

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA ELÉTRICA E DE COMPUTAÇÃO
DEPARTAMENTO DE ENGENHARIA DE COMPUTAÇÃO E AUTOMAÇÃO INDUSTRIAL

Sistemas Multiagentes em Mercados de Energia Elétrica

Tese de Doutorado

Autor: **Igor Alexandre Walter**

Orientador: **Prof. Dr. Fernando Antônio Campos Gomide**

Banca Examinadora: **Prof. Dr. Fernando Antônio Campos Gomide**
(FEEC-Unicamp)

Prof^a. Dr^a. Marley Maria Bernardes Rebuzzi Vellasco (DEE-PUC-Rio)

Prof. Dr. Paulo de Barros Correia (FEM-Unicamp)

Prof. Dr. Secundino Soares Filho (FEEC-Unicamp)

Prof. Dr. Ricardo Ribeiro Gudwin (FEEC-Unicamp)

Prof. Dr. Ivan Luiz Marques Ricarte (FEEC-Unicamp)

Tese submetida à Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas, como parte dos requisitos para obtenção do Título de Doutor em Engenharia Elétrica, com área de concentração em Engenharia de Computação.

Campinas – SP, 4 de dezembro de 2006

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA E ARQUITETURA – BAE – UNICAMP

W171s Walter, Igor Alexandre
Sistemas multiagentes em mercados de energia elétrica / Igor
Alexandre Walter. –Campinas, SP: [s.n.], 2006.

Orientador: Fernando Antônio Campos Gomide
Tese (doutorado) - Universidade Estadual de Campinas, Faculdade
de Engenharia Elétrica e de Computação.

1. Agentes inteligentes (Software). 2. Inteligência artificial
distribuída. 3. Algoritmos genéticos. 4. Sistemas difusos. 5. Energia
elétrica – Mercado. 6. Leilões. 7. Negociação. I. Gomide, Fernando.
II. Universidade Estadual de Campinas. Faculdade de Engenharia
Elétrica e de Computação. III. Título.

Título em inglês: Multiagent Systems Bidding Approach for Competitive Electricity Markets

Palavras-chave em inglês: Multiagent systems, Genetic fuzzy systems, Electricity market,
Agent-based computational economics, Auctions, Coordination strategies,
Competitive markets

Área de concentração: Engenharia de Computação

Titulação: Doutor em Engenharia Elétrica

Banca Examinadora: Marley Bernardes Rebuszi Vellasco, Paulo de Barros Correia,

Secundino Soares Filho, Ricardo Ribeiro Gudwin e Ivan Luiz Marques Ricarte

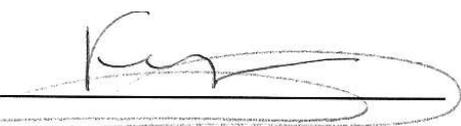
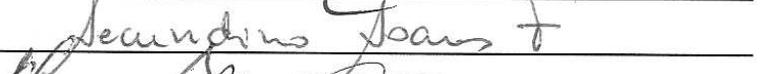
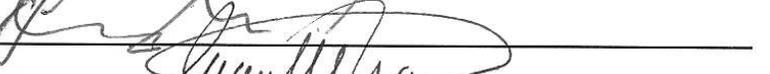
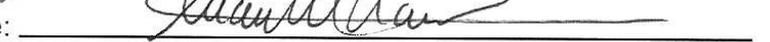
Data da defesa: 04/12/2006

Programa de Pós-Graduação: Engenharia Elétrica

Sistemas Multiagentes em Mercados de Energia Elétrica

Autor: Igor Alexandre Walter

Orientador: Fernando Antônio Campos Gomide

Prof. Dr. Fernando Antônio Campos Gomide (Presidente): 
Prof. Dra. Marley Maria Bernardes Rebuszi Vellasco: 
Prof. Dr. Paulo de Barros Correia: 
Prof. Dr. Secundino Soares Filho: 
Prof. Dr. Ricardo Ribeiro Gudwin: 
Prof. Dr. Ivan Luiz Marques Ricarte: 

Campinas, 4 de dezembro de 2006.

Resumo

Sugerimos uma abordagem evolutiva para o projeto de estratégias de interação em sistemas multiagentes, especialmente estratégias de oferta modeladas como sistemas baseados em regras nebulosas. O objetivo é a aprendizagem das estratégias de oferta em leilões em modelos em que a base de conhecimento sofre evolução para melhorar o desempenho dos agentes atuando em um ambiente competitivo. Dados para aprendizagem e otimização das estratégias são raros em ambientes competitivos como os leilões. Introduzimos um modelo de sistema genético *fuzzy* (GFS) cujos operadores genéticos utilizam uma representação de tamanho variável do cromossomo e uma relação hierárquica estabelecida através do *fitness* dos indivíduos, em um esquema que explora e explota o espaço de busca ao longo das gerações. A evolução de estratégias de interação permite a descoberta de comportamentos dos agentes previamente desconhecidos e inesperados, permitindo uma análise mais rica dos mecanismos de negociação e seu papel como protocolo de coordenação.

A aplicação da abordagem proposta no mercado de energia elétrica permite a simulação destes mercados através da evolução de estratégias de oferta (*bidding*) em leilões de energia. A reestruturação destes mercados nas economias contemporâneas apresenta novos desafios e oportunidades, uma vez que não há consenso sobre qual seria sua melhor organização. A evolução da estrutura organizacional destes mercados salienta a falta de discernimento sobre as principais questões a serem analisadas e levadas em consideração. Argumenta-se que a abordagem econômica neoclássica se mostra limitada na análise dos efeitos da reestruturação e no estudo do comportamento dos agentes econômicos competindo nos mercados de energia elétrica reestruturados. Apresentamos uma arquitetura computacional inspirada na Economia Computacional baseada em Agentes que permite a modelagem, estudo e simulação destes mercados. Aplicamos ferramentas de inteligência computacional adequadas à concepção dos agentes participantes nos mercados de energia e que podem ser estendidas a outros mecanismos de mercado e negociação.

Os mercados de energia elétrica são sistemas complexos habitados por agentes econômicos com interesse próprio que interagem entre si. Concluimos que é natural modelar e simular estes mercados como sistemas multiagentes. A evolução de estratégias de oferta permite a descoberta de comportamentos que auxiliam na tomada de decisão de um participante e na avaliação do mecanismo de negociação por parte de seus projetistas.

Abstract

We suggest an evolutionary approach to design interaction strategies for multiagent systems, focusing on strategies modeled as fuzzy rule-based systems. The aim is to learn models represented by evolving knowledge bases to achieve agents' performance improvement when playing in a competitive environment. In competitive situations data for learning and tuning are rare and rule bases must jointly evolve with the databases. We introduce an evolutionary algorithm whose operators use variable length chromosome, a hierarchical relationship among individuals through fitness, and a scheme that successively explores and exploits the search space along generations. Evolution of interaction strategies uncovers unknown and unexpected agent behaviors and allows a richer analysis of negotiation mechanisms and their role as a coordination protocol.

An application concerning an electricity market illustrates the effectiveness of the approach and allows to simulate the market through evolutionary bidding strategies. The restructuring process of power markets raises new challenges and opportunities, since there is no consensual market architecture. The evolution of the power industry organization shows a lack of insight about the issues to be addressed and taken into account. Several authors have considered the available tools based on the neoclassical economics theory a limited approach to analyze the effects of the industry restructuring and to study economical agents behavior participating in a restructured electricity market. We present Artificial Economy Multiagent System (AEMAS), a computational architecture inspired on Agent-based Computational Economics (ACE) that allows to model, study and simulate a power market. We apply Computational Intelligence tools to conceive the market agents that we expect could be extended to other negotiation environments.

A power market is a complex system populated by self interested economical agents that interact. We conclude that it is feasible to model and simulate these markets on a multiagent system based approach. The evolution of bidding strategies allows to uncover new and unexpected behaviors that help to address the negotiation mechanism analysis by its designers and to support a market player decision process.

Agradecimentos

Ao Frederico, filho querido, por aceitar minha ausência durante as horas a fio em frente ao computador.

À Claudia, amor da minha vida, pelo incentivo, principalmente na reta final.

Aos meus pais, Oswaldo e Ecléia, pelo carinho, incentivo e compreensão. A Yuri e Tatiana, queridos irmãos. Ao tio Edeimar.

Ao Fernando Gomide pela orientação acadêmica, profissional e pessoal tão valiosa em todos os momentos em que convivemos ao longo destes anos.

À banca de examinadores, pela paciência e contribuições construtivas e pertinentes.

Um agradecimento especial ao Nicola, pela amizade e pela ajuda na fase final do Doutorado. Aos comparsas Rodrigo, Naur e Gonzaga.

A Marina, Ivana, Leila, Ivette, Rachel, Gisele, Michel, Marcelo, Cynthia, afortunados colegas sob a mesma orientação.

A Miglinsk, Tomás, André Coelho, Paulo Bueno, Jacqueline, Tiago Barra, Luiz Gustavo, Rossano, Alencar, Gabriela, Helder, Romaric, Renato Cazangi, Ricardo Capitanio, e tantos outros companheiros do DCA.

Ao pessoal do COSE que sempre me acolheu muito bem: Luciana, Thyago, Marcelo Ciccogna, Manoel Henrique, Edeneser, Thaís. A Tatiane, Romis, Igor Kopcak. A Rodrigo e Paulo, pela perseverança em levar a frente a C-Flex e pela disponibilidade sempre que solicitados. A Francisco Hernandez, Fernando Colli, Adriano Jerônimo Silva, Tiago de Barros Correia, Letícia Takahashi, Fabio Zanfelicce.

Aos amigos Luiz Carlos Cunha, Leonardo Vieiralves, Rogério Oliveira, Daniela Mariuzzo, e Cláudio Quintana, sempre incentivando.

Aos professores da FEEC e em especial aos professores Secundino, Rafael, Von Zuben, Leandro, Gudwin, Ivan, Jino, André França, Paulo Valente, Ivanil e Pedro.

Aos professores Rosângela Ballini e Cid Carvalho de Souza. Aos professores do pós-graduação em Planejamento Energético Sinclair Mallet-Guy Guerra, Moacyr Trindade e Paulo de Barros Correia, que me receberam com especial atenção.

Aos professores que admirei ao longo deste longo percurso de estudante, que contribuíram na minha formação cada um a seu modo, enfrentando sempre as limitações destas paragens.

Aos professores Francisco Herrera, da Universidade de Granada, e Luis Magdalena, da Universidade de Madri, que me receberam e apoiaram durante participação na EUSFLAT 2003 em Zittau na Alemanha. Ao comitê de organização da EUSFLAT 2003 pelo *student grant* concedido para o Congresso em Zittau, Alemanha. Aos professores Frank Hoffman, e Oscar Cordón que cordialmente me receberam em 2003 em breve visita à Universidade de Dortmund e à Universidade de Granada, respectivamente.

A Toni, Clarissa e Sílvia pela força e apoio.

A Carmen, Fernando, Noêmia, Giane, Jaqueline, Washington, alunos de EA044.

Ao pessoal da BAE, em especial, Márcia Regina, Rose Meire, Raquel. Ao pessoal do SBU, em especial da BC, da BIMECC, e do CEDOC IE que sempre me atenderam com cordialidade e paciência.

Aos revisores anônimos dos artigos publicados e ao relator anônimo da FAPESP.

À FEEC, que me acolheu depois de alguns anos de ausência. À FAPESP, pelo suporte financeiro e institucional. À ANEEL que me apoiou no necessário.

E a todos os outros que não fui capaz de citar, a lista seria enorme, mas que de um modo ou de outro contribuíram para que chegasse até aqui.

in memoriam Rolf Walter,
querido Opapa.

in memoriam Vitor Negrete

à Claudia

Este trabalho contou com suporte financeiro da FAPESP – Fundação de Amparo à Pesquisa do Estado de São Paulo, através de bolsa de Doutorado, processo FAPESP número 01/13568-8.

Os dados apresentados nesta tese foram obtidos a partir de fontes públicas e procuram respeitar o sigilo industrial das empresas a que se referem. São apresentados como ilustração de sistemas reais e não devem servir para análise de investimentos e risco. Nenhum dos dados apresentados foi fornecido por qualquer uma das empresas citadas nem advém de consultas às empresas ou de qualquer outra fonte interna.

Na produção deste trabalho foi utilizado preferencialmente *software* livre. Quando o uso de *software* livre não foi possível ou conveniente, foi utilizado algum programa comercial adquirido pela Unicamp ou de uso privado, devidamente registrado.

Sumário

SUMÁRIO	xv
LISTA DE FIGURAS	xxi
LISTA DE TABELAS	xxiv
1 Introdução	1
1.1 Motivação	3
1.2 Relevância	3
1.3 Objetivos	3
1.4 Organização	4
2 Sistemas Multiagentes	5
2.1 Inteligência Computacional	5
2.1.1 Sistemas Nebulosos	5
2.1.2 Computação Evolutiva	5
2.1.3 Sistemas <i>Fuzzy</i> Genéticos	7
2.2 Teoria de Agentes	8
2.3 Sistemas Multiagentes	8
2.3.1 Mecanismos de Interação	9
2.3.2 Negociação	10
2.3.3 Comunicação	11
2.3.4 Padronização	12
2.3.5 Aprendizado Multiagentes	13
2.4 Projeto de Sistemas Multiagentes	13

2.4.1	Desenvolvimento Ágil Orientado a Agentes	14
2.5	Aplicações de Sistemas Multiagentes	15
2.5.1	Mercado de Energia Elétrica	16
2.5.2	Comércio Eletrônico	16
2.5.3	Sistemas de Potência	17
2.5.4	Defesa	18
2.5.5	Meio Ambiente	19
3	Modelos de Mercado	21
3.1	Leilões	21
3.2	Classificação de Leilões	22
3.2.1	Natureza	22
3.2.2	Forma de Oferta dos Lances	23
3.2.3	Preço de Fechamento	24
3.2.4	Taxonomia	25
3.3	Parametrização de Leilões	26
3.3.1	Atividades Essenciais	26
3.4	Leilões <i>Online</i>	27
3.5	Leilões em Inteligência Artificial	28
3.5.1	Leilões Combinatórios	28
3.6	Aplicações	28
3.7	Economia Computacional Baseada em Agentes	30
3.7.1	Mercados de Eletricidade Baseados em Agentes	30
3.8	Programação Orientada a Mercados	30
3.8.1	Programação Orientada a Mercados em Sistemas de Energia Elétrica	31
3.9	Projeto de Mecanismos	31
3.9.1	Projeto Evolutivo de Mecanismos	31
4	Mercado de Energia Elétrica	33
4.1	Introdução	33
4.1.1	Agentes no Mercado Brasileiro	34
4.2	Mecanismos de Formação de Preços	35

4.2.1	O Despacho Hidrotérmico por Custos	36
4.3	Leilão de Energia Elétrica	37
4.3.1	Protocolo do Leilão a Preço Uniforme	38
4.3.2	Algoritmo de Formação de Preço	39
4.3.3	Definição do Instrumento de Oferta	41
4.3.4	Equacionamento das Funções de Custo e Lucro	44
4.4	Mercado Financeiro	47
4.4.1	Contratatação Bilateral	48
4.5	Regulação do Mercado de Energia	51
5	Sistemas Multiagentes no Mercado de Eletricidade	53
5.1	Introdução	53
5.2	Sistemas Multiagentes na Síntese de Economias Artificiais	53
5.2.1	Arquitetura Multiagentes de Mercado	54
5.3	Instâncias da Arquitetura AEMAS	57
5.3.1	Mercado de Energia Elétrica	57
5.3.2	Modelo AEMAS do Despacho Centralizado	59
5.3.3	Modelo AEMAS do Leilão de Energia	60
5.4	Pesquisa Relacionada	62
6	Estratégias Inteligentes de Mercado	65
6.1	Introdução	65
6.2	Estratégias de Oferta Evolutivas	65
6.2.1	Estratégias de Oferta em Mercados de Energia	66
6.2.2	Pesquisa Relacionada	67
6.3	Estratégia Baseada em Sistema <i>Fuzzy</i> Genético	69
6.3.1	Representação do Cromossomo	70
6.3.2	Operadores Genéticos	73
6.3.3	Seleção	73
6.3.4	Crossover da Base de Dados	74
6.3.5	Crossover da Base de Regras	76
6.3.6	Mutação	78

6.3.7	Algoritmo Evolutivo	82
6.3.8	Função de <i>Fitness</i>	82
7	Estratégias Inteligentes de Oferta: Aplicação no Mercado de Energia	85
7.1	Ambiente e Modelo do Sistema	85
7.1.1	Características de Demanda	86
7.1.2	Função de Custo Operacional	86
7.1.3	Leilão a Preço Uniforme	86
7.2	Configuração de Mercado	88
7.3	Resultados	91
7.4	Experimento 1: Lance de Preço	91
7.5	Experimento 2: Lance de Preço e Quantidade	94
7.6	Experimento 3: Lance de Preço e Quantidade	98
7.7	Lance de Quantidade	99
7.7.1	Experimento 4	99
7.8	Mercado Hidrotérmico	103
7.8.1	Experimento 5	103
7.9	Oferta com Múltiplos Lances	106
7.10	Conclusão	109
8	Estratégias de Oferta: Previsão de Preço e Aprendizagem por Reforço	111
8.1	Aquisição de Informação: Estratégias com Previsão	111
8.1.1	Dados de Treinamento e Teste	112
8.1.2	Resultados	114
8.1.3	Conclusão e Investigação Futura	124
8.2	Aprendizagem por Reforço no Leilão de Energia	124
8.2.1	Ambiente de Simulação	126
8.2.2	Agentes Inteligentes	126
8.2.3	Estratégia de Oferta	127
8.2.4	Aprendizado	129
8.2.5	Resultados	132
8.2.6	Conclusão	133

8.2.7	Pesquisa Futura	133
9	Conclusão	135
9.1	Perspectivas Futuras	137
A	Diagramas de Classes UML	139
B	Implementação da Arquitetura AEMAS em FIPA-OS	145
B.1	Implementação em FIPA-OS	145
B.1.1	Protótipo FIPA-OS	145
B.1.2	Inicialização da Plataforma FIPA-OS	145
B.1.3	Inicialização do Auctioneer	146
B.1.4	Inicialização de um Agente	146
B.1.5	Descrição de um Agente	147
B.1.6	Inscrição de um Agente no Leilão	147
B.1.7	Mensagem de Busca do Mercado	147
B.1.8	Abertura do Leilão	149
B.1.9	<i>Call for Proposals</i>	149
B.1.10	Submissão de Propostas	151
B.1.11	Modelagem do Conteúdo das Mensagens	152
C	Programação Neurodinâmica	155
C.1	Programação Neurodinâmica	155
C.1.1	Processo de Decisão Markoviano	155
C.1.2	Critério de Otimalidade de Bellman	158
C.1.3	<i>Q-learning</i>	160
C.1.4	<i>Q-learning</i> Aproximado	162
D	Ambiente Computacional	165
D.1	<i>Hardware</i> e Sistema Operacional	165
D.2	Ambiente de Desenvolvimento	165
D.2.1	Plataforma de Desenvolvimento	166
D.3	Ambiente de Editoração	166

E Nomenclatura	167
E.1 Acrônimos	167
Referências Bibliográficas	169

Lista de Figuras

2.1	Diagrama de atividades UML do algoritmo genético.	6
2.2	Agente de Russel e Norvig.	8
2.3	Taxonomia dos mecanismos de coordenação.	10
3.1	Taxonomia hierárquica de leilões.	25
4.1	Atividades no leilão de energia.	38
4.2	Ordem de mérito de leilões de energia.	39
4.3	Lucro de Argentina II para diferentes preços (em R\$/h).	45
4.4	Lucro de Argentina II para diferentes geradores marginais.	46
4.5	Lucro de Argentina II para diferentes geradores marginais.	46
5.1	Arquitetura AEMAS.	55
5.2	Instância AEMAS de um sistema de potência sob despacho centralizado.	58
5.3	Instância AEMAS de um mercado de energia <i>loose pool</i>	60
5.4	Arquitetura de MASCEM	63
6.1	Esquema de representação do cromossomo dos indivíduos do GFRBS.	70
6.2	Partição nebulosa <i>forte</i> com funções de pertinência trapezoidais.	72
6.3	Bases de regras de dois indivíduos selecionados para reprodução.	77
6.4	<i>Crossover</i> dos antecedentes e conseqüentes de dois indivíduos.	77
6.5	Bases de regras de dois indivíduos após <i>crossover</i>	78
6.6	Bases de regras da prole de dois indivíduos.	78

6.7	Exemplo de <i>crossover</i> da base de regras.	79
7.1	Perfil horário da demanda da região Sul.	85
7.2	Curva de oferta agregada.	89
7.3	Estratégia de oferta sob a ótica da arquitetura AEMAS.	90
7.4	Evolução do <i>fitness</i> para população de 24 indivíduos, $N = 1, M = 1$	91
7.5	Preço horário para as estratégias conservadora e GFRBS, $N = 1, M = 1$	93
7.6	Lucro para as estratégias conservadora e GFRBS, $N = 1, M = 1$	94
7.7	Evolução do <i>fitness</i> para população de 24 indivíduos, com $N = 1, M = 2$	96
7.8	Lucro de duas estratégias GFRBS, $N = 1, M = 2$	98
7.9	Evolução do <i>fitness</i> para população de 24 indivíduos, lance de quantidade.	99
7.10	Quantidade despachada estratégias conservadora e GFRBS, lance de quantidade.	100
7.11	Preço horário para estratégias conservadora e GFRBS, lance de quantidade.	100
7.12	Lucro para estratégias conservadora e GFRBS, lance de quantidade.	101
7.13	Custo global energia para estratégias conservadora e GFRBS, experimentos 1 e 4.	101
7.14	Preço da energia e lance de Itumbiara para a estratégia GFRBS	103
7.15	Preço da energia e quantidade despachada de Itumbiara para a estratégia GFRBS	104
7.16	Determinação da quantidade e preço de múltiplos lances.	107
7.17	Variação do preço segundo número de lances por agente.	108
8.1	Sistema genético baseado em regras nebulosas com previsão de preços.	111
8.2	Dados de treinamento da rede neural: demanda e preço normalizados.	113
8.3	Dados de treinamento do GFRBS: demanda e preço normalizados.	113
8.4	Dados de teste do GFRBS: demanda e preço normalizados.	114
8.5	Teste da rede MLP com 1 entrada.	115
8.6	Evolução do <i>fitness</i>	116
8.7	Preço de oferta da energia no período de teste.	117
8.8	Potência despachada no período de teste.	117

8.9	Preço de oferta e potência despachada “GFRBS”.	118
8.10	Preço de oferta e potência despachada “GFRBS+MLP”.	119
8.11	Preço <i>spot</i> e de oferta “GFRBS”.	119
8.12	Preço <i>spot</i> e de oferta “GFRBS+MLP”.	120
8.13	Preço <i>spot</i> no período de teste.	120
8.14	Receita, custo e lucro “GFRBS”.	121
8.15	Receita, custo e lucro “GFRBS+MLP”.	122
8.16	Receita “GFRBS” vs. “GFRBS+MLP”.	122
8.17	Custo “GFRBS” vs. “GFRBS+MLP”.	123
8.18	Lucro “GFRBS” vs. “GFRBS+MLP”.	123
8.19	Função de decremento relativo σ em função de B_r/D .	126
8.20	Curva de oferta do agente inteligente (em $R\$/MW$).	128
8.21	Curva de oferta dos competidores.	130
8.22	Saída da rede MLP, entradas: <i>bid</i> e variação de preço, saída: <i>bid</i> competidor.	132
A.1	Diagrama de classes do protótipo AEMAS em FIPA-OS.	139
A.2	Protocolo de iterações no leilão fechado.	140
A.3	Diagrama de classes do conteúdo das mensagens ACL de <i>CFP</i> e <i>Proposal</i> .	141
A.4	Diagrama de classes do simulador do leilão de energia.	142
A.5	Diagrama das classes dos agentes participantes no leilão de energia.	143
C.1	Diagrama de blocos de um agente interagindo com o ambiente.	155
C.2	Rede neural para aproximar a função J^* .	160
C.3	Layout de rede neural para aproximar o fator-Q $Q^{alvo}(i, a, \mathbf{w})$.	163

Lista de Tabelas

2.1	Protocolos de Interação FIPA.	12
3.1	Relação entre vendedores e compradores conforme natureza dos leilões.	22
4.1	Caracterização do mercado de energia elétrica.	34
4.2	Ofertas de preço em uma determinada hora h	40
4.3	Resultado do algoritmo de formação de preço para hora h	41
4.4	<i>Bid</i> múltiplo do agente Canoas.	41
4.5	Ordem das ofertas de preço em uma determinada hora h para múltiplos lances.	42
4.6	Resultado do algoritmo de formação de preço na hora h para múltiplos lances.	43
4.7	Exemplo de termoeletricas remodeladas com custos quadráticos.	44
4.8	Exemplo de contratação bilateral no mercado brasileiro.	49
7.1	Configuração de mercado: características das termoeletricas.	87
7.2	Funções de custos das termoeletricas.	88
7.3	Comparação dos resultados entre estratégias de oferta conservadora e GFRBS	92
7.4	Competição entre duas estratégias GFRBS, $N = 1, M = 1$	95
7.5	Experimento 2: competição entre duas estratégias GFRBS, $N = 1, M = 2$	97
7.6	Experimento 3: competição entre duas estratégias GFRBS, $N = 1, M = 2$	98
7.7	Comparação resultados estratégias conservadora e GFRBS, lance de quantidade.	99
7.8	Características das usinas hidrelétricas em mercado hidrotérmico.	103
7.9	Regra para agente hidrelétrico <i>smart</i>	106
8.1	Erros resultantes do teste da rede MLP 12-3-1 com 1 entrada.	114
8.2	Dados de geração do agente inteligente CHESF.	127
8.3	Dados de oferta do agente inteligente CHESF.	128
8.4	Dados de geração dos agentes competidores.	129

8.5	Dados de oferta dos agentes competidores.	130
B.1	Mensagens de inicialização do AMS e do DF na plataforma FIPA-OS.	146
B.2	Mensagens de inicialização do Auctioneer no protótipo em FIPA-OS.	146
B.3	Mensagens de inicialização do agente ArgentinaII no protótipo em FIPA-OS.	146
B.4	Descrição do agente ArgentinaII no DF do protótipo em FIPA-OS.	147
B.5	Inscrição do agente ArgentinaII no mercado gerenciado por EnergyAuctioneer.	148
B.6	Mensagem recebida pelo DF	148
B.7	Mensagem do DF de concordância com a busca pelo mercado.	149
B.8	Mensagem de resposta do DF contendo resultado da busca.	150
B.9	Mensagens de abertura do leilão enviadas a sete agentes.	151
B.10	Mensagens de CFP (<i>Call for Proposals</i>) enviadas a sete agentes.	152
B.11	Mensagens de resposta às CFP's.	153

Capítulo 1

Introdução

*A ciência excitada
Fará o sinal da cruz
E acenderemos fogueiras
Para apreciar a lâmpada elétrica.*
Tom Zé.

A abrangência da Tecnologia da Informação e Comunicação¹ tem acarretado mudanças socioeconômicas importantes e proporcionam a possibilidade de mudanças ainda mais profundas. Em um cenário futuro, agentes de *software* seriam capazes de negociar produtos e serviços, não somente em nome de suas contrapartes humanas mas entre si, constituindo uma Economia da Informação (Hanson 2001). Neste contexto é necessário estudar o comportamento dos agentes de *software*, com interesse próprio e certo poder computacional, com o objetivo de avaliar os resultados que emergem da interação entre os agentes participantes nesta nova economia.

Um cenário intermediário entre o atual estágio de comércio eletrônico e esta Economia da Informação que também deve ser considerado e estudado é aquele onde agentes de *software* auxiliam no comércio eletrônico em nome de suas contrapartes humanas, quer sejam estas um consumidor ou uma organização. Os agentes de *software* são capazes de coletar informações, avaliar propostas, engajar-se em negociações e aumentar a eficiência econômica das relações comerciais. Neste contexto, podem auxiliar na tomada de decisão das partes envolvidas e na sua intermediação (Greenwald, Jennings & Stone 2003).

Conscientes da importância dos agentes de *software* nos mercados eletrônicos, tomamos o mercado de energia elétrica como exemplo prático de aplicação e experimentação. A reestruturação da indústria de energia elétrica no Brasil e em boa parte dos países ocidentais apresenta novos desafios e oportunidades, uma vez que não há consenso sobre qual seria sua melhor organização. Este é um processo contínuo e dinâmico onde cada decisão a ser tomada expõe limitações na capacidade

¹ICT, *Information and Communication Technology*.

de lidar com os novos desafios e aproveitar as oportunidades para atingir melhor eficiência, menores custos e reduzir o impacto ambiental (Rudnick 1996). A evolução da estrutura organizacional da indústria salienta uma lacuna de ferramentas para melhor análise e discernimento sobre as questões levantadas e, além disso, as consequências de escolhas estruturais equivocadas podem ser dramáticas (Bagnall & Smith 2005).

A modelagem econômica convencional mostra-se uma abordagem limitada para a análise dos efeitos da reestruturação e o estudo do comportamento dos agentes econômicos competindo em um mercado de energia elétrica reestruturado. As ferramentas disponíveis baseadas na teoria econômica neoclássica tendem a apresentar versões agregadas e muito simplificadas destes mercados que são, em geral, caracterizados por um oligopólio de geradores, pouca elasticidade da demanda no curto prazo e mecanismos de funcionamento complexos (Harp, Brignone, Wollenberg & Samad 2000, Bunn & Oliveira 2001).

Inspirados na Economia Computacional baseada em Agentes (Tsfatsion 2002, Tsfatsion & Judd 2006) e na Programação Orientada a Mercados (Wellman 1993) apresentamos uma arquitetura multiagentes suficientemente genérica que permite a simulação de diferentes estruturas de mercado constituindo uma ferramenta de análise e apoio à tomada de decisão nestes ambientes. É uma abordagem baseada em Sistemas Multiagentes onde os agentes de *software* que representam agentes econômicos com interesse próprio constituem um mercado artificial que pode ser simulado para enriquecer a análise e o projeto de estruturas alternativas de um mercado real.

Tomando um modelo do mercado de energia elétrica como instância da arquitetura sugerida, estudamos o comportamento dos agentes econômicos participando no mercado de energia elétrica, fornecendo subsídios para a simulação do seu funcionamento através de mecanismos de negociação baseados em leilões. Propomos a utilização de ferramentas de inteligência computacional adequadas à concepção das estratégias de coordenação dos agentes participantes no mercado de energia elétrica. Acreditamos que a abordagem apresentada pode ser estendida a outros mecanismos de mercado e de negociação como aqueles contemplados em uma Economia da Informação e outros cenários de comércio eletrônico.

Deste modo, através do estudo, análise, modelagem e simulação do mercado de energia deseja-se aprimorar o uso da inteligência computacional na construção de ambientes de negociação eletrônica como os leilões eletrônicos sugerindo uma abordagem baseada em Sistemas Multiagentes. Esta abordagem se justifica duplamente: os mercados modelados são em geral resultado da interação de múltiplos agentes econômicos com interesse próprio, em especial o de maximizar sua utilidade e, portanto, é natural modelar e simular estes mercados através de uma abordagem multiagentes; por outro lado, os mercados e em especial os mecanismos de leilão, são protocolos de interesse na coordenação de sistemas multiagentes. Esta computação baseada em mecanismos de mercado é especialmente útil na solução de problemas complexos e distribuídos, onde a Economia é a inspiração

para o desenvolvimento de algoritmos de resolução de problemas, mimetizando modelos de mercado, em paralelo à computação inspirada na natureza que mimetiza processos naturais.

1.1 Motivação

Definir um mecanismo de coordenação é uma decisão de projeto essencial em sistemas inteligentes distribuídos pois o mecanismo caracteriza as propriedades de uma coleção de agentes atuando em um ambiente comum. Sugerimos um sistema genético baseado em regras nebulosas (GFRBS) como abordagem para o projeto de estratégias de coordenação com foco nas estratégias de oferta em ambientes competitivos.

O mercado de energia elétrica é um sistema composto por vários agentes econômicos que interagem entre si e portanto é natural modelá-lo como um sistema multiagentes. Os agentes de *software* representam modelos dos agentes econômicos e sua interação se dá através de uma interface bem definida: os mecanismos de negociação.

A evolução de estratégias de oferta permite a descoberta de comportamentos inesperados e previamente desconhecidos dos agentes, levando ao enriquecimento da análise de mecanismos de leilão e do papel destes como protocolo de coordenação em sistemas multiagentes. A estratégia de oferta nebulosa sugerida permite lidar com incertezas e o sistema genético baseado em regras nebulosas mostra-se uma abordagem sistemática para evoluir estratégias de oferta.

1.2 Relevância

A relevância deste trabalho advém da importância dos leilões como mecanismo de alocação de recursos e formação de preço, em especial os leilões de energia. A abordagem sugerida complementa uma lacuna de ferramentas para a tomada de decisão no projeto de mercados de energia elétrica. É evidente a importância econômica do comércio eletrônico e dos mecanismos de negociação em ambientes de mercado, para os quais esperamos estender a *expertise* adquirida com a aplicação da abordagem baseada na Inteligência Artificial Distribuída no mercado de energia.

1.3 Objetivos

Apresentamos resumidamente os objetivos deste trabalho:

- Estabelecer uma abordagem de projeto de estratégias de interação em mercados;

- Estudar diferentes técnicas de aprendizagem de agentes inteligentes em ambientes de mercado;
- Estabelecer uma arquitetura de modelagem de mercados baseada em sistemas multiagentes;
- Simular o mercado de energia através da modelagem baseada em sistemas multiagentes.

1.4 Organização

No Capítulo 2 descrevemos os sistemas multiagentes e exemplificamos algumas de suas aplicações. Neste capítulo também tratamos resumidamente de descrever o papel de alguns métodos de Inteligência Computacional na construção de agentes inteligentes.

No Capítulo 3 apresentamos os modelos de mercado mais relevantes ao foco deste trabalho, em especial os leilões. No Capítulo 4 apresentamos o mercado de energia elétrica com especial atenção ao modelo brasileiro que vem passando por mudanças estruturais desde a década de 90, acompanhando as reformas realizadas em outros países.

No Capítulo 5 apresentamos uma proposta de arquitetura para a modelagem de economias artificiais através da abordagem baseada em Sistemas Multiagentes. Já no Capítulo 6 detalhamos a principal contribuição no projeto automatizado de estratégias de oferta como ferramenta de apoio à tomada de decisão e nos Capítulos 7 e 8, apresentamos resultados de sua aplicação em uma instância simplificada do mercado de energia elétrica. No Capítulo 9 traçamos as principais conclusões e estabelecemos perspectivas futuras de pesquisa.

No Apêndice A reunimos os diagramas UML referenciados ao longo do texto. No Apêndice B exemplificamos um protótipo construído em uma plataforma multiagentes, fonte de inspiração e prova conceitual da arquitetura delineada no Capítulo 5. No Apêndice C revisamos a Programação Neurodinâmica e o algoritmo de *Q-learning*² utilizado para modelar a aprendizagem por reforço de agentes no leilão de energia tratada na seção 8.2.

No Apêndice D descrevemos o ambiente computacional utilizado na implementação deste trabalho e no Apêndice E apresentamos a descrição dos principais acrônimos utilizados.

²Uma vez que a revisão da Programação Neurodinâmica não é fundamental para o entendimento deste trabalho, a título de organização do texto foi inserida como apêndice.

Capítulo 2

Sistemas Multiagentes

*Everybody get around
'cause we're gonna play a game called Simon says
If Simon says you do it
and you stay in the game
Jimi Hendrix*

2.1 Inteligência Computacional

Nesta seção abordamos parte da Inteligência Computacional que mais interessa ao desenvolvimento dos capítulos seguintes, especialmente os sistemas nebulosos, a computação evolutiva e os sistemas *fuzzy* genéticos¹.

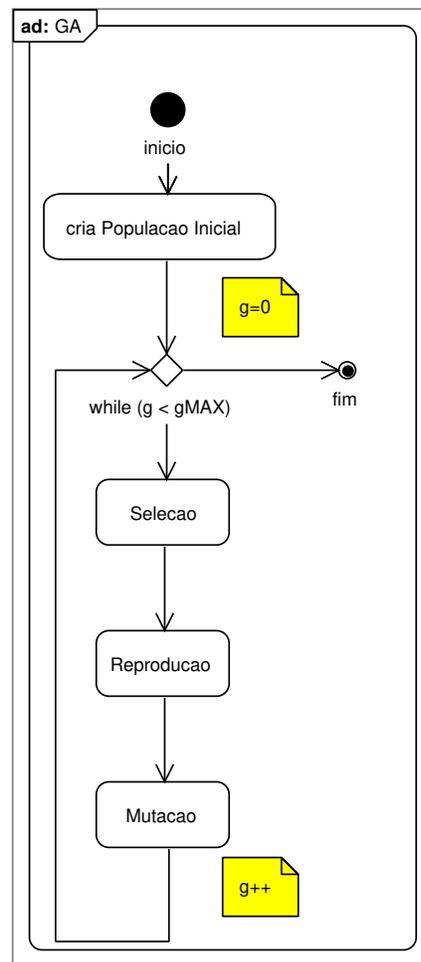
2.1.1 Sistemas Nebulosos

Os sistemas nebulosos representam uma importante ferramenta de modelagem baseada na teoria dos conjuntos nebulosos. Têm sido aplicados com sucesso em diversas áreas como: controle, classificação e reconhecimento de padrões, suporte à tomada de decisão, sistemas inteligentes, previsão de séries temporais e robótica (Jang, Sun & Mizutani 1997).

2.1.2 Computação Evolutiva

Definição 1 *Os algoritmos genéticos são algoritmos estocásticos de busca inspirados na genética natural para evoluir as soluções de um problema.*

¹Outra área relevante de aplicação da Inteligência Computacional no projeto de agentes inteligentes é a abordagem através dos sistemas classificadores, originalmente proposta por Holland (1986). Uma visão recente e abrangente dos sistemas classificadores é apresentada por Vargas (2005).



Created with Poseidon for UML Community Edition. Not for Commercial Use.

Figura 2.1: Diagrama de atividades UML do algoritmo genético.

O diagrama de atividades UML da Figura 2.1 ilustra o funcionamento do algoritmo genético.

2.1.3 Sistemas *Fuzzy* Genéticos

Um sistema *fuzzy* genético (GFS, *Genetic Fuzzy System*) é basicamente um sistema nebuloso adicionado de um processo de aprendizado baseado em um algoritmo genético. O ponto principal neste tipo de abordagem é a geração da base de conhecimento através de um processo automático de otimização ou de busca.

O GFS mais abrangente é o sistema genético baseado em regras nebulosas (*Genetic Fuzzy Rule-Based System*, GFRBS). Neste tipo de abordagem o primeiro passo é decidir quais partes da base de conhecimento vão estar sujeitas ao processo de otimização do algoritmo genético (Cordón, Herrera, Hoffman & Magdalena 2001) Este tipo de decisão depende de dois objetivos conflitantes, a granularidade e a eficiência da busca. Daí a importância de se distinguir os problemas de ajuste e de aprendizado.

2.1.3.1 Aprendizagem da Base de Conhecimento

O aprendizado da base de conhecimento de um sistema baseado em regras nebulosas envolve o aprendizado da base de dados (especificação dos universos de discurso e o número de termos de cada variável linguística bem como a função de pertinência associada à cada termo) e a determinação de uma base de regras (especificação do número de regras e composição de cada regra).

Há diferentes abordagens na evolução da base de conhecimento (base de dados + base de regras) de um sistema baseado em regras nebulosas:

- Aprendizado da base de regras utilizando uma base de dados pré-definida.
- Ajuste das funções de pertinência para uma base de regras pré-definida.
- Aprendizado simultâneo dos componentes da base de conhecimento.
- Derivação da base de conhecimento pelo aprendizado prévio da base de dados.
- Abordagem coevolutiva.

A abordagem coevolutiva é descrita em (Delgado 2002) e as outras abordagens são descritas e exemplificadas em diversos trabalhos como (Cordón, Herrera & Villar 2001, Cordón, Herrera, Hoffman & Magdalena 2001). Uma revisão do desenvolvimento recente no campo de sistemas *fuzzy* genéticos é encontrada em (Cordon, Gomide, Herrera, Hoffman & Magdalena 2004).

2.2 Teoria de Agentes

Definição 2 *Agentes são entidades de software que funcionam continuamente e de maneira autônoma em um ambiente freqüentemente co-habitado por outros agentes e processos (Shoham 1997).*

Definição 3 *Agente inteligente: sistema computacional **situado** em algum ambiente, capaz de agir de maneira **autônoma** e **flexível** para cumprir seus objetivos de projeto. (Wooldridge & Jennings 1995)*

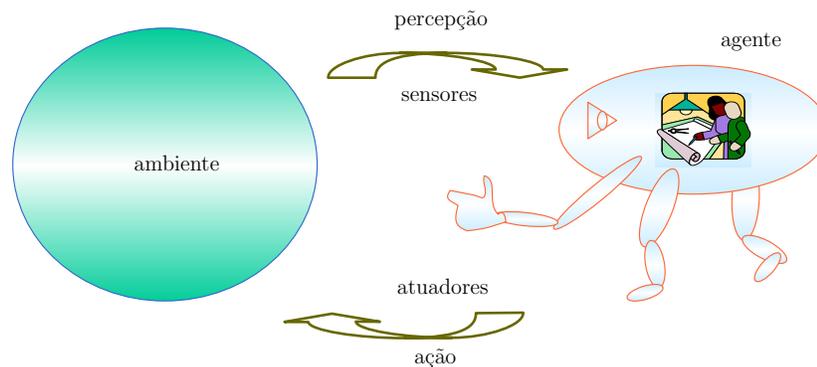


Figura 2.2: Agente de Russel e Norvig (Russel & Norvig 2004).

Estar situado em um ambiente significa receber entradas sensoriais através dos sensores e tomar ações através de atuadores que de algum modo procuram mudar o ambiente. Esta definição se assemelha àquela de Russel & Norvig (2004) bastante difundida e representada pictoricamente na Figura 2.2. A autonomia e a flexibilidade se traduzem resumidamente por:

- Autonomia: controle sobre estado interno e sobre o próprio comportamento
- Flexibilidade
 - Reatividade: responder prontamente a mudanças no ambiente
 - Pró-atividade: agir em antecipação com vistas a objetivos futuros e iniciativa
 - Sociabilidade: ser capaz de interagir para resolver problemas

2.3 Sistemas Multiagentes

Segundo (Jennings, Sycara & Wooldridge 1998), agentes e sistemas multiagentes representam uma nova forma de analisar, projetar e implementar sistemas de software complexos. Inteligência artificial distribuída (DAI, de *Distributed Artificial Intelligence*) é o estudo e a construção de

sistemas compostos de entidades inteligentes que interagem entre si. É comum na literatura dividir a inteligência artificial distribuída em dois grandes domínios, a resolução distribuída de problemas (DPS, de *distributed problem solving*) e os sistemas multiagentes (MAS, de *multiagent systems*).

No domínio da resolução distribuída de problemas o projetista do sistema pode assumir hipóteses quanto ao comportamento dos agentes que têm um objetivo comum: resolver o problema em questão. Já em sistemas multiagentes, têm-se, em geral, a interação entre agentes com interesse próprio e que não têm necessariamente algum objetivo em comum.

As abordagens baseadas em Sistemas Multiagentes podem melhorar nossa habilidade para conceber, desenvolver e construir sistemas de *software* complexos e distribuídos. Segundo (Jennings, Sycara & Wooldridge 1998), a abordagem baseada em agentes de *software* proporciona maior produtividade, confiabilidade e menor necessidade de manutenção do *software*.

2.3.1 Mecanismos de Interação

Definição 4 *Interação*

Genericamente tudo que ocorre entre agentes (interação agente-agente) e entre agentes e o ambiente (interação agente-ambiente).

A interação entre agentes é necessária para atingir objetivos individuais dos agentes e gerenciar interdependências. Conceitualmente a interação acontece no nível do conhecimento, através da definição dos objetivos, da temporalidade da interação, e dos sujeitos envolvidos. Para se obter uma resposta flexível aos eventos interativos, necessária em tempo de execução, através das abordagens tradicionais, os comportamentos desejados dos agentes são, em geral, codificados explicitamente (*hard-wired*) no código do agente de *software* em tempo de projeto.

Definição 5 *Coordenação*

Refere-se ao estado de uma comunidade de agentes no qual ações dos agentes se ajustam adequadamente umas às outras, bem como ao processo de atingir este estado.

Considerável atenção em inteligência artificial distribuída é voltada à coordenação como forma específica de interação. O grau de coordenação de um sistema multiagentes é a extensão na qual os agentes evitam atividades inadequadas reduzindo a contenção de recursos, evitando *livelock* e *deadlock*, e mantendo condições de segurança. Huhns & Stephens (1999) apresentam uma taxonomia dos mecanismos de coordenação, apresentada na Figura 2.3. Manifestações de coordenação especialmente importantes em DAI são a competição e a cooperação. Competição é coordenação entre agentes movidos por interesse próprio. Já na cooperação os agentes trabalham em prol de um objetivo comum.

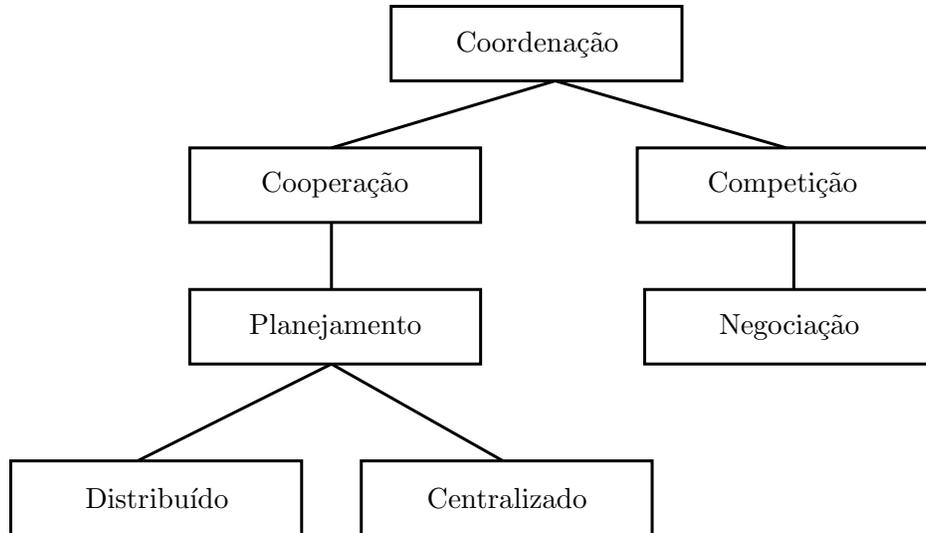


Figura 2.3: Taxonomia dos mecanismos de coordenação (Huhns & Stephens 1999).

Definição 6 *Competição*

Coordenação entre agentes na qual o sucesso de um (agente) participante implica na falha dos outros.

Definição 7 *Cooperação*

Coordenação entre agentes não antagônicos.

2.3.2 Negociação

Definição 8 *Negociação*

Interação entre agentes através de comunicação com o propósito de chegar a um acordo.

Negociação está relacionada com a resolução distribuída de conflitos e tomada de decisão distribuída. Requer que os agentes utilizem uma linguagem comum (e.g. ACL, *agent communication language*). Durante a negociação um agente faz uma proposta que é então comentada (e.g. refinada, criticada, refutada) pelo(s) outro(s) agente(s). Negociação pode ser interpretada como coordenação entre agentes competitivos ou simplesmente agentes “egoístas” (com interesse próprio ou *self interested*). Outra interpretação de negociação é vê-la como uma busca distribuída, baseada na comunicação, e no espaço de soluções possíveis.

Há várias outras definições possíveis na literatura de negociação e uma que se apresenta suficientemente concisa é definir negociação como (Jennings, Parsons, Sierra & Faratin 2000) um

processo pelo qual um grupo de agentes se comunica para tentar encontrar um acordo mútuo em alguma matéria. Negociação dá suporte às tentativas de cooperar e coordenar (entre agentes artificiais e humanos) e é necessária quando os agentes são egoístas e quando são cooperativos. É de central importância porque os agentes são autônomos. Para que um agente influencie um “conhecido” (*acquaintance*) é necessário que o “conhecido” seja convencido de que deve agir em algum modo particular. A maneira de chegar a isto é através de propostas, da discussão de opções, e da oferta de concessões, esperando chegar a um acordo mútuo. Ou seja, negociando.

2.3.2.1 Parametrização de Mecanismos de Negociação

Lomuscio, Wooldridge & Jennings (2003) apresentam um esquema de classificação dos mecanismos de negociação automatizada que representa uma parametrização do espaço de possíveis mecanismos². Parametrização semelhante, considerando o espaço de possíveis mecanismos de leilão, é apresentada em (Wurman, Wellman & Walsh 2001). Apesar dos leilões serem também mecanismos de negociação, a classificação de (Lomuscio, Wooldridge & Jennings 2003) trata não somente destes mas dos mecanismos de negociação em geral.

2.3.3 Comunicação

Um sistema multiagentes provê, através de componentes de *software*, a infra-estrutura necessária para uma linguagem de comunicação entre agentes e um canal de comunicação. A linguagem de comunicação entre agentes serve à comunicação interagentes e se dá em geral através de um conjunto de ações expressas por palavras-chave performativas³ de alto nível. Uma primeira linguagem deste tipo é KQML (*Knowledge Query and Manipulation Language*). Após sua implementação e utilização em diversas aplicações, foram evidenciadas algumas idiossincrasias e surgiram novas linguagens de comunicação entre agentes (ACL, *Agent Communication Language*), em especial FIPA-ACL, parte do padrão FIPA (*Foundation for Intelligent Physical Agents*) discutido na Seção 2.3.4.

De alguma maneira, para se efetivar a comunicação entre os agentes é necessário prover um canal de comunicação (serviço de transporte) que pode ser baseado em Java, como JMS (*Java Messaging System*) e Java RMI (*Remote Method Invocation*), baseado nos padrões OMG, como CORBA IIOP e CORBA RMI, baseado em TCP/IP como SMTP, XML sobre HTTP e WAP (*Wireless Access Protocol*), ou ainda baseado em outros sistemas de mensagens proprietários.

²Em (Lomuscio, Wooldridge & Jennings 2001) os autores apresentam a mesma classificação considerando a análise de uma gama ampliada de mecanismos.

³Performativo (da Lingüística): diz-se de verbo cujo emprego numa sentença cria uma força ilocucionária pela qual a enunciação da sentença em questão representa o ato descrito no verbo (e.g.: declarar, solicitar, prometer).

2.3.4 Padronização

FIPA tem por objetivos promover o desenvolvimento de especificações de tecnologias de agentes genéricas e maximizar a interoperabilidade entre aplicações baseadas em agentes. As especificações FIPA são normativas e são produzidas através de um ciclo de vida que depende de aprovação do conselho (*board*) da organização.

As especificações FIPA provêm padrões para, entre outros: plataforma de agentes, linguagem de comunicação entre agentes (ACL), linguagem de conteúdo (*Content Language*) e protocolos de interação. A especificação da plataforma de agentes (ou plataforma multiagentes) define: padrões para a infraestrutura necessária para a operação dos agentes, um modelo de referência de agentes e o ciclo de vida dos agentes. A especificação da ACL define a linguagem de performativas para codificar as mensagens de comunicação entre os agentes (ver Seção 2.3.3). Estas mensagens são atos comunicativos baseadas na teoria dos atos de fala⁴ (Huhns & Stephens 1999).

A linguagem de conteúdo por sua vez é a linguagem para se codificar o conteúdo das mensagens, sendo o conteúdo a parte da mensagem dependente do domínio de aplicação do sistema multiagentes. O padrão FIPA provê um conjunto de referências de linguagens de conteúdo: FIPA SL (*Semantic Language*), FIPA CCL (*Constraint Choice Language*), FIPA KIF (baseada em *Knowledge Interchange Format*) e FIPA RDF (baseada em *Resource Description Framework*).

Protocolos definem padrões típicos de trocas de mensagens e FIPA padroniza também os protocolos de interação mais comuns que são definidos através de atos comunicativos definidos na especificação (FIPA 2002b). Os protocolos de interação FIPA especificados são aqueles listados na Tabela 2.1.

referência	especificação do protocolo FIPA
FIPA00026	<i>FIPA Request Interaction Protocol Specification</i>
FIPA00027	<i>FIPA Query Interaction Protocol Specification</i>
FIPA00028	<i>FIPA Request When Interaction Protocol Specification</i>
FIPA00029	<i>FIPA Contract Net Interaction Protocol Specification</i>
FIPA00030	<i>FIPA Iterated Contract Net Interaction Protocol Specification</i>
FIPA00031	<i>FIPA English Auction Interaction Protocol Specification</i>
FIPA00032	<i>FIPA Dutch Auction Interaction Protocol Specification</i>
FIPA00033	<i>FIPA Brokering Interaction Protocol Specification</i>
FIPA00034	<i>FIPA Recruiting Interaction Protocol Specification</i>
FIPA00035	<i>FIPA Subscribe Interaction Protocol Specification</i>
FIPA00036	<i>FIPA Propose Interaction Protocol Specification</i>

Tabela 2.1: Protocolos de Interação FIPA.

⁴*Speech act theory* (Searle 1969).

2.3.5 Aprendizado Multiagentes

Na Seção C.1 do Apêndice C discutimos a modelagem do problema de aprendizado quando se assume que há um único agente atuando no ambiente. Ou seja, a existência de outros agentes é modelada como parte do ambiente e os efeitos da interação entre os agentes não são explicitamente detalhados.

Tesauro (2000) assume que os agentes participantes em seu modelo de mercado eletrônico não tomam ações simultâneas, ou seja, quando um agente decide o preço já conhece a decisão de seu oponente, o que facilita o tratamento do problema.

Assumir que os outros agentes estão implícitos na modelagem do ambiente é uma simplificação que auxilia no tratamento do problema mas com suas consequências. Uma alternativa é considerar os demais agentes no processo de aprendizagem, como por exemplo na abordagem de *Q-learning* multiagentes. Outra alternativa é uma abordagem baseada em algoritmos coevolutivos (Chen, Wong, Nguyen & Chung 2006).

2.3.5.1 *Q-learning* Multiagentes

Uma extensão do algoritmo de aprendizado *Q-learning*⁵ para múltiplos agentes em jogos estocásticos de soma genérica (nula ou não-nula) é proposta em (Hu & Wellman 2003). Entretanto, este ainda não é um resultado definitivo pois, como apontado por Tesauro (2000), assume-se em (Hu & Wellman 2003) que os agentes escolhem as ações baseados no equilíbrio de Nash. Ou seja, assume-se racionalidade ilimitada de todos os agentes, bem como conhecimento completo das transições de estado e das funções de utilidade de todos os jogadores. Além disso, o problema de se escolher entre equilíbrios de Nash múltiplos não é resolvido, o que pode representar um sério problema pois estas soluções de equilíbrio tendem a se proliferar quando há suficiente ênfase em recompensas futuras, ou seja, quando o valor da taxa de desconto γ é grande.

2.4 Projeto de Sistemas Multiagentes

Uma vez que o uso de sistemas multiagentes no projeto de sistemas de software complexos oferece vantagens em relação aos métodos tradicionais (Jennings 2001, Jennings & Bussmann 2003), é necessário estabelecer uma metodologia de projeto para a efetiva utilização dos sistemas multiagentes. Wooldridge, Jennings & Kinny (2000) apresentam a metodologia Gaia de análise e projeto de sistemas multiagentes. Dário (2005) recentemente propôs uma metodologia unificada, baseada em três metodologias existentes: MaSE, Prometheus e Tropos.

⁵No Apêndice C revisamos a Programação Neurodinâmica e o algoritmo *Q-learning*.

Bergenti & Poggi (2000) propõem o uso de diferentes tipos de diagrama e estereótipos para modelar um sistema multiagentes utilizando UML (*Unified Modeling Language*). Estereótipos `<<entity>>` utilizados em diagramas de classe denominados diagramas de ontologia modelam a ontologia do sistema. O estereótipo `<<agent>>` é utilizado no diagrama de arquitetura do sistema. O estereótipo `<<role>>` serve para modelar os papéis que um agente pode assumir em um protocolo de interação, que é modelado através de um diagrama de colaboração denominado diagrama de protocolo. A vantagem desta modelagem é facilitar a utilização de ferramentas CASE existentes.

Já Odell, Parunak & Bauer (n.d.) propõem uma nova notação para modelar esses protocolos de interação baseada nos diagramas de sequência, porém não completamente compatível com UML. A dificuldade é que este dialeto de UML, AUML para *Agent UML*, ainda não é suportado pelas ferramentas CASE, apesar de ser adotado na especificação dos protocolos FIPA (*Foundation for Intelligent Physical Agents*).

Dadas as limitações da ferramenta Poseidon⁶, utilizada neste trabalho na modelagem em UML, que não apresenta estereótipos `<<agent>>` e `<<role>>`, e que não possibilita a criação destes estereótipos, nos modelos apresentados no Capítulo 5 não é seguida a modelagem proposta em (Bergenti & Poggi 2000). Em modelos futuros esperamos utilizar outra ferramenta que possibilite esta modelagem ou aquela preconizada em (Odell, Parunak & Bauer n.d.). Dessa forma utilizamos pura e simplesmente a modelagem UML padrão.

2.4.1 Desenvolvimento Ágil Orientado a Agentes

Uma área florescente, que merece atenção nas metodologias de projeto e desenvolvimento de sistemas multiagentes, é a aplicação de metodologias de engenharia de *software* recentes como Programação Extrema (XP, *eXtreme Programming*), Programação Orientada a Aspectos (AOP, *Aspect Oriented Programming*) e Desenvolvimento Ágil (*Agile Development Methodology*) ao desenvolvimento de sistemas multiagentes. Uma vez que o uso de uma plataforma multiagentes pode implicar em uma curva de aprendizado para os programadores mais acentuada, estas metodologias tendem a amenizar a sobrecarga da abordagem baseada em sistemas multiagentes, trazendo maior prestação ao desenvolvimento com a entrega de subprodutos em menor tempo, através do projeto e implementação do sistema em ciclos rápidos de iteração.

Há iniciativas pioneiras no estabelecimento de metodologias de desenvolvimento ágil orientadas a agentes. A partir da metodologia PASSI (Cossentino, Sabatucci & Chella 2003) utilizada para o desenvolvimento de sistemas multiagentes em Robótica, Chella, Cossentino, Sabatucci & Seidita (2006) desenvolveram a versão ágil de PASSI, baseada na Programação Extrema: *Agile PASSI* (Chella, Cossentino, Sabatucci & Seidita 2004, Chella, Cossentino, Sabatucci & Seidita 2006).

⁶Disponível em <http://www.gentleware.com>.

Knublauch, Koeth & Rose (2002) apresentam um estudo de caso de aplicação na área de sistemas de saúde baseado em extensão da abordagem XP para a construção de uma base de conhecimento (Knublauch 2002b, Knublauch 2002a).

Coelho, Kulesza, von Staa & Lucena (2006) propõem um agente de testes *Mock* que auxilia no teste dos agentes que compõem um sistema multiagentes, utilizando técnicas orientadas a aspectos para controlar a execução assíncrona dos agentes de teste. O agente *Mock* proposto é implementado na plataforma JADE e utiliza o *framework* de testes JUnit (Gamma & Beck 2000). Segundo (Coelho, Kulesza, von Staa & Lucena 2006), pouca pesquisa foi endereçada para prover um processo de teste detalhado e ferramentas de suporte ao teste de *software* utilizado no desenvolvimento de sistemas multiagentes. A abordagem proposta em (Coelho, Kulesza, von Staa & Lucena 2006) vem no sentido de dar os primeiros passos no preenchimento desta lacuna. O teste de *software* não é mais visto como uma atividade que se inicia somente após a finalização da fase de codificação. Cada fase do processo de desenvolvimento leva a uma atividade de teste correspondente. Os testes de unidade (*unit tests*) do agente *Mock* têm seu foco na fase de implementação do sistema, testando o *constructo* básico dos sistemas multiagentes: os agentes. O agente *Mock* é inspirado no padrão de projeto de testes *Mock Object*, de (Mackinnon, Freeman & Craig 2000). Estes objetos são baseados em *stubs*, implementações *fake* de código de produção que retornam um resultado canônico. *Mock* é um objeto que funciona como *stub* e também inclui asserções para testar as interações do objeto alvo do teste e seus vizinhos. O agente *Mock* funciona como o objeto *Mock*: é um agente regular que se comunica somente com o agente sob teste (*AUT, Agent Under Test*), e tem planos para testar somente este agente. Para detalhes da implementação do agente *Mock* em JADE, usando JUnit e AspectJ para monitorar os agentes, bem como um exemplo prático de uso nos referimos a (Coelho, Kulesza, von Staa & Lucena 2006).

2.5 Aplicações de Sistemas Multiagentes

Na literatura encontram-se inúmeros exemplos de aplicação de Sistemas Multiagentes nas mais diversas áreas: sistemas de potência, sistemas de transporte, defesa, sistemas de manufatura, controle de processos, telecomunicações, controle de tráfego aéreo, gestão da informação, comércio eletrônico, entretenimento, entre outras. Neste capítulo procuramos elencar alguns exemplos de aplicação de Sistemas Multiagentes que julgamos pertinentes, sem fazê-lo porém de modo exaustivo, dada a pervasiva aplicabilidade da abordagem baseada em Sistemas Multiagentes, o que torna hercúlea a tarefa de uma revisão de exemplos de aplicação que se pretenda exaustiva.

É comum aos exemplos de aplicação apresentados a utilização da abordagem baseada em Sistemas Multiagentes para tratar a complexidade dos sistemas modelados. Reduzir sistemas complexos a um conjunto de entidades cujos grânulos são agentes é um modo de reduzir problemas

complexos a níveis tratáveis. Jennings (2001) argumenta ainda que o uso de sistemas multiagentes no projeto de sistemas de software complexos pode oferecer vantagens em relação aos métodos tradicionais. Além disso, sistemas multiagentes são adequados para representar problemas que têm múltiplos métodos de solução, múltiplas perspectivas e múltiplas entidades interessadas em resolvê-los.

2.5.1 Mercado de Energia Elétrica

No Capítulo 5 sugerimos uma abordagem multiagentes dos mercados de energia elétrica e apresentamos o estado da arte da literatura relevante a esta abordagem. No Capítulo 6 abordamos as estratégias de oferta em leilões de energia bem como revisão relevante do tema.

O argumento mais forte para justificar a utilização de um sistema multiagentes no mercado de energia elétrica é que estes mercados são sistemas complexos intrinsecamente compostos de vários agentes econômicos interagindo. Nada mais natural que modelá-los como um sistema multiagentes. Isto permite que cada agente econômico possa construir seu modelo de mercado no seu próprio agente de software que interage com os outros agentes através de uma interface bem definida: os mecanismos de negociação.

Em trabalhos anteriores (Walter & Gomide 2003a, Walter & Gomide 2003b, Walter & Gomide 2006, Walter & Gomide 2007) utilizamos a modelagem de estratégias de oferta através de sistemas baseados em regras nebulosas com aprendizado da base de conhecimento via algoritmos evolutivos no intuito de estudar o comportamento de agentes inteligentes em mercados competitivos de energia elétrica. A concepção e os resultados oriundos destes trabalhos se encontram sistematizados no Capítulo 6.

No Capítulo 5 propomos um modelo suficientemente genérico para simular um mercado de energia elétrica através da abordagem multiagentes. Acreditamos que instâncias deste modelo genérico poderiam ser por exemplo o modelo utilizado em (Praça, Ramos, Vale & Cordeiro 2003a), aquele desenvolvido em (Ferreira 2002, Carvalho 2003) e outros modelos baseados em sistemas multiagentes encontrados na literatura. Outra instância seria o próprio modelo de despacho hidrotérmico centralizado. Até então, não foi proposto na literatura nenhum modelo genérico e na medida do possível parametrizável para o problema em questão. Os modelos encontrados na literatura em geral podem ser vistos como instâncias do modelo proposto no Capítulo 5.

2.5.2 Comércio Eletrônico

Apesar da decepção provocada com o estouro da “bolha” das empresas .com e a frustração das previsões realizadas no final da década de 90, a importância do comércio eletrônico pode ser verificada no informe da *comScore Networks* que prevê vendas no varejo de US\$ 170 bilhões

para o ano de 2006 nos Estados Unidos, excluindo leilões e compras de grandes corporações (B2B, *business to business*) (Lipsman 2006). Neste informe segundo a *comScore Networks* foram realizadas vendas de US\$80,8 bilhões no primeiro semestre de 2006, um crescimento de 20,1% em relação ao mesmo período de 2005. Destes US\$80,8 bilhões, US\$ 34,7 (43%) foram despesas de viagens (*travel spendings*), um crescimento de 14,7% em relação a 2005.

A aplicação de agentes em comércio eletrônico data de 1995 com o lançamento do BargainFinder, um *shopbot* para comparação de preços de discos compactos (CD's) de música. Os *shopbots*, agentes Web que realizam *queries* em múltiplos *sites* para fornecer ao usuário informação comparativa com relação a preços e outros atributos de mercadorias e serviços mostram como os agentes são importantes no comércio eletrônico, atualmente e no futuro. O mySimon⁷ compara preços de dezenas de categorias de produtos, utilizando para alguns produtos uma função de utilidade multi-atributos a partir de um questionário respondido pelo usuário (Greenwald & Kephart 1999).

2.5.2.1 Passagens Aéreas

Em (Darlin 2006), é divulgado o *site Farecast.com*⁸, projetado pela equipe de Oren Etzioni (Etzioni, Tuchinda, Knoblock & Yates 2003). Neste *site* se disponibiliza um serviço de comparação de preços de passagens aéreas e de previsão de seus preços futuros. Deste modo o usuário do site, além de ter uma idéia comparativa dos preços, pode avaliar se aquele é o melhor momento para efetivar sua compra (tendência de aumento nos preços) ou se é melhor aguardar mais postergando esta compra para um momento onde os preços tendem a estar melhores (menores). O site foi construído utilizando plataformas abertas⁹ e técnicas de *data mining* e simulação.

2.5.3 Sistemas de Potência

Em (Geus, de Souza, Milsztajn, Kolb, Dometerco, Braga, Parolin, Frisch, Fortunato, Erzinger & Jonack 2006), uma aplicação de sistemas multiagentes é proposta como arquitetura de controle do sistema de distribuição de energia elétrica da COPEL, Companhia Paranaense de Energia.

Já (Corera, Laresgoiti & Jennings 1996) traz um dos primeiros exemplos de aplicação de sistemas multiagentes na gestão de sistemas de potência. Desenvolveu-se um sistema para o gerenciamento da parte norte da rede espanhola de potência, atendida pela Iberdrola e coordenada a partir do Centro de Controle e Despacho de Bilbao. Utilizou-se o sistema ARCHON¹⁰ para a implementação de uma aplicação real de Inteligência Artificial Distribuída (DAI), que integra agentes

⁷<http://www.mysimon.com>

⁸<http://www.farecast.com>

⁹Entre outras, Linux/Unix/OS X, Apache, Tomcat, Java, JSP, Perl, MySQL.

¹⁰ARchitecture for Cooperative Heterogeneous ON-line systems.

heterogêneos: alguns provenientes de sistemas legados e outros *ad-hoc* construídos especialmente para a aplicação. Segundo Corera, Laresgoiti & Jennings (1996), a abordagem DAI provê economia, robustez, confiabilidade e uma representação natural do problema.

ARCHON é um projeto de pesquisa europeu em Inteligência Artificial Distribuída, que propõe arquitetura, *framework* e metodologia de propósito geral, utilizada para o desenvolvimento de aplicações industriais (Jennings & Wittig 1992, Jennings, Mamdani, Corera, Laresgoiti, Perriolat, Skarek & Varga 1996, Cockburn & Jennings 1996). Exemplos exitosos de sua aplicação incluem a aplicação em sistemas de potência (Cockburn, Varga & Jennings 1992, Varga, Jennings & Cockburn 1994, Corera, Laresgoiti & Jennings 1996), controle de complexo industrial de produção de cimento, controle de acelerador de partículas (Perriolat, Skarek, Varga & Jennings 1996) e controle em Robótica (Oliveira, Camacho & Ramos 1991).

(Rehtanz 2003) representa uma obra completa que relata a aplicação de Sistemas Multiagentes na operação e controle de sistemas de potência. Rehtanz (2003), da área de pesquisa da ABB¹¹ argumenta que a arquitetura proposta, baseada em sistema de agentes autônomos, possibilita atingir um nível maior de automação e uma operação mais confiável de sistemas de potência.

2.5.4 Defesa

2.5.4.1 Simulação de Coalizão Internacional

Exemplo de utilização da tecnologia de agentes, o experimento realizado por Allsopp, Beutenement, Kirton, Bradshaw, Suri, Durfee, Knoblock, Tate & Thompson (2002) consiste na aplicação de um sistema multiagentes na simulação de uma coalizão militar internacional. Diferentes sistemas computacionais são integrados através de sistemas baseados em agentes. Os sistemas legados (*legacy systems*) que originalmente não são baseados em agentes são transformados em sistemas habilitados a responder em um ambiente multiagentes através de um envelope (*wrapper*) que realiza o mapeamento de requisições ao agente em chamadas ao código legado¹². O experimento é composto deste modo de uma rede heterogênea através da qual interagem diferentes sistemas que estão sob a responsabilidade de diferentes organizações de diferentes nações.

Toma-se um cuidado especial em relação à segurança do sistema e à autenticação dos agentes. O sistema de gerenciamento de domínio KAOs (Bradshaw, Dutfield, Benoit & Woolley 1997) provê serviços para assegurar que agentes de diferentes desenvolvedores e executando em diferentes plataformas operem sempre dentro de limites de políticas definidas, e que estes agentes sejam continuamente responsivos ao controle humano para permitir uma utilização segura quando em operação. Serviços e ferramentas do sistema KAOs permitem a especificação de políticas,

¹¹ A ABB, Asea Brown Boveri, www.abb.com, é líder em tecnologias de potência e automação.

¹² A mesma técnica de *wrapping* é empregada no exemplo citado na Seção 2.5.3 como descrito em (Corera, Laresgoiti & Jennings 1996).

gerenciamento e resolução de conflitos, e limitações aos contextos específicos estabelecidos pelas complexas estruturas organizacionais militares.

Simulações deste tipo também interessam às Forças Armadas brasileiras. Foi realizado em Brasília, de 18 a 28 de julho de 2005, o Exercício “Operações de Manutenção da Paz Sul 2005”, onde foi simulada uma coalizão internacional de defesa com auxílio de simulações computadorizadas (EME 2004). Este exercício (ou jogo de guerra) já havia sido realizado em 10 outras oportunidades, sob o nome de Forças Unidas (PKOS, *Peacekeeping Operations South*) com a promoção pelo Exército dos Sul dos EUA (*US Army South*). No exercício de 2005 contou com a participação das Forças Armadas de outros 14 países da América Latina, agências das Nações Unidas, organizações não-governamentais entre outros. Apesar de não ter sido divulgada a tecnologia de simulação empregada neste evento comprova o interesse em aplicações da abordagem descrita em (Allsopp, Beutenement, Kirton, Bradshaw, Suri, Durfee, Knoblock, Tate & Thompson 2002).

2.5.4.2 Treinamento de Tropas

Além de simulações de coalizões internacionais, a abordagem baseada em Sistemas Multiagentes vem sendo utilizada no treinamento de tropas. Agentes inteligentes cujos comportamentos são modelados através de máquinas de estados finitos povoam um ambiente virtual onde operações militares são simuladas e seu planejamento avaliado (Lyrio & Seixas 2006). Trata-se de uma especialização dos sistemas tutores inteligentes (Vicari & Giraffa 2003) voltada para o treinamento militar.

2.5.4.3 Patrulhamento Urbano

Reis, Melo, Coelho & Furtado (2006) apresentam GAPatrol, uma abordagem baseada em sociedades de agentes (Barone 2003) e algoritmos genéticos para estabelecer rotas adequadas de patrulhamento urbano a partir de modelos georeferenciados de comportamento de criminosos. O sistema proposto é implementado na plataforma Repast¹³ a partir de modelos baseados em inteligência coletiva (*swarm intelligence*) que capturam adequadamente a aprendizagem por reforço comumente utilizada pelos criminosos.

2.5.5 Meio Ambiente

Em (LBA 2006) é apresentado um *framework* científico baseado em autômatos finitos e dados de satélites para a simulação da devastação da floresta na Bacia Amazônica, em diferentes cenários de governança. O modelo é simulado através da ferramenta DINAMICA (Soares, Cerqueira

¹³ *Recursive Porous Agent Simulation Toolkit*, disponível em <http://repast.sourceforge.net>.

& Pennachin 2002), utilizando probabilidades de transição calculadas através de métodos bayesianos e algoritmos genéticos. Os estudos apresentados mostram a preocupação com diversos fatores como por exemplo a expansão da malha viária na região amazônica, e as suas consequências segundo dois cenários principais: um de governança com maior controle do desflorestamento e outro mais drástico de “*business as usual*” onde haveria diminuição de quase 40% da floresta total.

Janssen & Ostrom (2006) apresentam uma revisão da abordagem *ACE*¹⁴ aplicada no projeto de mercados de certificados de emissão de poluentes. Há uma percepção de que mecanismos de mercados podem ser mais eficientes para o controle das emissões de poluentes, o que justifica o interesse crescente neste domínio. Kraus (2001) apresenta mecanismos de negociação para a redução da poluição no contexto de sistemas multiagentes.

¹⁴Ver Seção 3.7 para introdução à Economia Computacional baseada em Agentes, *ACE*.

Capítulo 3

Modelos de Mercado

O sistema de mercado é como a democracia: é a pior forma de economia, excetuando-se todas as outras que de vez em quando são tentadas.

McMillan (2004)

3.1 Leilões

Definição 9 *Um leilão é uma instituição de mercado com um conjunto de regras explícitas determinando uma alocação de recursos e preços com base em lances dos participantes no mercado (McAfee & McMillan 1987).*

Os leilões são uma das mais antigas classes de instituições econômicas (Milgrom 1987). A utilização de leilões foi relatada no mundo antigo, na Babilônia, na Grécia, no Império Romano, na China e no Japão¹. Tão impressionante quanto a longevidade histórica dos leilões é a corrente gama de utilização. Há leilões para *commodities* substituíveis bem como para itens raros de coleção (como por exemplo diamantes, obras de arte, selos). Bens duráveis (e.g. máquinas usadas), perecíveis (e.g. peixe fresco), ativos financeiros² (e.g. letras do tesouro americano), contratos de suprimento e construção são todos comumente negociados em leilões. O leilão de itens únicos sugere a alguns autores que leilões são um veículo apropriado a monopolistas. Entretanto não são utilizados somente por quem se encontra em uma posição de mercado vantajosa. Também há leilões de venda de propriedades, equipamentos e suprimentos de firmas e fazendas falidas, que mostram que leilões podem ser utilizados por vendedores desesperados por *cash* e que desejam vender ativos ainda que a preços abaixo do custo de reposição (Milgrom 1987). Banker & Mitra (2006) relatam experiência de um leilão *online* de café na Índia, com o objetivo de permitir a pequenos agricultores o acesso ao mercado global de *commodities*.

¹Para a história detalhada de leilões bem como sua utilização no mundo moderno, ver (Cassady 1967).

²*Financial assets*.

leilão	vendedores	compradores
de demanda	1	m
de oferta	n	1
duplo	n	m

Tabela 3.1: Relação entre vendedores e compradores conforme natureza dos leilões.

O único denominador comum claramente identificável para os tipos de objetos negociáveis em leilões é a necessidade de estabelecer preços individuais para cada item negociado. Por exemplo, ao contrário de carros novos, carros usados cujas condições variam tremendamente são vendidos a revendedores em leilões. Gado é vendido em leilões embora substituíveis estejam disponíveis, pois podem haver diferenças de peso e saúde entre os animais. O preço de peixe fresco precisa ser determinado diariamente pois a oferta diária de peixe varia tremendamente. Contratos de construção são normalmente complexos demais para permitir que uma precificação simples funcione, lances competitivos oferecem uma alternativa (Milgrom 1987).

Vários tipos de leilão são encontrados na vasta literatura³ e utilizados na prática. A principal característica de um leilão é fornecer uma comparação explícita entre os lances (Milgrom 1987). A caracterização de leilões pode ser feita a partir de sua natureza (oferta, demanda ou duplo), pela forma como os lances são oferecidos (aberto ou fechado) e pela determinação do preço de fechamento (primeiro ou segundo preço) (Masili 2004). Na seção 3.2 a seguir é apresentada uma classificação baseada em (Masili 2004).

3.2 Classificação de Leilões

3.2.1 Natureza

A natureza de um leilão pode ser determinada através do papel exercido pelos grupos de participantes no leilão. Os leilões são caracterizados conforme sua natureza como leilão simples de oferta, leilão simples de demanda ou leilão duplo. A natureza do leilão define a relação entre número de vendedores e compradores como 1:m no leilão de demanda, n:1 no leilão de oferta e n:m no leilão duplo, como ilustrado na Tabela 3.1.

3.2.1.1 Leilão de Demanda

Em um leilão de demanda os compradores fazem lances de demanda para comprar um bem que o leiloeiro pretende vender pelo maior preço. Vence o participante que fizer o maior lance de

³Algumas referências embrionárias correspondem a (Engelbrecht-Wiggans 1980, Friedman 1993, McAfee & McMillan 1987, Milgrom 1987, Milgrom & Weber 1982).

demanda.

Preço de Reserva O leiloeiro pode estabelecer um preço de reserva mínimo abaixo do qual o bem não é vendido. Ou seja, o lance do vencedor deve ser maior ou igual ao preço de reserva.

3.2.1.2 Leilão de Oferta

No leilão de oferta os vendedores ofertam um bem que o leiloeiro pretende adquirir ao menor preço. O preço do produto leilado é determinado pelos lances dos vendedores. Vence o leilão o participante que fizer o menor lance de oferta. Este leilão também é denominado de leilão reverso ou de leilão de *procurement*.

Preço de Reserva Pode ser estabelecido pelo leiloeiro um preço de reserva máximo acima do qual o bem não é adquirido. Ou seja, o lance do vencedor deve ser menor ou igual ao preço de reserva.

3.2.1.3 Leilão Duplo

No leilão duplo (*double auction*) os vendedores fazem lances de oferta e os compradores fazem lances de demanda simultaneamente. O preço de fechamento do leilão é estabelecido no intervalo entre os lances de oferta e demanda segundo as regras estabelecidas *a priori* no leilão.

Mercados de derivativos (e.g. *call market*) e leilões duplos contínuos (CDA, *Continuous Double Auction*) são instituições utilizadas para a negociação de instrumentos financeiros, como as ações de empresas. Ambos são especializações dos leilões duplos com regras de funcionamento específicas como o fechamento (*settlement*) contínuo no caso de leilões duplos contínuos (CDA).

3.2.2 Forma de Oferta dos Lances

A forma de oferta dos lances de um leilão caracteriza como são realizados os lances, em um leilão aberto (*open-outcry*) ou fechado (*sealed bid*).

3.2.2.1 Leilão Aberto

No leilão aberto, o preço do bem leilado é determinado através de um processo dinâmico de estabelecimento do lance vencedor. Os lances são informação pública de conhecimento dos participantes no leilão. O processo pode ocorrer de forma ascendente através de um incremento dos lances pelo objeto ou descendente através do decréscimo do valor do bem.

Leilão Inglês No leilão inglês os lances são realizados seqüencialmente e cada lance melhora o lance imediatamente anterior. No leilão de demanda os lances são ascendentes. Este leilão de demanda ascendente aberto é o leilão popularizado pelos leilões de obras de arte. No leilão de oferta os lances são descendentes e vence o menor lance.

No leilão de demanda o preço dos lances pode ser anunciado pelo leiloeiro (gradativamente contra o relógio) ou pelos compradores interessados.

O leilão inglês é freqüentemente utilizado para vender arte e outros itens de coleção.

Leilão Holandês No leilão descendente (de demanda) ou leilão holandês o leiloeiro inicia o leilão com um valor extremamente alto e o reduz continuamente. O primeiro agente comprador a aceitar o lance corrente vence o objeto e o adquire pelo preço corrente. O leilão holandês é comumente utilizado para vender perecíveis tais como peixes e flores.

3.2.2.2 Leilão Fechado

No leilão fechado (*sealed bid auction*) os lances são apresentados simultaneamente ao leiloeiro em envelopes fechados. Portanto os lances não são de conhecimento dos participantes. Vence o participante que fizer o melhor lance.

No leilão de demanda fechado de múltiplas unidades a preferência de alocação das unidades leiloadas é para os agentes com melhores lances de preço, até que estas unidades se esgotem. No leilão de oferta a preferência é para os agentes com menores preços até que a demanda seja atendida.

3.2.3 Preço de Fechamento

O preço de fechamento estabelece o valor pelo qual o bem leilado é negociado. Pode ser uniforme ou discriminatório.

3.2.3.1 Leilão a Preço Uniforme

Em um leilão a preço uniforme de demanda (oferta) todos os agentes vencedores pagam (recebem) o mesmo preço independentemente do valor de seus lances. Os leilões de preço uniforme (de oferta ou demanda) podem ser de primeiro ou segundo preço.

Leilão de Primeiro Preço No leilão de primeiro preço vence o participante que fizer o melhor lance e o preço de fechamento corresponde ao lance vencedor.

Leilão de Segundo Preço No leilão de segundo preço vence o participante que fizer o melhor lance porém o preço de fechamento corresponde ao melhor lance perdedor.

Leilões fechados de primeiro preço (FPSB, *first price sealed bid*) e leilões fechados de segundo preço (ou de Vickrey) são mais frequentemente utilizados em situações de *procurement*, ou seja, em leilões de oferta.

3.2.3.2 Leilão a Preço Discriminatório

No leilão de demanda a preço discriminatório ou leilão *Yankee* ou ainda *pay as bid*, cada agente comprador paga o valor de seu lance. No leilão de demanda a preço discriminatório cada vendedor recebe o valor de seu lance.

3.2.4 Taxonomia

Assim, a partir da classificação apresentada anteriormente podemos estabelecer uma taxonomia hierárquica dos leilões mais comumente utilizados como sugerido por alguns autores (Engelbrecht-Wiggans 1980, Friedman 1993) e ilustrado na Figura 3.1. Porém deve-se notar que uma representação em árvore introduz uma ordem artificial em decisões de projeto do leilão além de esconder características comuns em diferentes ramos (Wurman, Wellman & Walsh 2001).

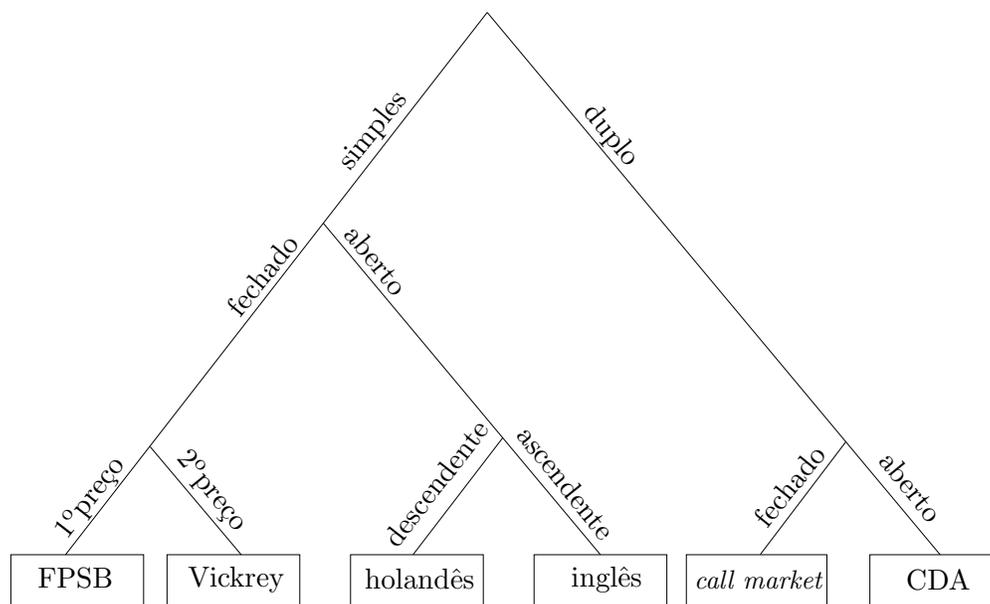


Figura 3.1: Taxonomia hierárquica de leilões.

3.3 Parametrização de Leilões

A popularidade de leilões na internet sugere que leilões eletrônicos tem um papel significativo no comércio eletrônico. Este pode ser o caso pois por definição qualquer conjunto bem definido de regras para determinar os termos de uma troca de algo por numerário pode ser razoavelmente caracterizado como um leilão (McAfee & McMillan 1987).

Como a automação de processos de negociação invariavelmente requer sua especificação precisa (ao menos em programas de computador), Wurman, Wellman & Walsh (2001) sugerem que a tarefa de projetar regras de negociação é essencialmente aquela de projetar leilões. Então o projeto de leilões constitui uma atividade central para qualquer situação onde agentes – humanos ou de *software* – negociam a troca de recursos.

A literatura em leilões identifica uma variedade de tipos de leilão caracterizados na seção 3.2. Apesar da maioria dos leilões *online* implementar alguma variação do leilão inglês aberto mais familiar ao público em geral, as regras e interfaces não são padronizadas e então os usuários devem aprender as convenções de operação de um *site* particular. Para implementar agentes de *software* que possam automatizar a oferta de lances é necessário adaptar o comportamento do agente aos *sites* individuais. Isto torna particularmente difícil a coordenação do comportamento de oferta de lances através de diferentes *sites* que pode ser desejada quando itens idênticos ou substituíveis são leiloados simultaneamente em múltiplos *sites* de leilões.

Para facilitar o desenvolvimento de agentes capazes de participar em múltiplos leilões seria necessário padronizar as regras dos leilões ou prover uma maneira padronizada de descrevê-las. Esta última abordagem é mais flexível que a anterior e é aquela defendida por Wurman, Wellman & Walsh (2001). Desta forma os leilões publicariam suas regras em termos descritivos padronizados, interpretáveis por seres humanos e por agentes de *software*. Baseado nestas regras, os agentes sintetizam estratégias de oferta de acordo com seus objetivos.

No sentido de identificar parâmetros comuns a diferentes mecanismos de leilão, Wurman, Wellman & Walsh (2001) apresentam uma parametrização do espaço de possíveis mecanismos de leilão. Além da praticidade na implementação de leilões e na descrição de suas regras, esta parametrização é útil como uma caracterização mais detalhada do espaço de projeto dos leilões e é um passo decisivo na organização da pesquisa em mecanismos de negociação automatizados.

3.3.1 Atividades Essenciais

É conveniente identificar as atividades essenciais comum aos leilões. Todos os leilões devem realizar as duas primeiras atividades e a maioria realiza também a terceira.

- **Receber lances:** Lances (*bids*) são mensagens enviadas pelos agentes para identificar seu

desejo em participar em trocas (comprar ou vender). Ao receber um lance, o leilão verifica se o lance satisfaz as regras do leilão e então o admite no conjunto de lances ativos.

- **Fechamento:** O propósito central de um leilão é fechar o mercado (*clearing*), determinando trocas de recursos e correspondentes pagamentos entre compradores e vendedores.
- **Revelar informação intermediária:** Leilões comumente fornecem alguma forma de informação intermediária de status, tipicamente na forma de resultados hipotéticos caso o leilão fechasse naquele momento. Estes relatórios de status são genericamente chamados de cotações (*quotes*).

A partir destas atividades é natural descrever um leilão a partir de três eixos, regras de oferta de lances, política de fechamento e política de cotação (ou de revelação de informação). Wurman, Wellman & Walsh (2001) apresentam então um conjunto de parâmetros ortogonais que definem unicamente um leilão a partir destas três atividades essenciais.

3.4 Leilões *Online*

A proliferação de leilões *online* na *internet* faz dos leilões uma dos principais meios de comércio eletrônico. Há alguns *sites* de leilão *online* na *internet* e podemos citar o eBay⁴ que além de ser o mais importante e com maior volume de transações atua no mercado nacional através de seu associado local, o MercadoLivre⁵, presente também em outros 8 países da América Latina: Argentina, Colômbia, Chile, Equador, México, Peru, Uruguai e Venezuela. Há quem entenda que eBay vende entretenimento através da competição pelos produtos em leilão (Huhns & Vidal 1999). Porém, o MercadoLivre oferece realmente acesso a produtos mais baratos que aqueles encontrados através dos canais convencionais, ainda que não seja sempre em formato de leilão mas de oferta a preço fixo e que a procedência dos produtos possa ser de algum modo questionável.

Uma empresa brasileira que foi criada em 1999 a partir da experiência dos fundadores em leilões públicos oficiais é a SuperBid⁶ que oferece principalmente leilões de execução judiciária e de vendas de ativos de empresas, denominados leilões industriais. Na área de vendas de ativos a SuperBid possui parceria internacional com a DoveBid⁷, que divulga ter realizado mais de 5000 leilões industriais, vendendo mais de 10 milhões de lotes e receita de US\$ 5 bilhões em vendas de ativos. Já a SuperBid divulga em sua página ter disponibilizado desde 1999 mais de 60 mil lotes de produtos, de mais de 200 empresas. A SuperBid teria recebido nestes pregões mais de 900 mil lances desde o ano 2000. Além dos leilões industriais a SuperBid está oferecendo uma versão aos

⁴<http://www.ebay.com>

⁵<http://www.mercadolivre.com.br>

⁶<http://www.superbid.net>

⁷<http://www.dovebid.com>

consumidores e disponibiliza em todas as modalidades de leilão eletrônico acesso à voz do pregoeiro. A SuperBid procura então se especializar nos nichos de mercado: vendas de ativos de empresas, execuções judiciais e leilões comerciais.

Leilões *online* podem reduzir custos de armazenamento, de expedição e entrega e de contabilização (*clearing*) em diferentes mercados (Garcia, Giménez, Godo & Rodríguez-Aguilar 1999). Os exemplos citados ilustram uma quantidade crescente de transações econômicas negociadas através dos leilões eletrônicos. Como veremos na seção 3.5, a atividade presente e potencial dos leilões eletrônicos traz à tona a importância dos agentes de software como mediadores destas transações e a possibilidade de redução de custos e obtenção de ganhos de escala, na direção da construção de uma economia que alguns autores denominam uma economia sem perdas (*frictionless economy*) (Bakos 1998).

3.5 Leilões em Inteligência Artificial

Os leilões são um domínio de interesse da Inteligência Artificial (IA) em ao menos duas áreas de pesquisa: leilões mediados por agentes (de *software*) e leilões como protocolo de coordenação (Garcia, Giménez, Godo & Rodríguez-Aguilar 1999).

A Inteligência Computacional pode ser empregada na construção de sistemas multiagentes de negociação eletrônica (*e-trading*) como os leilões *online*, os agentes de compra e venda (*shopbots* e *pricebots*) e outros agentes que participam de diferentes mercados e ambientes de negociação. Sandholm (2000) apresenta resultados que demonstram como a Inteligência Artificial pode contribuir para melhorar a eficiência do comércio eletrônico. Kephart & Hanson (2000) apresentam um apanhado dos resultados obtidos no grupo de pesquisa de Economia da Informação da IBM através da modelagem de agentes de *software* motivados economicamente.

3.5.1 Leilões Combinatórios

Hunsberger & Grosz (2000) mostram que um grupo de agentes pode decidir se deve cooperar em um plano conjunto através de um leilão em que os agentes oferecem lances por tarefas a serem realizadas neste plano conjunto.

3.6 Aplicações

Podemos elencar algumas das mais importantes aplicações dos leilões:

- Leilões nos mercados de energia elétrica

- Leilões de *slots* de aterrissagem e decolagem
- Leilões de direitos de mineração
- Pregões e licitações eletrônicas (compras governamentais)

No setor de energia podemos comprovar a importância destas instituições elencando a realização dos seguintes leilões⁸:

- Leilões do “Setor Elétrico Brasileiro” organizados pelo MAE/CCEE
 - Leilões de Certificados (2001-2002)
 - Leilão de Venda de Energia (2002)
 - Leilão de Excedentes (2003)
 - Leilões de Compra de Energia (2003-2004)
 - Leilões de Energia Existente (2004, 2005)
 - Leilões de Ajuste (2005, 2006)
 - Leilões de Energia Nova (2005, 2006)
- Leilões do “Setor Elétrico Brasileiro” organizados por agentes
 - Leilões reversos de Compra de Energia
 - Leilões de Venda de Energia
 - Leilões de Contratos de Curto Prazo de Energia Elétrica ABRACEEL/BM&F
- Outros Leilões do “Setor Elétrico”
 - Leilões de Concessão de Linhas de Transmissão ANEEL/BOVESPA
 - Leilões de Privatização de Empresas (e.g. venda de lote de ações da CTEEP)
 - Leilões de Fontes Alternativas de Energia Elétrica⁹
- Leilões do Setor de Petróleo, Gás Natural e Biocombustíveis
 - Rodadas de Licitações de Áreas de Exploração de Petróleo e Gás Natural (*Brasil Rounds*)
 - Rodadas de Licitações de Áreas de Exploração Inativas
 - Leilões de Compra de Biodiesel

⁸Almeida & Camargo (2006) sistematiza o histórico da utilização de leilões na indústria de energia elétrica no Brasil.

⁹Em estudo pelo programa PROINFA.

3.7 Economia Computacional Baseada em Agentes

A Economia Computacional baseada em Agentes (ACE, *Agent-based Computational Economics*) está interessada em um comportamento econômico que possa emergir da agregação de vários agentes, geralmente com racionalidade limitada e interesse próprio (Tsfatsion 2001a, Tsfatsion 2001b, Tsfatsion & Judd 2006).

3.7.1 Mercados de Eletricidade Baseados em Agentes

Com a utilização da ACE no mercado de energia, procura-se uma modelagem mais refinada que aquela fornecida pela modelagem econômica neoclássica (Bunn & Oliveira 2001, Bower & Bunn 2001).

Bunn & Oliveira (2001) e Bower & Bunn (2001) utilizaram a Economia Computacional baseada em Agentes para comparar, através de simulações, a influência no preço da energia da adoção do pagamento discriminatório antes da implantação do NETA¹⁰ na Inglaterra. Os resultados obtidos foram opostos à expectativa do OFFER¹¹, agência reguladora do sistema inglês, e mostraram que sob o pagamento uniforme os preços tendem a ser mais baixos. Enquanto em (Bunn & Oliveira 2001) o processo de aprendizagem é baseado em informação de histórico do mercado, em (Bower & Bunn 2001) são utilizados algoritmos de aprendizagem por reforço.

Nicolaisen, Petrov & Tsfatsion (2001) também adotam uma abordagem baseada na ACE para simular um mercado de eletricidade reestruturado no qual os preços são definidos por um leilão duplo a preço discriminatório.

Marks (2006) apresenta estado da arte do projeto de mercados através da abordagem ACE utilizando os mercados de eletricidade e os leilões duplos como ilustração. Na seção 5.4 apresentamos uma revisão de outras experiências na modelagem de mercados de energia através de abordagens baseadas em sistemas multiagentes.

3.8 Programação Orientada a Mercados

Definição 10 *A programação orientada a mercados (MOP, de Market-Oriented Programming) refere-se à abordagem genérica de encontrar soluções a problemas de alocação distribuída de recursos através da computação do equilíbrio competitivo de uma economia artificial (Wellman 1993).*

A Programação Orientada a Mercado (Wellman 1993) consiste basicamente em definir uma economia que represente o problema que se deseja otimizar. MOP compartilha com a programação

¹⁰ *New Electricity Trading Arrangements*

¹¹ *Office of Electricity Regulation*

orientada a agentes (Shoham 1993, Shoham 1997) a visão de que os módulos da resolução distribuída de problemas são melhor projetados e compreendidos como agentes racionais. Trata-se então de uma abordagem de resolução distribuída de problemas no domínio da inteligência artificial distribuída.

3.8.1 Programação Orientada a Mercados em Sistemas de Energia Elétrica

Ygge (1999) utiliza agentes de software e a programação orientada a mercado para estabelecer um ambiente de comércio eletrônico onde pequenos e médios consumidores poderiam comprar energia diretamente dos produtores através do *pool*, sem a necessidade dos revendedores de energia¹². Preocupados com o grande número de participantes em um mercado de energia sem revendedores, Carlsson, Ygge & Andersson (2001) apresentam um mecanismo denominado *Con-fast* para lidar com mercados onde o equilíbrio é bastante dinâmico e com a presença de muitos participantes, baseado na programação orientada a mercado.

Uma discussão mais aprofundada sobre a necessidade ou não dos revendedores de energia e a questão da liberação do preço de revenda (final) da energia para refletir as variações de preço no atacado encontra-se em (Joskow 2000, Borenstein 2001). Já Littlechild (2000) argumenta baseado na experiência inglesa que os revendedores de energia são necessários e o órgão regulador deve proteger os consumidores com preços tarifados.

3.9 Projeto de Mecanismos

O estudo dos mecanismos de leilão pode se distinguir em duas grandes áreas: o projeto de mecanismos (*mechanism design*) e o projeto de estratégias dado um determinado mecanismo. O projeto do mecanismo de leilão pode interessar ao realizador do leilão (e.g. agente regulador) que deseja estabelecer um mecanismo que atenda alguns requisitos como por exemplo estabilidade, maximização do bem estar social, *incentive compatible*.

Já o projeto de estratégias de oferta quando um determinado mecanismo é estabelecido pode interessar tanto aos agentes participantes no mercado quanto ao realizador do leilão que deseja estressar o mecanismo projetado e identificar eventuais lacunas (*holes*) e é abordado em detalhes no Capítulo 6.

3.9.1 Projeto Evolutivo de Mecanismos

O projeto do mecanismo é geralmente realizado caso a caso por economistas e engenheiros com conhecimento dos mecanismos mais utilizados e suas vantagens e desvantagens. Entretanto

¹²No modelo atual do sistema brasileiro, a revenda de energia a pequenos e médios consumidores (cativos) é realizada pela figura do distribuidor de energia.

há uma área recente de pesquisa que busca automatizar parte deste projeto de mecanismo parametrizando o espaço de busca (Wurman, Wellman & Walsh 2001) dos possíveis leilões e utilizando algum mecanismo de busca heurística para encontrar mecanismos mais adequados sob uma determinada ótica, de acordo com uma função de adaptabilidade (*fitness*) (Phelps, Parsons, McBurney & Sklar 2002, Byde 2002, Cliff 2003).

Capítulo 4

Mercado de Energia Elétrica

*L'Environnement terrestre constitue
une immense et extrêmement complexe machinerie vitale
qui étend sur toute la terre une mince pellicule énergétique¹.*
Commoner (1971) *apud* (Passet 1996)

4.1 Introdução

A reestruturação da indústria de energia elétrica² no Brasil e em boa parte dos países ocidentais apresenta novos desafios e oportunidades, uma vez que não há consenso sobre qual seria sua melhor organização. Mesmo no Chile, que implementou reformas pioneiras na década de 80, este é um processo contínuo e dinâmico onde cada decisão a ser tomada expõe limitações na capacidade de lidar com os novos desafios e aproveitar as oportunidades para atingir melhor eficiência, menores custos e reduzir o impacto ambiental (Rudnick 1996). A indústria brasileira apresenta características como a concentração em capacidade hidrelétrica, grande parte da geração detida por entes estatais convivendo com interesses privados em um modelo híbrido recentemente reformulado que requerem uma solução não necessariamente baseada inteiramente nas experiências de outros países, sugerindo a adoção de um modelo específico às necessidades brasileiras.

No mercado de energia elétrica um produtor de energia converte uma *commodity* (óleo, gás,

¹ *O ambiente terrestre constitui uma maquinaria vital imensa e extremamente complexa que estende sobre a Terra uma película energética.*

² O termo mais comumente utilizado para se referir à indústria de energia elétrica no Brasil é “Setor Elétrico” ou “Setor Elétrico Brasileiro (SEB)”. Porém, se quisermos ser mais rigorosos, tradicionalmente a atividade econômica se divide em setores (industrial, agrícola, terceiro setor, isto é, comércio, setor público e serviços, de transportes, de energia, ...) e cada um destes em seus ramos. Por exemplo no setor industrial temos os ramos da indústria alimentícia, de papel e celulose, metal-mecânica, ..., no setor de transportes temos os ramos dos transportes rodoviários, ferroviários, aviários, marítimos e fluviais. Desta forma, ao se referir ao “Setor Elétrico” o mais correto seria o termo *setor de energia elétrica* ou ainda *indústria de energia elétrica* como procuramos utilizar, sem confundir-lo com a indústria de equipamentos elétricos. Fica então a ressalva de que ao utilizarmos indústria de energia elétrica estamos nos referindo ao termo mais usual “Setor Elétrico”.

	Mercado físico	Mercado financeiro
	<i>ISO, pool, PX</i>	<i>commodity exchange</i>
	<i>trade commitments</i> produção e consumo	contratos financeiros e derivativos (baseados no mercado físico)
EUA	CalPX	NYMEX, Chicago Board of Trade
Brasil	ONS, CCEE	BMF, BOVESPA

Tabela 4.1: Caracterização do mercado de energia elétrica.

carvão, urânio, água) em outra: eletricidade³. O custo do combustível e a eficiência tecnológica deste processo de transformação determinam o custo de produzir energia elétrica (Ilic & Skantze 2000). Pode se dizer que os mercados de energia elétrica se compõem de um mercado físico com transações de produção e consumo de energia (*trade commitments*) e outro financeiro cujos ativos são baseados neste mercado físico. A Tabela 4.1 adaptada de (Ilic & Skantze 2000) apresenta uma caracterização destes mercados, exemplificada em instâncias norte-americanas e na brasileira.

O mercado de energia elétrica compõe-se geralmente do leilão de energia no curto prazo e da contratação de longo prazo. Em alguns mercados há também um leilão de serviços ancilares como reserva de energia e potência reativa e a negociação de derivativos de energia elétrica no mercado financeiro. Salientamos a importância da contratação bilateral nos mercados de energia e a tendência de mercado de procurar nos derivativos de energia uma solução para a proteção ao risco (*hedging*).

4.1.1 Agentes no Mercado Brasileiro

Os agentes econômicos participando no mercado de energia elétrica brasileiro atuam em papéis típicos destes mercados e podem ser descritos resumidamente:

CCEE Câmara de Comercialização de Energia Elétrica⁴, atua como operador do mercado de energia

ONS Operador Nacional do Sistema, desempenha o papel do operador independente do sistema (ou ISO, *Independent System Operator*)

ANEEL Agência Nacional de Energia Elétrica, órgão governamental, agência reguladora do setor

geradores agentes produtores de energia elétrica

³Para uma discussão mais ampla em relação a tratar a eletricidade como uma *commodity* nos referimos a (Vieira 2005).

⁴Em 2004 a CCEE sucedeu o MAE, Mercado Atacadista de Energia. Com a mudança de modelo do Setor Elétrico seu papel foi alterado mudando também seu estatuto social.

distribuidores agentes distribuidores de energia, compram energia dos geradores e distribuem aos consumidores, podem ser vistos como uma demanda agregada de energia

transmissores transmitem energia entre um agente gerador e um agente distribuidor recebendo tarifa de transmissão

comercializadores agentes negociadores de energia (*traders*), compram e revendem energia

consumidores livres têm a liberdade de escolher de qual gerador ou comercializador comprar sua demanda independentemente do distribuidor concessionário de sua área geográfica

consumidores cativos devem obrigatoriamente comprar energia do distribuidor que serve sua área geográfica⁵

4.2 Mecanismos de Formação de Preços

A crise de abastecimento no Brasil em 2001 salientou as deficiências do mecanismo de formação de preços do mercado de curto prazo. Este mecanismo consiste na otimização do sistema através da Programação Dinâmica Dual Estocástica implementada pelo software NEWAVE. A valoração da energia pelo custo marginal de operação assim obtido não foi capaz de sinalizar a escassez de energia alguns meses antes do início do racionamento.

É peculiar ao sistema brasileiro que o mercado tenha preços estabelecidos de maneira exógena, operando sob o modelo de *tight pool*⁶, como definido por alguns autores (Nascimento & Nunes 2001, Freitas 2006). A modelagem do problema de otimização também pode ser questionável visto que agrega em um único reservatório equivalente vários reservatórios de diferentes bacias e regime pluviométrico heterogêneo e desconsidera não-linearidades e não-convexidades.

O mecanismo de formação de preços por oferta seria segundo (GCE 2002a) uma maneira de delegar aos agentes do setor a estimativa da valoração de sua própria energia fazendo com que estes assumam os bônus e ônus de suas decisões ao invés de responsabilizar o operador do sistema e do mercado pela valoração indevida da energia. No Brasil não há definição quanto ao mecanismo de formação de preço de curto prazo por oferta. Durante os trabalhos do Comitê de Revitalização do Modelo do Setor Elétrico (GCE 2002a, GCE 2002b) iniciados a partir da crise de abastecimento de 2001 uma nova proposta de leilão de curto prazo foi desenhada. Porém, este leilão não foi adotado até então e argumenta-se que no mercado brasileiro é mais pertinente estimular a competição pelo mercado do que a competição no mercado⁷, principalmente devido à característica de dependência da fonte hídrica.

⁵A tendência natural dos mercados de energia é que gradativamente um maior número de consumidores cativos tornem-se consumidores livres, aumentando a competitividade do mercado.

⁶Em contraposição a este modelo de *tight pool*, há o *loose pool* onde a formação de preços se dá por ofertas.

⁷*Competition for the market versus competition in the market.*

4.2.1 O Despacho Hidrotérmico por Custos

O atual mecanismo de formação de preços de curto prazo implementado através do modelo computacional **NEWAVE** baseia-se na resolução do problema de otimização do despacho de energia utilizando o método de Programação Dinâmica Dual Estocástica (PDDE).

O algoritmo do processo de despacho (MAE 2000) apresentado em (Pereira, Campodónico & Kelman 1998) consiste basicamente na minimização de uma função de custo total, agregação dos custos imediato e futuro da geração de energia, sujeito às restrições do sistema.

A função de custo imediato é relacionada ao custo de geração térmica no estágio t . Quanto maior a energia armazenada no reservatório equivalente do sistema menos água encontra-se disponível para a produção de energia e então o custo imediato aumenta com o despacho de um número maior de usinas termoeletricas para atender a demanda. Já a função de custo futuro é associada ao custo esperado de geração termoeletrica para suprir a demanda do período $t + 1$ ao final do horizonte de planejamento. Quanto maior a energia armazenada, mais água sobra para produção de energia no futuro e portanto a função de custo futuro decresce com o armazenamento.

O algoritmo de Programação Dinâmica Dual Estocástica minimiza a função de custo total no ponto onde as derivadas de ambas as funções é igual, determinando para cada estágio o custo de oportunidade das hidroelétricas (*water value*) igual ao custo marginal de operação do sistema (CMO). Esse custo determina o preço *spot* da CCEE para cada semana: v_t . Simplificadamente, cada usina termoeletrica i deve receber receita contábil $g_{i,t}v_t$ referente à sua produção despachada $g_{i,t}$ pelo preço *spot* v_t .

As usinas hidroelétricas são remuneradas de acordo com o Mecanismo de Realocação de Energia (MRE). Cada usina hidroelétrica j recebe receita

$$R_{j,t} = G_{H,t}v_t\rho_j \quad (4.1)$$

onde $G_{H,t} = \sum_{j=1}^H g_{j,t}$ é o total de energia hidroelétrica produzida pelas H usinas na semana t e ρ_j é o coeficiente relativo de produção hidroelétrica correspondente ao certificado de energia assegurada no submercado da usina j .

No entanto o despacho físico de cada usina é feito igualmente de forma centralizada pelo ONS otimizando os fluxos de energia elétrica e geralmente não corresponde ao despacho contábil ou comercial.

Um algoritmo determinístico para o planejamento de médio prazo é sugerido por Oliveira & Soares (1995). Martinez (2001) compara as diferentes metodologias de planejamento energético relevando as características favoráveis da política de controle em malha aberta.

4.3 Leilão de Energia Elétrica

A reestruturação da indústria de energia elétrica em diferentes países introduziu competitividade através da sua desverticalização. Segundo a filosofia de mercado dos diferentes modelos implementados, diversos mecanismos de leilão são utilizados. Há uma enorme variação nos tipos de leilão que foram implementados nos diferentes modelos de reestruturação. Porém dois objetivos primordiais podem ser identificados: o leilão é projetado como um mecanismo eficiente de alocação de recursos e de formação de preços da energia⁸. O leilão pode ser executado pelo ISO (*Independent System Operator*), por uma ou mais Bolsas de Energia (PX, *Power Exchange*) ou pelo *pool*.

Além de serem utilizados como mecanismos de mercado, os leilões têm sido utilizados também no processo de desverticalização e privatização dos ativos das empresas de energia. Porém nos referimos a (Dutra & Menezes 2001a, Dutra & Menezes 2001b) para tratar destes leilões de vendas de ativos que não são abordados neste trabalho. É importante salientar que a reestruturação da indústria de energia elétrica não depende de privatizações, mesmo que estas sejam frequentemente implementadas durante os processos de desverticalização. Prova de que as privatizações não são uma condição necessária a uma reestruturação adequada é o setor elétrico norueguês, onde as empresas continuaram na sua maioria sob controle estatal, e operando através de um mecanismo de mercado que incentiva a competição e reduz as ineficiências econômicas (Rosa, Tolmasquim & Pires 1998).

O modelo de leilão que apresentamos neste trabalho é o leilão onde os fornecedores de energia fazem ofertas de quantidade e preço para atender uma determinada previsão de demanda em um determinado período de tempo. Este leilão é diferente do leilão duplo (*double auction*) onde há ofertas não somente dos vendedores mas também dos compradores de energia⁹. O leilão de energia caracteriza-se por ser um leilão reverso (ou de *procurement*), onde se pretende comprar energia dos agentes que a oferecem pelo menor preço, em contraposição ao leilão inglês onde uma mercadoria é vendida àquele que oferece o maior lance.

Há diversas maneiras de se definir o preço da energia. No leilão duplo as ofertas de compra e venda são casadas e definem um preço de equilíbrio em cada rodada do leilão. No leilão simples, dentre as maneiras mais usuais de definição do preço pago pela energia temos: a preço discriminatório, onde cada lance aceito é pago ao preço do lance realizado, e a preço uniforme, onde todas os lances aceitos são pagos ao preço do maior lance aceito.

De maneira diversa aos leilões abertos (*open cry*) como o inglês e o holandês, o leilão de energia é frequentemente caracterizado como um leilão fechado (*sealed bid auction*) onde os lances não são de conhecimento público. A menos da formação de conluio entre os agentes, um agente

⁸Na seção 3.6 citamos boa parte dos leilões realizados no setor de energia no Brasil.

⁹Apesar de ser considerado economicamente mais eficiente o leilão duplo é mais complexo e talvez por essa razão tenha sido utilizado apenas em alguns mercados como os da Califórnia e da Nova Zelândia.

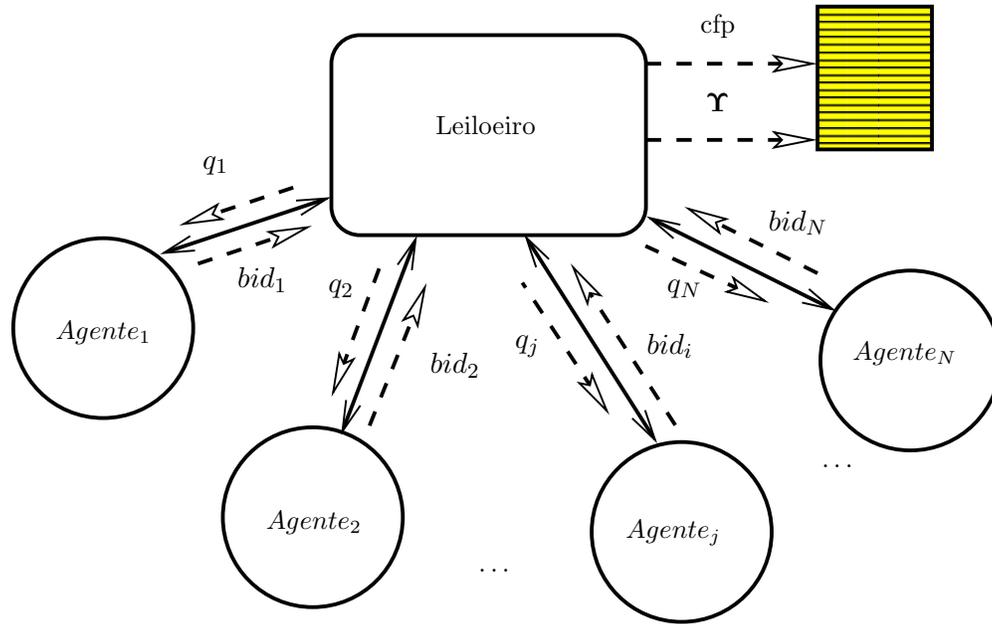


Figura 4.1: Atividades no leilão de energia.

não conhece as ofertas dos competidores. A informação de preço e quantidade de cada oferta (*bid*) é de domínio privado do leiloeiro (*auctioneer*) e do agente que realizou a oferta.

O leilão de energia no curto prazo pode ser realizado no dia anterior à previsão de demanda (*day ahead market*) e estabelece preços para a demanda de 24 períodos de 1 hora ou 48 períodos de meia hora. Estes períodos podem ir da zero hora às 23 horas do dia seguinte mas também podem começar às 6 da manhã do dia seguinte e terminar às 6 do outro dia. A definição destes períodos é arbitrária e indiferente para este estudo onde é modelado um leilão de 24 lances horários de energia no dia anterior à demanda.

4.3.1 Protocolo do Leilão a Preço Uniforme

É possível então estabelecer um protocolo de funcionamento do leilão fechado a preço uniforme (*uniform price sealed bid auction*) como ilustrado na Figura 4.1.

Para cada dia de leilão o leiloeiro deve¹⁰:

1. abrir o leilão;
2. publicar a previsão de demanda para o dia seguinte;
3. aceitar lances dos agentes participantes no leilão;

¹⁰Anteriormente ao início do leilão em um determinado momento o leiloeiro deve aceitar a inscrição de novos interessados em participar no leilão e de algum modo deve neste momento verificar garantias dos participantes.

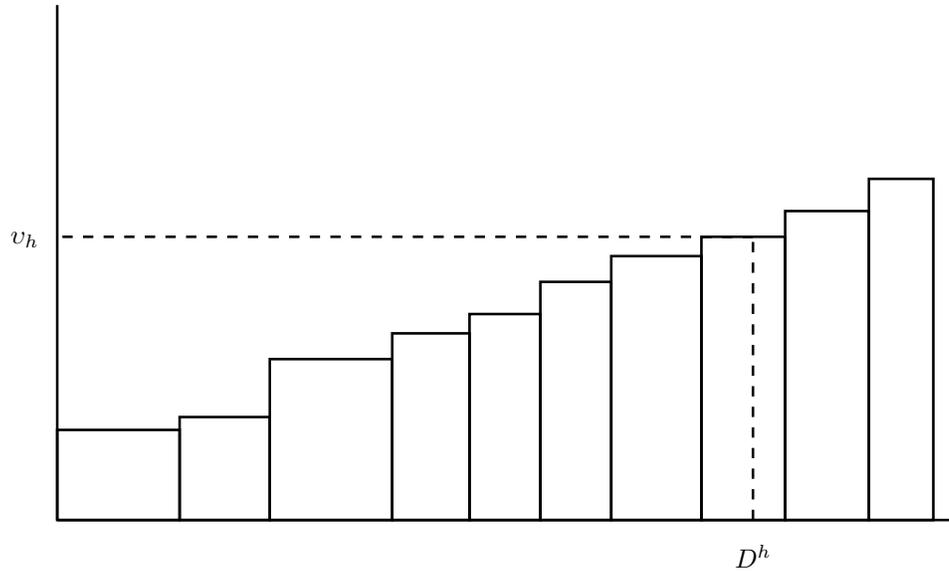


Figura 4.2: Ordem de mérito de leilões de energia.

4. encerrar o recebimento de lances;
5. aplicar o algoritmo de formação de preço;
6. publicar o vetor de preços horários v ;
7. informar a cada agente a quantidade de energia aceita a ser produzida;
8. fechar o leilão.

Este leilão é um mecanismo de alocação *ex ante*, onde o leiloeiro faz uma previsão de demanda e despacha cada agente supondo a priori que a demanda será aquela prevista. Não detalhamos os mecanismos de contabilização *ex ante* e *ex post* e fazemos uma simplificação assumindo que o leiloeiro prevê exatamente o que será demandado. Porém dificilmente a demanda corresponderá exatamente ao que foi previsto e então serão necessários mecanismos de contabilização *ex post* que corrijam a posteriori o que foi realmente produzido em relação ao que deveria ter sido produzido. O mecanismo proposto em (GCE 2002b) introduz uma peculiaridade: elimina a liquidação *ex-ante* sob a justificativa de que as previsões são muito incertas e que esta liquidação estaria sujeita a manipulações por parte dos agentes. Isto implica que ao contrário dos outros leilões de energia o preço *spot* só seria conhecido no dia posterior ao despacho.

4.3.2 Algoritmo de Formação de Preço

O algoritmo de formação de preço implementado é, para cada um dos intervalos de tempo (e.g. 24 períodos de 1 hora), ordenar os lances, do menor para o maior preço, até atender a demanda

no período. Esse algoritmo é a ordem de mérito (*merit order*) e, a preço uniforme o preço horário é definido como o lance marginal ou o último lance aceito para atender a demanda, como ilustrado na Figura 4.2.

Maximizar o *benefício social* corresponde a minimizar o custo total pago pelo mercado (e portanto pelos consumidores) maximizando o lucro percebido pelos agentes produtores. Por esta razão procura-se despachar os lances de menor preço pela ordem de mérito.

Agente	quantidade (MW)	preço (R\$/MWh)	oferta agregada (MW)
Angra 1	657	8,500	657
Angra 2	1.309	8,500	1.966
P.Medici	446	32,945	2.412
Canoas	500	37,951	2.912
Araucaria	480	38,038	3.392
Argentina I	1.018	41,045	4.410
Argentina II	1.000	41,046	5.410
J.Lacerda C	363	52,638	5.773
J.Lacerda B	262	63,302	6.035
J.Lacerda A	232	65,965	6.267
Charqueadas	72	68,043	6.339
Uruguaiana	600	82,951	6.939
R.Silveira	32	91,782	6.971

Tabela 4.2: Ofertas de preço em uma determinada hora h .

A título de exemplo poderíamos tomar termoeletricas de diferentes tecnologias como na Tabela 4.7 e a demanda de uma determinada hora na região sul. As termoeletricas do exemplo não se encontram neste sub-mercado que é atendido essencialmente como todo o mercado nacional por geração hídrica. Então, se em uma determinada hora h o leiloeiro receber ofertas como na Tabela 4.2 para atender uma demanda de 5.527,8 MW, o resultado seria um preço *spot* de R\$52,64/MWh correspondente ao preço ofertado pelo último gerador a ser despachado para atender a previsão de demanda.

O agente J.Lacerda C é o agente marginal. Os agentes com ofertas abaixo do preço marginal têm a oferta aceita (e a priori despachada) na sua totalidade, o agente marginal é despachado até atender a demanda, completando no caso a diferença $5.527,8 - 5.410$, e aqueles que realizaram lances acima do preço marginal não são despachados (produziriam 0 naquela hora).

Todos os agentes auferem receita equivalente à quantidade de energia produzida paga ao preço *spot* como pode ser observado na Tabela 4.3. A obtenção das funções de custo, do custo marginal e do lucro horário (receita subtraída do custo) é detalhada na seção 4.3.4.

Agente	Energia (MWh)	C.Marginal (R\$/MWh)	Receita (R\$)	Custo (R\$)	Lucro (R\$)
Angra 1	657	8,50	34.583	5.584	28.998
Angra 2	1.309	8,50	68.903	11.126	57.776
P.Medici	446	32,95	23.476	14.991	8.486
Canoas	500	37,95	26.319	19.530	6.789
Araucaria	480	38,04	25.266	18.742	6.524
Argentina I	1.018	41,05	53.585	42.034	11.551
Argentina II	1.000	41,05	52.638	41.290	11.348
J.Lacerda C	117,8	52,64	6.201	7.089	-888
J.Lacerda B	0	63,30	0	1.408	-1.408
J.Lacerda A	0	65,97	0	1.334	-1.334
Charqueadas	0	68,04	0	415	-415
Uruguaiana	0	82,95	0	4.307	-4.307
R.Silveira	0	91,78	0	431	-431

Tabela 4.3: Resultado do algoritmo de formação de preço para hora h .

4.3.3 Definição do Instrumento de Oferta

Na exemplificação do algoritmo de formação de preço, cada agente participante no leilão fez uma única oferta de [quantidade, preço]. Este seria um instrumento de *bid* simples.

Porém pode ser definido no leilão um instrumento de *bid* múltiplo onde cada agente oferta para cada hora várias quantidades a diferentes preços.

quantidade (MW)	preço (R\$/MWh)
50	30,000
150	37,951
200	40,000
100	60,000

Tabela 4.4: *Bid* múltiplo do agente Canoas.

Segundo sua estratégia de oferta (*bidding*) o agente Canoas poderia por exemplo ofertar energia como na Tabela 4.4 o que levaria a uma nova ordenação das ofertas (Tabela 4.5) e a um resultado diferente para os agentes Canoas e J.Lacerda C, porém sem alterar neste caso o preço *spot* (Tabela 4.6).

Aparentemente não há razão para que um agente oferte energia deste modo pois estaria recebendo menos receita e conseqüentemente realizando um lucro menor. Porém isto não é sempre verdade quando pensamos em um agente hidrelétrico que deseja acumular água no reservatório para vender energia a um preço cuja expectativa seja de aumento no futuro.

No projeto do leilão, além de múltiplas ofertas de energia outros parâmetros podem compor

Agente	quantidade (MW)	preço (R\$)	oferta agregada (MW)
Angra 1	657	8,500	657
Angra 2	1.309	8,500	1.966
Canoas	50	30,000	2.016
P.Medici	446	32,945	2.412
Canoas	150	37,951	2.612
Araucaria	480	38,038	3.092
Canoas	200	40,000	3.292
Argentina I	1.018	41,045	4.310
Argentina II	1.000	41,046	5.310
J.Lacerda C	363	52,638	5.673
Canoas	100	60,000	5.773
J.Lacerda B	262	63,302	6.035
J.Lacerda A	232	65,965	6.267
Charqueadas	72	68,043	6.339
Uruguaiana	600	82,951	6.939
R.Silveira	32	91,782	6.971

Tabela 4.5: Ordem das ofertas de preço em uma determinada hora h para múltiplos lances.

o *bid* múltiplo. No mercado espanhol cada participante pode fazer ofertas de quantidade e preço e três outros parâmetros que são levados em conta na formação dos preços (Contreras, Candiles, de la Fuente & Gómez 2001):

- Uma quantidade (de energia) não divisível: a oferta mais barata de cada agente corresponde à uma quantidade indivisível, é despachada na sua totalidade ou não é despachada. Serve para que agentes termoeletrônicos possam definir o nível mínimo acima do qual devem produzir.
- Receita diária mínima: minimiza riscos dos geradores que têm de internalizar custos dos combustíveis para *start up* e para manter a usina sem carga.
- *Ramp rates* ou taxas de subida e descida, as variações máximas na saída de uma unidade em horas consecutivas que o algoritmo de despacho tem de respeitar.

O mecanismo que foi proposto pelo Comitê de Revitalização considerava o instrumento de *bid* múltiplo, onde cada agente informa N pares [quantidade, preço]. A expectativa era de que os agentes contratados oferecessem um bloco de energia equivalente ao montante contratado a um preço baixo para assegurar que este bloco fosse despachado e outro bloco que refletiria a percepção do agente do valor da energia (GCE 2002b).

Agente	Energia (MWh)	C.Marginal (R\$/MWh)	Receita (R\$)	Custo (R\$)	Lucro (R\$)
Angra 1	657	8,50	34.583	5.584	28.998
Angra 2	1.309	8,50	68.903	11.126	57.776
P.Medici	446	32,95	23.476	14.991	8.486
Canoas	400	37,95	21.056	15.775	5.281
Araucaria	480	38,04	25.266	18.742	6.524
Argentina I	1.018	41,05	53.585	42.034	11.551
Argentina II	1.000	41,05	52.638	41.290	11.348
J.Lacerda C	217,8	52.64	11.464	11.993	-528
J.Lacerda B	0	63,30	0	1.407,65	-1.407,65
J.Lacerda A	0	65,97	0	1.333,79	-1.333,79
Charqueadas	0	68,04	0	414,59	-414,59
Uruguiana	0	82,95	0	4.306,82	-4.306,82
R.Silveira	0	91,78	0	431,36	-431,36

Tabela 4.6: Resultado do algoritmo de formação de preço na hora h para múltiplos lances.

4.3.3.1 Mecanismo de Realocação de Energia

Apesar de ter proposto um novo mecanismo para a formação do preço da energia no curto prazo, o Comitê de Revitalização propôs a manutenção do Mecanismo de Realocação de Energia (MRE) com base nos certificados de energia assegurada para não quebrar contratos estabelecidos na privatização de algumas empresas, notadamente a EletroSul e a CESP.

A incorporação do MRE no mecanismo de formação de preço por oferta se faria desacoplando o despacho físico do despacho contábil. As usinas continuam a ser despachadas de maneira “otimizada” pelo ONS respeitando restrições de fluxo elétrico e uso múltiplo da água. Contabilmente cada usina possui uma conta onde são adicionados depósitos proporcionais ao total de energia afluyente do sistema segundo os certificados de energia assegurada, ou seja, preservando de algum modo o MRE ainda que hoje ele seja calculado com base na energia efetivamente produzida.

Este mecanismo pode parecer interessante pois liberaria o sistema dos jogos (*gaming*) provocados pelos agentes que poderiam se aproveitar de restrições operativas do sistema para aumentar o preço da energia e garantindo que são despachados do mesmo modo. Este comportamento, de agentes aproveitando restrições de transmissão para inflacionar preços, foi observado no mercado da Califórnia (Niimura & Nakashima 2001).

Os dados necessários ao cálculo do Mecanismo de Realocação de Energia detalhado nos relatórios do Comitê (GCE 2002a, GCE 2002b) estariam disponíveis ao Mercado Atacadista e ao ONS. Porém, na realidade não há energia afluyente ao sistema, o que aflui ao sistema é água. Dependendo de como esta água é turbinada ela é transformada em energia mas no caso extremo se ela for vertida, sua energia afluyente seria zero. O cálculo da energia afluyente leva em conta

a produtividade média das usinas. Isto implica que não haveria qualquer incentivo para uma melhora de produtividade na operação dos agentes a menos de uma revisão dos certificados de energia assegurada.

4.3.4 Equacionamento das Funções de Custo e Lucro

4.3.4.1 Função de Custo Termoelétrico

Termoelétrica	tipo	Capacidade (MW)	Cap.Agregada (MW)	Custo ONS (R\$/MWh)	Custo Marg. (R\$/MWh)
Angra 1	nuclear	657	657	8,50	8,50
Angra 2	nuclear	1.309	1.966	8,50	8,50
P.Medici	carvão	446	2.412	30,93	32,945
Canoas	gás	500	2.912	35,91	37,951
Araucaria	gás	480	3.392	35,91	38,038
Argentina I	gás	1.018	4.410	36,91	41,045
Argentina II	gás	1.000	5.410	36,91	41,046
J.Lacerda C	carvão	363	5.773	49,3	52,638
J.Lacerda B	carvão	262	6.035	59,75	63,302
J.Lacerda A	carvão	232	6.267	62,50	65,965
Charqueadas	carvão	72	6.339	64,04	68,043
Uruguaiiana	gás	600	6.939	79,84	82,951
R.Silveira	gás	32	6.971	88,27	91,782

Tabela 4.7: Exemplo de termoelétricas remodeladas com custos quadráticos.

A definição de funções quadráticas de custo de termoelétricas a gás, carvão e óleo pode ser feita a partir de funções de entrada x saída segundo (El-Hawary & Christensen 1979). Para cada tipo de fonte energética fóssil e algumas capacidades encontram-se diferentes coeficientes $\hat{\alpha}$, $\hat{\beta}$, $\hat{\gamma}$ que definem a função de custo do combustível necessário para produzir uma determinada potência ativa P_s como na expressão (4.2).

$$F(P_s) = \hat{\alpha} + \hat{\beta}P_s + \hat{\gamma}P_s^2 \quad [\text{GJ/h}] \quad (4.2)$$

$$\frac{dF(P_s)}{dP_s} = \hat{\beta} + 2\hat{\gamma}P_s \quad [\text{GJ/MWh}] \quad (4.3)$$

Estes parâmetros foram interpolados, as curvas obtidas derivadas e as funções de custo marginal agora em função de $g_{j,h}$ ajustadas para corresponderem ao custo declarado ao ONS quando a usina está à metade de sua capacidade. O custo declarado ao ONS é aquele atualmente utilizado nas otimizações e de domínio público (ONS 2002).

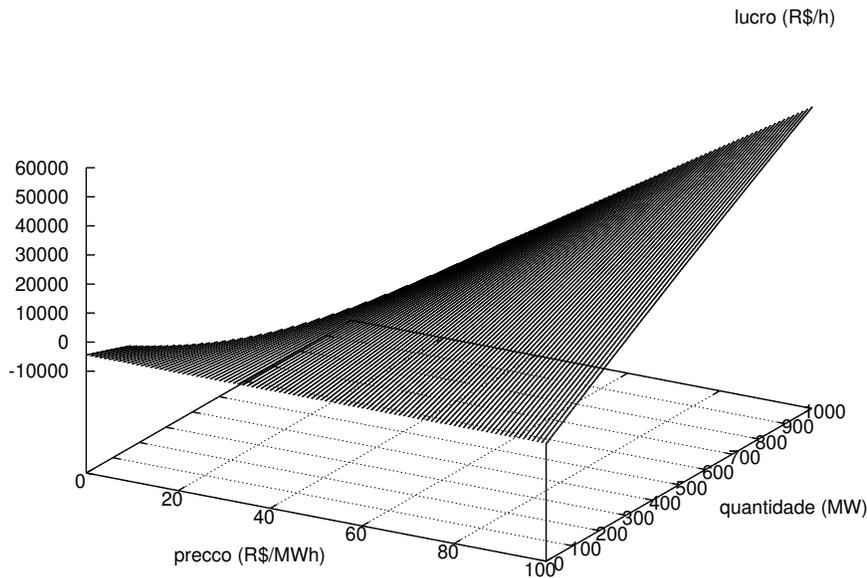


Figura 4.3: Lucro de Argentina II para diferentes preços (em R\$/h).

$C_j(\cdot)$ equivale à função de custo dos geradores dada por $F(P_s)$ multiplicada pelos custos do combustível em R\$/GJ. E deste modo temos a função de custo do agente j para produzir a energia $g_{j,h}$ na hora h dada por:

$$C_j(g_{j,h}) = \alpha + \beta g_{j,h} + \gamma g_{j,h}^2 \quad [\text{R}/\text{h}] \quad (4.4)$$

Seguindo este procedimento para o agente Argentina II por exemplo, a função de custo é dada pela expressão (4.5) a menos de uma aproximação dos parâmetros.

$$C(g_{j,h}) = 4.379,82 + 32,774 g_{j,h} + 0,00414 g_{j,h}^2 \quad [\text{R}/\text{h}] \quad (4.5)$$

$$\frac{dC(g_{j,h})}{dg_{j,h}} = 32,774 + 0,00828 g_{j,h} \quad [\text{R}/\text{MWh}] \quad (4.6)$$

Aplicando-se o mesmo procedimento a algumas termoeletricas a combustíveis fósseis obtém-se a Tabela 4.7 onde a coluna custo marginal corresponde ao custo marginal a plena capacidade. Como as curvas foram ajustadas para corresponderem ao custo declarado ao ONS à metade da capacidade, há um significativo incremento no custo marginal a plena capacidade.

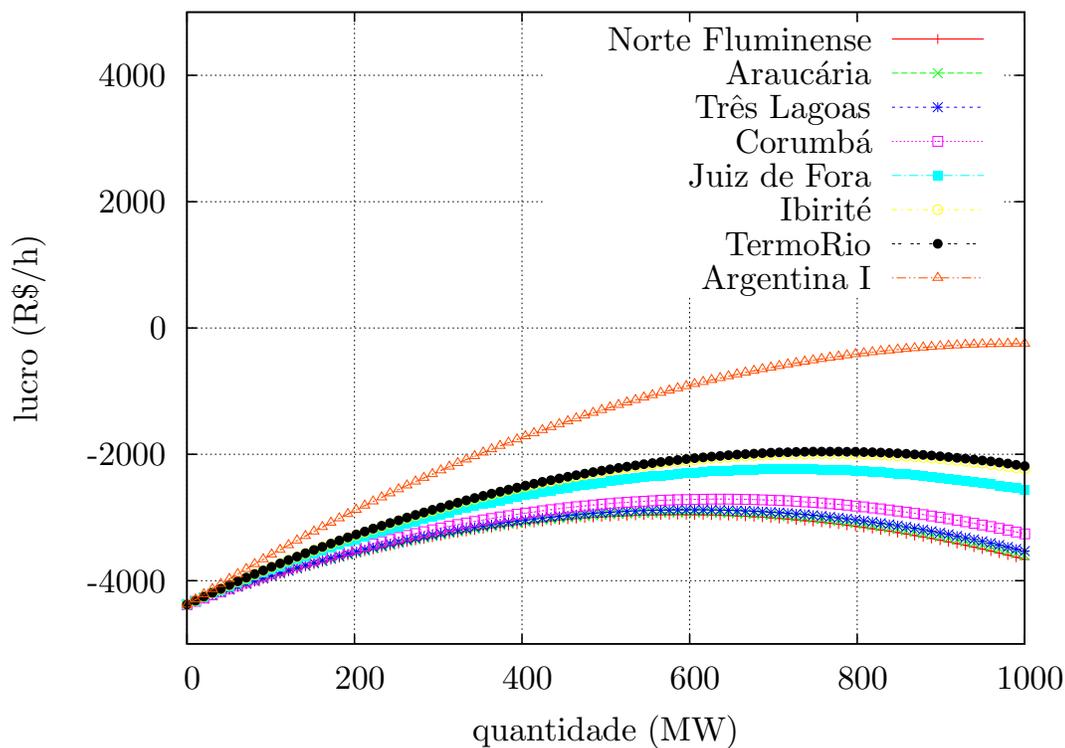


Figura 4.4: Lucro de Argentina II para diferentes geradores marginais.

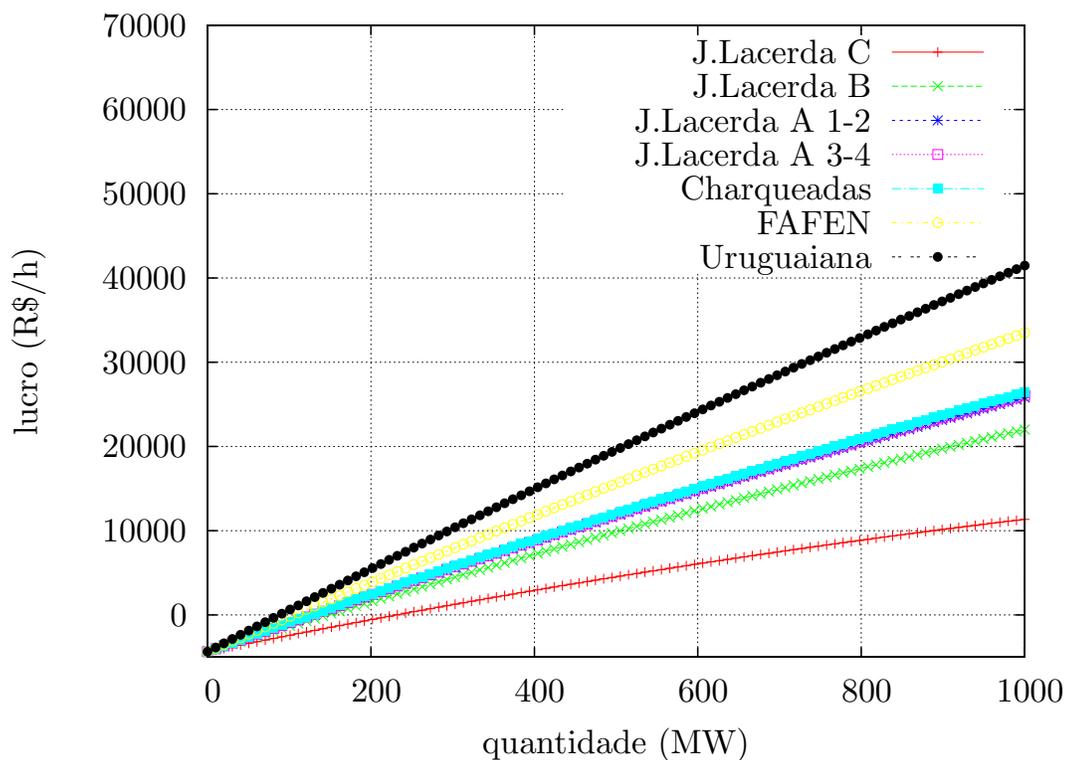


Figura 4.5: Lucro de Argentina II para diferentes geradores marginais.

4.3.4.2 Receita e Lucro

Segundo o algoritmo de formação de preços, ignorando-se o MRE, todos os T_h agentes despachados na hora h são retribuídos pelo preço *spot* do sub-mercado v_h , segundo a quantidade despachada $g_{j,h}$, auferindo uma receita $R_{j,h} = v_h g_{j,h}$ e um lucro dado pela expressão (4.7) onde $C(\cdot)$ é a função de custo do agente j .

$$P_{j,h} = R_{j,h} - C_j(g_{j,h}) \quad [\text{R\$/h}] \quad (4.7)$$

A função de lucro do agente Argentina II para diferentes preços encontra-se na Figura 4.3. Utilizando os preços resultantes de tomarmos cada uma das usinas da configuração de mercado da Tabela 7.1 como gerador marginal, obtém-se as funções de lucro¹¹ do agente Argentina II que encontram-se nas Figuras 4.4 e 4.5.

Para atender à demanda deve-se respeitar a cada hora h o balanço energético dado pela expressão (4.8) já que a demanda é considerada inelástica. Uma demanda elástica significa uma demanda $D_h(v_h)$ função do preço da energia.

$$\sum_{j=1}^{T_h} g_{j,h} = D_h \quad (4.8)$$

O despacho na hora h custaria ao mercado $D_h v_h(D_h)$, equivalente à receita total auferida pelos geradores uma vez que neste modelo o operador do mercado não tem fins lucrativos.

Maximizar o *benefício social* pode corresponder a minimizar esse custo total horário pago pelo mercado (e portanto pelos consumidores) maximizando o lucro percebido pelos agentes produtores. Por esta razão procura-se despachar as ofertas mais baratas segundo a ordem de mérito deixando as termoeletricas caras como capacidade de reserva para os horários de ponta.

No Capítulo 6 tratamos de uma abordagem para o projeto de estratégias de oferta de energia e revisamos o tema.

4.4 Mercado Financeiro

No mercado financeiro os contratos são derivativos negociados com base no preço *spot* e têm como função proteger vendedores de preços baixos e compradores de preços altos, isto é, fornecer aos agentes econômicos uma proteção (*hedging*) da volatilidade do mercado.

¹¹Lucro negativo significa um prejuízo para o agente, com receita inferior aos custos.

Há vários tipos de contrato nos mercados de energia elétrica (Ilic & Skantze 2000):

- opções de compra e venda (*options*)
- contratos a termo (*forward*)
- contratos futuros (*future*)
- contratos de *swap*
- contratos bilaterais (*nonstandard options*)

Nascimento & Nunes (2001) descrevem os vários instrumentos financeiros que podem ser utilizados na gestão de riscos e indicam os derivativos de clima baseados na hidrologia como uma alternativa para a redução de riscos inerentes às oscilações climáticas.

4.4.1 Contratatação Bilateral

Os contratos bilaterais comercializados no Brasil são instrumentos financeiros (contratos a termo) que definem condições para entrega e comercialização de energia. Na contratação bilateral agentes negociam contratos de compra e venda de energia a preço de contrato. Os agentes geradores de energia podem participar como vendedores, as distribuidoras e consumidores livres como compradores e as comercializadoras ou *traders* podem atuar como compradores e como vendedores de energia.

Atualmente os consumidores cativos são obrigados a comprar energia da distribuidora à qual suas unidades consumidoras estão fisicamente conectadas a preços tarifados. As distribuidoras podem ser vistas como uma demanda agregada ou como revendedores de energia que devem comprar energia necessária para atender a demanda de seus consumidores.

No mercado brasileiro quando efetuados os contratos são registrados na agência reguladora (ANEEL) e a informação das quantidades contratadas entre os agentes é fornecida à CCEE. A informação do preço da energia contratada permanece de caráter privado e não é de conhecimento dos competidores nem do mercado.

4.4.1.1 Exemplo de Contratação Bilateral

Para entender como funciona a contratação bilateral de energia no Brasil pode tomar-se na Tabela 4.8 um exemplo adaptado de (PSR 1998). No exemplo os agentes $T_j, j = 1, 2, 3$ são produtores (vendedores) de energia termoeletrica e o agente H_1 um gerador hidrelétrico. Os agentes D_1 e D_2 representam demandas (compradores) de energia.

Agente	Geração (MWh)	Carga não contratada (MWh)	Carga contratada (MWh)	Receita <i>spot</i> (R\$)	Receita contratos (R\$)
T_1	$P_{T_1}^k$		Q_{T_1}	$(P_{T_1}^k - Q_{T_1})p^k$	$Q_{T_1}X_{T_1}$
T_2	$P_{T_2}^k$		0	$P_{T_2}^k p^k$	0
H_1	$P_{H_1}^k$		0	$P_{H_1}^k p^k$	0
T_3	0		Q_{T_3}	$-Q_{T_3}p^k$	$Q_{T_3}X_{T_3}$
D_1		0	Q_{T_1}	0	$-Q_{T_1}X_{T_1}$
D_2		P_{D_2}	Q_{T_3}	$-P_{D_2}p^k$	$-Q_{T_3}X_{T_3}$
Total	$\sum_{i \in \mathcal{G}} P_i^k$	$\sum_{j \in \mathcal{D}} P_j^k$	$\sum_{j \in \mathcal{D}} Q_j$	0	0

Tabela 4.8: Exemplo de contratação bilateral no mercado brasileiro.

A demanda D_1 e o gerador T_1 estabeleceram um contrato bilateral de Q_{T_1} MWh por período a um preço de execução (*strike price*) X_{T_1} . Já a demanda D_2 estabeleceu um contrato de Q_{T_3} MWh com o gerador T_3 a um preço X_{T_3} .

Em um período¹² k cada gerador $i \in \mathcal{G}$, $\mathcal{G} = \{T_j, H_1\}$, deve produzir segundo o algoritmo de formação de preços uma energia P_i^k . Já as demandas consomem uma energia não contratada P_j^k mais a energia de contrato Q_G .

Os agentes geradores T_2 e H_1 não estabeleceram nenhum contrato bilateral e portanto recebem no mercado receita referente à venda ao preço *spot* p^k de toda sua produção, respectivamente $P_{T_2}^k p^k$ e $P_{H_1}^k p^k$.

O gerador T_3 não produziu pois sua oferta foi acima do preço marginal p^k mas deve garantir a compra de Q_{T_3} MWh contratados e paga ao mercado $Q_{T_3}p^k$ recebendo da demanda D_2 o equivalente ao contratado a preço de contrato $Q_{T_3}X_{T_3}$. Se o preço *spot* é menor que o preço de execução do contrato $p^k < X_{T_3}$ então o gerador percebe uma receita líquida $Q_{T_3}(X_{T_3} - p^k)$. Caso contrário amarga um pagamento no período de $Q_{T_3}(p^k - X_{T_3})$. Em outras palavras, se o agente T_3 foi hábil na negociação de um bom preço de execução do contrato ele obtém lucro comprando energia no mercado ao preço *spot* e vendendo ao preço de contrato, provavelmente porque o preço *spot* é menor que seus próprios custos de produção. Caso contrário o agente teria um incentivo a oferecer energia mais barata e entrar no despacho.

É o que ocorre com o gerador T_1 que produziu no período $P_{T_1}^k$ MWh pelos quais recebe do mercado $P_{T_1}^k p^k$. Porém como o gerador estabeleceu um contrato de Q_{T_1} MWh deve comprá-los do mercado ao preço *spot* ficando com a diferença $(P_{T_1}^k - Q_{T_1})p^k$. Se a quantidade produzida é maior (menor) que a contratada o agente recebe do (paga ao) mercado. Entretanto a receita total do agente é esta receita (pagamento) *spot* mais a receita referente ao contrato recebida da demanda D_1 : $R_{T_1} = P_{T_1}^k p^k + Q_{T_1}(X_{T_1} - p^k)$.

¹²Atualmente os períodos de contabilização no mercado brasileiro são semanais mas os contratos em geral são estabelecidos com quantidades mensais e preços que podem ser sazonais.

A demanda D_1 consome somente a energia contratada e portanto paga ao agente T_1 Q_{T_1} MWh ao preço X_{T_1} . Já a demanda D_2 consome além dos Q_{T_3} MWh contratados de T_3 e pagos a este agente a preço de contrato X_{T_3} outros $P_{D_2}^k$ comprados do mercado a preço *spot*.

Obviamente este exemplo pode ser estendido ao caso onde cada agente estabelece contratos com vários outros agentes.

Observe que na Tabela 4.8 as quantidades produzidas e demandadas obedecem em cada período ao balanço energético entre a geração e a carga dado pela expressão (4.9) pois assume-se que não há elasticidade da demanda.

$$\sum_{i \in \mathcal{G}} P_i^k = \sum_{j \in \mathcal{D}} P_j^k + \sum_{j \in \mathcal{D}} Q_j \quad (4.9)$$

É relevante notar que a contabilização na CCEE considera somente energia contratada, o preço de execução do contrato é um acordo privado entre os agentes e o fluxo financeiro correspondente a este acordo (última coluna à direita, receita contratos) não é conhecido pelo mercado atacadista. Outra observação importante é que o operador do leilão não realiza lucro o que equivale à receita *spot* total igual a zero na Tabela 4.8.

A importância da contratação bilateral reside no fato da agência reguladora brasileira obrigar a contratação de boa parte da demanda das distribuidoras (anteriormente 85%, então 95% e atualmente 100% da carga) com o objetivo de garantir o financiamento da expansão da oferta. Essa arbitragem também se justifica no intuito de diminuir a exposição dos agentes à volatilidade de preços, protegendo compradores (distribuidores) de preços altos e vendedores (geradores) de preços muito baixos.

Indubitavelmente o nível de contratação de um agente influi no seu comportamento no leilão (Wolak 2000). Um fornecedor (gerador) contratado espera que os preços a curto prazo sejam baixos (ou ao menos menores ou iguais aos preços pelos quais contratou sua energia). Já um comprador contratado tende a ser indiferente a preços altos. Além disso o preço esperado de curto prazo serve para sinalizar os preços dos novos contratos a serem estabelecidos.

A contratação bilateral também pode ser implementada através de um leilão de contratos padronizados onde um ou mais geradores oferecem energia e os compradores que oferecem o melhor preço estabelecem então um contrato de fornecimento com o gerador responsável por aquele lote. Este leilão pode ser implementado como um leilão inglês, com ofertas abertas. O MAE realizou diversos leilões de contratos de 25% da energia dos contratos estabelecidos pelas estatais federais no início da reestruturação, os contratos iniciais, em lotes padronizados de 0,5 MW e períodos de 2, 4 ou 6 anos. Além das estatais federais outras empresas participaram do leilão. Porém o resultado destes leilões realizados em 2002 ficaram abaixo das expectativas devido a uma sobre-oferta de

energia como consequência do racionamento de 2001.

A CCEE realizou desde 2004 alguns leilões de energia onde os distribuidores formam um *pool* (ou “condomínio”) e este *pool* compra energia de geradores em um leilão reverso descendente. O resultado final deste leilão é uma série de contratos bilaterais entre cada uma das distribuidoras que formam o *pool* e cada um dos geradores de energia. Estes leilões evidenciam a importância dos leilões e da contratação bilateral em mercados de energia, ainda que estes não sejam leilões realizados diariamente. Almeida & Camargo (2006) trazem um apanhado dos leilões realizados no mercado brasileiro de energia elétrica, ao longo do seu processo de reestruturação.

4.5 Regulação do Mercado de Energia

A regulação do mercado de energia elétrica pode ser vista como um sistema complexo onde distinguimos seis funções principais (Genoud 2003):

1. projeto do arcabouço legal setorial;
2. reforço das obrigações dos serviços públicos;
3. regulação da competição e anti-truste;
4. regulação de monopólios naturais;
5. implementação de políticas públicas;
6. avaliação da liberalização e do arcabouço regulatório.

Genoud (2003) destaca o papel das Agências Reguladoras Independentes como tomadores de decisão e gestores de rede (*network managers*) no jogo da regulação. Este jogo é tradicionalmente modelado como o jogo principal-agente onde a agência reguladora é o principal e os agentes regulados tomam o papel do agente (Laffont & Martimort 2001). A crítica um tanto pretensiosa de (Genoud 2003) é a de que falta a esta abordagem tradicional uma melhor conceituação das dimensões organizacional e inter-organizacional do processo de regulação. Os aspectos inter-organizacionais são reduzidos a interações entre dois agentes racionais: o agente e o principal. E os aspectos organizacionais (relações de poder dentro das organizações) são demasiadamente simplificados ou completamente desprezados. A principal razão é que não há no jogo principal-agente um modelo do processo regulatório em si.

Em (FERC 2003), a agência reguladora do mercado norte-americano discute os quatro principais objetivos de um mercado atacadista de energia:

- serviço confiável (ausência de *blackouts* e *brownouts*);

- livre acesso às linhas de transmissão;
- sinais econômicos (preços) adequados que garantam incentivos aos investimentos necessários em capacidade de geração e transmissão;
- procedimentos efetivos de fiscalização do mercado e de mitigação do poder de mercado.

Estes são os macro objetivos de um agente regulador que está preocupado com o projeto de um mercado eficiente.

Capítulo 5

Sistemas Multiagentes e Economias Artificiais no Mercado de Eletricidade

Economics is one of the sciences of the artificial.
(Simon 1979)

5.1 Introdução

Este capítulo descreve uma abordagem baseada em Sistemas Multiagentes para a simulação de economias através da análise, modelagem, implementação e simulação de economias artificiais povoadas por agentes de *software* que representam agentes econômicos com interesse próprio. Os agentes de *software* são os constructos de um sistema econômico complexo, uma *economia artificial baseada em agentes*¹ (Batten 2000).

O interesse principal desta abordagem é possibilitar a simulação de mercados artificiais, que podem representar um modelo de um mercado real existente ou um projeto de mercado. O objetivo maior é a análise do comportamento que emerge da interação de diferentes agentes com interesse próprio participando da economia artificial, denominado “comportamento emergente”. Na literatura esta abordagem é tipicamente definida como Economia Computacional baseada em Agentes (ou ACE, *Agent-based Computational Economy*) (Tsfatsion 2002, Tsfatsion & Judd 2006).

5.2 Sistemas Multiagentes na Síntese de Economias Artificiais

A arquitetura sugerida neste trabalho é inspirada na Programação Orientada a Mercados (MOP), concebida por Wellman (1993)². O principal objetivo é a obtenção de uma arquitetura

¹*Agent Based Artificial Economy.*

²Para sucinta revisão de Programação Orientada a Mercados ver seção 3.8.

genérica que através da criação de instâncias apropriadas nos permita analisar, modelar, projetar e simular diferentes estruturas de organização industrial e seus correspondentes mercados.

Em alguns setores da economia, e.g. mercados de energia, não há consenso a respeito da estrutura mais eficiente que resulte em um maior benefício social no seu sentido mais amplo, garantindo no caso dos mercados de energia preços baixos (modicidade tarifária) e confiabilidade no atendimento corrente através da operação correta e no atendimento futuro através do estímulo a novos investimentos. Deste modo uma arquitetura adequada deve propiciar que diferentes instâncias equivalentes a estruturas de mercado diversificadas sejam criadas e implementadas para facilitar a análise e projeto das diferentes alternativas estruturais, e permitir a comparação de suas vantagens e eventuais desvantagens e vulnerabilidades.

Tomando novamente o mercado de energia elétrica como exemplo, uma instância da arquitetura proposta é o despacho centralizado comum a estes mercados antes da reestruturação ocorrida nos últimos anos. Outra instância é o *pool* baseado em mecanismos de leilão, comum aos mercados reestruturados.

No caso do mercado de energia brasileiro, a instância mais adequada para representá-lo seria um modelo híbrido. Neste modelo híbrido a operação, o despacho e a formação de preços de curto prazo se dão de forma centralizada e são baseados em modelos de otimização, a competição para o estabelecimento de contratos de longo prazo é baseada em leilões e o estabelecimento de contratos bilaterais é baseada em mecanismos de negociação. Finalmente a competição pelo mercado³, para decidir qual agente econômico obtém o direito de construção de determinado empreendimento, também é modelada através de leilões.

5.2.1 Arquitetura Multiagentes de Mercado

A entidade constituinte da arquitetura AEMAS (*Artificial Economy MultiAgent System*) sugerida é o agente inteligente de Wooldridge e Jennings, definido na seção 2.2 a partir de (Wooldridge & Jennings 1995). Ou seja, os agentes participando no mercado e o próprio mecanismo de mercado são modelados como agentes de *software* inteligentes.

A partir do agente inteligente, que notaremos como `IntelligentAgent`, obtemos praticamente quatro tipos principais de agentes: o negociador, o coordenador do mercado, o operador da economia e o regulador do mercado. O primeiro agente representa os participantes do mercado e os três últimos estão relacionados ao funcionamento do próprio mercado. A Figura 5.1 apresenta uma visão geral da arquitetura AEMAS⁴. A seguir detalhamos cada um destes agentes. Devido à sua complexidade, alguns dos agentes poderiam ser modelados como um sistema multiagentes,

³Competição pelo mercado (*competition for the market*) em contraposição à competição no mercado (*competition in the market*), esta última característica dos leilões de curto prazo.

⁴Para melhor clareza omitimos da figura a denominação `Agent` dos diversos agentes modelados.

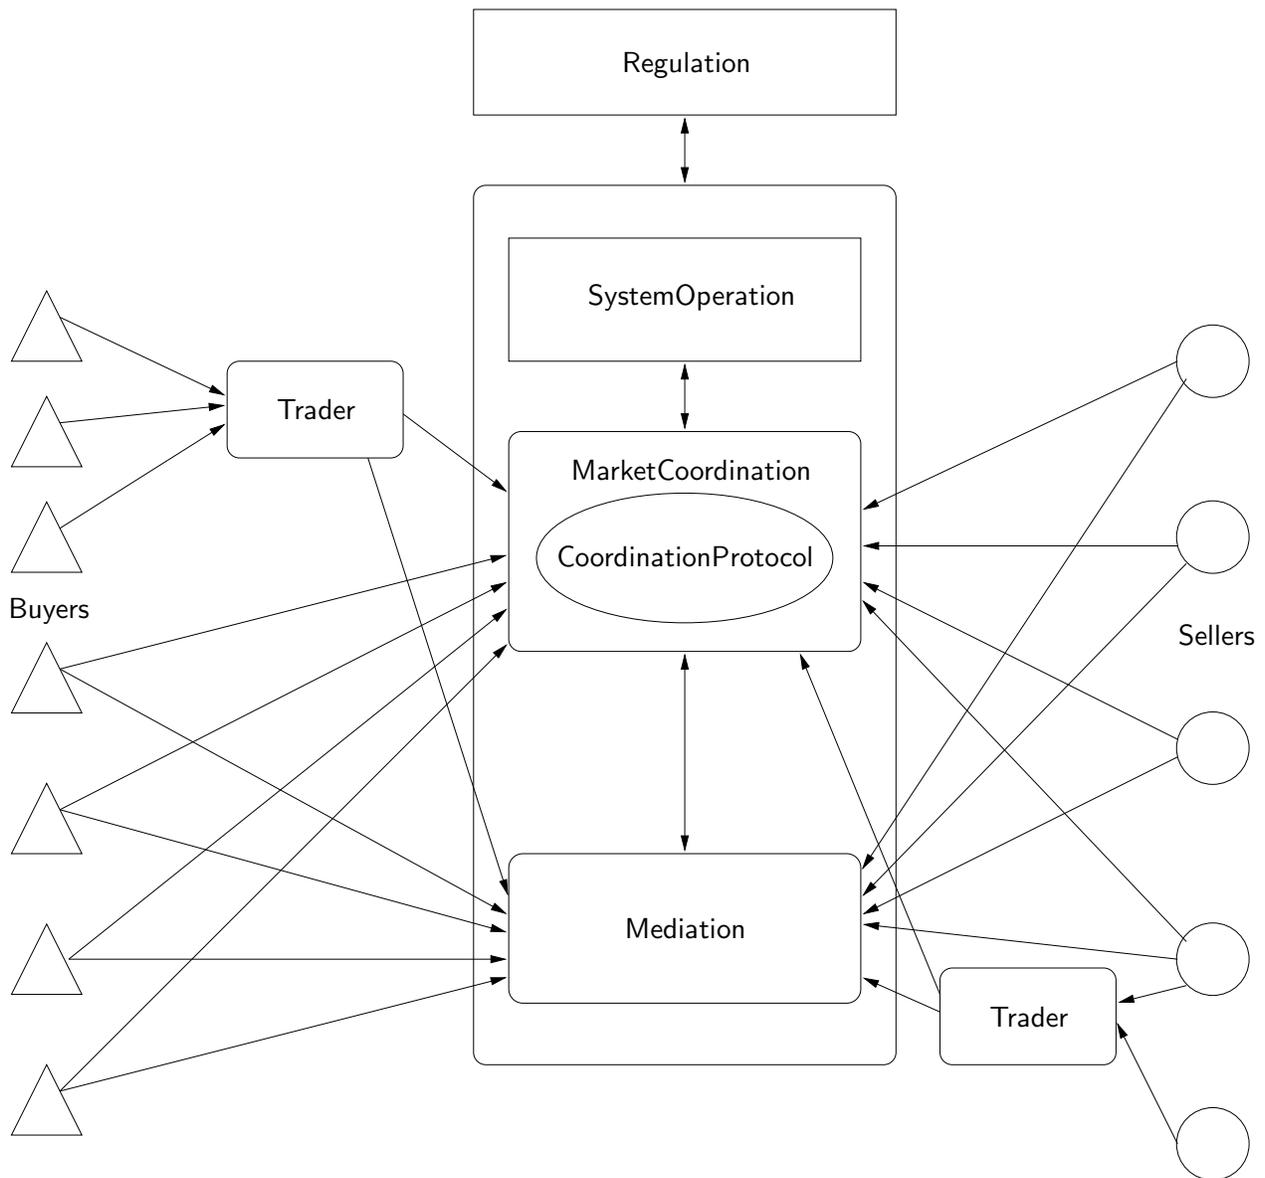


Figura 5.1: Arquitetura AEMAS.

e a economia artificial a ser simulada seria composta deste modo por um conjunto de sistemas multiagentes.

5.2.1.1 Agentes Negociadores

Os agentes negociadores, denominados *NegotiationAgent* são os participantes da economia artificial e vão desde um negociador inflexível, tomador de preços (*price taker*) e que não negocia nenhum tipo de contrato bilateral a um negociador pleno, que é capaz de revender energia através de contratos multilaterais, levando em conta o poder de mercado dos agentes estratégicos (*price maker*) presentes nos oligopólios.

Há três tipos principais de agentes negociadores, o vendedor *SellerAgent*, o comprador *BuyerAgent* e o comercializador *TraderAgent*. O agente vendedor *SellerAgent* corresponde aos produtores da Programação Orientada a Mercado (MOP) que produzem determinada mercadoria de acordo com uma função de tecnologia. O agente comprador *BuyerAgent* corresponde aos consumidores da MOP. O agente comercializador *TraderAgent* por sua vez corresponde também aos consumidores da MOP uma vez que estes podem comprar, vender e consumir mercadorias.

5.2.1.2 Agente Coordenador do Mercado

O agente coordenador do mercado notado como *MarketCoordinationAgent* representa o mecanismo de mercado e é responsável por sua operação, pela coordenação dos agentes participantes do mercado e pela alocação de recursos. Aloca recursos procurando maximizar a eficiência econômica e estabelece preços, os sinais econômicos que valoram as trocas deste mercado. O agente coordenador do mercado é responsável pelo protocolo de coordenação *CoordinationProtocol* e pelo mecanismo de formação de preços *PricingMechanism*.

5.2.1.3 Agente Mediador

Pode ser necessário em algumas estruturas de mercado um intermediário ou mediador que provê entre outros um espaço para o estabelecimento de negociações bilaterais e que possa prover garantias de cumprimento dos contratos estabelecidos, através do serviço de garante ou fiador (*escrow*). Este agente é representado pelo *MediationAgent*.

5.2.1.4 Agente Operador da Economia

O agente operador da economia, notado como *SystemOperationAgent*, é o agente que opera a economia (ou sistema), mantendo regras de operação, restrições de segurança e garantindo que

as regras de coordenação estabelecidas pelo agente regulador sejam obedecidas. Podem ser delegadas a este agente algumas atividades que envolvam o controle de parte da operação dos agentes negociadores.

5.2.1.5 Agente Regulador

O agente regulador, denominado `RegulationAgent`, estabelece as regras de operação, coordenação e negociação da economia modelada. Pode também impor ações de fiscalização, mediar conflitos e sancionar desvios de comportamento dos agentes.

Na seção 4.5 distinguimos seis funções principais e os macro-objetivos da regulação do mercado de energia elétrica, regulação que pode ser vista como um sistema complexo que por sua vez poderia ser modelado como um sistema multiagentes. Genoud (2003) propõe um modelo do processo regulatório que poderia servir como base para a constituição de um agente regulador através de um sistema multiagentes que levasse em conta aspectos inter e intra-organizacionais.

No entanto não é tarefa simples modelar objetivos tão amplos como aqueles discutidos na seção 4.5 em um agente de *software*. Porém alguns objetivos como o de obter preços adequados e o projeto de um mercado onde não haja exercício de poder de mercado exacerbado poderiam fazer parte de um agente regulador que serve à experimentação de diferentes configurações de mercado. Descrevemos na seção 3.9.1, uma abordagem para automatizar ao menos uma parte do projeto de um mecanismo de mercado almejado. Este procedimento adaptativo modifica o protocolo utilizado pelo agente coordenador do mercado `CoordinationMarketAgent`.

Outro objetivo como o livre acesso ao *grid* é premissa básica da maior parte dos modelos de projeto e simulação dos mercados de energia. Já as condições de congestão das linhas de transmissão são simuladas em modelos de mercado que levam em consideração a capacidade de transmissão do sistema.

Um agente regulador delineado em (Griss & Letsinger 2000) é um agente que modela alguns efeitos provocados pelo banco central norte-americano (*Federal Reserve Board*) que poderia modificar a oferta de algum recurso ou impor taxas em certas transações, introduzindo um *risco regulatório* que os agentes negociadores participando no mercado teriam de levar em conta.

5.3 Instâncias da Arquitetura AEMAS

5.3.1 Mercado de Energia Elétrica

Tomando o mercado de energia elétrica como exemplo de aplicação da arquitetura AEMAS sugerida, propomos duas instâncias para modelar as duas principais configurações de organização

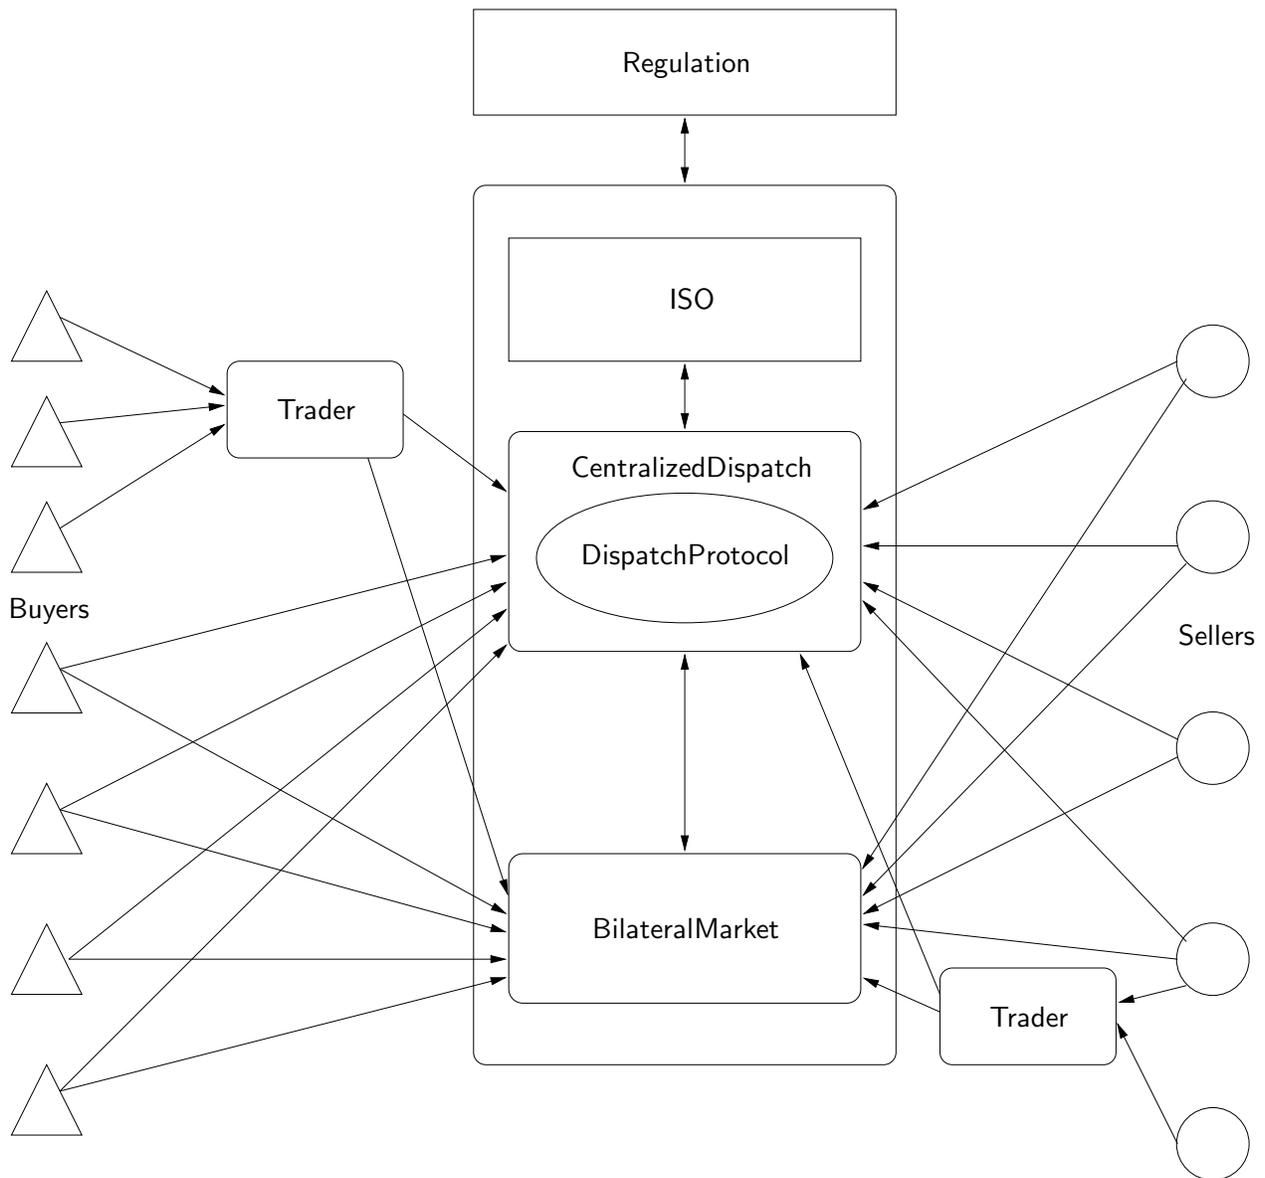


Figura 5.2: Instância AEMAS de um sistema de potência sob despacho centralizado.

da indústria de energia elétrica:

- o despacho centralizado, comum às estruturas pré-reestruturação; e
- o modelo de *pool* baseado em leilões de energia, comum aos mercados reestruturados.

É importante salientar que a arquitetura AEMAS sugerida possibilita a modelagem de estruturas híbridas onde o despacho centralizado convive com uma estrutura de mercado, comuns aos mercados que não finalizaram seu processo de reestruturação.

5.3.2 Modelo AEMAS do Despacho Centralizado

A estrutura de planejamento e despacho centralizado, comum aos mercados de energia que não sofreram a reestruturação das últimas décadas pode ser modelada através da arquitetura AEMAS como detalhado a seguir.

O mecanismo de despacho em si é uma especialização do agente coordenador do mercado `MarketCoordinationAgent`. Podemos nomeá-lo `CentralizedDispatchAgent` e este agente deve ter conhecimento das funções de custo de todos os agentes vendedores (produtores), do tipo `SellerAgent` que representam as usinas do sistema. No caso mais simples, há um único agente comprador (consumidor) que agrega toda a demanda, especialização de `BuyerAgent`, que podemos nomear `AggregatedDemandAgent`.

O mecanismo de formação de preços, ou `PricingMechanism`, é o modelo de um algoritmo de otimização, e.g. minimização do custo de geração da energia, denominado `MinimalCostMechanism`.

O despacho obtido pelo agente coordenador do mercado é verificado pelo agente operador da economia, `SystemOperationAgent`. No caso da produção centralizada de energia, este operador é instanciado no `ISOAgent`⁵ que estabelece a saída de cada produtor `SellerAgent` nominalmente sua produção em cada intervalo de tempo.

Na ausência de contratos bilaterais, os agentes produtores podem perceber sua produção remunerada pelo preço *spot* da energia. Estes agentes produtores seguem um protocolo de coordenação `CoordinationProtocol` que estabelece como o despacho e os preços são informados: `DispatchProtocol`. Uma estratégia conservadora `ConservativeStrategy` para um agente produtor é revelar ao agente `CentralizedDispatchAgent` a sua função de custos real.

A Figura 5.2 ilustra esta instância de AEMAS para um sistema de potência coordenado através de um mecanismo de despacho centralizado.

⁵ISO é o operador independente do sistema (*Independent System Operator*)

5.3.3 Modelo AEMAS do Leilão de Energia

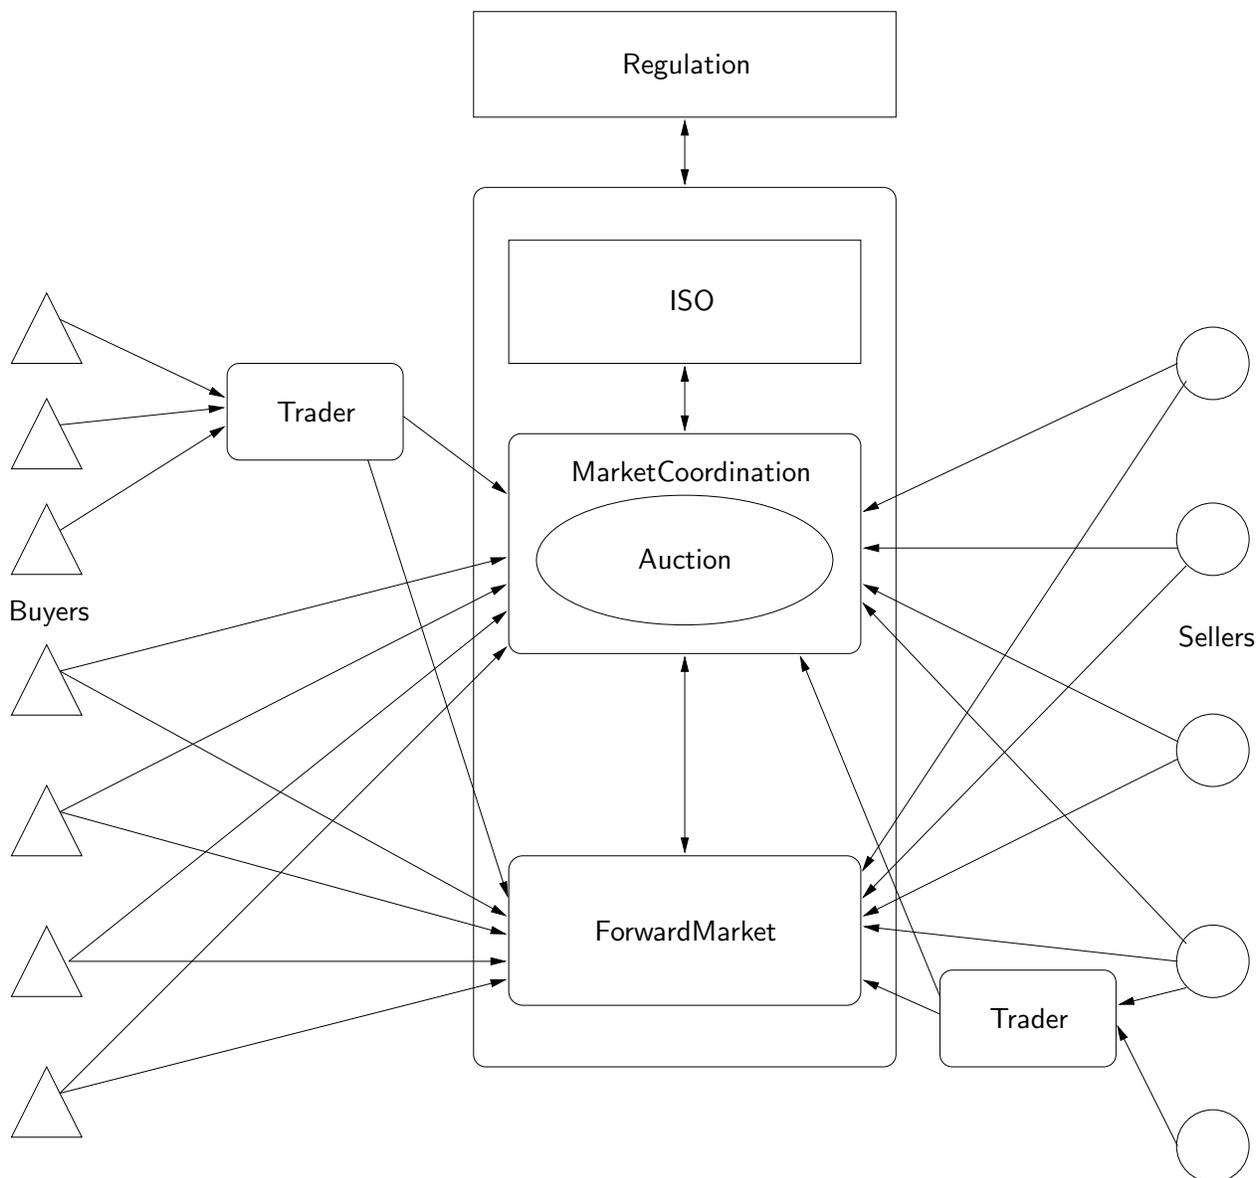


Figura 5.3: Instância AEMAS de um mercado de energia *loose pool*.

A Figura 5.3 ilustra uma instância da arquitetura AEMAS que representa um mercado de energia reestruturado baseado em leilões denominado *loose pool*. A seguir detalhamos uma implementação deste modelo abstrato em uma plataforma multiagentes. Nota-se que o mecanismo de coordenação é baseado em leilões e o mediador pode ser por exemplo um ambiente de contratos a termo `ForwardMarketAgent`.

5.3.3.1 Implementação do Modelo AEMAS do Leilão de Energia

Um possível diagrama de classes para modelar os agentes econômicos participantes no mercado de energia elétrica como um sistema multiagentes baseado em FIPA-OS⁶ encontra-se na Figura A.1.

A classe `SubscribingAgent` é uma abstração dos agentes que podem se inscrever no leilão ou em uma negociação bilateral utilizando o protocolo FIPA `subscribe`. Sub-classes de `SubscribingAgent` são `GenCo`, `DistCo`, `TradCo` e `ConCo` modelando respectivamente os geradores, distribuidores, comercializadores e consumidores livres. Estas sub-classes implementam as interfaces de compra e venda de energia, segundo suas habilidades. Assim `GenCo` implementa `SellingAbility`, `DistCo` e `ConCo` implementam `BuyingAbility` e `TradCo` implementa ambas as interfaces, `BuyingAbility` e `SellingAbility` pois pode comprar e vender energia. Desta maneira as classes que implementam a interface `SellingAbility` são os agentes vendedores `SellerAgent` da arquitetura AEMAS. As classes que implementam a interface `BuyingAbility` são os agentes compradores `BuyerAgent` da arquitetura AEMAS. E as classes que implementam ambas as interfaces, `SellingAbility` e `BuyingAbility` são os agentes comercializadores `TraderAgent` da arquitetura AEMAS.

A classe `MarketManager` aceita inscrições através do protocolo FIPA `subscribe`. A classe operador do leilão ou leiloeiro `Auctioneer`, sub-classe de `MarketManager` implementa o agente coordenador do mercado `CoordinationMarketAgent`. Já a classe `MarketPlaceManager` implementa o facilitador de uma ou mais negociações bilaterais simultâneas e corresponde ao agente mediador `MediationAgent`. Seu papel é o de intermediador dessas negociações, para que as sub-classes de `SubscribingAgent` possam participar de uma ou mais negociações sem necessitar gerenciá-las diretamente. A classe `MarketPlaceManager` também é responsável por informar ao `Auctioneer` as quantidades estabelecidas na contratação bilateral e pelo serviço de `Escrow`, que garante a integridade dos contratos bilaterais. Em outras palavras, o serviço de `Escrow` é aquele provido por uma terceira parte⁷ na negociação bilateral que garante que aquilo que foi negociado seja estabelecido.

Neste modelo onde o interesse principal são os aspectos da comercialização de energia, os fluxos de energia elétrica e portanto os agentes de transmissão e operação do sistema não são representados. As regras do mercado são supostas estáveis e a o agente regulador também não é modelado.

No Apêndice B apresentamos a implementação da arquitetura sugerida AEMAS para o leilão de energia na plataforma FIPA-OS.

⁶FIPA-OS é uma implementação em código aberto das recomendações FIPA, ou seja, uma plataforma multiagentes. Mais detalhes a respeito do padrão FIPA são descritos na seção 2.3.4.

⁷Fiador ou garante.

Protocolo de Iterações O diagrama da Figura A.2 ilustra de maneira simplificada uma possível iteração entre o leiloeiro e cada um dos participantes no leilão. No protocolo ilustrado, o leiloeiro inicia uma conversa informando a todos os participantes do início do leilão. Em seguida, através de uma requisição de ofertas (ou CFP, de *call for proposals*) requisita ofertas para uma determinada previsão de demanda. Cada um dos participantes no leilão pode responder com um lance que pode ser ou não aceito. Ao fim do período de lances o leiloeiro informa que o recebimento de lances terminou, publica para todos os participantes o preço horário e informa a cada um deles o seu despacho. E finalmente informa a todos o término do leilão.

5.4 Pesquisa Relacionada

Vários podem ser os argumentos na adoção de um sistema multiagentes para modelar o mercado de energia elétrica. A Economia Computacional baseada em Agentes (ACE, *Agent-based Computational Economics*) está interessada em um comportamento econômico que possa emergir da agregação de vários agentes, geralmente com racionalidade limitada e interesse próprio (Tsfatsion 2001a, Tsfatsion 2001b). Com a utilização da ACE no mercado de energia, procura-se uma modelagem mais refinada que aquela fornecida pela modelagem econômica neoclássica (Bunn & Oliveira 2001, Bower & Bunn 2001). Em (Harp, Brignone, Wollenberg & Samad 2000), a utilização de um sistema adaptativo complexo (CAS, *Complex Adaptive System*) como protótipo multiagentes do mercado de energia permitiu uma representação *bottom-up* do sistema de energia que não depende de cenários hipotéticos ou pré-concebidos.

Monclar & Quatrain (2001) relatam resultados obtidos com MADERE, um sistema multiagentes do mercado inglês utilizado para entender as tendências do mercado sob diferentes condições. A maior vantagem apontada é a flexibilidade com que novos cenários e diferentes simulações podem ser produzidas em um modelo razoavelmente realista do mercado.

Al-Agtash (2004) propõe uma abordagem multiagentes utilizando uma implementação de KQML (*Knowledge Query Manipulation Language*) em C++ para modelar a negociação entre produtores e consumidores em um mercado de energia. Parâmetros das estratégias de negociação como tempo máximo de negociação e intervalo de valores aceitáveis são obtidos através de um algoritmo genético cujo objetivo é o de maximizar a utilidade dos agentes.

A partir da literatura fica evidente a adequação da modelagem de mercados de energia elétrica através de sistemas multiagentes, utilizados na sua implementação ou o que é mais comum, na sua simulação. Por exemplo, Praça, Ramos, Vale & Cordeiro (2003a) apresentam MASCEM, um sistema multiagentes para simular mercados competitivos de eletricidade cujo mecanismo de interação é um leilão. O simulador proposto, cujos agentes estão representados na Figura 5.4, permite a modelagem de mercados onde além do leilão há também a contratação bilateral. As

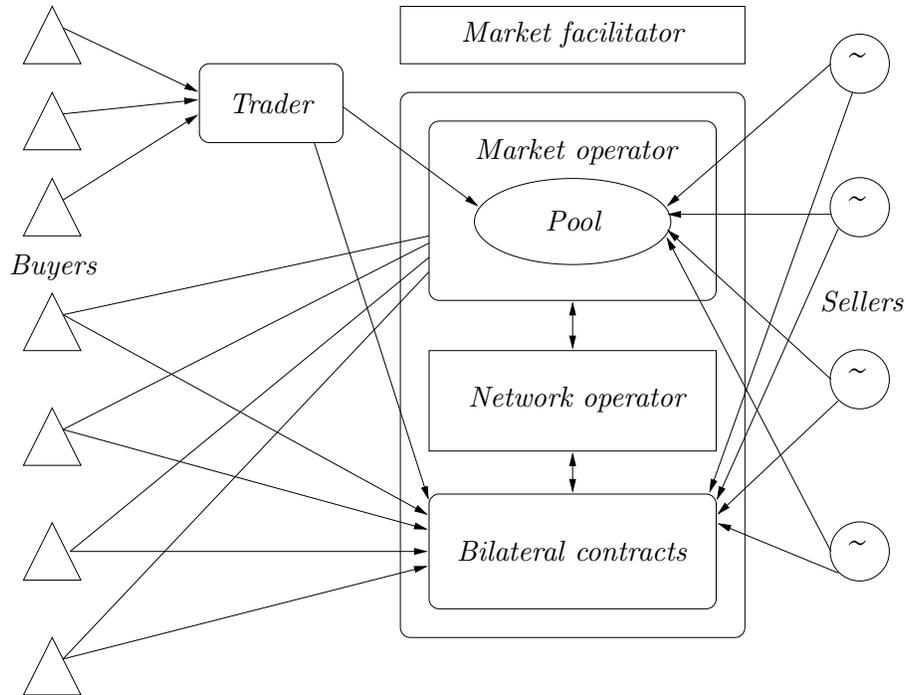


Figura 5.4: Arquitetura de MASCEM (Praça, Ramos, Vale & Cordeiro 2003a).

estratégias de oferta adaptativas e os cenários de análise definidos pelos usuários em MASCEM provêem uma rica ferramenta de simulação.

A factibilidade e pertinência da abordagem é reforçada por (Ferreira 2002, Carvalho 2003) cujos resultados constam resumidamente de (Ferreira & Vinhal 2002, Ferreira, Vinhal & Lima 2002b, Ferreira, Vinhal & Lima 2002a, Ferreira, Vinhal, Carvalho & Lima 2003) e (Vinhal, Carvalho & Lima 2004, Carvalho & Vinhal 2004). Mais recentemente temos (Freitas 2006, Lima & Freitas 2006).

O argumento mais forte para justificar a utilização de um sistema multiagentes no mercado de energia elétrica é que o mercado é um sistema intrinsecamente composto de vários agentes econômicos interagindo. Nada mais natural que modelá-lo como um sistema multiagentes. Isto permite que cada agente econômico possa construir seu modelo de mercado no seu próprio agente de software que interage com os outros agentes através de uma interface bem definida: os mecanismos de negociação.

Capítulo 6

Estratégias Inteligentes de Mercado

6.1 Introdução

Com o desenvolvimento de mercados *online*, práticas como a formação dinâmica de preços, os leilões e as bolsas *online* se tornaram relevantes em uma ampla variedade de mercados. A habilidade dos participantes nestes mercados em rapidamente adquirir e processar informação a respeito do mercado é crucial para assegurar eficiência. A habilidade de um comprador em encontrar o melhor negócio depende de quantas ofertas de diferentes fornecedores são comparadas. E a habilidade de um vendedor em maximizar sua receita depende de quantos prováveis compradores consideram suas ofertas de venda. Desta forma, a automação da requisição e comparação de ofertas em um ambiente dinâmico é do interesse de ambas as partes (Dumas, Aldred, Governatori & Ter Hofstede 2005).

O escopo deste capítulo é estudar o aprendizado automático de estratégias de oferta de um agente participando em um leilão através da utilização da informação comumente disponível nos leilões eletrônicos, tomando os leilões de energia como principal ambiente de aplicação, devido à sua relevância como instância adequada de experimentação da abordagem sugerida. Encontramo-nos então no domínio do projeto das estratégias de oferta, quer com o intuito de melhorar um dado mecanismo ou de explorar o espaço ao *gaming* e ao exercício do poder de mercado.

6.2 Estratégias de Oferta Evolutivas

A abordagem sugerida neste trabalho evolui estratégias nebulosas de oferta. A despeito de outras abordagens evolutivas correlatas, o objetivo é a modelagem de estratégias de oferta utilizando a teoria de conjuntos nebulosos.

Ao proporcionar a um sistema nebuloso um mecanismo de aprendizagem evolutiva espera-se

encontrar estratégias de oferta efetivas e transparentes. Assume-se que as estratégias de oferta são modeladas por sistemas baseados em regras nebulosas (FRBS, *fuzzy rule-based systems*). Considera-se para a aplicação em questão que os algoritmos evolutivos são especialmente mais atraentes que métodos de tentativa e erro para derivar os modelos de oferta pois podem otimizar a base de conhecimento para uma dada configuração de mercado.

Adota-se um esquema de sistema genético baseado em regras nebulosas (GFRBS, *genetic fuzzy rule-based system*) no qual são evoluídas simultaneamente a base de dados e a base de regras de um FRBS com o objetivo de encontrar a estratégia de oferta mais rentável. O resultado é um sistema nebuloso cuja base de conhecimento representa uma estratégia de oferta capaz de lidar com incertezas nos dados.

É utilizada uma abordagem evolutiva baseada em (Cordón, Herrera, Magdalena & Villar 2001) para evoluir a base de dados do FRBS. Para a evolução da base de regras é adotada uma representação de cromossomo de comprimento variável. Um operador de *crossover ad-hoc* é delineado para melhorar a performance do processo evolutivo. O treinamento do GFRBS compreende uma instância de mercado assumindo que os agentes remanescentes são agentes conservadores, isto é, oferecem energia a um preço equivalente a seus custos marginais. A performance do melhor FRBS obtido é verificada em leilões cujos competidores são os mesmos agentes conservadores mas com diferentes dados de demanda. Os resultados mostram que o lucro do agente GFRBS aumenta e a quantidade de energia produzida diminui, incrementando deste modo sua lucratividade.

6.2.1 Estratégias de Oferta em Mercados de Energia

Como discutido no Capítulo 4, observamos que grande parte da indústria de energia elétrica, após sua reestruturação em diferentes países, utiliza diferentes tipos de leilão como mecanismo de alocação de recursos e coordenação do sistema. O projeto do leilão leva a um mecanismo em que os agentes podem ter uma capacidade maior ou menor de explorar as imperfeições do mecanismo para “jogar” (*gaming*) com o mercado (Silva, Wollenberg & Zheng 2001).

Um gerador de energia competindo em um mercado de energia elétrica tem que decidir quanto de energia oferecer e a que preço. Em um mercado competitivo perfeito, um participante avesso ao risco tem incentivos para oferecer energia a um preço equivalente a seus custos marginais (Green 2000). Entretanto, mercados de eletricidade são muito mais um oligopólio que um *laissez-faire*, com barreiras de entrada, custos de saída e restrições físicas. A curto prazo podemos assumir nenhuma ou baixa elasticidade da demanda. Deste modo o gerador de energia pode encontrar incentivos para oferecer energia a um preço diverso de seus custos marginais e extrair excedente econômico de um mercado imperfeito.

O leilão a preço uniforme¹ é considerado um mecanismo de incentivo para que os agentes façam suas ofertas ao custo marginal (Green 2000).

Ofertar sua capacidade ao custo marginal pode ser então considerada uma estratégia de oferta conservadora que no leilão uniforme garante que:

- um agente não será despachado quando o preço não for suficiente para cobrir seus custos variáveis evitando prejuízo;
- o gerador marginal terá seus custos variáveis ressarcidos e
- os geradores despachados ao preço *spot* com custo abaixo deste preço estarão obtendo receita para recuperar seu investimento e custos fixos.

Definição 11 *Oferta estratégica de energia (strategic bidding) é o comportamento de um gerador que realiza ofertas de energia a preços diversos do custo marginal, procurando explorar as imperfeições do mercado. (David & Wen 2000)*

O comportamento de um gerador que oferece energia a um preço diverso do custo marginal em um esforço de explorar as imperfeições do mercado é definido na literatura como oferta estratégica. A estratégia mais comum é maximizar o lucro esperado, mas outras estratégias podem interessar um gerador como, por exemplo, competir pela carga de base² (Visudhipan & Ilic 1999), aumentar poder de mercado, aumentar parcela de mercado³, aumentar margem de lucro (Monclar & Quatrain 2001), maximizar o lucro horário, garantir uma saída estável mínima (Wen & David 2001). Uma revisão sobre oferta estratégica de energia encontra-se em (David & Wen 2000).

Al-Agtash & Yamin (2004) propõem uma abordagem baseada na decomposição de Benders para resolver o problema da curva ótima de estratégia de oferta (OSCB, *optimal supply curve bidding*) e então resolver sub-problemas onde são levadas em conta as restrições de transmissão e de factibilidade do despacho de cada unidade (rampas de subida e descida). É apresentado um experimento baseado em um sistema IEEE 24-bus com 9 geradores que demonstram a efetividade da abordagem e resultam em aumento do lucro dos geradores e no preço da energia.

6.2.2 Pesquisa Relacionada

Richter & Sheblé (1997) conceberam uma estratégia de oferta nebulosa para tratar incertezas nos custos dos combustíveis, aversão ao risco e previsão de preço da energia. Entretanto, até

¹No leilão a preço discriminatório cada agente auferir receita correspondente à quantidade aceita pelo preço de seu lance.

²Base-load.

³Market share.

onde conseguimos avaliar, não foram apresentados resultados de experimentação relativos à este modelo concebido por Richter & Sheblé (1997). Um modelo de regressão para lidar com a flutuação excessiva dos preços do mercado da Califórnia e predizer uma distribuição de possibilidades dos preços é discutido em (Niimura & Nakashima 2001). Um método para encontrar um modelo nebuloso da estratégia de oferta de um gerador baseado em dados históricos do mercado é proposto em (Widjaja, Sugianto & Morrison 2001). Abordagens evolutivas para a oferta estratégica de energia também foram propostas e incluem: algoritmos genéticos (Richter & Sheblé 1998, Al-Agtash 2004), programação genética (Richter, Sheblé & Ashlock 1999), estratégias evolutivas (Xiong, Hashiyama & Okuma 2002b) e sistemas classificadores (Bagnall & Smith 1999b, Bagnall & Smith 1999a, Bagnall 2000b, Bagnall & Smith 2000, Bagnall 2000a, Bagnall & Smith 2005).

Tanto na abordagem baseada em algoritmos genéticos (Richter & Sheblé 1998) quanto na aquela baseada em programação genética (Richter, Sheblé & Ashlock 1999), o resultado do processo evolutivo é um lance baseado em um modelo de leilão duplo similar ao utilizado no mercado da Califórnia, onde há múltiplas rodadas de negociação. Portanto neste ambiente de aplicação os agentes têm a oportunidade de ajustar seus lances em resposta aos resultados obtidos nas rodadas anteriores. A abordagem baseada em uma estratégia evolutiva (Xiong, Hashiyama & Okuma 2002b) resulta na evolução do valor de um lance que é válido para as 24 horas do mercado do dia seguinte. Neste sentido, as abordagens propostas em (Richter & Sheblé 1998, Richter, Sheblé & Ashlock 1999, Xiong, Hashiyama & Okuma 2002b) não resultam em uma estratégia de como efetuar as ofertas mas em um valor do lance que é otimizado para a configuração simulada.

A abordagem proposta por Bagnall & Smith (2005) é um sistema classificador⁴ cuja estrutura hierárquica é baseada no sistema classificador XCS de Wilson (1995), e é capaz de lidar com as restrições de transmissão do mercado britânico. A estrutura hierárquica de Bagnall & Smith (2005) contempla dois sistemas classificadores para modelar ofertas de preço de um agente gerador de energia. 10 bits são utilizados para codificar informações sobre as restrições elétricas do sistema, 4 níveis distintos de previsões de demanda e prêmio por capacidade. O ambiente é descrito então por $2^{10} = 1024$ possíveis estados. O classificador tem 32 possíveis ações correspondendo a uma oferta (*bid*) entre £0 e £31 por MWh. O modelo de aprendizagem utiliza também listas de 20 casos bons e ruins como memória de persistência longa externa aos classificadores, acelerando a convergência e melhorando a qualidade dos resultados. O sistema classificador proposto leva em conta os geradores que são obrigados pelo operador a entrar ou sair do despacho devido às restrições elétricas.

Diferentemente das abordagens citadas, a abordagem sugerida neste trabalho é capaz de lidar com incertezas nas entradas. E incertezas são comuns aos ambientes similares ao mercado de energia. Além disto, o resultado é uma estratégia de oferta e não somente um valor de lance.

⁴Vargas (2005) apresenta uma visão recente e abrangente de novos desenvolvimentos em sistemas classificadores.

Como detalhado na seção 5.4, há abordagens baseadas em sistemas multiagentes propostas para a modelagem do mercado de energia elétrica, como por exemplo (Monclar & Quatrain 2001, Harp, Brignone, Wollenberg & Samad 2000, Praça, Ramos, Vale & Cordeiro 2003b). Nenhuma destas lida com a descoberta automática de estratégias de oferta, apesar de apresentarem ambientes dinâmicos povoados por agentes adaptativos.

6.2.2.1 Q-learning nos Leilões de Energia Elétrica

Há evidências na literatura da factibilidade e conveniência da abordagem *Q-learning* no aprendizado de estratégias de oferta em leilões, em especial em leilões de energia elétrica. Xiong, Hashiyama & Okuma (2002a) e Xiong, Okuma & Fujita (2004) utilizam *Q-learning* para a aprendizagem de estratégias de oferta em um leilão de energia que se repete diariamente. Naghibi-Sistani, Akbarazdeh-Tootoonchi, Bayaz & Rajabi-Mashhadi (2006) mostram que as estratégias de oferta obtidas através da abordagem *Q-learning* tendem ao equilíbrio de Nash em um modelo de *pool* no qual os participantes submetem curvas de oferta lineares. Em (Ma, Bompard, Napoli & Jiang 2006) ilustra-se a efetividade da abordagem *Q-learning* através da sua aplicação ao sistema de potência IEEE 14-barras.

6.3 Estratégia Baseada em Sistema *Fuzzy* Genético

O sistema *fuzzy* genético (GFS) desenvolvido neste trabalho utiliza uma representação do cromossomo de tamanho variável para ambas as partes da base de conhecimento, a base de dados e a base de regras. A representação adota codificação similar às sugeridas em (Cordón, Herrera, Magdalena & Villar 2001, Cordón, Herrera & Villar 2001, Delgado, Zuben & Gomide 2001). As operações de *crossover* na base de dados e na base de regras são síncronas, isto é, os pontos de *crossover* na base de dados e na base de regras induzem troca de porções do cromossomo que mantém a estrutura das regras e termos na próxima geração. Diferentemente de esquemas evolutivos encontrados na literatura, neste trabalho diversas bases de regra podem ser associadas a um único indivíduo da população de bases de dados. Este esquema induz um algoritmo que simultaneamente explora e explota o espaço de busca ao longo das gerações. O *fitness* dos indivíduos é uma função da performance das bases de regras decodificadas em relação à base de dados. Podemos atribuir por exemplo o valor máximo entre as medidas de performance de cada base de regras como o valor do *fitness* do indivíduo correspondente. Utilizamos deste modo uma forma de relação hierárquica induzida pelo *fitness*.

Um primeiro passo para projetar um GFRBS é decidir quais partes da base de conhecimento serão otimizadas pelo algoritmo genético (Cordon, Gomide, Herrera, Hoffman & Magdalena 2004, Cordón, Herrera, Hoffman & Magdalena 2001). Esta decisão usualmente significa um compromisso

entre granularidade e eficiência no processo de busca. Na abordagem sugerida neste trabalho, utilizamos o aprendizado simultâneo dos componentes da base de conhecimento.

Desta forma um algoritmo evolutivo é empregado na evolução dos seguintes componentes da base de conhecimento do sistema baseado em regras nebulosas:

- base de dados
 - granularidade (isto é, o número de termos linguísticos)
 - parâmetros das funções de pertinência
- base de regras
 - número de regras ativas (status das regras)
 - sintaxe das regras

Status de uma regra significa que uma regra está ativa ou inativa. Uma regra ativa pertence à base de regras e é utilizada durante o processo de inferência nebulosa. Uma regra inativa permanece no genótipo da base de regras mas não é utilizada na inferência. Evoluir o status das regras (ativo ou inativo) é um meio indireto de evoluir o número de regras na base de regras.

A abordagem utilizada neste trabalho evolui simultaneamente a base de dados e a base de regras e um indivíduo representa um sistema nebuloso baseado em regras completo como na abordagem Pittsburgh⁵. Em outras palavras, o FRBS é codificado em um cromossomo Cr composto pelas respectivas representações da base de dados e da base de regras.

6.3.1 Representação do Cromossomo

O GFRBS sugerido utiliza um esquema de codificação hierárquico que pode ser observado na Figura 6.1. Para cada base de dados há R bases de regras correspondentes. Resultados de trabalhos anteriores (Walter & Gomide 2003b) mostraram que o uso desta abordagem hierárquica possibilita que o *fitness* progrida mais rapidamente quando comparada à abordagem não-hierárquica, ainda que a diferença seja relativamente tênue. Uma abordagem não-hierárquica como a apresentada em trabalhos anteriores (Walter & Gomide 2003a, Walter & Gomide 2004, Walter & Gomide 2006) corresponde a fazermos $R = 1$.

6.3.1.1 Base de Dados

Há dois componente na base de dados para definir a sua granularidade e as respectivas funções de pertinência. A granularidade da base de dados é definida no primeiro componente,

⁵Na abordagem Michigan utilizada nos sistemas classificadores o conjunto da população de indivíduos representa um único sistema nebuloso.

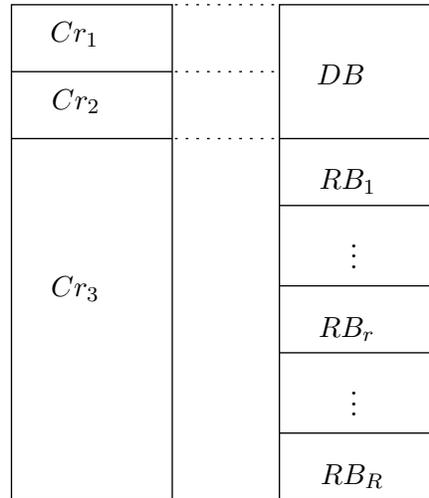


Figura 6.1: Esquema de representação do cromossomo dos indivíduos do GFRBS.

Cr_1 , codificada em uma cadeia de tamanho variável de números inteiros $(N, M, \mathbf{n}, \mathbf{m})$, com $\mathbf{n} = (n_1, \dots, n_i, \dots, n_N)$ e $\mathbf{m} = (m_1, \dots, m_j, \dots, m_M)$, onde N é o número de antecedentes, M é o número de conseqüentes, n_i o número de termos lingüísticos da variável de entrada i e m_j o número de termos lingüísticos da variável de saída j , com $i = 1, \dots, N; j = 1, \dots, M$.

Este esquema de representação utiliza um total de L conjuntos nebulosos que é a soma de L_a e L_c conjuntos nebulosos de antecedentes e conseqüentes, respectivamente, conforme definido pela expressão (6.1).

$$L = L_a + L_c, L_a = \sum_{i=1}^N n_i, L_c = \sum_{j=1}^M m_j \quad (6.1)$$

Em (Walter & Gomide 2003a) e (Walter & Gomide 2004) assume-se que a única entrada é a demanda e a única variável de decisão é o preço da oferta, $p_{j,h}$. Então temos $N = 1, M = 1$. Evoluir o número de variáveis de entrada e saída pode ser importante ao lidar com um modelo multi-dimensional mas o foco em (Walter & Gomide 2003a) e (Walter & Gomide 2004) é o caso de uma única entrada e uma única saída. Então o primeiro componente do cromossomo torna-se $Cr_1 = (1, 1, n_1, m_1)$ e não há necessidade de evoluir o número de variáveis de entrada e saída. Entretanto o número de termos lingüísticos que particiona cada variável sofre evolução.

6.3.1.2 Funções de Pertinência

Baseado na abordagem sugerida em (Cordón, Herrera, Magdalena & Villar 2001) são utilizadas partições nebulosas *fortes* (*strong fuzzy partition*) (Glorennec 1996). Esta abordagem permite um ajuste global das funções de pertinência: variar somente um parâmetro resulta em uma nova

partição nebulosa do espaço de entrada ou saída, com o número de conjuntos nebulosos mantido o mesmo. Além disso, os FRBS's obtidos são mais transparentes, pois usualmente resultam em melhores *frames* de cognição⁶. São assumidas funções de pertinência trapezoidais e como são adotadas as partições *fortes*, cada variável linguística i necessita $2 \times (n_i - 1)$ números reais para definir a partição do correspondente universo de discurso. Estes números reais são codificados em um componente Cr_2 do cromossomo cujo comprimento é dado pela expressão (6.2). Como não é realizada nenhuma normalização, cada valor deve estar no intervalo $[v_{min}^X, v_{max}^X]$, limites do universo de discurso.

$$L_{mf} = \sum_{i=1}^N 2 \times (n_i - 1) + \sum_{j=1}^M 2 \times (m_j - 1) \quad (6.2)$$

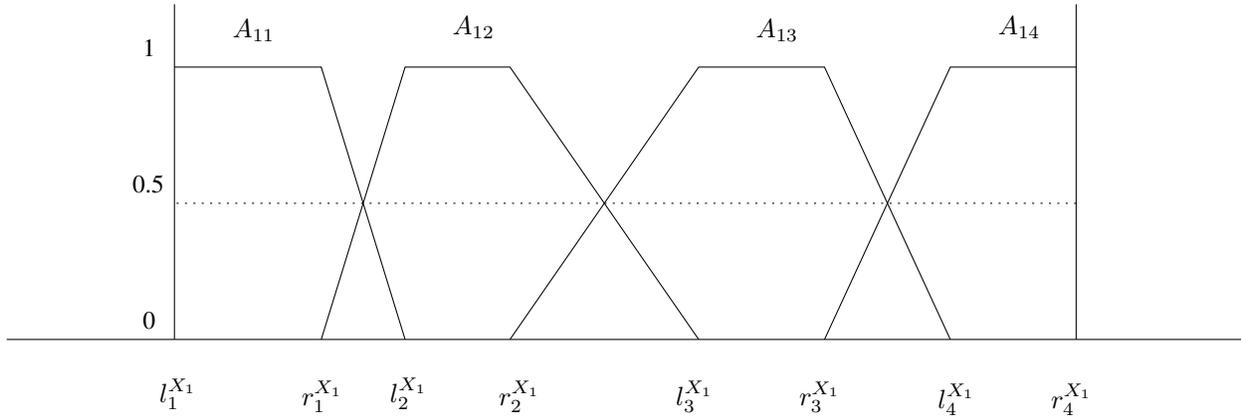


Figura 6.2: Partição nebulosa *forte* com funções de pertinência trapezoidais.

Por exemplo, se tivermos $N = 1$ e $M = 2$, e temos Cr_1 codificado como $(1, 2, (n_1), (m_1, m_2))$. Então as funções de pertinência da variável entrada X_1 e das variáveis de saída Y_1 e Y_2 são codificadas em Cr_2 em dois vetores de $2 \times (n_1 - 1)$ e $2 \times (m_1 - 1) + 2 \times (m_2 - 1)$ números reais como na expressão (6.3). O parâmetro esquerdo do topo do k -ésimo trapézio que define o k -ésimo conjunto nebuloso da variável linguística X_1 é denotado por $l_k^{X_1}$, enquanto $r_k^{X_1}$ é o parâmetro no do topo direito do trapézio.

$$\begin{aligned} & ((r_1^{X_1}, l_2^{X_1}, r_2^{X_1}, \dots, l_k^{X_1}, r_k^{X_1}, \dots, l_{n_1}^{X_1}), \\ & (r_1^{Y_1}, l_2^{Y_1}, r_2^{Y_1}, \dots, l_k^{Y_1}, r_k^{Y_1}, \dots, l_{m_1}^{Y_1}), \\ & (r_1^{Y_2}, l_2^{Y_2}, r_2^{Y_2}, \dots, l_k^{Y_2}, r_k^{Y_2}, \dots, l_{m_2}^{Y_2})) \end{aligned} \quad (6.3)$$

⁶A idéia de *frames* de cognição é discutida em (Pedrycz & Gomide 1998).

A Figura 6.2 mostra um exemplo de partição forte onde $n_1 = 4$. Note que neste caso $l_1^{X_1} = v_{min}^{X_1}, r_4^{X_1} = v_{max}^{X_1}$.

6.3.1.3 Base de Regras

Assumimos um sistema nebuloso descrito por um conjunto de regras combinadas pelo operador de união:

$$R = \bigcup (R_1, R_2, \dots, R_k)$$

Cada regra é do tipo

$$\text{Se } X_i \text{ é } (A_{io} \text{ ou } A_{ip} \text{ ou } \dots) \text{ e } \dots \text{ então } Y_j \text{ é } (C_{jq} \text{ ou } C_{jr} \text{ ou } \dots) \dots$$

onde A_{io}, A_{ip} são conjuntos nebulosos associados à variável de entrada X_i , e C_{jq}, C_{jr} , associados à variável de saída Y_j , com $o, p \leq n_i$; $q, r \leq m_j$. Deste modo, cada regra é uma cadeia de bits de tamanho variável L dado pela expressão (6.1). Se o antecedente de uma regra contém uma entrada como X_i is A_{ij} , então o bit correspondente na posição $p_{bit} = j + \sum_{k=1}^{i-1} n_k$ é 1, caso contrário é 0.

Por exemplo, se $N = 3, M = 1, n = \{5, 3, 5\}, m = \{7\}$ e então ($L_a = 13, L_c = 7$). A cadeia que representa uma regra tem comprimento $20 + 1$ e uma regra como na expressão (6.4) abaixo é codificada pela sequência

$$(1) 00110 \ 000 \ 10000 \Rightarrow 0001100$$

onde o primeiro bit indica se a regra está ativa (1) ou inativa (0). Uma regra ativa significa uma regra que contribui ativamente para a saída através da inferência do sistema nebuloso, enquanto uma regra inativa permanece no genótipo da base de regras mas não é utilizada no processo de inferência do sistema nebuloso e não contribui para a saída do FRBS.

$$\text{Se } X_1 \text{ é } (A_{13} \text{ ou } A_{14}) \text{ e } X_3 \text{ é } (A_{31})$$

$$\text{então } Y_1 \text{ é } (C_{14} \text{ ou } C_{15}) \tag{6.4}$$

Cada base de regras contém L_r regras de acordo com a expressão (6.5), onde L_a e L_c são definidos pela expressão (6.1). Tomando por exemplo $N = 1$ e $M = 1$, Cr_3 tem no mínimo $\min(n_1, m_1)$ e no máximo $n_1 \times m_1$ regras de tamanho $1 + n_1 + m_1$.

$$\min(L_a, L_c) \leq L_r \leq L_a \times L_c \tag{6.5}$$

O número de regras, o tamanho de cada regra e as próprias regras definem o componente Cr_3 do cromossomo, composto por dois inteiros e L_r cadeias de bits de tamanho $L + 1$, pois o primeiro bit de cada cadeia é utilizado para indicar uma regra (in)ativa.

6.3.2 Operadores Genéticos

Devido à estrutura de codificação do cromossomo utilizada para representar a base de conhecimento, a natureza dos operadores genéticos é uma questão chave para evoluir o GRFBS de maneira eficiente. Como há relações entre os componentes do cromossomo, são necessários operadores que trabalhem de maneira cooperativa e considerem o relacionamento hierárquico codificado na representação do cromossomo.

6.3.3 Seleção

A seleção utilizada é a roleta com um modelo elitista: o melhor indivíduo é mantido na população de geração a geração.

O *fitness* de um indivíduo é escolhido como o melhor (maior) valor entre as medidas de desempenho de todas as bases de regras codificadas em um indivíduo. Ou seja, o *fitness* de um indivíduo é o valor da medida de desempenho que um indivíduo atinge quando sua base de dados é decodificada com sua melhor base de regras.

No leilão de energia a função de *fitness* escolhida é o lucro obtido nos leilões realizados no período de treinamento. Maiores detalhes a respeito da função de *fitness* na seção 6.3.8.

6.3.4 Crossover da Base de Dados

Dois operadores de *crossover* são desenvolvidos e utilizados dependendo da granularidade dos indivíduos selecionados.

Dois indivíduos dados por

$$(N, M, (n_1, \dots, n_i, \dots, n_N), (m_1, \dots, m_j, \dots, m_M))$$

$$(N, M, (\eta_1, \dots, \eta_i, \dots, \eta_N), (\mu_1, \dots, \mu_j, \dots, \mu_M))$$

têm a mesma granularidade se e somente se $n_i = \eta_i$, $i = 1, \dots, N$ e $m_j = \mu_j$, $j = 1, \dots, M$.

6.3.4.1 Recombinação de Indivíduos com Granularidade Diversa

Quando o par selecionado tem granularidade diferente, uma posição aleatória de *crossover* p é escolhida, $1 \leq p \leq (N + M - 1)$. A granularidade (componente Cr_1) e os correspondentes parâmetros das funções de pertinência (componente Cr_2) são recombinados.

Tomemos dois indivíduos cujos componentes Cr_1 sejam dados por:

$$((n_1, \dots, n_i, \dots, n_N), (m_1, \dots, m_j, \dots, m_M))$$

$$((\eta_1, \dots, \eta_i, \dots, \eta_N), (\mu_1, \dots, \mu_j, \dots, \mu_M))$$

Quando estes indivíduos sofrem *crossover* na posição p , $p \leq N$, o resultado é a prole dada por:

$$((n_1, \dots, n_{p-1}, \eta_p, \dots, \eta_N), (\mu_1, \dots, \mu_j, \dots, \mu_M))$$

$$((\eta_1, \dots, \eta_{p-1}, n_p, \dots, n_N), (m_1, \dots, m_j, \dots, m_M))$$

O resultado é similar para $N < p \leq N + M - 1$. Os parâmetros das funções de pertinência correspondentes são recombinados da mesma maneira para gerar novas partições do universo de discurso.

6.3.4.2 Recombinação de Indivíduos com Granularidade Igual

Quando a granularidade é a mesma, uma região promissora do espaço de busca foi encontrada e precisa ser apropriadamente *explotada* (Cordón, Herrera & Villar 2001). Neste caso, a granularidade da base de dados contida em Cr_1 é mantida nos filhos e os parâmetros da função de pertinência codificados em Cr_2 combinados via o algoritmo *max-min-aritmético* (MMA) proposto em (Herrera, Lozano & Verdegay 1997) e utilizado entre outros em (Cordón, Herrera & Villar 2001, Cordón, Herrera, Magdalena & Villar 2001). O algoritmo *max-min-aritmético* recombina os elementos de cada vetor, posição a posição, criando, na mesma posição de cada um dos quatro vetores nos filhos, o mínimo, o máximo e duas combinações lineares dos dois parâmetros dos pais.

Ou seja, dados dois indivíduos cujas funções de pertinência são representadas pelos cromossomos abaixo

$$(r_1^{X_1}, l_2^{X_1}, r_2^{X_1}, \dots, l_k^{X_1}, r_k^{X_1}, \dots, l_{n_1}^{X_1}), (r_1^{Y_1}, l_2^{Y_1}, r_2^{Y_1}, \dots, l_k^{Y_1}, r_k^{Y_1}, \dots, l_{m_1}^{Y_1})$$

$$(\rho_1^{X_1}, \lambda_2^{X_1}, \rho_2^{X_1}, \dots, \lambda_k^{X_1}, \rho_k^{X_1}, \dots, \lambda_{n_1}^{X_1}), (\rho_1^{Y_1}, \lambda_2^{Y_1}, \rho_2^{Y_1}, \dots, \lambda_k^{Y_1}, \rho_k^{Y_1}, \dots, \lambda_{m_1}^{Y_1})$$

são gerados quatro filhos como nas expressões 6.6, 6.7, 6.8 e 6.9.

$$\begin{aligned}
& (\min(r_1^{X_1}, \rho_1^{X_1}), \dots, \min(l_k^{X_1}, \lambda_k^{X_1}), \min(r_k^{X_1}, \rho_k^{X_1}), \dots, \min(l_{n_1}^{X_1}, \lambda_{n_1}^{X_1})), \\
& (\min(r_1^{Y_1}, \rho_1^{Y_1}), \dots, \min(l_k^{Y_1}, \lambda_k^{Y_1}), \min(r_k^{Y_1}, \rho_k^{Y_1}), \dots, \min(l_{n_1}^{Y_1}, \lambda_{n_1}^{Y_1})) \quad (6.6)
\end{aligned}$$

$$\begin{aligned}
& (\max(r_1^{X_1}, \rho_1^{X_1}), \dots, \max(l_k^{X_1}, \lambda_k^{X_1}), \max(r_k^{X_1}, \rho_k^{X_1}), \dots, \max(l_{n_1}^{X_1}, \lambda_{n_1}^{X_1})), \\
& (\max(r_1^{Y_1}, \rho_1^{Y_1}), \dots, \max(l_k^{Y_1}, \lambda_k^{Y_1}), \max(r_k^{Y_1}, \rho_k^{Y_1}), \dots, \max(l_{n_1}^{Y_1}, \lambda_{n_1}^{Y_1})) \quad (6.7)
\end{aligned}$$

$$\begin{aligned}
& (dr_1^{X_1} + (1-d)\rho_1^{X_1}, \dots, dl_k^{X_1} + (1-d)\lambda_k^{X_1}, dr_k^{X_1} + (1-d)\rho_k^{X_1}, \dots, dl_{n_1}^{X_1} + (1-d)\lambda_{n_1}^{X_1}), \\
& (dr_1^{Y_1} + (1-d)\rho_1^{Y_1}, \dots, dl_k^{Y_1} + (1-d)\lambda_k^{Y_1}, dr_k^{Y_1} + (1-d)\rho_k^{Y_1}, \dots, dl_{n_1}^{Y_1} + (1-d)\lambda_{n_1}^{Y_1}), \quad (6.8)
\end{aligned}$$

$$\begin{aligned}
& ((1-d)r_1^{X_1} + d\rho_1^{X_1}, \dots, (1-d)l_k^{X_1} + d\lambda_k^{X_1}, (1-d)r_k^{X_1} + d\rho_k^{X_1}, \dots, (1-d)l_{n_1}^{X_1} + d\lambda_{n_1}^{X_1}), \\
& ((1-d)r_1^{Y_1} + d\rho_1^{Y_1}, \dots, (1-d)l_k^{Y_1} + d\lambda_k^{Y_1}, (1-d)r_k^{Y_1} + d\rho_k^{Y_1}, \dots, (1-d)l_{n_1}^{Y_1} + d\lambda_{n_1}^{Y_1}), \quad (6.9)
\end{aligned}$$

O parâmetro d pode ser uma constante ou variar com a idade da população. Foi utilizado $d = 0,35$ a partir de (Herrera, Lozano & Verdegay 1997). Cordón, Herrera & Villar (2001) descartam os dois piores dentre estes quatro filhos e adicionam somente os dois melhores na geração que sofrerá mutação. Como a avaliação do *fitness* de um FRBS participando no leilão de energia é realizada antes de se selecionar os indivíduos a serem recombinados na próxima geração, e esta avaliação é muito custosa computacionalmente, opta-se na aplicação ao leilão de energia por adicionar todos os indivíduos gerados pelo algoritmo MMA à geração de filhos que sofrerá mutação.

Além disso, ao invés de serem recombinadas os conjuntos de bases de regras, adota-se a estratégia de criar oito filhos de pais com mesma granularidade, onde cada filho terá as funções de pertinência dadas pelo algoritmo MMA e as bases de regras de um dos pais. Procura-se deste modo evoluir os parâmetros das funções de pertinência mantendo as bases obtidas até este momento do processo evolutivo.

Assim para os dois indivíduos abaixo⁷

$$(Cr_1, Cr_2, Cr_3)$$

$$(Cr_1, \Gamma_2, \Gamma_3)$$

⁷O componente relativo à granularidade Cr_1 é o mesmo pois ambos os indivíduos têm a mesma granularidade.

teremos oito filhos dados por:

$$(Cr_1, \min(Cr_2, \Gamma_2), Cr_3)$$

$$(Cr_1, \min(Cr_2, \Gamma_2), \Gamma_3)$$

$$(Cr_1, \max(Cr_2, \Gamma_2), Cr_3)$$

$$(Cr_1, \max(Cr_2, \Gamma_2), \Gamma_3)$$

$$(Cr_1, d \cdot Cr_2 + (1 - d) \cdot \Gamma_2, Cr_3)$$

$$(Cr_1, d \cdot Cr_2 + (1 - d) \cdot \Gamma_2, \Gamma_3)$$

$$(Cr_1, (1 - d) \cdot Cr_2 + d \cdot \Gamma_2, Cr_3)$$

$$(Cr_1, (1 - d) \cdot Cr_2 + d \cdot \Gamma_2, \Gamma_3)$$

6.3.5 Crossover da Base de Regras

Um novo operador de *crossover* foi desenvolvido para combinar duas bases de regras quando a granularidade dos indivíduos é diferente⁸. Primeiramente, para a reprodução de dois indivíduos, cada qual com R bases de regras, para cada base de regras RB_r do primeiro indivíduo é escolhida aleatoriamente e sem repetição uma base de regras RB_x do outro indivíduo, seu parceiro. Desta forma RB_x é tal que x é um inteiro uniformemente escolhido em $\{1, 2, \dots, R\}$.

Então, o passo seguinte é transformar as duas bases de regras RB_r e RB_x em uma cadeia de bits de tamanho variável. Por exemplo, supondo dois indivíduos cuja granularidade sejam aquelas em $(1, 1, 4, 5)$ e $(1, 1, 3, 4)$, isto é, a granularidade do primeiro indivíduo é 4 e 5, e do segundo indivíduo é 3 e 4. Podemos assumir que estes indivíduos estão associados a bases de regras RB_r e RB_x contendo respectivamente 9 regras $\{r_1, r_2, \dots, r_9\}$ e 7 regras $\{\rho_1, \rho_2, \dots, \rho_7\}$, como observado na Figura 6.3. Na figura, A representa o antecedente e C o conseqüente do primeiro indivíduo. De maneira similar, o antecedente do segundo indivíduo é representado por α e seu conseqüente por γ .

O antecedente e o conseqüente de cada base de regras é transformado em um genótipo de tamanho variável, separando-se a porção do antecedente e do conseqüente de cada base de regras,

⁸Quando a granularidade é igual, o *crossover* é realizado como detalhado na seção anterior, mantendo cópias das bases de regras Cr_3 e Γ_3 para cada uma das quatro diferentes bases de dados gerados pelo algoritmo MMA, resultando em oito indivíduos diversos.

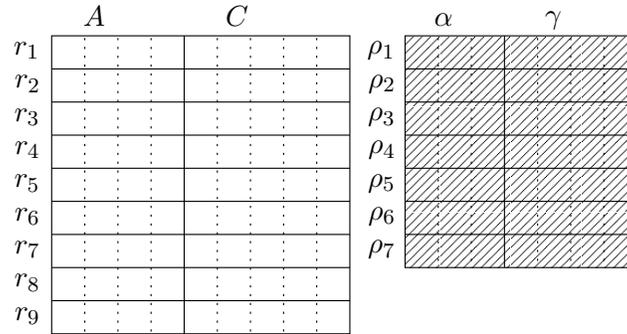


Figura 6.3: Bases de regras de dois indivíduos selecionados para reprodução.

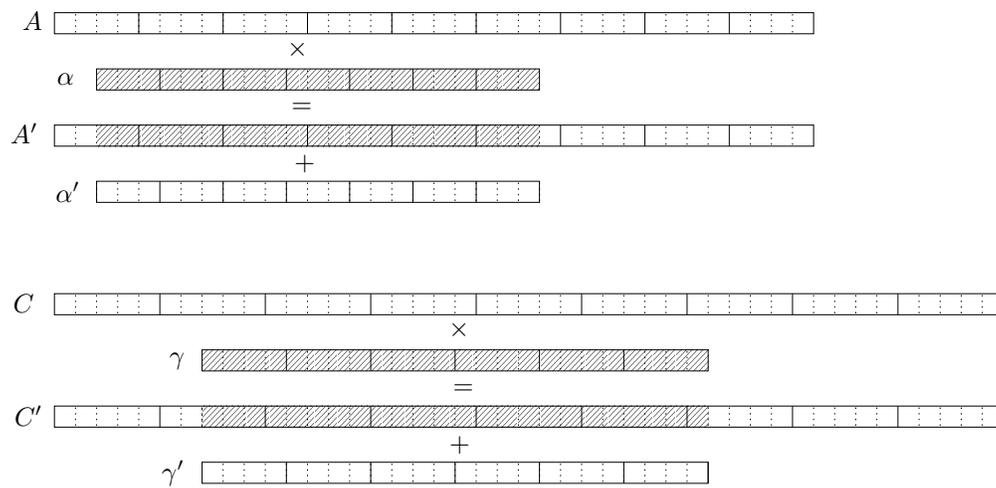


Figura 6.4: *Crossover* dos antecedentes e consequentes de dois indivíduos.

como mostrado na Figura 6.4. Estes cromossomos sofrem *crossover* como mostrado na Figura 6.4, onde \times denota o operador de *crossover*.

As bases de regras resultantes do *crossover* tornam-se aquelas ilustradas na Figura 6.5. Nota-se que a granularidade das bases de dados também sofre *crossover* no mesmo ponto, resultando nas granularidades das bases de dados em $(1, 1, 4, 4)$ e $(1, 1, 3, 5)$, ou seja, granularidades 4 e 4, e 3 e 5, respectivamente. Portanto, as bases de regras refletem as mudanças ocorridas nas bases de dados. Para obter as bases de dados da prole procede-se como indicado na Figura 6.6. Nota-se que uma porção foi removida de C' para se obter C'' . Do mesmo modo, uma porção composta de consequentes de regras escolhidos aleatoriamente em γ' foi adicionada à porção original de γ' para se obter γ'' . Esta última troca de código entre C' e C'' , e γ' e γ'' tem um único objetivo: evitar que as regras da prole se assemelhem demasiadamente àsquelas que compõem as bases de regras dos pais, como observa-se nas bases de regras intermediárias da Figura 6.5.

Podemos assumir por exemplo dois indivíduos com granularidade $(1, 1, 3, 5)$ e $(1, 1, 4, 3)$ e as

	A'	C'		α'	γ'
r_1	ρ_1
r_2	ρ_2
r_3	ρ_3
r_4	ρ_4
r_5	ρ_5
r_6	ρ_6
r_7	ρ_7
r_8			
r_9			

Figura 6.5: Bases de regras de dois indivíduos após *crossover*.

	A'	γ''		α'	C''
r_1	ρ_1
r_2	ρ_2
r_3	ρ_3
r_4	ρ_4
r_5	ρ_5
r_6	ρ_6
r_7	ρ_7
r_8			
r_9			

Figura 6.6: Bases de regras da prole de dois indivíduos.

bases de regras no topo da Figura 6.7, onde o primeiro bit indica uma regra ativa (1) ou inativa (0). O *crossover* destes dois indivíduos resulta em dois filhos com granularidade (1, 1, 3, 3) e (1, 1, 4, 5) cujas bases de regras são apresentadas na parte inferior da Figura 6.7. A última regra da base de regras do filho (1, 1, 4, 5) na parte inferior à direita da figura é a recombinação da última regra 0 1011 \Rightarrow 010 do pai com a segunda regra 0 110 \Rightarrow 00110 escolhida aleatoriamente na base de regras de seu parceiro.

6.3.6 Mutação

O operador de mutação é implementado de maneira diferenciada, segundo o componente do cromossomo em que deve atuar. Cada uma das $N + M$ granularidades sofre mutação com probabilidade $p_{mutacao}$. Quando a granularidade, representada por um inteiro no intervalo [3, 9], sofre mutação, uma variação local é introduzida pela adição ou subtração de uma unidade com igual probabilidade. Parâmetros das funções de pertinência utilizam o operador de mutação não-uniforme de Michalewicz (Michalewicz 1996). As bases de regras utilizam a mutação padrão bit a bit. Estes mecanismos de mutação são detalhados a seguir.

6.3.6.1 Mutação da granularidade

Cada uma das $N + M$ granularidades do GFRBS sofre mutação segundo uma probabilidade $p_{mutacao}$. Quando uma granularidade, representada por um inteiro no intervalo [3, 9], sofre mutação, uma variação local é introduzida, e o novo valor da granularidade será com igual probabilidade o inteiro imediatamente inferior ou superior, com exceção dos valores 3 e 9 nos limites do intervalo que são mudados nos únicos valores possíveis, 4 e 8 respectivamente. Esta mutação é utilizada com frequência na literatura e segue entre outros (Cordón, Herrera & Villar 2001).

Uma vez modificada uma granularidade em Cr_1 esta modificação é propagada às funções

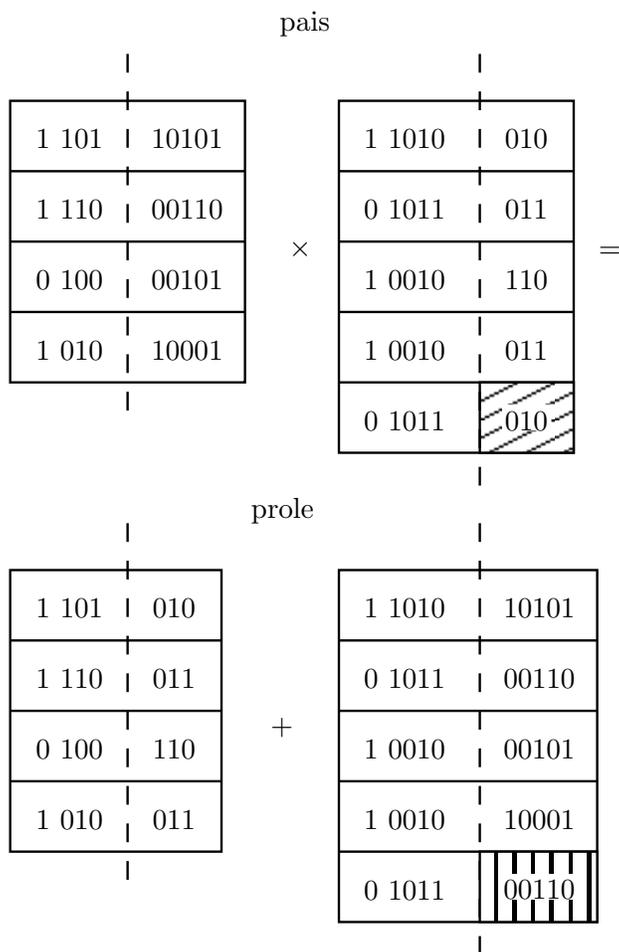


Figura 6.7: Exemplo de *crossover* da base de regras.

de pertinência em Cr_2 e à base de regras em Cr_3 . Quando o número de termos diminui, um dos termos é escolhido aleatoriamente e os parâmetros da função de pertinência correspondentes àquele termo são removidos de Cr_2 . Na base de regras Cr_3 , o bit correspondente ao termo escolhido é removido de cada uma das regras.

Quando o número de termos aumenta, dois novos parâmetros escolhidos aleatoriamente no universo de discurso correspondente são adicionados a Cr_2 e um bit escolhido com probabilidade $p_{TermoLativo}$ é adicionado a cada uma das regras em Cr_3 .

Neste sentido esta abordagem é diferente daquela proposta em (Cordón, Herrera & Villar 2001) onde a mutação de uma granularidade gera uma nova partição uniforme da variável lingüística e que consideramos destrutiva demais.

6.3.6.2 Mutação das funções de pertinência

A mutação dos parâmetros das funções de pertinência codificados em Cr_2 segue a abordagem proposta em (Cordón, Herrera & Villar 2001) com o emprego do operador de mutação não-uniforme de Michalewicz (1996). Seja um indivíduo com funções de pertinência representadas pela equação 6.3. Quando o parâmetro $l_k^{X_1}$ cujo intervalo válido é $(v_{min}^{X_1}, v_{max}^{X_1})$ sofre mutação, o parâmetro mutado será $\lambda_k^{X_1}$ segundo a equação 6.10.

$$\lambda_k^{X_1} = \begin{cases} l_k^{X_1} + \Delta(t, v_{max}^{X_1} - l_k^{X_1}) & \text{se } c = 0 \\ l_k^{X_1} - \Delta(t, l_k^{X_1} - v_{min}^{X_1}) & \text{se } c = 1 \end{cases} \quad (6.10)$$

Nesta equação 6.10, t é a geração corrente, c um número aleatório que pode assumir o valor 0 ou 1 e a função $\Delta(t, y)$ dada pela equação 6.11 retorna um valor no intervalo $[0, y]$ tal que a probabilidade de $\Delta(t, y)$ se aproximar de 0 aumenta com t . O valor r é escolhido aleatoriamente com distribuição uniforme no intervalo $[0, 1]$, T é o número máximo de gerações e b é um parâmetro que determina o grau de dependência com o número de iterações. Neste trabalho é utilizado $b = 5$ como proposto por Michalewicz (1996) e utilizado por (Cordón, Herrera & Villar 2001). O parâmetro b faz com que o operador realize uma busca uniforme no espaço inicial quando t é pequeno e uma busca bem localizada nos estágios finais do processo de evolução.

$$\Delta(t, y) = y(1 - r^{(1 - \frac{t}{T})^b}) \quad (6.11)$$

Com a utilização do operador de mutação não-uniforme cada parâmetro codificado em Cr_2 sempre sofre a mutação que acabamos de descrever, independentemente da probabilidade de mutação $p_{mutacao}$.

6.3.6.3 Mutação da base de regras

Tanto o bit que indica se uma regra está ativa ou inativa bem como cada um dos $L = L_a + L_c$ bits que compõem as L_r regras das bases codificadas em Cr_3 sofrem a mutação padrão onde um bit escolhido para mutação com probabilidade $p_{mutacao}$ assume o complemento de seu valor. Mutar o bit que indica se a regra está ativa (1) ou inativa (0) equivale a mutar indiretamente o número de regras ativas ainda que o número total de regras na base permaneça o mesmo ao longo do processo evolutivo.

6.3.7 Algoritmo Evolutivo

Algoritmo 1 Algoritmo evolutivo GFRBS

 $t \leftarrow 0$

 criar população inicial (aleatória) Ω_0
repeat

 avaliar cada indivíduo através da função de *fitness*

 selecionar pais na população Ω_t baseado no *fitness* relativo em Ω_t

 aplicar operadores genéticos de *crossover* e mutação nos pais para produzir prole que compõe população Ω_{t+1}
 $t \leftarrow t + 1$
until (critério de parada é satisfeito) {e.g. número máximo de gerações é alcançado}

O algoritmo evolutivo utilizado neste trabalho é um algoritmo evolutivo padrão como detalhado no Algoritmo 1. Os operadores genéticos de seleção, *crossover* e mutação necessários ao algoritmo evolutivo são aqueles detalhados na seção 6.3.2.

6.3.8 Função de *Fitness*

Algoritmo 2 Avaliação dos Indivíduos da População

for todo indivíduo i tal que $i \in \Omega_t$ **do**
for toda base de regras RB_r **do**

 decodificar RB_r com base de dados de i

 adicionar o agente correspondente A_i^r ao mercado

simular o mercado (leilão) para o período de treinamento

fitness $F_{A_i^r}$ é o lucro do agente A_i^r no período de treinamento

 remover agente A_i^r do mercado

end for
fitness F_i do indivíduo i é $F_i = \max_{r=1}^R F_{A_i^r}$
end for

O *fitness* de um indivíduo (GFRBS) no leilão de energia é o lucro do agente correspondente durante o período de treinamento. Cada indivíduo codifica R bases de regras que, decodificadas, proporcionam R diferentes estratégias de oferta. O *fitness* de um indivíduo é considerado o *fitness* da estratégia de oferta nebulosa equivalente à melhor base de regras decodificada e à base de dados correspondente. Ou seja, cada uma das R bases de regras é decodificada juntamente com a base de dados do indivíduo. O sistema baseado em regras nebulosas (FRBS) correspondente é adicionado ao mercado e o leilão é realizado durante o período de treinamento. O sistema nebuloso que obtém o maior lucro entre os R agentes correspondentes a estas estratégias de oferta durante o período de

treinamento define o *fitness* F_i do indivíduo i . Este procedimento é resumido no Algoritmo 2.

Para evitar um valor do *fitness* negativo, uma constante, cujo valor é igual ao número de horas H do período de treinamento vezes os custos fixos de operação do agente, é adicionada à função de *fitness*. Quando modelamos os custos como na expressão (7.1), temos $C_{fixo} = \alpha$. Para um período de treinamento do GFRBS de uma semana, temos $H = 168$ e o *fitness* do agente j é dado pela expressão (6.12), onde $P_{j,h}$ é o lucro horário do agente j na hora h , dado pela expressão (4.7). No Algoritmo 2, o agente j da expressão (4.7) corresponde à decodificação da base de regras RB_r do indivíduo i , ou seja, o agente j corresponde a A_i^r .

$$F_j = \sum_{h=1}^{168} P_{j,h} + 168 * \alpha \quad (6.12)$$

Capítulo 7

Estratégias Inteligentes de Oferta: Aplicação no Mercado de Energia

7.1 Ambiente e Modelo do Sistema

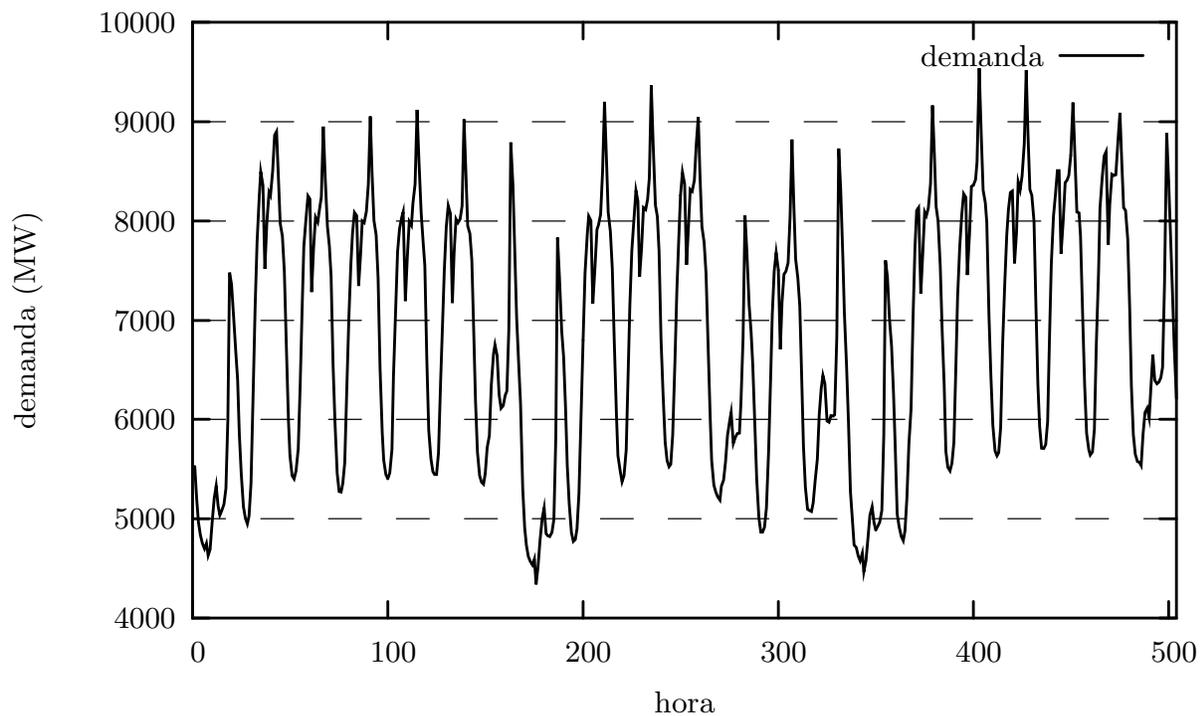


Figura 7.1: Perfil horário da demanda da região Sul¹.

O sistema genético baseado em regras nebulosas considerado neste trabalho é desenvolvido como ferramenta de *suporte à tomada de decisão* para auxiliar uma termoelétrica que tem de decidir a qual preço oferecer energia elétrica quando competindo em um *pool* de geradores. As considerações

em relação ao sistema de potência e o ambiente competitivo adotadas neste estudo são descritas a seguir.

7.1.1 Características de Demanda

A demanda do sistema é supostamente de conhecimento público e o leilão é um mecanismo *ex-ante* para alocar a potência a ser produzida por cada usina e definir o preço horário da energia. A carga real do mercado brasileiro correspondente ao sub-mercado Sul, divulgada pelo Operador Nacional do Sistema (ONS 2002), é utilizada nas simulações. Os dados correspondem ao período de três semanas com início em 19 de maio de 2002. A primeira semana (equivalente a 168 horas) é utilizada para a evolução do GFRBS (aprendizagem) e as duas semanas seguintes (336 horas) para testar o melhor GFRBS encontrado durante o período de aprendizagem. A Figura 7.1 mostra o perfil horário da demanda para as três semanas.

7.1.2 Função de Custo Operacional

Um *pool* de usinas é utilizado baseado em dados reais das usinas termoeletricas do setor elétrico brasileiro. Porém, restrições elétricas e submercados não são levados em conta neste trabalho. Há excesso de oferta embora os custos de racionamento sejam iguais àqueles definidos pelo ONS. Os custos operacionais da produção de potência em usinas movidas a carvão, gás e óleo são modelados como funções quadráticas da potência suprida pela usina $g_{j,h}$ como sugerido na seção 4.3.4 e dado pela expressão (4.4), expressa novamente em 7.1 por conveniência. Usinas nucleares e a bagaço de cana são modeladas como funções de custos lineares. Os participantes conservadores no mercado escolhem somente o preço ao qual a energia é oferecida pois assume-se que a quantidade oferecida é equivalente a toda sua capacidade disponível.

$$C_j(g_{j,h}) = \alpha + \beta g_{j,h} + \gamma g_{j,h}^2 \quad [\text{R\$/h}] \quad (7.1)$$

7.1.3 Leilão a Preço Uniforme

O mecanismo de formação de preços é um leilão fechado a preço uniforme para o mercado do dia seguinte (*day-ahead*). Em cada dia de negociação o operador do leilão realiza as atividades definidas na seção 4.3.1.

O operador do leilão decide o despacho horário escolhendo quais geradores produzem energia e o correspondente preço a fim de minimizar o custo total da energia. A demanda D_h é considerada inelástica ao preço. Assim, o operador do leilão deve assegurar que para cada hora h , $\sum_{j=1}^{T_h} g_{j,h} =$

Usina	Tipo	Capacidade (MW)	Cap. Agregada (MW)	Custo marginal (R\$/MWh)
Angra 1	Nuclear	657	657	8,500
Angra 2	Nuclear	1.309	1.966	8,500
P.Médici 3-4	Carvão	320	2.286	32,946
P.Médici 1-2	Carvão	126	2.412	33,330
TermoBahia	Gás	171	2.583	34,378
TermoCeara	Gás	153	2.736	34,719
Canoas	Gás	450	3.186	37,543
Norte Fluminense	Gás	426,6	3.612,6	37,631
Araucária	Gás	441,6	4.054,2	37,697
Três Lagoas	Gás	324	4.378,2	37,762
Corumba	Gás	79,2	4.457,4	38,034
Juiz de Fora	Gás	103	4.560,4	38,732
Ibirité	Gás	766,5	5.326,9	39,065
TermoRio	Gás	824,7	6.151,6	39,109
Argentina I	Gás	1.018	7.169,6	41,045
Argentina II	Gás	1.000	8.169,6	41,046
J.Lacerda C	Carvão	363	8.532,6	52,638
J.Lacerda B	Carvão	262	8.794,6	63,302
J.Lacerda A 1-2	Carvão	100	8.894,6	67,105
J.Lacerda A 3-4	Carvão	132	9.026,6	67,350
Charqueadas	Carvão	69,1	9.095,7	67,723
FAFEN	Gás	57,6	9.153,3	74,782
Uruguaiana	Gás	582	10.266,3	82,765
Nova Piratininga	Gás	531	10.298,3	88,794

Tabela 7.1: Configuração de mercado: características das termoeletricas.

D_h , onde $g_{j,h}$ é a potência gerada pela usina j . A um preço uniforme esta alocação custa $D_h v_h(D_h)$ e o leiloeiro procura, então, minimizar este custo. O lucro dos geradores é dado por:

$$P_{j,h} = v_h g_{j,h} - C_j(g_{j,h})$$

O mecanismo de formação de preços é realizado através da ordem pelo mérito dos lances, do menor para o maior preço. A intersecção desta curva de oferta com a demanda define o preço horário da energia. Usinas ofertando energia abaixo do preço horário geram a quantidade oferecida, a usina marginal gera a quantidade suficiente para completar a demanda e as usinas ofertando a um preço maior que o preço horário não produzem energia.

Os fornecedores de energia devem internalizar seus custos em um lance simples, um par $(q_{j,h}; p_{j,h})$ da quantidade oferecida (em MW) e seu preço (em unidades monetárias), onde a quantidade $q_{j,h}$ é menor ou igual à capacidade da usina, G_j .

Usina	$C_j(\cdot)$
Angra 1	$8,5g$
Angra 2	$8,5g$
P.Médici 3-4	$865,3 + 28,914g + 0,0063g^2$
P.Médici 1-2	$343,34 + 28,53g + 0,01905g^2$
TermoBahia	$580,54 + 30,985g + 0,00992g^2$
TermoCeara	$505,29 + 30,558g + 0,0136g^2$
Canoas	$1.575,22 + 33,869g + 0,00408g^2$
Norte Fluminense	$1.484,92 + 33,759g + 0,00454g^2$
Araucária	$1.505,65 + 33,782g + 0,00443g^2$
Três Lagoas	$1.115,29 + 33,595g + 0,00643g^2$
Corumba	$278,97 + 33,256g + 0,03016g^2$
Juiz de Fora	$323,68 + 33,088g + 0,0274g^2$
Ibirité	$3.632,08 + 31,966g + 0,00463g^2$
TermoRio	$3.904,05 + 31,912g + 0,00436g^2$
Argentina I	$4.459,61 + 32,775g + 0,00406g^2$
Argentina II	$4.379,82 + 32,774g + 0,00414g^2$
J.Lacerda C	$1.547,15 + 45,962g + 0,00919g^2$
J.Lacerda B	$1.407,65 + 56,198g + 0,01356g^2$
J.Lacerda A 1-2	$549,89 + 57,895g + 0,04605g^2$
J.Lacerda A 3-4	$728,6 + 57,65g + 0,03674g^2$
Charqueadas	$414,59 + 60,037g + 0,05559g^2$
FAFEN	$417,18 + 66,857g + 0,06879g^2$
Uruguaiana	$4.306,82 + 76,729g + 0,00519g^2$
Nova Piratininga	$4.547,35 + 82,418g + 0,006g^2$

Tabela 7.2: Funções de custos das termoeletricas.

Agentes conservadores fazem ofertas em um *bid* representado pelo par $(G_j, MC_j(G_j))$, onde $MC_j(G_j)$ é o custo marginal a plena capacidade G_j :

$$MC_j(G_j) = \left. \frac{dC_j(g_{j,h})}{dg_{j,h}} \right|_{g_{j,h} = G_j} \quad (7.2)$$

7.2 Configuração de Mercado

Foi utilizada como mercado a mesma configuração utilizada em (Walter & Gomide 2007), com demanda equivalente àquela do sub-mercado Sul do sistema elétrico brasileiro divulgada pelo Operador Nacional do Sistema (ONS 2002). A Tabela 7.1 mostra as usinas termoeletricas que são utilizadas para suprir a demanda. Na Tabela 7.2 encontram-se as funções de custo das termoeletricas. O custo marginal (R\$/MWh) na capacidade total, quarta coluna da Tabela 7.1, é calculado a partir das funções de custo e corresponde ao preço da energia quando da oferta conservadora,

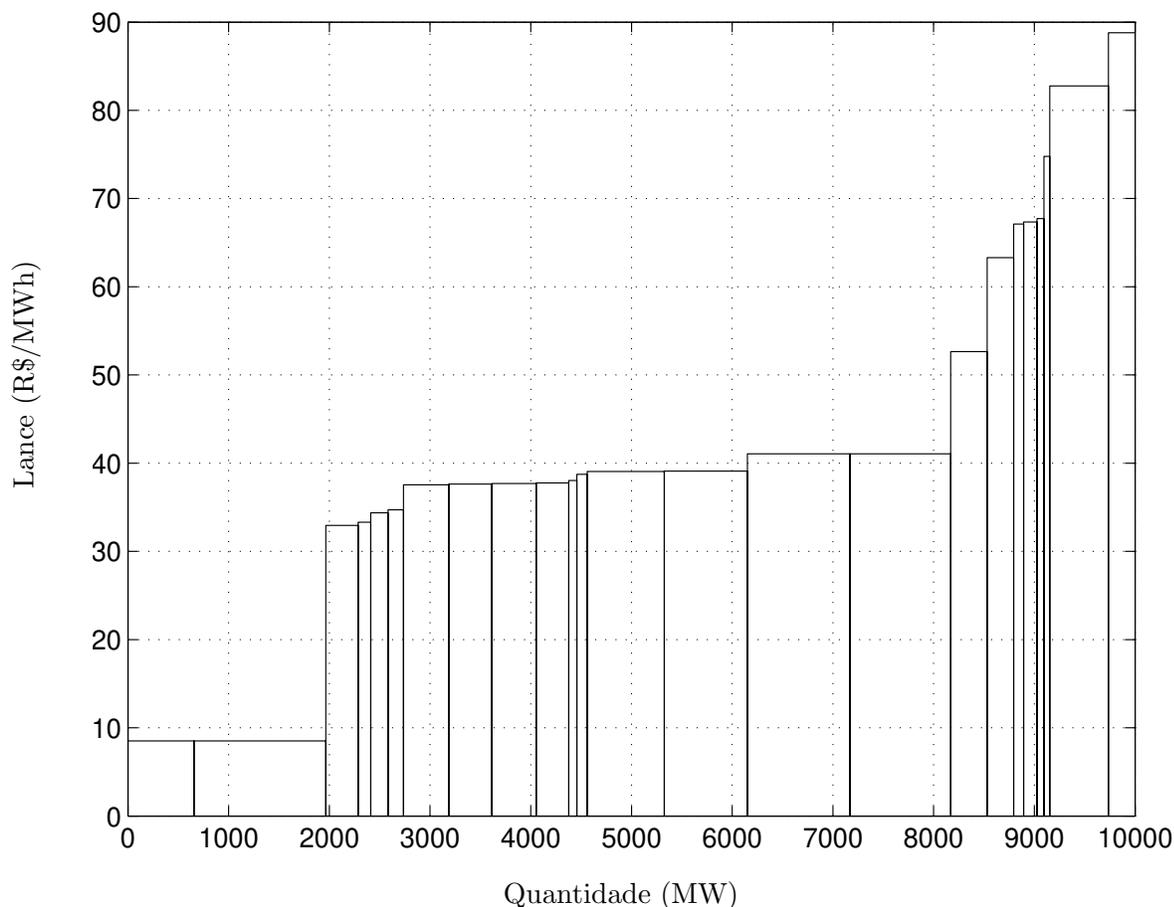


Figura 7.2: Curva de oferta agregada.

definido na expressão (7.2). Esta tabela corresponde então à ordem de mérito a partir da qual é traçada a curva agregada de oferta da Figura 7.2.

Utilizando a arquitetura AEMAS sugerida no Capítulo 5 a simulação que se realiza através da estratégia de oferta descrita neste capítulo é ilustrada pela Figura 7.3. Nota-se que desaparece a figura do comercializador (TraderAgent) e os compradores do tipo BuyerAgent foram agregados em uma única demanda que se assume conhecida pelo ISO² que no caso brasileiro é o ONS. Os vendedores do tipo SellerAgent são o conjunto de termelétricas conservadoras e o agente inteligente baseado na abordagem GFRBS que estamos descrevendo. Finalmente o *pool* é modelado por um mecanismo de leilão fechado a preço uniforme, não há contratação bilateral e as regras do mercado são estáveis.

²ISO: *Independent System Operator*.

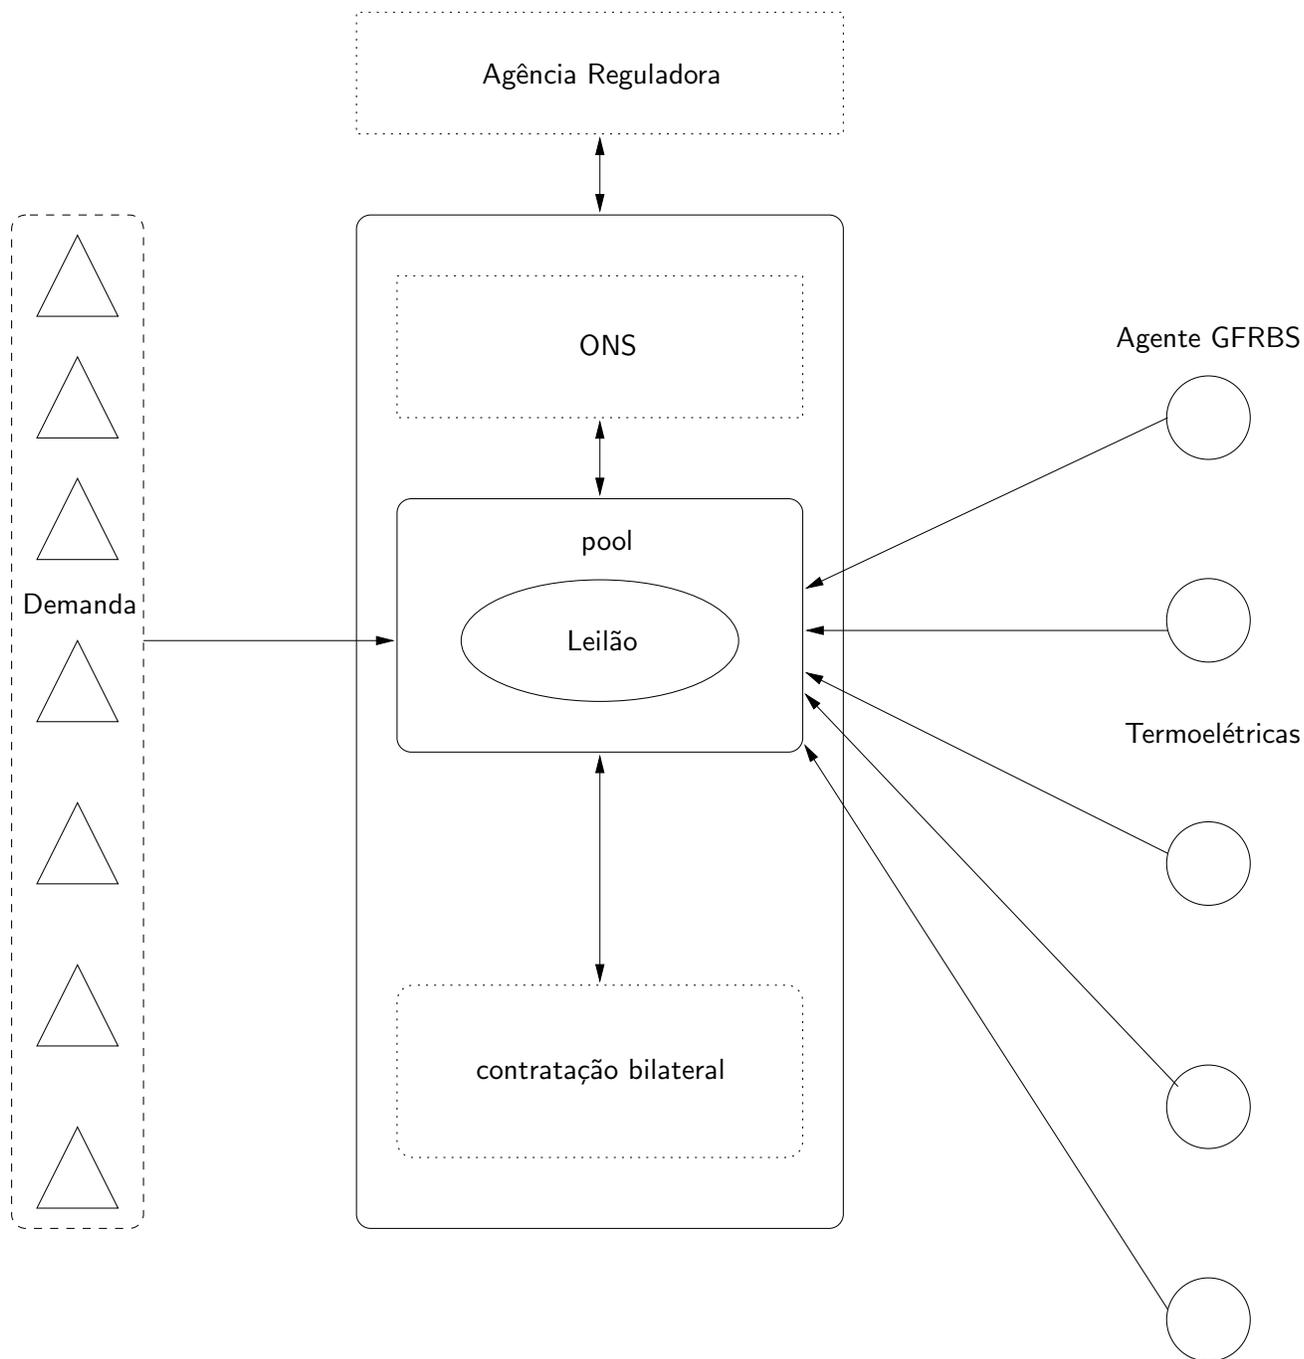


Figura 7.3: Estratégia de oferta sob a ótica da arquitetura AEMAS.

7.3 Resultados

Nesta seção descrevemos resultados de experimentos realizados aplicando-se a abordagem GFRBS sugerida ao mercado de energia elétrica cujas características são descritas na seção 7.2. Outros resultados similares foram apresentados em trabalhos precedentes, utilizando uma abordagem não-hierárquica, ou seja, $R = 1$, (Walter & Gomide 2003a, Walter & Gomide 2004, Walter & Gomide 2006) e utilizando a abordagem hierárquica sugerida neste trabalho (Walter & Gomide 2003b).

7.4 Experimento 1: Lance de Preço

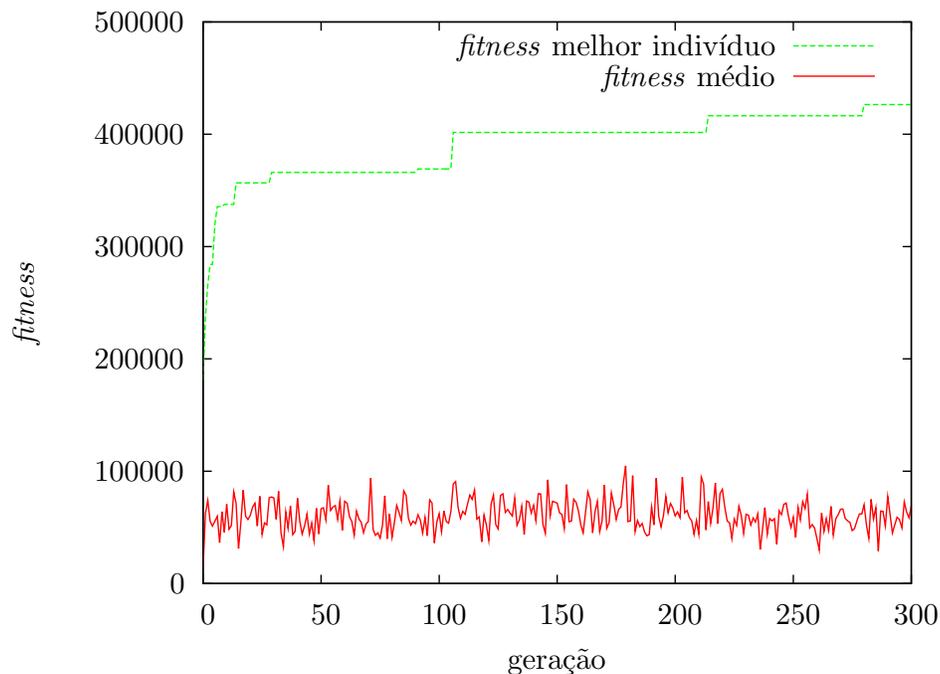


Figura 7.4: Evolução do *fitness* para população de 24 indivíduos, $N = 1$, $M = 1$.

Em um primeiro experimento há somente uma única variável de decisão, de modo similar ao estudo apresentado em (Walter & Gomide 2003b). A partir de uma única entrada, a previsão de demanda fornecida pelo leiloeiro o agente inteligente GFRBS decide o preço da oferta (*bid*) de energia. A quantidade de energia da oferta é a capacidade do agente. Temos então um sistema SISO (*single input single output*), com uma única entrada e uma única saída, e usando a notação adotada na seção 6.3.1 temos $N = 1$ e $M = 1$.

O agente que sofre evolução corresponde ao agente Argentina II. Assume-se que todos os outros competidores definidos na Tabela 7.1 são conservadores, ou seja, realizam ofertas de toda a

estratégia	horas	quantidade (MWh)	lucro bruto (R\$)	lucro líquido (R\$)	lucro médio (R\$/MWh)
conservadora	149	116.381	1.049.818	230.791	1,98
GFRBS	316 (+112%)	295.660 (+154%)	1.088.983 (+3,7%)	1.001.386 (+334%)	3,39 (+70,8%)

Tabela 7.3: Comparação dos resultados entre estratégias de oferta conservadora e GFRBS, $N = 1$, $M = 1$.

sua capacidade ao preço definido pelo custo marginal a capacidade plena.

A probabilidade de *crossover* neste experimento é $p_{crossover} = 0,7$ e a probabilidade de mutação $p_{mutacao} = 0,08$. O número de bases de regras codificadas em cada indivíduo é definido por $R = 4$.

Para uma população de 24 indivíduos o *fitness* evolui como se observa na Figura 7.4. O melhor indivíduo após 300 gerações possui 3 conjuntos nebulosos no antecedente e outros 3 no conseqüente, com uma base de regras contendo 3 regras ativas. Quando decodificado, este indivíduo é testado durante o período de duas semanas de teste e aufer um lucro bem maior que o seu correspondente conservador. Este resultado é obtido através da seguinte estratégia de oferta: lances com preços bem pequenos quando a demanda é baixa e lances com preços maiores que seu custo marginal quando há a oportunidade de que Argentina II seja o gerador marginal³. Ofertas a preços pequenos garantem que o agente inteligente seja despachado mesmo quando o preço da energia é menor que seu custo marginal a plena capacidade $MC_{ArgentinaII}(G_{ArgentinaII})$ porém maior que o custo fixo a saída 0, $MC_{ArgentinaII}(0)$. Como resultado, o agente inteligente reduz perdas em relação ao caso conservador quando normalmente não seria despachado e arcaria com custos fixos sem nenhuma produção e portanto receita nula.

A Tabela 7.3 apresenta uma comparação entre os resultados obtidos com a estratégia inteligente GFRBS e aquela conservadora. Definimos o lucro líquido como o denominado lucro bruto subtraído dos custos fixos para as horas durante as quais o agente não produz energia. Os percentuais em parênteses indicam a variação da estratégia GFRBS em relação à estratégia conservadora, onde observa-se que a estratégia GFRBS resulta claramente em maior lucratividade.

Na Figura 7.5 temos o preço horário do sistema quando utilizamos as estratégias conservadora e GFRBS para a primeira semana do período de teste. Nota-se que em geral o preço aumenta quando se adota a estratégia GFRBS, ainda que para demanda baixa o preço sob esta estratégia seja ligeiramente menor. Na Figura 7.6 temos o lucro horário para as estratégias conservadora e GFRBS, também durante a primeira semana do período de teste. O lucro é praticamente o mesmo para ambas as estratégias durante as horas de maior lucro uma vez que o preço da energia é defi-

³O gerador marginal é o último gerador despachado e determina o preço horário v_h .

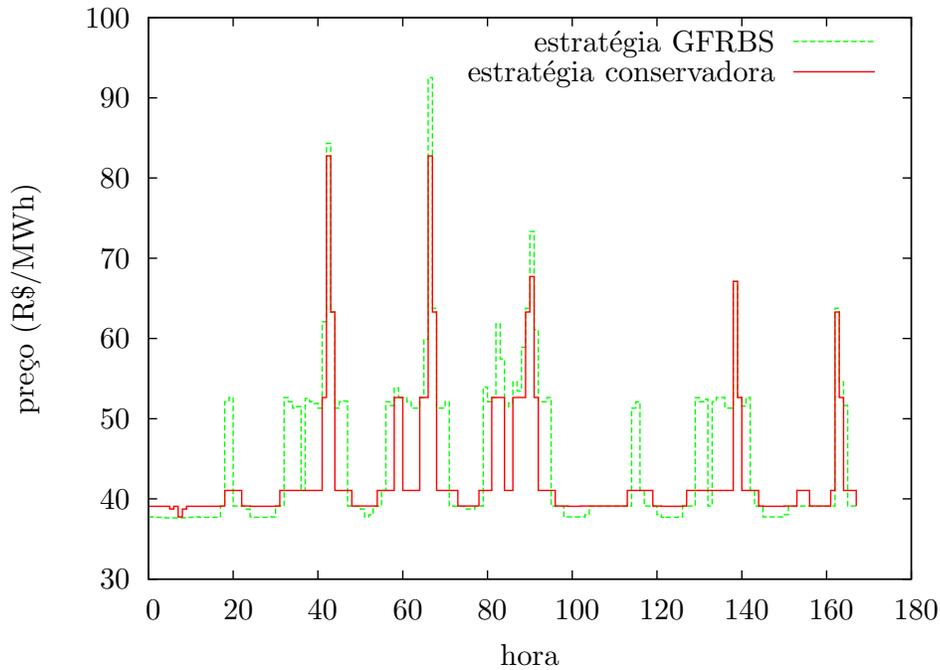


Figura 7.5: Preço horário para as estratégias conservadora e GFRBS, $N = 1$, $M = 1$.

nido por geradores mais caros que Argentina II na ordem pelo mérito. Nas horas em que o lucro é médio, o lucro da estratégia GFRBS é maior em relação à estratégia conservadora devido ao seu comportamento de oferta de aumentar seu *bid* quando se encontra na posição de gerador marginal. Durante as horas de menor lucro, o GFRBS perde menos em relação à estratégia conservadora ao ser despachado mesmo quando os preços da energia são pequenos. Na Figura 7.6, a área sob a curva de lucro para a estratégia GFRBS é maior que aquela da estratégia conservadora e o mesmo vale para o lucro total do GFRBS.

Uma variação no experimento é introduzida com a evolução de um segundo agente, Argentina I, supondo Argentina II como agente conservador. Ou seja, Argentina I sofre evolução em competição com um *pool* conservador do mesmo modo que a evolução de Argentina II que acabamos de descrever. Todos os parâmetros do algoritmo evolutivo (tamanho da população, probabilidades de *crossover* e mutação) são mantidos com os mesmos valores utilizados na evolução de Argentina II. Ao final do processo de evolução de Argentina I tomamos os melhores indivíduos encontrados em ambos os processos e adicionamos ambos ao *pool* de geradores. O resultado da competição entre estes dois agentes segundo estratégias GFRBS é resumido na Tabela 7.4. Nota-se que os resultados obtidos por Argentina II são melhores que aqueles previamente apresentados quando em competição com uma estratégia conservadora para Argentina I. Ou seja, o emprego da estratégia GFRBS por Argentina I melhorou o lucro de Argentina II. Isto é devido principalmente ao fato que Argentina I faz ofertas a preços maiores mas é o agente Argentina II que produz mais energia

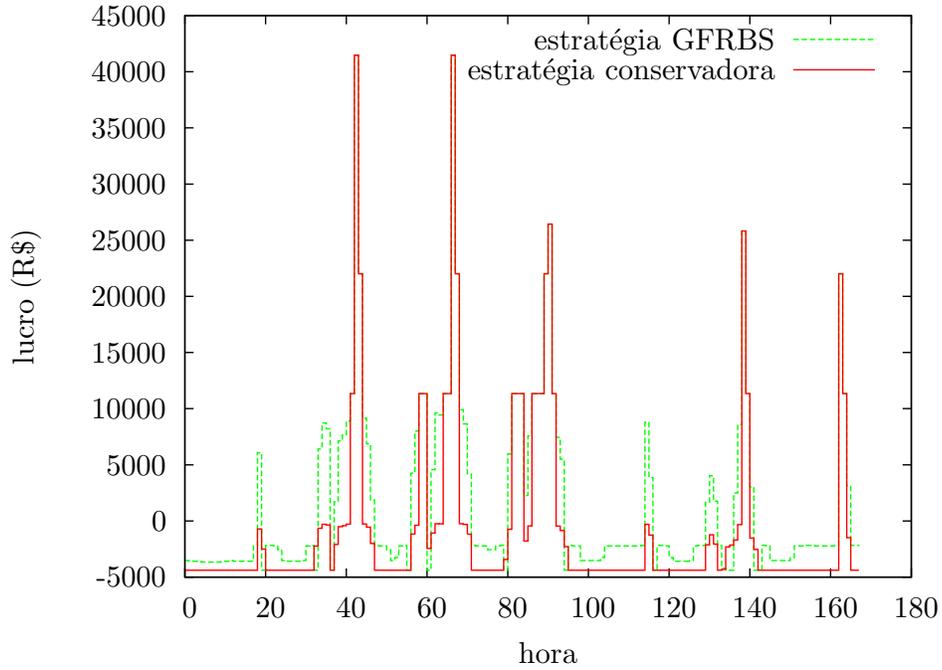


Figura 7.6: Lucro para as estratégias conservadora e GFRBS, $N = 1, M = 1$.

a estes preços, se apropriando do ganho proporcionado por estes preços.

7.5 Experimento 2: Lance de Preço e Quantidade

Tomando o lucro do agente j definido pela expressão (4.7), dado um preço v_h , e assumindo um mercado perfeitamente competitivo, podemos encontrar a quantidade de energia $\hat{g}_{j,h}$ que maximiza o lucro. A derivada $dP_{j,h}/dg_{j,h}$ provê informação sobre a quantidade apropriada a ser oferecida em um lance composto por um par (quantidade; preço).

Quando o preço é tal que $v_h < \beta$, a quantidade de energia que maximiza lucros é zero. Ou seja, é melhor manter o agente gerador sem produzir nada que fazer ofertas de energia a estes preços pequenos demais.

Quando o preço é $v_h \geq \beta + 2\gamma G_j$, onde G_j é a capacidade do agente j , a melhor estratégia é produzir a capacidade plena, G_j . Esta então é a quantidade a compor o lance ótimo.

Quando o preço é tal que $\beta < v_h < \beta + 2\gamma G_j$, a quantidade que maximiza o lucro é dada por⁴:

$$\hat{g}_{j,h} = \frac{v_h - \beta}{2\gamma} \quad (7.3)$$

⁴Para Argentina II temos $\beta = 32,774$ e $\beta + 2\gamma G_j = 41,046$, seu lance conservador.

agente	estratégia	competição	horas	quant. (MWh)	lucro		
					bruto (R\$)	líquido (R\$)	médio (R\$/MWh)
Arg I	conserv.	conserv.	202	179.595	1.065.269	467.682	2,61
Arg I	GFRBS	conserv.	196	139.480	1.470.721	846.376	6,07
Arg I			(-3%)	(-22%)	(+38%)	(+81%)	(+133%)
Arg I	GFRBS	GFRBS	151	133.471	1.838.689	1.013.662	7,59
Arg I			(-25%)	(-26%)	(+73%)	(+117%)	(+192%)
Arg II	conserv.	conserv.	149	116.381	1.049.818	230.791	1,98
Arg II	GFRBS	conserv.	316	295.660	1.088.983	1.001.386	3,39
Arg II			(+112%)	(+154%)	(+3,7%)	(+334%)	(+70,8%)
Arg II	GFRBS	GFRBS	316	307.523	1.479.871	1.392.274	4,53
Arg II			(+112%)	(+164%)	(+41%)	(+503%)	(+129%)

Tabela 7.4: Competição entre duas estratégias GFRBS, $N = 1$, $M = 1$.

Na dedução acima ignoramos o fato de que o preço depende de $g_{j,h}$ uma vez que os mercados não são perfeitamente competitivos. Podemos então utilizar uma estratégia GFRBS para realizar ofertas de uma quantidade de energia e seu preço correspondente. Neste caso, o *bid* não é simplesmente um preço a plena capacidade mas um par (quantidade, preço). Ou seja, no sistema baseado em regras nebulosos (FRBS) temos um antecedente, a previsão de demanda do leiloeiro e dois consequentes, quantidade e preço do lance. Utilizando a notação adotada na seção 6.3.1 temos $N = 1$ e $M = 2$.

Neste experimento é utilizada uma probabilidade de *crossover* $p_{crossover} = 0,5$ e uma probabilidade de mutação $p_{mutacao} = 0,01$. O número de bases de regras por indivíduo é mantido em $R = 4$ e o tamanho da população em 24. Ambos os agentes, Argentina I e Argentina II sofrem evolução competindo em um *pool* de competidores conservadores, ou seja, supõe-se Argentina I conservadora durante a evolução de Argentina II e vice-versa. Os melhores indivíduos encontrados em ambos os processos de evolução são testados durante o período de testes de duas semanas.

A evolução do *fitness* durante o processo evolutivo de Argentina II é observado na Figura 7.7. Notamos que o *fitness* progride mais rapidamente e alcança valores maiores de *fitness* quando comparado aos resultados já apresentados em relação a lances realizados a plena capacidade.

Os resultados comparativos estão resumidos na Tabela 7.5. Uma vez que para a estratégia GFRBS os agentes são despachados durante todas as 336 horas do período de teste, os lucros bruto e líquido são iguais.

Entretanto, notamos que a quantidade de energia produzida por Argentina II é menor que aquela quando as ofertas são realizadas a plena capacidade. Ao reduzir sua oferta de energia disponível, Argentina II faz com que Argentina I seja despachada mais frequentemente e a quantidade

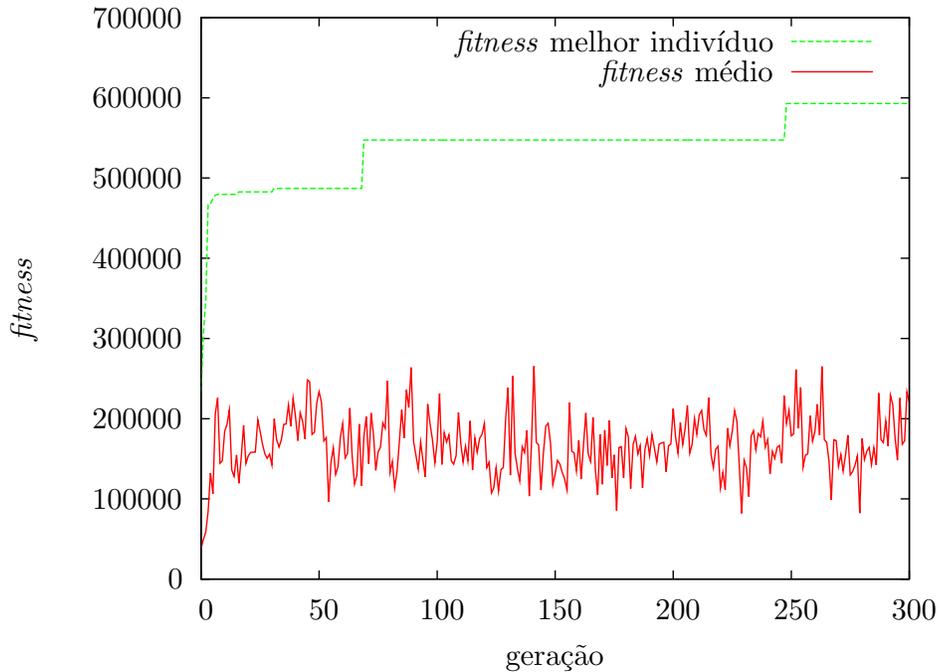


Figura 7.7: Evolução do *fitness* para população de 24 indivíduos, com $N = 1$, $M = 2$.

de energia produzida por Argentina I aumenta. Ambos os agentes, Argentina I e Argentina II, provocam aumento nos preços da energia ao diminuir sua energia disponível e realizar ofertas a preços maiores, aumentando os seus lucros. Em outras palavras, jogam com o mercado.

A estratégia de oferta exhibe no entanto um comportamento mais complexo que este apenas descrito. Consideremos por exemplo o comportamento apresentado no período de uma hora das 15h às 16h do domingo 26 de maio, a 16ª do período de testes no qual a demanda é $D_{16} = 4860,1 MW$. O preço da energia é dado pela termoeletrica Norte Fluminense, o gerador marginal, a um preço $v_{16} = 37,63$ (em R\$/MWh). A quantidade ótima a ser produzida a este preço para Argentina II é:

$$\hat{g}_{ArgII,16} = \frac{37,63 - 32,774}{2 * 0,00414} = 585,5$$

(em MW). Produzir estes 585,5 MW durante uma hora a este preço resultaria em uma perda de R\$ 2.956,00. O lance de Argentina II para a hora $h = 16$ é (760; 18, 18) em (MW; R\$/MWh) e resulta em perda de R\$ 3.078,00, apenas 4% a mais que a perda para o lance ótimo. Portanto, o GFRBS é capaz de aprender uma estratégia para este período que é muito próxima do que seria um comportamento ótimo que minimiza perdas, equivalente a maximizar lucros. A estratégia conservadora é efetuar o lance de capacidade total ao custo marginal, ou seja, (1.000; 41, 05) em (MW; R\$/MWh). Neste caso Argentina II não é despachada e o resultado é uma perda de R\$ 4.379,82, 42% a mais que a perda obtida pela estratégia GFRBS. Nesta mesma hora o lance de Argentina I é (834, 1; 27, 10) o que significa uma perda de R\$ 3.136,00, comparada a uma perda de

agente	estratégia	competição	horas	quant. (MWh)	lucro		
					bruto (R\$)	líquido (R\$)	médio (R\$/MWh)
Arg I	conserv.	conserv.	202	179.595	1.065.269	467.682	2,61
Arg I	GFRBS	conserv.	336	264.771	1.269.095	1.269.095	4,79
Arg I			(+66%)	(+47%)	(+19%)	(+171%)	(+83%)
Arg I	GFRBS	GFRBS	336	276.876	1.791.809	1.791.809	6,47
Arg I			(+66%)	(+54%)	(+68%)	(+283%)	(+148%)
Arg II	conserv.	conserv.	149	116.381	1.049.818	230.791	1,98
Arg II	GFRBS	conserv.	336	236.769	1.261.933	1.261.933	5,33
Arg II			(+125%)	(+103%)	(+20%)	(+446%)	(+169%)
Arg II	GFRBS	GFRBS	336	253.009	1.670.519	1.670.519	6,60
Arg II			(+125%)	(+117%)	(+87%)	(+624%)	(+233%)

Tabela 7.5: Experimento 2: competição entre duas estratégias GFRBS, $N = 1$, $M = 2$.

R\$ 4.459,61 para a estratégia conservadora.

Na hora 18 no mesmo dia, a demanda é $D_{19} = 7831,9$ (em MW). O comportamento de ambos os agentes é completamente diferente. Os lances de Argentina I e Argentina II são $(835,6; 59,61)$ e $(q_{ArgII,19}; 62,72)$, onde $q_{ArgII,19} \geq g_{ArgII,19} = 481,7$, a quantidade despachada de Argentina II. Nesta hora Argentina II é o gerador marginal e então o preço da energia é $v_{19} = 62,72$ (R\$/MWh). Este preço resulta em um lucro de R\$ 17.722 para Argentina I e R\$ 9.084 para Argentina II. Note que os agentes inteligentes fazem lances mais elevados que aquele de J. Lacerda C cujo lance é sua capacidade de 363 MW ao seu custo marginal de R\$ 52,64/MWh. A estratégia conservadora para esta hora resulta em R\$41,05 como preço horário com Argentina II marginal o que leva a uma perda de R\$ 249 para Argentina I que é completamente despachada e uma perda de R\$ 715 para Argentina II que produz 662,3 MW. J. Lacerda C não é despachada.

Às vezes a estratégia de Argentina I é bastante agressiva. Consideremos a hora 9 da segunda-feira 27 de maio, quando a demanda é $D_{34} = 7857,0$ (MW). Os lances de J.Lacerda C, Argentina II, J. Lacerda B e Argentina I são respectivamente $(363; 52,64)$, $(773,1; 62,65)$, $(262; 63,3)$, $(q_{ArgI,34}; 64,03)$, onde $q_{ArgI,34} \geq g_{ArgI,34} = 307,3$, a quantidade produzida por Argentina I. Isto resulta em um lucro de respectivamente R\$ 17.316 e R\$ 4.762 para Argentina II e Argentina I. Nesta mesma hora, a estratégia conservadora resulta em uma perda de R\$ 249 para Argentina II e R\$ 648 para Argentina I, com o preço dado pelo custo marginal de Argentina II, R\$ 41,05/MWh. J. Lacerda C e J. Lacerda B não são despachadas quando os agentes assumem a estratégia conservadora. Entretanto a quantidade ótima para Argentina II seria produzir a plena capacidade e Argentina I produziria os 80,4 MW restantes. Argentina I poderia aumentar ligeiramente seu lance, para algo pouco menor que R\$ 67,11, o próximo lance na ordem de mérito, de J. Lacerda A 1-2.

Concluimos que a capacidade de definir a saída (energia produzida) ao realizar lances de oferta contendo também quantidade e não somente preço, permite a evolução de estratégias GFRBS capazes de decidir a respeito de lances mais lucrativos.

7.6 Experimento 3: Lance de Preço e Quantidade

agente	estratégia	competição	horas	quant. (MWh)	lucro		
					bruto (R\$)	líquido (R\$)	médio (R\$/MWh)
Arg I	conserv.	conserv.	202	179595	1065269	467682	2,61
Arg I	GFRBS	GRFBS	336	221144	1995854	1995854	9,03
Arg I			(+66%)	(+23%)	(+87%)	(+326%)	(+247%)
Arg II	conserv.	conserv.	149	116381	1049818	230791	1,98
Arg II	GFRBS	GRFBS	336	230411	1766032	1766032	7,66
Arg II			(+125%)	(+98%)	(+68%)	(+665%)	(+287%)

Tabela 7.6: Experimento 3: competição entre duas estratégias GFRBS, $N = 1$, $M = 2$.

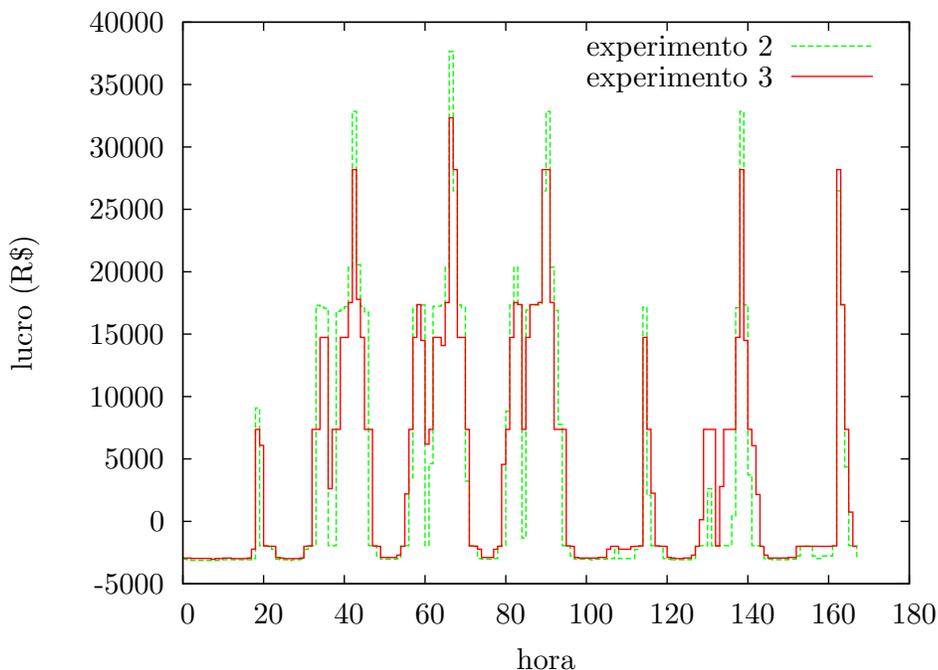


Figura 7.8: Lucro de duas estratégias GFRBS, $N = 1$, $M = 2$.

Prosseguindo na mesma direção do experimento 2, outro experimento é configurado com uma entrada e duas saídas, ou seja, $N = 1$ e $M = 2$. O número de bases de regras por indivíduo é

estratégia	horas	quantidade (MWh)	lucro bruto (R\$)	lucro líquido (R\$)	lucro médio (R\$/MWh)
conservadora	149	116.381	1.049.818	230.791	1,98
GFRBS	149 (0%)	90.218 (-22,5%)	1.466.855 (+39,7%)	647.828 (+180,7%)	7,18 (+262,6%)

Tabela 7.7: Comparação dos resultados entre estratégias de oferta conservadora e GFRBS, $N = 1$, $M = 1$ e lance de quantidade.

mantido em $R = 4$ bem como o tamanho da população, 24. Entretanto são utilizadas probabilidade de *crossover* $p_{crossover} = 0,7$ e probabilidade de mutação $p_{mutacao} = 0,08$. O resultado obtido é ainda melhor que aquele obtido no experimento 2, como podemos observar na Tabela 7.6. Na Figura 7.8 encontra-se o lucro obtido pelo melhor indivíduo correspondente a Argentina II comparado ao lucro obtido no experimento 2.

7.7 Lance de Quantidade

7.7.1 Experimento 4

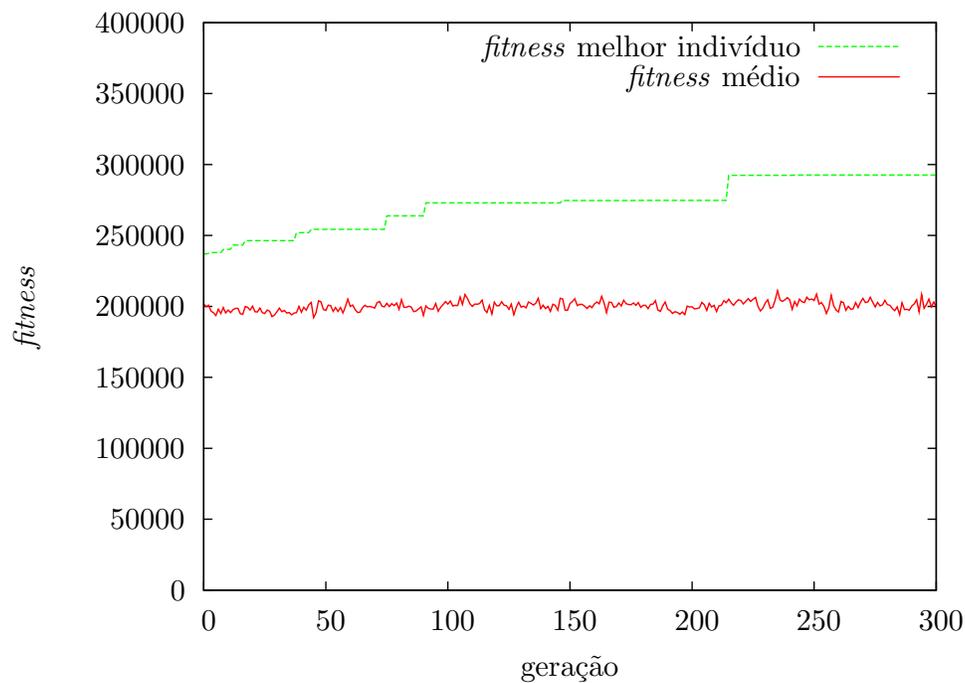


Figura 7.9: Evolução do *fitness* para população de 24 indivíduos, com $N = 1$, $M = 1$ e lance de quantidade.

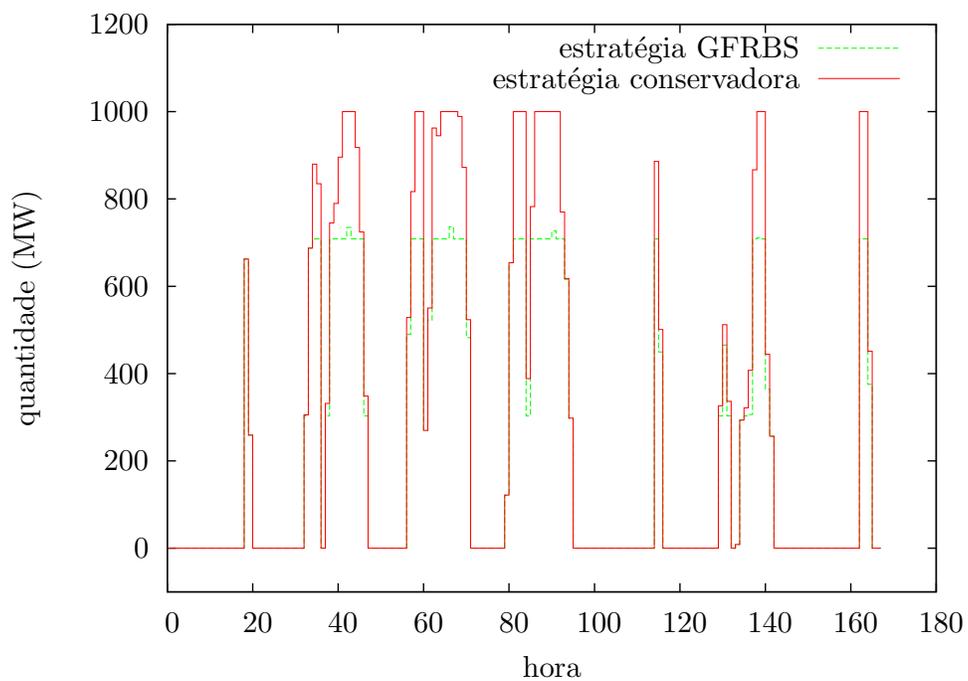


Figura 7.10: Quantidade despachada para as estratégias conservadora e GFRBS, com $N = 1$, $M = 1$ e lance de quantidade.

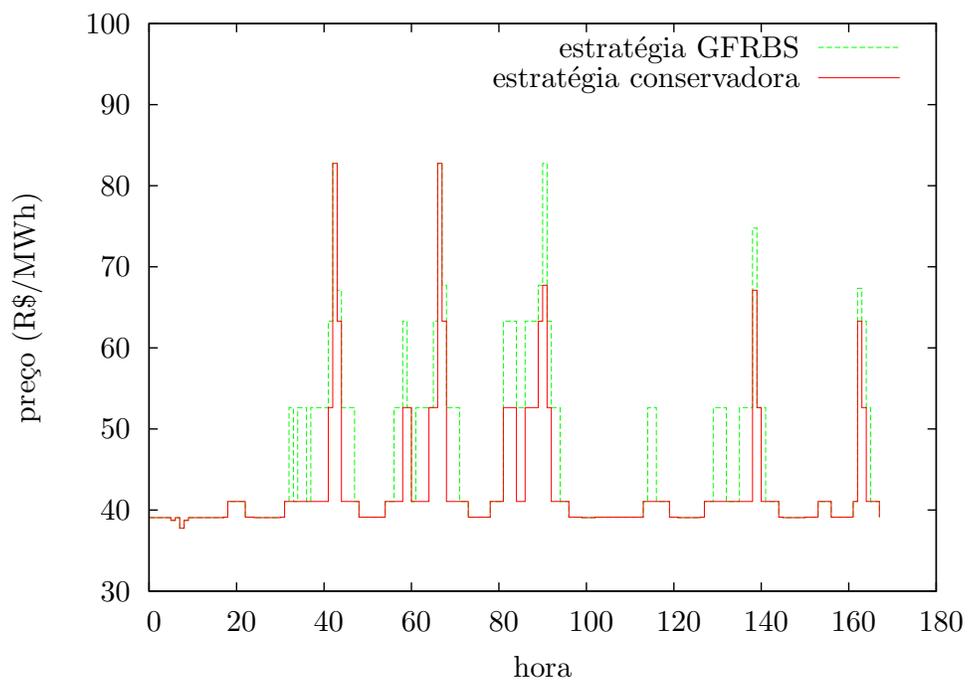


Figura 7.11: Preço horário para as estratégias conservadora e GFRBS, com $N = 1$, $M = 1$ e lance de quantidade.

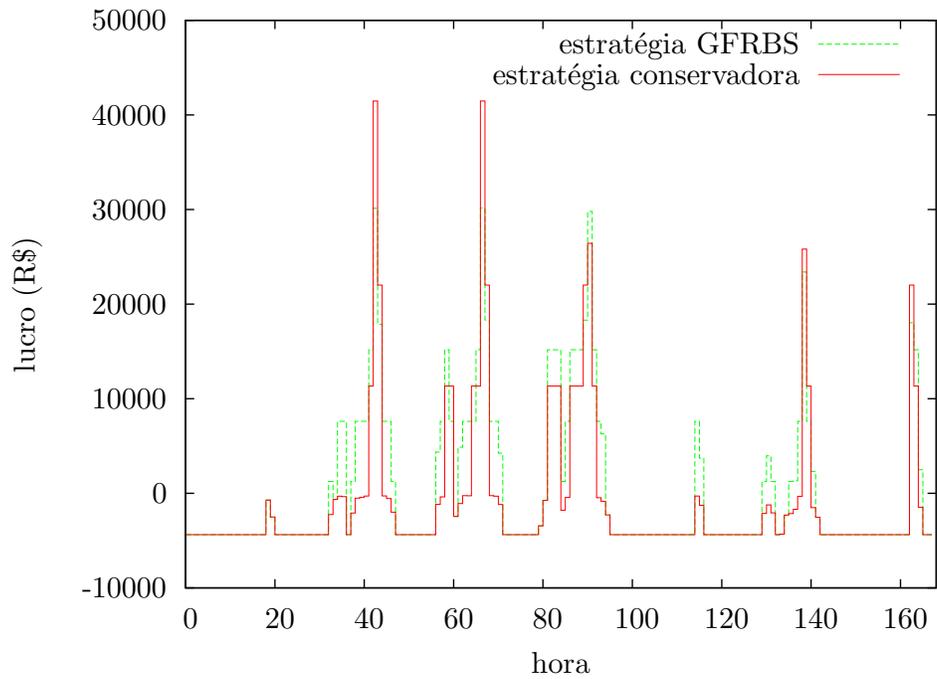


Figura 7.12: Lucro para as estratégias conservadora e GFRBS, com $N = 1, M = 1$ e lance de quantidade.

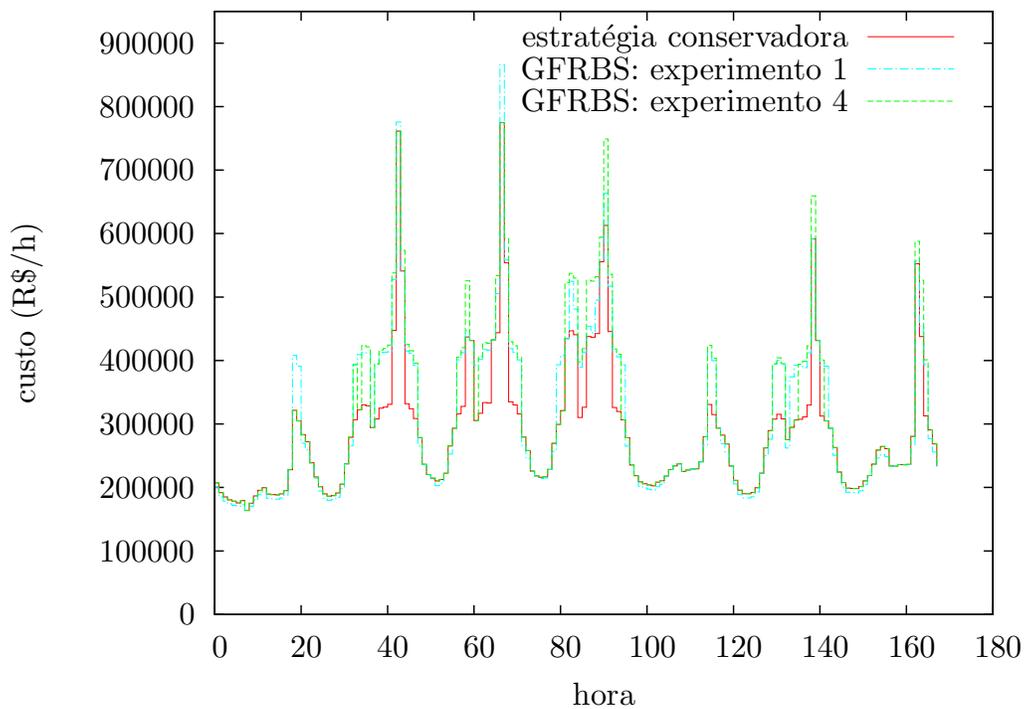


Figura 7.13: Custo global da energia para as estratégias conservadora e GFRBS, com $N = 1, M = 1$, experimentos 1 e 4.

Uma maneira de aplicar o leilão descrito na seção 4.3.1 ao mercado brasileiro é a evolução de um lance onde a oferta é formada por um único valor: a quantidade de energia do lance. Ou seja, o lance é um par (quantidade; preço) onde o preço é o custo marginal à capacidade total, e o agente decide somente a quantidade do lance. O custo marginal à capacidade total $C(G_j)$ corresponde ao custo informado pelos agentes ao ONS e portanto não varia durante a execução do leilão.

Um leilão modelado desta maneira pode caracterizar, por exemplo, a capacidade dos agentes do mercado brasileiro comunicarem uma manutenção forçada (não-prevista), em uma possível tentativa de influenciar preços procurando aumentar lucros. Interessa estudar o efeito de restringir capacidade (*capacity withholding*) para procurar aumentar o preço da energia, como ficou evidenciado com frequência no mercado britânico anterior ao NETA (Bunn & Oliveira 2003). Também interessa a concepção de uma ferramenta de análise do mercado que permita distinguir quando os agentes estão legitimamente em manutenção ou quando usam da manutenção não-prevista como artifício para exercício do seu poder de mercado.

Deste modo, foi configurado o mesmo mercado descrito na seção 7.2. Porém neste experimento decide-se apenas a quantidade do lance utilizando a demanda como única entrada. Ou seja, temos $N = 1$, $M = 1$ e a única saída é a quantidade de energia que compõe o lance, sendo o preço o custo marginal do agente à plena capacidade. Novamente temos probabilidade de *crossover* $p_{crossover} = 0,7$, probabilidade de mutação $p_{mutacao} = 0,08$, $R = 4$ bases de regras por indivíduo em uma população de 24 indivíduos.

Na Figura 7.9 encontra-se o *fitness* médio e do melhor indivíduo para um processo evolutivo que dura 300 gerações. Nota-se uma melhora do *fitness* mas este não alcança valores tão elevados quanto aqueles dos experimento 1 e 2 nas Figuras 7.4 e 7.7.

Na Figura 7.10 observamos como a estratégia GFRBS realiza lances de menor quantidade que a capacidade total, resultando em menor quantidade despachada após a formação de preços dada pela ordem de mérito. Este comportamento provoca aumento de preços, como se observa na Figura 7.11. Em geral este aumento de preços resulta em aumento no lucro da estratégia GFRBS como se observa na Figura 7.12. Porém, durante as horas nas quais a estratégia GFRBS não é capaz de influenciar os preços pois estes são suficientemente elevados, a estratégia GFRBS realiza um lance de menor quantidade e isto resulta em lucros menores, já que não tira proveito de preços elevados a plena capacidade.

Portanto, durante as horas de preços mais elevados o lucro da estratégia conservadora é maior. Durante todo o período de teste no entanto, o lucro da estratégia GFRBS é maior que o lucro para uma estratégia conservadora baseada no custo marginal, como exemplificado na Tabela 7.7. Notamos que o lucro bruto da estratégia GFRBS para um lance de quantidade é maior que aquele do experimento 1, quando a estratégia GFRBS decide qual o preço do lance. Ou seja, não permitir ofertas baseadas em preços, utilizando-se ofertas de quantidade, não garante, por si só, a eficiência

do mercado. Isto pode ser observado na Figura 7.12 onde temos o custo total da energia para a primeira semana do período de teste. Observamos que em diversas oportunidades o experimento 4 com lances de quantidade resulta em um custo global maior.

7.8 Mercado Hidrotérmico

7.8.1 Experimento 5

Usina	Cap. (MW)	E.firme (\overline{MW})	C. marginal (R\$/MWh)	$C_j(\cdot)$ (R\$/h)
Três Marias	396,0	236,4	18,56	$C(g) = 623,65 + 17,136 * g + 0,00302 * g^2$
Ibitinga	131,4	72,7	18,49	$C(g) = 211,13 + 16,843 * g + 0,01132 * g^2$
Itumbiara	2280,0	999,9	17,91	$C(g) = 2393,57 + 14,898 * g + 0,00151 * g^2$
Total	2807,4	1309,0		

Tabela 7.8: Características das usinas hidrelétricas em mercado hidrotérmico.

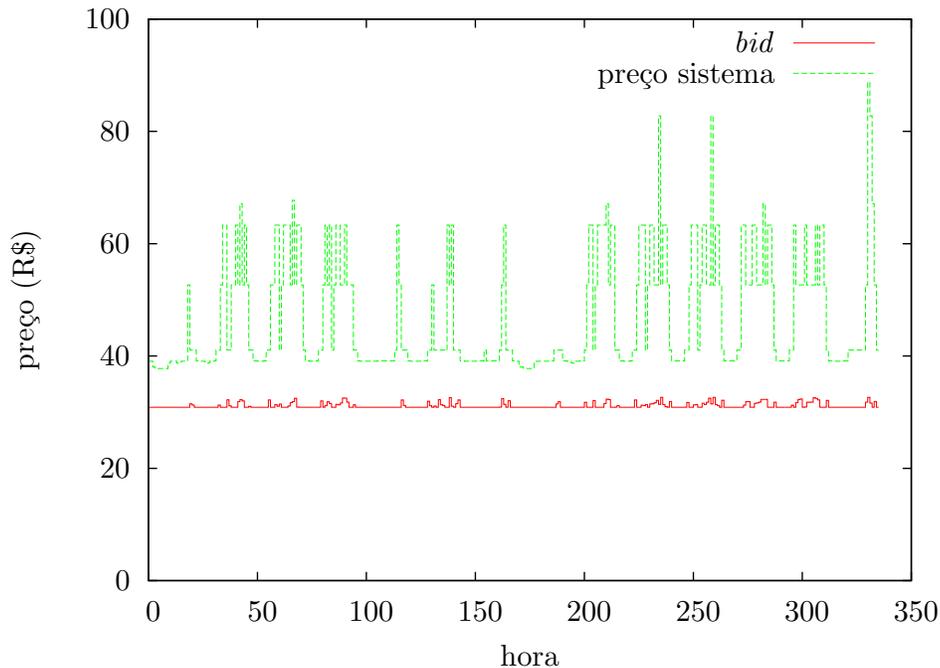


Figura 7.14: Preço da energia e lance de Itumbiara para a estratégia GFRBS, com $N = 1, M = 2$.

No intuito de aproximarmos a aplicação da abordagem sugerida baseada em sistemas *fuzzy* genéticos à realidade do mercado brasileiro, procuramos introduzir usinas hidrelétricas na configuração de mercado e estudar os efeitos de sua presença na evolução das estratégias de oferta. Desta forma substituímos a termoeletrica Angra 2 de 1309 MW de capacidade na base do sistema definido

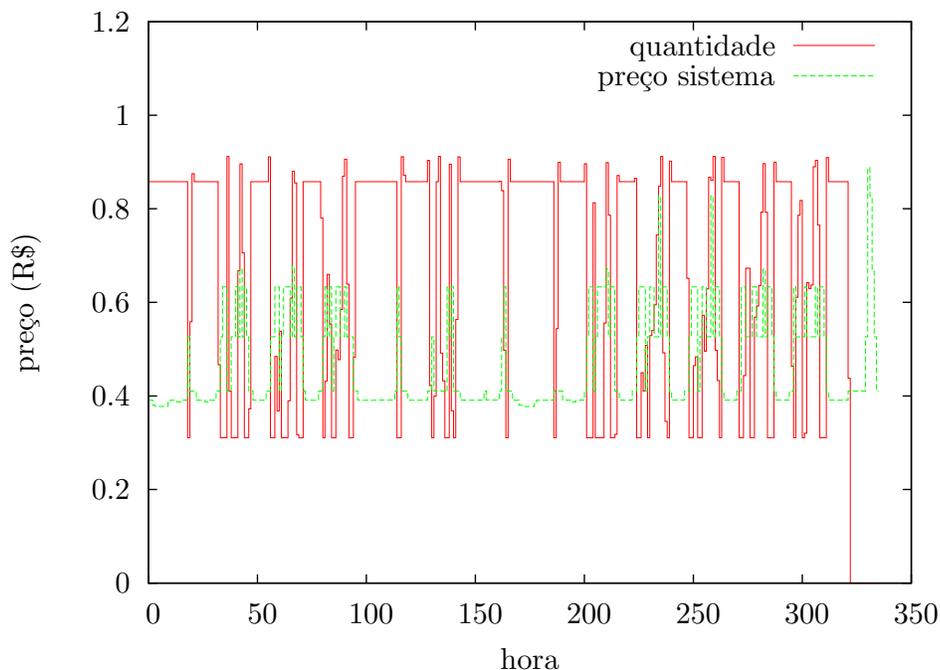


Figura 7.15: Preço da energia e quantidade despachada de Itumbiara para a estratégia GFRBS, com $N = 1, M = 2$.

na Tabela 7.1 pelas três hidrelétricas da Tabela 7.8. Deste modo em termos de energia firme temos três usinas hidrelétricas equivalentes a Angra 2 e a usina de Itumbiara equivalente a Argentina II. Os custos marginais das usinas foram obtidos a partir do preço mínimo do mercado atacadista brasileiro⁵, $PLD_{min} = 18,33$ (em R\$/MWh). A última coluna da Tabela 7.8 apresenta a função de custo de uma termoeletrica a gás de capacidade equivalente a cada uma das usinas hidrelétricas, modelada como descrito na seção 4.3.4.

Não detalhamos a modelagem dos aspectos hidrológicos de um agente hidrelétrico, e, portanto, não levamos em conta, dentre outros aspectos, suas não-linearidades e o aspecto de previsão de vazões. A principal diferença entre as termoeletricas utilizadas anteriormente e um agente hidrelétrico é que este último pode fazer lances de quantidades limitados pela sua capacidade desde que ao longo de um período a energia despachada não supere sua energia firme disponível. Ou seja, dada a energia firme E_{firme} (em \overline{MW}) em um período, temos a energia total disponível $E_{disponivel}$ definida pela expressão (7.4). Devemos ter a geração do agente hidrelétrico j tal que a expressão (7.5) seja respeitada. Desta forma o agente hidrelétrico procura maximizar o seu lucro sujeito à restrição de disponibilidade de energia dada por esta expressão. O agente hidrelétrico j procura então resolver o problema de otimização dado por 7.6. No caso do agente Itumbiara temos que

⁵Conforme Resolução ANEEL n°337/2003, Resolução Homologatória ANEEL n°286/2004 e Despacho ANEEL n°001/2005.

o lance pode variar de 0 a 2280 MW desde que a geração despachada durante uma semana não ultrapasse 167.983,2 MWh.

$$E_{disponivel} = \sum_{h=1}^H E_{firme} \quad (7.4)$$

$$\sum_{h=1}^H g_{j,h} \leq E_{disponivel} \quad (7.5)$$

$$\max P_{j,h}$$

s.a

$$\sum_{h=1}^H g_{j,h} \leq E_{disponivel}$$

$$0 \leq g_{j,h} \leq G_j \quad (7.6)$$

Procedemos deste modo à evolução do agente hidrelétrico Itumbiara ao longo de 500 gerações, com população de 24 indivíduos e parâmetros do algoritmo genético similares aos utilizados nos outros experimentos, isto é, probabilidade de *crossover* $p_{crossover} = 0,7$ e probabilidade de mutação $p_{mutacao} = 0,08$. Além disso temos $R = 4$ bases de conhecimento por indivíduo e temos a demanda como entrada e um par (quantidade; preço) como saída do FRBS, ou seja, $N = 1$ e $M = 2$ como nos experimentos 2 e 3.

O melhor indivíduo obtido ao longo das 500 gerações resulta em uma receita bruta de R\$ 14.908.656, 1,36% maior que aquela obtida por um agente que faz lances correspondentes à energia firme de 999,9 MW ao custo marginal. Na Figura 7.14 observa-se que o lance de Itumbiara não varia muito e permanece próximo de R\$31/MWh. Além disso Itumbiara nunca é o gerador marginal e o preço horário da energia é sempre maior que seu lance. Porém como se observa⁶ na Figura 7.15, a estratégia GRFBS desperdiça a oportunidade de fazer lances de maior quantidade nas horas em que o preço da energia é mais elevado perdendo lucratividade. Na prática a estratégia GFRBS para Itumbiara se traduz, como já observado nos experimentos anteriores, em um comportamento de segurar capacidade para aumentar preços quando seria mais rentável produzir mais energia por um preço menor. Além disso, a estratégia esgota a energia firme do agente que é obrigado a gerar 0 MW nas últimas horas do período de teste. A dificuldade dos algoritmos genéticos em resolver problemas com restrições é bem conhecida na literatura e para superá-la é necessário reprojeter a representação cromossômica levando em conta novas restrições ao sistema.

⁶Preço normalizado em R\$100/MWh e quantidade em 1500 MW.

demanda	<i>bid</i> : (quantidade; preço)
$D_h \leq 8000$	$(E_{livre}; CM(E_{livre}))$
$8000 < D_h \leq 9000$	$(E_{livre} * 1, 2; CM(E_{livre} * 1, 2))$
$D_h > 9000$	$(G_j; 63, 00)$

Tabela 7.9: Regra para agente hidrelétrico *smart*.

A partir da observação do comportamento do agente Itumbiara quando da evolução de uma estratégia GRFBS que obteve sucesso, delineamos uma estratégia heurística que denominamos *smart* dada por uma regra *crisp* ajustada por tentativa e erro, como definido na Tabela 7.9, onde G_j é a capacidade do agente, $CM(\cdot)$ é o custo marginal, e E_{livre} é a energia disponível dada pela energia firme total subtraída da energia já despachada nos dias anteriores e já ofertada nas horas anteriores do dia atual. Quando o agente não realizou nenhum despacho e nenhum lance acima da energia firme, E_{livre} é a energia firme. Caso contrário para o lance da hora λ do dia Δ temos que E_{livre} é dada pela expressão (7.7), onde $q_{j,h}$ é a quantidade do lance do agente j na hora h .

$$E_{livre} = \frac{E_{disponivel} - (\sum_{h=1}^{\Delta*24} g_{j,h} + \sum_{h=1}^{\lambda-1} q_{j,h})}{H - \Delta * 24 - \lambda + 1} \quad (7.7)$$

Tomando-se os demais agentes como conservadores, Itumbiara seguindo a regra *smart*, submete-se Argentina II ao processo evolutivo na abordagem GFS. A partir desta regra para a estratégia de Itumbiara, verificamos que a evolução de Argentina II resulta em estratégias rentáveis, com lucro líquido na ordem daquele encontrado no experimento 1, porém inferior ao experimento 2. Ou seja, a partir de resultados preliminares observamos que a concorrência entre Argentina II e Itumbiara utilizando a regra *smart*, aumenta a dificuldade da abordagem GRFBS para encontrar uma estratégia rentável para Argentina II.

7.9 Oferta com Múltiplos Lances

No leilão de energia, podem ser utilizados diferentes instrumentos de oferta. O lance mais simples é um único par (quantidade; preço). Porém alguns leilões como o *pool* da Inglaterra permitem a utilização de uma curva de oferta onde cada empresa participante no leilão pode realizar uma oferta que se aproxime da sua curva agregada de custos de diversas usinas. De qualquer modo, o número de ofertas tende a ser limitado. Nos leilões de compra e venda brasileiros, segundo (Masili 2004, Azevedo 2004, Munhoz 2004), são utilizados cinco lances de oferta de quantidade e preço. Descrições de lances complexos no mercado espanhol são descritos em (Contreras, Candiles, de la Fuente & Gómez 2001).

Uma questão importante é o estudo da influência do número de lances por agente permi-

tido no leilão. É de se esperar que, quanto maior o número de lances e menor os blocos de energia (quantidade) ofertados em cada lance, o resultado do leilão tenda ao despacho centralizado ótimo, quando os agentes ofertam de maneira conservadora (custos marginais). Ou seja, pode ser interessante ao projetista do mercado estabelecer um número de lances ou o tamanho máximo dos blocos de energia ofertados tal que o resultado do leilão se aproxime do despacho ótimo.

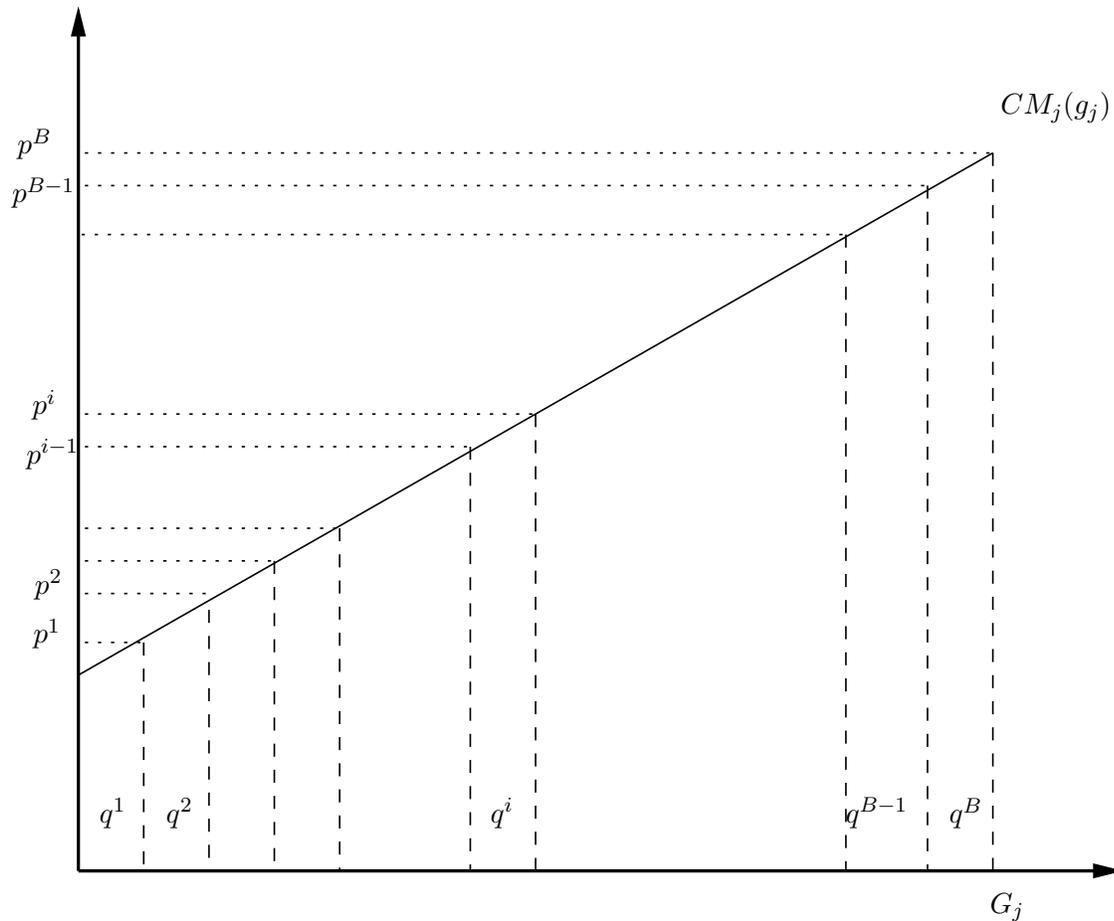


Figura 7.16: Determinação da quantidade e preço de múltiplos lances.

Utilizando o mesmo sistema já detalhado, é reconfigurado um leilão que permite múltiplos lances por agente. A estratégia (ingênua) de cada agente é dividir sua capacidade pelo número máximo B de lances permitidos no leilão. Cada lance i do agente j é então formado por uma quantidade q_j^i e um preço b_j^i , $j = 1, \dots, T$, $i = 1, \dots, B$, onde T é o total de agentes. Não foi encontrado na literatura um tratamento apropriado desta questão porém uma maneira intuitiva de encontrar o preço do lance de cada bloco é através da curva de custo marginal. Então temos cada lance formado pelo par $(q_j^i; b_j^i)$ onde

$$q_j^i = \frac{G_j}{B}$$

sendo G_j a capacidade do agente j , e

$$b_j^i = CM_j \left(\sum_{k=1}^i q_j^k \right),$$

sendo

$$CM_j(g_j) = \frac{dC_j(g_j)}{g_j}$$

o custo marginal do agente j . Ou seja, os lances acompanham a curva de custo marginal do agente onde cada bloco representa um custo incremental segundo seu custo marginal. A Figura 7.16 ilustra este procedimento.

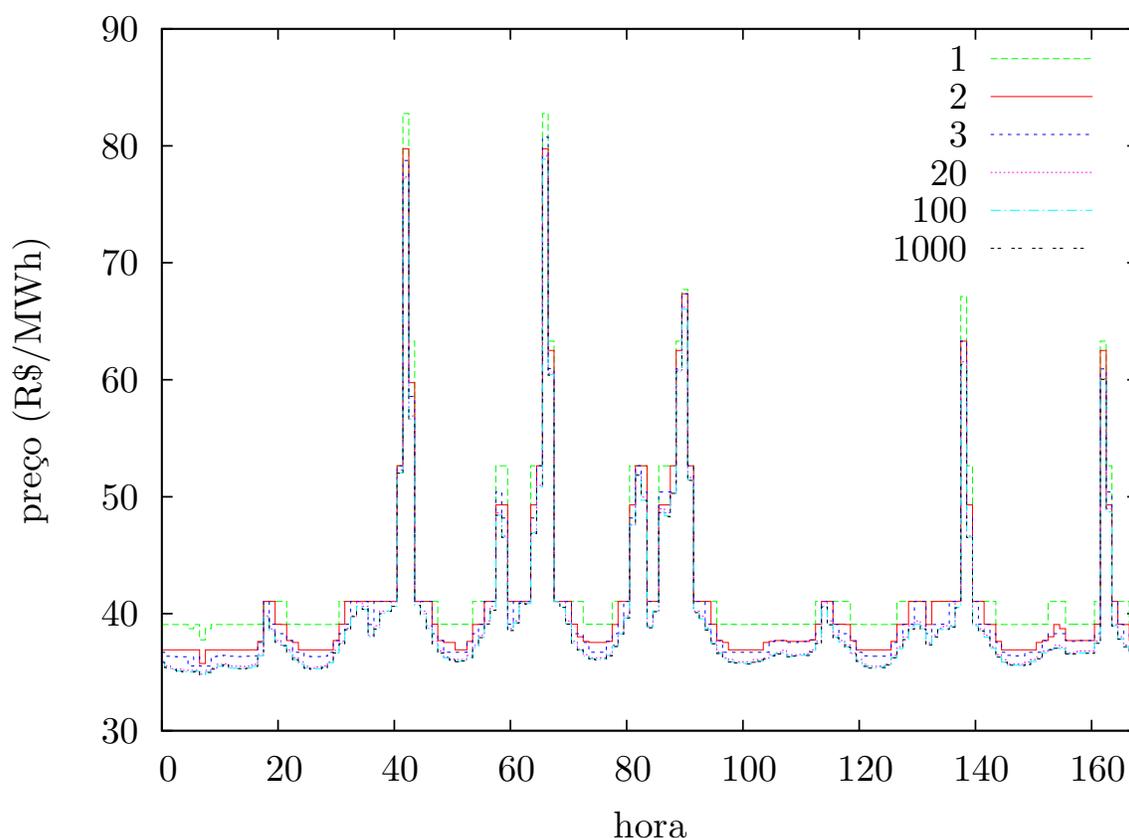


Figura 7.17: Variação do preço segundo número de lances por agente.

Procedendo desta maneira, na Figura 7.17 temos o preço da energia segundo o número de lances efetuado por cada agente conservador para o mercado em questão. Observa-se que quanto maior o número de lances, mais o preço tende ao preço *spot* equivalente ao preço obtido no despacho ótimo centralizado. Ou seja, com o aumento do número de lances os preços vão gradativamente diminuindo. Para 2 ou 3 lances observa-se esta diminuição dos preços. Para 20 lances também observa-se uma diminuição dos preços. Já para 100 ou 1.000 lances, praticamente não há diferença de preços em relação ao uso de 20 lances e todas as três curvas tendem ao despacho ótimo e portanto

representam a curva de preços mais baixos na figura. Estes preços ótimos foram verificados através da otimização do sistema não linear equivalente a este mercado no pacote de otimização Lingo (Lindo 2004).

Deste modo, pode ser interessante a utilização de múltiplos lances no leilão de energia ainda que, para o exemplo em questão, isto não resulte em diferenças significativas no preço da energia para estratégias conservadoras. Porém, na oferta estratégica de energia a utilização de múltiplos lances pode mitigar o poder de mercado de alguns agentes, promovendo, portanto, maior competição. A verificação deste comportamento é objeto de pesquisa futura.

Outra questão em aberto quando se utilizam múltiplos lances é a definição de uma estratégia adequada de oferta. Uma possibilidade seria “mimetizar” a curva de oferta através de um sistema nebuloso Takagi-Sugeno-Kang (TSK) (Takagi & Sugeno 1985, Sugeno & Yasukawa 1993). Diferentes abordagens evolutivas existem para o aprendizado de tais sistemas (Delgado, Von Zuben & Gomide 2004, Alcalá, Alcalá-Fdez, Casillas, Cordón & Herrera 2004). Yager (1998) lida com a solução de equilíbrio entre oferta e demanda através de modelos nebulosos (Yager 2000, Yager 1998). Porém este tópico também demanda investigação mais aprofundada.

Uma alternativa ao leilão com oferta composta por múltiplos lances é o leilão horizontal proposto em (Elmaghraby 2005, Elmaghraby & Oren 1999). O leilão horizontal é realizado por períodos de por exemplo 24 horas, ou seja, os lotes horizontais tem 24 horas de largura. Estes períodos podem ser distintos segundo o tipo de demanda (ponta, média ou base⁷), por exemplo com períodos mais longos que 24 horas para a carga de base.

Neste leilão o leiloeiro deve fracionar os lotes de acordo com os custos das usinas termoelétricas. Cada lote deve esgotar a produção de uma usina para o período, resultando em um único ganhador por lote e evitando que este gerador participe nos leilões dos outros lotes. Não fica claro qual seria o efeito de não se conhecer bem os custos dos geradores e criar lotes horizontais de por exemplo 1 MW de demanda.

7.10 Conclusão

Sugerimos uma abordagem evolutiva para desenvolver estratégias de oferta para leilões de energia. O mecanismo de ofertas através de lances é um mecanismo importante para coordenar comportamento e alocação de recursos em ambientes distribuídos. Mercados competitivos de energia elétrica são exemplos de tais sistemas. A abordagem proposta utiliza um sistema genético baseado em regras nebulosas para lidar com imprecisão na informação relacionada ao lance (previsão de demanda) e para modelar a estratégia de oferta.

⁷ *Peak, shoulder ou base.*

Simulações com dados reais mostraram que a abordagem sugerida é capaz de evoluir estratégias de oferta eficientes quando comparadas à estratégia baseada em custos marginais comumente utilizada em mercados de energia. Entretanto algumas questões permanecem a ser investigadas. Por exemplo, nota-se que a estratégia evoluída é adequada à configuração de mercado cuja dinâmica permanece a mesma durante as fases de treinamento e teste. O efeito de mudanças no comportamento dos agentes ou entrada e saída de competidores heterogêneos tem de ser avaliado. Além disso, uma investigação mais aprofundada é necessária para estudar: o número de variáveis de entrada levando em conta outras informações estratégicas na formação do lance (Mattson, Lucarella & Liu 2001).

Capítulo 8

Estratégias de Oferta: Previsão de Preço e Aprendizagem por Reforço

8.1 Aquisição de Informação: Estratégias com Previsão

Com o objetivo de averiguar o efeito da aplicação de uma metodologia de previsão de preço nas estratégias de oferta de energia, é incorporada uma previsão de preço através de redes neurais ao sistema genético baseado em regras nebulosas GFRBS descrito em (Walter & Gomide 2003b, Walter & Gomide 2003a) e detalhado na seção 6.2.

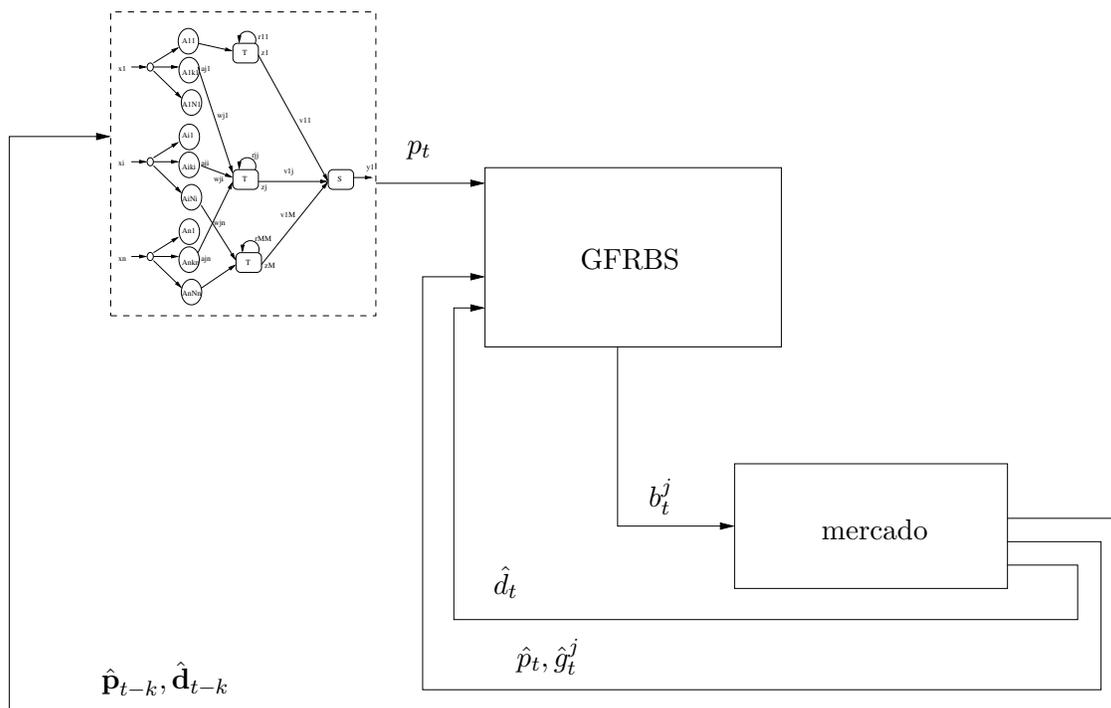


Figura 8.1: Sistema genético baseado em regras nebulosas com previsão de preços.

O esquema da Figura 8.1 ilustra o funcionamento do sistema de *bidding* composto de um GFRBS, uma rede neural e um simulador do mercado de energia. Na figura, p_t é a previsão de preço, saída da rede neural, entrada do GFRBS. \hat{d}_t é a demanda publicamente conhecida fornecida pelo mercado, entrada do GFRBS. O lance b_t^j (*bid*) é um par (quantidade; preço), saída do GFRBS. \hat{p}_t é o preço *spot* no período (hora) t . \hat{g}_t^j o despacho ou a quantidade de energia gerada pelo agente j no período t . O agente conhece o preço *spot* e quantidade de energia gerada somente após realizar o lance, estes são resultados do processo de oferta no leilão. $\hat{\mathbf{p}}_{t-k}$ e $\hat{\mathbf{d}}_{t-k}$ são os vetores de preço e demanda defasados em k . Estes servem de entrada à rede.

Temos então como entradas da rede neural: $\hat{\mathbf{p}}_{t-k}$ e $\hat{\mathbf{d}}_{t-k}$, saída da rede neural: p_t , entradas do GFRBS: p_t e \hat{d}_t , saída do GFRBS: b_t^j , *feedback* do mercado ao GFRBS após a realização do leilão: \hat{p}_t e \hat{g}_t^j .

Os dados de demanda e preços são separados em 3 conjuntos (períodos): dados de treinamento da rede, dados de treinamento do sistema genético baseado em regras nebulosas, e dados de teste. A rede neural é treinada com os dados de treinamento da rede onde os preços são obtidos considerando-se todos os agentes conservadores.

Em seguida a rede é utilizada em modo *feedforward* para prover ao sistema genético baseado em regras nebulosas a previsão de preço no período t em que se deseja ofertar energia. Além da previsão de preço é fornecida ao GFRBS a demanda no período em questão. O GFRBS tem como saída um par (quantidade; preço) que é utilizado no leilão de energia. O resultado da estratégia de oferta codificada no GFRBS é utilizado no mercado durante o período de treinamento do GFRBS e o lucro obtido no período utilizado como *fitness* para evoluir esta estratégia. O GFRBS evolui então durante um determinado número de gerações com os dados do período de treinamento do GFRBS. O melhor GFRBS encontrado ao final do processo evolutivo é avaliado no período de testes.

8.1.1 Dados de Treinamento e Teste

A configuração de mercado é a mesma descrita na seção 7.2. Foram utilizados para dados de treinamento da rede neural os dados de demanda e preço correspondentes ao período de 19 de maio de 2002 (domingo) a 7 de setembro de 2002 (sábado), ou seja, 16 semanas. Os dados de treinamento do GFRBS correspondem à semana de 8 a 14 de setembro de 2002. Os dados de teste do sistema correspondem às duas semanas de 15 a 28 de setembro de 2002. Por exemplo, na Figura 8.2 encontram-se os dados das duas primeiras semanas do período de treinamento da rede neural. Na Figura 8.3 os dados de treinamento do GFRBS. Note que os preços na figura são os preços em um mercado conservador enquanto os preços utilizados no treinamento do GFRBS variam de acordo com a evolução de sua própria estratégia de oferta.

Na Figura 8.4 encontra-se a demanda do período de teste e o preço que resultaria de um

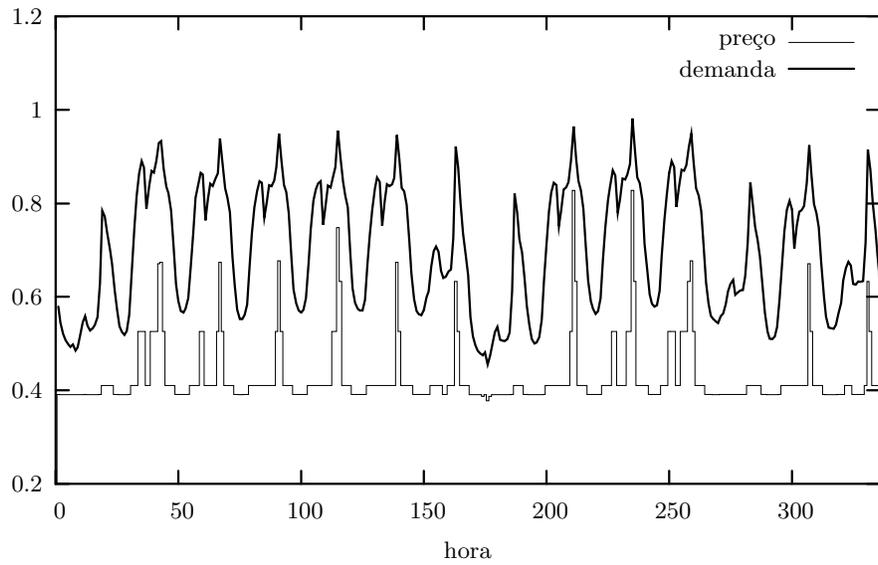


Figura 8.2: Dados de treinamento da rede neural: demanda e preço normalizados.

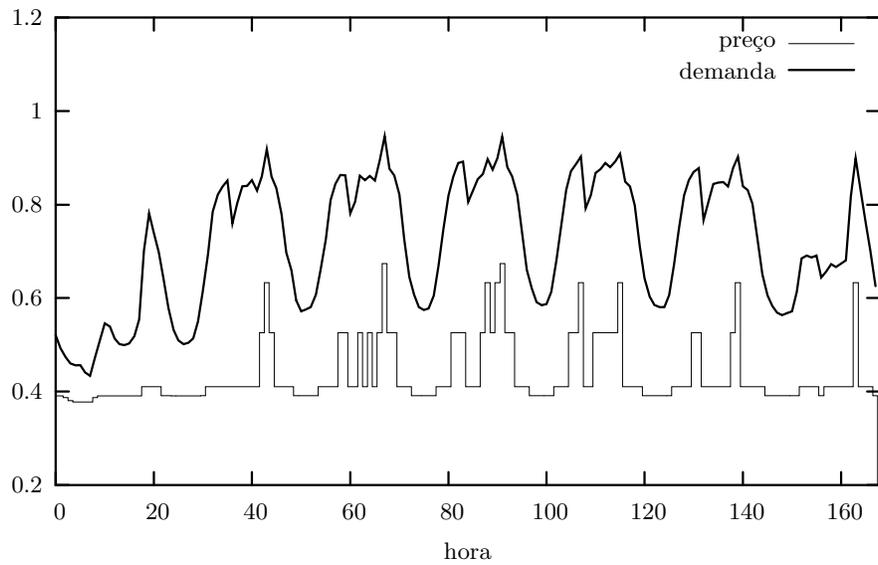


Figura 8.3: Dados de treinamento do GFRBS: demanda e preço normalizados.

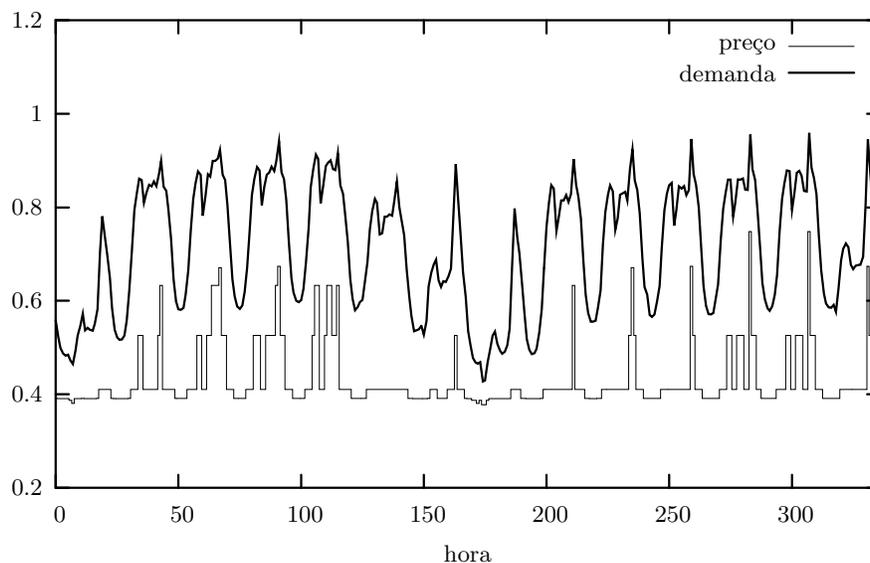


Figura 8.4: Dados de teste do GFRBS: demanda e preço normalizados.

mercado composto apenas de agentes conservadores.

8.1.2 Resultados

8.1.2.1 Rede MLP com 1 Entrada

Inicialmente, é utilizada uma rede neural com uma única entrada que seja capaz de mapear a demanda conhecida a priori em uma previsão de preço de energia. Deste modo temos uma rede MLP 12-3-1 treinada com dados de treinamento como já detalhado. O teste da rede com os dados de treinamento do GFRBS pode ser observado na Figura 8.5 onde o preço corresponde ao preço de um mercado conservador. Observa-se que a previsão não é precisa mas é uma aproximação inicial do preço de mercado.

Erro	médio	máximo
Absoluto	0,009523	0,038463
Quadrático	0,000172	0,001479
Percentual	4,15%	14,02%

Tabela 8.1: Erros resultantes do teste da rede MLP 12-3-1 com 1 entrada.

Na Tabela 8.1 encontram-se as estatísticas de erro para o teste desta rede. Nota-se que o erro percentual médio de 4,15% é bastante satisfatório, apesar da rede utilizar apenas uma entrada. O período de teste da rede é o período de treinamento do GFRBS e foram considerados os preços obtidos em um mercado conservador para o teste da rede. Sua utilização efetiva porém se dá com a

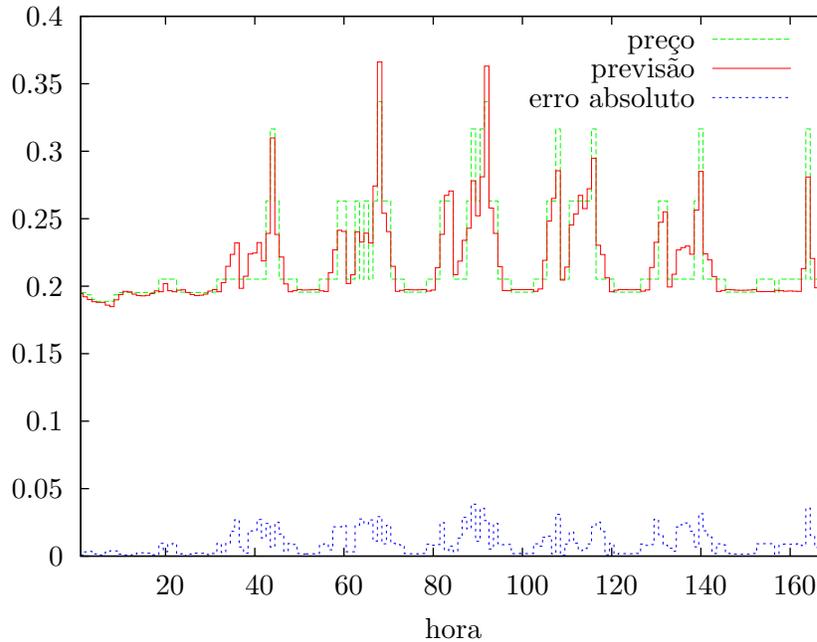


Figura 8.5: Teste da rede MLP com 1 entrada.

estratégia nebulosa evolutiva e portanto os preços previstos pela rede e aqueles obtidos no mercado podem ser bastante diferentes, resultando em piora da performance da rede.

8.1.2.2 Análise da Incorporação da Previsão de Preços

Interessa averiguar se a utilização da previsão de preços resulta em melhor performance do GFRBS, ou seja, se uma estratégia de oferta que utiliza a informação de previsão de preços auferir maior lucro, visto que este é levado em conta na função de *fitness* do agente. Para tal são comparados dois sistemas com os mesmos parâmetros que dirigem o processo evolutivo, um deles com uma única entrada ($N = 1$): demanda. E outro com 2 entradas ($N = 2$): demanda e previsão de preço. Temos para ambos sistemas uma população de 40 indivíduos que sofre evolução durante 300 gerações. A probabilidade de *crossover* é $p_C = 0,5$ e a probabilidade de mutação é $p_M = 0,01$. É utilizado o modelo hierárquico descrito em (Walter & Gomide 2003b, Walter & Gomide 2007). Neste modelo o número de bases de regra utilizado é $R = 4$. São utilizados multiplicadores do preço e da quantidade ofertada como saída, temos portanto duas saídas, ou seja, $M = 2$. O universo de discurso destes multiplicadores é $[0, 5]$ para o preço e $[0, 1, 2]$ para a quantidade. Na defuzzificação do preço e da quantidade ofertada procede-se como detalhado na seção 6.3 onde o limite superior da quantidade do lance é a capacidade do agente. São utilizadas no máximo nove conjuntos nebulosos trapezoidais para particionar cada variável. No modelo que incorpora a rede neural é utilizada a rede neural MLP 12-3-1 com uma entrada treinada durante 10.000 épocas cujos testes foram

apresentados anteriormente.

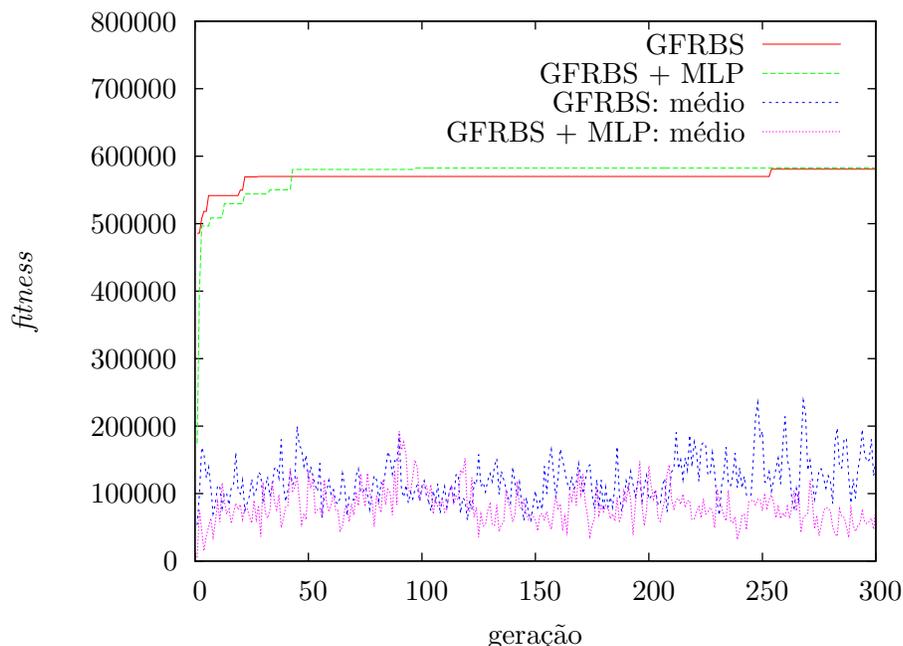


Figura 8.6: Evolução do *fitness*.

Primeiramente na Figura 8.6 pode ser observado a evolução do *fitness* do melhor indivíduo e a evolução do *fitness* médio da população para ambos os sistemas, o GFRBS com uma entrada, denotado simplesmente por “GFRBS”, e o GFRBS com 2 entradas sendo uma entrada a saída da rede MLP que denotaremos por “GFRBS+MLP”. Observa-se que o *fitness* do melhor indivíduo evolui um pouco mais rapidamente para o “GFRBS+MLP” e estabiliza em um valor ligeiramente maior. Porém o *fitness* médio é instável para ambos os sistemas e pode se dizer que o *fitness* médio do “GFRBS” ao final das 300 gerações é maior do que para o “GFRBS+MLP”. Em termos de *fitness* não notamos então grandes diferenças entre os sistemas com ou sem a incorporação da previsão de preços.

Como em termos de *fitness* não temos discrepâncias, o resultado que nos interessa realmente é a comparação dos sistemas no período de testes, com dados das duas semanas que vão de 15 a 28 de setembro de 2002. Na Figura 8.7 temos o preço pelo qual é ofertada a energia para ambos os sistemas. Na Figura 8.8 temos a potência despachada para ambos os sistemas no período de teste. Observa-se que a quantidade mínima despachada no sistema “GFRBS + MLP” é pouco acima dos 600 MW e o sistema “GFRBS” às vezes é despachado abaixo deste nível. Porém na maior parte do tempo, o sistema “GFRBS” é despachado a quase 700 MW. Poucas vezes o sistema “GFRBS+MLP” é despachado a um nível maior que “GFRBS”, em geral para potências altas, acima dos 800 MW¹. Na totalidade do período de teste o sistema “GFRBS” produz 230.932,7 MW enquanto o sistema

¹Note que a capacidade do agente Argentina II é de 1.000 MW.

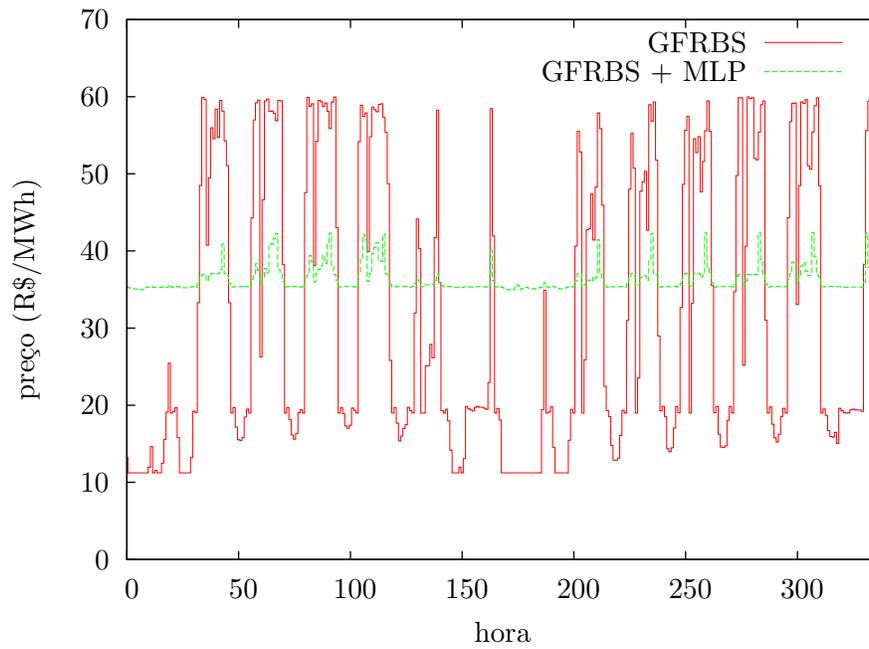


Figura 8.7: Preço de oferta da energia no período de teste.

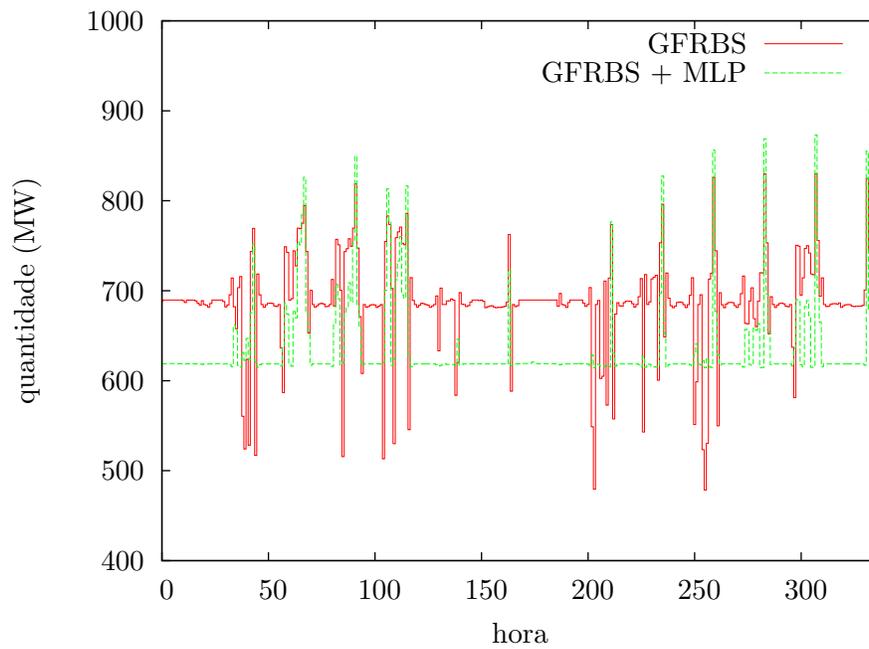


Figura 8.8: Potência despachada no período de teste.

“GFRBS + MLP” produz 213.729 MW, um decréscimo de 7,45%. Ou seja, a área da curva de potência despachada no período de teste para o sistema “GFRBS+MLP” é menor.

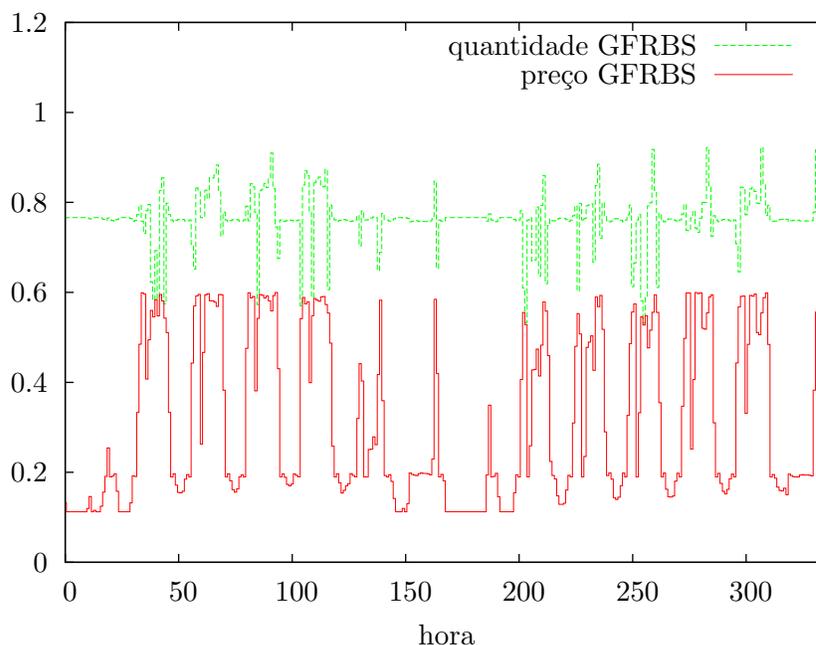


Figura 8.9: Preço de oferta e potência despachada “GFRBS”.

Nas Figuras 8.10 e 8.9 observa-se como a quantidade despachada se relaciona com o preço do lance de oferta². Nota-se que o sistema “GFRBS” faz ofertas demasiadamente altas que podem resultar em menor quantidade despachada. Já o sistema “GFRBS+MLP” consegue obter potências despachadas maiores com um pequeno aumento de preço. Um exemplo deste comportamento é o que ocorre na hora 21 para os dados do segundo dia de teste, 16 de setembro de 2002. Nesta hora o sistema “GFRBS” é o gerador marginal e tem 517 MW despachados a R\$54,27/MWh o que lhe proporciona uma receita de R\$28.060, e, com custos de R\$22.429, lucro de R\$5.631. Já o sistema “GFRBS+MLP” realiza um lance de oferta de 620,9 MW a R\$37,07/MWh e tem esta quantidade despachada na sua totalidade visto que o gerador marginal é J. Lacerda C a um preço *spot* de R\$52,64. O sistema “GRFBS + MLP” auferiu receita de R\$32.684 e descontados o custo de R\$26.325 realiza lucro de R\$6.360, cerca de 13% maior em relação ao sistema GFRBS sem rede MLP para esta hora.

Nas Figuras 8.11 e 8.12 encontram-se respectivamente os preços de oferta e *spot* para o “GFRBS”, e para o “GFRBS+MLP”. Observa-se na Figura 8.12 que o preço do lance de oferta do “GFRBS+MLP” é sempre menor que o preço *spot*, ou seja, este nunca é o gerador marginal. Já para o “GFRBS” (Figura 8.11) às vezes o preço do lance de oferta equivale ao preço *spot* da energia,

²Os preços foram normalizados de forma tal que um preço de R\$100/MWh equivale a 1, já a quantidade de potência despachada foi normalizada em 900 MW.

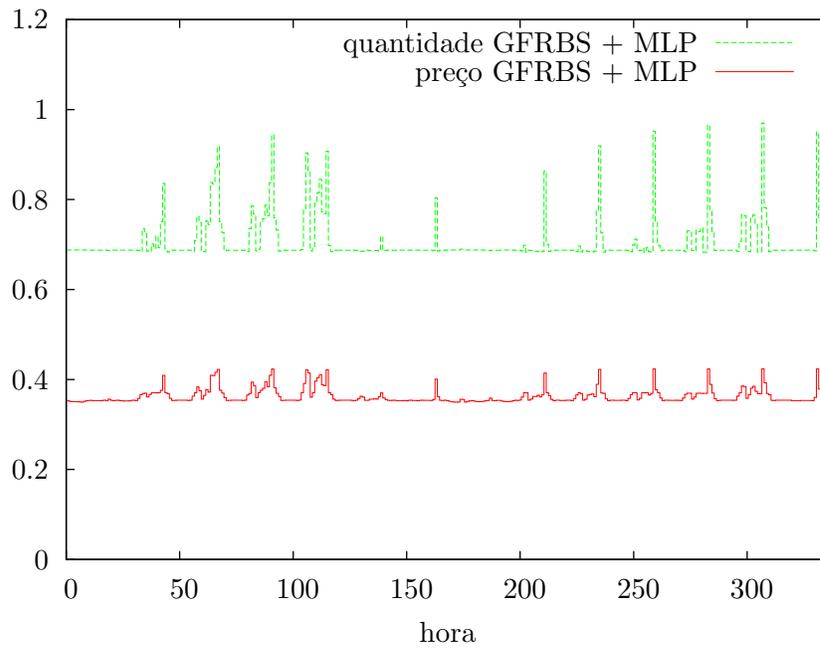
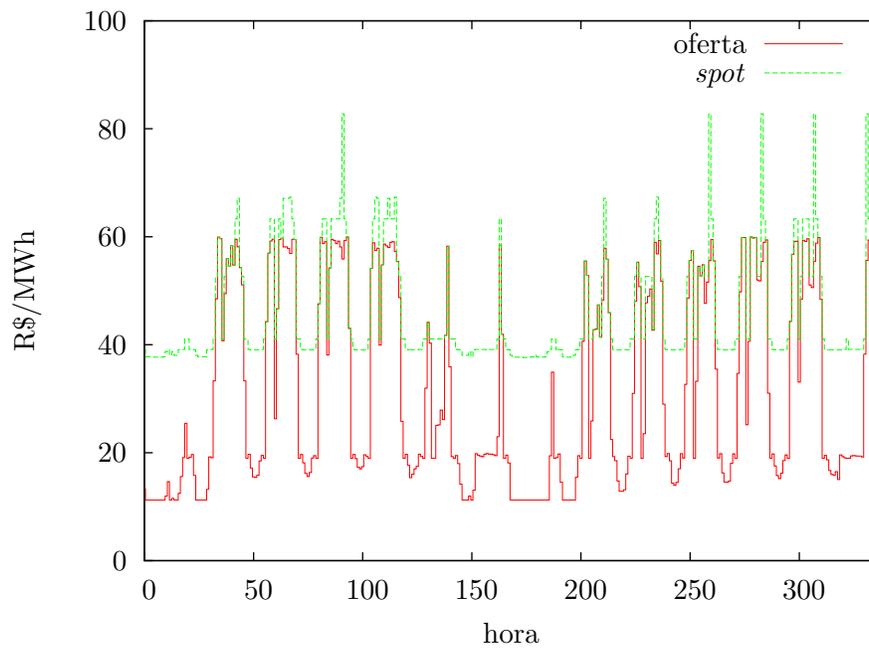
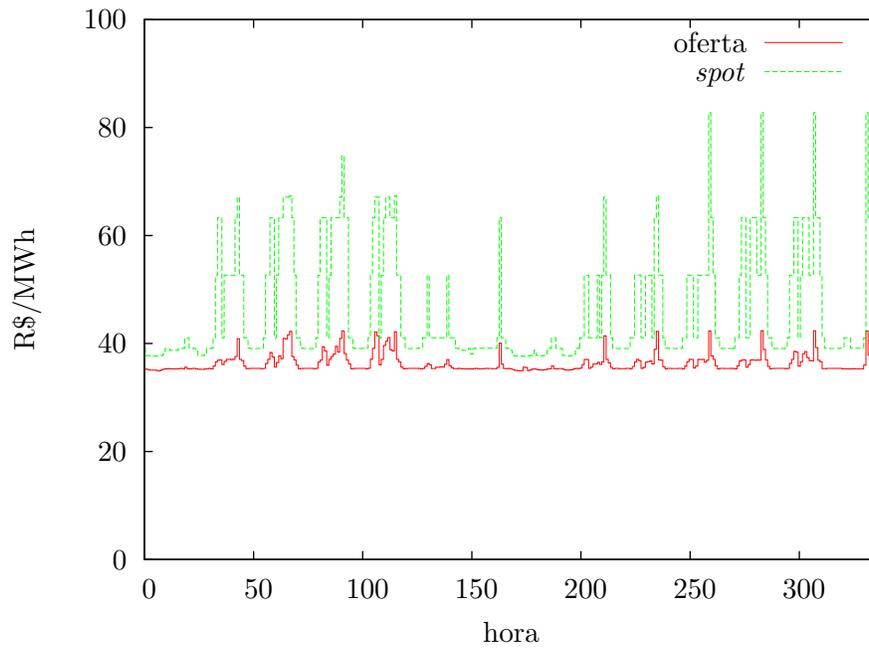
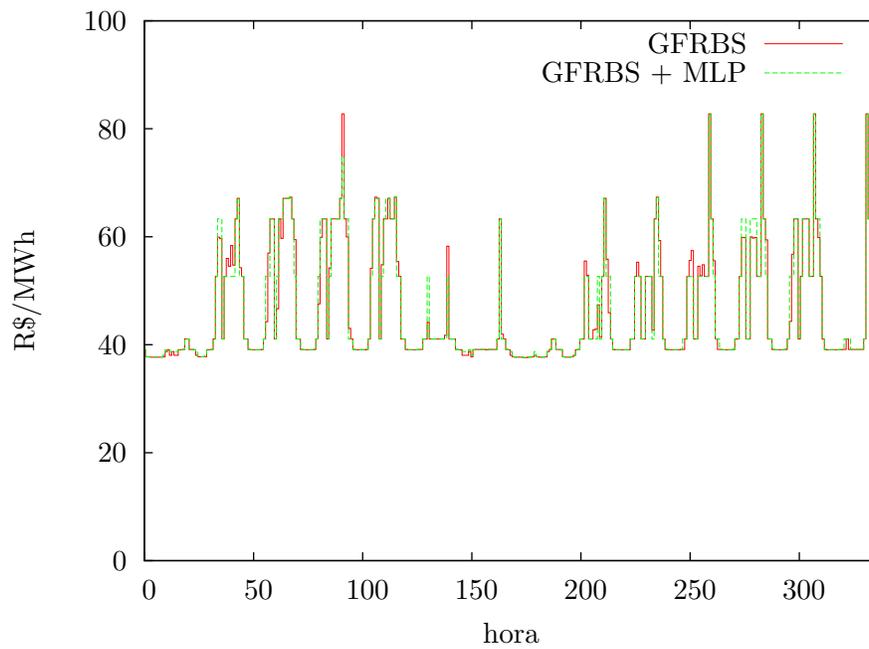


Figura 8.10: Preço de oferta e potência despachada “GFRBS+MLP”.

Figura 8.11: Preço *spot* e de oferta “GFRBS”.

Figura 8.12: Preço *spot* e de oferta “GFRBS+MLP”.Figura 8.13: Preço *spot* no período de teste.

ou seja, às vezes o sistema “GFRBS” é o gerador marginal. Na Figura 8.13 encontra-se o preço *spot* para ambos os sistemas. Observa-se que raras vezes o preço *spot* para o “GFRBS” é mais alto que o preço *spot* que resulta de um mercado com o “GFRBS+MLP”. Em geral pode se dizer que o preço *spot* praticamente não varia com a adoção ou não da rede MLP. Em outras palavras, a previsão de preços parece não influenciar os preços da energia.

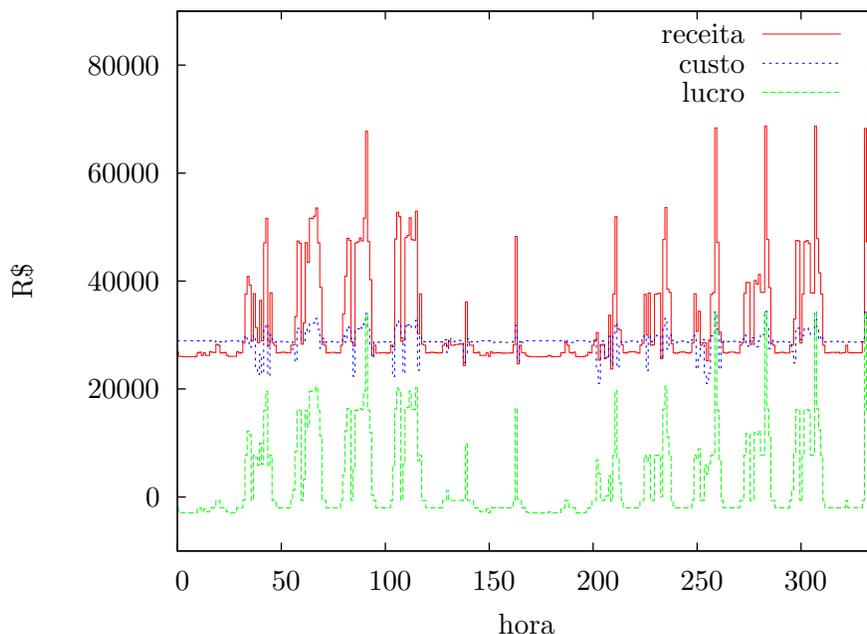


Figura 8.14: Receita, custo e lucro “GFRBS”.

Nas Figuras 8.14 e 8.15 encontram-se a receita, os custos e o lucro obtidos no período de testes para cada um dos sistemas, “GFRBS” e “GFRBS+MLP” respectivamente. Observa-se como a curva de lucro acompanha o perfil da receita visto que as variações de custos não são enormes.

Nas Figuras 8.16, 8.17 e 8.18 temos respectivamente uma comparação da receita, dos custos e do lucro, obtidos por cada um dos sistemas, com e sem a rede MLP. Observa-se que o sistema “GFRBS” auferir maior receita mas tem custos maiores e isto resulta em um lucro ligeiramente maior.

No total para o período o agente “GFRBS” auferir receita de R\$ 10.659.065, com custos de R\$ 9.700.276 resultando em lucro de R\$ 958.789. Já o agente “GFRBS+MLP” realiza R\$ 9.948.410 (-6,67%), com custos de R\$ 9.041.555 (-6,79%) resultando em lucro de R\$ 906.855 (-5,42%). Porém como a quantidade de energia produzida pelo agente “GFRBS + MLP” é 7,45% menor, enquanto o agente “GFRBS” realiza lucro médio de R\$4,15/MWh, o agente “GFRBS+MLP” percebe um lucro médio de R\$4,24/MWh (+2,17%).

O lucro por potencial de geração instalado φ_j^{cap} é dado pela expressão (8.1) onde H é o

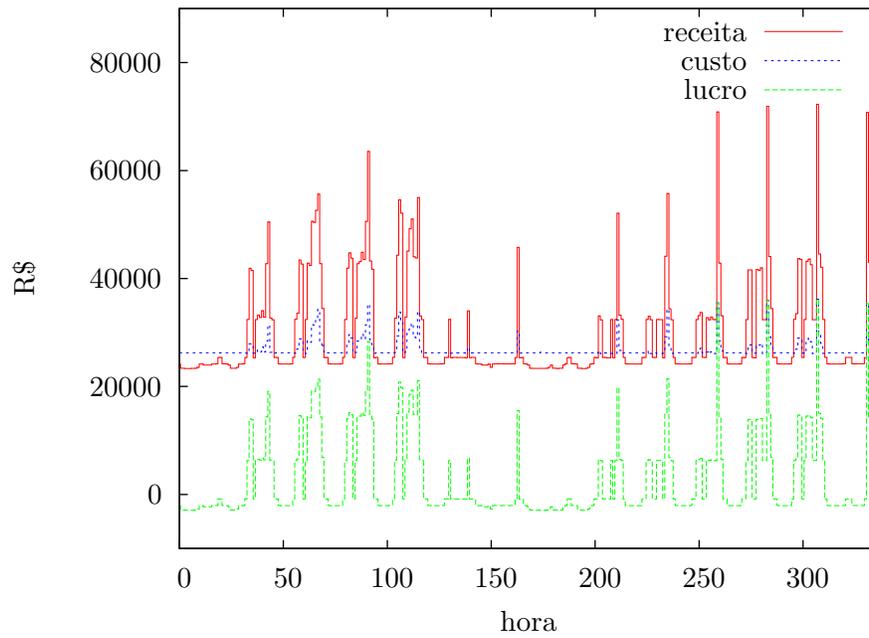


Figura 8.15: Receita, custo e lucro “GFRBS+MLP”.

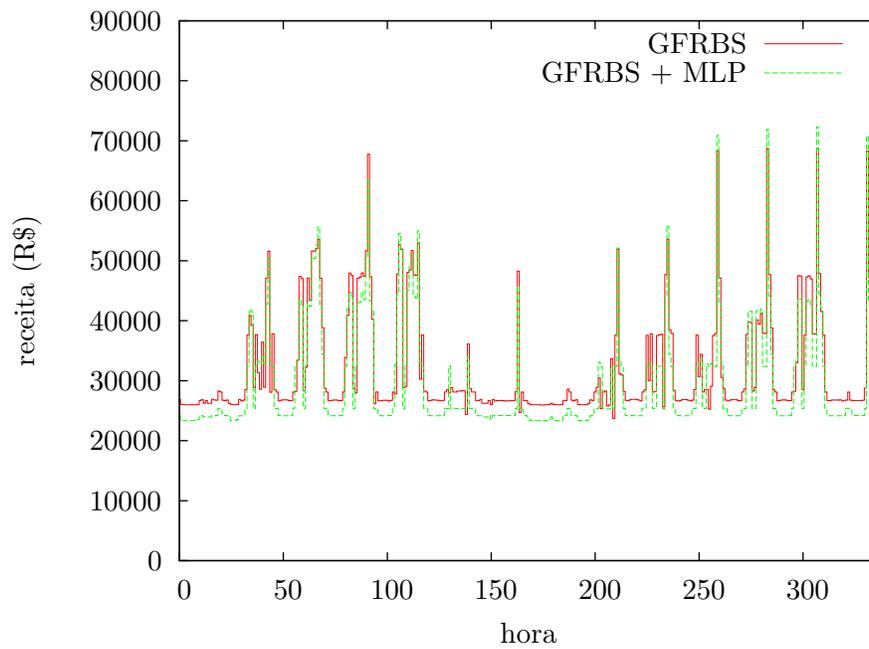


Figura 8.16: Receita “GFRBS” vs. “GFRBS+MLP”.

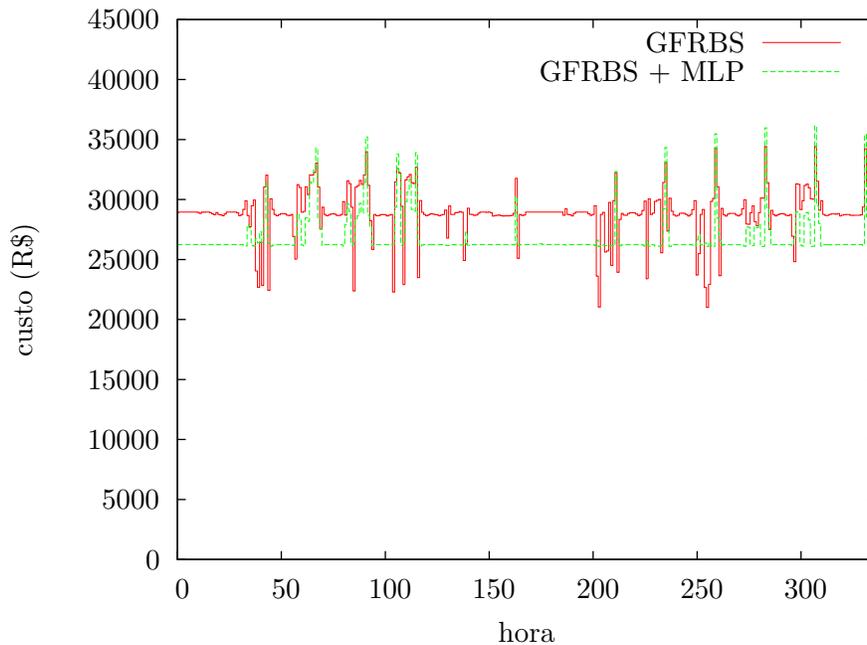


Figura 8.17: Custo “GFRBS” vs. “GFRBS+MLP”.

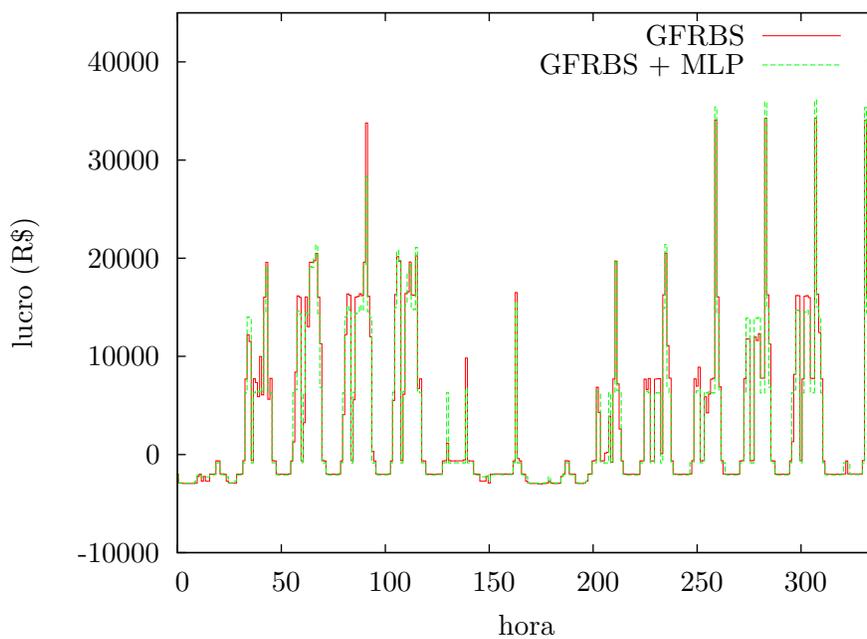


Figura 8.18: Lucro “GFRBS” vs. “GFRBS+MLP”.

número total de horas no período (para o período de teste, $H = 336$), $P_{j,h}$ é o lucro do agente j e G_j sua capacidade instalada. Temos $\wp_{GFRBS}^{cap} = R\$2,85/MWh$ e $\wp_{GFRBS+MLP}^{cap} = R\$2,70/MWh$ (-5,26%). Ou seja, o agente “GFRBS” lucra mais com a mesma capacidade instalada.

$$\wp_j^{cap} = \frac{\sum_{h=1}^H P_{j,h}}{H * G_j} \quad (8.1)$$

8.1.3 Conclusão e Investigação Futura

Podemos concluir que o uso da previsão de preços não resultou em melhora significativa dos resultados econômicos do agente gerador de energia. Resta saber o porquê. Levantamos algumas hipóteses que necessitam de pesquisa mais aprofundada para que uma resposta definitiva seja encontrada:

- A previsão de preços de uma rede MLP tão simples quanto a testada não é boa o suficiente para conferir alguma vantagem competitiva em relação ao agente que não faz previsão de preços. Mais testes com redes neurais mais robustas e com mais entradas precisam ser realizados para comprovar esta hipótese.
- O aumento do espaço de busca com uma nova variável de entrada dificulta a busca de um FRBS eficiente pelo algoritmo evolutivo.
- A configuração de mercado utilizada não permite melhora significativa dos resultados. Uma possível solução a ser experimentada é o reescalonamento da função de *fitness* para torná-la mais sensível a pequenas variações.
- A informação de preço é irrelevante, ao menos para o problema formulado. Esta hipótese é contra-intuitiva e coloca em xeque boa parte da literatura que justifica no valor da informação a busca por melhores mecanismos de previsão de preços de energia. Intuitivamente um agente que conhece os preços pode formar seus lances para garantir que seja despachado se o preço previsto é maior que seus custos marginais. Porém temos de encontrar dados experimentais que comprovem a intuição e possam negar por completo esta hipótese.

8.2 Aprendizagem por Reforço no Leilão de Energia

Esta seção apresenta uma aplicação de agentes com aprendizagem por reforço em um leilão de energia, baseado no exemplo real do “1º Leilão de Energia Existente” realizado no mercado brasileiro em 7 de dezembro de 2004 pela CCEE, Câmara de Comercialização de Energia Elétrica (MAE 2004a). Este é um leilão de compra de energia com um único comprador (o *pool* de concessionárias de distribuição de energia elétrica) e cerca de 20 vendedores, os participantes do leilão.

Trata-se de um leilão de preço descendente com *clock*. Neste estudo é assumida a simplificação de se considerar apenas um único produto ao invés de três produtos como proposto no edital do leilão (MAE 2004c).

A sistemática da primeira fase do leilão detalhada em (MAE 2004b) é delineada de maneira simplificada pelo Algoritmo 3, assumindo-se o ponto de vista do leiloeiro.

Algoritmo 3 Sistemática simplificada do Leilão de Energia Existente.

```

abrir o leilão
 $r \leftarrow 1$ 
 $p_r \leftarrow p_0$  {inicializa preço corrente}
 $B_r \leftarrow \infty$  {inicializa bid total}
while ( $B_r > D$ ) & ( $p_r > p_{min}$ ) do
  comunica  $p_r$  {informa preço corrente}
  while  $t \leq T$  do
    recebe bids  $b_{j,i}$  { $b_{j,i}$ : bid do agente  $j$  na rodada  $i$ }
  end while
   $B_r = \sum_{j=1}^N b_{j,i}$  {agrega bids}
  if  $B_r > D$  then
     $p_{r+1} \leftarrow p_r(1 - \Delta p(D, B_r))$  {aplica decremento}
  end if
   $r \leftarrow r + 1$ 
end while
clearing( $p_r, p_{r-1}, p_{reserva}$ )
fecha leilão

```

O Algoritmo 3 supõe que a demanda $D = \sum_r d_r$ é conhecida a priori pelo leiloeiro. Além disso o leiloeiro define o preço inicial p_0 , o preço de reserva $p_{reserva}$ e os parâmetros da função de decremento. O preço inicial e o preço de reserva são divulgados em um momento próximo ao início do leilão e a função de decremento não é de conhecimento dos participantes do leilão.

A função de decremento pode ser definida como a função $\Delta p(D, B_r)$ e ao multiplicá-la pelo preço corrente obtemos o preço na rodada seguinte. Ou seja, $p_{r+1} = p_r(1 - \Delta p(D, B_r))$. A fim de se obter uma função que independa da demanda e da quantidade ofertada total, mas que capture o efeito de reduzir o *bid* podemos utilizar uma função degrau de decremento relativo σ que toma como entrada B_r/D e tem como saída os valores mostrados no gráfico da Figura 8.19. Ou seja, temos que:

$$\Delta p(D, B_r) = \sigma \left(\frac{B_r}{D} \right)$$

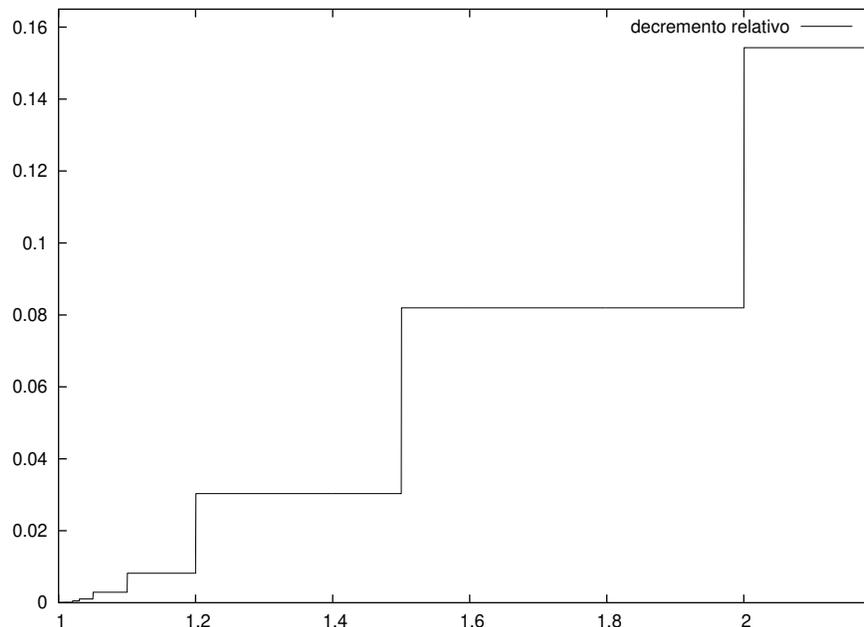


Figura 8.19: Função de decremento relativo σ em função de B_r/D .

8.2.1 Ambiente de Simulação

Alguns trabalhos prévios especificam uma possível arquitetura computacional de simulação de leilões de energia (Lanzotti, Masili, Silva & Correia 2003). O ambiente de simulação implementado pode ser visto como uma versão simplificada desta arquitetura, sem algumas preocupações como as restrições de segurança por exemplo.

Um diagrama de algumas das classes do ambiente de simulação do leilão implementado encontra-se na Figura A.4. Na Figura A.5 encontra-se o diagrama das classes dos agentes vendedores e do agente comprador de energia.

8.2.2 Agentes Inteligentes

No aprendizado das estratégias de oferta aplicamos técnicas de inteligência computacional – que inclui redes neurais, sistemas nebulosos e computação evolutiva – desenvolvendo agentes de software inteligentes (Wooldridge 2002). Estes agentes representam os agentes econômicos que participam no leilão eletrônico de energia.

Em trabalhos anteriores utilizou-se a demanda publicada pelo leiloeiro como entrada de um sistema baseado em regras nebulosas que é projetado automaticamente através de um algoritmo genético (Walter & Gomide 2003b, Walter & Gomide 2003a). O sistema nebuloso resultante representa deste modo uma estratégia de oferta no leilão de energia que leva em conta incertezas nas

Nome	Tipo	Potência	Pot.(%)	Início	Anos	Preço
Paulo Afonso 2	Hidro	443	4,32	1961	43	18,60
Boa Esperança 1-2	Hidro	110	1,07	1970	34	23,53
Paulo Afonso 3	Hidro	794	7,75	1971	33	24,24
Moxotó	Hidro	400	3,90	1977	27	29,63
Paulo Afonso 4	Hidro	2.462,4	24,04	1979	25	32,00
Sobradinho	Hidro	1.050	10,25	1982	22	36,36
Itaparica	Hidro	1.480	14,45	1990	14	57,14
Boa Esperança 3-4	Hidro	127,3	1,24	1991	13	61,54
Xingó	Hidro	3.162	30,86	1994	10	80,00
Camaçari	Gás	216	2,11	2004	0	138,85
Total		10.244,7	100,0			

Tabela 8.2: Dados de geração do agente inteligente CHESF.

entradas, no caso a demanda.

Estamos interessados em utilizar a informação do preço e da variação do preço durante o leilão. Supõe-se que a demanda total não é divulgada pelo leiloeiro e estamos interessados em identificar cenários de competitividade demasiadamente alta ou demasiadamente baixa durante o leilão. Estes cenários podem levar a um resultado do leilão distante do equilíbrio e desvantajoso economicamente.

A competitividade pode ser descrita através da construção da curva de demanda residual em um leilão de compra como o estudado neste trabalho.

8.2.3 Estratégia de Oferta

Uma estratégia de oferta simples e conservadora é implementada através da definição de uma curva de oferta privada com P patamares, através de pares quantidade, preço (qp_j^k, pp_j^k) . Se o preço corrente p_r é maior ou igual ao preço do patamar k aquela quantidade é adicionada ao bid $b_{j,r}$ do agente j . Ou seja,

$$b_{j,r} = \sum_{k=1}^P qp_j^k \mid pp_j^k \leq p_r$$

Assim foi construída uma curva de oferta do agente inteligente com 10 patamares correspondendo às principais usinas da CHESF, tomada como empresa de exemplo de aplicação da metodologia. Foram utilizados os dados da Tabela 8.2 e o agente responde por uma oferta de aproximadamente 11,5% da oferta total de energia de 19999 blocos de 1 \overline{MW} . Este agente teria então lastro de 2.304 \overline{MW} .

Os preços foram obtidos a partir do tempo de amortização das usinas de maneira proporcional aos 10 anos da usina de Xingó cujo preço foi estabelecido arbitrariamente a $\text{R}\$80,00/\overline{MW}$. Assim uma usina com Y anos de amortização tem preço do bloco correspondente a $80\frac{Y}{10}$. Usinas com diferentes entradas de funcionamento das máquinas geradoras foram separadas em diferentes blocos como por exemplo Paulo Afonso e Boa Esperança. O preço médio da energia resultante destes dados é de $\text{R}\$ 52,15/\overline{MW}$. Os blocos de energia e os preços resultantes encontram-se na Tabela 8.3. Observa-se a respectiva curva de oferta na Figura 8.20.

Nome	Quantidade	Acumulado	Preço
Paulo Afonso 2	99	99	18,60
Boa Esperança 1-2	24	123	23,53
Paulo Afonso 3	179	302	24,24
Moxotó	90	392	29,63
Paulo Afonso 4	555	947	32,00
Sobradinho	236	1.183	36,36
Itaparica	333	1.516	57,14
Boa Esperança 3-4	28	1.544	61,54
Xingó	712	2.256	80,00
Camaçari	48	2.304	138,85

Tabela 8.3: Dados de oferta do agente inteligente CHESF.

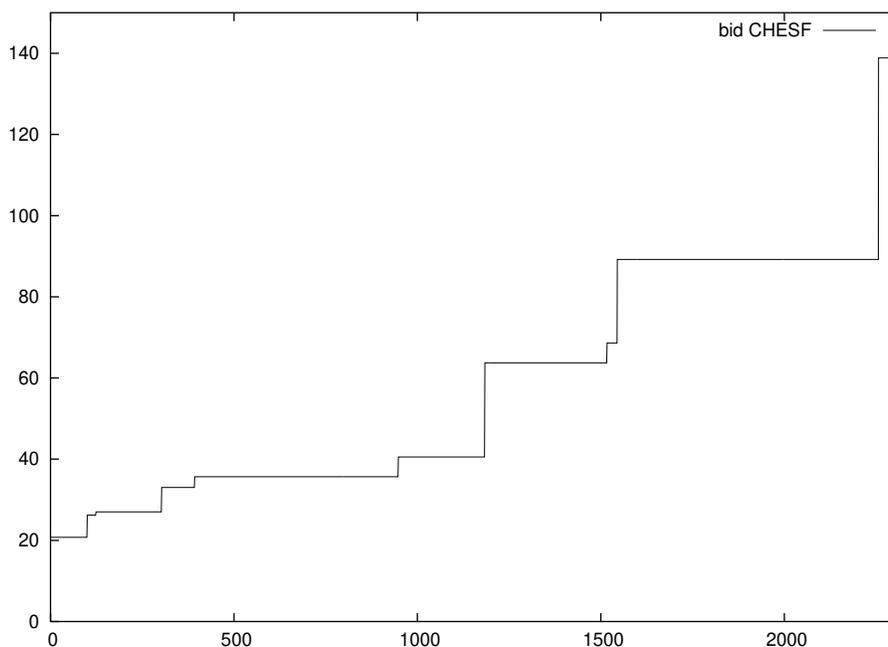


Figura 8.20: Curva de oferta do agente inteligente (em $\text{R}\$/\overline{MW}$).

Todos os agentes competidores deste agente inteligente são agregados em um único agente

Nome	Potência	Pot.(%)	Preço
BREITENER	162,34	0,33	72,06
CDSA	658,00	1,34	72,06
CEC	121,50	0,25	72,06
CEEE	2.187,59	4,44	78,50
CEMIG	6.089,49	12,36	52,50
CERAN	360,00	0,73	72,06
CESP	7.455,30	15,13	78,20
CGTEE	490,00	0,99	78,50
COPEL	4.538,74	9,21	71,00
DUKE	2.299,40	4,67	78,40
ELETRONORTE	6.469,13	13,13	56,20
EMAE	1.393,50	2,83	82,30
ESCELSA	193,49	0,39	72,06
FURNAS	9.388,00	19,05	86,30
LIGHT	976,57	1,98	72,06
TRACTEBEL	6.503,00	13,19	72,20
Total	49.286,06	100,0	

Tabela 8.4: Dados de geração dos agentes competidores.

“adversário” com a capacidade restante, ou seja, $17695 \overline{MW}$. A curva do adversário foi projetada utilizando-se dados de geração da ANEEL (ANEEL 2004), dos vendedores habilitados para o leilão (MAE 2004d) e dos preços dos contratos iniciais (Batista, Haiama & Santo 2004). Os dados dos maiores geradores do sistema tomados como competidores encontram-se na Tabela 8.4. Os dados de oferta encontram-se na Tabela 8.5 aos quais corresponde o preço médio de $R\$72,06/\overline{MW}$. Observa-se a curva de oferta dos competidores na Figura 8.21.

8.2.4 Aprendizado

Tomando a programação neurodinâmica discutida no Apêndice C como paradigma de aprendizado nesta seção procuramos formular um modelo do problema de aprendizado do agente inteligente participando no leilão. Como as variáveis de entrada são contínuas, a modelagem baseada no algoritmo *Q-learning* é proposta para que o agente aprenda uma política sub-ótima, utilizando uma rede neural como aproximador de função ³.

Tomamos o modelo de um único agente discutido na seção C.1 considerando porém que um tratamento mais rigoroso iria requerer uma modelagem multiagentes como descrito na seção 2.3.5, uma vez que o problema de leilão é um jogo de soma não-nula com jogadas simultâneas de múltiplos

³Na seção 6.2.2.1 apresentamos o estado da arte em estratégias de oferta em leilões de energia através da abordagem *Q-learning*.

Nome	Quantidade	Acumulado	Preço
CEMIG	2.186	2.186	52,50
ELETRONORTE	2.323	4.509	56,20
COPEL	1.629	6.138	71,00
TEC	0	6.138	72,06
CEC	43	6.181	72,06
BREITENER	58	6.239	72,06
ESCELSA	69	6.308	72,06
CERAN	129	6.437	72,06
CDSA	236	6.673	72,06
LIGHT	350	7.023	72,06
TRACTEBEL	2.335	9.358	72,20
CESP	2.677	12.035	78,20
DUKE	825	12.860	78,40
CGTEE	175	13.035	78,50
CEEE	785	13.820	78,50
EMAE	500	14.320	82,30
FURNAS	3.371	17.691	86,30

Tabela 8.5: Dados de oferta dos agentes competidores.

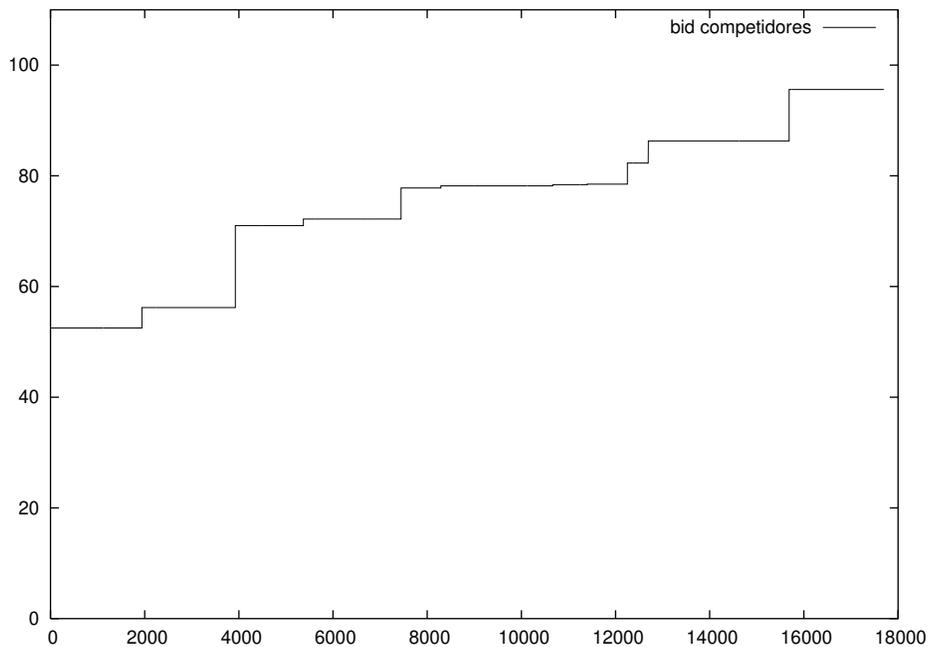


Figura 8.21: Curva de oferta dos competidores.

jogadores. Devido aos problemas em aberto que esta modelagem multiagentes do aprendizado apresenta, trataremos de modelar o problema supondo um único agente inteligente atuando no sistema e seus competidores modelados de modo implícito como parte do modelo do ambiente.

Definimos então o estado do sistema como o preço corrente p_r . A ação do agente é o bid (quantidade) $b_{j,r}$ tal que $b_{j,r} \leq b_{j,r-1}$. Como as quantidades são inteiros representando o número de blocos de $1 \overline{MW}$, o número de ações admissíveis é finito porém relativamente grande. Além disso o estado (preço corrente) deve ser discretizado de maneira conveniente (e.g. em 10 centavos da unidade monetária) o que levaria a um número razoavelmente grande de estados possíveis. Considerando por exemplo um preço inicial de aproximadamente R\$100,00 e um preço mínimo de R\$18,60 teríamos 814 possíveis estados (preços).

O problema em questão é um problema de horizonte finito porém o número de estágios K não é conhecido a priori. Outra característica que poderia representar uma dificuldade durante o aprendizado é a inexistência do custo imediato (recompensa). O agente percebe um benefício somente ao final do processo. Porém de acordo com exemplo de (Mitchell 1997) é possível tratar o problema com recompensa nula. Se chamarmos de I a iteração onde o Algoritmo 3 que descreve o leilão converge para um preço final, o objetivo do agente j pode ser descrito como:

$$\max b_{j,R-1} p_R \quad (8.2)$$

Ou seja, modelando como um problema de otimização temos para o agente j :

$$\max_{\mathbf{b}_j} b_{j,R-1} p_R \quad (8.3)$$

s.a

$$b_{j,r+1} \leq b_{j,r} \quad r = 1, \dots, R-2$$

$$\underline{b}_j \leq b_{j,r} \leq \bar{b}_j \quad r = 1, \dots, R-2$$

Uma opção para modelar uma recompensa (ou custo) em cada estágio de decisão seria considerar o bid corrente multiplicado pela variação de preço como uma perda incorrida pelo agente. Ainda que na realidade isto não ocorre esta seria uma maneira indireta de indicar ao agente a perda de oportunidade conforme o preço decresce. Assim teríamos o custo $g_n(i_n, a_n, j_n) = b_{j,r} \Delta p(D, B_r)$ onde o estado corrente é $i_n = p_r$, a ação admissível é o bid $a_n = b_{j,r}$ e o estado sucessivo $j_n = p_{r+1}$. É possível atribuir um peso a este custo para torná-lo menos importante em relação ao benefício no último estágio.

8.2.5 Resultados

Com o objetivo de analisar a factibilidade de se inferir a curva de demanda residual a partir do preço corrente p_r projetou-se uma rede neural cujas entradas normalizadas são o bid do agente inteligente e a variação de preço $\Delta p = p_r - p_{r-1}$.

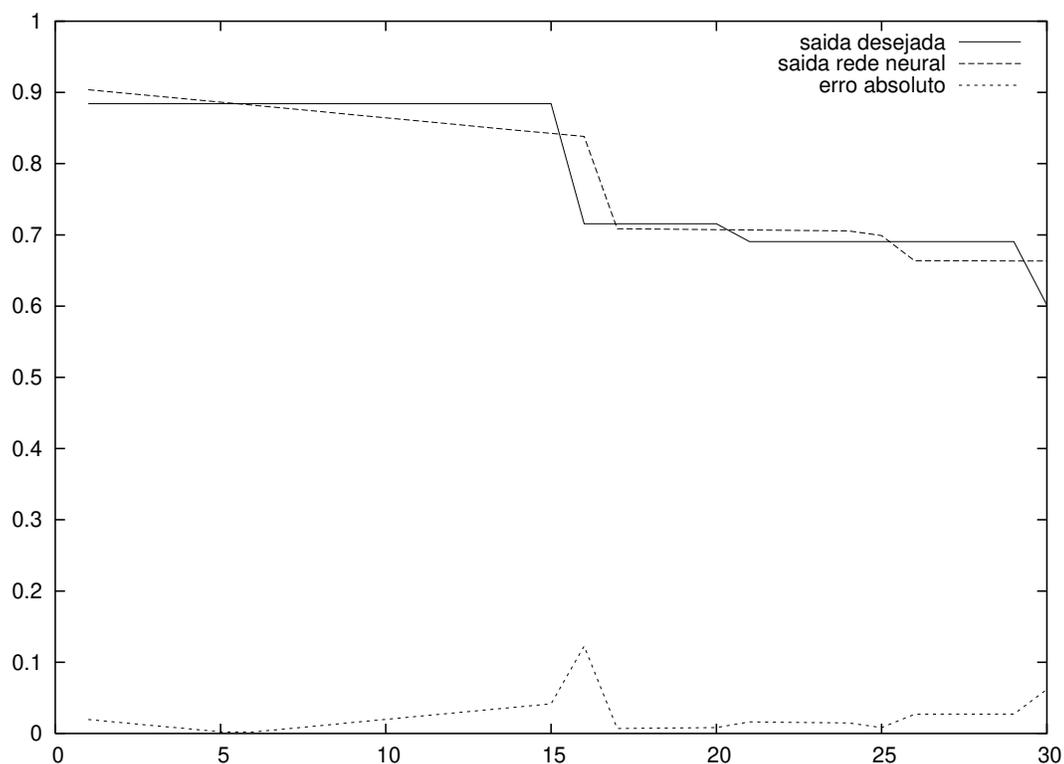


Figura 8.22: Saída da rede MLP, entradas: *bid* e variação de preço, saída: *bid* competidor.

Utilizando uma rede neural MLP (*multi layer perceptron*) com 8 neurônios sigmoidais de entrada, 3 do mesmo tipo na camada intermediária e 1 neurônio linear na camada de saída, com taxa de aprendizado de 0,01 e momento de 0,002, após 10.000 décadas de treinamento foi obtida a saída que se encontra na Figura 8.22, com erro percentual médio de 2,96%.

Podemos concluir que a variação de preço traz informação a respeito do bid dos competidores. Porém é inverossímil imaginar que o bid dos competidores (saída desejada da rede) estaria disponível para treinamento da rede. Além disso deve-se observar que devido à escassez de dados a rede foi testada no mesmo conjunto de dados de treinamento.

8.2.6 Conclusão

A abordagem de programação neurodinâmica se mostra adequada na modelagem do aprendizado de agentes no leilão de energia. É necessário tratar o problema da modelagem multiagentes através do jogo que se estabelece entre os participantes.

Como apontado em (Walter, Takahashi, Correia & Gomide 2006), conjecturamos que uma rede neural é capaz de extrair informação dos preços das rodadas anteriores do leilão para prever o preço da próxima rodada. Como utilizar esta previsão é uma questão em aberto que procuramos responder na seção 8.1.

8.2.7 Pesquisa Futura

Fica indicado como tópico de pesquisa futura a extensão da metodologia de aprendizado baseada em *Q-learning* para um leilão simultâneo de múltiplos produtos como aqueles realizados no mercado brasileiro. E também a implementação do algoritmo de *Q-learning* sugerido para os leilões de energia.

Capítulo 9

Conclusão

Sugerimos uma abordagem evolutiva baseada em sistemas genéticos *fuzzy* (GFS) para desenvolver estratégias de oferta em leilões no contexto de sistemas multiagentes. O mecanismo de ofertas através de lances é um mecanismo importante para coordenar comportamento e alocar recursos em ambientes multiagentes. Mercados competitivos de energia elétrica são exemplos típicos de sistemas multiagentes onde coordenação e alocação de recursos são essenciais para caracterizar comportamentos.

A abordagem proposta utiliza um sistema genético baseado em regras nebulosas (GFRBS) para lidar com imprecisão na informação relacionada ao lance e evolui um sistema baseado em regras nebulosas (FRBS) para modelar a estratégia de oferta. Sugerimos um esquema de GFRBS que evolui simultaneamente as partes constituintes da base de conhecimento: a base de dados e a base de regras. Introduzimos um cromossomo de tamanho variável para codificar a base de conhecimento e um operador de *crossover* da base de regras. A codificação sugerida permite uma estrutura hierárquica onde há mais de uma base de regras para cada indivíduo, induzindo uma relação entre a base de dados e as bases de regras através do *fitness*.

Os mercados de energia elétrica são considerados como um domínio de aplicação uma vez que são uma instância de sistemas multiagentes de inquestionável importância. Simulações computacionais com dados reais atestam que a abordagem sugerida é capaz de evoluir estratégias de oferta eficientes quando comparadas à estratégia baseada em custos marginais. A estratégia baseada em GFRBS ajuda a revelar comportamento emergente dos agentes previamente desconhecidos. Entretanto algumas questões permanecem a ser esclarecidas. Uma investigação mais aprofundada é necessária para estudar o número de variáveis de entrada levando em conta outras informações estratégicas na formação do lance e mercados heterogêneos. Por exemplo, nota-se que a estratégia obtida é adequada à configuração de mercado cuja dinâmica permanece a mesma durante as fases de treinamento e teste. O efeito de mudanças no comportamento dos agentes ou entrada e saída de competidores tem de ser avaliado. Neste sentido está em curso de desenvolvimento uma extensão

coevolutiva da abordagem sugerida onde poderemos avaliar o impacto da evolução simultânea de estratégias inteligentes no comportamento dos agentes e no comportamento emergente do sistema.

Apresentamos uma arquitetura multiagentes suficientemente genérica que permite a simulação de diferentes estruturas de mercado constituindo uma ferramenta de análise e apoio à tomada de decisão nestes ambientes. Trata-se de uma abordagem baseada em Sistemas Multiagentes onde os agentes de *software* que representam agentes econômicos com interesse próprio constituem um mercado artificial que pode ser simulado para enriquecer a análise e o projeto de estruturas alternativas de um mercado real. A arquitetura sugerida é discutida e é apresentada a implementação em Java de um protótipo do mercado de energia elétrica baseado na plataforma FIPA-OS. A partir dos resultados obtidos e de evidências encontradas na literatura concluímos que a abordagem multiagentes é factível e relevante na modelagem de uma economia complexa e intrinsecamente composta de múltiplos agentes econômicos como é o caso do mercado de energia elétrica. A modelagem multiagentes captura comportamentos (e.g. adaptativo), auxilia no estudo do comportamento emergente (e.g. tendências de preço) e serve como ferramenta de análise e projeto do mecanismo de mercado e de suporte à tomada de decisão.

Quanto a abordagem baseada na programação neurodinâmica sugerida na seção 8.2 podemos dizer que esta se mostra adequada na modelagem do aprendizado de agentes no leilão de energia e que a aprendizagem de máquina é útil para estressar um mecanismo de leilão. Porém para enriquecer o modelo baseado em *Q-learning* apresentado é necessário tratar o problema multiagentes através do jogo que se estabelece entre os participantes. Evidenciamos que uma rede neural é capaz de extrair informação comumente disponível nos leilões de energia. Permanece uma questão em aberto: como tomar vantagem desta previsão?

Sistemas multiagentes ajudam a endereçar descentralização intrínseca de sistemas distribuídos onde há múltiplos pontos de controle, sistemas que podem ser modelados, analisados, projetados e utilizados sob múltiplas perspectivas e por agentes com interesses que podem ser competitivos. A Computação baseada em Agentes fornece modelos para se especificar e se compreender os sistemas multiagentes. Já a Engenharia de *Software* Orientada a Agentes fornece ferramentas e metodologias necessárias à implementação de sistemas multiagentes. A Inteligência Computacional por sua vez ajuda a estabelecer o comportamento dos agentes através de mecanismos de aprendizagem apropriados, a lidar com incertezas, a modelar uma representação do conhecimento e ao raciocínio aproximado (*approximate reasoning*).

A principal e mais consistente contribuição deste trabalho é sugerir uma metodologia baseada em sistemas *fuzzy* genéticos como abordagem no projeto de estratégias de oferta em leilões, utilizando os leilões de energia elétrica como exemplo de aplicação e experimentação. Propomos uma arquitetura multiagentes para simulação de mercados, em especial os de energia elétrica. Sistematizamos a modelagem de sistemas distribuídos como os mercados de energia através da abordagem

baseada em Sistemas Multiagentes utilizando a Inteligência Computacional como ferramenta de concepção das estratégias de coordenação dos agentes.

9.1 Perspectivas Futuras

Como perspectivas futuras visualizamos:

1. Aumentar o número de variáveis de entrada na estratégia de oferta baseada em sistemas *fuzzy* genéticos levando em conta um número maior de informações para decidir a melhor estratégia.
2. Considerar variáveis de estado no GFRBS.
3. Considerar a contratação bilateral na estratégia de oferta.
4. Tratar com maior propriedade o aspecto hídrico do mercado de energia levando em conta a previsão de vazões e o planejamento energético nas estratégias de oferta.
5. Levar em conta restrições elétricas na simulação do mercado de energia.
6. Estabelecer um ambiente de competição computacional mais heterogêneo composto por agentes inteligentes mais diversificados.
7. Estudar e implementar a coevolução de estratégias de oferta.
8. Projetar um agente adaptativo que seja capaz de absorver mudanças estruturais no mercado.
9. Implementar o projeto automatizado do mecanismo de mercado baseado na literatura como discutido na seção 3.9.1 utilizando a evolução de arquiteturas de mercado como abordagem de projeto dos mecanismos de negociação. Deste modo pretendemos considerar o uso de mecanismos multi-objetivos de apoio à tomada de decisão para analisar o comportamento emergente e o resultado de estruturas alternativas de mercado, procurando tratar adequadamente a questão do *design* de mercados. Esta é uma questão essencial em aberto no projeto de sistemas multiagentes.
10. Implementar e estudar a coevolução hierárquica do mecanismo de mercado e das estratégias de oferta.
11. Generalizar a abordagem baseada em sistemas *fuzzy* genéticos no projeto de estratégias de oferta em leilões de energia para leilões em geral.

Apêndice A

Diagramas de Classes UML

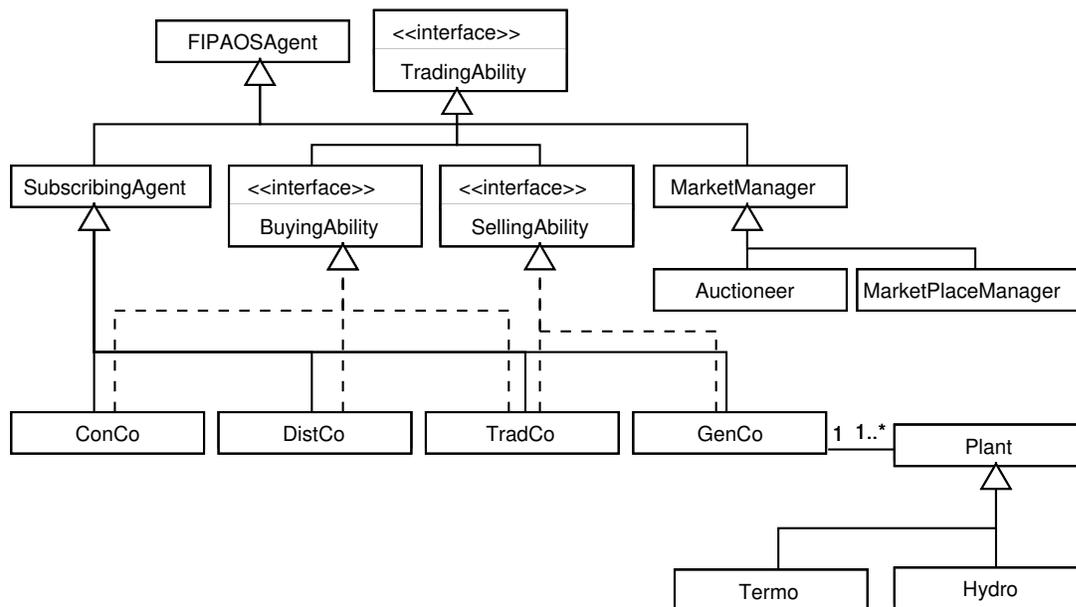


Figura A.1: Diagrama de classes do protótipo AEMAS em FIPA-OS.

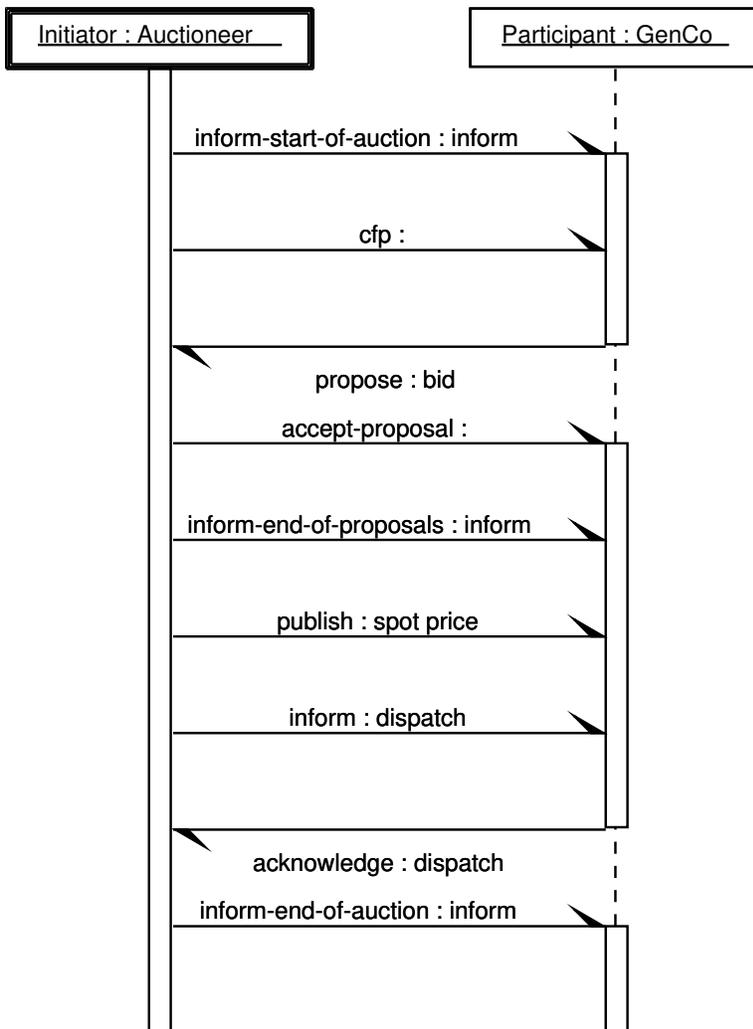


Figura A.2: Protocolo de iterações no leilão fechado.

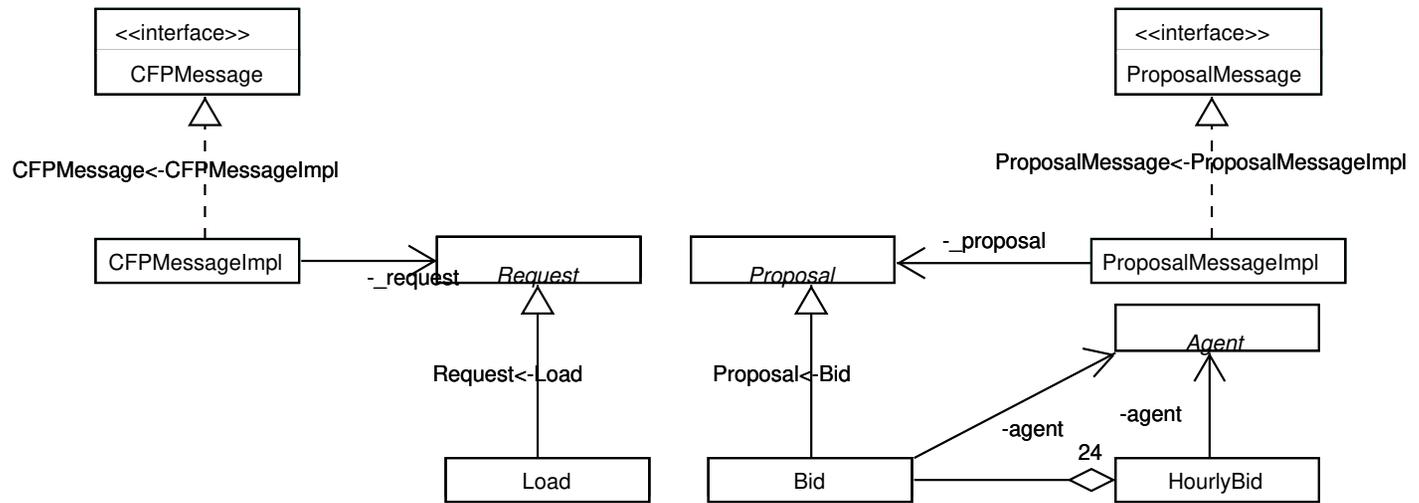


Figura A.3: Diagrama de classes do conteúdo das mensagens ACL de *CFP* e *Proposal*.

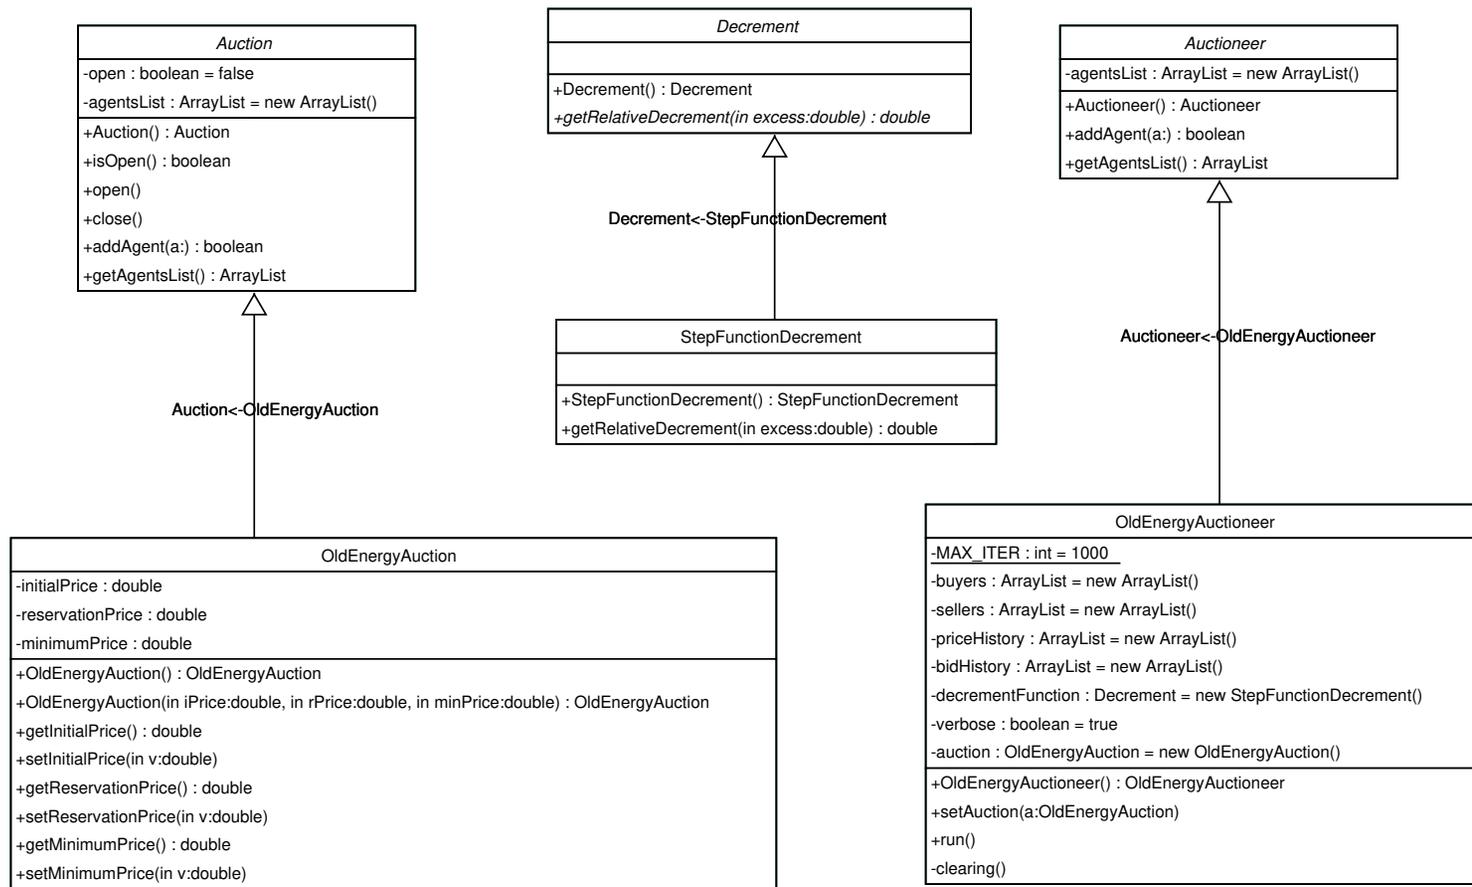


Figura A.4: Diagrama de classes do simulador do leilão de energia.

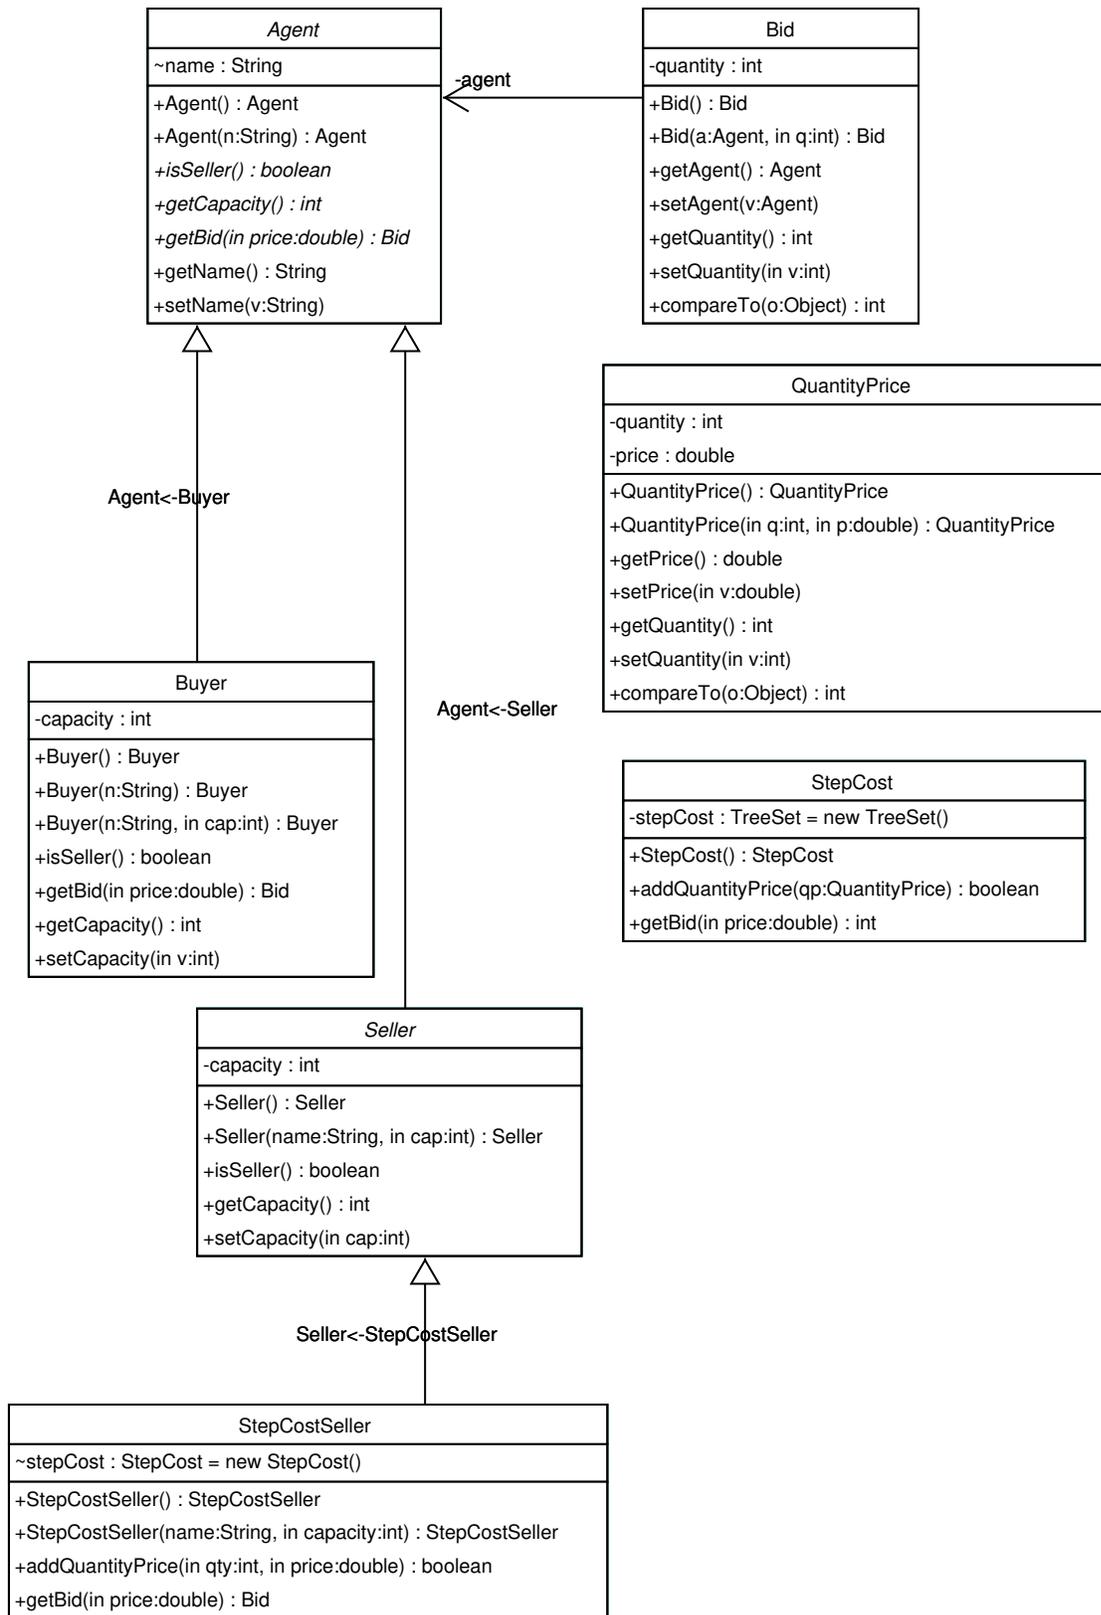


Figura A.5: Diagrama das classes dos agentes participantes no leilão de energia.

Apêndice B

Implementação da Arquitetura AEMAS em FIPA-OS

B.1 Implementação em FIPA-OS

Neste apêndice apresentamos uma implementação da arquitetura AEMAS em FIPA-OS.

B.1.1 Protótipo FIPA-OS

É utilizada a versão 2.1.0 de FIPA-OS que implementa parte da especificação FIPA 2000 (FIPA 2000). Mais precisamente, FIPA-OS adere ao modelo de referência FIPA especificado em (FIPA 2002a, FIPA 2004).

FIPA-OS fornece um agente padrão (*agent shell*), a classe FIPAOSAgent, que serve de base a todos os agentes do protótipo, como ilustrado no diagrama de classes da Figura A.1. Também utiliza-se a programação por tarefas, outra característica da plataforma.

As mensagens neste apêndice são do tipo

```
nome do agente | classe do agente | nível: mensagem
```

B.1.2 Inicialização da Plataforma FIPA-OS

Com a inicialização da plataforma FIPA-OS observa-se a inicialização e identificação dos agentes AMS (*Agent Management System*) e DF (*Directory Facilitator*) na Tabela B.1. No conteúdo das mensagens *ipanema* é o *host* que hospeda a plataforma FIPA-OS. FIPA-OS fornece também uma interface gráfica de visualização dos agentes registrados no DF.

```
ams | fipaos.platform.AgentManagementSystem | 5: Agent has been assigned AgentID
(agent-identifier :name ams@localap
                 :addresses (sequence fipaos-rmi://ipanema:3000/ams ) )
```

```
df | fipaos.platform.DirectoryFacilitator | 5: Agent has been assigned AgentID
(agent-identifier :name df@localap
                 :addresses (sequence fipaos-rmi://ipanema:3000/df ) )
```

Tabela B.1: Mensagens de inicialização do AMS e do DF na plataforma FIPA-OS.

B.1.3 Inicialização do Auctioneer

```
EnergyAuctioneer | bidding.agent.manager.Auctioneer | 5:
Agent has been assigned AgentID
(agent-identifier :name EnergyAuctioneer@localap
                 :addresses (sequence fipaos-rmi://ipanema:3000/EnergyAuctioneer ) )
```

```
EnergyAuctioneer | bidding.agent.manager.Auctioneer | 5: Registered with AMS
```

```
EnergyAuctioneer | bidding.agent.manager.Auctioneer | 5: Registered with DF
```

Tabela B.2: Mensagens de inicialização do Auctioneer no protótipo em FIPA-OS.

Na Tabela B.2 encontram-se as mensagens de inicialização do Auctioneer, que implementa o agente alocador de recursos ResourceAllocationAgent. O Auctioneer provê um serviço FIPA do tipo *market-manager*.

B.1.4 Inicialização de um Agente

```
ArgentinaII | bidding.Termo | 5: Agent has been assigned AgentID
(agent-identifier :name ArgentinaII@localap
                 :addresses (sequence fipaos-rmi://ipanema:3000/ArgentinaII ) )
```

```
ArgentinaII | bidding.Termo | 5: Registered with AMS
```

```
ArgentinaII | bidding.Termo | 5: Registered with DF
```

```
ArgentinaII | bidding.Termo | 5: ArgentinaII : 1000.0 MW 36.91 R$/MWh
```

Tabela B.3: Mensagens de inicialização do agente ArgentinaII no protótipo em FIPA-OS.

Na Tabela B.3 encontram-se as mensagens de inicialização de um agente na plataforma FIPA-OS.

B.1.5 Descrição de um Agente

```
(df-agent-description
  :name (agent-identifier
         :name ArgentinaII@localap
         :addresses (sequence
                    fipaos-rmi://ipanema:3000/ArgentinaII ) )
  :services (set
             (service-description
              :name energy-seller
              :type energy-seller )) )
```

Tabela B.4: Descrição do agente ArgentinaII no DF do protótipo em FIPA-OS.

Na Tabela B.4 encontra-se a descrição do agente GenCo “ArgentinaII” no FIPA-OS DF (*Directory Facilitator*).

B.1.6 Inscrição de um Agente no Leilão

Através de uma interface gráfica simples cada agente pode se inscrever a um ou mais mercados selecionados a partir de uma interface de seleção que permite a visualização dos mercados (agentes que prestam o serviço *market-manager*) encontrados no DF e aos quais o agente pode se inscrever.

B.1.7 Mensagem de Busca do Mercado

Para se ter uma idéia do tipo de mensagem trocado entre um agente procurando se inscrever no leilão e o DF, na Tabela B.7 encontra-se ilustrada uma mensagem gerada pelo DF concordando com a busca requisitada pelo agente ArgentinaII. Esta busca pelo agente que provê o serviço de *market-manager* (instância do agente Auctioneer) é ilustrada na Tabela B.5 quando da seleção do leilão. Na Tabela B.6 o conteúdo da mensagem recebida pelo DF. Observe que o agente requisitou uma busca de nível 2 e como o DF não encontrou outro DF para federá-la (a quem reenviar) respondeu com a mensagem “No DF’s to federate search!”. Esta busca em vários níveis seria útil para que um mercado em outro *host* pudesse ser encontrado.

```
df | fipaos.platform.df.SearchTask | 3: No DF's to federate search!
```

```
ArgentinaII | bidding.Termo | 5: Sending subscription request
```

```
EnergyAuctioneer | bidding.agent.manager.Auctioneer | 5: Subscribed
(agent-identifier
  :name ArgentinaII@localap
  :addresses (sequence fipaos-rmi://ipanema:3000/ArgentinaII ) )
```

```
ArgentinaII | bidding.Termo | 5:
(agent-identifier
  :name ArgentinaII@localap
  :addresses (sequence fipaos-rmi://ipanema:3000/ArgentinaII ) )
has subscribed with the market manager
```

Tabela B.5: Inscrição do agente ArgentinaII no mercado gerenciado por EnergyAuctioneer.

```
20021211T111106816 | df | fipaos.platform.DirectoryFacilitator | 2:
Received message:
(request
  :sender (agent-identifier :name ArgentinaII@localap
    :addresses (sequence fipaos-rmi://ipanema:3000/ArgentinaII ) )
  :receiver ( set (agent-identifier :name df@localap ) )
  :content #197"((action (agent-identifier :name df@localap )
    (search (df-agent-description
      :services (set (service-description
        :name market-manager
        :type market-manager))))
      (search-constraints :max-depth 2 ))))
  :language FIPA-SL0
  :ontology fipa-agent-management
  :protocol fipa-request
  :conversation-id ArgentinaII@localap103961226632410 )
```

Tabela B.6: Mensagem recebida pelo DF: agente ArgentinaII busca pelos agentes que prestam o serviço *market-manager*.

```

20021211T111106826 | df |
fipaos.agent.conversation.standard.ConversationManagerImpl | 2:
Sending message:
(agree
  :sender (agent-identifier :name df@localap
  :addresses (sequence fipaos-rmi://ipanema:3000/df ) )
  :receiver ( set (agent-identifier :name ArgentinaII@localap
  :addresses (sequence fipaos-rmi://ipanema:3000/ArgentinaII ) ) )
  :content #197"((action (agent-identifier :name df@localap )
    (search (df-agent-description
      :services (set (service-description
        :name market-manager
        :type market-manager)))
      (search-constraints :max-depth 2 ) ) ) )
  :language FIPA-SL0
  :ontology fipa-agent-management
  :protocol fipa-request
  :conversation-id ArgentinaII@localap103961226632410 )

```

Tabela B.7: Mensagem do DF de concordância com a busca pelo mercado.

A resposta do DF com o conjunto de mercados ativos (serviço *market-manager*) encontra-se na Tabela B.8. Note que a ordem das mensagens é: o agente envia a mensagem de busca descrita na Tabela B.6 e então o DF responde concordando com a busca como descrito na Tabela B.7. Finalmente, após encontrar os agentes que satisfazem a busca o DF envia a mensagem de resposta com o resultado da busca ilustrada na Tabela B.8.

B.1.8 Abertura do Leilão

As mensagens na Tabela B.9 ilustram o envio de mensagens do Auctioneer¹ a cada um dos participantes no leilão comunicando a sua abertura.

B.1.9 *Call for Proposals*

A sequência na Tabela B.10 ilustra o Auctioneer enviando a cada participante uma requisição de ofertas (ou CFP de *Call for Proposals*) para a previsão de demanda do dia seguinte.

¹Aqui foi utilizada *SubMarketAgent*, uma sub-classe de *Auctioneer* para implementar cada um dos sub-mercados de energia no Brasil.

```

20021211T111106984 | df |
fipaos.agent.conversation.standard.ConversationManagerImpl | 2:
Sending message:
(inform
  :sender (agent-identifier :name df@localap
           :addresses (sequence fipaos-rmi://ipanema:3000/df ) )
  :receiver (set (agent-identifier :name ArgentinaII@localap
           :addresses (sequence fipaos-rmi://ipanema:3000/ArgentinaII ) ) )
  :content #689"((result (action (agent-identifier :name df@localap )
           (search (df-agent-description
           :services (set (service-description
                           :name market-manager
                           :type market-manager)))
           (search-constraints :max-depth 2 )))
           (set (df-agent-description
           :name (agent-identifier
           :name EnergyAuctioneer@localap
           :addresses
           (sequence fipaos-rmi://ipanema:3000/EnergyAuctioneer))
           :services (set (service-description
                           :name market-manager
                           :type market-manager)))
           (df-agent-description
           :name (agent-identifier
           :name anotherEnergyAuctioneer@localap
           :addresses
           (sequence fipaos-rmi://ipanema:3000/anotherEnergyAuctioneer))
           :services (set (service-description
                           :name market-manager
                           :type market-manager ) ) ) ) ) ) ) )
  :language FIPA-SL0
  :ontology fipa-agent-management
  :protocol fipa-request
  :conversation-id ArgentinaII@localap103961226632410 )

```

Tabela B.8: Mensagem de resposta do DF contendo resultado da busca.

```
EnergyAuctioneer | bidding.agent.manager.SubMarketAgent | 5:
Sending inform start of auction to (agent-identifier :name Eletrobolt@localap
:addresses (sequence fipaos-rmi://ipanema:3000/Eletrobolt ) )
EnergyAuctioneer | bidding.agent.manager.SubMarketAgent | 5:
Sending inform start of auction to (agent-identifier :name ArgentinaII@localap
:addresses (sequence fipaos-rmi://ipanema:3000/ArgentinaII ) )
EnergyAuctioneer | bidding.agent.manager.SubMarketAgent | 5:
Sending inform start of auction to (agent-identifier :name ArgentinaI@localap
:addresses (sequence fipaos-rmi://ipanema:3000/ArgentinaI ) )
EnergyAuctioneer | bidding.agent.manager.SubMarketAgent | 5:
Sending inform start of auction to (agent-identifier :name PresMedici@localap
:addresses (sequence fipaos-rmi://ipanema:3000/PresMedici ) )
EnergyAuctioneer | bidding.agent.manager.SubMarketAgent | 5:
Sending inform start of auction to (agent-identifier :name Angra1@localap
:addresses (sequence fipaos-rmi://ipanema:3000/Angra1 ) )
EnergyAuctioneer | bidding.agent.manager.SubMarketAgent | 5:
Sending inform start of auction to (agent-identifier :name Araucaria@localap
:addresses (sequence fipaos-rmi://ipanema:3000/Araucaria ) )
EnergyAuctioneer | bidding.agent.manager.SubMarketAgent | 5:
Sending inform start of auction to (agent-identifier :name Angra2@localap
:addresses (sequence fipaos-rmi://ipanema:3000/Angra2 ) )
```

Tabela B.9: Mensagens de abertura do leilão enviadas a sete agentes.

B.1.10 Submissão de Propostas

Cada um dos agentes emitiu uma mensagem reconhecendo que o leilão estava aberto e se preparando então para lidar com uma CFP. Na Tabela B.11 observa-se a assincronicidade com que as CFP's são recebidas e as propostas enviadas. Em um modelo orientado a objetos (sem agentes) com simples chamadas aos métodos das classes isto não seria possível de modo tão transparente. Cada participante no leilão responderia imediatamente e de modo síncrono a uma chamada a algum método como por exemplo `getBid(CFP)` que retorna o `Bid`, a menos que se utilizasse programação *multi-thread*. A programação orientada a agentes através da plataforma FIPA-OS acentua a autonomia de cada um dos participantes no leilão de modo transparente.

A submissão de uma proposta como resposta a uma CFP se dá através de uma interface `OfferEngine` possibilitando que diferentes implementações desta interface possam ser utilizadas segundo a estratégia de oferta do agente. O projeto automatizado das estratégias de oferta é detalhado no Capítulo 6.

```

EnergyAuctioneer | bidding.agent.manager.SubMarketAgent | 5:
Sending initial CFP to (agent-identifier :name Eletrobolt@localap
:addresses (sequence fipaos-rmi://ipanema:3000/Eletrobolt ) )
EnergyAuctioneer | bidding.agent.manager.SubMarketAgent | 5:
Sending initial CFP to (agent-identifier :name ArgentinaII@localap
:addresses (sequence fipaos-rmi://ipanema:3000/ArgentinaII ) )
EnergyAuctioneer | bidding.agent.manager.SubMarketAgent | 5:
Sending initial CFP to (agent-identifier :name ArgentinaI@localap
:addresses (sequence fipaos-rmi://ipanema:3000/ArgentinaI ) )
EnergyAuctioneer | bidding.agent.manager.SubMarketAgent | 5:
Sending initial CFP to (agent-identifier :name PresMedici@localap
:addresses (sequence fipaos-rmi://ipanema:3000/PresMedici ) )
EnergyAuctioneer | bidding.agent.manager.SubMarketAgent | 5:
Sending initial CFP to (agent-identifier :name Angra1@localap
:addresses (sequence fipaos-rmi://ipanema:3000/Angra1 ) )
EnergyAuctioneer | bidding.agent.manager.SubMarketAgent | 5:
Sending initial CFP to (agent-identifier :name Araucaria@localap
:addresses (sequence fipaos-rmi://ipanema:3000/Araucaria ) )
EnergyAuctioneer | bidding.agent.manager.SubMarketAgent | 5:
Sending initial CFP to (agent-identifier :name Angra2@localap
:addresses (sequence fipaos-rmi://ipanema:3000/Angra2 ) )

```

Tabela B.10: Mensagens de CFP (*Call for Proposals*) enviadas a sete agentes.

Poderíamos prosseguir no detalhamento das mensagens necessárias a cumprir o protocolo de interação dos agentes participantes no leilão com o leiloeiro definido na seção 4.3.1 e ilustrado no diagrama da Figura A.2. Porém não o fazemos considerando que as mensagens apresentadas são suficientes para ilustrar o comportamento do sistema.

B.1.11 Modelagem do Conteúdo das Mensagens

Especificamos como foram definidos os conteúdos das mensagens de CFP (*Call for Proposal*) e de oferta (*Proposal*). Estes conteúdos são encapsulados em mensagens ACL (*Agent Communication Language*) através do método `ACL.setMessageContent(Object msg_content)` e acessados com `ACL.getMessageContent(Object msg_content)`.

O diagrama de classes da Figura A.3 ilustra como as mensagens `ProposalMessage` e `CFPMessage` encapsulam o conteúdo `Proposal` e `Request`.

Eletrobolt | bidding.Termo | 5: Eletrobolt@localap Dealing with CFP
ArgentinaII | bidding.Termo | 5: ArgentinaII@localap Dealing with CFP
Eletrobolt | bidding.Termo | 5: Eletrobolt@localap Sending proposal
ArgentinaII | bidding.Termo | 5: ArgentinaII@localap Sending proposal
ArgentinaI | bidding.Termo | 5: ArgentinaI@localap Dealing with CFP
ArgentinaI | bidding.Termo | 5: ArgentinaI@localap Sending proposal
PresMedici | bidding.Termo | 5: PresMedici@localap Dealing with CFP
PresMedici | bidding.Termo | 5: PresMedici@localap Sending proposal
Angra1 | bidding.Termo | 5: Angra1@localap Dealing with CFP
Angra1 | bidding.Termo | 5: Angra1@localap Sending proposal
Araucaria | bidding.Termo | 5: Araucaria@localap Dealing with CFP
Araucaria | bidding.Termo | 5: Araucaria@localap Sending proposal
Angra2 | bidding.Termo | 5: Angra2@localap Dealing with CFP
Angra2 | bidding.Termo | 5: Angra2@localap Sending proposal

Tabela B.11: Mensagens de resposta às CFP's.

Apêndice C

Programação Neurodinâmica

C.1 Programação Neurodinâmica

A discussão a seguir baseada em (Haykin 1999) pressupõe um único agente atuando no sistema sendo que a possibilidade da existência de outros agentes é modelada no ambiente. A extensão deste paradigma a um ambiente multi agentes é discutida na seção 2.3.5. Em (Bertsekas & Tsitsiklis 1996) discutem-se os detalhes e os benefícios potenciais da programação neurodinâmica.

C.1.1 Processo de Decisão Markoviano

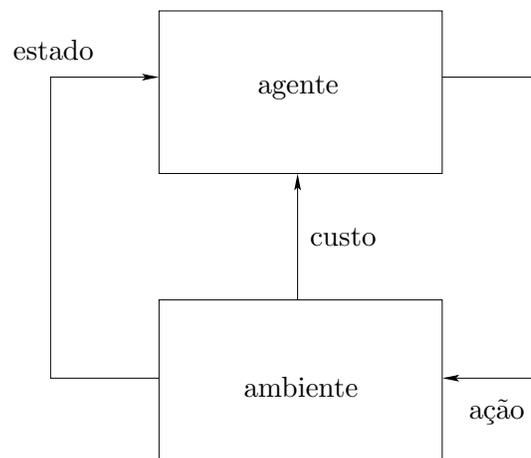


Figura C.1: Diagrama de blocos de um agente interagindo com o ambiente.

Podemos considerar o agente como um sistema de aprendizado que interage com o ambiente segundo o diagrama da Figura C.1. O sistema opera de acordo com um processo de decisão Markoviano finito e discreto no tempo que é caracterizado como:

- O ambiente evolui probabilisticamente ocupando um conjunto finito de estados discretos. O estado não contém estatísticas do passado embora estas poderiam ser úteis ao agente.
- Para cada estado do ambiente há um conjunto finito de possíveis ações que podem ser tomadas pelo agente.
- Cada vez que o agente toma uma ação isto incorre em um custo (ou benefício).
- Os estados são observados, ações são tomadas, e custos (benefícios) são incorridos em tempos discretos.

A variável aleatória que denota o estado no tempo n é X_n e sua realização $\mathbf{x}(n)$. O conjunto finito de estados é denotado por \mathcal{X} . Para o estado i o conjunto disponível de ações é denotado por $\mathcal{A}_i = \{a_{ik}\}$ onde k indica a disponibilidade ao agente de várias ações quando o sistema se encontra no estado i . A transição do estado i para o estado j devido à ação a_{ik} é probabilística por natureza. E a probabilidade de transição do estado i ao estado j depende inteiramente do estado atual i e da ação a_{ik} . Esta é a propriedade de Markov, crucial pois significa que o estado atual do ambiente provê informação necessária para o agente decidir qual ação tomar.

A variável aleatória A_n denota a ação tomada pelo agente no estágio n . Seja $p_{ij}(a)$ a probabilidade de transição do estado i ao estado j devido à ação tomada no estágio n onde $A_n = a$. Devido à propriedade de Markov temos:

$$p_{ij}(a) = P(X_{n+1} = j \mid X_n = i, A_n = a) \quad (\text{C.1})$$

Para um dado número de estados e probabilidades de transição a sequência de estados resultantes das ações tomadas pelo agente no tempo formam uma cadeia de Markov.

Em cada transição de um estado a outro um custo é incorrido pelo agente. Então na n -ésima transição do estado i ao estado j sob ação a_{ik} , o agente incorre um custo denotado por $\gamma^n g(i, a_{ik}, j)$ onde $g(\cdot, \cdot, \cdot)$ é uma função de custo e γ , $0 \leq \gamma < 1$ um fator de desconto.

Um fator de desconto γ corresponde a uma taxa de juros $(1/\gamma) - 1$ (Russel & Norvig 2004). Fazer γ igual a 1 é o mesmo que utilizar custos (recompensas) aditivos.

Nosso interesse é formular uma política, definida como o mapeamento de estados em ações. Ou seja, uma regra utilizada pelo agente para decidir que ação tomar dado o conhecimento do estado atual. A política é denotada por

$$\pi = \{\mu_0, \mu_1, \mu_2, \dots\} \quad (\text{C.2})$$

onde μ_n é uma função que mapeia o estado $X_n = i$ em uma ação $A_n = a$ no estágio (passo) $n = 0, 1, 2, \dots$. Este mapeamento é tal que

$$\mu_n(i) \in \mathcal{A}_i, \quad \forall i \in \mathcal{X}$$

onde \mathcal{A}_i denota o conjunto de todas as ações possíveis tomadas pelo agente no estado i . Estas políticas são ditas admissíveis.

Uma política pode ser estacionária ou não-estacionária. Uma política não-estacionária varia no tempo como indicado na equação (C.2). Entretanto quando a política é independente do tempo, isto é,

$$\pi = \{\mu, \mu, \mu, \dots\}$$

a política é dita estacionária. Ou seja, uma política estacionária especifica exatamente a mesma ação cada vez que um determinado estado é visitado. Se uma política estacionária μ é empregada, então a sequência de estados $\{X_n, n = 0, 1, 2, \dots\}$ forma uma cadeia de Markov com probabilidades de transição $p_{ij}(\mu(i))$ onde $\mu(i)$ é uma ação. Este processo é definido então como um processo de decisão Markoviano.

Um problema de programação dinâmica pode ser definido em um horizonte finito ou infinito. Em um problema de decisão finito o custo (benefício ou recompensa) é acumulado sobre um número finito de estágios. Em um problema de horizonte infinito o custo é acumulado sobre um horizonte infinito. Problemas de horizonte infinito são uma aproximação razoável de problemas finitos mas com número de estágios muito grande. São de particular interesse pois o desconto assegura que os custos para todos os estágios são finitos para qualquer política (quando não se adota recompensa aditiva).

O custo total esperado em um problema de horizonte infinito cujo estado inicial é $X_0 = i$ utilizando uma política $\pi = \{\mu_n\}$ é definido por

$$J^\pi(i) = E \left[\sum_{n=0}^{\infty} \gamma^n g(X_n, \mu_n(X_n), X_{n+1}) \mid X_0 = i \right] \quad (\text{C.3})$$

onde o valor esperado é tomado com respeito à cadeia de Markov $\{X_1, X_2, \dots\}$. A função $J^\pi(i)$ é chamada de funcional de custo (*cost-to-go function*) para a política π a partir do estado i . Seu valor ótimo em um problema de minimização é definido por

$$J^*(i) = \min_{\pi} J^\pi(i) \quad (\text{C.4})$$

Quando a política π é estacionária, ou seja, $\pi = \{\mu, \mu, \mu, \dots\}$, a notação $J^\mu(i)$ é utilizada no lugar de $J^\pi(i)$.

Podemos então resumir o problema de programação dinâmica como:

Dado um processo de decisão Markoviano descrevendo a interação de um agente e seu ambiente, encontre uma política estacionária $\pi = \{\mu, \mu, \mu, \dots\}$ que minimiza a função $J^\mu(i)$ para todos estados iniciais i .

Note que durante o aprendizado o comportamento do agente pode mudar com o tempo. Entretanto a política ótima que o agente procura será estacionária (Watkins 1989).

C.1.2 Critério de Otimalidade de Bellman

A programação dinâmica se baseia em um princípio conhecido como o princípio de otimalidade de Bellman:

Uma política ótima tem a seguinte propriedade: quaisquer que sejam o estado e a decisão iniciais, as decisões remanescentes devem constituir uma política ótima em relação ao estado resultante da primeira decisão.

Uma decisão é uma escolha de controle em um dado instante de tempo e uma política é a sequência de controle ou função de controle.

Considerando um problema de horizonte finito, podemos definir o funcional de custo por

$$J_0(X_0) = E \left[g_K(X_K) + \sum_{n=0}^{K-1} g_n(X_n, \mu_n(X_n), X_{n+1}) \right] \quad (\text{C.5})$$

onde K é o horizonte (número de estágios) e $g_K(X_K)$ o custo terminal. O princípio da otimalidade pode ser então formulado como:

Seja $\pi^* = \{\mu_0^*, \mu_1^*, \dots, \mu_{K-1}^*\}$ uma política ótima para o problema de horizonte finito. Assuma que quando uma política π^* é utilizada um dado estado X_n ocorre com probabilidade positiva. Considere o sub-problema onde o ambiente está no estado X_n no tempo n , e suponha que queremos minimizar a função

$$J_n(X_n) = E \left[g_K(X_K) + \sum_{k=n}^{K-1} g_k(X_k, \mu_k(X_k), X_{k+1}) \right] \quad (\text{C.6})$$

para $n = 0, 1, \dots, K-1$. Então a política $\{\mu_n^*, \mu_{n+1}^*, \dots, \mu_{K-1}^*\}$ é ótima para o sub-problema.

O algoritmo de programação dinâmica pode ser definido como:

Para todo estado inicial X_0 , o custo ótimo $J^*(X_0)$ do problema básico de horizonte finito é igual a $J_0(X_0)$ onde J_0 é obtido do último passo de:

$$J_n(X_n) = \min_{\mu_n} E_{X_{n+1}} [g_n(X_n, \mu_n(X_n), X_{n+1}) + J_{n+1}(X_{n+1})] \quad (\text{C.7})$$

com

$$J_K(X_K) = g_K(X_K) .$$

Se μ_n^* minimiza o lado direito da equação (C.7) então a política $\pi^* \{\mu_n^*, \mu_{n+1}^*, \dots, \mu_{K-1}^*\}$ é ótima.

No sentido de lidar com o problema de horizonte infinito com taxa de desconto γ reverte-se o índice de tempo fazendo-no corresponder ao problema com taxa de desconto e define-se $g_n(X_n, \mu(X_n), X_{n+1}) = \gamma^n g(X_n, \mu(X_n), X_{n+1})$. Podemos reformular o algoritmo de programação dinâmica como

$$J_{n+1} = \min_{\mu} E [g(X_0, \mu(X_0), X_1) + \gamma J_n(X_1)] \quad (\text{C.8})$$

que inicia com $J_0(X) = 0$ para todo X . Podemos ver o custo ótimo de horizonte infinito como $J^*(i) = \lim_{K \rightarrow \infty} J_K(i)$ para todo i . Fazendo $n + 1 = K$ e $X_0 = i$ temos

$$J^*(i) = \min_{\mu} E [g(i, \mu(i), X_1) + \gamma J^*(X_1)] \quad (\text{C.9})$$

Seja

$$c(i, \mu(i)) = E [g(i, \mu(i), X_1)] = \sum_{j=1}^N p_{ij} g(i, \mu(i), j) \quad (\text{C.10})$$

o custo imediato esperado incorrido no estado i ao se seguir a ação recomendada pela política μ .

Podemos avaliar o valor esperado de $J^*(X_1)$ com respeito a X_1 como

$$E [J^*(X_1)] = \sum_{j=1}^N p_{ij} J^*(j) \quad (\text{C.11})$$

Então usando as equações (C.10) e (C.11) em (C.8) temos a equação de otimalidade de Bellman:

$$J^*(i) = \min_{\mu} \left(c(i, \mu(i)) + \gamma \sum_{j=1}^N p_{ij}(\mu) J^*(j) \right), \quad i = 1, 2, \dots, N \quad (\text{C.12})$$

Há dois métodos para computar a política ótima: iteração de políticas e iteração de valores. Duas questões práticas surgem quando se considera o uso destes algoritmos:

- Maldição da dimensionalidade. O número de estados e ações admissíveis podem ser tão grandes que os requisitos computacionais são enormes.
- Informação incompleta. É necessário conhecimento a respeito do processo de decisão Markoviano, ou seja, as probabilidades p_{ij} e os custos $g(i, a, j)$ que nem sempre estão disponíveis.

Procura-se então uma política sub-ótima que envolva uma rede neural e/ou simulação com o propósito de aproximar a função $J^*(i)$ para todo $i \in \mathcal{X}$. Para um estado i , $J^*(i)$ é substituída por uma aproximação $\hat{J}(i, \mathbf{w})$ onde \mathbf{w} é um vetor de parâmetros. Como ilustrado na Figura C.2, $\hat{J}(i, \mathbf{w})$ é a saída de uma rede neural que funciona como aproximador universal em resposta a um estado i como entrada.

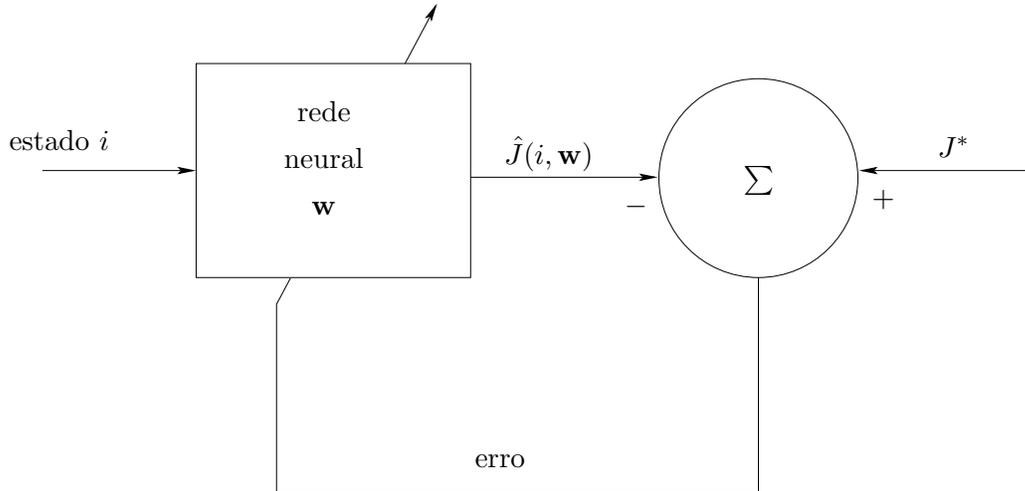


Figura C.2: Rede neural para aproximar a função J^* .

Um problema que surge com esta abordagem é que não há dados de treinamento (exemplos de pares entrada-saída $\{(i, J^*(i))\}$) para treinar a rede neural. A única possibilidade é utilizar simulação de Monte Carlo onde um modelo substituto é utilizado no lugar do processo decisório Markoviano real.

C.1.3 *Q-learning*

O algoritmo de aprendizado *Q-learning* é uma resposta à seguinte questão: “Existe um procedimento de aprendizado *online* para aprender a política ótima a partir da experiência obtida através de amostras do tipo

$$s_n = (i_n, a_n, j_n, g_n) \quad (\text{C.13})$$

onde n denota o tempo discreto, e s_n consiste em uma quádrupla descrita pela ação a_n no estado i_n que resulta na transição $j_n = i_{n+1}$ a um custo $g_n = g(i_n, a_n, j_n)$?”

A resposta a esta questão é sim e é encontrada em um método estocástico chamado *Q-learning* (Watkins 1989, Watkins & Dayan 1992). Este método é um procedimento de programação dinâmica incremental que determina a política ótima passo a passo. É indicado para resolver problemas de decisão Markovianos sem conhecimento explícito das probabilidades de transição. Entretanto seu sucesso assume que o estado do ambiente é totalmente observável, o que significa que o ambiente seja uma cadeia de Markov totalmente observável.

Definindo o fator-Q como

$$Q^\mu(i, a) = c(i, a) + \gamma \sum_{j=1}^n p_{ij} J^\mu(j) \quad (\text{C.14})$$

onde a ação $a = \mu(i)$. Combinando esta equação com a equação de otimalidade de Bellman definida pela equação (C.12) e usando a definição do custo imediato esperado $c(i, a)$ dado pela equação (C.10), obtemos:

$$Q^*(i, a) = \sum_{j=1}^N p_{ij}(a) (g(i, a, j) + \gamma \min_{b \in \mathcal{A}_j} Q^*(j, b)) \quad \forall(i, a) \quad (\text{C.15})$$

A solução deste sistema linear de equações define os fatores Q ótimos $Q^*(i, a)$ unicamente para todos os pares estado-ação (i, a) .

Um algoritmo para resolver este sistema de equações é o algoritmo de iteração de valores formulado em termos dos fatores Q. Então temos para uma iteração do algoritmo:

$$Q(i, a) \leftarrow \sum_{j=1}^N p_{ij}(a) (g(i, a, j) + \gamma \min_{b \in \mathcal{A}_j} Q(j, b)) \quad \forall(i, a) \quad (\text{C.16})$$

Uma versão desta é dada por

$$Q(i, a) \leftarrow (1 - \eta)Q(i, a) + \eta \sum_{j=1}^N p_{ij}(a) (g(i, a, j) + \gamma \min_{b \in \mathcal{A}_j} Q(j, b)) \quad \forall(i, a) \quad (\text{C.17})$$

$$(\text{C.18})$$

que requer as probabilidades de transição $p_{ij}(a)$, onde η é uma taxa de aprendizado com $0 < \eta < 1$. Para eliminar esta necessidade podemos formular uma versão estocástica substituindo a média sobre todos os possíveis estados por uma única amostra, resultando em

$$Q_{n+1}(i, a) = (1 - \eta_n(i, a))Q_n(i, a) + \eta_n(i, a) [g(i, a, j) + \gamma J_n(j)] \quad \forall(i, a) = (i_n, a_n) \quad (\text{C.19})$$

$$(\text{C.20})$$

onde

$$J_n(j) = \min_{b \in \mathcal{A}_j} Q(j, b) \quad (\text{C.21})$$

e j é o estado sucessivo, $\eta_n(i, a)$ é a taxa de aprendizado no passo n para o par estado-ação (i, a) . A equação de atualização (C.20) aplica-se ao par estado corrente-ação (i_n, a_n) para o qual $j = J_n$ de acordo com a equação (C.13). Para todos os outros pares admissíveis de estado-ação, os fatores Q permanecem o mesmo como mostrado por

$$Q_{n+1}(i, a) = Q_n(i, a) \quad \forall(i, a) \neq (i_n, a_n) \quad (\text{C.22})$$

Estas equações (C.20) e (C.22) constituem o algoritmo *Q-learning*.

Resumindo, *Q-learning* é uma forma de aproximação estocástica do algoritmo de iteração de valor. Calcula-se o fator-Q para um único par estado-ação a cada iteração do algoritmo, ou seja,

o estado atual e a ação executada. Mais importante, no limite, o algoritmo converge para os valores Q ótimos sem formar um modelo explícito dos processos de decisão Markovianos. Uma vez que os valores Q ótimos estão disponíveis, uma política ótima pode ser determinada com relativamente pouca computação utilizando:

$$\mu^*(i) = \arg \min_{a \in \mathcal{A}_i} Q^*(i, a), \quad i = 1, 2, \dots, N \quad (\text{C.23})$$

A convergência do algoritmo *Q-learning* para uma política ótima assume o uso de uma representação através de uma tabela de *lookup* para os fatores Q $Q_n(i, a)$. Este método de representação é direto e computacionalmente eficiente. Entretanto, quando o espaço de entrada consistindo de pares estado-ação é grande ou as variáveis de entrada são contínuas, o uso de uma tabela pode ser proibitivo devido à exigência de uma memória enorme. Nesta situação podemos utilizar uma rede neural como aproximador de função.

C.1.4 *Q-learning* Aproximado

Reescrevendo as equações (C.20) e (C.21) na forma:

$$Q_{n+1}(i_n, a_n) = Q_n(i_n, a_n) + \eta_n(i_n, a_n) \left[g(i_n, a_n, j_n) + \gamma \min_{b \in \mathcal{A}_{j_n}} Q_n(j_n, b) - Q_n(i_n, a_n) \right] \quad (\text{C.24})$$

Tratando a expressão entre colchetes do lado direito desta equação como o sinal de erro envolvido em atualizar o fator- Q atual $Q_n(i_n, a_n)$ podemos identificar o fator- Q alvo (desejado) no passo n como:

$$Q_n^{alvo}(i_n, a_n) = g(i_n, a_n, j_n) + \gamma \min_{b \in \mathcal{A}_{j_n}} Q_n(j_n, b) \quad (\text{C.25})$$

onde $j_n = i_{n+1}$ é o estado sucessivo. Esta equação mostra como j_n é crítico na determinação do fator- Q alvo. Usando esta definição do fator- Q podemos reformular o algoritmo *Q-learning* como:

$$Q_{n+1}(i, a) = Q_n(i, a) + \Delta Q_n(i, a) \quad (\text{C.26})$$

onde a mudança incremental no fator- Q atual é definida por

$$\Delta Q_n(i, a) = \begin{cases} \eta_n(Q_n^{alvo}(i, a) - Q_n(i, a)) & \text{para } (i, a) = (i_n, a_n) \\ 0, & \text{caso contrário} \end{cases} \quad (\text{C.27})$$

Por definição a ação ótima a_n no estado atual i_n é a ação particular no estado para o qual o fator- Q no passo n é mínimo. Então, dado os fatores Q $Q_n(i_n, a)$ para ações admissíveis $a \in \mathcal{A}_{i_n}$ no estado i_n , a ação ótima em (C.25) é dada por:

$$a_n = \min_{a \in \mathcal{A}_{i_n}} Q_n(i_n, a) \quad (\text{C.28})$$

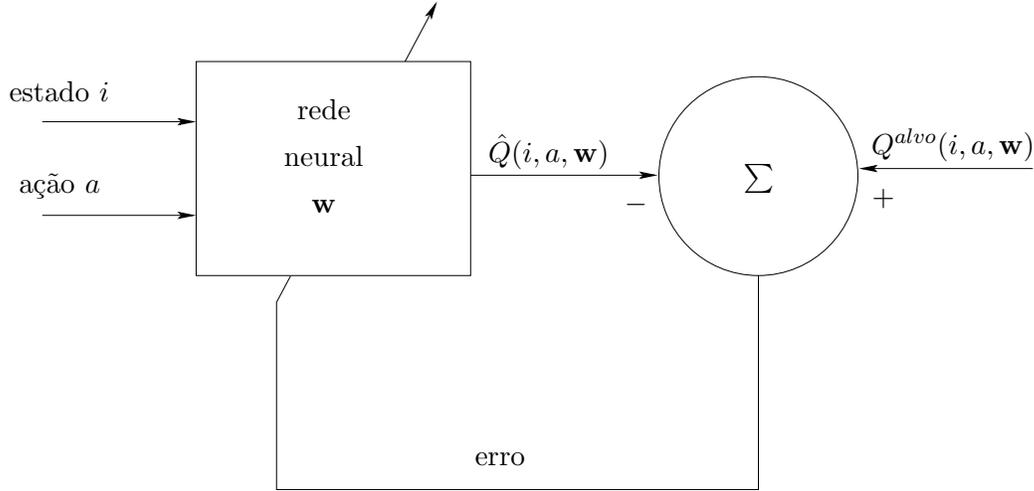


Figura C.3: Layout de rede neural para aproximar o fator-Q $Q^{alvo}(i, a, \mathbf{w})$.

Seja $\hat{Q}_n(i_n, a_n, \mathbf{w})$ a aproximação do fator-Q $Q_n(i_n, a_n)$ calculada através de uma rede neural. O par estado atual-ação (i_n, a_n) é entrada da rede neural com vetor de parâmetros \mathbf{w} , produzindo a saída $\hat{Q}_n(i_n, a_n, \mathbf{w})$ como ilustrado na Figura C.3. Como ambos os valores $\hat{Q}_n(i_n, a_n, \mathbf{w})$ e $Q_n^{alvo}(i_n, a_n, \mathbf{w})$ variam com a atualização de \mathbf{w} não há garantia de convergência.

O Algoritmo 4 apresenta o algoritmo de *Q-learning* aproximado.

Algoritmo 4 Algoritmo *Q-learning* aproximado.

iniciar com o peso \mathbf{w}_0 resultando no fator-Q $Q(i_0, a_0, \mathbf{w}_0)$.

for $n = 1, 2, \dots$ **do**

$$a_n = \min_{a \in \mathcal{A}_{i_n}} Q_n(i_n, a, \mathbf{w})$$

$$Q_n^{alvo}(i_n, a_n, \mathbf{w}) = g(i_n, a_n, j_n) + \gamma \min_{b \in \mathcal{A}_{j_n}} Q_n(j_n, b, \mathbf{w})$$

$$Q_{n+1}(i, a, \mathbf{w}) = Q_n(i, a, \mathbf{w}) + \Delta Q_n(i, a, \mathbf{w}) \text{ onde}$$

$$\Delta Q_n(i, a, \mathbf{w}) = \begin{cases} \eta_n(i_n, a_n)(Q_n^{alvo}(i, a, \mathbf{w}) - Q_n(i, a, \mathbf{w})) & \text{para } (i, a) = (i_n, a_n) \\ 0, & \text{caso contrário} \end{cases}$$

aplicar (i_n, a_n) como entrada da rede neural produzindo saída $\hat{Q}_n(i_n, a_n, \mathbf{w})$ como aproximação de $Q_n^{alvo}(i_n, a_n, \mathbf{w})$.

mudar ligeiramente o vetor \mathbf{w} para trazer $\hat{Q}_n(i_n, a_n, \mathbf{w})$ mais próximo de $Q_n^{alvo}(i_n, a_n, \mathbf{w})$.

end for

Apêndice D

Ambiente Computacional

Descrevemos o ambiente computacional para o desenvolvimento e a implementação da arquitetura sugerida e simulada, bem como para a confecção deste documento.

D.1 *Hardware* e Sistema Operacional

- DellTM Dimension 4500, arquitetura Intel[©] Pentium[©] 4, 2 GHz 256 Mb RAM
- GNU/Linux Red Hat 9.0, kernel 2.4.18-14

D.2 Ambiente de Desenvolvimento

- JDK 1.4.2
- GNU Make version 3.79.1
- Apache Ant 1.5.1
- FIPA-OS 2.1.0
- Poseidon for UML Community Edition 4.2
- GNU Emacs 21.2.1
- netBeans IDE 3.6
- CVS 1.11.2
- SmartCVS 2.2.1
- Gnuplot 3.7

D.2.1 Plataforma de Desenvolvimento

Como gerador de números aleatórios foi utilizado uma implementação Java de Mersenne Twister (Matsumoto & Nishimura 1998) disponível em (Hoschek 1999). Para a implementação do sistema de inferência nebuloso, foi utilizado o *NRC FuzzyJ Toolkit* (NRC 2002).

D.3 Ambiente de Editoração

- Gnuplot 3.7
- L^AT_EX kpathsea 3.5.4
- GNU Make version 3.79.1

Apêndice E

Nomenclatura

E.1 Acrônimos

Empregamos e nos referenciamos a nomenclatura diversificada. Com o intuito de auxiliar na leitura do texto, a seguir alguns acrônimos.

ACE : *Agent-based Computational Economics*

ACL : *Agent Communication Language*

ANEEL : Agência Nacional de Energia Elétrica

BMF : Bolsa Mercantil de Futuros

BOVESPA : Bolsa de Valores de São Paulo

CalPX : *California Power Exchange*

CCL : *Constraint Choice Language*

DF : *Directory Facilitator*

FIPA : *Foundation for Intelligent Physical Agents*

FIPA-OS : *FIPA Open Source*

ISO : *Independent System Operator*

JADE : *Java Agent Development Framework*

JMS : *Java Messaging System*

KIF : *Knowledge Interchange Format*

KQML : *Knowledge Query and Manipulation Language*

NETA : *New Electricity Trading Arrangements*

NYMEX : *New York Mercantile Exchange*

OFFER : *Office of Electricity Regulation*

ONS : *Operador Nacional do Sistema*

RDF : *Resource Description Framework*

RMI : *Remote Method Invocation*

SL : *Semantic Language*

WAP : *Wireless Access Protocol*

Referências Bibliográficas

- Al-Agtash, S. (2004), 'Evolutionary negotiation strategies in emerging electricity markets', *Lecture Notes in Artificial Intelligence* **3070**, 1099–1104. ICAISC 2004.
- Al-Agtash, S. & Yamin, H. Y. (2004), 'Optimal supply curve bidding using Benders decomposition in competitive electricity markets', *Electric Power Systems Research* **71**, 245–255.
- Alcalá, R., Alcalá-Fdez, J., Casillas, J., Cordón, O. & Herrera, F. (2004), 'Local identification of prototypes for genetic learning of accurate TSK fuzzy rule-based systems', *International Journal of Intelligent Systems* (Special Issue on Evolutionary Fuzzy Systems). (to appear).
- Allsopp, D. N., Beutenement, P., Kirton, M., Bradshaw, J. M., Suri, N., Durfee, E., Knoblock, C. A., Tate, A. & Thompson, C. W. (2002), 'Coalition agents experiment: Multiagent cooperation in international coalition', *IEEE Intelligent Systems* **17**(3), 26–35.
- Almeida, L. H. B. & Camargo, I. M. T. (2006), A utilização de leilões de energia elétrica no setor elétrico brasileiro, *in* Camargo et al. (2006).
- ANEEL (2004), 'Banco de informações de geração'. <http://www.aneel.gov.br>.
- Azevedo, E. M. (2004), Modelo Computacional de Teoria de Jogos Aplicado aos Leilões Brasileiros de Energia Elétrica, PhD thesis, Faculdade de Engenharia Mecânica, Unicamp, Campinas, SP.
- Bagnall, A. J. (2000a), Modelling the UK Market in Electricity Generation with Autonomous Adaptive Agents, PhD thesis, School of Information Systems, University of East Anglia.
- Bagnall, A. J. (2000b), A multi-adaptive agent model of generator bidding in the UK market in electricity, *in* 'Genetic and Evolutionary Computation Conference GECCO 2000', Morgan Kaufmann, pp. 605–612.
- Bagnall, A. J. & Smith, G. D. (1999a), An adaptive agent model for generator company bidding in the UK power pool, *in* '4th European Conference on Artificial Evolution', Springer-Verlag, pp. 191–203.

- Bagnall, A. J. & Smith, G. D. (1999b), Using an adaptive agent to bid in a simplified model of the UK market in electricity, *in* 'Genetic and Evolutionary Computation Conference GECCO'99', Morgan Kaufmann, p. 774.
- Bagnall, A. J. & Smith, G. D. (2000), Game playing with autonomous adaptive agents in a simplified economic model of the UK market in electricity generation, *in* 'IEEE PES/CSEE International Conference Power Systems Technology', pp. 891–896.
- Bagnall, A. J. & Smith, G. D. (2005), 'A multiagent model of the UK market in electricity generation', *IEEE Transactions on Evolutionary Computation* **9**(5), 522–536.
- Bakos, Y. (1998), 'The emerging role of electronic marketplaces on the internet', *Communications of the ACM* **41**(8), 35–42.
- Banker, R. D. & Mitra, S. (2006), 'Procurement models in the agricultural supply chain: A case study of online coffee auctions in India', *Electronic Commerce Research and Applications*. (to appear).
- Barone, D., ed. (2003), *Sociedades Artificiais: A Nova Fronteira da Inteligência nas Máquinas*, Bookman, Porto Alegre, RS.
- Batista, P., Haiama, E. & Santo, R. E. (2004), 'Perspectiva para o setor elétrico, painel setorial de energia elétrica: ABRADÉE / APIMEC', http://abradee.org.br/Downloads/Painel/apresentacoes/Painel_3/Pactual.pdf.
- Batten, D. F. (2000), *Discovering Artificial Economics: How Agents Learn and Economies Evolve*, Westview Press, Boulder, Colorado.
- Bergenti, F. & Poggi, A. (2000), 'Exploiting UML in the design of Multi-Agent Systems'.
- Bertsekas, D. P. & Tsitsiklis, J. N. (1996), *Neuro-Dynamic Programming*, Athenas Scientific, Belmont, MA.
- Borenstein, S. (2001), The trouble with electricity markets (and some solutions), Technical Report PWP-081, University of California Energy Institute, Berkeley, California. <http://www.ucei.org>.
- Bower, J. & Bunn, D. W. (2001), 'Experimental analysis of the efficiency of uniform-price versus discriminatory auctions in the England and Wales electricity market', *Journal of Economic Dynamics and Control* **25**(3–4), 561–592.
- Bradshaw, J. M., Dutfield, S., Benoit, P. & Woolley, J. D. (1997), Kaos: Toward an industrial-strength open agent architecture, *in* 'Software Agents', AAAI Press/MIT Press, Cambridge, Massachusetts, pp. 375–418.

- Bunn, D. W. & Oliveira, F. S. (2001), 'Agent-based simulation - An application to the New Electricity Trading Arrangements of England and Wales', *IEEE Transactions on Evolutionary Computing* **5**(5), 493–503.
- Bunn, D. W. & Oliveira, F. S. (2003), 'Evaluating individual market power in electricity markets via agent-based simulation', *Annals of Operations Research* **121**(1–4), 57–77.
- Byde, A. (2002), Applying evolutionary game theory to auction mechanism design, Technical Report HPL-2002-321, HP Laboratories, Bristol.
- Camargo, I. M. d. T. et al., eds (2006), *V CBPE Congresso Brasileiro de Planejamento Energético*, Brasília, DF.
- Carlsson, P., Ygge, F. & Andersson, A. (2001), 'Extending equilibrium markets', *IEEE Intelligent Systems* **16**(4), 18–26.
- Carvalho, F. S. (2003), Simulação multiagentes de mercados de energia elétrica utilizando aprendizado por reforço: Uma abordagem distribuída, Master's thesis, Escola de Engenharia Elétrica e de Computação, Universidade Federal de Goiás, Goiânia, GO.
- Carvalho, F. S. & Vinhal, C. D. N. (2004), Temporal difference methods applied to thermoelectric energy markets: A distributed multi-agents approach, in 'XV Congresso Brasileiro de Automática (CBA 2004)', Gramado, RS.
- Cassady, R. (1967), *Auctions and Auctioneering*, University of California Press, Berkeley.
- Chella, A., Cossentino, M., Sabatucci, L. & Seidita, V. (2004), From PASSI to Agile PASSI: Tailoring a design process to meet new needs, in 'IEEE/WIC/ACM International Conference on Intelligent Agents (IAT'04)'.
- Chella, A., Cossentino, M., Sabatucci, L. & Seidita, V. (2006), 'Agile PASSI: An Agile process for designing agents', *Computer Systems Science and Engineering* **21**(2). Special Issue on Software Engineering for Multi-Agent Systems.
- Chen, H., Wong, K., Nguyen, D. & Chung, C. (2006), 'Analyzing oligopolistic electricity market using coevolutionary computation', *IEEE Transactions on Power Systems* **21**(1), 143–152.
- Cliff, D. (2003), 'Explorations in evolutionary design of online auction market mechanisms', *Electronic Commerce Research and Applications* **2**, 162–175.
- Cockburn, D. & Jennings, N. R. (1996), ARCHON: A distributed artificial intelligence system for industrial applications, in G. M. P. O'Hare & N. R. Jennings, eds, 'Foundations of Distributed Artificial Intelligence', Wiley, pp. 319–344.

- Cockburn, D., Varga, L. Z. & Jennings, N. R. (1992), Cooperating intelligent systems for electricity distribution, in 'Proc. Expert Systems 1992 (Applications Track)', Cambridge, UK.
- Coelho, R., Kulesza, U., von Staa, A. & Lucena, C. (2006), Unit testing in multi-agent systems using mock agents and aspects, in 'SELMAS '06: Proceedings of the 2006 international workshop on Software engineering for large-scale multi-agent systems', ACM Press, New York, NY, USA, pp. 83–90.
- Commoner, B. (1971), *L'Encerclement*, Seuil.
- Contreras, J., Candiles, O., de la Fuente, J. I. & Gómez, T. (2001), 'Auction design in day-ahead electricity markets', *IEEE Transactions on Power Systems* **16**(3), 409–417.
- Cordon, O., Gomide, F., Herrera, F., Hoffman, F. & Magdalena, L. (2004), 'Ten years of genetic fuzzy systems: current framework and new trends', *Fuzzy Sets and Systems* **141**(1), 5–31. Special Issue on Genetic Fuzzy Systems: New Developments.
- Cordón, O., Herrera, F., Hoffman, F. & Magdalena, L. (2001), *Genetic Fuzzy Systems: Evolutionary tuning and learning of fuzzy knowledge bases*, Vol. 19 of *Advances in Fuzzy Systems: Applications and Theory*, World Scientific, Singapore.
- Cordón, O., Herrera, F., Magdalena, L. & Villar, P. (2001), 'A genetic learning process for scaling the factors, granularity and contexts of the fuzzy rule-based system data base', *Information Sciences* **136**, 85–107.
- Cordón, O., Herrera, F. & Villar, P. (2001), 'Generating the knowledge base of a fuzzy rule-based system by the genetic learning of the data base', *IEEE Transactions on Fuzzy Systems* **9**(4), 667–674.
- Corera, J., Laresgoiti, I. & Jennings, N. R. (1996), 'Using archon, part 2: Electricity transportation management', *IEEE Expert* **11**(6), 71–79.
- Cossentino, M., Sabatucci, L. & Chella, A. (2003), A possible approach to the development of robotic multiagent systems, in 'IEEE/WIC IAT'03 Conference', Halifax, Canada, pp. 539–544.
- Dário, C. F. B. (2005), Uma metodologia unificada para o desenvolvimento de sistemas orientados a agentes, Master's thesis, FEEC, Unicamp, Campinas, SP.
- Darlin, D. (2006), 'Airlines made easy (or easier)', *The New York Times*. <http://www.nytimes.com/2006/07/01/business/01money.html>.
- David, A. K. & Wen, F. S. (2000), Strategic bidding in competitive electricity markets: A literature survey, in 'IEEE PES 2000 Summer Power Meeting', Vol. 4, IEEE Power Engineering Society, IEEE, Seattle, USA, pp. 2168–2173.

- Delgado, M. R. (2002), Projeto Automático de Sistemas Nebulosos: Uma Abordagem Co-Evolutiva, PhD thesis, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, SP.
- Delgado, M. R., Von Zuben, F. & Gomide, F. (2004), 'Coevolutionary genetic fuzzy systems: A hierarchical collaborative approach', *Fuzzy Sets and Systems* **141**(1), 89–106.
- Delgado, M. R., Zuben, F. V. & Gomide, F. (2001), 'Hierarchical Genetic Fuzzy Systems', *Information Sciences* **136**, 29–52.
- Dumas, M., Aldred, L., Governatori, G. & Ter Hofstede, A. H. M. (2005), 'Probabilistic automated bidding in multiple auctions', *Electronic Commerce Research* **5**, 25–49.
- Dutra, J. C. & Menezes, F. M. (2001a), Hybrid auctions I: Theory, Technical report, EPGE/FGV, Rio de Janeiro, RJ.
- Dutra, J. C. & Menezes, F. M. (2001b), Hybrid auctions II: Experimental evidence, Technical report, EPGE/FGV, Rio de Janeiro, RJ.
- El-Hawary, M. E. & Christensen, G. S. (1979), *Optimal Economic Operation of Electric Power Systems*, Vol. 142 of *Mathematics in Science and Engineering*, Academic Press, New York.
- Elmaghraby, W. J. (2005), 'Multi-unit auctions with complementarities: Issues of efficiency in electricity auctions', *European Journal of Operational Research* **166**(2), 430–448.
- Elmaghraby, W. J. & Oren, S. (1999), 'The efficiency of multi-unit electricity auctions', *Energy* **20**(4), 89–116.
- EME (2004), 'Portaria nº 121-EME'. Operações de Manutenção da Paz Sul 2005.
- Engelbrecht-Wiggans, R. (1980), 'Auctions and bidding models: A survey', *Management Science* **26**, 119–142.
- Etzioni, O., Tuchinda, R., Knoblock, C. A. & Yates, A. (2003), To buy or not to buy: Mining airfare data to minimize ticket purchase price, in 'SIGKDD'03 Proceedings of the ninth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining', ACM, Washington, DC, pp. 119–128.
- FERC (2003), Notice of white paper, Technical report, Federal Energy Regulatory Commission.
- Ferreira, W. D. (2002), Modelo multiagentes para determinação do comportamento estratégico em mercados de energia, Master's thesis, Escola de Engenharia Elétrica e de Computação, Universidade Federal de Goiás, Goiânia, GO.
- Ferreira, W. D. & Vinhal, C. D. N. (2002), A FIPA multi-agent framework for hydrothermal electricity generation market analysis, in 'V IEEE Induscon', Salvador, Bahia.

- Ferreira, W. D., Vinhal, C. D. N., Carvalho, F. & Lima, W. S. (2003), Análise estratégica de comercialização de energia utilizando modelos multi-agentes em sistemas hidrotérmicos, *in* ‘XVII SNPTEE Seminário Nacional de Produção e Transmissão de Energia Elétrica’, Vol. GAE, Uberlândia, MG.
- Ferreira, W. D., Vinhal, C. D. N. & Lima, W. S. (2002a), Modelo multiagentes para determinação do comportamento estratégico em mercados de energia, *in* ‘I Encontro Regional de Matemática Aplicada e Computacional (ERMAC 2002)’.
- Ferreira, W. D., Vinhal, C. D. N. & Lima, W. S. (2002b), A multi-agent framework based on game theory for strategic analysis of hydrothermal systems, *in* ‘XIV Congresso Brasileiro de Automática (CBA 2002)’, pp. 1804–1809.
- FIPA (2000), *FIPA 2000*, Foundation for Intelligent Physical Agents. <http://www.fipa.org/repository/fipa2000.html>.
- FIPA (2002a), *FIPA Agent Message Transport Service Specification (FIPA00067)*, Foundation for Intelligent Physical Agents. <http://www.fipa.org/specs/fipa00067/>.
- FIPA (2002b), *FIPA Communicative Act Library Specification (FIPA00037)*, Foundation for Intelligent Physical Agents. <http://www.fipa.org/specs/fipa00037/>.
- FIPA (2004), *FIPA Agent Management Specification (FIPA00023)*, Foundation for Intelligent Physical Agents. <http://www.fipa.org/specs/fipa00023/>.
- Freitas, E. N. A. (2006), DYNAMIS: Framework de simulação de mercados hidrotérmicos de energia com despacho centralizado baseado na tecnologia multiagentes, Master’s thesis, Escola de Engenharia Elétrica e de Computação, Universidade Federal de Goiás, Goiânia, GO.
- Friedman, D. (1993), The double auction market institution: A survey, *in* D. Friedman & J. Rust, eds, ‘The Double Auction Market: Institutions, Theories and Evidence’, Addison-Wesley Publishing, Reading, MA, pp. 3–26.
- Gamma, E. & Beck, K. (2000), ‘JUnit: A regression testing framework’, <http://www.junit.org>.
- Garcia, P., Giménez, E., Godo, L. & Rodríguez-Aguilar, J. A. (1999), Bidding strategies for trading agents in auction-based tournaments, *in* P. Noriega & C. Sierra, eds, ‘AMET-98’, Vol. 1571 of *Lecture Notes in Artificial Intelligence*, Springer, pp. 151–165.
- GCE (2002a), Relatório de progresso n^o 2, Technical report, Comitê de Revitalização do Setor Elétrico, Câmara de Gestão da Crise de Energia. <http://www.energiabrasil.gov.br>.
- GCE (2002b), Relatório de progresso n^o 3, Technical report, Comitê de Revitalização do Modelo do Setor Elétrico, Câmara de Gestão do da Crise de Energia. <http://www.energiabrasil.gov.br>.

- Genoud, C. (2003), Regulation as a game: The role of independent regulatory agencies in the regulatory process, *in* ‘CARR Risk and Regulation Research Student Conference’, London School of Economics and Political Science, London, UK.
- Geus, K., de Souza, A. M., Milsztajn, F., Kolb, C. J. J., Dometerco, J. H., Braga, C. C., Parolin, E. L., Frisch, A. C., Fortunato, Jr., L. K., Erzinger, Jr., A. & Jonack, M. A. (2006), Tecnologia multiagentes e um modelo para automação distribuída de subestações, *in* ‘Simpósio Brasileiro de Sistemas Elétricos’.
- Glorennec, P. (1996), Constrained optimization of FIS using an evolutionary method, *in* F. Herrera & J. L. Verdegay, eds, ‘Genetic Algorithms and Soft Computing’, Vol. 8 of *Studies in Fuzziness and Soft Computing*, Physica-Verlag, Wurzburg, pp. 349–368.
- Green, R. (2000), ‘Competition in generation: The economic foundations’, *Proceedings of the IEEE* **88**(2), 128–139.
- Greenwald, A., Jennings, N. R. & Stone, P. (2003), ‘Agents and markets’, *Intelligent Systems* **18**(6), 12–14.
- Greenwald, A. R. & Kephart, J. O. (1999), Shopbots and pricebots., *in* A. Moukas, C. Sierra & F. Ygge, eds, ‘Agent Mediated Electronic Commerce (IJCAI Workshop)’, Vol. 1788 of *Lecture Notes in Computer Science*, Springer, pp. 1–23.
- Griss, M. & Letsinger, R. (2000), Games at work - Agent mediated e-commerce simulation, *in* ‘Autonomous Agents 2000’, Barcelona, Spain. HP Laboratories Technical Report HPL-2000-52.
- Hanson, J. E. (2001), Cultivating the information economy, *in* ‘Proceedings of the Fifth International Symposium on Autonomous Decentralized Systems (ISADS-01)’, pp. 149–150.
- Harp, S. A., Brignone, S., Wollenberg, B. F. & Samad, T. (2000), ‘SEPIA: A simulator for electric power industry agents’, *IEEE Control Systems Magazine* **20**(4), 53–69.
- Haykin, S. (1999), Neurodynamic programming, *in* ‘Neural networks: A comprehensive foundation’, Prentice-Hall, chapter 12.
- Herrera, F., Lozano, M. & Verdegay, J. L. (1997), ‘Fuzzy connectives based crossover operators to model genetic algorithms population diversity’, *Fuzzy Sets and Systems* **92**(1), 21–30.
- Holland, J. H. (1986), Escaping brittleness: The possibilities of general-purpose learning algorithms applied to parallel rule-based systems, *in* R. S. Michalski, J. G. Carbonell & T. M. Mitchell, eds, ‘Machine Learning: An Artificial Intelligence Approach’, Vol. II, Morgan Kaufmann, Los Altos, CA.

- Hoschek, W. (1999), ‘Open source libraries for high performance scientific and technical computing in Java, Colt version 1.0.2’, <http://nicewww.cern.ch/~hoschek/colt/>.
- Hu, J. & Wellman, M. P. (2003), ‘Nash Q-learning for general-sum stochastic games’, *Journal of Machine Learning Research* **4**, 1039–1069.
- Huhns, M. N. & Stephens, L. M. (1999), Multiagent systems and societies of agents, in G. Weiss, ed., ‘Multiagent Systems: A Modern Approach to Distributed Artificial Intelligence’, MIT Press, Cambridge, Massachusetts, chapter 2.
- Huhns, M. N. & Vidal, J. M. (1999), ‘Online auctions’, *Internet Computing* pp. 103–105.
- Hunsberger, L. & Grosz, B. J. (2000), A combinatorial auction for collaborative planning, in ‘International Conference on Multi-Agent Systems (ICMAS-2000)’.
- IEE (2001), *International Conference on Intelligent System Application to Power Systems*, Budapest, Hungary.
- Ilic, M. & Skantze, P. (2000), ‘Electric power systems operation by decision and control’, *IEEE Control Systems Magazine* **20**(4), 25–39.
- Jang, J. S., Sun, C. T. & Mizutani, E. (1997), *Neuro-Fuzzy and Soft Computing*, Prentice Hall.
- Janssen, M. A. & Ostrom, E. (2006), Governing socio-ecological systems, in Tesfatsion & Judd (2006), chapter 15.
- Jennings, N. R. (2001), ‘An agent-based approach for building complex software systems’, *Communications of the ACM* **44**(4).
- Jennings, N. R. & Bussmann, S. (2003), ‘Agent-based control systems: Why are they suited to engineering complex systems?’, *IEEE Control Systems Magazine* **23**(3), 61–73.
- Jennings, N. R., Mamdani, E. H., Corera, J., Laresgoiti, I., Perriolat, F., Skarek, P. & Varga, L. Z. (1996), ‘Using ARCHON to develop real-word DAI applications: Part 1’, *IEEE Expert* **11**(6), 64–70.
- Jennings, N. R., Parsons, S., Sierra, C. & Faratin, P. (2000), Automated negotiation, in ‘Proceedings of the 5th International Conference on Practical Application of Intelligent Agents and Multi-Agent Systems (PAAM-2000)’, Manchester, UK.
- Jennings, N. R., Sycara, K. & Wooldridge, M. (1998), ‘A roadmap of agent research and development’, *Autonomous Agentes and Multi-Agent Systems* **1**(1), 7–38.
- Jennings, N. R. & Wittig, T. (1992), ARCHON: Theory and practice, in N. M. Avouris & L. Gasser, eds, ‘Distributed Artificial Intelligence: Theory and Praxis’, Kluwer Academic Press, pp. 179–195.

- Joskow, P. L. (2000), 'Why do we need electricity retailers? Or, can you get it cheaper wholesale?'.
Kephart, J. O. & Hanson, J. E. (2000), 'Dynamic pricing by software agents', *Computer Networks*
. <http://www.research.ibm.com/infoecon/>.
- Knublauch, H. (2002a), An Agile Development Methodology for Knowledge-Based Systems Including a Java Framework for Knowledge Modeling and Appropriate Tool Support, PhD thesis, Fakultät für Informatik, Universität Ulm, Berlin-Lichterfelde.
- Knublauch, H. (2002b), Extreme programming of multi-agent systems, in 'AAMAS '02: Proceedings of the first international joint conference on Autonomous agents and multiagent systems', ACM Press, New York, NY, USA, pp. 704–711.
- Knublauch, H., Koeth, H. & Rose, T. (2002), Agile development of a clinical multi-agent system: An extreme programming case study, in 'XP2002'.
- Kraus, S. (2001), Negotiations about how to reduce pollution, in 'Strategic Negotiation in Multiagent Environments', MIT Press, chapter 7.
- Laffont, J.-J. & Martimort, D. (2001), *The Theory of Incentives: The Principal-Agent Model*, Princeton University Press.
- Lanzotti, C. R., Masili, G. S., Silva, A. J. & Correia, P. B. (2003), Simulador de leilão para a comercialização de energia elétrica, in 'III Congresso Brasileiro de Regulação de Serviços Públicos', Gramado, RS.
- LBA (2006), Spatially explicit simulation model of deforestation for the amazon basin, Technical report, Centro de Sensoriamento Remoto. Experimento de Grande Escala da Biosfera-Atmosfera na Amazônia (Large-Scale Biosphere - Atmosphere Experiment in Amazonia, LBA), <http://www.csr.ufmg.br/simamazonia/>.
- Lima, W. & Freitas, E. N. A. (2006), A multi agent based simulator for Brazilian wholesale electricity energy market, in 'X Ibero-American Artificial Intelligence Conference, XVIII Brazilian Artificial Intelligence Symposium, IBERAMIA'2006/SBIA'2006', Vol. 4140 of *Lecture Notes in Computer Science*, Springer, Ribeirão Preto, SP, pp. 68–77.
- Lindo (2004), *Lingo 6.0*, Lindo Systems Inc., Chicago, IL, USA. <http://www.lindo.com>.
- Lipsman, A. (2006), 'comscore forecasts total e-commerce spending by consumers will reach approximately \$170 billion in 2006', <http://www.comscore.com/press/release.asp?press=959>.
- Littlechild, S. C. (2000), 'Why we need electricity retailers: A reply to Joskow on wholesale spot price pass-through'.

- Lomuscio, A. R., Wooldridge, M. & Jennings, N. R. (2001), A classification scheme for negotiation in electronic commerce, *in* F. Dignum & C. Sierra, eds, 'Agent Mediated Electronic Commerce, LNAI', Vol. 1991, pp. 19–33.
- Lomuscio, A. R., Wooldridge, M. & Jennings, N. R. (2003), 'A classification scheme for negotiation in electronic commerce', *International Journal of Group Decision and Negotiation* **12**(1), 31–56.
- Lyrio, G. H. S. O. & Seixas, R. B. (2006), Modelagem de forças de defesa baseada em agentes, *in* 'IX SPOLM Simpósio de Pesquisa Operacional e Logística da Marinha', Rio de Janeiro, RJ.
- Ma, Y., Bompard, E., Napoli, R. & Jiang, C. (2006), Modeling the strategic bidding of the producers in competitive electricity markets with the watkins' $Q(\lambda)$ reinforcement learning approach, Technical Report Working Paper 2, Hermes Ricerche, Moncalieri (TO), Italy. <http://www.hermesricerche.it>.
- Mackinnon, T., Freeman, S. & Craig, P. (2000), EndoTesting: Unit testing with Mock objects, *in* 'XP2000'.
- MAE (2000), *Regras da 1ª Etapa do MAE, Resolução ANEEL 290/2000, Apêndice D: Processo de Utilização dos Modelos de Otimização na Formação do Preço MAE*. <http://www.aneel.gov.br>.
- MAE (2004a), Cronograma, *in* MAE (2004c), chapter Anexo I. <http://www.ccee.org.br>.
- MAE (2004b), *Detalhamento da Sistemática do Leilão de Compra de Energia Elétrica Proveniente de Empreendimentos Existentes - 2004*. <http://www.ccee.org.br>.
- MAE (2004c), *Edital de Leilão nº 001/2004: Compra de Energia Elétrica Proveniente de Empreendimentos de Geração Existente*. <http://www.ccee.org.br>.
- MAE (2004d), *1º Leilão de Energia Existente: Vendedores Habilitados*. <http://www.ccee.org.br>.
- Marks, R. (2006), Market design using agent-based models, *in* Tesfatsion & Judd (2006), chapter 12.
- Martinez, L. (2001), Políticas de Controle Malha Fechada e Malha Aberta no Planejamento da Operação Energética de Sistemas Hidrotérmicos, PhD thesis, Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas.
- Masili, G. S. (2004), Metodologia e software para simulação de leilões de energia elétrica do mercado brasileiro, Master's thesis, Faculdade de Engenharia Mecânica, Unicamp, Campinas, SP.
- Matsumoto, M. & Nishimura, T. (1998), 'Mersenne Twister: A 623-dimensionally equidistributed uniform pseudorandom number generator', *ACM Transactions on Modeling and Computer Simulation* **8**(1), 3–30.

- Mattson, C., Lucarella, D. & Liu, C.-C. (2001), Modeling a competitor's bidding behavior using fuzzy inference networks, in *International Conference on Intelligent System Application to Power Systems* (IEE 2001).
- McAfee, R. P. & McMillan, J. (1987), 'Auctions and bidding', *Journal of Economic Literature* **25**, 699–738.
- McMillan, J. (2004), *A Reinvenção do Bazar: Uma história dos mercados*, Jorge Zahar, Rio de Janeiro, RJ.
- Michalewicz, Z. (1996), *Genetic Algorithms + Data Structures = Evolution Programs*, Springer-Verlag, Vienna, Austria.
- Milgrom, P. R. (1987), Auction theory, in T. Bewley, ed., 'Advances in Economic Theory: Fifth World Congress', Cambridge University Press, Cambridge.
- Milgrom, P. R. & Weber, R. J. (1982), 'A theory of auctions and competitive bidding', *Econometrica* **50**, 1089–1122.
- Mitchell, T. M. (1997), *Reinforcement Learning*, McGraw-Hill, New York, chapter 13.
- Monclar, F.-R. & Quatrain, R. (2001), Simulation of electricity markets: A multi-agent approach, in *International Conference on Intelligent System Application to Power Systems* (IEE 2001), pp. 207–212.
- Munhoz, F. C. (2004), Metodologia e *Software* para fixação de lances em leilões de energia elétrica, Master's thesis, Faculdade de Engenharia Mecânica, Unicamp, Campinas, SP.
- Naghibi-Sistani, M. B., Akbarazdeh-Tootoonchi, M. R., Bayaz, M. H. J.-D. & Rajabi-Mashhadi, H. (2006), 'Application of Q-learning with temperature variation for bidding strategies in market pool based power systems', *Energy Conversion and Management* **47**, 1529–1538.
- Nascimento, J. G. A. & Nunes, H. R. A. (2001), A utilização de instrumentos financeiros na gestão de riscos na comercialização de energia elétrica, in 'XVI SNPTEE Seminário Nacional de Produção e Transmissão de Energia Elétrica', Campinas, SP.
- Nicolaisen, J., Petrov, V. & Tesfatsion, L. (2001), 'Market power and efficiency in a computational electricity market with discriminatory double-auction pricing', *IEEE Transactions on Evolutionary Computing* **5**(5), 504–523.
- Niimura, T. & Nakashima, T. (2001), 'Deregulated electricity market data representation by fuzzy regression models', *IEEE Transactions on Systems, Man and Cybernetics, Part C: Applications and Reviews* **31**(3), 320–326.
- NRC (2002), 'NRC FuzzyJ Toolkit, version 1.3', http://ai.iit.nrc.ca/IR_public/fuzzy/.

- Odell, J., Parunak, H. V. D. & Bauer, B. (n.d.), *Representing Agent Interaction Protocols in UML*.
- Oliveira, E., Camacho, R. & Ramos, C. (1991), 'A multi-agent environment in robotics', *Robotica* **9**, 431–440.
- Oliveira, G. & Soares, S. (1995), 'A second order network flow algorithm for hydrothermal scheduling', *IEEE Transactions on Power Systems* **10**(3), 1635–1641.
- ONS (2002), 'Operador Nacional do Sistema, Brazilian ISO', <http://www.ons.org.br>.
- Passet, R. (1996), *L'Économique et le Vivant*, Economica, Paris, France.
- Pedrycz, W. & Gomide, F. (1998), *An Introduction to Fuzzy Sets: Analysis and Design*, MIT Press.
- Pereira, M., Campodónico, N. & Kelman, R. (1998), Long term hydro scheduling based on stochastic models, in 'Proceedings of the EPSOM'98', Zurich.
- Perriolat, F., Skarek, P., Varga, L. Z. & Jennings, N. R. (1996), 'Using archon, part 3: Particle accelerator control', *IEEE Expert* **11**(6), 80–86.
- Phelps, S. G., Parsons, S., McBurney, P. & Sklar, E. (2002), Co-evolution of auction mechanisms and trading strategies: Towards a novel approach to microeconomic design, in 'Proceedings of the 2nd Workshop on Evolutionary Computation and Multi-Agent Systems', New York, NY.
- Praça, I., Ramos, C., Vale, Z. & Cordeiro, M. (2003a), 'MASCEM: A multiagent system that simulates competitive electricity markets', *IEEE Intelligent Systems* **18**(6), 54–60.
- Praça, I., Ramos, C., Vale, Z. & Cordeiro, M. (2003b), A new agent-based framework for the simulation of electricity markets, in 'Proceedings of the IEEE/WIC International Conference on Intelligent Agents (IAT'03)', IEEE, Halifax, Canada, pp. 1931–1938.
- PSR (1998), Overview of the Brazilian regulatory framework, Technical Report 39/98, PSRI, Rio de Janeiro, RJ. <http://www.psr-inc.com>.
- Rehtanz, C. (2003), *Autonomous Systems and Intelligent Agents in Power System Control and Operation*, Springer.
- Reis, D., Melo, A., Coelho, A. L. V. & Furtado, V. (2006), GAPatrol: An evolutionary multiagent approach for the automatic definition of hotspots and patrol routes, in 'X Ibero-American Artificial Intelligence Conference, XVIII Brazilian Artificial Intelligence Symposium, IBERAMIA'2006/SBIA'2006', Vol. 4140 of *Lecture Notes in Computer Science*, Springer, Ribeirão Preto, SP, pp. 118–127.
- Richter, C. W. & Sheblé, G. B. (1997), Building fuzzy bidding strategies for the competitive generator, in 'North American Power Symposium', Laramie, Wyoming, USA.

- Richter, Jr., C. W. & Sheblé, G. B. (1998), ‘Genetic algorithm evolution of utility bidding strategies for the competitive marketplace’, *IEEE Transactions on Power Systems* **13**(1), 256–261.
- Richter, Jr., C. W., Sheblé, G. B. & Ashlock, D. (1999), ‘Comprehensive bidding strategies with genetic programming/finite state automata’, *IEEE Transactions on Power Systems* **14**(4), 1207–1212.
- Rosa, L. P., Tolmasquim, M. T. & Pires, J. C. L. (1998), *A Reforma do Setor Elétrico no Brasil e no Mundo: Uma Visão Crítica*, Relume Dumará, Rio de Janeiro, RJ.
- Rudnick, H. (1996), ‘Pioneering electricity reform in South America’, *IEEE Spectrum* pp. 38–44.
- Russel, S. & Norvig, P. (2004), *Inteligência Artificial*, tradução da segunda edição edn, Campus.
- Sandholm, T. (2000), eMediator: A next generation electronic commerce server, in ‘Fourth International Conference on Autonomous Agents’.
- Searle, J. R. (1969), *Speech Acts: An Essay in the Philosophy of Language*, Cambridge University Press.
- Shoham, Y. (1993), ‘Agent-oriented programming’, *Artificial Intelligence* **60**, 51–92.
- Shoham, Y. (1997), An overview of agent-oriented programming, in J. M. Bradshaw, ed., ‘Software Agents’, AAAI Press.
- Silva, C., Wollenberg, B. F. & Zheng, C. Z. (2001), ‘Application of mechanism design to electric power markets’, *IEEE Transactions on Power Systems* **16**(4), 862–869.
- Simon, H. A. (1979), From substantive to procedural rationality, in F. Hahn & M. Hollis, eds, ‘Philosophy and Economic Theory’, Oxford University Press, pp. 65–86.
- Soares, Filho, B. S., Cerqueira, G. C. & Pennachin, C. L. (2002), ‘DINAMICA a stochastic cellular automata model designed to simulate the landscape dynamics in an amazonian colonization frontier’, *Ecological Modelling* **154**(3), 217–235.
- Sugeno, M. & Yasukawa, T. (1993), ‘A fuzzy-logic-based approach to qualitative modeling’, *IEEE Transactions on Fuzzy Systems* **1**(1), 7–31.
- Takagi, T. & Sugeno, M. (1985), ‘Fuzzy identification of systems and its application to modeling and control’, *IEEE Transactions on Systems, Man, and Cybernetics* **15**(1), 116–132.
- Tesauro, G. (2000), Pricing in agent economies using neural networks and multi-agent Q-learning, in R. Sun & C. L. Giles, eds, ‘Sequence Learning’, Vol. 1828 of *Lecture Notes in Artificial Intelligence*, Springer, pp. 288–307.

- Tesfatsion, L. (2001a), ‘Special double issue: Agent-based Computational Economics (ACE)’, *Journal of Economic Dynamics and Control* **25**(3–4).
- Tesfatsion, L. (2001b), ‘Special issue on Agent-based Modeling of Evolutionary Economic Systems’, *IEEE Transactions on Evolutionary Computation* **5**(5).
- Tesfatsion, L. (2002), ‘Agent-based computational economics: Growing economies from the bottom up’, *Artificial Life* **8**(1), 55–82.
- Tesfatsion, L. & Judd, K. L., eds (2006), *Handbook of Computational Economics: Agent-Based Computational Economics*, Vol. 2 of *Handbooks in Economics*, North Holland.
- Varga, L. Z., Jennings, N. R. & Cockburn, D. (1994), ‘Integrating intelligent systems into a cooperating community for electricity distribution management’, *International Journal of Expert Systems with Applications* **7**(4), 563–579.
- Vargas, P. A. (2005), *Sistemas Computacionais Bio-Inspirados: Síntese e Aplicação em Inteligência Computacional e Homeostase Artificial*, PhD thesis, Faculdade de Engenharia Elétrica e de Computação, Unicamp, Campinas, SP.
- Vicari, R. M. & Giraffa, L. M. M. (2003), Fundamentos dos sistemas tutores inteligentes, in D. Barone, ed., ‘Sociedades Artificiais: A Nova Fronteira da Inteligência nas Máquinas’, Bookman, Porto Alegre, RS, chapter 7.
- Vieira, J. P. (2005), *Energia Elétrica Como Antimercadoria e sua Metamorfose no Brasil: A Reestruturação do Setor e as Revisões Tarifárias*, PhD thesis, EP/FEA/IEE/IF, USP, São Paulo, SP.
- Vinhal, C. D. N., Carvalho, F. S. & Lima, W. S. (2004), Modelo multiagentes com aprendizado por reforço para análise de mercados de energia elétrica, in ‘IX Simpósio de Especialistas em Planejamento da Operação e Expansão Elétrica - SEPOPE 2004’.
- Visudhipan, P. & Ilic, M. (1999), Dynamic games-based modeling of electricity markets, in ‘IEEE Power Engineering Society Winter Meeting’, Vol. 1, IEEE, New York City, NY, USA, pp. 274–281.
- Walter, I. & Gomide, F. (2003a), Evolving fuzzy bidding strategies in competitive electricity markets, in ‘IEEE International Conference on Systems, Man and Cybernetics SMC 2003’, Vol. 4, IEEE, Washington D.C., USA, pp. 3976–3981.
- Walter, I. & Gomide, F. (2003b), Genetic fuzzy systems to evolve coordination strategies in competitive distributed systems, in ‘Third EUSFLAT International Conference in Fuzzy Logic and Technology’, European Society for Fuzzy Logic and Technology (EUSFLAT), Zittau, Germany, pp. 114–119.

- Walter, I. & Gomide, F. (2004), Evolução de estratégias nebulosas de oferta em mercados competitivos de eletricidade, *in* ‘Congresso Brasileiro de Automática (CBA)’, Gramado, RS.
- Walter, I. & Gomide, F. (2006), ‘Design of coordination strategies in multiagent systems via genetic fuzzy systems’, *Soft Computing* **10**(10), 903–915. Special Issue: New Trends in the Design of Fuzzy Systems.
- Walter, I. & Gomide, F. (2007), ‘Genetic fuzzy systems to evolve coordination strategies in multi-agent systems’, *International Journal of Intelligent Systems* **22**(9), 971–991. Special Issue on Genetic Fuzzy Systems.
- Walter, I., Takahashi, L., Correia, P. B. & Gomide, F. (2006), Aprendizado de agentes no leilão de energia elétrica, *in* Camargo et al. (2006).
- Watkins, C. & Dayan, P. (1992), ‘Q-learning’, *Machine Learning* **8**, 279–292.
- Watkins, C. J. C. H. (1989), Learning from Delayed Rewards, PhD thesis, University of Cambridge, England.
- Wellman, M. P. (1993), ‘A market-oriented programming environment and its application to distributed multicommodity flow problems’, *Journal of Artificial Intelligence Research* **1**(1), 1–23.
- Wen, F. S. & David, A. K. (2001), ‘Strategic bidding for electricity supply in a day-ahead energy market’, *Electric Power Systems Research* **59**, 197–206.
- Widjaja, M., Sugianto, L. F. & Morrison, R. E. (2001), Fuzzy model of generator bidding system in competitive electricity markets, *in* ‘10th IEEE International Conference on Fuzzy Systems’, Vol. 3, IEEE, Melbourne, Australia, pp. 1396 – 1399.
- Wilson, S. W. (1995), ‘Classifier fitness based on accuracy’, *Evolutionary Computation* **3**(2), 149–175.
- Wolak, F. A. (2000), An empirical analysis of the impact of hedge contracts on bidding behavior in a competitive electricity market, *in* ‘Fourth Annual Power Research Conference’, Berkeley, CA. <http://www.stanford.edu/~wolak>.
- Wooldridge, M. (2002), *An Introduction to MultiAgent Systems*, Wiley.
- Wooldridge, M. & Jennings, N. R. (1995), ‘Intelligent agents: Theory and practice’, *The Knowledge Engineering Review* **10**(2), 115–152.
- Wooldridge, M., Jennings, N. R. & Kinny, D. (2000), ‘The Gaia methodology for Agent-Oriented analysis and design’, *Journal of Autonomous Agents and Multi-Agents Systems* **3**(3), 285–312.
- Wurman, P. R., Wellman, M. P. & Walsh, W. E. (2001), ‘A parametrization of the auction design space’, *Games and Economic Behavior* **35**, 304–338.

- Xiong, G., Hashiyama, T. & Okuma, S. (2002a), An electricity supplier bidding strategy through q-learning, *in* 'Power Engineering Society Summer Meeting', Vol. 3, IEEE, pp. 1516–1521.
- Xiong, G., Hashiyama, T. & Okuma, S. (2002b), An evolutionary computation for supplier bidding strategy in electricity auction market, *in* 'IEEE Power Engineering Society Transmission and Distribution Conference', Vol. 1, IEEE, Yokohama, Japan, pp. 83–88.
- Xiong, G., Okuma, S. & Fujita, H. (2004), Multi-agent based experiments on uniform price and pay-as-bid electricity auction markets, *in* '2004 IEEE International Conference on Electricity Utility Deregulation, Restructuring and Power Technologies (DRPT2004)', Hong Kong, pp. 72–76.
- Yager, R. R. (1998), On the solution of simultaneous fuzzy models, *in* 'IEEE International Conference on Fuzzy Systems', Vol. 2, Anchorage, AK, USA, pp. 956–960.
- Yager, R. R. (2000), 'Simultaneous solution of fuzzy models: an application to economic equilibrium analysis', *Fuzzy Sets and Systems* **115**(2), 339–349.
- Ygge, F. (1999), Energy resellers — An endangered species?, Technical Report EnS 99:02, EnerSearch AB, Gothenburg, Sweden. <http://www.enersearch.se/ygge>.