio de 2013.

SOWA, J. F. **Conceptual structures: information processing in mind and machine**. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1984. ISBN 0-201-14472-7.

STOTTS, D.; FURUTA, R. Language-theoretic classification of hypermedia paths. In: **Proceedings of the fifteenth ACM conference on Hypertext and hypermedia**. New York, NY, USA: ACM, 2004. (HYPERTEXT '04), p. 40–41. ISBN 1-58113-848-2. Disponível em: <<http://doi.acm.org/10.1145/1012807.1012822>>.

STOTTS, P. D.; FURUTA, R. Petri-net-based hypertext: document structure with browsing semantics. **ACM Trans. Inf. Syst.**, ACM, New York, NY, EUA, v. 7, n. 1, p. 3 – 29, Janeiro 1989. ISSN 1046-8188. Disponível em: <<http://delivery.acm.org/10.1145/70000/64791/p3-stotts.pdf>>. Acesso em: 7 de Fevereiro de 2013.

STOTTS, P. D.; FURUTA, R. Petri-net-based hypertext: document structure with browsing semantics. **ACM Trans. Inf. Syst.**, ACM, New York, NY, USA, v. 7, n. 1, p. 3–29, Janeiro 1989. ISSN 1046-8188. Disponível em: <<http://doi.acm.org/10.1145/64789.64791>>.

STOTTS, P. D.; FURUTA, R. **The Trellis Project - Process Modeling for CSCW**. [S.l.], 1993. Disponível em: <[http://www.csdl.tamu.edu/\\$\sim\\$furuta/trellis/TAMU-HRL-93-005/pn93cscw.pdf](http://www.csdl.tamu.edu/$\sim$furuta/trellis/TAMU-HRL-93-005/pn93cscw.pdf)>. Acesso em: 7 de Fevereiro de 2013.

SUCUPIRA, I. R. Métodos heurísticos genéricos: Meta-heurísticas e hiper-heurísticas. Note. 2004.

TANOMARU, J. Motivação, fundamentos e aplicações de algoritmos genéticos. **II Congresso Brasileiro de Redes Neurais**, 1995. Disponível em: <[http://www.dca.ufrn.br/\\$\sim\\$meneghet/FTP/Motiva\%E7\%E3o\%20Fundamentos\%20e\%20Aplica\%E7\%F5es\%20de\%20\%Algoritmos\%20Gen\%E9ticos.pdf](http://www.dca.ufrn.br/$\sim$meneghet/FTP/Motiva\%E7\%E3o\%20Fundamentos\%20e\%20Aplica\%E7\%F5es\%20de\%20\%Algoritmos\%20Gen\%E9ticos.pdf)>. Acesso em: 25 de Maio de 2013.

TATIBANA, C. Y.; KAETSU, D. Y. **Uma Introdução à Redes Neurais Artificiais**. 2013. Disponível em: <[http://www.din.uem.br/\\$\sim\\$ia/neurais/](http://www.din.uem.br/$\sim$ia/neurais/)>. Acesso em: 06 de Maio de 2013.

TERESA. **Multimodal TERESA - Tool for Design and Development of Multi-platform Applications**. 2013. Disponível em: <<http://giove.cnuce.cnr.it/teresa.html>>.

TOTH, P.; VIGO, D. Models, relaxations and exact approaches for the capacitated vehicle routing problem. **Discrete Appl. Math.**, Elsevier Science Publishers, Amsterdam, Netherlands, v. 123, n. 1-3, p. 487–512, Novembro 2002. ISSN 0166-218X. Disponível em: <http://www.researchgate.net/publication/222653651_Models_relaxations_and_exact_approaches_for_the_capacitated_vehicle_routing_problem/file/79e4150c0a709a0283.pdf>. Acesso em: 19 de Maio de 2013.

TSETLIN, M. L. **Automaton Theory and Modeling of Biological Systems**. [S.l.]: Academic Press, 1973. (Mathematics in Science and Engineering). ISBN 9780127016504.

ULLMAN, J. **Principles of Database and Knowledge-Base Systems**. Computer Science Press, 1989. (Principles of Computer Science Series, v. 1). ISBN 9780881751888. Disponível em: <<http://books.google.com.br/books?id=YmpqAAAAMAAJ>>. Acesso em: 1 de Fevereiro de 2013.

UNSAL, C. **Intelligent navigation of autonomous vehicles in an automated highway system: learning methods and interacting vehicles approach**. Tese (Doutorado) — Faculty of the Virginia Polytechnic Institute and State University, Janeiro 1997. Disponível em: <<http://scholar.lib.vt.edu/theses/available/etd-5414132139711101/>>. Acesso em: 12 de Abril de 2013.

VARSHAVSKII, V. I.; VORONTSOVA, I. P. On the behavior of stochastic automata with variable structure. **Automat. Telemekh.**, v. 24, p. 253–360, 1963.

VASQUEZ, J. G. P. Ambientes adaptativos: trilhando novos caminhos para a hipermídia. In: _____. [S.l.]: Ciência Moderna Ltda., 2006. cap. Técnicas de adaptação de conteúdo e apresentação em hipermídia adaptativa.

VAVAK, F.; FOGARTY, T.; JUKES, K. A genetic algorithm with variable range of local search for tracking changing environments. In: VOIGT, H.-M. et al. (Ed.). **Parallel Problem Solving from Nature PPSN IV**. Springer Berlin Heidelberg, 1996, (Lecture Notes in Computer Science, v. 1141). p. 376–385. ISBN 978-3-540-61723-5. Disponível em: <http://dx.doi.org/10.1007/3-540-61723-X_1002>.

VERNAZZA, L. Himalia: Model-driven user interfaces using hypermedia, controls and patterns. **1st International Workshop on Model-Driven User-Centric Design & Engineering MDUCDE'07**, Seul, p. 477–482, 2007.

VIANA, G. V. R. **Meta-heurísticas e Programação Paralela em Otimização Combinatória**. [S.l.]: Edições UFC, 1998.

WANNER, E. F. **Operadores para Algoritmos Genéticos baseados em aproximações quadráticas de funções de variáveis contínuas**. Tese (Doutorado) — Universidade Federal de Minas Gerais (UFMG), 2006. Disponível em: <http://www.bibliotecadigital.ufmg.br/dspace/bitstream/handle/1843/RHCT-6TDJGE/elizabeth_fialho_wanner.pdf>. Acesso em: 02 de Junho de 2013.

WICKERT, T. I. **Um Sistema para Sugestão e Otimização de Conteúdo Aplicado ao Servidor Multimídia do SBTVD**. Dissertação (Mestrado) — Universidade do Vale do Rio

dos Sinos (UNISINOS), 2012. Disponível em: <<http://biblioteca.asav.org.br/vinculos/000001/00000176.pdf>>. Acesso em: 10 de Maio de 2013.

WISER. **Global PC, Tablet, Smartphone Sales**. 2013. Disponível em: <<http://pt.wiser.org/article/61670dc8dd5c5a3adba285f39bbf8145>>. Acesso em: 10 de Maio de 2013.

WU, H. **A reference architecture for adaptive hypermedia applications**. Tese (Doutorado) — Technische Universiteit Eindhoven, 2002. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.81.1839&rep=rep1&type=pdf>>. Acesso em: 05 de Junho de 2013.

WU, H.; HOUBEN, G.-J.; BRA, P. D. Aham: a reference model to support adaptive hypermedia authoring. In: **Proceedings of the Conference on Information Science, Antwerp**. [s.n.], 1998. v. 51, p. 77–88. Disponível em: <[http://wwwis.win.tue.nl/\\$\sim\\$debra//infwet98/paper.pdf](http://wwwis.win.tue.nl/$\sim$debra//infwet98/paper.pdf)>. Acesso em: 09 de Junho de 2013.

WU, H.; HOUBEN, G.-J.; BRA, P. D. Supporting user adaptation in adaptive hypermedia applications. In: **Does Digital Divide Rhetoric Do More Harm Than Good? The Chronicle of Higher Education**. [s.n.], 2004. Disponível em: <<http://wwwis.win.tue.nl/ah2001/papers/wu.pdf>>. Acesso em: 05 de Junho de 2013.