

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DO PARANÁ  
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA**

**EMERSON ROMANHUKI**

**APRENDIZAGEM DE POLÍTICAS DE OFERTA DE  
NEGOCIAÇÃO ENTRE AGENTES COGNITIVOS.**

**PÓS-GRADUAÇÃO EM INFORMÁTICA  
DISSERTAÇÃO DE MESTRADO**

**CURITIBA**

**2008**

**EMERSON ROMANHUKI**

**APRENDIZAGEM DE POLÍTICAS DE OFERTA DE  
NEGOCIAÇÃO ENTRE AGENTES COGNITIVOS.**

Dissertação apresentada ao Programa de Pós-Graduação em Informática da Pontifícia Universidade Católica do Paraná – Centro de Ciências Exatas e de Tecnologia, como parte dos requisitos para a obtenção do título de Mestre em Informática.

Área de Concentração: *Sistemas Inteligentes.*

Orientador: Prof. Dr. Edson Emílio Scalabrin

**CURITIBA**

**2008**

Dados da Catalogação na Publicação  
Pontifícia Universidade Católica do Paraná  
Sistema Integrado de Bibliotecas – SIBI/PUCPR  
Biblioteca Central

Romanhuki, Emerson  
R758a      Aprendizagem de políticas de oferta de negociação entre agentes  
2008      cognitivos / Emerson Romanhuki ; orientador, Edson Emílio Scalabrin. – 2008.  
            xiii, 87 f. : il. ; 30 cm

            Dissertação (mestrado) – Pontifícia Universidade Católica do Paraná,  
            Curitiba, 2008  
            Bibliografia f. 80-87

            1. Programação (Computadores) . 2. Algoritmos genéticos. 3. Programação  
            genética. I. Scalabrin, Edson Emílio. II. Pontifícia Universidade Católica do  
            Paraná. Programa de Pós-Graduação em Informática. III. Título.

CDD 20. ed. – 005.1



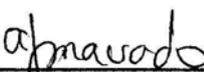
**ATA DE DEFESA DE DISSERTAÇÃO DE MESTRADO  
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA**

**DEFESA DE DISSERTAÇÃO Nº 06/2008**

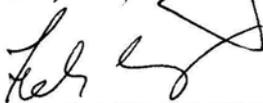
Aos 13 dias do mês de março de 2008 realizou-se a sessão pública de Defesa da Dissertação **“Aprendizagem de Políticas de Oferta de Negociação entre Agentes Cognitivos”**, apresentada pelo aluno **Emerson Romanhuki** como requisito parcial para a obtenção do título de **Mestre em Informática**, perante uma Banca Examinadora composta pelos seguintes membros:

Prof. Dr. Edson Emílio Scalabrin  
PUCPR (Orientador)

  
\_\_\_\_\_  
(assinatura)

  
\_\_\_\_\_  
(aprov/reprov.)

Prof. Dr. Fabrício Enembreck  
PUCPR

  
\_\_\_\_\_  
(assinatura)

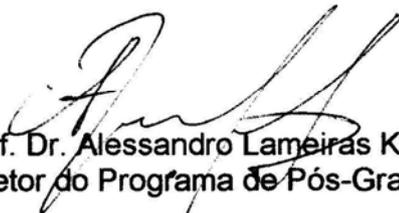
  
\_\_\_\_\_  
(aprov/reprov.)

Dr. Milton Pires Ramos  
TECPAR

  
\_\_\_\_\_  
(assinatura)

  
\_\_\_\_\_  
(aprov/reprov.)

Conforme as normas regimentais do PPGIa e da PUCPR, o trabalho apresentado foi considerado aprovado (aprovado/reprovado), segundo avaliação da maioria dos membros desta Banca Examinadora. Este resultado está condicionado ao cumprimento integral das solicitações da Banca Examinadora registradas no Livro de Defesas do programa.

  
Prof. Dr. Alessandro Lameiras Koerich  
Diretor do Programa de Pós-Graduação em Informática



### ***Dedicatória***

Dedico este trabalho a Deus, ao meu pai,  
A minha família e a todos que me  
Ajudaram e apoiaram

## Agradecimentos

Agradeço primeiramente a Deus por ter me guiado neste caminho. Agradeço aos professores do Programa de Pós-Graduação em Informática (PPGIa) em especial ao professor Dr. Fabrício Enembreck pelo apoio, incentivo e sugestões, ao professor Dr. Bráulio Coelho Ávila, ao professor Dr. Julio Nievola pelas longas discussões e principalmente ao orientador professor Dr. Edson Emílio Scalabrin por ter me auxiliado neste período.

Agradeço também aos meus familiares em especial a minha mãe. Agradecimento especial aos colegas:

- Marcio Fuckner pelo auxílio nas discussões dos trabalhos;
- Professora Elaine Angelotti por ter me colocado no caminho;
- Agradecimento especial à professora Dra. Deborah Ribeiro Carvalho por ter me despertado interesse pelo assunto e pelo incentivo;
- Nara Cunha pelo incentivo, apoio e ajuda em vários momentos;

# Sumário

<b>Agradecimento</b> .....	v
<b>Sumário</b> .....	vi
<b>Lista de Figuras</b> .....	ix
<b>Lista de Tabelas</b> .....	x
<b>Lista de Algoritmos</b> .....	xi
<b>Resumo</b> .....	xii
<b>Abstract</b> .....	xiii
<b>CAPÍTULO 1</b> .....	<b>14</b>
<b>INTRODUÇÃO</b> .....	<b>14</b>
1.1    Objetivos.....	15
1.2    Motivação .....	16
1.3    Organização .....	17
<b>CAPÍTULO 2</b> .....	<b>18</b>
<b>NEGOCIAÇÃO E APRENDIZAGEM EM SISTEMA MULTI-AGENTE</b> .....	<b>18</b>
2.1    Introdução.....	18
2.2    Tipos de Negociação .....	19
2.2.1    Negociação Bilateral .....	19
2.2.2    Negociação Multilateral .....	22
2.3    Táticas de Negociação.....	23
2.3.1    Tática Dependente do Tempo.....	24
2.3.2    Tática Dependente do Recurso.....	27
2.3.3    Táticas Imitativas.....	28
2.4    Negociação em Ambiente Multi-Agente.....	30
2.5    Negociação com Aprendizagem.....	33
2.5.1    Resumo dos Trabalhos .....	37
2.6    Considerações Finais .....	38

<b>CAPÍTULO 3</b> .....	<b>39</b>
<b>APRENDIZAGEM COM ALGORITMOS GENÉTICOS</b> .....	<b>39</b>
3.1    Introdução .....	39
3.2    Algoritmos Genéticos .....	39
3.2.1    População .....	42
3.2.2    Função de Aptidão .....	43
3.2.3    Métodos de Seleção .....	43
3.2.4    Operadores Genéticos .....	45
3.3    Considerações Finais .....	46
<b>CAPÍTULO 4</b> .....	<b>48</b>
<b>APRENDIZAGEM NA NEGOCIAÇÃO</b> .....	<b>48</b>
4.1    Introdução .....	48
4.2    Processo de Negociação .....	49
4.2.1    Arquitetura do Ambiente de Negociação .....	50
4.2.2    Configuração de uma Sessão de Negociação .....	54
4.2.3    Táticas de Negociação .....	59
4.2.4    Cálculo da Satisfação .....	59
4.2.5    Ferramentas Auxiliares da Negociação .....	60
4.3    Processo de Aprendizagem .....	60
4.3.1    Arquitetura do Processo de Aprendizagem .....	61
4.3.2    Representação do Indivíduo .....	63
4.3.3    Critério de Seleção .....	63
4.3.4    Função de Avaliação .....	64
4.3.5    Operador de Cruzamento e Mutação .....	64
4.3.6    Representação do processo de aprendizagem .....	65
4.4    Considerações Finais .....	67
<b>CAPÍTULO 5</b> .....	<b>68</b>
<b>EXPERIMENTOS E AVALIAÇÃO DOS RESULTADOS</b> .....	<b>68</b>
5.1    Introdução .....	68
5.2    Configuração dos Experimentos .....	68
5.2.1    Parâmetros de Negociação .....	68

5.2.2	Parâmetros das Táticas de Negociação.....	69
5.2.3	Parâmetros do Método de Aprendizagem .....	70
5.3	Avaliação dos Resultados.....	71
5.3.1	Cenário I .....	72
5.3.2	Cenário II.....	73
5.3.3	Cenário III .....	74
5.4	Considerações Finais .....	76
<b>CAPÍTULO 6.....</b>		<b>77</b>
<b>CONCLUSÕES E TRABALHOS FUTUROS.....</b>		<b>77</b>
6.1	Discussão .....	77
6.2	Conclusão .....	78
6.3	Trabalhos Futuros .....	79
<b>CAPÍTULO 7.....</b>		<b>80</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>		<b>80</b>

## Lista de Figuras

Figura 1: Divisão dos tipos de negociação.....	19
Figura 2: Processo da negociação bilateral.....	20
Figura 3: Processo da negociação bilateral para compra de CD.....	21
Figura 4: Gráfico comparativo entre as funções de geração de oferta.....	26
Figura 5: Comparação gráfica entre Boulware, Conceder e Linear.....	27
Figura 6: Estrutura básica de um algoritmo genético.....	42
Figura 7: Exemplo do Método da Roleta.....	44
Figura 8: Cruzamento de 1 ponto.....	45
Figura 9: Cruzamento de 2 pontos.....	46
Figura 10: Arquitetura do ambiente de negociação (ROMANHUKI <i>et al.</i> , 2008).....	50
Figura 11: Arquitetura do agente negociador (ROMANHUKI <i>et al.</i> , 2008).....	51
Figura 12: Formato do arquivo de negociações.....	52
Figura 13: Modelo de interface de entrada de dados.....	54
Figura 14: Formato dos dados de entrada para os critérios de um produto.....	55
Figura 15: Formato dos dados de entrada para as estratégias de uma negociação.....	56
Figura 16: <i>Log</i> do fechamento da negociação.....	57
Figura 17: <i>Log</i> do fechamento da negociação.....	58
Figura 18: Arquitetura do Processo de Aprendizagem.....	62
Figura 19: Representação do Indivíduo.....	63
Figura 20: Representação do Processo de Aprendizagem.....	65
Figura 21: Satisfação dos Agentes Comprador e Vendedor – Cenário I.....	72
Figura 22: Conjunto de parâmetros obtidos no processo de aprendizagem.....	73
Figura 23: Satisfação do Agente Comprador e Vendedor – Cenário II.....	74
Figura 24: Satisfação do Agente Comprador e Vendedor – Cenário III.....	75

## Lista de Tabelas

Tabela 1: Valores de $\alpha$ polinomial e exponencial. ....	25
Tabela 2: Valores das ofertas do agente A para B.....	25
Tabela 3: Valores da tática dependente do recurso. ....	28
Tabela 4: Quadro comparativo dos trabalhos relacionados.....	37
Tabela 5: Parâmetros do Método de Aprendizagem. ....	57
Tabela 6: Valores de cálculo simulado de negociação.....	58
Tabela 7: Parâmetros da Negociação.....	69
Tabela 8: Parâmetros das Táticas de Negociação.....	70
Tabela 9: Parâmetros do Método de Aprendizagem. ....	71

## Lista de Algoritmos

Algoritmo 1: Rotina principal do processo de negociação.....	53
Algoritmo 2: Rotina de preparação da oferta. ....	53
Algoritmo 3: Rotina principal do processo de aprendizagem. ....	66
Algoritmo 4: Rotina principal do processo de geração de ofertas.....	66

## Resumo

Este trabalho apresenta uma abordagem para a geração pró-ativa de políticas de oferta e contra-ofertas em um processo de negociação bilateral entre agentes cognitivos utilizando técnicas de aprendizagem de máquina. As aplicações deste trabalho destinam-se a negociações comerciais de compra e venda de produtos e serviços. A abordagem se configura, à medida que cada participante de um processo de negociação consegue melhorar seu grau de satisfação utilizando conhecimentos obtidos a partir de experiências anteriores. Cada participante individualmente refina o seu conhecimento por meio da aplicação de algoritmo genético sobre sua base histórica de ofertas com objetivo de redefinir os parâmetros de configuração das estratégias e táticas. Esta abordagem foi testada em um ambiente simulado de negociação bilateral que envolveu um agente comprador e um agente vendedor. As discussões sobre os resultados confrontam diferentes sessões de negociações, onde os agentes utilizaram e não utilizaram os recursos de re-configuração de suas estratégias e táticas para geração das ofertas e contra-ofertas. Os valores da satisfação foram melhores quando ambos os participantes de uma sessão de negociação utilizaram a capacidade de aprendizagem e de adaptação. A aprendizagem do melhor conjunto parâmetros por meio de algoritmo genético revelou-se bastante apropriada.

Palavras-chaves: Agente Cognitivo, Negociação Bilateral, Algoritmo Genético.

## **Abstract**

This work proposes an approach to generate pro-active offer and counter-offers politics in a process of bilateral negotiations between cognitive agents with learning machine capacities. The applications of this work are destined to commercial negotiations to purchase and sale of products and services. The approach is configured, as each participant in a negotiation process can improve their satisfaction degree using knowledge obtained from previous experiences. Each participant individually refines their knowledge through the application of genetic algorithm on the historical dataset of offers with objective of redefine the parameters of configuration of the strategies and tactics. This approach was tested in a simulated bilateral negotiation environment, which involved a buyer agent and a seller agent. The discussions about the results confront different negotiations sessions, where the agents used and did not use the reconfiguration capabilities of their strategies and tactics to generation of offers and counter-offers. The values of the satisfaction were better when both participants of a negotiation session used the learning capacity and of adaptation. The learning of the best parameters group through genetic algorithm proved to be quite appropriate.

Key-words: Cognitive Agent, Bilateral Negotiation Model, Genetic Algorithm.

# Capítulo 1

---

## INTRODUÇÃO

O uso de conhecimento adquirido por meio do processo de mineração de dados vem crescendo de forma significativa nos últimos anos tanto na área comercial quanto na área científica (SANTOS *et al.*, 2005), (GAMBERGER *et al.*, 2002), (LANGLEY *et al.*, 1995). Isso se dá pelo grande avanço nos estudos, pesquisas e desenvolvimentos de algoritmos e aplicações na área de descoberta de conhecimento. Estes esforços têm contribuído para um processo de obtenção de conhecimentos mais confiáveis a partir de bases de dados, com respostas mais objetivas e em alguns casos de forma mais rápida. Com o crescimento das bases de dados, tanto em volume quanto em número e também pela necessidade de extração de informações confiáveis em unidades de tempo cada vez menores, o processo de descoberta de conhecimento tornou-se inviável sem o uso dessas ferramentas auxiliares. Estas ferramentas auxiliares buscam automatizar totalmente ou parcialmente o processo de descoberta de conhecimentos a partir de fontes de dados. Nesta linha, recentes estudos e práticas comerciais indicam um movimento de transferência da competência de algumas tomadas de decisão para programas de computadores. Uma dessas práticas são as negociações comerciais de produtos e serviços.

As negociações podem ser definidas como uma forma de tomada de decisão envolvendo duas ou mais partes, as quais não podem tomar decisões independentemente e são requisitadas a fazer concessões para chegarem a um acordo (KERSTEN *et al.*, 1991). Assim sendo, as negociações também podem ser delegadas a programas de computadores. Os programas que são incumbidos de realizar, de maneira autônoma, tarefas em lugar das pessoas são conhecidos por agentes de *software* (WOOLDRIGE *et al.*, 1995), (LESSER, 1998), (FERBER, 1999), (HORLING *et al.*, 2001), cujos modelos foram concebidos pela comunidade científica que se interessa, em particular, pela subárea da Inteligência Artificial denominada de Inteligência Artificial Distribuída (GASSER, 1989), (WERNER, 1989), (WEISS, 1999).

Pode-se encontrar, em Raiffa (1982), um procedimento para a realização da negociação integrativa ou colaborativa. Entretanto, para que tal procedimento seja possível, os

negociadores devem ser capazes de raciocinar, mesmo que inconscientemente, baseando-se em funções de utilidade ou de valor. Outra exigência é que tais funções tenham, no mínimo, dois atributos de decisão. Isto significa que para oferecer um produto, o vendedor deve possuir os conhecimentos iniciais sobre os produtos disponíveis e sobre o perfil inicial do cliente. Dentro da área da Ciência da Computação, este conhecimento pode ser atribuído a um vendedor artificial por meio de algoritmos de aprendizagem de máquina (BISHOP, 2007), (ALPAYDIN, 2004), (CARVALHO *et al.*, 2000), (FREITAS *et al.*, 1998), (MICHALSKI *et al.*, 1983) e descoberta de conhecimentos (MIERSWA *et al.*, 2006), (PENG *et al.*, 2006), (FAYYAD, 1996), (ADRIAANS *et al.*, 1996, p.158).

Dentre os diferentes métodos utilizados em aprendizagem de máquina estão os algoritmos genéticos que foram inspirados no processo de evolução genética. Os algoritmos genéticos constituem um conjunto de métodos adaptativos comumente usados na resolução de problemas de pesquisa e otimização (HOLLAND, 1975). Neste contexto, um problema de otimização caracteriza-se fundamentalmente em encontrar uma boa solução ou uma série de boas soluções em um número muito grande de possíveis soluções, chamado de espaço de busca. Em um algoritmo genético, cada solução do problema a ser resolvido corresponde a um indivíduo que, conseqüentemente, poderá passar pelo processo de evolução.

## 1.1 Objetivos

O objetivo geral deste trabalho é utilizar agentes de software capazes de negociar a compra e venda de produtos ou serviços de forma inteligente, baseando-se em técnicas de computação evolutiva e em um modelo de negociação bilateral com múltiplos critérios. A inteligência do sistema manifesta-se por meio da capacidade dos agentes de aprender a partir de suas experiências e de aplicar o que aprenderam de forma produtiva, dinâmica e autônoma.

Os objetivos específicos são:

- Estudar e selecionar um modelo de negociação capaz de automatizar a compra e venda de produtos ou serviços;
- Estudar e selecionar um método de aprendizagem de máquina que pode ser incorporado facilmente em um agente de software, dotando-o da capacidade de

aprender a partir de suas experiências e de aplicar o que aprendeu de forma produtiva, dinâmica e autônoma em negociações futuras;

- Avaliar, por meio da construção e experimentação de um ambiente de simulação da negociação bilateral multi-critério de compra e venda de produtos ou serviços, o desempenho dos agentes envolvidos em um processo de negociação.

Espera-se como resultado que os agentes, por serem dotados da capacidade de aprendizagem e utilização do conhecimento obtido, sejam capazes de realizar uma negociação cujo resultado, para ambos os papéis (vendedor e comprador), seja próximo ao *ganha-ganha* (RECK *et al.*, 1990), (SCHOONMAKER *et al.*, 1989). Sabendo-se que os objetivos dos participantes, em uma transação de compra e venda, são opostos, a obtenção do resultado *ganha-ganha* ocorre através da diminuição da margem do valor da satisfação de cada papel.

## 1.2 Motivação

Em geral as transações entre pessoas e/ou empresas no seu dia-a-dia envolve algum tipo de negociação. Requisitos de negociação como preço, qualidade e prazo de entrega são relevantes para fechar um negócio. No comércio tradicional, os parceiros comerciais fecham um acordo por meio de um processo de compra e venda de determinado produto. Isto acontece após todos os parâmetros, de ambos os lados, serem avaliados. Esta comunicação entre os participantes de uma negociação nem sempre é eficaz. Por exemplo, os pesos de cada parâmetro podem ser diferentes para cada participante, resultando em longas interações e até mesmo situações de impasse.

No comércio eletrônico, um grande crescimento foi observado nos últimos anos por diversas razões. Primeiramente, o número dos usuários da Internet cresce a cada ano de forma surpreendente chegando a 1 bilhão em 2006, conforme pesquisa da eMarketer (UOL, 2006). Um outro fator é o aumento no movimento financeiro que esta atividade fornece chegando a 1,08 bilhões de transações no Natal brasileiro no ano de 2007 (UOL, 2007). Finalmente, a facilidade e a conveniência fornecida pelas transações no mundo virtual também contribuem ao crescimento do comércio baseado na Internet. Os leilões são importantes e tradicionais mecanismos de mercado. Recentemente, leilões têm obtido cada vez mais espaço e popularidade no comércio eletrônico.

Muitos trabalhos já foram realizados para analisar, desenvolver e implementar modelos de negociação como (SHMEIL, 1999), (FARATIN *et al*, 1998), (MIA *et al*, 2005), (ZHANG *et al.*, 2006) e (KRAININ *et al*, 2007). A contribuição deste trabalho, dá-se pela utilização do algoritmo genético como ferramenta de aprendizagem de máquina em um ambiente de negociação bilateal. Esta implementação permite aos agentes aprenderem a partir de suas experiências em negociações passadas e aplicar o conhecimento obtido nas próximas negociações. O objetivo optarmos pelo algoritmo genético neste trabalho, deu-se pela necessidade de utilizarmos uma ferramenta de aprendizagem capaz de identificar a melhor estratégia negociação de forma qualitativas.

### **1.3 Organização**

Esta pesquisa está organizada em 7 capítulos. O primeiro capítulo apresenta uma breve introdução e os objetivos do trabalho. O capítulo 2 contém a fundamentação teórica sobre os assuntos negociação, aprendizagem em negociação e os trabalhos relacionados. O capítulo 3 apresenta o algoritmo genético como modelo de aprendizagem. A metodologia e arquitetura desenvolvida neste trabalho são apresentadas no capítulo 4. No capítulo 5 são apresentados os cenários de testes e os resultados obtidos. No capítulo 6 está a discussão, a conclusão e os trabalhos futuros. Por fim, o capítulo 7 mostra as referências bibliográficas.

## Capítulo 2

---

### NEGOCIAÇÃO E APRENDIZAGEM EM SISTEMA MULTI-AGENTE

#### 2.1 Introdução

A negociação é um processo que ocorre entre dois ou mais agentes, humanos ou virtuais, com objetivos contraditórios, onde eles buscam resolver as diferenças e chegar a um acordo comum (PRUITT, 1981). Em RAHWAN *et al.* (2002), negociação é o processo onde duas ou mais partes, com critérios, restrições e preferências específicas, chegam a um acordo comum nos termos da transação. Este acordo pode ser o valor de um bem, prazo de entrega, prazo de garantia ou outros serviços. A negociação entre os agentes virtuais inicia pela troca de mensagens de ofertas e contra-ofertas baseadas em um dado protocolo, que destina o estabelecimento dos limites e regras da negociação. O termo agente será usado para designar agente virtual ou de software.

A negociação é usada em processos de cooperação entre agentes, onde o foco está na delegação de tarefas específicas para cada agente e na resolução de conflitos. Este processo se dá através de diversas interações entre os agentes usando um protocolo formal de comunicação. A coordenação para a resolução de um problema concentra-se principalmente no controle de utilização de recursos. Já no caso de resolução de conflito, o objetivo é encontrar o estado da negociação que estabiliza a satisfação das partes envolvidas. O conceito de negociação é aplicado em diversas áreas da inteligência artificial como, por exemplo, fusão da informação e controle de alocação de recursos.

Este capítulo apresenta alguns elementos de negociação que foram utilizados em nossa metodologia, tais como: estratégias e táticas de negociação. Esta seção faz também uma análise de alguns trabalhos relacionados aos assuntos negociação e a aprendizagem em negociação. Em resumo, as próximas seções estão organizadas nos seguintes tópicos: tipos de negociação, táticas de negociação, negociação em ambiente multi-agente e negociação envolvendo computação evolutiva.

## 2.2 Tipos de Negociação

Dentre os diferentes tipos de negociação existentes, destacam-se a negociação bilateral e a negociação multilateral. A negociação bilateral caracteriza-se pelo envolvimento de apenas dois participantes. A negociação multilateral caracteriza-se pelo envolvimento de três ou mais participantes no processo. A Figura 1 ilustra a divisão entre os tipos de negociação.

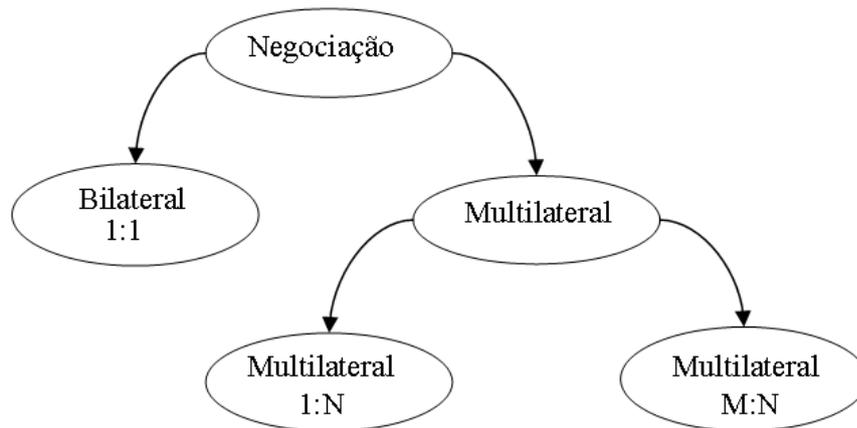


Figura 1: Divisão dos tipos de negociação.

A negociação 1:1, bilateral, é uma negociação simples entre um comprador e um vendedor. Já a negociação multilateral é tipicamente um processo de leilão. Neste tipo de negociação, as regras incorporam explicitamente mais de dois participantes em uma negociação, ou seja, mais de um participante com o papel de vendedor ou de comprador. Existem duas classificações no tipo de negociação multilateral: negociações 1:N, um para muitos, e negociações N:M, muitos para muitos. As negociações do tipo 1:N são tipicamente leilões nos quais um único fornecedor recebe ofertas de vários compradores que concorrem para fechar o negócio. As negociações do tipo N:M são espécies de leilão no qual vários vendedores e vários compradores participam fazendo suas propostas, que são casadas segundo determinadas regras pré-definidas.

### 2.2.1 Negociação Bilateral

Segundo Raiffa (1982) a negociação bilateral é um processo em que dois negociadores com desejos conflitantes trocam propostas na tentativa de atingir um acordo. Aqui, apenas

dois agentes participam do processo de negociação trocando oferta e contra-oferta. Estes agentes têm objetivos opostos e entram em processo de negociação para chegar a um acordo comum.

Cada agente tem uma lista de preferências que define o domínio da negociação. Esta lista inclui o limite inicial, o limite final e os possíveis valores/características que poderão ser utilizados durante o processo. De acordo com esta lista, o organizador, que pode ser um comprador, envia uma proposta para o respondente com um valor próximo ao limite inicial. O respondente, que pode ser um vendedor, pode aceitar a oferta ou enviar uma contra-oferta ao organizador. Este processo é executado iterativamente até que ambos entrem em comum acordo ou cancelem a operação caso o número de tentativas ou o tempo tenha excedido. O organizador e o respondente relaxam os valores de suas ofertas e contra-ofertas na direção do seu próprio limite final. A Figura 2 ilustra o processo de negociação bilateral em termos de limite inicial e final, bem como faixa de aceitação.

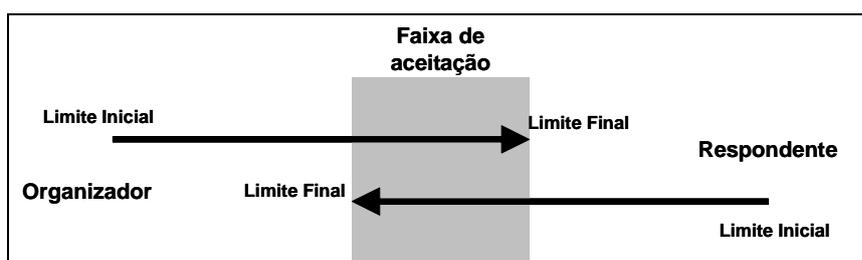


Figura 2: Processo da negociação bilateral.

Como pode ser observado na Figura 2, o acordo é alcançado quando ambos os agentes entram na faixa de aceitação. O fechamento do acordo torna-se impossível caso seja atingido o número de trocas de ofertas (iterações) pré-definidas sem que ambos os agentes esteja na faixa de aceitação.

Com base no modelo proposto em Raiffa (1982), o processo de negociação bilateral pode ser ilustrado no exemplo de uma compra de um CD cujo preço é o único atributo de negociação. Neste caso, um vendedor e um comprador irão iniciar um processo de negociação na tentativa de chegarem a um preço que satisfaça as condições de ambos. Suponha que o vendedor queira vender o CD por 30 reais, mas esteja disposto a vendê-lo por até 20 reais, nunca menos que isso. Suponha que o comprador pretenda pagar 15 reais pelo CD, mas esteja disposto a pagar até no máximo 25 reais. Estes valores são conhecidos como limites de

negociação e estão representados na Figura 3. Deve-se enfatizar que os valores dos limites da negociação são os piores valores que um agente pode conseguir em uma negociação, nesse caso 25 reais para o comprador e 15 reais para o vendedor.

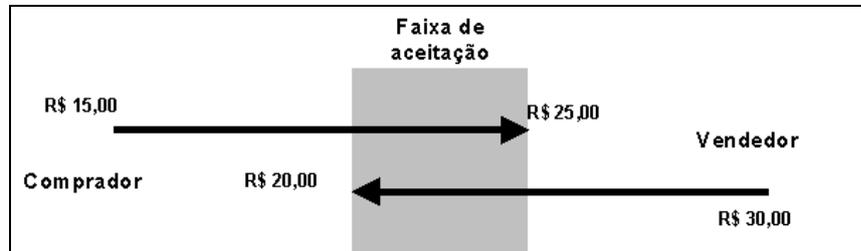


Figura 3: Processo da negociação bilateral para compra de CD.

Iniciada a negociação, o comprador irá propor o valor inicial de 15 reais e o vendedor irá propor o valor inicial de 30 reais. Com base nesses valores são geradas novas ofertas e contra-ofertas para comunicá-las ao seu oponente até que eles entrem em um acordo. É importante ressaltar que os negociadores não revelam o limite da negociação para os seus oponentes e nem a função de avaliação das propostas, ou seja, não é possível para os negociadores saberem o quanto exatamente eles devem ceder para alcançar um acordo ou mesmo se é possível alcançá-lo.

Um item a ressaltar no modelo de negociação proposto em Raiffa (1982) é a importância relativa que um agente atribui a cada critério de negociação. Tal importância que o agente  $i$  atribui a um item  $j$  é representada pelo vetor de pesos  $W_j^i$ . Assume-se que os pesos são normalizados, i.e.,  $\sum W_j^i = 1$  para todo  $i$  em  $\{a, b\}$ . A partir deste ponto é possível definir uma função de avaliação de um agente para uma determinada oferta. Sendo uma oferta representada por um vetor de valores  $x = (x_1, x_2, \dots, x_n)$  no espaço multidimensional definido pelos intervalos dos valores de caracterização dos itens sob negociação. Tal função é dada pelo cálculo da utilidade (ver F-2.1):

$$V^i(x) = \sum_{1 \leq j \leq n} W_j^i * V_j^i(x_j) \quad (\text{F-2.1})$$

Onde:

- $V_j^i(x_j)$  - é o valor da utilidade da oferta  $x$  para o agente  $i$  e o critério  $j$ .

O cálculo da utilidade da negociação é realizado por meio da função F-2.2. Como

cada critério da negociação tem limites diferentes, então a função F-2.2 é meio de como um agente pode consolidar as preferências individuais de cada critério.

$$V_j^i(x_j) = \frac{x_j - \min_j^i}{\max_j^i - \min_j^i} \quad (\text{F-2.2})$$

Onde:

- $\min_j^i$  - é o valor mínimo da negociação para o agente  $i$  e o critério  $j$ .
- $\max_j^i$  - é o valor máximo da negociação para o agente  $i$  e o critério  $j$ .

### 2.2.2 Negociação Multilateral

O tipo de negociação multilateral caracteriza-se pelo envolvimento de mais de dois agentes no processo, ou seja, mais de um participante com o papel de vendedor ou de comprador. As negociações multilaterais são tipicamente processos de leilão onde os participantes com o mesmo papel concorrem entre si. Neste tipo de negociação existe um mediador, chamado leiloeiro, responsável por definir quem será o ganhador, cumprindo as regras especificadas pelo protocolo. O objetivo do leiloeiro é vender um item e receber o maior pagamento possível, enquanto os participantes querem adquirir o item com o menor preço possível (HE *et al.*, 2003) (KERSTEN *et al.*, 2000) (ANTHONY *et al.*, 2001). Dentre os tipos de leilão existentes, destacam-se:

- **Leilão Inglês:** É um leilão de primeiro preço, lance aberto e ascendente. O leiloeiro começa sugerindo um preço de reserva pelo bem. Se os agentes não realizam nenhuma oferta, o bem é alocado ao leiloeiro por esse valor. Os agentes, em cada lance, realizam uma oferta maior que a última oferta realizada. As ofertas aumentam até que nenhum agente volta a realizar um lance. Nesse momento o bem é alocado ao agente que realizou a maior oferta.
- **Leilão Holandês:** O leilão holandês é um exemplo de leilão de primeiro preço, lance aberto e descendente. O leiloeiro começa ofertando o bem num valor artificialmente grande (maior ao valor privado esperado de qualquer agente). O leiloeiro continua diminuindo o preço da oferta por algum valor pequeno até que algum agente realize

uma oferta igual ao preço atual ofertado. O bem é alocado no agente que realizou a oferta.

- **Leilões de primeiro preço e lance fechado:** Os leilões deste tipo são de uma rodada. Nele, os participantes realizam somente um lance e o bem é alocado ao agente que realizou a maior oferta. Um problema com este tipo de leilão é que ao final, o ganhador pode considerar como dinheiro perdido a diferença entre sua oferta e a segunda melhor oferta. Portanto a estratégia é ofertar menos do que o valor privado procurando obter informação sobre as possíveis ofertas de outros agentes e assim evitar ofertar um valor muito pequeno.
- **Leilão Vickrey:** Este é um tipo de leilão de segundo preço e de lance fechado. Nele somente existe uma rodada e o bem é alocado ao agente que realizou a maior oferta. No entanto o preço pago pelo ganhador é o valor da segunda maior oferta.

### 2.3 Táticas de Negociação

As táticas de negociação são expressas na forma de conjuntos de funções que determinam como será calculado o valor de cada atributo usado na negociação. Existem diferentes tipos de funções, onde cada uma tem seu próprio comportamento (FARATIN *et al.*, 1998). Cada agente, organizador ou respondente, tem a sua própria tática codificada. Todavia, um agente pode ter, por exemplo, duas táticas, T1 e T2, e neste caso cada tática terá um peso diferente: i.e., um agente *A* inicia uma negociação com um valor \$5 para um atributo *j* cujo domínio é [\$0, \$25]. Um agente *B*, com o domínio [\$20, \$50] para o mesmo atributo *j*, faz uma contra-oferta de \$40. Na próxima proposta, o agente *A* oferece \$10. O agente *B* pode então seguir duas táticas: a primeira é continuar relaxando em \$10 conforme foi a sua própria estratégia na primeira contra-oferta e oferecer \$30, a segunda é seguir a estratégia do agente *A* e propor \$35 relaxando apenas \$5. Neste exemplo, se o agente *B* optar por utilizar ambas as táticas T1 e T2, definindo o peso de 3/4 para T1 e 1/4 para T2, então, neste caso, o valor da contra-oferta do agente *B* é \$33, obtido a partir da expressão  $((0,75 * 35) + (0,25 * 30))$ . Este processo continua até o final da negociação.

Em nossos experimentos, as funções para os cálculos das táticas são as mesmas utilizadas por FARATIN (1998). Algumas destas funções serão detalhadas a seguir.

### 2.3.1 Tática Dependente do Tempo

Na tática dependente do tempo, o fator predominante para decidir qual o valor da próxima oferta é o tempo. Este tipo de tática baseia seu comportamento no tempo restante para o encerramento de uma negociação e o agente tende a ceder mais rapidamente a medida que o limite de tempo da negociação se aproxima do fim (FARATIN *et al.*, 1998).

A oferta inicial é instanciada como sendo um ponto no domínio dos valores do atributo  $j$  da negociação, preço ou quantidade. Para definir tal ponto e, conseqüentemente calcular o valor a ser ofertado, faz-se uso da constante  $K_j^a$ . O valor da oferta é obtido por meio da fórmula F-2.3:

$$x_{a \rightarrow b}^t[j] = \begin{cases} \min_j^a + \alpha_j^a(t)(\max_j^a - \min_j^a) & V_j^a - \text{decreciente} \\ \min_j^a + (1 - \alpha_j^a(t))(\max_j^a - \min_j^a) & V_j^a - \text{crescente} \end{cases} \quad (\text{F-2.3})$$

Onde:

- $\min_j^a$  - é o valor mínimo da negociação para o agente A e o critério  $j$ .
- $\max_j^a$  - é o valor máximo da negociação para o agente A e o critério  $j$ .
- $\alpha_j^a$  - é valor da função exponencial ou polinomial e está entre 0 e 1.

A função  $\alpha(t)$  calcula a variação das ofertas no tempo  $t$ . Esta função pode ser polinomial (F-2.4) ou exponencial (F-2.5). O comportamento da função polinomial é relaxar os valores da negociação de forma constante e da função exponencial, ao contrário, é relaxar os valores de forma mais lenta no início da negociação e de forma mais rápida tendendo para o final. A seguir são apresentadas as funções polinomial e exponencial (FARATIN *et al.*, 1998).

Polinomial	$\alpha_t^a(t) = k_j^a + (1 - k_j^a) \left( \frac{\min(t, t_{\max}^a)}{t_{\max}^a} \right)^{\frac{1}{\beta}}$	(F-2.4)
------------	---	---------

Exponencial	$\alpha_t^a(t) = e^{\left( 1 - \frac{\min(t, t_{\max}^a)}{t_{\max}^a} \right)^{\beta} \ln k_j^a}$	(F-2.5)
-------------	---	---------

Onde:

- $k_j^a$  - é uma constante que determina o valor do critério  $j$  para ser oferecido na primeira proposta pelo agente  $A$ .
- $\beta$  - é a constante que determina o comportamento da negociação.
- $t$  - é o tempo da negociação.

A título de ilustração, dados os valores:  $B = 0,5$ ;  $\min^a_j = 1,8$ ;  $\max^a_j = 6,5$  e  $k_j^a = 0,1$ , a Tabela 1 mostra, para um conjunto de tempos  $t = 6$ , os  $\alpha$  para as funções  $\alpha$  polinomial e  $\alpha$  exponencial.

Tabela 1: Valores de  $\alpha$  polinomial e exponencial.

<b>tempo (t)</b>	<b><math>\alpha</math> Polinomial</b>	<b><math>\alpha</math> Exponencial</b>
0,00	0,10	0,10
0,20	0,14	0,13
0,40	0,24	0,17
0,60	0,42	0,23
0,80	0,68	0,36
1,00	1,00	1,00

A partir dos valores da Tabela 1 pode-se gerar as ofertas aplicando para tal a função F-2.3 (pág. 24). A Tabela 2 mostra, para o agente comprador, os valores das ofertas.

Tabela 2: Valores das ofertas do agente A para B.

<b>tempo (t)</b>	<b>Polinomial</b>	<b>Exponencial</b>
0,00	2,27	2,27
0,20	2,44	2,40
0,40	2,95	2,59
0,60	3,79	2,90
0,80	4,98	4,00
1,00	6,50	6,50

O gráfico da Figura 4 mostra as curvas para os valores calculados e mostrados na Tabela 2, tanto para função polinomial quanto para a função exponencial.

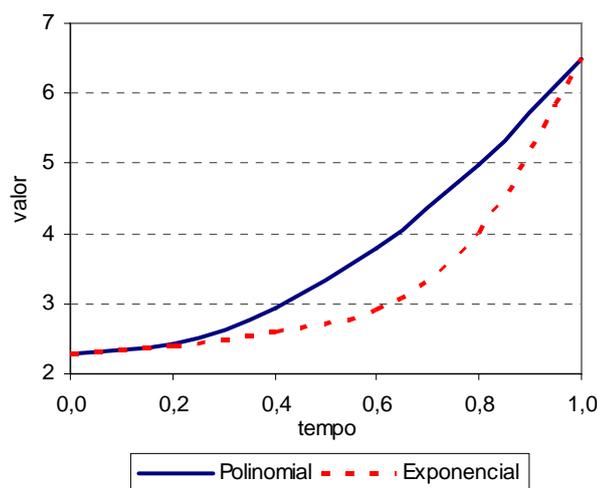


Figura 4: Gráfico comparativo entre as funções de geração de oferta.

Conforme descrito anteriormente, a função polinomial relaxa os valores de forma mais uniforme do início ao fim de uma negociação. Já a função exponencial mantém o valor da oferta e ao chegar próximo do final da negociação, relaxam-se os valores de forma mais rápida.

Na tática dependente do tempo, o comportamento da negociação é definido pela constante  $\beta$ . Existem três comportamentos para as funções  $\alpha(t)$ , a saber:

- **Boulware.** Este comportamento foi proposto por Lemuel Boulware (RAIFFA, 1982, p. 48). Ele assume uma oferta inicial e mantém a oferta até que o tempo de encerramento da negociação esteja quase esgotado. A partir daí, ele começa a relaxar até os valores limite das ofertas ( $\beta < 1$ ).
- **Linear.** Aqui as ofertas são calculadas linearmente do início até o fim da negociação ( $\beta = 1$ ).
- **Conceder.** Este comportamento foi proposto por Pruitt (1981, p.20). Ele inicia com uma oferta cujos valores estão próximos ao limite final da negociação. Ele relaxa os valores de contra-oferta em pequenas porções ( $\beta > 1$ ).

O gráfico da Figura 5 mostra os três comportamentos para as funções  $\alpha(t)$  citadas (FARATIN *et al.*, 1998).

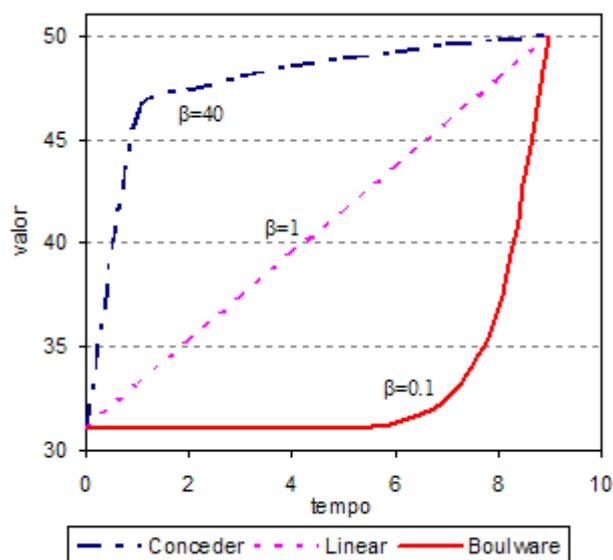


Figura 5: Comparação gráfica entre Boulware, Conceder e Linear.

Ao final do prazo da negociação, todos os agentes propõem seus valores pertencentes ao limite da negociação. Por exemplo, se o tempo da negociação estiver se aproximando do final, então existe uma urgência para o fechamento do negócio. Quando isso acontece, um agente, dependendo da estratégia, cede mais rapidamente para que a negociação seja acordada.

### 2.3.2 Tática Dependente do Recurso

A tática que depende do recurso é similar à tática dependente do tempo (FARATIN *et al.*, 1998). Em tese, a tática dependente do tempo pode ser vista como um tipo de tática dependente de recurso, onde o recurso considerado é o tempo. A tática dependente de recurso gera contra-ofertas dependendo de como um recurso está sendo utilizado. Os recursos podem ser: os valores que estão sendo trocados entre os agentes, o número de agentes interessados em uma negociação, o tempo de negociação, etc. Este comportamento é para que o agente torne-se, progressivamente, mais conciliador enquanto a quantidade de recursos diminui. Tal função pode ser expressa como mostra a fórmula F-2.6, para um agente  $A$  e um tempo  $t$ :

$$\alpha_j^a(t) = k_j^a + (1 - k_j^a) e^{-resource^a(t)} \quad (F-2.6)$$

Onde a função  $resource(t)$  mede a quantidade de recursos no tempo  $t$  para um agente A. As funções podem ser:

$$resource^a(t) = |N^a(t)| \quad (F-2.7)$$

$$resource^a(t) = \mu^a \frac{|N^a(t_c)|^2}{\sum_i |x_{i \leftrightarrow a}^{t_c}|} \quad (F-2.8)$$

$$resource^a(t) = \min(0, t - t^a_{max}) \quad (F-2.9)$$

No primeiro exemplo (F-2.7), o recurso é o número de agentes participantes na negociação. O segundo exemplo (F-2.8) utiliza o tempo como um recurso de maneira semelhante à tática *dependente do tempo*. Mais detalhes sobre este modelo são encontrados em (FARATIN *et al.*, 1998). O terceiro exemplo (F-2.9) também utiliza o tempo como recurso, mas neste caso a quantidade do recurso diminui de forma linear. A Tabela 3 mostra os valores das funções  $resource(t)$  e  $\alpha(t)$ , tendo o valor 0,1 para  $k_j^a$ .

Tabela 3: Valores da tática dependente do recurso.

tempo (t)	resource(t)	$\alpha(t)$
0,00	-1,00	2,55
0,20	-0,80	2,10
0,40	-0,60	1,74
0,60	-0,40	1,44
0,80	-0,20	1,20
1,00	0,00	1,00

Os valores desta tabela mostram que quando o tempo da negociação se aproxima do final a quantidade de recurso diminui.

### 2.3.3 Táticas Imitativas

Nas táticas *imitativas*, a contra-oferta do agente depende do comportamento do oponente (FARATIN *et al.*, 1998). Por exemplo, um agente A inicia uma negociação

sugerindo um valor \$10 para um atributo  $j$ . Um agente  $B$  recebe esta oferta e lança uma contra-oferta para o mesmo atributo com valor \$50. A segunda oferta enviada pelo agente  $A$  é de \$15, aumentando \$5. Neste tipo de tática, o agente  $B$  ao gerar uma contra-oferta imitará o relaxamento do agente  $A$  diminuindo também \$5, gerando uma contra-oferta de \$45.

Neste tipo de tática existem diferentes tipos de imitação, por exemplo, os valores das ofertas podem ser alterados proporcionalmente, em termos absolutos ou em termos da média de certo número de ofertas anteriores.

No tipo RELATIVE TIT-FOR-TAT, o agente reproduz, em percentual, o comportamento do oponente a  $\delta \geq 1$  passos anteriores. A condição para aplicar esta tática é  $n > 2\delta$ .

$$x_{a \rightarrow b}^{t_{n+1}}[j] = \min(\max(\frac{x_{b \rightarrow a}^{t_{n-2\delta}}[j]}{x_{b \rightarrow a}^{t_{n-2\delta+2}}[j]} x_{a \rightarrow b}^{t_{n-1}}[j], \min_j^a), \max_j^a) \quad (\text{F-2.10})$$

Onde:

- $x_{a \rightarrow b}^t$  - é uma oferta do agente  $A$  para  $B$  no tempo  $t$ .
- $\min_j^a$  - é o valor mínimo da negociação para o agente  $A$  e o critério  $j$ .
- $\max_j^a$  - é o valor máximo da negociação para o agente  $A$  e o critério  $j$ .
- $\delta$  - é o número de passos para trás que serão analisados.

O tipo RANDOM ABSOLUTE TIT-FOR-TAT, é parecido com o anterior, mas em termos absolutos. Isto significa que se um agente relaxar a oferta em £2 então o outro agente vai relaxar em £2 também.

$$x_{a \rightarrow b}^{t_{n+1}}[j] = \min(\max(x_{a \rightarrow b}^{t_{n-1}}[j] + (x_{b \rightarrow a}^{t_{n-2\delta}}[j] - x_{b \rightarrow a}^{t_{n-2\delta+2}}[j]) + (-1)^S R(M), \min_j^a), \max_j^a) \quad (\text{F-2.11})$$

Onde:

- $x_{a \rightarrow b}^t$  - é uma oferta do agente  $A$  para  $B$  no tempo  $t$ .
- $\min_j^a$  - é o valor mínimo da negociação para o agente  $A$  e o critério  $j$ .
- $\max_j^a$  - é o valor máximo da negociação para o agente  $A$  e o critério  $j$ .
- $\delta$  - é o número de passos para trás que serão analisados.
- $R(M)$  - é uma função que gera valor randômico no intervalo de  $[0, M]$ .

No tipo AVERAGE TIT-FOR-TAT, o agente calcula a média do percentual dos valores das ofertas. A condição para aplicar esta tática é  $n > 2\gamma$ .

$$x_{a \rightarrow b}^{t_{n+1}}[j] = \min(\max(\frac{x_{b \rightarrow a}^{t_{n-2\gamma}}[j]}{x_{b \rightarrow a}^{t_n}[j]} x_{a \rightarrow b}^{t_{n-1}}[j], \min_j^a), \max_j^a) \quad (\text{F-2.12})$$

Onde:

- $x_{a \rightarrow b}^t$  - é uma oferta do agente A para B no tempo  $t$ .
- $\min_j^a$  - é o valor mínimo da negociação para o agente A e o critério  $j$ .
- $\max_j^a$  - é o valor máximo da negociação para o agente A e o critério  $j$ .
- $\gamma$  - é o número de ofertas para calcular a média.

## 2.4 Negociação em Ambiente Multi-Agente

As negociações surgiram há muito tempo onde não existiam moedas e as mercadorias eram trocadas entre si, sem equivalência de valor. Após séculos de prática, o mercado evoluiu a ponto de duas pessoas geograficamente distantes conseguirem realizar uma transação comercial com sucesso. Entretanto, deseja-se ir além disso, fazendo com que agentes de software possam realizar transações comerciais cujos conflitos sejam resolvidos por processos sofisticados como a negociação. Para isso, muitos esforços em pesquisa foram realizados até o aparecimento de modelos e formas diferentes de implementar um processo de negociação em ambiente multi-agente.

Em (FARATIN *et al.*, 1998) pode-se encontrar uma representação formal de funções de decisão para um agente realizar negociações bilaterais. Segundo o mesmo autor, não é possível encontrar uma solução ótima para esse domínio, por isso é necessário criar um modelo para que um dado agente consiga acordos com seus oponentes, tentando sempre maximizar a sua própria função de avaliação/satisfação. O trabalho do Faratin considera que a negociação é "orientada a serviço" onde um agente (o cliente) requer a execução de um serviço a outro agente (o servidor). A negociação requer a determinação dos termos e condições do contrato. É importante notar que nesse modelo os agentes podem assumir dois papéis, que estão tipicamente em conflito, o de comprador e o de vendedor. Ou seja, os agentes possuem interesses opostos em qualquer uma das dimensões da negociação. Dessa forma existindo dois valores  $X$  e  $Y$  para um mesmo item sob negociação, tais que  $X \geq Y$ , as

avaliações do comprador e do vendedor devem sempre respeitar a regra  $V_c(X) \geq V_c(Y)$  somente se  $V_v(Y) \leq V_v(X)$  onde  $V_c$  é a utilidade do agente comprador e  $V_v$  é a utilidade do agente vendedor. No trabalho de FARATIN (1998) foi adotado o modelo de negociação multi-lateral e multi-dimensão. A negociação ocorre por meio de trocas de ofertas entre os agentes, os quais relaxam os valores se utilizando diversas táticas e estratégias baseadas, por exemplo, no tempo, na disponibilidade de recursos ou no comportamento dos oponentes de negociação. Após a definição do conjunto de variáveis sobre as quais eles vão negociar, o processo de negociação entre os agentes consiste de uma sucessão alternada de ofertas e contra-ofertas de valores para estas variáveis. Esse processo continua até que uma proposta seja aceita pelo oponente ou que um dos lados desista da negociação. Geralmente os agentes possuem um tempo limite para concluir a negociação ( $T_{max}$ ) e se um acordo não for alcançado dentro deste prazo os negociadores encerram a negociação. Os autores definiram um tempo comum representado por uma seqüência ordenada de instantes ( $t$ , iniciando em  $t_1=0$ ) e um meio de comunicação que não gera atrasos na transmissão das mensagens. Ou seja, o tempo de envio e recebimento de uma mensagem é sempre o mesmo. A arquitetura do agente é formada por: mecanismos de geração de ofertas, um mecanismo para interpretação de ofertas e uma função de avaliação de ofertas para negociação multi-critério. O mecanismo de interpretação de ofertas tem a finalidade de gerar uma contra-oferta em função da oferta recebida do oponente. Se o tempo máximo para concluir a negociação ( $T_{max}$ ) for alcançado sem que se tenha chegado a um acordo, o agente rejeita a oferta recebida. Caso o tempo limite ainda não tenha sido alcançado, o agente atribui um valor à oferta recebida dentro de uma escala de  $[0,1]$ , usando sua função de avaliação. Caso a avaliação da oferta recebida seja superior à avaliação da próxima que ele poderia propor, então ele aceita. Caso contrário, ele faz uma nova proposta. Segundo FARATIN (1998), a interpretação de uma oferta pode ser definida pela relação:

$$I^a(t', x_{b \rightarrow a}^t) = \begin{cases} \text{aceitar, se } t' > t_{max}^a \\ \text{rejeitar, se } V^a(x_{b \rightarrow a}^t) \geq V^a(x_{a \rightarrow b}^{t'}) \\ x_{a \rightarrow b}^{t'} \text{ caso contrário} \end{cases} \quad (\text{F-2.13})$$

Onde:

- $V^a(x_{b \rightarrow a}^t)$  - representa a avaliação que o agente  $a$  faz da oferta recebida do agente  $b$  no instante de tempo  $t$ .
- $V^a(x_{a \rightarrow b}^t)$  - é a próxima oferta que o agente iria propor.
- $t_{\max}^a$  - é o tempo máximo da negociação.
- $t'$  - é o tempo atual da negociação.

DE PAULA (2001) desenvolveu um modelo de negociação chamado RAP. Este modelo estende o modelo de Faratin, incluindo no modelo: sugestão de produto alternativo e envio de ultimato. No protocolo definido por esse modelo os agentes devem enviar uma proposta de ultimato antes de desistir da negociação. Isso impede que os negociadores sejam surpreendidos com a desistência do oponente e tenham sempre a última chance de fechar um negócio. Nesse modelo o agente não possui uma função específica de geração de ultimato e por isso utiliza suas próprias funções de geração de proposta para gerar o ultimato sempre que o tempo limite da negociação é ultrapassado.

Marcos Shmeil (SHMEIL, 1999) desenvolveu um modelo de negociação multilateral (1:N), onde a arquitetura é definida com agentes denominados organizadores e respondentes e uma base de conhecimento corporativa. Cada agente, tanto organizador quanto respondente, possui o seu próprio conjunto de valores de critérios. Estes valores são agrupados em três subconjuntos, a saber: os valores que satisfazem mais, os valores que satisfazem e os valores que satisfazem menos. Durante o processo de negociação, os agentes procuram manter os valores dentro da região que satisfaz mais, tentando obter a melhor satisfação. A geração da ofertas pelo organizador e as contra-ofertas pelo respondente, é baseada na estratégia decremental por oferta, e na tática de trocas. O conjunto dessas constitui uma sessão de negociação que só termina com a verificação do critério de parada. Os critérios de parada podem ser: o número de ofertas e contra-ofertas definidas ou a igualdade dos valores de todos os critérios ofertados em relação às contra-ofertas. Durante o processo de negociação é gerado um conjunto de exemplos resultado das ofertas e contra-ofertas entre os organizadores e os respondentes. Este conjunto de exemplos forma uma base de dados que é utilizada como fonte de dados para um processo de aprendizagem de máquina. No trabalho de Shmeil, a aprendizagem foi feita sobre a base de dados do organizador o qual aplica o algoritmo de indução ID3 (Quinlan, 1979) (Quinlan, 1993).

Baseado no modelo de FARATIN *et al.* (1998), Geber Ramalho e seus colaboradores (RAMALHO *et al.*, 2003), desenvolveram um modelo de negociação bilateral para o comércio eletrônico. Nesse modelo foram adicionadas algumas facilidades tais como: sugestão de produtos alternativos; ultimato na geração da proposta e fechamento do acordo; e possibilidade de negociação com um conjunto de produtos e múltiplos atributos tornando as negociações mais flexíveis. O trabalho utiliza conceitos de negociação bilateral apresentado por RAIFFA (1982) onde a negociação ocorre entre dois agentes (vendedor e comprador). O ciclo da negociação inicia quando o agente recebe uma oferta e termina quando esse mesmo agente envia uma contra-oferta. Cada ciclo é chamado de iteração e o agente tem um número máximo de iterações ( $T_{max}$ ). O número de iterações é usado para indicar que o tempo da negociação está chegando ao final, forçando os agentes a chegarem a um acordo rapidamente. Depois que o agente recebe a proposta, esta última é avaliada para identificar se é uma boa oferta ou não. É possível que a negociação ocorra entre agentes humanos e agentes autônomos desde que o protocolo usado e as condições de configuração sejam as mesmas. A entrega de cada proposta não é feita diretamente pelos agentes negociadores. Ela é feita por um agente mediador.

## 2.5 Negociação com Aprendizagem

Com a evolução das negociações mediadas por software, cresceram também as necessidades de tornarem as negociações mais inteligentes, em particular, tornando-as menos dependentes do projetista dos agentes e mais eficientes em termos de níveis de satisfação. Uma forma de tornar uma negociação mais eficaz é utilizar técnicas de aprendizagem de máquina para dotar os negociadores da capacidade de adaptação.

Fabrizio Enembreck (ENEMBRECK *et al.*, 2007) propuseram o uso de técnicas de *drift detection* (GAMA *et al.*, 2004) para aprendizagem de políticas de ofertas em negociações bilaterais com múltiplos critérios. Buscou-se no trabalho dotar os agentes da capacidade de aprendizagem a ponto de prever as possíveis mudanças de conceitos nas políticas de ofertas e contra-ofertas de um sistema. Neste caso, cada agente reaprende as políticas de ofertas e contra-ofertas dinamicamente. A questão crucial é saber quando exatamente reaprender para evitar um esforço desnecessário aprendizagem e também evitar uma queda no desempenho por operar por muito tempo com conhecimentos desatualizados. A técnica de *drift detection*

foi usada para detectar as mudanças de conceitos do modelo corrente de ofertas de um agente e atualizá-lo rapidamente. A técnica utilizada permite que os agentes detectem automaticamente as mudanças de estratégias de seu oponente. Experiências realizadas com dados simulados mostraram que o algoritmo IB3 (baseado em instâncias), proposto por AHA (1991), detectou rapidamente as trocas de conceitos. O próximo passo para o agente foi reaprender para recuperar o seu desempenho já nas próximas interações.

Chegar a um acordo em negociações bilaterais com múltiplos atributos torna-se difícil quando as preferências dos agentes e a importância relativa dos atributos não são conhecidas entre os agentes (SAHA, 2006). E mesmo chegando a um acordo na negociação, muitas vezes eles são alcançados de forma ineficaz com interesse próprio de cada agente. A maioria dos modelos de negociação existente sugere soluções usando um mediador confiável, onde os agentes revelam ao mediador suas preferências e importância dos atributos. O mesmo autor mostra um protocolo para negociações bilaterais de múltiplos atributos que habilitam os agentes a explorar e chegar a um acordo do tipo *ganha-ganha* sem revelar suas preferências e importâncias ao agente oponente. O modelo consiste de duas fases, que são: alocação e realocação. Na primeira fase, ambos os agentes fazem suas propostas ao mesmo tempo e baseadas em qualquer atributo. Na segunda fase, qualquer um dos agentes pode iniciar a negociação solicitando uma proposta para o agente oponente que pode propor algo baseado também em qualquer um de seus atributos. O modelo proposto orienta os agentes a alcançar uma solução ótima de *Pareto*<sup>1</sup>, ou próxima da ótima, rapidamente com poucas trocas de ofertas. O modelo também ajuda os agentes a explorar a assimetria nas preferências dos agentes e encontrar uma melhor solução para ambos os agentes. A grande contribuição foi a de melhorar o acordo e chegar rapidamente próximo da solução ótima de Pareto, mesmo quando os agentes não revelam suas preferências.

A utilização de um modelo para análise e estudos de negociações dinâmicas foi proposto num trabalho desenvolvido por Koen Hindriks (HINDRIKS *et al.*, 2007), onde a análise dinâmica pode ser feita enquanto ocorrem as trocas de ofertas entre os agentes negociadores. Tal modelo pode ser usado para estudar tanto o desempenho das negociações entre humanos quanto o desempenho das negociações entre sistemas automáticos de

---

<sup>1</sup> A Lei de Pareto, também conhecido como princípio 80-20, afirma que para muitos fenômenos, 80% das consequências advém de 20% das causas.

negociação. O interesse está em analisar, classificar e precisar aspectos característicos das negociações dinâmicas que influenciam no acordo final destas negociações. O principal interesse foi de propor conceitos e métricas que relatam estes fatores para especificar aspectos da negociação dinâmica e também para melhorar o entendimento dos resultados finais da negociação. Eles usaram duas estratégias nos agentes negociadores, que são: ABMP (*Agent-Based Market Places*) (JONKER *et al*, 2001) e Trade-Off (FARATIN *et al*, 2003). As análises foram feitas comparando AMPO (*Associated Metropolitan Police Officers*), como agente B, vs City (*administração de uma cidade fictícia*), como agente A (RAIFFA *et al*, 2002) e (RAIFFA, 1982, pág. 133). O modelo proposto mostrou eficiência nas negociações dinâmicas utilizando seres humanos e computadores. A estratégia *Trade-Off* obteve os melhores resultados em comparação com as outras estratégias utilizadas.

Leen e Xin (LEEN & XIN, 2004) propuseram uma adaptação da estratégia de negociação 1 para muitos (1:N) do tipo multi-critério para um sistema multi-agente em um ambiente dinâmico, tempo real, incerto e ruidoso. O objetivo dos autores, para utilizar este tipo de estratégia, era melhorar a relação custo-benefício e a satisfação do solicitante no ambiente de negociação. O agente solicitante conduz múltiplas negociações concorrentes com os agentes respondentes e em cada negociação ele (o solicitante) emprega uma abordagem alinhada, uma negociação por vez, ou uma abordagem baseada na confiança, por pacotes. Na primeira abordagem, faltam conhecimentos sobre o agente respondente, que negocia um problema de cada vez. Na segunda abordagem, com conhecimento do comportamento do agente respondente, a negociação é multi-critério em forma de pacotes. No trabalho foi incorporada a segunda abordagem adaptada em um modelo de formação multi-fase (MPCF), onde os agentes aprendem a formar coligações e executar tarefas globais.

Matos (MATOS *et al.*, 1998) utilizaram um modelo de negociação onde os agentes variam os valores das ofertas baseados em determinados critérios, modelados na forma de táticas, que podem ser combinadas de forma ponderada. Uma estratégia é definida como uma função que altera os pesos das táticas a utilizar em cada instante. A aprendizagem realizada neste estudo consiste na utilização de algoritmos genéticos, que permitem gerar uma seqüência de populações cada vez mais adaptadas à situação, como resultado de um método de pesquisa modelado por um mecanismo de seleção, combinação e mutação. No caso apresentado, os indivíduos da população são agentes negociadores e os materiais genéticos são os parâmetros das táticas e os seus pesos relativos. O objetivo é determinar quais as

melhores estratégias e verificar como e quando estas estratégias evoluem, dependendo do contexto e do comportamento de negociação dos oponentes.

Em Zeng e Sycara (ZENG E SYCARA, 1998) é descrito o sistema Bazaar. Ele inclui um modelo de negociação seqüencial que é capaz de aprender. Aqui, a negociação é modelada explicitamente como uma tarefa seqüencial de tomada de decisão, usando atualizações Bayesianas como mecanismo de aprendizagem subjacente. Em tal modelo, os agentes possuem informações das condições evolutivas do ambiente e dos modelos de outros agentes. A aprendizagem Bayesiana é utilizada para atualizar os conhecimentos e as crenças de cada agente sobre o ambiente e sobre os outros agentes. Um exemplo de informação sobre um oponente, num processo de negociação para a transação de um determinado produto, é o valor do seu preço de reserva. O comprador não sabe qual é o preço de reserva do vendedor, dado que esta informação é privada. Contudo, ele é capaz de alterar a crença relacionada ao preço de reserva, por meio das suas interações com o vendedor e do seu conhecimento sobre o domínio na área do negócio. A atualização Bayesiana é probabilística, e ocorre quando o comprador recebe novos sinais do ambiente ou do vendedor, notadamente por meio da troca de ofertas e contra-ofertas. O conhecimento do domínio é fundamental para que esta informação possa ser utilizada de forma eficiente.

Raymond Lau (LAU, 2005) utilizou conceitos de algoritmos genéticos como mecanismo de aprendizagem em negociação e-Business entre agentes. O interesse principal para o uso prático da teoria proposta é melhorar o espaço da busca ao considerar todas as estratégias e possíveis interações com objetivo de identificar melhores soluções. O mecanismo utilizado permite que cada agente aprenda quais são as preferências do agente adversário e se adapte de acordo com a evolução da negociação permitindo tratar situações complexas e dinâmicas.

Mia (Mia *et al*, 2005), apresenta um problema de negociação e-commerce quando utilizados múltiplos atributos considerando especificamente a construção incremental do conhecimento. Estes atributos geralmente têm alguns relacionamentos complexos entre eles que precisam ser balanceados para satisfazer as necessidades do comprador. O conhecimento pode ser adquirido a partir de informações dos produtos, dos vendedores e dos compradores, representados por agentes autônomos, e podem ser usados como conhecimento para o comprador em outras negociações. O autor do artigo comenta que o negociador humano freqüentemente não tem uma idéia bem definida dos seus próprios objetivos ou preferência.

Entretanto, tem uma idéia aproximada do valor que pode gastar na compra do produto. Esta negociação ocorre até que o comprador fique satisfeito com o produto ou quando for identificado que não é possível chegar a um acordo. A base de dados de produtos é montada como uma base de regras que conseqüentemente pode ser analisada.

### 2.5.1 Resumo dos Trabalhos

Muitos trabalhos na área de negociação utilizando aprendizagem foram desenvolvidos. A Tabela 4 mostra um resumo de alguns trabalhos examinados, bem como posicionamento do nosso trabalho, que se encontra em destaque na última linha desta mesma tabela.

Tabela 4: Quadro comparativo dos trabalhos relacionados.

	Configuração	Negociação	Aprendizagem	Táticas / Estratégia	Observação
LAU (2005)	Multi-critério	Multilateral	Algoritmo Genético	Aprender as preferências do agente adversário e daptar-se de acordo com a evolução da negociação	Adaptação do modelo de Matos aplicado em <i>e-Business</i> .
ZENG E SYCARA (1998)	Multi-critério	Multilateral	<i>Bayesiana</i>	A modelo de aprendizagem é utilizada para atualizar o conhecimento dos agentes sobre o ambiente de negociação.	A negociação é modelada como uma tarefa seqüencial de tomada de decisão.
MATOS (1998)	Multi-critério	Multilateral	Algoritmo Genético	Evolução dos indivíduos via Algoritmo Genético.	Cada indivíduo da população é um agente negociador.
ENEMBRECK (2007)	Multi-critério	Bilateral	Detecção de mudança de conceito	Detecção automática de mudança de conceitos com técnicas de <i>drift detection</i> .	Técnicas de <i>Drift Detection</i>
SCHMEIL (1999)	Multi-critério	Multilateral	ID3	a) Tática de troca / Incremental por Oferta. b) Dividida em áreas de satisfação.	A aprendizagem é feita organizador nos dados de toda a negociação.
NOSSA PROPOSTA	Multi-critério	Bilateral	Algoritmo Genético	a) Evolução das estratégias de negociação via Algoritmo Genético. b) Melhorar a satisfação dos agentes.	Identifica melhor estratégia de negociação a partir de informações anteriores.

## 2.6 Considerações Finais

A negociação é um tema amplamente estudado nas mais diversas áreas do conhecimento. Entretanto, o nosso interesse portou-se na negociação automática realizada por entidades autônomas, chamadas de agentes inteligentes. A inteligência se manifesta nestas entidades à medida que elas são capazes, por exemplo, de estabelecer uma relação tipicamente reservada aos seres humanos, que é a da negociação da compra e venda de produtos ou serviços. Além disso, estes agentes são equipados com estratégias e táticas para a negociação multi-critério bilateral ou multilateral, e às vezes, eles também são equipados com a capacidade de aprender a partir de suas experiências e de aplicar o que aprendeu em negociações futuras. A capacidade de aprender pode ser designada aos Algoritmos Genéticos que, através de processos de evolução, podem identificar melhores soluções para o problema. O próximo capítulo apresenta o algoritmo genético e suas características como ferramenta de aprendizagem.

## Capítulo 3

---

### APRENDIZAGEM COM ALGORITMOS GENÉTICOS

#### 3.1 Introdução

A teoria da evolução, como é conhecida nos dias de hoje, combina genética e seleção natural, sendo Charles Darwin o pesquisador mais conhecido nesta área. A evolução natural é responsável pelo aparecimento e diversidade de todos os organismos vivos no nosso planeta. Esta diversidade é produzida pela recombinação e pela inserção de material genético novo na população. Um algoritmo genético é baseado no mecanismo de seleção natural e produz como resultado a sobrevivência do indivíduo mais apto. Eles são especialmente atrativos por não exigirem que se saiba como encontrar uma solução ótima para um problema, mas sim como reconhecê-la como ótima (HOLLAND, 1975).

Neste capítulo são apresentados os principais elementos de um algoritmo genético aplicado na resolução de problemas.

#### 3.2 Algoritmos Genéticos

Os Algoritmos Genéticos (A.G.) são métodos de resolução de problemas inspirados nos processos de seleção natural e genética evolucionária. Algoritmos Genéticos foram propostos inicialmente por John Holland (HOLLAND, 1975), com intuito de aplicar a teoria da evolução das espécies elaborada por Darwin (DARWIN, 1994), ou seja, utilizar os conceitos da evolução biológica, tais como, como genes, cromossomos, cruzamento, mutação e seleção em outros problemas de otimização por meio de algoritmos computacionais.

Os principais elementos relacionados com os AGs são:

- **Cromossomo:** Cadeia de caracteres representando uma informação relativa às variáveis do problema. Cada cromossomo representa também deste modo uma solução para o problema em questão.

- **Gene:** É a unidade básica do cromossomo. Cada cromossomo tem um dado número de genes, onde cada um deles descreve uma dada variável do problema.
- **População:** Conjunto de cromossomos ou soluções para o problema em questão.
- **Geração:** O número da iteração que o algoritmo genético executa.
- **Operações Genéticas:** Operações que o algoritmo genético realiza sobre cada um dos cromossomos.
- **Espaço de Busca:** É o conjunto, espaço ou região, que compreende as soluções possíveis ou viáveis do problema em questão a ser otimizado. Ele deve ser caracterizado pelas funções de restrição, que definem as soluções viáveis do problema a ser resolvido.
- **Função Objetivo:** É a função que se quer otimizar. Ela contém a informação numérica do desempenho de cada cromossomo na população. Nela estão representadas as características do problema que o algoritmo genético necessita para realizar seu objetivo, sendo expressa normalmente como *fitness*.

Da evolução natural das espécies, sabe-se que os indivíduos mais adaptados ao meio possuem as maiores probabilidades de sobreviverem e de se reproduzirem. Assim, a sua informação genética será herdada por mais descendentes e terá menor probabilidade de se perder. Estas características retiradas da própria evolução das espécies serviram de inspiração para a criação dos algoritmos genéticos. Em termos computacionais, usando-se de seqüências binárias que designam cromossomos, ou indivíduos, e que representam possíveis soluções para um problema, simula-se a evolução natural criando novas seqüências por meio da reprodução das já existentes.

Os algoritmos genéticos transformam uma população de indivíduos, cada um com um valor associado de adaptabilidade, chamado de **aptidão**, em numa nova geração de indivíduos usando os princípios Darwianos de reprodução e sobrevivência dos mais aptos, pela aplicação de operações genéticas, tais como: **recombinação** e **mutação**. O processo de recombinação é também chamado de reprodução sexual, onde existem troca de materiais genéticos entre os dois progenitores, originando novos indivíduos que combinam as características dos pais. Com menos freqüência, ocorrem as mutações genéticas que são pequenas alterações acidentais ou induzidas, que podem ter repercussões nas características do novo ser. O fenômeno da mutação tem uma probabilidade muito reduzida. Quando acontece, o gene de

um filho fica diferente do gene correspondente de ambos os pais. Uma reprodução sem mutações implica que cada gene do cromossomo do filho seja igual ao gene correspondente de um dos pais.

No processo é mantida uma população de indivíduos chamados cromossomos, os quais representam possíveis soluções para um problema específico. No processo de evolução, são efetuadas inúmeras iterações sobre a população chamadas de gerações. A cada geração, são identificadas as melhores soluções, sendo estas selecionadas para formar nova população. A formação de tais soluções se dá por meio de operações de *crossover* e *mutação*. Ao final de uma iteração, um novo conjunto de soluções é obtido.

Devido à inspiração nos ambientes naturais, a escolha das soluções é aleatória, tentando refletir as condições do ambiente real. A escolha da população inicial, no entanto, pode utilizar alguma heurística para evitar a geração de soluções pouco aptas e retardar o desenvolvimento da população. Para isso é necessário construir um modelo de evolução onde os indivíduos sejam soluções de um problema. A execução do algoritmo pode ser resumida nos seguintes passos:

- Inicialmente escolhe-se uma população inicial que é definida de acordo com o objetivo do problema;
- Todos os indivíduos são avaliados por uma função de aptidão ou *fitness*. Esta função define a qualidade dos indivíduos;
- Em seguida, por meio do operador de seleção, escolhem-se os indivíduos de melhor qualidade como base para a criação de um novo conjunto de possíveis soluções;
- Os novos indivíduos são obtidos por meio dos operadores genéticos. Existem dois tipos de operadores: cruzamento que mistura as características dos indivíduos e mutação que altera a característica de um indivíduo;
- Estes passos são repetidos até um determinado número de gerações, ou que seja encontrada uma solução aceitável ou ainda até que o algoritmo não consiga mais melhorar a solução já encontrada.

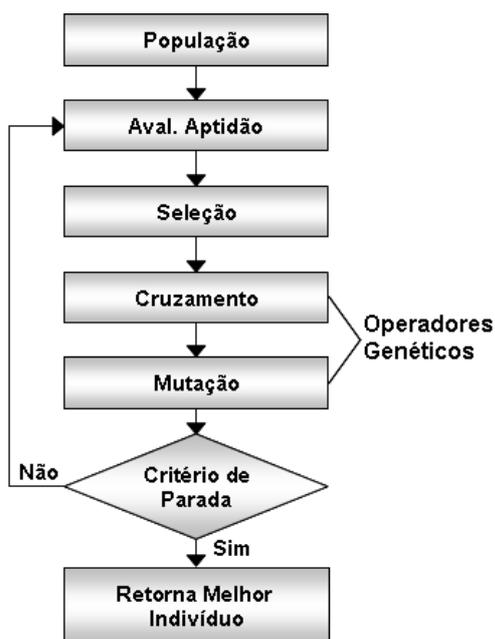


Figura 6: Estrutura básica de um algoritmo genético.

Os principais passos dos algoritmos genéticos são mostrados na Figura 6 que são detalhados nos próximos itens.

### 3.2.1 População

A população de um algoritmo genético é um conjunto de indivíduos, ou cromossomos, que representam uma solução do problema. Estes indivíduos serão usados para criar o novo conjunto de indivíduos através dos operadores genéticos para análise. O desempenho global e a eficiência dos algoritmos genéticos são afetados diretamente pelo tamanho da população. Existem algumas maneiras de representar um indivíduo em um AG. A mais simples e comumente utilizada é a representação binária de tamanho fixo, em que um indivíduo é uma cadeia de bits que assumem valores 0 ou 1 (HINTERDING, 2000). Porém, essa representação torna-se problemática quando as variáveis a serem representadas assumem valores contínuos (FREITAS, 2000). Em casos em que a representação binária não é a mais natural nem a mais apropriada, outros tipos de representação podem ser utilizados, como sugerido em (MICHALEWICZ, 1996).

A população inicial pode ser obtida por meio da geração de indivíduos, obedecendo às condições de contorno previamente estabelecidas pelo usuário. O usuário estabelece estas condições, tendo em vista o seu conhecimento prévio do problema a ser otimizado. Quanto

mais restritas forem as condições de contorno, mais rápida será a convergência, isso porque os valores gerados aleatoriamente estarão mais próximos da solução desejada (LACERDA & CARVALHO, 1999). Populações muito pequenas têm grandes chances de perder a diversidade necessária para convergir a uma boa solução, porque fornecem uma pequena cobertura do espaço de busca do problema. Entretanto, se a população tiver muitos indivíduos, o algoritmo poderá perder grande parte de sua eficiência pela demora em avaliar a função de aptidão de todo o conjunto a cada iteração, além de ser necessário trabalhar com maiores recursos computacionais (URSEM, 2002).

### **3.2.2 Função de Aptidão**

O cálculo do valor de aptidão de cada indivíduo é efetuado pela função de avaliação que indica a qualidade de cada indivíduo na população. Esta função avalia de modo a atribuir um valor para cada indivíduo e precisa ser definida para cada problema que se pretende solucionar. A codificação do indivíduo e o cálculo da aptidão são os dois componentes do algoritmo genético que estão relacionados diretamente com o domínio do problema. Em uma população natural, a função de avaliação é determinada pela capacidade do indivíduo de sobreviver a predadores e outros obstáculos naturais, e depois se reproduzir. Em uma população artificial, é responsável pela vida ou morte dos indivíduos.

### **3.2.3 Métodos de Seleção**

Os algoritmos genéticos são baseados no princípio da seleção natural de indivíduos. Desta forma, eles devem ser capazes de identificar os indivíduos mais aptos, para que permaneçam na população durante o processo de evolução, e os mais fracos, para que sejam excluídos do processo. Esta identificação é feita através dos métodos de seleção que se baseiam no princípio da sobrevivência dos melhores indivíduos, onde os cromossomos com melhor aptidão têm maior chance de ser selecionado para reprodução. A seleção pode ser definida de maneira simples como sendo a escolha probabilística de cromossomos de uma população tendo como base as suas aptidões.

Existem vários métodos diferentes de seleção, cada um com a sua particularidade. Dentre eles estão o método da roleta, o método de seleção por torneio e o método de seleção por ranking (DEB, 2001), (FREITAS, 2000), (GOLDBERG, 1989).

O MÉTODO DA ROLETA, proposto originalmente por HOLLAND (1975), é implementado de forma que uma roleta é dividida em  $N$  partes, sendo  $N$  o número de indivíduos da população, e o tamanho de cada uma das partes é proporcional à função de avaliação do indivíduo representado. Assim, para indivíduos com alta aptidão é dada uma porção maior da roleta, enquanto aos indivíduos de aptidão mais baixa, é dada uma porção relativamente menor, conforme exemplo (Figura 7).

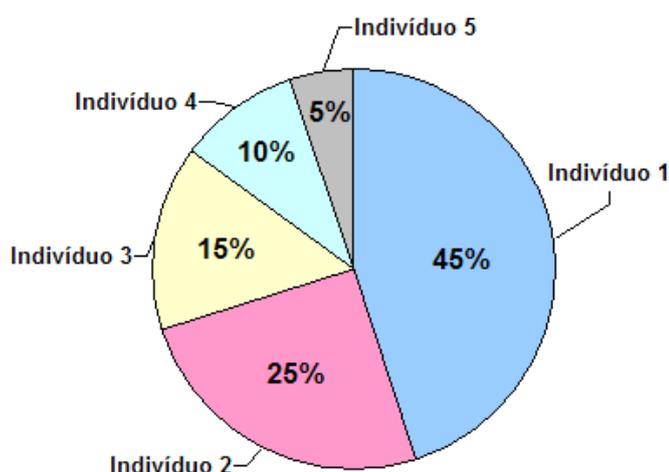


Figura 7: Exemplo do Método da Roleta.

A roleta é então girada  $N$  vezes, e a cada uma delas o indivíduo indicado pelo ponteiro é selecionado para que participe do processo de evolução.

O MÉTODO POR TORNEIO seleciona um número de  $N$  indivíduos da população aleatoriamente para formar uma sub-população temporária. Nesta primeira seleção, o método não leva em consideração a avaliação dos indivíduos. Da seleção de  $N$  indivíduos, aquele que tiver o melhor valor da função de avaliação é então selecionado para reprodução. O valor de  $N$  é definido pelo usuário. Quanto maior o valor de  $N$ , maior a pressão seletiva, ou seja, maior a velocidade com que os indivíduos mais fortes dominam a população, causando a extinção dos mais fracos (MITCHELL, 1997).

O MÉTODO POR RANKING pode ser dividido em duas etapas. Na primeira etapa, as soluções são ordenadas de acordo com seus valores da função de avaliação. A ordem, crescente ou decrescente, é de acordo com o objetivo do algoritmo. Se o propósito for maximizar a função de avaliação, ou em ordem decrescente, caso o objetivo seja minimizá-la. Estando a lista ordenada, para cada indivíduo é atribuído um novo valor da função de

avaliação equivalente à sua posição no *ranking*. Numa segunda fase, um procedimento similar à seleção proporcional é aplicado. Quanto melhor a posição do indivíduo no *ranking*, maior sua chance de ser selecionado.

### 3.2.4 Operadores Genéticos

A escolha dos operadores genéticos, juntamente com a determinação da função de aptidão e da representação apropriada dos indivíduos, é determinante para o sucesso de um algoritmo genético. Os operadores genéticos de cruzamento e mutação fornecem o mecanismo básico de busca e são usados para criar novas soluções baseadas nas melhores soluções existentes na população atual do algoritmo genético. Goldberg GOLDBERG (1989) formalizou as principais características dos operadores clássicos de cruzamento e mutação. Informações detalhadas podem ser encontradas em (GOLDBERG, 1989), (HERRERA, 1998).

O OPERADOR DE CRUZAMENTO é o principal responsável pela evolução da população. Uma vez que os indivíduos já foram selecionados, é possível aplicar o operador de cruzamento, o qual realiza a troca de material genético entre pares de indivíduos selecionados para reprodução. Existem várias formas de efetuar cruzamentos onde as mais utilizadas são:

- **um-ponto:** neste tipo de cruzamento, um ponto é escolhido e a partir dele as informações genéticas dos pais são trocadas. A Figura 8 mostra um exemplo de cruzamento de um ponto.

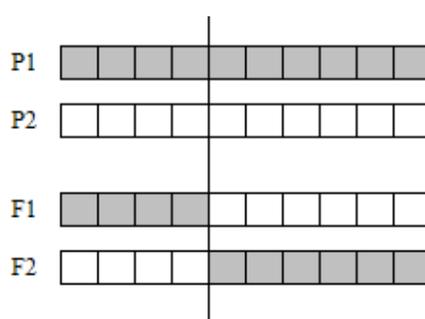


Figura 8: Cruzamento de 1 ponto.

- **multi-ponto:** no tipo de cruzamento multi-ponto vários pontos são selecionados e as informações dos pais são trocadas. A Figura 9 mostra um exemplo de cruzamento de multi-ponto.

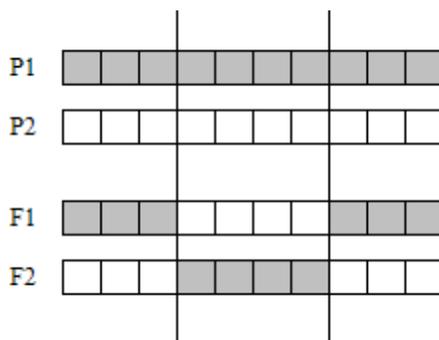


Figura 9: Cruzamento de 2 pontos.

A taxa de cruzamento é definida como a medida da possibilidade de aplicação do operador de cruzamento a um dado par de indivíduos. Os valores típicos para esta taxa situam-se no intervalo de 60% e 100%. Quanto maior for esta taxa, maior é a quantidade de indivíduos introduzidos na população. Sendo o tamanho da população normalmente fixo, mais indivíduos tenderão a ser substituído, logo pode haver a tendência para a perda de indivíduos com aptidão elevada. Para valores baixos desta taxa, será gerado menos indivíduos em cada geração, o que pode originar um aumento do número de gerações para obter os mesmos resultados.

OS OPERADORES DE MUTAÇÃO são outros elementos importantes em um algoritmo genético. A mutação é um processo simples, geralmente visto como um operador secundário que ajuda a manter a diversidade na população. Ao contrário da recombinação, a mutação opera sobre um único indivíduo, provocando pequenas perturbações no seu genótipo que irá se refletir de alguma forma no fenótipo. No caso da codificação binária, ela pode ser definida simplesmente como uma inversão do bit na posição selecionada. Já na codificação não binária a mutação ocorre pela troca da posição entre dois genes. A taxa de mutação é uma medida da taxa de ocorrência da operação mutação sobre o genótipo de um dado indivíduo. Dado que uma taxa de mutação elevada tenderá a tornar o algoritmo genético em um algoritmo essencialmente aleatório, é usual esta taxa assumir valores relativamente baixos que, tipicamente, estão no intervalo de 0% e 10% (GOLDBERG, 1989).

### 3.3 Considerações Finais

Neste capítulo foram apresentados diversos aspectos relacionados aos algoritmos genéticos aplicado na resolução de problemas de otimização. Os algoritmos genéticos

demonstram grande eficiência, desde que implementados apropriadamente, como ferramenta que pode ser utilizada para otimização de problemas complexos. Vários itens foram abordados neste capítulo como: definição do algoritmo genético; conceitos de população, onde cada indivíduo corresponde a uma solução do problema proposto; métodos de seleção; e operadores de cruzamento e mutação que é responsável pelo processo de mutação nos algoritmos genéticos.

Como ferramenta de aprendizagem de máquina, os algoritmos genéticos podem ser utilizados em modelos de negociação com o objetivo de identificar melhores estratégias ao iniciar uma negociação. Ao identificar melhores estratégias, cada agente tende a melhorar a satisfação nas negociações. O próximo capítulo mostra o desenvolvimento do trabalho aplicando algoritmos genéticos como a ferramenta de aprendizagem.

# Capítulo 4

---

## APRENDIZAGEM NA NEGOCIAÇÃO

### 4.1 Introdução

Aprendizagem aplicada em sistemas de agentes tem recebido grande atenção nos últimos anos, tanto por parte da comunidade da inteligência artificial quanto pela comunidade de aprendizagem de máquina (BOND *et al.*, 1988), (DIETTERICH, 1997), (ENEMBRECK *et al.*, 2006). Dada à complexidade da maioria dos sistemas de negociação, mesmo quando se trata de negociações aparentemente simples, torna-se difícil ou mesmo impossível prever os comportamentos que poderão levar os agentes a obterem um consenso no processo de negociação. A maior característica destes sistemas, onde os agentes podem iniciar ou terminar uma atividade a qualquer momento e cujas estratégias e comportamentos são muitas vezes não determinísticos, torna muitas vezes impossível determinar qual o melhor comportamento para o agente participante. Desta forma é desejável dotar um agente da capacidade de aprendizagem, permitindo-lhe modificar autonomamente seu comportamento em função da experiência adquirida e das possíveis alterações do ambiente.

A proposta deste trabalho é a utilização do conhecimento previamente adquirido por agentes em um processo de negociação. Este capítulo apresenta uma metodologia para simular um processo de negociação bilateral multi-critérios, onde cada agente é dotado da capacidade de aprender a partir de suas experiências em negociações anteriores e conseqüentemente adaptar-se ao ambiente. O método compreende as fases: (i) a definição e realização de um processo de negociação, sendo que os agentes negociam produtos sem utilizar conhecimentos sobre seus oponentes, baseando-se apenas em algumas táticas e estratégias pré-definidas; (ii) a incorporação de um processo de aprendizagem em cada agente negociador. Em termos computacionais, esta tarefa consiste em aplicar um algoritmo de aprendizagem sobre uma base de dados de negociações anteriores e utilizar o conhecimento adquirido na reconfiguração automática do módulo de geração de ofertas e contra-ofertas de cada agente.

## 4.2 Processo de Negociação

Neste trabalho a negociação é um processo dinâmico e bilateral que envolve dois agentes. Os agentes representam dois papéis bem-definidos, um comprador e um vendedor, sendo que cada um possui um conjunto de conhecimentos sobre a importância de cada critério de uma negociação, como por exemplo, preço, quantidade, prazo de entrega. O modelo presume que ambos conhecem os atributos a serem negociados e desconhecem os critérios utilizados, bem como o domínio e a importância de cada atributo. A duração de uma sessão de negociação é definida em função de intervalo de tempo ou pelo fechamento da negociação, que pode ser configurado quando os valores ofertas (pelo comprador) e contra-ofertas (pelo vendedor) são os mesmos, indicando que o processo de negociação foi estabilizado.

Dentro da nossa proposta de trabalho, a etapa de negociação descrita no parágrafo anterior é fundamental porque a sua execução com diferentes cenários de negociação geram subsídios para a etapa de aprendizagem, ou em outras palavras, os dados das negociações anteriores. O resultado desta aprendizagem vai formar a base para o mecanismo de adaptação dinâmica do módulo de negociação de cada agente.

O ambiente de negociação desenvolvido é do tipo multi-critério e segue o modelo de negociação bilateral proposto por (RAIFFA, 1982). Este ambiente possui as seguintes características:

- Cada sessão de uma negociação requer dois agentes, um deles desempenha o papel de comprador e o outro o papel de vendedor;
- Um agente A negocia apenas um único objeto O de cada vez com outro agente B. Ou seja, a sessão de negociação nunca envolverá mais de dois agentes;
- O agente comprador desempenha papel de consumidor, i.e, este agente deseja obter um produto ou um serviço;
- O agente vendedor desempenha papel de provedor de bens ou de serviços;
- Em termos de ambiente de execução e biblioteca de funcionalidades, ambos os agentes utilizam a mesma arquitetura e estrutura de negociação, bem como as mesmas táticas codificadas. No entanto ambos estão livres para escolher aquelas mais adequadas à situação.

#### 4.2.1 Arquitetura do Ambiente de Negociação

A arquitetura do ambiente de negociação desenvolvida neste trabalho baseia-se em módulos de software especializados implementando protocolos voltados à geração e envio de ofertas e contra-ofertas entre agentes, que desempenham respectivamente os papéis de comprador e de vendedor (Figura 10). É importante notar que inicialmente cada agente recebe do projetista o seu conjunto de parâmetros que definem os valores da negociação, os pesos dos atributos e táticas, o tempo de duração da negociação e também os comportamentos, estratégias, de cada agente de acordo com o ambiente de negociação. O funcionamento do sistema de negociação é composto de 3 etapas: a) na primeira etapa ocorre a geração da oferta pelo agente, comprador ou vendedor, e enviada ao agente oponente; b) na segunda etapa ocorre a análise da oferta; após a análise, ocorre c) o aceite ou a rejeição da oferta. Se a oferta for rejeitada então uma nova oferta é gerada e enviada ao agente oponente.

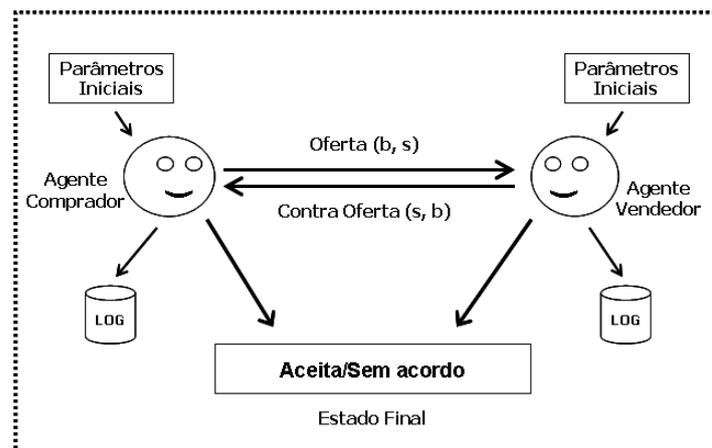


Figura 10: Arquitetura do ambiente de negociação (ROMANHUKI *et al.*, 2008).

É importante notar que todas as mensagens trocadas durante uma sessão de negociação são armazenadas em uma base de dados, denominada de *LOG*. A existência desta base de dados é mandatória para a execução do processo de aprendizagem. A quantidade de trocas de ofertas e contra-ofertas é definida pelo parâmetro *tempo*, que define a duração da sessão de negociação. A negociação pode ser encerrada de duas formas: (i) quando o intervalo de tempo tem seu limite de futuro atingido sem que haja aceitação da proposta ou (ii) quando ocorre a aceitação de uma oferta por ambos os agentes.

A arquitetura interna de cada agente visa atender às necessidades de um ambiente de

negociação que envolve uma tarefa de aprendizagem de máquina e inclui os seguintes elementos:

- Um conjunto de parâmetros de negociação, que define a estratégia;
- Um processo de negociação;
- Um processo de aprendizagem.

A Figura 11 mostra também os parâmetros iniciais de negociação que são fornecidos a cada agente por meio ambiente externo (ou arquivo de configuração no formato XML) sem passar pelo processo de aprendizagem. É importante notar que ao finalizar da negociação, individualmente, cada agente registra no seu arquivo de *LOG* local os dados que resultaram do fechamento da negociação.

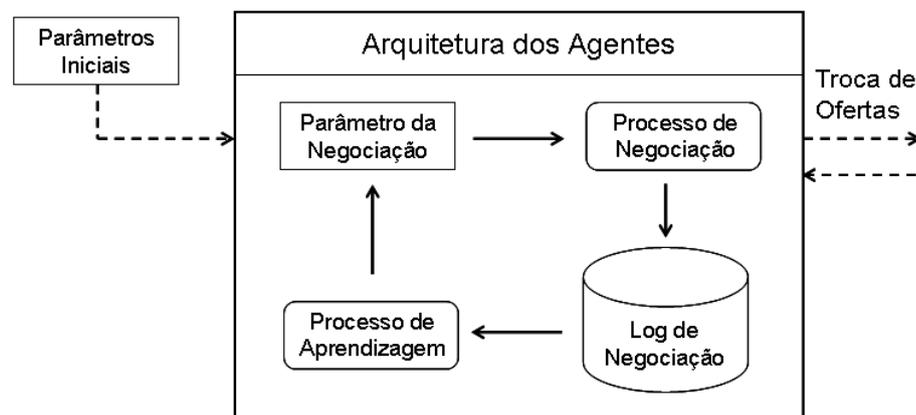


Figura 11: Arquitetura do agente negociador (ROMANHUKI *et al.*, 2008).

A *log* é gerada contendo as informações necessárias para serem utilizadas no processo de aprendizagem.

```

<learning>
  <learn-data>
  - <values>
    <ID>50</ID>
    <actualTime>0.79661016949</actualTime>
    <maxTime>1.0</maxTime>
    <precoWeightValue>0.75</precoWeightValue>
    <volumeWeightValue>0.25</volumeWeightValue>
    <txTime>0.7</txTime>
    <txImitation>0.3</txImitation>
    <kPreco>0.1</kPreco>
    <kVolume>0.1</kVolume>
    <betaValue>0.1</betaValue>
    <stepValue>1.0</stepValue>
    <satisfactionValue>2.05754</satisfactionValue>
    <isAccepted>1</isAccepted>
    <funcType>1.0</funcType>
  </values>
</learn-data>
</learning>

```

Figura 12: Formato do arquivo de negociações.

Esta *log*, cujo formato é mostrado na Figura 12, foi desenvolvida para este trabalho e é composta por um identificador de iteração (ID), pelo tempo em que a negociação foi fechada (*actualTime*), o limite de tempo (*maxTime*), pelos pesos de cada atributo (*precoWeightValue* e *volumeWeightValue*), pelas taxas, ou peso, de cada tática utilizada (*txTime* e *txImitation*), pela taxa de criação da oferta inicial (*kPreco* e *kVolume*), pelo grau de convexidade da função de comportamento (*betaValue*), pelo valor que define o número de passos na tática imitativa (*stepValue*), pela satisfação do agente (*satisfactionValue*) e pelo indicativo do tipo de função utilizada, polinomial = 1 ou exponencial = 0, (*funcType*).

Na rotina principal do processo de negociação, o agente A cria uma oferta e envia para o agente B. Neste momento, o agente A fica aguardando retorno do agente B. O agente A então recebe uma contra-oferta do agente B, o qual faz a avaliação da proposta e aceita ou reinicia o *looping* criando uma nova oferta (ver Algoritmo 1).

```

NegotiationProcess(estratégia e)
início
    Enquanto (Tempo não Acabou) e (Negociação não for aceita)
    início
        // Cria uma oferta utilizando as táticas.
        preparaOferta(tempo t, estratégia e);
        // Envia a oferta para o agente oponente.
        enviaOferta(oferta);
        // Recebe contra-oferta.
        recebeContraOferta();
        // Avalia a oferta utilizando a utilidade.
        avaliacao(contraOferta);
    fim
    // Calcula a Satisfação da oferta final da negociação.
    CalculaSatisfação(utilidade);
    // Grava na base LOG.
    GravaLog(Dados da Negociação);
fim

```

Algoritmo 1: Rotina principal do processo de negociação.

Na preparação da oferta, o agente utiliza as equações das táticas para calcular os seus valores. Neste momento, os parâmetros da estratégia são utilizados para auxiliar na definição dos valores da oferta (ver Algoritmo 2).

```

preparaOferta(tempo t)
início
    Para cada critério j da negociação
    início
        // Calcula o valor da oferta pela tática Dependente do Tempo
        TDT = TáticaTempo(critério j, tempo t, estratégia);
        // Calcula o valor da oferta usando a tática Imitativa
        IT = TáticaImitativa(critério j, ofertasAnteriores, estratégia);
        // Aplica os pesos das táticas
        ValorCritério = (TDT * PesoTáticaTempo) +
                        (IT * PesoTáticaImitativa);
    fim
    CalculaUtilidade(oferta);
fim

```

Algoritmo 2: Rotina de preparação da oferta.

O valor da oferta é composto pelo valor de todos os critérios da negociação, por exemplo: preço e quantidade. As funções utilizadas para efetuar o cálculo das ofertas são as táticas, que estão detalhadas nas funções F-2.3 (pág. 24) e F-2.10 (pág. 29). Após todos os valores dos critérios terem sido definidos é possível calcular o valor da utilidade da oferta. A utilidade é um item importante utilizado para avaliar as ofertas e é calculado por meio da avaliação da fórmula F-2.1 (pág. 22). O valor da utilidade será utilizado na decisão a respeito do fechamento de uma negociação ou da criação de uma nova oferta. Esta decisão será feita pelo item *avaliação*, Algoritmo 1, que implementa a fórmula F-2.13 (pág. 31).

#### 4.2.2 Configuração de uma Sessão de Negociação

A atribuição dos parâmetros iniciais de configuração do agente comprador e do agente vendedor é uma atividade importante para que o processo de negociação ocorra. A carga destes valores de configuração pode ser realizada de duas formas, a saber: (i) via interface gráfica, conforme mostra a Figura 13, onde é especificado os parâmetros de entrada para o agente comprador; e (ii) via arquivo XML, conforme mostra a Figura 14 onde é especificada a lista de critérios que define o valor mínimo e máximo do produto da negociação, bem como os pesos de cada atributo do produto em questão.

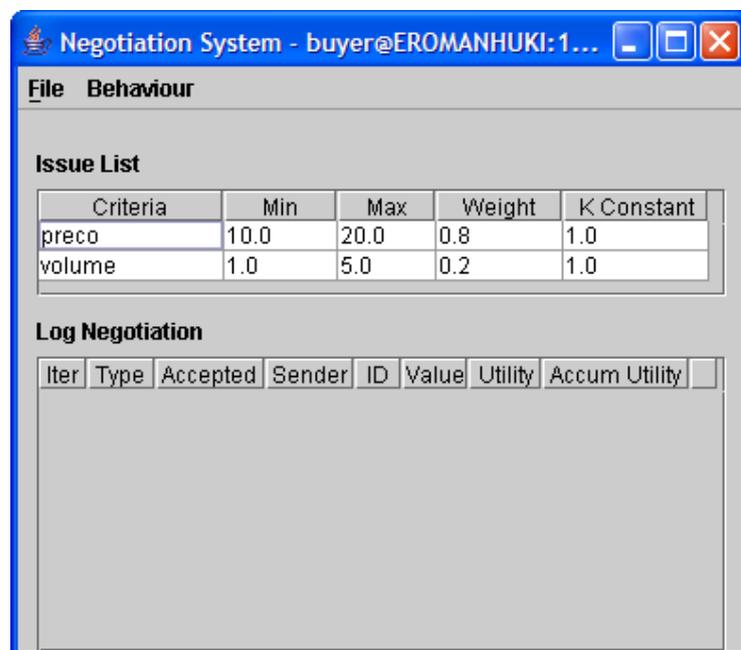


Figura 13: Modelo de interface de entrada de dados.

O padrão XML foi adotado como representação de uma lista de critérios, com o objetivo de facilitar a criação do protocolo de comunicação entre os agentes. A Figura 14 mostra a estrutura do arquivo de descrição dos critérios utilizados para a negociação de um produto ou de um serviço.

```

- <criteria-list>
- <selection-criteria>
  <criteria>preco</criteria>
  <min>10</min>
  <max>20</max>
  <weight>0.8</weight>
  <constantK>0.01</constantK>
</selection-criteria>
- <selection-criteria>
  <criteria>volume</criteria>
  <min>1</min>
  <max>5</max>
  <weight>0.2</weight>
  <constantK>0.01</constantK>
</selection-criteria>
</criteria-list>

```

Figura 14: Formato dos dados de entrada para os critérios de um produto.

O conjunto de etiquetas definidas para o arquivo de entrada de dados do sistema possui os seguintes significados, onde: (i) <criteria> identifica o atributo do produto da negociação; (ii) <min> valor mínimo do critério; (iii) <max> valor máximo do critério; (iv) <weight> define o peso de cada atributo onde a soma deve ser 1; (v) <constantK> auxilia na definição do valor da oferta inicial (ver item 2.3.1, pág 24). A contante K é utilizada nas funções da tática dependente do tempo e define em que ponto da linha do domínio será a primeira oferta.

O mesmo padrão XML foi adotado para facilitar a entrada dos parâmetros de negociação. Esses parâmetros definem os comportamentos e as estratégias dos agentes envolvidos em uma sessão de negociação. O agente *comprador*, por exemplo, pode ter comportamento ou estratégia diferente do agente *vendedor*. A Figura 15 mostra a estrutura do arquivo dos parâmetros utilizado no modelo de negociação que é carregado pelos agentes.

```

<parameter>
  <set-parameter>
    <product-name>camisa</product-name>
    <rand-param>y</rand-param>
    <beta-value>0.5</beta-value>
    <step-value>1</step-value>
    <boul-conc>b</boul-conc>
    <function-type>poly</function-type>
    <times-number>100</times-number>
    <tx-times>0.7</tx-times>
    <tx-imitation>0.3</tx-imitation>
  </set-parameter>
</parameter>

```

Figura 15: Formato dos dados de entrada para as estratégias de uma negociação.

O conjunto de etiquetas definidas para o arquivo de entrada para as estratégias de negociação do sistema possui os seguintes significados: (i) <product-name> identifica o nome do produto da negociação; (ii) <rand-param> indica se os parâmetros serão gerados de forma aleatória; (iii) <beta-value> define o grau de convexidade da função de comportamento; (iv) <step-value> define o número de passos para a tática imitativa; (v) <boul-conc> define se a função do comportamento será do tipo Boulware, Conceder ou Linear; (vi) <function-type> define se a função de geração de ofertas terá um comportamento *polinomial* ou *exponencial*; (vii) <times-number> define o número de tempo/interações da negociação; (viii) <tx-times> define a taxa do valor calculado quando se utiliza a tática de tempo; e (ix) <tx-imitation> define a taxa do valor calculado quando se utiliza a tática imitativa.

Durante o processo de negociação é gerada uma base de dados sobre as trocas de mensagens, onde tais mensagens correspondem às ofertas e contra-ofertas expedidas pelos agentes *comprador* e *vendedor*. Como já dito anteriormente, a negociação finaliza quando uma das duas situações a seguir acontece: o intervalo de tempo da negociação tem seu limite de futuro atingido; ou ocorre a aceitação de uma oferta ou contra-oferta por ambos os agentes. Ao final do processo de negociação, o ambiente de simulação apresenta os valores negociados, conforme mostra a Figura 16.

Negotiation Log							
Iter	Type	Accepted	Sender	ID	Value	Utility	Accum Utility
0	model.negotiation.Negotiation		buyer@EROMANHUKI:1099/JADE	preco	10.1	8.08	8.288
0	model.negotiation.Negotiation		buyer@EROMANHUKI:1099/JADE	volume	1.04	0.2080	8.288
0	model.negotiation.Answer	false	seller@EROMANHUKI:1099/JADE	preco	22.5	18.0	19.3
0	model.negotiation.Answer	false	seller@EROMANHUKI:1099/JADE	volume	6.5	1.3	19.3
1	model.negotiation.Negotiation		buyer@EROMANHUKI:1099/JADE	preco	10.1	8.08	8.288
1	model.negotiation.Negotiation		buyer@EROMANHUKI:1099/JADE	volume	1.04	0.2080	8.288
1	model.negotiation.Answer	false	seller@EROMANHUKI:1099/JADE	preco	22.5	18.0	19.3
1	model.negotiation.Answer	false	seller@EROMANHUKI:1099/JADE	volume	6.5	1.3	19.3

Figura 16: Log do fechamento da negociação.

O processo de negociação pode seguir diversos caminhos dependendo da estratégia utilizada. Cada agente pode ter valores diferentes para  $\beta$ , e assim, utilizar configurações de táticas e funções diferentes. Em uma negociação de compra de um determinado produto, analisando apenas um critério (preço), a Tabela 5, define para efeito de ilustração os parâmetros iniciais.

Tabela 5: Parâmetros do Método de Aprendizagem.

	Comprador	Vendedor
Valor Mínimo	55	65
Valor Máximo	80	85
Constante K	0,05	0,1
Peso do atributo	1	1
Tempo	10 ut	10 ut
Valor Beta	5 (Conceder)	0,5 (Boulware)

A título de ilustração, a Tabela 6 mostra os valores dos diferentes cálculos para 10 unidades de tempo, sem considerar a análise das contra-ofertas, isto é, mesmo com valores que poderiam fechar a negociação, os cálculos foram executados para 10 ofertas.

Tabela 6: Valores de cálculo simulado de negociação.

tempo (t)	Comprador				Vendedor			
	$\alpha$ - poly	$\alpha$ - exp	Oferta poly	Oferta exp	$\alpha$ - poly	$\alpha$ - exp	Oferta poly	Oferta exp
0,00	0,05	0,05	56,25	56,25	0,10	0,10	83,00	83,00
0,11	0,66	0,19	71,55	59,74	0,11	0,11	82,78	82,72
0,22	0,75	0,43	73,83	65,66	0,14	0,13	82,11	82,38
0,33	0,81	0,67	75,32	71,85	0,20	0,15	81,00	81,95
0,44	0,86	0,85	76,44	76,33	0,28	0,18	79,44	81,41
0,56	0,89	0,95	77,37	78,73	0,38	0,22	77,44	80,69
0,67	0,93	0,99	78,15	79,69	0,50	0,26	75,00	79,71
0,78	0,95	1,00	78,84	79,96	0,64	0,34	72,11	78,24
0,89	0,98	1,00	79,45	80,00	0,81	0,46	68,78	75,72
1,00	1,00	1,00	80,00	80,00	1,00	1,00	65,00	65,00

A Tabela 6 mostra duas possibilidades de cálculos: a primeira utilizando a função polinomial e a segunda utilizando a função exponencial. O cálculo da oferta foi feito utilizando apenas a tática dependente do tempo. A Figura 17 mostra de forma gráfica a diferença entre as duas funções e o comportamento do comprador e do vendedor, já que ambos estão com táticas diferentes.

Lê-se, no gráfico, VP para Vendedor função Polinomial, CP para Comprador função Polinomial, VE para Vendedor função Exponencial e CE para Comprador função Exponencial.

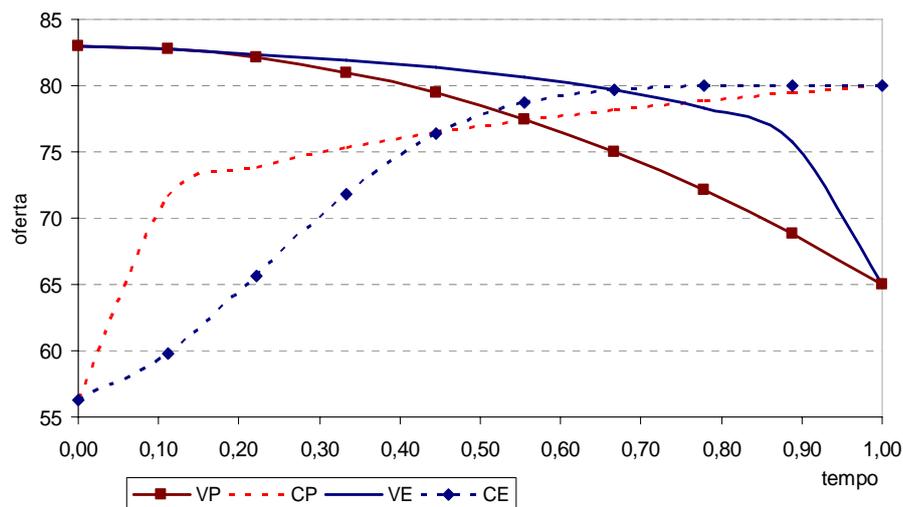


Figura 17: Log do fechamento da negociação.

Como o comprador utiliza o valor  $\beta > 1$ , então a estratégia é ceder na negociação rapidamente. Diferentemente, a estratégia do vendedor é ceder a negociação mais lentamente. Analisando apenas o comprador, vemos que a tendência da função exponencial é ceder na negociação de forma mais lenta enquanto que a função polinomial cede mais rapidamente.

### 4.2.3 Táticas de Negociação

O processo de negociação requer a definição de táticas para se obter os valores que serão ofertados, por exemplo, por um agente comprador ao seu opositor, um agente vendedor. Em nossas experimentações foram consideradas duas táticas para realizar os cálculos dos valores das ofertas e contra-ofertas. Elas são: a tática *dependente do tempo* e a tática *imitativa*, também conhecida por *relative tit for tat* (ver Capítulo 2). O peso de cada tática é definido pelo valor das variáveis  $\langle tx\text{-times} \rangle$  e  $\langle tx\text{-imitation} \rangle$ , que são fornecidas aos agentes negociadores durante a carga dos parâmetros iniciais.

As Figuras 14 e 15 ilustram, na forma de arquivo XML, a entrada de dados que definem as estratégias de negociação.

### 4.2.4 Cálculo da Satisfação

A cada conjunto de trocas entre o agente comprador e o agente vendedor, na forma de ofertas e contra-ofertas, é possível avaliar o grau de satisfação do conjunto. Para isso foram criadas funções de cálculo da satisfação dos agentes negociadores, dadas por:

$$\text{buyer agent: } stf^b(t) = 1 + \left( \frac{(1-t)}{V_{b \rightarrow s}} \right) \quad (\text{F-4.1})$$

$$\text{seller agent: } stf^s(t) = 1 + \left( \frac{(1-t)}{(1-V_{s \rightarrow b})} \right) \quad (\text{F-4.2})$$

Onde:

- a)  $V_{b \rightarrow s}$ : é a utilidade da oferta do agente comprador para o agente vendedor;
- b)  $V_{s \rightarrow b}$ : é a utilidade da oferta do agente vendedor para o agente comprador;
- c)  $t$ : é o tempo em que a negociação foi fechada.

No cálculo da satisfação o tempo é usado como peso para fazer com que a satisfação

seja maior no tempo menor.

Nesta primeira parte do capítulo apresentamos o modelo e as definições utilizadas no processo de negociação bem como avaliar o grau de satisfação dos negociadores. No próximo item apresentaremos a definição dos mecanismos que permitem dotar os agentes negociadores de um processo de aprendizagem. Este processo deve ser capaz de tornar os agentes mais inteligentes, em termos da capacidade de levar em conta as experiências passadas nas negociações futuras de forma autônoma e produtiva.

#### **4.2.5 Ferramentas Auxiliares da Negociação**

No modelo de negociação do nosso trabalho foram utilizadas algumas ferramentas auxiliares. O protocolo de comunicação adotado para a realização das negociações neste trabalho foi o Contract-Net, definido por DAVID SMITH (1980) e SANDHOLM (1993). Trata-se também de um protocolo adotado pela FIPA (Fipa, 2008). Em termos práticos, tal protocolo atendeu integralmente às nossas necessidades de estruturação e realização da comunicação, bem como o estabelecimento de contratos entre agentes comprador e vendedor. As performativas utilizadas foram as seguintes: call\_for\_propose, propose, accept\_proposal, reject\_proposal. O modelo de negociação foi desenvolvido usando JADE (Java Agent Development Framework) o qual é um *framework* adotado pela FIPA (BELLIFEMINE, 2003).

### **4.3 Processo de Aprendizagem**

A capacidade de aprender e aplicar o que aprendeu, de forma autônoma e produtiva, é essencial para a concepção de agentes inteligentes adaptáveis. A possibilidade de um agente de software ser dotado de tal capacidade é um desafio que requer a consecução de tarefas e algoritmos de aprendizagem de máquina não triviais.

Em nossos experimentos, o processo de aprendizagem de máquina envolveu um conjunto de elementos e técnicas para capacitar um agente a usufruir de suas experiências passadas em negociações futuras, a saber:

- Uma base de dados individual contendo as estratégias utilizadas nas negociações;

- Um processo de pré-processamento dos dados para possibilitar a execução de uma tarefa de aprendizagem de máquina;
- Um processo de aprendizagem de máquina baseado em um algoritmo genético; e
- Um processo de incorporação do que se aprendeu com vistas a aplicação do conhecimento em negociações futuras.

Desta forma, durante uma sessão de negociação diferentes detalhamentos em termos de dados e processos são executados. Após a realização de várias sessões de negociação é possível executar o processo de aprendizagem sobre os dados armazenados referentes às experiências anteriores e, conseqüentemente, tentar identificar e aplicar os novos valores para os parâmetros que devem resultar em uma melhora da satisfação do agente ao final de uma negociação futura. Na prática, o processo de aprendizagem consiste na execução de um algoritmo genético que seleciona os melhores parâmetros, segundo uma função de aptidão.

#### **4.3.1 Arquitetura do Processo de Aprendizagem**

O processo de aprendizagem é essencialmente baseado na execução de um algoritmo genético cujos processos foram desenvolvidos e adaptados para este trabalho (ver item 4.3.6). O algoritmo genético retorna a lista dos parâmetros mais promissores para realizar uma boa negociação na próxima sessão.

Em termos genéricos, no modelo evolucionário, uma população contendo um conjunto de possíveis soluções para um problema em questão, evolui por meio da aplicação de algoritmos de computação evolutiva, de modo que exista uma tendência de que, na média, os indivíduos representem soluções cada vez melhores à medida que o processo evolutivo progride. Embora um algoritmo genético use internamente um método heurístico e probabilístico para obter os novos elementos, ele não pode ser considerado como uma simples busca aleatória, uma vez que ele explora as informações disponíveis de forma a encontrar novos indivíduos ou soluções capazes de melhorar progressivamente um critério de desempenho.

Seguindo esta analogia, onde cada indivíduo corresponde a uma solução do problema, utilizou-se de um algoritmo genético para a realização do processo de aprendizagem e identificação da melhor estratégia (ou conjunto de parâmetros), a ser utilizado nas

negociações futuras. A Figura 18 mostra a arquitetura do processo de aprendizagem, onde a população inicial é formada pelos indivíduos obtidos da *log* de negociação.

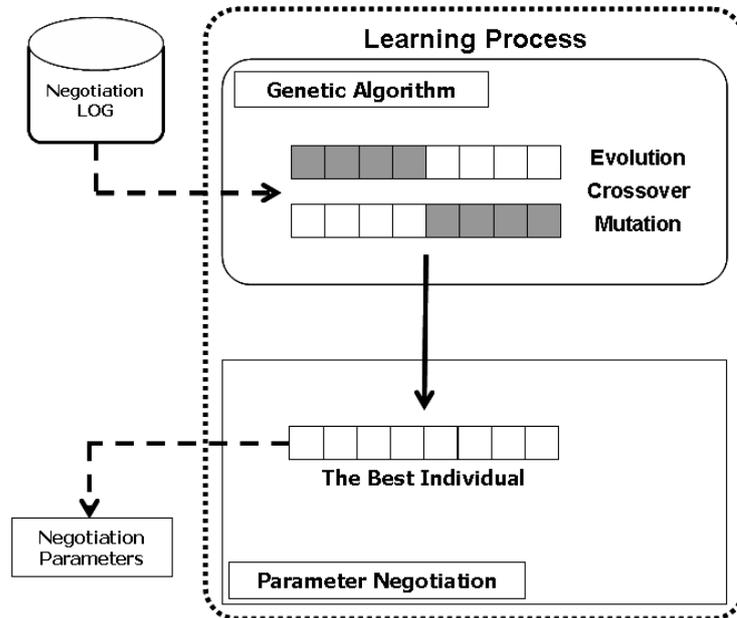


Figura 18: Arquitetura do Processo de Aprendizagem.

Cada conjunto de parâmetros utilizado em uma negociação forma um indivíduo o qual passará pelo processo de evolução genética. Após certo número gerações, ocorre a etapa de utilização do conhecimento adquirido onde o melhor indivíduo (ou conjunto de parâmetros) é eleito para fazer parte da negociação seguinte. O processo de evolução de um algoritmo genético possui algumas particularidades que são: (i) a representação do indivíduo (ou cromossomo); (ii) o critério de seleção; (iii) a função de avaliação; e (iv) o operador de cruzamento e mutação.

Outras ferramentas de aprendizagem foram estudadas para serem utilizadas neste trabalho como Árvore de Decisão e Redes Neurais. Como o objetivo deste trabalho é identificar o melhor conjunto de parâmetros, houve a necessidade de uma ferramenta de aprendizagem do tipo qualitativa. Como a Árvore de Decisão e a Rede Neural são do tipo quantitativa, isto é, necessitam de um conjunto de informações maior para treinamento, não foi possível dar continuidade nos estudos.

### 4.3.2 Representação do Indivíduo

Em nosso contexto, cada indivíduo, ou cromossomo, utilizado em um algoritmo genético representa um conjunto de parâmetros que foram utilizados em uma negociação. O tamanho do cromossomo está intimamente ligado ao problema abordado. Ele também determina o tamanho das soluções candidatas para o problema em questão. Em nossos experimentos, todos os indivíduos possuem o mesmo tamanho. Este tamanho corresponde ao número de atributos considerados na *log* de negociação (Figura 19).

1	2	3	4	5	6	7	8	9	10
tempo	precoWgt	volumeWgt	txTime	txImitation	Kpreco	Kvolume	betaValue	stepValue	funcType

Figura 19: Representação do Indivíduo.

Cada gene representa um atributo que foi utilizado como parâmetro na negociação. O gene 1 corresponde ao tempo em que a negociação foi aceita. Os genes 2 e 3 correspondem aos pesos dos atributos preço e volume, respectivamente, utilizado durante as negociações. Os genes 4 e 5 correspondem aos pesos das táticas *dependente do tempo* e *imitativa*, respectivamente. Assim como os genes 2 e 3, os genes 4 e 5 são complementares, ou seja, a soma deles deve ser igual a um. Os genes 6 e 7 correspondem à constante  $K$  do processo de negociação. O gene 8 corresponde ao valor  $Beta$ , que define o grau de convergência da negociação. O gene 9 corresponde ao passo que define a tática *imitativa*. Por fim, o gene 10 define a função que usada, que pode ser *polinomial* ou *exponencial*.

### 4.3.3 Critério de Seleção

O processo de seleção baseia-se no princípio da sobrevivência dos melhores indivíduos, onde os indivíduos com melhor aptidão permanecem no processo de evolução e os indivíduos com baixa aptidão serão descartados da população. Dentre os métodos vistos anteriormente, a seleção dos indivíduos em nossos experimentos é feita pelo *método de ranking*, onde os indivíduos são ordenados de acordo com seus valores da função de avaliação, em ordem decrescente. Após a aplicação do método de seleção, os indivíduos são enviados para o processo de evolução, onde são aplicados os operadores de cruzamento e mutação.

#### 4.3.4 Função de Avaliação

No caso presente, a função de avaliação é baseada no cálculo da satisfação do agente, cuja consecução passa pela combinação de um conjunto de diferentes parâmetros, taxas e pesos. É importante notar que valores que compõem tal conjunto provêm dos atributos disponíveis para uma negociação. A fórmula do cálculo de *fitness* foi definida como segue:

$$\text{buyer agent: } \textit{fitness} = 1 + \left( \frac{1}{V} \right) \quad (\text{F - 4.3})$$

$$\text{seller agent: } \textit{fitness} = 1 + \left( \frac{1}{(1-V)} \right) \quad (\text{F - 4.4})$$

Onde, V: é o valor de utilidade (ver F – 2.1 e F – 2.2).

Após a aplicação dos operadores de cruzamento e mutação, que serão apresentados a seguir, o cálculo do *fitness* é essencial para avaliar a qualidade do indivíduo. É importante notar que tal indivíduo corresponde ao conjunto de parâmetros de configuração do módulo de geração de ofertas de um agente. Em outras palavras, o agente negociará tão bem quanto for à qualidade dos parâmetros de configuração do seu gerador de ofertas. Isto é verdade frente a um objetivo de fazer com que os agentes negociem dentro de uma política do estilo *ganha-ganha*.

#### 4.3.5 Operador de Cruzamento e Mutação

Em nossos experimentos, foram utilizadas duas formas de cruzamento: um ponto e dois pontos. Tanto os cruzamentos de um ponto como os cruzamentos de dois pontos iniciam a partir do quinto gene do indivíduo, pois os conjuntos de atributos 2 e 3, e 4 e 5 são dependentes. A escolha da forma de cruzamento é feita de forma aleatória durante o processo, sendo que as duas formas têm 50% de possibilidade.

O processo de mutação é responsável por criar um novo indivíduo na população totalmente independente dos demais. Este processo deve ser usado em taxas muito baixas sob o risco de acrescentar à busca o mesmo adjetivo de seu nome, e torná-la completamente aleatória. Em nossos experimentos, o processo de mutação ocorre sempre entre o segundo e o terceiro gene, ou entre o quarto e o quinto gene, ou ainda entre o sexto e o sétimo gene (ver Figura 19). Isto é necessário, porque tais conjuntos de atributos são dependentes. Para os

outros genes, a mutação efetua uma troca dos valores de acordo com o domínio de campo.

#### 4.3.6 Representação do processo de aprendizagem

A execução do processo de aprendizagem deve resultar na identificação de um conjunto de parâmetros que define a melhor estratégia de negociação. É importante salientar que os processos de aprendizagem de cada agente são independentes, isto é, um agente não tem acesso à base histórica do agente oponente.

A população inicial é formada pelo conjunto de parâmetros que definem as estratégias em negociações anteriores. Conforme mostra a Figura 20, representação do processo de aprendizagem, no primeiro passo aplica-se o processo de evolução do algoritmo genético, desenvolvido para este trabalho, realizando as seguintes etapas: criação de novos indivíduos, aplicação de *crossover* e mutação.

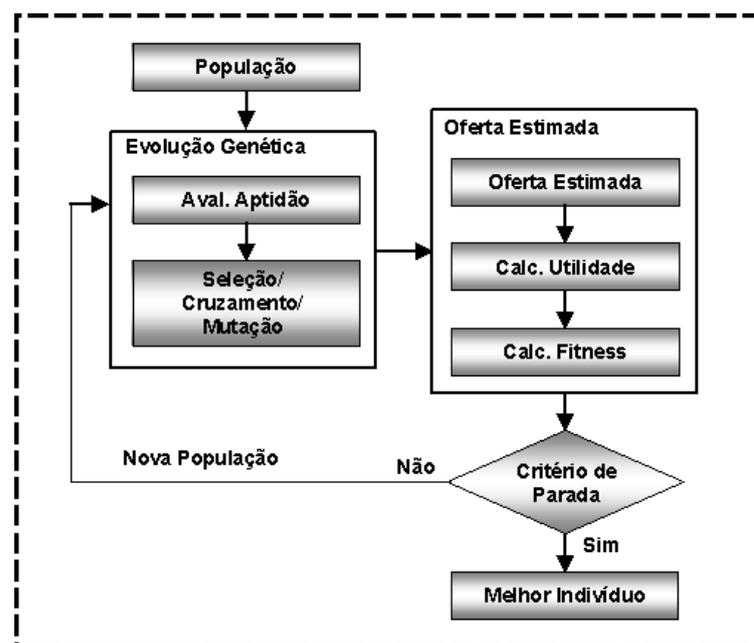


Figura 20: Representação do Processo de Aprendizagem.

A execução deste primeiro passo, descrito acima, é feita conforme descreve o Algoritmo 3.

```

LearningProcess(população p)
início
    Enquanto (Número de gerações não terminar)
    início
        // Aplica os processos de evolução do Algoritmo Genético;
        // Cria novos indivíduos, aplica mutação;
        processoEvolucao(população p);
        // Estima uma oferta com estratégia do indivíduo;
        calculaOfertaEstimada(indivíduo i)
    fim
Fim

```

Algoritmo 3: Rotina principal do processo de aprendizagem.

No segundo passo, é criada uma oferta estimada utilizando o conjunto de parâmetros do indivíduo para definir a estratégia. Em seguida esta oferta estimada é avaliada, conforme demonstrado na Figura 20. O Algoritmo 4 descreve como a oferta estimada é calculada.

```

calculaOfertaEstimada(indivíduo i)
início
    estrategia e = indivíduo i;
    // O tempo da tática é o gene 1 do indivíduo;
    tempo t = indivíduo i[1];

    Para cada Critério j da negociação
    início
        // Calcula o valor da oferta estimada
        // pela tática Dependente do Tempo.
        TDT = Tatica_Tempo(critério j, tempo t, estrategia e);
        Valor_Critério = (TDT * Peso_I_Tempo);
    fim
    // Calcula a utilidade da oferta criada.;
    Calcula_Utilidade(ofertaEstimada o, indivíduo i);
    // Calcula o valor fitness a partir da utilidade;
    avaliacaoFitness(utilizada u);
Fim

```

Algoritmo 4: Rotina principal do processo de geração de ofertas.

A tática imitativa, como o próprio nome diz, imita o comportamento do agente oponente, por isso não pode ser utilizada para estimar uma oferta. A função responsável pela avaliação de cada indivíduo de uma população é a função *fitness*, definida em F-4.3 (pág. 65) e F-4.4 (pág. 65). O objetivo desta função é estimar uma oferta que poderia ser criada com os parâmetros selecionados e chegar próximo ao valor da satisfação obtida com aquela oferta. Como um agente não tem informações do outro agente, então o valor obtido na função *fitness* é uma estimativa do valor que poderia ser obtido na satisfação da oferta.

#### **4.4 Considerações Finais**

Neste capítulo foram apresentados os passos para o desenvolvimento do ambiente computacional de simulação de negociações. Este ambiente inclui a realização de um processo de negociação bilateral de multi-critério, bem como a incorporação, tanto no agente comprador quanto no agente vendedor, da capacidade de aprender a partir das experiências passadas e aplicar o aprendizado em negociações futuras, esperando que estas últimas produzam um resultado melhor em termos de satisfação de cada negociador envolvido.

Pôde-se constatar que a adoção da abordagem evolucionária, em particular, por meio dos algoritmos genéticos, foi decisiva para se obter um modelo simples e operacional de reconfiguração dinâmica e autônoma do módulo de negociação de cada agente, seja ele um comprador ou um vendedor.

A avaliação de desempenho, de cada agente em sessões de negociações, será apresentada na próxima seção. Para tal, alguns cenários foram definidos e executados.

# Capítulo 5

---

## EXPERIMENTOS E AVALIAÇÃO DOS RESULTADOS

### 5.1 Introdução

Este capítulo está basicamente dividido em duas seções. A primeira seção define o domínio de cada parâmetro utilizado para definir a estratégia das negociações. Estes parâmetros correspondem às configurações de negociação, das táticas de negociação e do sistema de aprendizagem (ou algoritmo genético). Os parâmetros de negociação são também utilizados nas táticas e definem os pesos dos atributos. A segunda seção é dedicada à apresentação dos resultados das experimentações realizadas para um processo de negociação, onde é avaliado o desempenho de cada agente que negocia um produto, num primeiro momento, sem a capacidade de aprendizagem e, num segundo momento, dotado da capacidade de aprendizagem e adaptação.

### 5.2 Configuração dos Experimentos

O perfil de cada agente para uma dada negociação é definido por meio de um conjunto de parâmetros. Em termos práticos, cada parâmetro define um comportamento relativo à negociação ou à tática de negociação ou ainda ao processo de aprendizagem.

#### 5.2.1 Parâmetros de Negociação

Antes de iniciar uma negociação propriamente dita, cada agente precisa ser configurado com informações sobre o produto a ser negociado. Conforme mostra a Tabela 7, os atributos que definem os parâmetros da negociação são: preço (min, máx), e volume (min, máx), bem como os valores da constante  $K$  definidos pelas taxas do valor da oferta para o preço e para o volume. Ela também inclui os pesos dos atributos que vão auxiliar nos cálculos da utilidade da negociação. Deve-se notar que estes pesos são elementos de informação utilizados no processo de aprendizagem.

Tabela 7: Parâmetros da Negociação.

	<b>Comprador</b>	<b>Vendedor</b>
<b>Parâmetros de Negociação</b>		
Delivery Type	on-demand	on-demand
Duração	60 ut	60 ut
Preço	[10 ; 20]	[15 ; 30]
Volume	[1 ; 5]	[4 ; 9]
K - Preço	[0.01 ; 0.05 ; 0.1 ; 0.5]	[0.01 ; 0.05 ; 0.1 ; 0.5]
K - Volume	[0.01 ; 0.05 ; 0.1 ; 0.5]	[0.01 ; 0.05 ; 0.1 ; 0.5]
Peso - Preço	[0.75 ; 0.25]	[0.75 ; 0.25]
Peso - Volume	[0.25 ; 0.75]	[0.25 ; 0.75]

Além dos parâmetros relativos ao objeto que será transacionado, o processo de negociação de cada agente requer um conjunto inicial de parâmetros de configuração para as táticas de negociação a serem utilizadas.

### 5.2.2 Parâmetros das Táticas de Negociação

Um processo de negociação é fundamentado sobre um processo de decisão local e troca de informações sobre um objeto, por exemplo, via mensagem. Entretanto, cada agente precisa minimamente de conhecimentos táticos para saber quando e como gerar uma oferta ou contra-oferta. Em termos práticos, as táticas de negociação são responsáveis por determinar os cálculos que serão realizados para os valores de cada atributo para uma nova oferta. Cada tática tem um comportamento próprio e utiliza um conjunto de parâmetros específicos que servem de base para suas execuções. Nos experimentos foram utilizadas apenas duas táticas, que são: a tática *dependente do tempo* e tática *imitativa*. Os valores para tais parâmetros encontram-se na Tabela 8.

Tabela 8: Parâmetros das Táticas de Negociação.

	<b>Comprador</b>	<b>Vendedor</b>
<b>Tática Dependente do Tempo</b>		
Conceder	$\beta = [5 ; 10 ; 25 ; 40]$	$\beta = [5 ; 10 ; 25 ; 40]$
Linear	$\beta = [1]$	$\beta = [1]$
Boulware	$\beta = [0.05 ; 0.1 ; 0.2 ; 0.5]$	$\beta = [0.05 ; 0.1 ; 0.2 ; 0.5]$
Função	[Poly ; Exp]	[Poly ; Exp]
Peso	[0.7 ; 0.3]	[0.7 ; 0.3]
<b>Tática Imitativa</b>		
Relative TFT	$\delta = [1 ; 2]$	$\delta = [1 ; 2]$
Peso	[0.3 ; 0.7]	[0.3 ; 0.7]

Dentro do nosso propósito, que é a concepção e a realização de um processo de negociação distribuído sobre um conjunto de entidades autônomas dotados da capacidade de adaptação, a abordagem adotada requer também que um conjunto de parâmetros de configuração do método de aprendizagem seja fornecido.

### 5.2.3 Parâmetros do Método de Aprendizagem

A execução do processo de aprendizagem em cada agente tem por objetivo identificar os melhores conjuntos de parâmetros para definir a melhor estratégia para uma negociação. A abordagem adotada para realizar a aprendizagem foi a evolucionária, em particular, o algoritmo genético. O ponto forte de qualquer algoritmo genético é a função que realiza o cálculo do *fitness*, que neste trabalho está diretamente relacionado com o cálculo da utilidade. No nosso caso, o objetivo desta função é identificar antecipadamente o melhor conjunto de parâmetros para definir uma estratégia. A Tabela 9 mostra os parâmetros e seus respectivos valores utilizados no processo de aprendizagem, em particular, para configurar o algoritmo genético responsável pela tarefa de encontrar o melhor conjunto de parâmetros a ser usado em uma negociação futura. Relembramos que o método de seleção utilizado neste trabalho foi à seleção por *ranking*.

Tabela 9: Parâmetros do Método de Aprendizagem.

<b>Parâmetros do Algoritmo Genético</b>	
Tamanho da População	100
Gerações	50
Taxa de Cruzamento	85%
Taxa de Mutação	5%
Genes	14
Método de Seleção	Ranking
Cruzamento	1 pt ; 2 pt

Espera-se que tal abordagem tenha produzido, ao final de uma negociação, resultados superiores àqueles obtidos em negociações onde os agentes não foram dotados da capacidade de aprendizagem e adaptação. Desta forma, espera-se ter contribuído para definição de um processo de negociação, cujo estilo ganha-ganha seja vantajoso para ambos os papéis: comprador e vendedor.

### 5.3 Avaliação dos Resultados

Os resultados, para efeito de verificação de desempenho dos agentes envolvidos em processo de negociação, foram obtidos após a definição e a realização de alguns cenários onde os agentes negociavam um produto, utilizando ou não as suas capacidades de aprendizagem e adaptação. Neste contexto, salienta-se que o principal item de avaliação e comparação das negociações, no contexto dos diferentes cenários, é o valor de satisfação de cada agente, dado pela fórmula F-4.1 (pág. 59) para o comprador e pela fórmula F-4.2 (pág. 59) para o vendedor. O valor da satisfação dos agentes é medido na escala de 0 (zero) a 7 (sete).

Os cenários definidos para tanto foram 3, que se caracterizam de forma resumida como segue:

CENÁRIO I, os agentes negociam um produto sem colocar em prática as suas capacidades de aprendizagem e adaptação. Eles são avaliados em termos dos valores obtidos para o quesito satisfação.

CENÁRIO II, os agentes negociam um produto, porém apenas o comprador coloca em prática as suas capacidades de aprendizagem e adaptação. Neste cenário, o algoritmo genético é executado ao final de cada negociação. Eles também são avaliados em termos dos valores obtidos para o quesito satisfação.

CENÁRIO III, os agentes negociam um produto e ambos os agentes, comprador e

vendedor, colocam em prática as suas capacidades de aprendizagem e adaptação. Eles também são avaliados em termos dos valores obtidos para o quesito satisfação.

### 5.3.1 Cenário I

Neste cenário, os agentes negociam um produto sem colocar em prática as suas capacidades de aprendizagem e adaptação. Eles são avaliados em termos dos valores obtidos para o quesito satisfação. Foram efetuadas 30 negociações com parâmetros escolhidos aleatoriamente, tomando como base a Tabela 7 e a Tabela 8, tanto para o agente comprador como para o agente vendedor. Os parâmetros foram escolhidos aleatoriamente para não influenciar a negociação para um ou para outro agente. A Figura 21 mostra o gráfico comparativo dos valores de satisfação para o agente comprador e para o agente vendedor em cada uma das 30 negociações. Pode-se observar que tais valores de satisfação não descrevem uma trajetória de estabilidade e os valores de satisfação são baixos. Isto tem ocorrido na maioria das vezes quando as negociações são fechadas próximas aos seus tempos limites. Desta forma, cabe lembrar que tal limite é um dos pesos utilizados no cálculo de satisfação. A média de satisfação do agente comprador e do agente vendedor foi de 1,22.

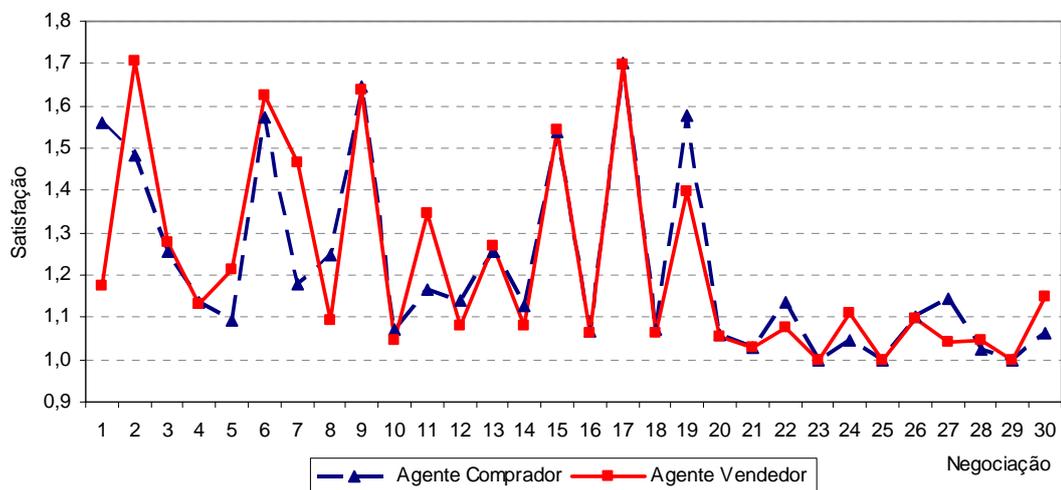


Figura 21: Satisfação dos Agentes Comprador e Vendedor – Cenário I.

Durante o processo de negociação, uma *LOG* foi gerada contendo informações sobre as trocas de ofertas entre os agentes. Estas informações estão preparadas para serem utilizadas no processo de aprendizagem, lembrando que cada conjunto de informações de uma

negociação é um cromossomo utilizado pelo algoritmo genético. Após executar o processo de aprendizagem, o agente comprador tem à sua disposição, um conjunto de parâmetros de negociação que deve ser melhor do aquele que ele utilizou para negociar anteriormente (ver Figura 22).

tempo	precoWgt	volumeWgt	txTime	txlmitation	Kpreco	Kvolume	BetaValue	stepValue	funcType
0,80	0,75	0,25	0,70	0,30	0,10	0,10	40,00	1,00	Poly

Figura 22: Conjunto de parâmetros obtidos no processo de aprendizagem.

Este novo conjunto de parâmetros define a melhor estratégia e ele será utilizado no contexto do Cenário II, onde apenas o agente comprador fará uso.

### 5.3.2 Cenário II

Neste cenário, foram efetuadas 30 negociações cujas estratégias tiveram seus parâmetros alterados em função dos resultados obtidos por meio do processo de aprendizagem aplicado sobre a *LOG* de negociação do agente comprador. Neste cenário, os agentes também são avaliados de acordo com os valores obtidos para o quesito satisfação. Porém, os parâmetros para o agente vendedor foram escolhidos aleatoriamente, enquanto que, para o agente comprador utilizou-se do resultado produzido por seu mecanismo de aprendizagem.

A Figura 23 mostra o gráfico correspondente ao Cenário II, onde são exibidos de forma comparativa os valores de satisfação tanto do agente comprador, que fez uso do processo de aprendizagem e adaptação, quanto do agente vendedor, o qual não fez uso do processo de aprendizagem e adaptação. Pode-se observar que os valores satisfação do agente comprador crescem significativamente, enquanto que os valores de satisfação do agente vendedor decrescem de forma considerável à medida que novas negociações são executadas. A utilização da aprendizagem na reconfiguração da estratégia do agente comprador impactou negativamente nos valores de satisfação do agente vendedor. Isto ocorreu devido à identificação e utilização de uma boa estratégia para o agente comprador, enquanto que o agente vendedor continuou com uma estratégia baseada em um comportamento aleatório.

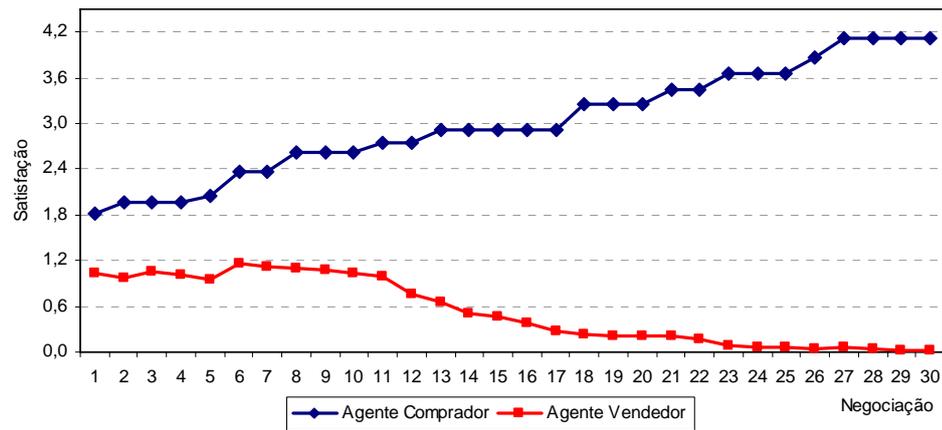


Figura 23: Satisfação do Agente Comprador e Vendedor – Cenário II.

Deve-se destacar que a média dos valores de satisfação para o agente comprador ficou em 3,01, contra 0,53 para o agente vendedor. Observa-se que o crescimento médio dos valores de satisfação para o agente comprador foi de 59%, confrontando os seus resultados no Cenário I e no Cenário II.

O próximo cenário mostra a situação onde ambos os agentes, comprador e vendedor, fazem uso prático de suas capacidades de aprendizagem e adaptação.

### 5.3.3 Cenário III

Neste cenário, foram efetuadas negociações cujas estratégias tiveram seus parâmetros alterados em função dos resultados obtidos por meio processo de aprendizagem, tanto para o agente comprador quanto para o agente vendedor.

Deve-se salientar aqui que cada agente realiza a aprendizagem com informações da sua log local de negociação. As *logs* utilizadas para o processo de aprendizagem foram com todas as negociações obtidas tanto no primeiro cenário como no segundo cenário. Com isso foi possível aproveitar o conjunto de parâmetros que poderiam ter sido utilizados no primeiro cenário e que não estavam presentes no segundo cenário. Cada conjunto de informações de uma negociação é um cromossomo para o algoritmo genético empregado. Após a aplicação do processo de aprendizagem foram identificados os conjuntos de parâmetros de reconfiguração para o agente comprador, bem como os conjuntos de parâmetros de reconfiguração para o agente vendedor.

Para analisar melhor a evolução dos resultados, nesta fase foram efetuadas 50

negociações com parâmetros que tiveram as melhores avaliações durante o processo de aprendizagem. É importante destacar que o processo de reaprendizagem foi executado em cada negociação.

O gráfico da Figura 24 mostra de forma comparativa os valores de satisfação tanto do agente comprador quanto do agente vendedor, ambos se utilizaram de seus processos de aprendizagem e adaptação, para cada negociação efetuada. Pode-se observar que nas primeiras negociações o agente comprador obteve melhores resultados, pois a base de aprendizagem estava mais evoluída contendo informações provenientes do Cenário II. Já o agente vendedor, que não tinha informações evoluídas, obteve valores de satisfação menores. Entretanto, na medida em que as negociações foram ocorrendo e o processo de aprendizagem e adaptação aplicado para ambos os agentes, o agente vendedor também conseguiu melhorar a sua estratégia de negociação. No decorrer de um número maior de negociações, observa-se que ambos os agentes buscam o *ganha-ganha*, fazendo com que os seus valores de satisfação aproximem-se.

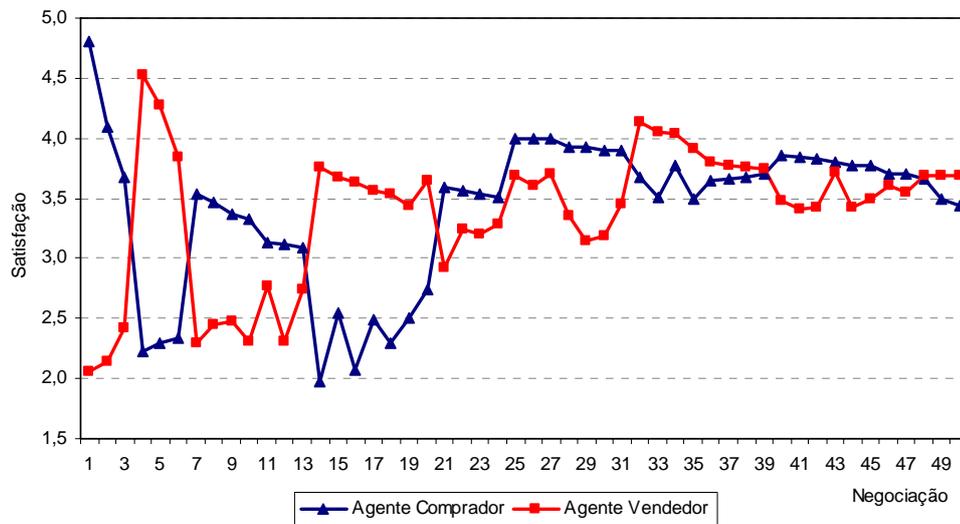


Figura 24: Satisfação do Agente Comprador e Vendedor – Cenário III.

Aqui, deve-se destacar que a média dos valores de satisfação para o agente comprador foi de 3,42 e para o agente vendedor foi de 3,38. Observa-se que crescimento médio dos valores de satisfação tanto para o agente comprador como para o agente vendedor foi de 64%, confrontando os seus resultados no Cenário I e no Cenário III. É importante notar que o agente comprador melhorou em 12% os seus valores de satisfação comparando o Cenário II e

Cenário III. Pode-se dizer, com certa cautela, que a capacidade de aprendizagem e adaptação aplicada em ambos os agentes é mais benéfica que apenas em um ou em outro.

#### **5.4 Considerações Finais**

Os experimentos foram estruturados em três cenários, cujo objetivo era colocar em evidência a capacidade de aprendizagem e de adaptação tanto do agente comprador como do agente vendedor. A consecução deste objetivo pode ser verificada no Cenário III, onde tanto o agente comprador melhorou seus valores de satisfação de forma significativa quanto o agente vendedor. É possível observar através da análise dos gráficos que o método atenua consideravelmente as oscilações de negociação e converge para uma estabilização e a tendência de uma negociação do tipo *ganha-ganha*.

## Capítulo 6

---

### CONCLUSÕES E TRABALHOS FUTUROS

#### 6.1 Discussão

A negociação é uma forma de tomada de decisão que envolve duas ou mais partes, onde cada parte não pode tomar decisões independentemente e é requisitada a fazer concessões para chegar a um acordo. Tal tomada de decisão pró-ativa é uma capacidade importante e própria dos seres humanos que pode ser reproduzida no mundo virtual, mesmo em processos complexos como a negociação comercial. A principal dificuldade da pró-atividade concerne em utilizar experiências passadas para melhorar uma tomada de decisão ou uma negociação no futuro.

A instanciação de um processo de negociação colaborativo entre dois agentes, a saber: um vendedor e um comprador, não é uma atividade trivial. A política de geração dinâmica de ofertas e contra-ofertas é central neste tipo de problema. De forma clássica, tal política pode ser fornecida totalmente pelo projetista ao sistema de negociação de cada agente. Entretanto, esta forma de projetar é insuficiente para um sistema autônomo, i.e., conceber um sistema correto não é suficiente. Ele precisa ser adaptativo.

A solução desenvolvida para a política de geração dinâmica de ofertas e contra-ofertas consistiu em dotar cada parte envolvida no processo de negociação de capacidade de aprendizagem e de adaptação. Cada agente descobre o melhor conjunto de parâmetros para configurar suas táticas de ofertas e contra-ofertas por meio da aplicação de um algoritmo genético sobre uma base de dados local. Esta base reúne o histórico das ofertas e contra-ofertas referentes a negociações anteriores. A evolução positiva dos níveis de satisfação de cada agente, mostrado em particular no Cenário III dos experimentos, conformam a tese que se pode automatizar um processo de negociação na forma de sistema autônomo de tomada de decisão.

O uso de um algoritmo genético para selecionar os melhores valores de configuração do módulo de negociação de cada agente mostrou-se bastante apropriado. Em outras palavras, mostrou-se que é possível identificar por meio do cálculo do *fitness* o melhor conjunto de

parâmetros para configurar a estratégia de negociação de um agente. Trata-se aqui de uma informação qualitativa.

## 6.2 Conclusão

O objetivo geral deste trabalho foi viabilizar um processo de aprendizagem de máquina para um modelo negociação bilateral, cujas entidades negociadoras são agentes distribuídos, autônomos e independentes. A utilização do algoritmo genético permitiu a colocação em prática do processo de aprendizagem de máquina em cada agente, e também chegar ao objetivo de identificar melhores conjuntos de parâmetros para uma negociação futura.

Para a verificação do objetivo geral, três cenários de testes foram desenvolvidos. No primeiro cenário dos experimentos foram feitas negociações sem utilizar o processo de aprendizagem. Os parâmetros foram selecionados de forma aleatória tanto pelo agente comprador como pelo agente vendedor, dentro de um domínio pré-definido. Neste cenário, notou-se um baixo desempenho na satisfação dos agentes. A baixa satisfação de ambos os agentes indica que as negociações foram finalizadas com pouca vantagem para um ou para outro agente. Durante a execução das negociações, as informações geradas foram armazenadas para serem utilizadas no processo de aprendizagem. No segundo cenário dos experimentos foram feitas negociações utilizando conhecimentos obtidos no processo de aprendizagem apenas para o comprador. Para o agente vendedor, os parâmetros foram selecionados de forma aleatória, dentro de um domínio pré-definido. Neste cenário, notou-se que a satisfação do agente comprador foi superior em relação ao primeiro cenário. Já o agente vendedor manteve a instabilidade nos seus valores de satisfação. Já no terceiro cenário, tanto o agente comprador como o agente vendedor utilizou o processo de aprendizagem para definir a estratégia de negociação. Neste cenário foi notou-se o crescimento dos valores de satisfação tanto do agente comprador como do agente vendedor. Além disso, pode-se também observar, juntamente com o crescimento dos valores da satisfação para ambos os agentes e a tendência de uma negociação do tipo ganha-ganha. Esta tendência é importante, tratando-se de agentes cooperativos.

Deve-se enfatizar que a melhoria dos valores de satisfação de cada agente negociador teve seu ápice quando ambos os participantes de uma sessão de negociação se utilizaram suas

capacidades de aprendizagem e de adaptação.

Em resumo, esta pesquisa avaliou uma forma de utilizar aprendizagem de máquina no processo de negociação comercial baseada em agentes autônomos independentes. A aprendizagem do melhor conjunto de parâmetros de configuração do módulo de negociação de um agente por meio de um algoritmo genético revelou-se bastante apropriada, em particular, por fornecer uma abordagem simples e eficiente, bem como uma informação qualitativa.

### **6.3 Trabalhos Futuros**

Alinhados com a aprendizagem aplicada à negociação bilateral, ficam deste trabalho diversos apontadores para trabalhos futuros. Por um lado, a aplicação de diferentes métodos de aprendizagem de máquina e de adaptação dinâmica do comportamento de um agente poderia constituir uma grande fonte de ensinamentos e permitir avaliar a eficiência dos diversos métodos de aprendizagem em diferentes modelos de negociação, bilateral ou multilateral. Por outro lado, ficam também em aberto algumas possíveis melhorias a introduzir no ambiente de simulação, tais como: criação dinâmica de agentes com boas estratégias de negociação para a compra e venda de produtos nunca negociados, introdução de mecanismos de detecção de mudanças de conceitos em políticas de ofertas, bem como de explicitação dos conhecimentos descobertos sobre as melhores configurações para as estratégias de negociação.

# Capítulo 7

---

## REFERÊNCIAS BIBLIOGRÁFICAS

ADRIAANS, P. & ZANTINGE D. (1996). **Data Mining**. Addison-Wesley Professional (1996), ISBN-10: 0201403803.

AHA, D. W.; KIBLER, D.; ALBERT, M. K. (1991). **Instance-based Learning Algorithms**. In: Machine Learning. 6(1), pág. 37-66.

ALPAYDIN, E. (2004). **Introduction to Machine Learning (Adaptive Computation and Machine Learning)**, MIT Press.

ANTHONY, P.; HALL, W.; DUNG, D. V.; JENNINGS, N. R. (2001). **Autonomous agents for participating in multiple online auctions**. In Proc. of the IJCAI Workshop on EBusiness and the Intelligent Web, Seattle WA, USA.

BELLIFEMINE, F.; CAIRE, G.; POGGI, A.; RIMASSA, G. (2003). **Jade, A White Paper**, Exp, Volume 3, N. 3.

BISHOP, C. M. (2007). **Pattern Recognition and Machine Learning**. Springer.

BOND, A. H.; GASSER, L. (1998). **Readings in Distributed Artificial Intelligence**. Morgan Kaufmann Publishers: San Mateo, CA, 1988, 1st edition.

CARVALHO, D. R.; FREITAS, A. A. (2000). **A hybrid decision tree/genetic algorithm for coping with the problem of small disjuncts in data mining**. Proc. Genetic and Evolutionary Computation (GECCO-2000), pág. 1061-1068, Las Vegas, NV, USA.

DARWIN, C. (1994). **On The Origin of Species: by means of Natural Selection, or the preservation of favoured races in the struggle for life.** Origem das Espécies. Tradução do original feita por Eugênio Amado. Belo Horizonte: Villa Rica.

DE PAULA, G. E. (2001). **Modelo de Negociação Bilateral para Comércio Eletrônico.** Dissertação de Mestrado. Universidade Federal de Pernambuco, Centro de Informática, Recife.

DEB, K. (2001). **Multi-Objective Optimization using Evolutionary Algorithms.** John Wiley & Sons, Inglaterra.

DIETTERICH, T. (1997). **Machine learning research: Four current directions.** AI magazine, pág. 97–136.

ENEMBRECK, F.; AVILA, B. C. (2006). **KNOMA: A new approach for knowledge integration.** In 11th IEEE Symposium on Computers and Communications, pág. 898–903.

ENEMBRECK, F.; AVILA, B. C.; SCALABRIN, E.; BARTHÈS, J. (2007). **Learning Drifting Negotiations.** In: Applied Artificial Intelligence International Journal, Volume 21, Issue 9, pág. 861-881.

FARATIN, P.; SIERRA, C.; JENNINGS, N. R. (1998). **Negotiation Decision Function for Autonomous Agents.** Int. Journal of Robotics and Autonomous Systems, pág. 159-182.

FARATIN, P.; SIERRA, C.; JENNING, N. R. (2003). **Using Similarity Criteria to Make Negotiation Trade-Offs.** In: Journal of Artificial Intelligence 142(2), pág. 205-237.

FAYYAD, U. M.; PIATETSKY-SHAPIRO, G.; SMYTH, P.; UTHURUSAMY, R. (1996). **Advances in knowledge discovery and data mining.** Menlo Park, Califórnia EUA: AAAI Press, Cap.1.

FERBER, J. (1999). **Multi-Agent Systems: An Introduction to Distributed Artificial Intelligence**. Addison-Wesley Pub Co; 1st Edition.

FIPA. (2008). **Foundation for Intelligent Physical Agents**, <http://www.fipa.org/>, visitado em Janeiro de 2008.

FREITAS, A. A.; LAVINGTON, S. H. (1998). **Mining Very Large Databases With Parallel Processing**. Kluwer Academic Publishers, London, ISBN: 0792380487, pág. 208.

FREITAS, A. A. (2000). **Understanding the Crucial Differences Between Classification and Discovery of Association Rules**. SIGKDD Explorations. V.2, No.1, pág. 65-69.

GAMA, J.; MEDAS, P.; RODRIGUES, P. (2004). **Learning with Drift Detection**. Proc. of the 17th Brazilian Symposium on Artificial Intelligence. SBIA'04, LNAI 3171.

GAMBERGER, D.; LAVRAC, N.; KRSTACIC, G. (2002). **Confirmation rule induction and its applications to coronary heart disease diagnosis and risk group discovering**. Journal of Intelligent and Fuzzy Systems: Applications in Engineering and Technology, pág. 12:35–48.

GASSER, L. (1989). **Distributed Artificial Intelligence**. ISSN:0888-3785. San Francisco, CA, USA, pág. 26-33.

GOLDBERG, D. (1989). **Genetic Algorithm in Search, Optimization and Machine Learning**. Addison-Wesley Publishing Company, Inc., Cap 1-4.

HE, M.; JENNINGS, N. R.; LEUNG, H. (2003). **On agent-mediated electronic commerce**. IEEE Trans on Knowledge and Data Engineering 15 (4), pág. 985-1003.

HERRERA, F.; LOZANO, M.; VERDEGAY, J. L. (1998). **Tackling Real-Coded Genetic Algorithms: Operators and Tools for Behavioural Analysis**. In: Artificial Intelligence Review, Volume 12, Number 4, Springer, pág. 265-319(55).

HINDRIKS, K.; JONKER, C. M.; TYKHONOV, D. (2007). **Analysis of Negotiation Dynamics**. CIA '07, Springer, LNAI 4676, pág. 27-35.

HINTERDING, R. (2000). **Representation, Mutation and Crossover Issues in Evolutionary Computation**. In: Proc. Conference on Evolutionary Computation, pág. 916-923.

HOLLAND, J. H. (1975). **Adaptation in Natural and Artificial Systems**. University of Michigan Press, Ann Arbor.

HORLING, B.; LESSER, V. (2001). **A Survey of Multi-Agent Organizational Paradigms**. Multi-Agent Systems Lab, Department of Computer Science, University of Massachusetts, Amherst, USA.

JONKER, C. M.; TREUR, J. (2001). **An Agent Architecture for Multi-Attribute Negotiation**. In: Proc. of the 17th Int. Joint Conference on AI (IJCAI'01), pág. 1195-1201.

KERSTEN, G.; MICHALOWISK, W.; SZPAKOWICZ, S.; KOPERCZAK, Z. (1991). **Restructurable representations of negotiation**. Management Science.

KERSTEN, G.; NORONHA, S.; TEICH, J. (2000). **Are All E-Commerce Negotiations Auctions?** Fourth International Conference on the Design of Cooperative Systems (COOP'2000). Sophia-Antipolis, France.

KRAININ, M.; AN, B.; LESSER, V. (2007). **An Application of Automated Negotiation to Distributed Task Allocation**. IEEE/WIC/ACM International Conference on Intelligent Agent Technology (IAT 2007), IEEE Computer Society Press, pág. 138-145.

LACERDA, E.; CARVALHO, A. (1999). **Introdução aos algoritmos genéticos**. Anais do XIX Congresso Nacional da Sociedade Brasileira de Computação, Vol. 2, pág. 51.126.

LANGLEY, P.; SIMON, P. (1995). **Applications of machine learning and rule induction.** Communications of the ACM, pág. 38:55–64.

LAU, R. Y. K. (2005). **Adaptive negotiation agents for e-business.** ACM International Conference Proceeding Series. Vol. 113, NY, USA, pág. 271-278.

LEEN-KIAT, S.; XIN L. (2004). **Adaptive, Confidence-Based Multiagent Negotiation Strategy Computer Science and Engineering.** University of Nebraska-Lincoln AAMAS'04, 2004, New York, New York, USA.

LESSER, V. R. (1998). **Reflections on the Nature of Multi-Agent Coordination and Its Implications for an Agent Architecture.** In: Autonomous Agents and Multi-Agent Systems. Vol 1. pág. 89-111.

MATOS, N.; SIERRA, C.; JENNINGS, N. R. (1998). **Determining Successful Negotiation Strategies: An Evolutionary Approach.** In Proceedings, Third International Conference on Multi-Agent Systems (ICMAS-98). IEEE Computer Society. pág. 182-189.

MIA, M; MUDUR, S. P.; RADHAKRISHNAN, T. (2005). **An Interactive System for Negotiation in E-commerce with Incremental User Knowledge.** Proceedings of the 2005 conference of the Centre for Advanced Studies on Collaborative research table of contents, Toronto, Canadá.

MICHALEWICZ, Z. (1996). **Genetic Algorithms + Data Structure = Evolution Programs.** Berlin, New York, 3<sup>o</sup>ed Springer Verlag.

MICHALSKI, R. S.; CARBONELL, J. G.; MITCHELL, T. M. (1983). **Machine Learning: An Artificial Intelligence Approach.** Tioga Publishing Company.

MIERSWA, I.; WURST, M.; KLINKENBERG, R.; SCHOLZ, M.; EULER, T. (2006). **Rapid Prototyping for Complex Data Mining Tasks.** In Proceedings of the 12th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD-06).

MITCHELL, M. (1997). **An introduction to genetic algorithms**. Cambridge: Mit Press. p. 207.

PENG, Y.; KOU, G.; SHI, Y.; CHEN Z. (2006). **A Systemic Framework for the Field of Data Mining and Knowledge Discovery**. In Proceeding of workshops on The Sixth IEEE International Conference on Data Mining (ICDM).

PRUITT, D. G. (1981). **Negotiation behavior**. New York: Academic Press.

QUINLAN, J. R. (1979). **Discovering rules by induction from large collections of examples**. In: Expert Systems in the Micro Electronic Age. Edinburgh, UK: Edinburgh University Press.

QUINLAN, J. R. (1993). **C4.5: Programs for Machine Learning**. San Mateo, CA, Morgan Kaufmann.

RAHWAN, I.; KOWALCZYK, R.; PHAM, H. H. (2002). **Intelligent Agents for Automated One-to-Many E-Commerce Negotiation**. Proc. of the 25th Australasian Computer Science Conference (ACSC ), Melbourne, Australia, pág. 197-204.

RAIFFA, H. (1982). **The Art & Science of Negotiation**. Harvard University Press, Cambridge, Massachusetts.

RAIFFA, H.; RICHARDSON, J.; METCALFE, D. (2002). **Negotiation Analysis: The Science and Art of Collaborative Decision Making**. Harvard University Press, Cambridge.

RAMALHO, G.; PAULA, G.; RAMOS, F. (2003). **Bilateral Negotiation Model for Agent Mediated Electronic Commerce**. London, Springer-Verlag.

RECK, R. R.; LONG, B. G. (1990). **The win-win negotiator. How to negotiate favorable agreements the last**. Hardcover, Sec. Edition.

ROMANHUKI, E.; FUCKNER, M.; ENEMBRECK, F.; AVILA, B.; SCALABRIN, E. E. (2008). **Improving Bilateral Negotiation with Evolutionary Learning**. In Proceedings of the 12th International Conference on Computer Supported Cooperative Work in Design (CDCWD 2008), Volume I, Xi'an, China, p. 343-349.

SAHA, S. (2006). **Improving Agreements in Multi-Issue Negotiation**. In: Journal of Electronic Commerce Research. Vol 7, No.1, University of Tulsa.

SANDHOLM, T. W. (1993). **An implementation of the contract net protocol based on marginal cost calculations**. In Eleventh National Conference on Artificial Intelligence (AAA-93), pág. 256-262, Washington D.C.

SANTOS, C. T.; BAZZAN, A. (2005). **Integrating knowledge through cooperative negotiation - a case study in bioinformatics**. Int. Workshop on Autonomous Intelligent Agents: Agents and Data Mining.

SCHOONMAKER, A. N. (1989). **Negotiate to Win: Gaining the Psychological Edge**. Englewood Cliffs, N.J.: Prentice Hall Trade.

SHMEIL, M. (1999). **Sistemas Multiagentes na Modelacao da Estrutura e Relação de Contratação de Organizações**. Tese de doutorado. Faculdade de Engenharia da Universidade do Porto.

SMITH, R. G. (1980). **The Contract Net Protocol: High-Level Communication and Control in a Distributed Problem Solver**. IEEE Trans. on Computers.

UOL. (2006). **Mundo atinge 1 bilhão de usuários de internet**. Universo On-Line, <http://idgnow.uol.com.br/internet/2006/05/19/idgnoticia.2006-05-19.2158242015/> site visitado em Janeiro de 2008, Pesquisa realizada em 2006.

UOL. (2007). **E-commerce no Brasil movimentou R\$ 1,08 bi no Natal de 2007**. Universo On-Line, <http://idgnow.uol.com.br/internet/2007/12/27/idgnoticia.2007-12-27.8074799320/>, site visitado em Janeiro de 2008, Pesquisa realizada em 2007.

URSEM, R. K. (2002). **Diversity-guided evolutionary algorithms**. Proceedings of PPSN 2002, pág. 462-471.

WEISS, G. (1999). **Multiagent Systems. A Modern Approach to Distributed Artificial Intelligence**. MIT Press.

WERNER, E. (1989). **Cooperating agents: A unified theory of communication and social structure**. In L.Gasser, and Huhns, M., eds., Distributed Artificial Intelligence, Volume 2. Morgan Kaufmann Publishers. pág. 3-36.

WOOLDRIGE, N.; JENNINGS, R. (1995). **Intelligent agents: Theory and practice**. Knowledge Engineering Review.

ZENG, D., SYCARA, K. (1998). **Benefits of Learning in Negotiation**. International Journal of Human Computer Systems, Vol. 48, pág. 125-141.

ZHANG, X.; LESSER, V.; WAGNER, T. (2006). **Integrative Negotiation Among Agents Situated in Organizations**. IEEE Transactions on Systems, Man, and Cybernetics, Part C, Volume 36, Number 1, IEEE Computer Society, pág. 19-30.