



Tese de Doutorado

**Metamodelo para adaptação de confiança e reputação  
em sistemas multiagente dinâmicos**

**Bruno Werneck Pinto Hoelz**

Brasília, setembro de 2013

**UNIVERSIDADE DE BRASÍLIA**

**FACULDADE DE TECNOLOGIA**



UNIVERSIDADE DE BRASÍLIA  
Faculdade de Tecnologia

Tese de Doutorado

**Metamodelo para adaptação de confiança e reputação  
em sistemas multiagente dinâmicos**

**Bruno Werneck Pinto Hoelz**

*Relatório submetido ao Departamento de Engenharia  
Elétrica como requisito parcial para obtenção  
do grau de Doutor em Engenharia Elétrica*

Banca Examinadora

Prof. Dra. Célia Ghedini Ralha, CIC/IE \_\_\_\_\_  
*Orientadora*

Prof. Dr. Jaime Simão Sichman, EP/USP \_\_\_\_\_  
*Examinador externo*

Prof. Dra. Alba Cristina M Alves de Melo, \_\_\_\_\_  
CIC/IE  
*Examinadora externa*

Prof. Dr. Alexandre Ricardo S. Romariz, \_\_\_\_\_  
ENE/FT  
*Examinador interno*

Prof. Dr. Wesley Pacheco Calixto, ENE/FT \_\_\_\_\_  
*Examinador interno*



## **Dedicatória**

*Aos meus pais e irmão, pelo apoio e incentivo.*

*A minha noiva, Renata, por me dar força nesta longa caminhada.*

*Bruno Werneck Pinto Hoelz*

---

## RESUMO

Modelos computacionais de confiança e reputação são elementos-chave no projeto de sistemas multiagente abertos. Eles oferecem um meio de avaliar e reduzir o risco de cooperação na presença de incerteza. No entanto, os modelos propostos na literatura não consideram os custos envolvidos na sua aplicação e como os modelos são afetados pela dinamicidade do ambiente. Neste trabalho, um metamodelo para adaptação de confiança e reputação em sistemas multiagente dinâmicos é proposto. O metamodelo tem como finalidade complementar os modelos de confiança e reputação já existentes, permitindo que agentes deliberativos possam raciocinar sobre os componentes do modelo em uso e reagir a mudanças no ambiente. O processo de adaptação é realizado ajustando a configuração do modelo adotado para melhor se adequar às condições atuais. É demonstrado como o metamodelo pode ser aplicado a modelos propostos na literatura e como planos de adaptação podem ser utilizados para ajustar seus componentes dinamicamente para melhorar seu desempenho. Um mecanismo de aprendizagem, incluindo uma prova de conceito baseada em algoritmos genéticos, é proposto para identificar novos planos de adaptação para cenários similares. Por fim, a avaliação experimental da aplicação do metamodelo e do mecanismo de aprendizagem mostra melhorias significativas em comparação com o uso de modelos não adaptáveis, o que contribui para a melhoria do projeto de agentes autônomos para sistemas multiagente dinâmicos.

---

## ABSTRACT

Computational trust and reputation models are key elements in the design of open multi-agent systems. They offer a way of evaluating and reducing risks of cooperation in the presence of uncertainty. However, the models proposed in the literature do not consider the costs they introduce and how they are affected by dynamic environments. In this work, a meta-model for trust and reputation adaptation in dynamic multi-agent systems is proposed. The meta-model acts as a complement to trust and reputation models, by allowing deliberative agents to reason about the components of the model being used, and to react to changes in the environment. The adaptation process is made by adjusting the model's configuration to better fit the current conditions. It is demonstrated how the meta-model can be applied to existing models proposed in the literature, and how adaptation plans can be used to adjust its components dynamically to improve its performance. A learning mechanism, along with a proof of concept implementation based on genetic algorithms, is proposed to identify new adaptation plans for similar scenarios. Finally, the experimental evaluation of the meta-model application and its learning mechanism shows significant improvements in comparison to the use of non-adaptable models. This contributes to improving the design of autonomous agents for dynamic multi-agent systems.

# SUMÁRIO

<b>1</b>	<b>Introdução</b> .....	<b>1</b>
1.1	CONTEXTUALIZAÇÃO .....	1
1.2	JUSTIFICATIVA .....	2
1.3	OBJETIVOS .....	3
1.4	CONTRIBUIÇÕES .....	4
1.5	METODOLOGIA .....	5
1.6	ORGANIZAÇÃO DA TESE .....	6
<b>2</b>	<b>Fundamentação teórica</b> .....	<b>7</b>
2.1	AGENTES INTELIGENTES .....	7
2.2	AMBIENTE .....	10
2.3	COORDENAÇÃO .....	11
2.4	MODELO BDI .....	14
<b>3</b>	<b>Confiança e reputação</b> .....	<b>23</b>
3.1	CONFIANÇA .....	23
3.2	REPUTAÇÃO .....	25
3.3	MODELOS COMPUTACIONAIS DE C&R .....	26
3.4	REVISÃO DOS MODELOS DA LITERATURA .....	28
3.5	RESUMO DOS MODELOS .....	50
<b>4</b>	<b>Metamodelo proposto</b> .....	<b>57</b>
4.1	VISÃO GERAL .....	57
4.2	METAMODELO DE C&R .....	58
4.3	FLUXO DE INFORMAÇÃO E DELIBERAÇÃO .....	73
4.4	METAMODELO DO AMBIENTE .....	76
4.5	MODELO DE ADAPTAÇÃO .....	82
4.6	APLICAÇÃO DO METAMODELO .....	85
4.7	APRENDIZAGEM DE PLANOS DE ADAPTAÇÃO .....	91
4.8	TRABALHOS CORRELATOS .....	95

<b>5</b>	<b>Avaliação experimental</b> .....	<b>99</b>
5.1	PLATAFORMA EXPERIMENTAL .....	99
5.2	METODOLOGIA .....	108
5.3	EXPERIMENTOS DE ADAPTAÇÃO .....	112
5.4	EXPERIMENTOS DE APRENDIZAGEM .....	127
<b>6</b>	<b>Conclusões</b> .....	<b>133</b>
	<b>Referências bibliográficas</b> .....	<b>137</b>
<b>A</b>	<b>Resumo do metamodelo</b> .....	<b>145</b>
<b>B</b>	<b>Modelos UML</b> .....	<b>149</b>
<b>C</b>	<b>Definição dos componentes</b> .....	<b>153</b>
<b>D</b>	<b>Código AgentSpeak</b> .....	<b>157</b>
<b>E</b>	<b>Análise estatística dos resultados</b> .....	<b>165</b>
<b>F</b>	<b>Configuração do algoritmo genético</b> .....	<b>169</b>

# LISTA DE FIGURAS

2.1	Interação do agente com o ambiente, adaptada de Russell e Norvig (2002) ....	7
2.2	Modelo de agente que mantém informações de estado, adaptada de Wooldridge (2009).....	9
2.3	Visão de um Sistema Multiagente (SMA), adaptada de Jennings (2000) .....	12
2.4	Taxonomia parcial de formas de coordenação em SMAs, adaptada de Weiss (1999).....	12
2.5	Organizações em forma de hierarquia e federação, adaptada de Horling e Lesser (2005).....	13
2.6	Arquiteturas propostas para SMA, adaptada de Braubach et al. (2008) .....	14
2.7	A arquitetura BDI do sistema PRS, adaptada de D’Inverno et al. (2004) .....	17
2.8	A arquitetura BDI proposta por Bratman et al. (1988) .....	18
2.9	Processos de planejamento, adaptada de Wooldridge (2009) .....	19
2.10	Arquitetura abstrata da plataforma Jadex, adaptada de Pokahr et al. (2005).	21
3.1	Visão de alto nível de um mecanismo de confiança, adaptada de Seigneur e Dondio (2011) .....	26
3.2	Cadeia de informação da confiança, adaptada de Staab e Muller (2012).....	26
3.3	Atitude, decisão e ação de confiar, adaptada de Castelfranchi (2008).....	27
3.4	Sistema de reputação centralizado, adaptada de Jøsang et al. (2007).....	28
3.5	Sistema de reputação distribuído, adaptada de Jøsang et al. (2007) .....	29
3.6	Confiança como uma relação de três partes.....	32
3.7	Caminhos possíveis para alcançar um objetivo, adaptada de Castelfranchi e Falcone (2001) .....	33
3.8	O modelo LIAR, adaptada de Vercouter e Muller (2010) .....	41
3.9	Rede bayesiana do modelo Blade (Regan et al., 2006) .....	45
3.10	Modelo HABIT visto como rede bayesiana, adaptado de Teacy et al. (2012) ..	47
4.1	Modelo de agente que inclui a adaptação de Confiança e Reputação (C&R) ..	59
4.2	Metamodelo de C&R .....	60
4.3	Metamodelo de uma fonte de informação .....	61
4.4	Interação com base nas fontes de informação.....	63
4.5	Efeitos da memória sobre a confiança .....	64

4.6	Confiabilidade da interação direta no ReGreT .....	66
4.7	Exemplo de processo de aquisição de informação .....	68
4.8	Confiança multidimensional.....	69
4.9	Tomada de decisão no LIAR, adaptada de Vercouter e Muller (2010).....	73
4.10	Fluxo de informação e deliberação da confiança .....	74
4.11	Fases de exploração, seleção e observações .....	74
4.12	Fluxo de informação no metamodelo proposto.....	75
4.13	Fases de observações e avaliações na visão da fonte de informação .....	76
4.14	Fases de intenções e atos de confiança .....	76
4.15	Fase de <i>feedback</i> do fluxo de informação.....	77
4.16	Metamodelo do ambiente .....	77
4.17	Modelo de adaptação proposto.....	82
4.18	Mapeamento do modelo de Marsh no metamodelo .....	85
4.19	Mapeamento do modelo SPORAS no metamodelo .....	87
4.20	Mapeamento dos modelo FIRE no metamodelo .....	87
4.21	Aprendizagem de planos de adaptação.....	92
4.22	Componentes do PTF, adaptada de Huynh (2009) .....	96
4.23	Processo de decisão da confiança, adaptada de Fullam e Barber (2007).....	97
5.1	Protocolos de interação da plataforma de avaliação ART, adaptada de Fullam et al. (2005) .....	100
5.2	Arquitetura de simulação da plataforma TREET, adaptada de Kerr e Cohen (2010).....	102
5.3	Cenário de teste do modelo ReGreT, adaptada de Sabater (2002) .....	103
5.4	Cenário de teste do modelo FIRE, adaptada de Huynh (2006).....	104
5.5	Rede de entrega de conteúdo multiagente .....	106
5.6	Configuração e geração do ambiente de simulação .....	107
5.7	Diagrama de sequência do processo de simulação .....	108
5.8	Memória e recência sem adaptação .....	114
5.9	Memória e recência com adaptação .....	115
5.10	Limiar de cooperação sem adaptação.....	118
5.11	Limiar de cooperação com adaptação .....	119
5.12	Escolha de agentes e o critério da intimidade .....	119
5.13	Nível de intimidade em ambientes estáticos diversos .....	120
5.14	Adaptação do nível de intimidade no cálculo da credibilidade .....	121
5.15	Aquisição de informação de reputação e utilidade .....	123
5.16	Custo da informação de reputação .....	124
5.17	Exploração das fontes de informação .....	125
5.18	Custo da exploração .....	126
5.19	Exploração da interação direta.....	127

5.20	Número de planos para cenários similares.....	130
5.21	Adequação dos planos para cenários similares .....	130
B.1	Principais interfaces do metamodelo.....	149
B.2	Interfaces do modelo de reputação .....	151
B.3	Interfaces do modelo de exploração .....	151
B.4	Interfaces do metamodelo do ambiente.....	151
F.1	Teste com diferentes configurações do AG .....	170



# LISTA DE TABELAS

3.1	Legenda das tabelas da Seção 3.5 .....	51
3.2	Características básicas dos modelos revisados .....	52
3.3	Fontes de informação e aspectos correlatos dos modelos revisados.....	54
3.4	Características operacionais dos modelos revisados .....	55
4.1	Fases da deliberação da confiança .....	78
4.2	Componentes do metamodelo do ambiente .....	79
4.3	Características do ambiente e suas dependências.....	92
4.4	Similaridade entre características de ambientes.....	94
5.1	Parâmetros da competição de 2007 da plataforma ART (Fullam, 2007) .....	101
5.2	Termos utilizados no teste de hipótese, adaptada de Huynh (2006) .....	109
5.3	Resumos dos experimentos .....	112
5.4	Configurações do Experimento 1.....	114
5.5	Configurações do Experimento 2.....	117
5.6	Configurações do Experimento 3.....	120
5.7	Configurações do Experimento 4.....	122
5.8	Configurações do Experimento 5a .....	125
5.9	Configurações do Experimento 5b .....	126
5.10	Parâmetros do modelo FIRE .....	128
5.11	Cenários de teste da aprendizagem .....	128
5.12	Configuração do algoritmo genético.....	129
A.1	Componentes do metamodelo de confiança .....	145
A.2	Componentes do metamodelo de reputação.....	146
A.3	Componentes do metamodelo de exploração.....	146
A.4	Componentes das fontes de informação .....	146
A.5	Componentes do metamodelo do ambiente .....	147
A.6	Definições do modelo de adaptação .....	147
C.1	Entradas e saídas dos componentes nas fases do processo de deliberação.....	154
F.1	Avaliação de diferentes configuração para o AG.....	169



# LISTA DE CÓDIGOS

2.1	Exemplos de crenças na linguagem AgentSpeak . . . . .	20
2.2	Exemplos de objetivos na linguagem AgentSpeak . . . . .	20
2.3	Exemplo de plano na linguagem AgentSpeak . . . . .	20
2.4	Definição da cabeça de um plano na plataforma Jadex . . . . .	22
2.5	Definição do corpo de um plano na plataforma Jadex . . . . .	22
3.1	Imagem e reputação no modelo BDI+Repage . . . . .	43
4.1	Exemplos de crenças do modelo de adaptação . . . . .	83
4.2	Exemplos de objetivos de monitoramento do modelo de adaptação . . . . .	83
4.3	Crenças relacionadas ao mapeamento de componentes . . . . .	86
4.4	Exemplos de objetivos de adaptação . . . . .	88
5.1	Algoritmo genético – adaptado de Luke (2013) . . . . .	111
B.1	Definição de fontes de informação . . . . .	150
C.1	Crenças do mapeamento do metamodelo . . . . .	155
C.2	Crenças do mapeamento de uma fonte de informação . . . . .	155
D.1	Código AgentSpeak do Experimento 1 . . . . .	157
D.2	Código AgentSpeak do Experimento 2 . . . . .	159
D.3	Código AgentSpeak do Experimento 3 . . . . .	160
D.4	Código AgentSpeak do Experimento 4 . . . . .	162
E.1	Análise estatística do Experimento 1 (Agente 4) . . . . .	165
E.2	Análise estatística do Experimento 2 (Agente 4) . . . . .	166
E.3	Análise estatística do Experimento 3 (Agente 1) . . . . .	166
E.4	Análise estatística do Experimento 4 . . . . .	167
F.1	Análise estatística dos resultados dos AGs . . . . .	170



# LISTA DE ABREVIATURAS

API *Application Program Interface.*

BDI *Belief-Desire-Intention.*

C&R *Confiança e Reputação.*

DHT *Distributed Hash Table.*

IA *Inteligência Artificial.*

P2P *Peer-to-Peer.*

PRS *Practical Reasoning System.*

SMA *Sistema Multiagente.*

XML *eXtensible Markup Language.*



# LISTA DE SÍMBOLOS

$C_{com}$	Custos de comunicação.
$C_{inf}$	Custo da informação.
$C_{op}$	Custo operacional.
$D_{fi}$	Disponibilidade das fontes de informação.
$D_{pc}$	Disponibilidade dos parceiros confiáveis.
$Env$	Metamodelo do ambiente.
$Env' \subseteq Env$	Subconjunto de características de $Env$ .
$F$	Frequência das transações.
$G_A$	Objetivos de adaptação.
$G_M$	Objetivos de monitoramento.
$P$	Biblioteca de planos de adaptação.
$U_{obt}$	Utilidade obtida.
$U_{total}$	Utilidade total ofertada.
$evt$	Evento de adaptação.
$m_{conf} \in m_{meta}$	Submodelo de confiança.
$m_{expl} \in m_{meta}$	Submodelo de exploração.
$m_{meta}$	Metamodelo de confiança e reputação.
$m_{rep} \in m_{meta}$	Submodelo de reputação.



# Capítulo 1

## Introdução

*Este capítulo apresenta a contextualização, a justificativa, os principais objetivos, a contribuição e a metodologia utilizada no desenvolvimento deste trabalho. Descreve, ainda, a organização e conteúdo dos demais capítulos.*

### 1.1 Contextualização

Confiança e Reputação (C&R) são dois conceitos que permeiam as interações cotidianas da sociedade humana. Pessoas depositam sua confiança, ou mesmo desconfiança, em diversas entidades do mundo que as cerca. Ao fazer uma compra, por exemplo, o comprador deposita sua confiança no vendedor, que deverá entregar o produto em perfeito estado e dentro do prazo estabelecido. O vendedor por sua vez, confia no meio de pagamento utilizado pelo comprador para garantir sua remuneração. Antes mesmo da realização da transação, tanto o vendedor quanto o comprador depositaram sua confiança no produto, e no seu fabricante, ao colocá-lo à venda e ao escolhê-lo para compra. Essa confiança pode ser fruto de experiências positivas no passado ou da boa reputação do fabricante na sociedade.

Situações semelhantes se repetem envolvendo não só pessoas, mas também instituições, recursos ambientais e de infraestrutura e até mesmo simples objetos. Um nível de confiança pode ser estabelecido, por exemplo, para uma ferramenta e sua capacidade de realizar a tarefa desejada. Pode, igualmente, ser estabelecido para serviços, tais como a manutenção da segurança pública, o abastecimento de água e o fornecimento de energia elétrica. Em cada uma dessas situações, a confiança é avaliada de uma forma distinta, dependendo da experiência de cada um dos agentes envolvidos e da reputação propagada entre eles.

Em um Sistema Multiagente (SMA), agentes computacionais autônomos interagem entre si em um ambiente distribuído para a resolução de problemas que estão além da capacidade de um agente individual (Wooldridge, 2009). Portanto, um agente depende da cooperação

de outros para alcançar seus objetivos. No entanto, os demais agentes podem possuir seus próprios, e potencialmente conflitantes, objetivos. Logo, o agente deve avaliar o risco envolvido nessa interação. Para isso, diversos modelos computacionais de C&R foram propostos. Com a escolha prioritária de interações suficientemente confiáveis, o agente pode reduzir os riscos e a probabilidade de falhas (Griffiths, 2005).

## 1.2 Justificativa

Modelos computacionais de Confiança e Reputação (C&R) tornaram-se abordagens comuns no apoio ao gerenciamento das interações em ambientes distribuídos (Keung e Griffiths, 2010). No comércio eletrônico, por exemplo, a reputação é utilizada como um mecanismo para fomentar a confiança e ao mesmo tempo evitar fraudes (Sabater, 2002). Dessa forma, diversos modelos foram propostos ao longo do tempo. No entanto, como demonstrado por levantamentos feitos por Sabater e Sierra (2005), Jøsang et al. (2007), Keung e Griffiths (2010) e Pinyol e Sabater-Mir (2011), a maioria dos modelos tem foco nos aspectos de representação da C&R e menos ênfase em aspectos operacionais, tais como a inicialização e a manutenção do modelo.

Outro aspecto negligenciado pelos modelos, são os custos introduzidos pela sua aplicação. Considere, por exemplo, o custo de obter informações sobre a reputação de um determinado vendedor. Obviamente, a procura por essas informações requer o tempo necessário para consultar uma ou mais fontes de informação – como conversar com conhecidos que já realizaram compras com esse vendedor. Logo, um agente autônomo que utiliza um modelo computacional de C&R deve ser capaz de avaliar se vale a pena buscar tal informação em vista da utilidade marginal que ela trará (Castelfranchi e Falcone, 2001). Fullam e Barber (2007) sugerem que o alto custo da reputação pode tornar seu uso inviável, mesmo quando as informações são bastante precisas e, portanto, mais úteis.

Em um ambiente dinâmico, mudanças nas condições de operação do SMA são constantes e podem afetar diretamente o modelo de C&R. Aspectos ambientais, como a disponibilidade e eficiência de canais de comunicação e de outros recursos, podem mudar ao longo do tempo. No exemplo anterior, suponha que nenhum conhecido esteja disponível para informar a reputação do vendedor (ou que nenhum seja capaz de informá-la). Nesse caso, outra fonte de informação poderia ser consultada (como *sites* na Internet). No entanto, por não considerar os aspectos operacionais (como os custos envolvidos) com mais detalhe, a grande maioria dos modelos computacionais propostos na literatura não possui qualquer capacidade de adaptação, utilizando parâmetros e funções pré-determinados (Sabater e Sierra, 2005; Jøsang et al., 2007; Keung e Griffiths, 2010; Pinyol e Sabater-Mir, 2011). Logo, em um ambiente dinâmico, muitos dos modelos propostos podem, em vez de trazer benefícios,

prejudicar o desempenho do agente, seja pela introdução de custos adicionais excessivos ou pela falta de adaptabilidade.

Esse cenário ilustra a necessidade de oferecer ao agente autônomo a capacidade de raciocinar sobre seu modelo de C&R e realizar dinamicamente os ajustes necessários para se adequar às condições ambientais encontradas. Com isso, o agente será capaz de aumentar o ganho de utilidade promovido pelo modelo de C&R, resultante da redução dos riscos de cooperação, mantendo-o acima dos custos introduzidos pela sua aplicação. Como apontado por Castelfranchi e Falcone (2001), a “noção de confiança é crucial para todos os grandes temas de SMA”. Por isso, dar ao agente essa capacidade de deliberação sobre a adaptação de C&R é essencial para garantir uma operação realmente autônoma em ambientes dinâmicos, sem a necessidade de intervenção humana, o que contribui para a melhoria do projeto de agentes autônomos para SMAs dinâmicos.

### 1.3 Objetivos

Como exposto, os modelos computacionais de C&R propostos na literatura apresentam pouca ou nenhuma capacidade de adaptação, o que impacta negativamente o seu desempenho em ambientes dinâmicos. Embora cada um desses modelos possa ser modificado individualmente para incluir algum nível de adaptabilidade, essa abordagem *ad hoc* não dá ao agente a autonomia necessária para que ele próprio ajuste o modelo de C&R de acordo com suas necessidades e limitações de recursos.

Assim, o objetivo principal deste trabalho é apresentar uma solução que permita a um agente deliberativo, raciocinar sobre o modelo de C&R adotado e sobre os aspectos ambientais que o afetam, permitindo que o agente realize a adaptação do modelo para melhor se adequar às condições do SMA.

Adicionalmente, alguns requisitos desejáveis para essa solução são propostos como objetivos secundários:

- a solução deve ser aplicável em ambientes dinâmicos envolvendo diferentes domínios;
- o raciocínio do agente deve ser realizado de forma independente do modelo específico de C&R em uso;
- os aspectos ambientais que impactam o modelo devem ser aplicáveis independentemente do domínio;
- a solução deve estabelecer um critério de avaliação, que permita ao agente identificar os custos de aplicação de um modelo em uma dada configuração e avaliar as possibilidades de adaptação;

- a solução deve permitir que o agente aprenda novas formas de adaptar o modelo, considerando as condições atuais do ambiente.

Esses requisitos permitem que a solução seja aplicada em diferentes modelos de C&R e domínios, sem prejudicar a capacidade de adaptação do agente.

Considerando o foco na adaptação de C&R, é importante estabelecer algumas limitações no escopo da pesquisa. A quantidade de modelos propostos na literatura introduz uma grande diversidade na representação da C&R, o que, conseqüentemente, introduz várias questões de interoperabilidade entre modelos. Solucionar tais questões não está entre os objetivos desta tese, sendo objeto central de outros trabalhos (Nardin et al., 2008; Şensoy et al., 2009; Koster et al., 2010). Assim, quando relevante, este trabalho assume a existência de um nível mínimo de interoperabilidade que permita que agentes interajam e troquem informações entre si. Também não é objetivo propor mais um modelo, ainda que adaptável, de C&R, mas, sim, oferecer uma solução complementar aos modelos de C&R já propostos e que não têm capacidade adequada de adaptação em ambientes dinâmicos.

## 1.4 Contribuições

Ao alcançar os objetivos propostos, este trabalho avança o estado da arte nos seguintes pontos:

- embora alguns poucos modelos de C&R apresentem alguma capacidade de adaptação, essa capacidade nunca foi incorporada a um agente deliberativo, de forma que o próprio agente pudesse realizar o processo de adaptação, independentemente do modelo usado e do domínio da aplicação;
- nenhum dos modelos de C&R encontrados na literatura considera explicitamente o impacto de aspectos ambientais sobre a operação do modelo e, conseqüentemente, sobre a disposição do agente de confiar;
- propõe um critério de avaliação que vai além da simples avaliação da utilidade obtida com o uso do modelo, mas que considera, também, os custos introduzidos pela aplicação deste;
- propõe um mecanismo de aprendizagem, que pode ser aplicado em qualquer modelo de C&R, para permitir o aprendizado de novas formas de adaptação, considerando os aspectos ambientais mencionados; anteriormente, apenas heurísticas de aprendizagem para características pontuais de modelos específicos haviam sido propostas na literatura.

## 1.5 Metodologia

Inicialmente, foi realizada uma revisão bibliográfica dos modelos computacionais de C&R propostos na literatura, com o intuito de identificar as diferentes abordagens na modelagem desses conceitos em SMAs. A partir dessa revisão, foram identificados:

- elementos comuns aos modelos de C&R, implementados pela maioria dos modelos;
- elementos próprios de alguns modelos que são desejáveis, mas não são implementados pelos demais modelos;
- limitações na adaptabilidade desses elementos em função de mudanças no ambiente ou no desempenho dos demais agentes;
- aspectos ambientais que interferem na operação e configuração desses elementos e, conseqüentemente, têm impacto sobre o desempenho do modelo.

Os elementos identificados a partir da revisão dos modelos foram então generalizados em um metamodelo de C&R. Uma versão preliminar desse metamodelo foi aplicada na formação dinâmica de coalizões em SMAs (Hoelz e Ralha, 2012). Essa aplicação demonstrou a necessidade de expandir o metamodelo de C&R para incluir um componente explícito de exploração, que é encontrado apenas em alguns modelos propostos, mas que se mostrou parte importante do processo de adaptação.

Essa aplicação permitiu, ainda, identificar aspectos ambientais que coincidiam com aqueles identificados a partir da revisão dos modelos de C&R, apesar dos diferentes domínios envolvidos. Dessa forma, optou-se pela generalização desses aspectos em um metamodelo de ambiente livre de domínio.

Após a definição dos componentes do metamodelo, foram estudadas as características de dinamicidade desses componentes e as possibilidades de adaptação. Para permitir que um agente autônomo raciocinasse sobre a adaptação dos componentes do metamodelo de C&R, foi proposto um modelo de adaptação baseado no modelo *Belief-Desire-Intention* (BDI). Com isso, os componentes do metamodelo também precisaram ser adequados a essa abordagem.

Para a avaliação experimental do modelo de adaptação, foram avaliadas outras plataformas de teste de modelos de C&R. No entanto, nenhuma das plataformas avaliadas incluía os requisitos de dinamicidade propostos neste trabalho. Logo, uma plataforma de testes baseada em um ambiente dinâmico foi proposta. Também foi necessário estabelecer um critério de avaliação que permitisse comparar os resultados obtidos pelo uso dos modelos de C&R. Para isso, foi utilizada a soma dos custos associados ao uso de cada componente do metamodelo de C&R.

Uma prova de conceito do modelo de adaptação foi implementada e alguns modelos de C&R foram utilizados em experimentos com e sem o uso do modelo de adaptação. Estabeleceu-se a hipótese de que agentes capazes de adaptar seus modelos em um ambiente dinâmico obteriam resultados significativamente melhores. Testes de hipótese foram então utilizados para realizar a avaliação dos resultados.

Foi proposto, ainda, um mecanismo de aprendizagem para permitir ao agente aprender novas formas de adaptação para um modelo específico de C&R e aplicá-las em cenários similares. Uma prova de conceito baseada em algoritmos genéticos foi implementada e avaliada.

Por fim, com base na análise do resultados obtidos, foram estabelecidas as conclusões da pesquisa e perspectivas de trabalhos futuros.

## 1.6 Organização da tese

Os demais capítulos deste documento estão organizados da seguinte forma:

- no Capítulo 2 são apresentados os principais conceitos de SMAs relacionados a este trabalho, incluindo uma apresentação sobre o modelo *Belief-Desire-Intention* (BDI) utilizado no modelo de adaptação proposto;
- no Capítulo 3, são abordados aspectos gerais dos modelos computacionais de C&R, bem como uma revisão dos modelos propostos na literatura e um resumo de suas principais características;
- o metamodelo para adaptação de C&R em SMAs dinâmicos é apresentado em detalhes no Capítulo 4;
- os experimentos realizados, incluindo a metodologia utilizada, e a análise dos resultados obtidos estão presentes no Capítulo 5;
- por fim, as conclusões e possibilidades de trabalhos futuros são apresentadas no Capítulo 6.

# Capítulo 2

## Fundamentação teórica

*Este capítulo apresenta os principais conceitos de sistemas multiagente aplicados neste trabalho, tais como: as classificações de agentes inteligentes, características do ambiente, formas de coordenação da interação e o modelo de raciocínio BDI.*

### 2.1 Agentes inteligentes

Um agente, como definido por Russell e Norvig (2002), é qualquer entidade que possa perceber seu ambiente por meio de sensores e atuar sobre ele por meio de atuadores. Um agente humano, por exemplo, percebe o ambiente utilizando seus sentidos e atua utilizando os membros do seu corpo. Um agente robótico pode utilizar câmeras de vídeo como sensores e um braço robótico como atuador. O mesmo pode ser imaginado para um agente de *software*. A Figura 2.1 ilustra a interação do agente com o ambiente.

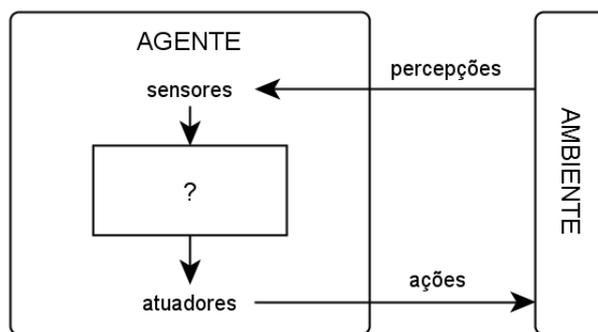


Figura 2.1: Interação do agente com o ambiente, adaptada de Russell e Norvig (2002)

Para Wooldridge (1999), um agente é uma entidade computacional, como um programa de *software* ou um robô, que além de perceber e atuar, o faz de maneira autônoma no sentido de que seu comportamento depende pelo menos parcialmente de sua própria experiência. A

flexibilidade de comportamento e a racionalidade são alcançadas pelo agente por meio de processos como: resolução de problemas, planejamento, tomada de decisões e aprendizagem. Segundo Russell e Norvig (2002), um agente racional é aquele que atua para alcançar o melhor resultado ou, na presença de incertezas, o melhor resultado esperado. Kolp et al. (2006) enfatizam que os agentes inteligentes são, em virtude de suas capacidades intencionais (habilidade de planejar e negociar), muito mais do que meros componentes de *software*.

Wooldridge (2009) afirma que não há definição universalmente aceita para o termo agente, embora haja consenso sobre a necessidade do mesmo ser autônomo. Portanto, ele define um agente como um sistema computacional situado em algum ambiente e que é capaz de ações autônomas sobre esse ambiente para atingir seus objetivos. Jennings (2000) acrescenta que os agentes devem exibir comportamento flexível na resolução de problemas. Eles devem ser capazes de reagir tempestivamente às mudanças que ocorrem no ambiente e de agir em antecipação aos seus objetivos futuros.

A racionalidade do agente, segundo Russell e Norvig (2002), deve levar em consideração o que o agente pode fazer, sua percepção do ambiente (incluindo o que já foi percebido) e a medida de desempenho que avalia o seu sucesso. Portanto, um agente racional deve buscar maximizar seu desempenho com base nas informações da sua percepção e do conhecimento que possui.

O projeto apropriado de um agente depende das suas percepções, ações, objetivos e do ambiente em que se encontra (Wooldridge, 2009). Dependendo de suas características, o ambiente pode exigir mais da racionalidade dos agentes. Para Wooldridge (2009), na maioria dos domínios de complexidade razoável, um agente não terá completo controle sobre o ambiente. Um agente também pode ter suas ações ou seu ambiente afetados por outros agentes com os quais poderá interagir de maneira competitiva ou cooperativa para atingir seus objetivos. Russell e Norvig (2002) apresentam uma classificação para agentes inteligentes em quatro tipos básicos:

1. reativo simples: reage à percepção atual, ignorando percepções anteriores;
2. reativo baseado em modelos: mantém um estado interno com base no seu histórico de percepções e no estado do ambiente, mas ainda age de forma reativa;
3. baseado em objetivos: além das informações de estado, baseia sua decisão atual nos seus objetivos, que descrevem situações que são desejáveis;
4. baseado na utilidade: além de considerar seus objetivos, considera também a utilidade de suas decisões e ações.

A Figura 2.2 apresenta o modelo de agente que mantém informações das suas percepções passadas e as considera na realização da próxima ação. Segundo Sycara (1998), para a maioria dos problemas, arquiteturas híbridas podem ser utilizadas, combinando aspectos

deliberativos e reativos. Em um sistema de múltiplas camadas, por exemplo, as camadas mais próximas dos sensores podem atuar de forma reativa, enquanto camadas superiores, que combinam informações e tomam decisões, podem utilizar uma abordagem deliberativa (descrita com mais detalhe na Seção 2.4).

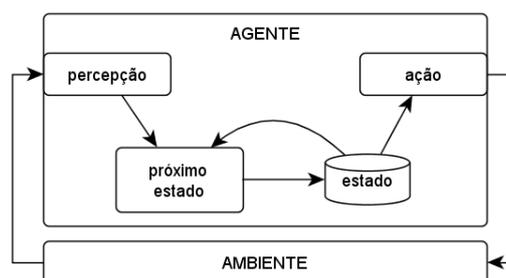


Figura 2.2: Modelo de agente que mantém informações de estado, adaptada de Wooldridge (2009)

A capacidade de um agente inteligente é limitada pelo seu conhecimento, seus recursos computacionais e sua percepção (Sycara, 1998). Logo, problemas complexos de maior escala estão acima das capacidades de um único agente inteligente. Para a resolução desses problemas, devem-se empregar vários agentes que, embora sozinhos não sejam capazes de resolver o problema, podem trabalhar conjuntamente para alcançar a solução.

### 2.1.1 Sistema multiagente

Um Sistema Multiagente (SMA), segundo Wooldridge (2009), é um sistema composto por diversos agentes que interagem, tipicamente pela troca de mensagens utilizando alguma infraestrutura de rede computacional. As principais características dos SMAs, segundo Sycara (1998), são:

- cada agente tem informações limitadas do ambiente ou capacidade insuficiente para solucionar um problema;
- o controle é distribuído, uma vez que os agentes são autônomos e não há um controle global do sistema;
- os dados estão descentralizados, distribuídos no ambiente e entre os agentes;
- a computação ocorre de forma assíncrona.

Viroli et al. (2007) fazem distinção entre duas classes principais de SMA. Uma inclui sistemas de resolução distribuída de problemas em que os agentes são explicitamente projetados para, cooperativamente, atingir um objetivo. A outra inclui sistemas abertos em que agentes, não necessariamente projetados para compartilhar objetivos em comum, podem

entrar e sair do sistema dinamicamente. Na primeira classe, todos os agentes são conhecidos *a priori* e são, supostamente, benevolentes. Logo, os agentes podem confiar uns nos outros durante as interações. Na segunda, a chegada dinâmica de agentes desconhecidos precisa ser levada em conta, bem como a possibilidade de comportamento auto-interessado no curso das interações.

Segundo Sycara (1998), problemas reais envolvem sistemas distribuídos e abertos. Para ela, um sistema aberto é aquele no qual a sua própria estrutura pode mudar dinamicamente, uma vez que seus componentes, os agentes, não são conhecidos de antemão e podem mudar com o tempo. Como exemplo, fontes de informação, canais de comunicação e agentes podem aparecer e desaparecer inesperadamente (Sycara, 1998). Logo, um sistema aberto representa um dos ambientes mais complexos para a operação e a interação de agentes inteligentes.

## 2.2 Ambiente

A interação do agente com o ambiente é essencial para o seu funcionamento. Logo, as características do ambiente têm grande impacto sobre o projeto e operação de um SMA. Segundo Russell e Norvig (2002), o ambiente pode ser classificado de acordo com as características a seguir.

- Completamente ou parcialmente observável: se os sensores do agente forem capazes de obter informações completas sobre o estado do ambiente, então ele é completamente observável. Caso haja ruído ou imprecisão na percepção do agente, o ambiente é parcialmente observável.
- Determinístico ou estocástico: em um ambiente determinístico, o próximo estado do ambiente é determinado completamente pelo estado atual e pela ação tomada. No ambiente estocástico, uma mesma ação pode levar a estados diferentes devido a variações no ambiente.
- Episódico ou sequencial: no ambiente episódico, a interação do agente com o ambiente é dividida em episódios bem definidos, independentes dos anteriores. Nesse tipo de ambiente, a ação é escolhida baseada apenas no episódio atual. No ambiente sequencial, a decisão atual afeta todas as decisões posteriores.
- Estático ou dinâmico: em um ambiente dinâmico, o próprio ambiente pode mudar enquanto o agente delibera sobre sua próxima ação. Assim, enquanto o agente não toma sua decisão, a passagem do tempo faz com que o ambiente se altere. Um ambiente estático permanece igual até que uma ação seja realizada sobre ele, não sofrendo, portanto, mudanças com a passagem do tempo.

- Discreto ou contínuo: a distinção entre ambiente discreto e contínuo pode dizer respeito aos estados do ambiente, às ações e percepções do agente e ao tempo. Por exemplo, um ambiente de estados discretos possui um número finito de estados distintos. Ele pode, no entanto, ter um tempo contínuo.
- Agente único ou multiagente: em um ambiente de agente único, o agente não precisa se preocupar com o impacto de suas ações sobre outros agentes, nem da ação de outros agentes sobre ele. No caso de um ambiente multiagente, a interação entre agentes faz com que o ambiente possa ser competitivo.

Russell e Norvig (2002) notam que os ambientes mais complexos de serem tratados são os parcialmente observáveis, estocásticos, sequenciais, dinâmicos, contínuos e multiagente. Para Viroli et al. (2007), o ambiente é uma das dimensões do projeto de aplicações multiagente que engloba porção significativa da complexidade do sistema.

Weyns et al. (2007) propõem dois papéis principais para o ambiente enquanto parte essencial de um SMA: fornecer as condições para os agentes existirem e prover uma abstração de projeto explorável na construção de aplicações multiagente. Além disso, o modelo do ambiente representa aspectos da dinamicidade do ambiente e de restrições impostas às percepções, interações e comunicação.

## 2.3 Coordenação

Para Jennings (2000), ao se adotar uma visão multiagente do mundo, torna-se evidente a necessidade de envolver múltiplos agentes na resolução de problemas. A Figura 2.3 ilustra a visão de um SMA. Nela, podem-se observar as interações provenientes da estrutura organizacional dos agentes, bem como a sobreposição das esferas de visibilidade e influência dos agentes. Logo, os agentes deverão interagir tanto para alcançar seus objetivos individuais quanto para lidar com as dependências de estarem em um ambiente comum. Jennings (1993) lembra que mesmo quando indivíduos atuam sozinhos e, portanto, sem a necessidade de coordenação, a informação descoberta por um agente pode ser de utilidade para outro, de forma que ambos os agentes possam se beneficiar.

Segundo Wooldridge (2009), há duas distinções principais entre SMAs e sistemas distribuídos tradicionais. Em um SMA, cada agente pode ter sido projetado e implementado por diferentes pessoas, com objetivos distintos. Portanto, eles podem não compartilhar os mesmos objetivos. Assim, ao interagir, os agentes devem atuar de maneira estratégica para obter o resultado desejado. Além disso, uma vez que os agentes são autônomos e tomam suas próprias decisões em tempo de execução, eles devem ser capazes de coordenar suas atividades e de cooperar dinamicamente com os outros. Em sistemas distribuídos tradicionais, a coordenação e a cooperação são estabelecidas durante o projeto do sistema.

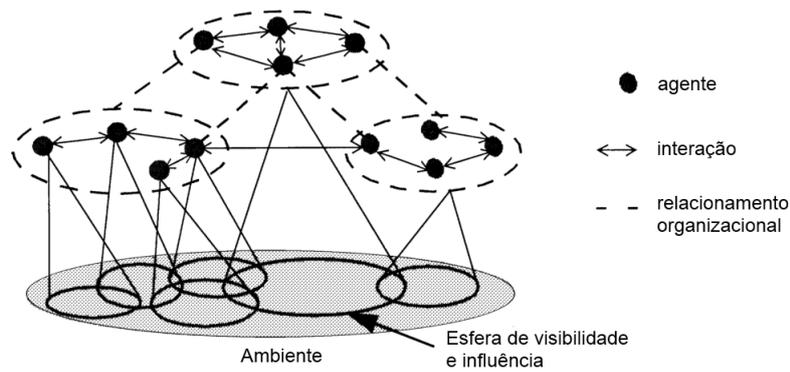


Figura 2.3: Visão de um SMA, adaptada de Jennings (2000)

A Figura 2.4 apresenta uma taxonomia parcial de formas de coordenação em SMAs. Cooperação, segundo Huhns e Stephens (1999), é a coordenação entre agentes não antagônicos, que exige o planejamento das ações conjuntas, enquanto negociação é a coordenação entre agentes competitivos ou auto-interessados.

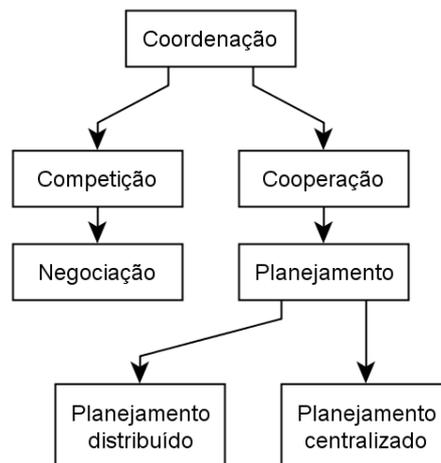


Figura 2.4: Taxonomia parcial de formas de coordenação em SMAs, adaptada de Weiss (1999)

Por causa da natureza descentralizada, um SMA não possui um controle global explícito das interações. Portanto, os próprios agentes devem (i) determinar que objetivos e tarefas compartilham com outros agentes, (ii) evitar conflitos e (iii) compartilhar informações (Huhns e Stephens, 1999). Para tanto, mecanismos distintos de coordenação foram propostos na literatura.

Estruturas organizacionais são um mecanismo de coordenação amplamente utilizado. De acordo com Jennings (1993), essas estruturas podem ser vistas como um padrão de informações e relações de controle entre indivíduos. Horling e Lesser (2005) apresentam um levantamento de paradigmas organizacionais diversos, tais como hierarquias, times,

federações e coalizões. Cada forma de organização estabelece formas de coordenação e convenções próprias. Em uma hierarquia, por exemplo, o fluxo de controle corre do topo para os níveis inferiores, enquanto o fluxo de resultados corre no sentido inverso (Horling e Lesser, 2005). Em uma federação, agentes se comunicam internamente em sua organização e delegam a comunicação entre organizações para um agente específico. A Figura 2.5 ilustra essa duas formas de organização.

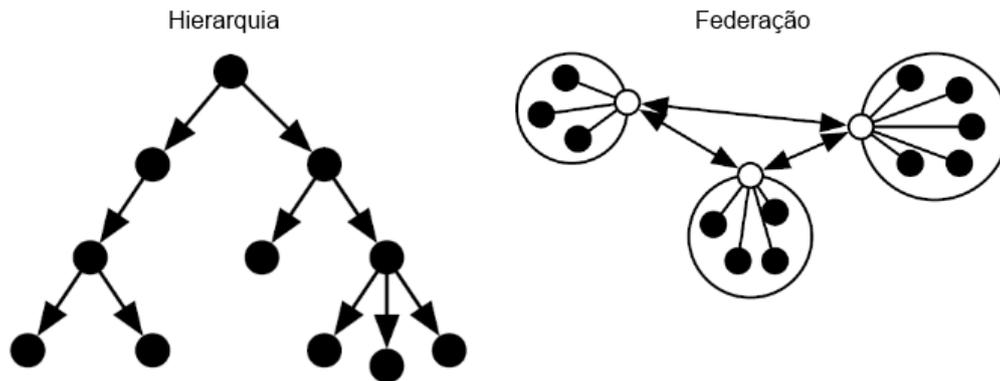


Figura 2.5: Organizações em forma de hierarquia e federação, adaptada de Horling e Lesser (2005)

Outro mecanismo é o planejamento multiagente. Nele, agentes formam um plano que especifica futuras ações e interações para atingir um objetivo comum (Jennings, 1993). Assim, antes da execução do plano, os agentes coordenam qual parte do espaço de busca será explorado por cada um, evitando conflitos e melhorando a utilização de recursos. Como ilustrado na Figura 2.4, o planejamento pode ser centralizado ou distribuído. No planejamento centralizado, um agente mestre distribui os planos a serem executados pelos demais agentes. No distribuído, duas situações são possíveis. Na primeira, um grupo de agentes pode cooperar para formar um plano, que será executado por outros. Na segunda, agentes podem cooperar para formar seus próprios planos individuais e, durante sua execução, dinamicamente coordenar suas atividades e negociar eventuais conflitos.

Normas e leis sociais são mais um exemplo de mecanismo de coordenação. Segundo Wooldridge (2009), uma norma é um padrão estabelecido do comportamento esperado, enquanto as leis sociais são normas associadas a um conceito de autoridade. Divergir da norma não resulta em punição explícita por parte dos agentes (Wooldridge, 2009). As leis sociais, no entanto, restringem as ações permitidas para os agentes com o intuito de regular o comportamento individual dos agentes para o benefício do sistema como um todo (Fitoussi e Tennenholtz, 2000).

## 2.4 Modelo BDI

Após a apresentação das principais características de um agente inteligente, do ambiente em que está inserido e das formas de coordenação das suas interações com os demais agentes, é necessário um modelo que descreva como o agente pode, diante de todos esses elementos, deliberar sobre suas próximas ações. A Figura 2.6, adaptada de Braubach et al. (2008), apresenta levantamento de arquiteturas propostas para agentes inteligentes e SMAs.

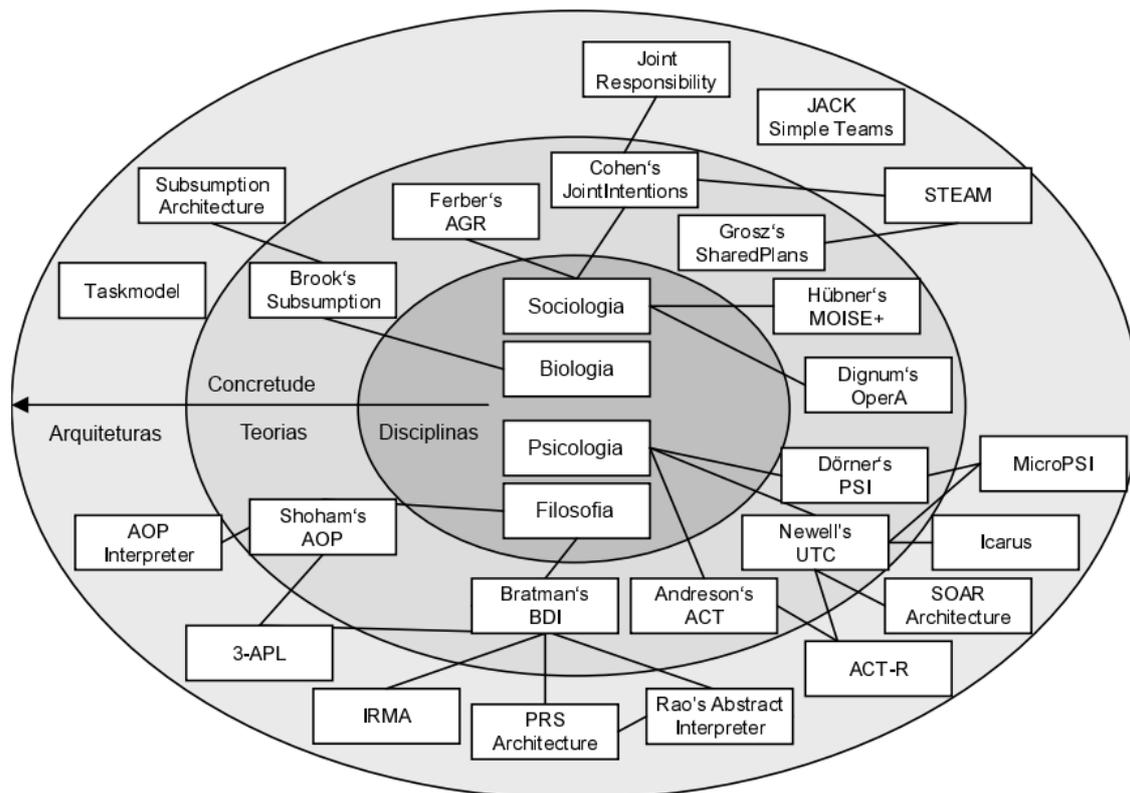


Figura 2.6: Arquiteturas propostas para SMA, adaptada de Braubach et al. (2008)

Nesta seção, serão abordadas propostas baseadas nos ramos que partem da filosofia, em especial do modelo *Belief-Desire-Intention* (BDI), que tornou-se o modelo mais conhecido e estudado de agentes dotados de raciocínio (Georgeff et al., 1999). A origem do modelo está na teoria do raciocínio prático humano desenvolvida por Bratman (1987), cujo foco principal é o papel das intenções no raciocínio. Raciocínio prático, segundo Wooldridge (2009), é o raciocínio direcionado para a ação, para o processo de decidir o que fazer. Para isso, o modelo considera três atitudes mentais: crenças (*beliefs*), desejos (*desires*) e intenções (*intentions*). Elas representam, respectivamente, os componentes informativo, motivacional e deliberativo dos agentes (Rao e Georgeff, 1995).

Crenças são fatos que representam o que o agente acredita sobre o mundo. O agente pode obter suas crenças ao observar o ambiente. Elas também podem ser baseadas em

inferências internas. As crenças de um agente não são necessariamente verdadeiras, uma vez que suas percepções ou inferências podem ser equivocadas ou tornarem-se inválidas pelas próprias alterações do mundo.

Desejos são objetivos ou estados finais desejados. Um agente pode ter desejos conflitantes. Ele pode, por exemplo, desejar estar em dois lugares ao mesmo tempo. Cohen e Levesque (1990) definem dois tipos de objetivos (*goals*): objetivos a alcançar (*achievement goals*) e objetivos a manter (*maintenance goals*). O primeiro tipo inclui objetivos (proposições) que o agente acredita serem falsos e, portanto, devem ser alcançados. O segundo tipo inclui aqueles que acredita serem verdadeiros e, portanto, devem ser mantidos.

Intenções dizem respeito aos compromissos com os objetivos e com os planos selecionados para atingi-los. As intenções devem ser consistentes, não podendo, portanto, ser conflitantes. Assim, apesar de ter múltiplos desejos, um agente terá intenções relacionadas apenas a um subconjunto deles. No exemplo anterior, o agente terá que decidir em qual lugar tem a intenção de estar.

Uma arquitetura conceitual do modelo BDI para Inteligência Artificial (IA) é descrita por Bratman et al. (1988). O modelo BDI tem foco no raciocínio de agentes com recursos limitados. Como os agentes têm memória e processamento limitados, o seu próprio raciocínio consome recursos e demanda tempo. Devido à dinamicidade do ambiente, o agente não pode levar um tempo indefinido para planejar suas ações, caso contrário, o ambiente poderá se alterar a ponto de invalidar a sua intenção (Bratman et al., 1988).

Segundo Rao e Georgeff (1991), sistemas e formalismos que dão importância principal às intenções são consideradas arquiteturas BDI. Cohen e Levesque (1990) formalizam parte dos conceitos propostos na teoria de Bratman (1987). Para Wooldridge (2009), essa formalização é uma das mais conhecidas e sofisticadas demonstrações de como os vários componentes da cognição do agente podem ser combinados para formar uma lógica da racionalidade de agentes. Cohen e Levesque (1990) apresentam uma teoria da intenção, na qual um agente autônomo deve:

- agir conforme suas intenções e não a despeito delas;
- adotar intenções que acredita serem realizáveis e abandonar as que considerar inviáveis;
- se comprometer com suas intenções, mas não para sempre;
- abandonar intenções que acredita terem sido satisfeitas;
- alterar intenções quando crenças relevantes mudarem;
- adotar intenções subsidiárias durante a formação de planos.

Além disso, as intenções de um agente devem satisfazer quatro propriedades (Rao e Georgeff, 1995), segundo as quais o agente:

1. possui a crença de que suas intenções são possíveis (realizáveis segundo as possibilidades do mundo);
2. não possui crença que implique que ele não poderá alcançar suas intenções;
3. possui a crença de que, agindo sob certas condições, poderá alcançar suas intenções;
4. não precisa pretender todos os efeitos esperados de suas intenções (efeitos colaterais são possíveis).

Bratman (1987) afirma que intenções propõem problemas aos agentes, que precisam determinar formas de resolvê-los, e fazem com que os agentes se dediquem à sua realização (e estejam dispostos a tentar novamente se suas tentativas falharem).

Para Cohen e Levesque (1990), intenções são escolhas com compromisso. Jennings (1993) define compromissos como promessas de manter uma determinada intenção, permitindo que um agente possua algum grau de previsibilidade sobre suas próprias ações e as de outros agentes. O nível de compromisso do agente com suas intenções representa o equilíbrio entre a reatividade e o direcionamento a objetivos (Rao e Georgeff, 1995). Em um ambiente em mudança, compromissos dão um senso de estabilidade para o processo de raciocínio do agente, provendo um “filtro de admissibilidade” para a adoção de outras intenções (Bratman, 1987). Com esse filtro, um agente pode rejeitar, sem a necessidade de raciocinar extensamente, oportunidades que entrem em conflito com suas intenções.

Um compromisso é composto de duas condições: uma que o agente se compromete a manter e outra sob a qual o agente termina o compromisso (Cohen e Levesque, 1990). As condições de término têm grande impacto no comportamento dos agentes, definindo, segundo Rao e Georgeff (1995), três tipos de agente:

1. cegamente comprometido: nega qualquer mudança em suas crenças ou desejos que entrem em conflito com seu compromisso;
2. de um só objetivo (*single-minded*): acolhem mudanças nas suas crenças e, consequentemente, mudam seus compromissos;
3. compreensivo: permite mudanças nas suas crenças e desejos que forçarão o abandono dos seus compromissos.

Jennings (1993) sugere que todo mecanismo de coordenação pode, em última instância, ser reduzido a compromissos e convenções estabelecidos entre os agentes. Compromissos compartilhados entre agentes permitem tomar decisões mais adequadas em relação a eventuais interdependências ou conflitos (Huhns e Stephens, 1999). As convenções representam os meios para monitorar e gerenciar os compromissos com a mudança de circunstâncias (Jennings, 1993). Elas estabelecem sob quais condições os compromissos devem ser reavaliados e quais ações tomar em cada situação: mantê-los, retificá-los ou abandoná-los.

Segundo Cohen e Levesque (1990), um agente só pode se comprometer de forma realista se possuir um plano que defina os passos necessários para alcançar o objetivo. Nas arquiteturas que utilizam o modelo BDI, apresentadas na Seção 2.4.1, bibliotecas de planos são utilizadas para fornecer os meios de atingir os fins representados pelas intenções do agente.

### 2.4.1 Arquiteturas

Vários sistemas e arquiteturas utilizando o modelo BDI foram propostos ao longo dos anos (Rao e Georgeff, 1995). Um dos primeiros sistemas a incorporar os conceitos da teoria do raciocínio prático, proposta por Bratman (1987), foi o *Practical Reasoning System* (PRS) (Georgeff e Lansky, 1987). A Figura 2.7 ilustra uma visão simplificada de uma arquitetura BDI, apresentada em D’Inverno et al. (2004), para o PRS. Para D’Inverno et al. (2004), o PRS é a arquitetura BDI mais bem estabelecida, tendo sido implantado em diversas aplicações industriais. A arquitetura ilustra os elementos básicos do modelo BDI e a utilização de um biblioteca de planos para auxiliar a realização das intenções do agente. Agentes que implementam uma arquitetura BDI são chamados agentes deliberativos (Sycara, 1998).

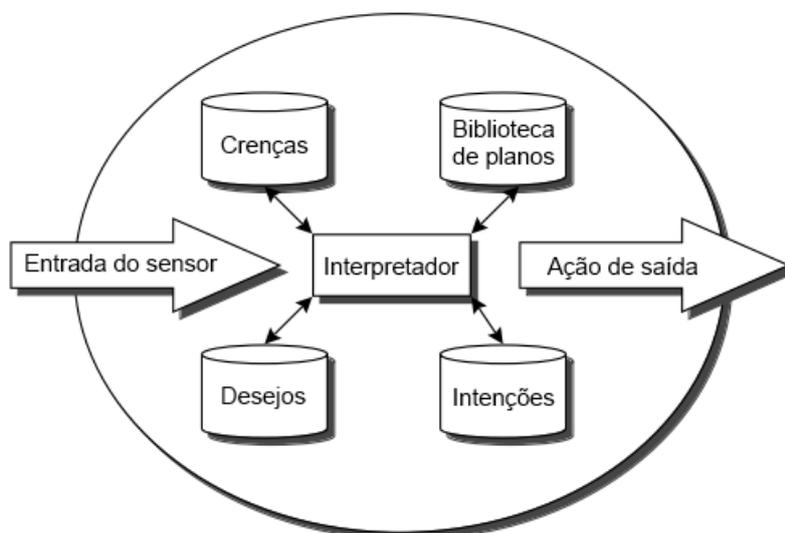


Figura 2.7: A arquitetura BDI do sistema PRS, adaptada de D’Inverno et al. (2004)

De forma semelhante, Bratman et al. (1988) apresentam uma arquitetura para agentes deliberativos que estruturam suas intenções em planos. A arquitetura também define uma biblioteca de planos, definida como um conjunto de crenças sobre as ações que seriam úteis para obter certos resultados sob condições específicas. O termo *plano* é aplicado para indicar os planos efetivamente adotados pelos agentes. A Figura 2.8 apresenta essa arquitetura.

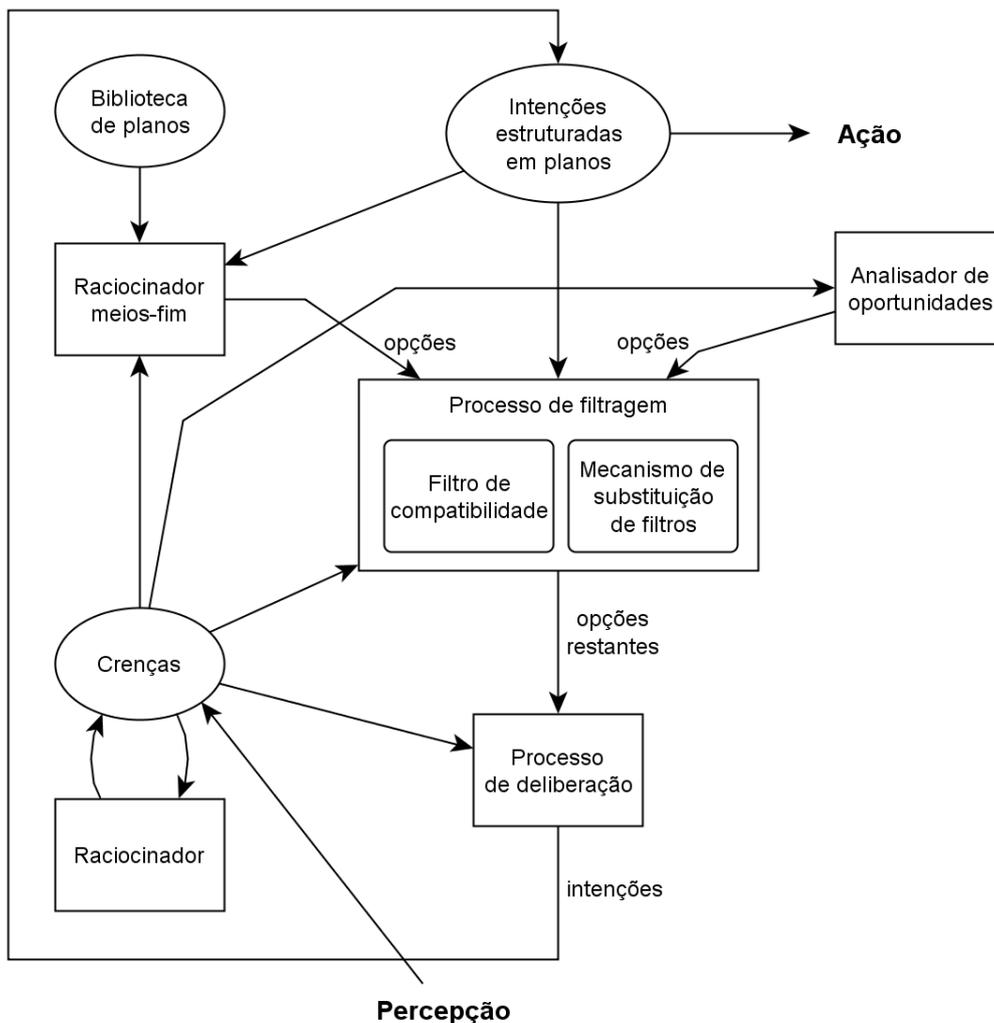


Figura 2.8: A arquitetura BDI proposta por Bratman et al. (1988)

Nesse modelo, o processo de raciocínio é dividido em quatro partes: (i) raciocinador meios-fim, (ii) analisador de oportunidades, (iii) processo de filtragem e (iv) processo de deliberação.

Após o agente definir um plano para o fim desejado (a sua intenção), o agente deve deliberar sobre o que fazer para atingir esse fim, ou seja, definir os meios. Por isso, esse componente é chamado raciocinador meios-fim (*means-end reasoner*). A Figura 2.9 apresenta uma ideia geral do processo de planejamento. Um sistema planejador recebe como entrada: (i) o objetivo, intenção ou tarefa desejados, (ii) o estado atual do ambiente baseado nas crenças do agente e (iii) as ações disponíveis para o agente (Wooldridge, 2009).

O resultado final do raciocinador meios-fim são opções de planos para atingir o fim desejado. Outras opções podem surgir de mudanças no ambiente (e conseqüentemente nas crenças do agente) após passarem pelo analisador de oportunidades. Os planos atuais e as demais opções passam pelo processo de filtragem, que determina a compatibilidade das opções com os planos existentes ou a necessidade de reconsiderar os planos atuais em função

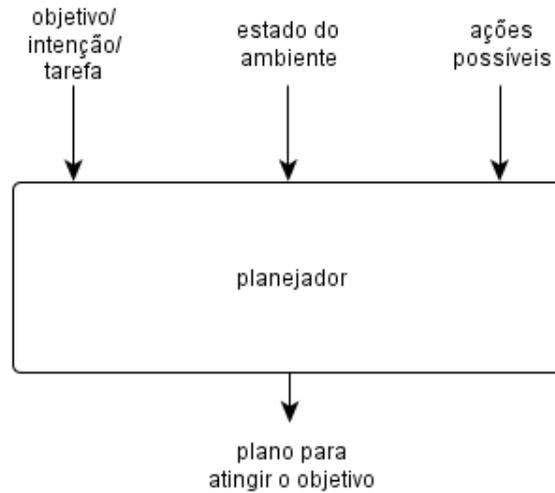


Figura 2.9: Processos de planejamento, adaptada de Wooldridge (2009)

de eventos inesperados. As opções restantes passam pelo processo de deliberação. Esse, por fim, produz intenções que serão incorporadas aos planos do agente.

## 2.4.2 Linguagens de programação

Para permitir a implementação de sistemas utilizando o modelo BDI, várias linguagens foram propostas na literatura. Nesta seção, a linguagem AgentSpeak, proposta por Rao (1996), será utilizada para ilustrar como os conceitos apresentados anteriormente são traduzidos em construções de uma linguagem de programação de agentes. Agent-0 (Shoham, 1993), 3APL (Hindriks et al., 1999) e CANPlan (Sardina e Padgham, 2010) são exemplos de linguagens semelhantes.

Segundo Rao (1996), AgentSpeak pode ser vista como uma linguagem textual simplificada do PRS. Ela é baseada em uma linguagem restrita de primeira ordem com eventos e ações. Logo, as crenças, desejos e intenções fazem parte da definição dos próprios agentes. O estado atual do agente, do ambiente e de outros agentes representam as crenças atuais. Os estados que o agente quer atingir com base em estímulos internos ou externos representam os desejos. Por fim, a adoção de programas para satisfazer esses estímulos pode ser vista como suas intenções. A definição do agente também inclui planos, que permitem a decomposição hierárquica de objetivos, bem como a execução de ações. Os planos dependem do contexto e são ativados por eventos.

As crenças são definidas como predicados de primeira ordem. No exemplo dado por Rao (1996), um robô tem como missão realizar a limpeza de ruas. As crenças do agente representam, por exemplo, sua localização e a localização de carros no seu caminho (Código 2.1). A linguagem distingue dois tipos de objetivos: objetivos a alcançar e objetivos a testar (*test*

### Código 2.1: Exemplos de crenças na linguagem AgentSpeak

```
location(robot, X).  
location(car, X).
```

---

*goals*). Esses objetivos são predicados como as crenças, mas recebem, respectivamente os prefixos “!” e “?”. No exemplo anterior, o robô pode estabelecer dois objetivos, mostrados no Código 2.2. O primeiro indica o desejo de deixar o local *b* limpo, enquanto o segundo verifica se há um carro passando pelo local *b*. Eventos ativadores (*triggering events*) repre-

### Código 2.2: Exemplos de objetivos na linguagem AgentSpeak

```
!cleared(b).  
?location(car, b).
```

---

sentam a adição ou a remoção de crenças e objetivos, e são representados, respectivamente, por um sinal de + ou – antes dos predicados. O evento `+location(waste, X)` indica, no exemplo anterior, que o robô percebeu a presença de lixo em um local *X*. Ações são definidas de forma semelhante às crenças (ex.: `move(robot, X)`)

Planos são divididos em duas partes: cabeça e corpo. A cabeça é composta de um evento ativador e um contexto, separados por “:”. O evento especifica porque o plano foi ativado. O contexto especifica as crenças que devem ser mantidas quando o plano é ativado. O corpo do plano é uma sequência de objetivos e ações, especificados depois do símbolo “<-”. Um exemplo de plano, apresentado por Rao (1996), é mostrado no Código 2.3. O

### Código 2.3: Exemplo de plano na linguagem AgentSpeak

```
+location(waste, X) : location(robot, X) &  
                    location(bin, Y)  
<- pick(waste);  
   !location(robot, Y);  
   drop(waste).
```

---

plano apresentado é ativado após o robô identificar a presença de lixo em um local *X*. Considerando que o robô está em *X* e a lixeira em *Y*, o robô realizará a ação de pegar o lixo (`pick(waste)`), buscará o objetivo de se mover até o local *Y* e, em seguida, realizará a ação de deixar o lixo (`drop(waste)`).

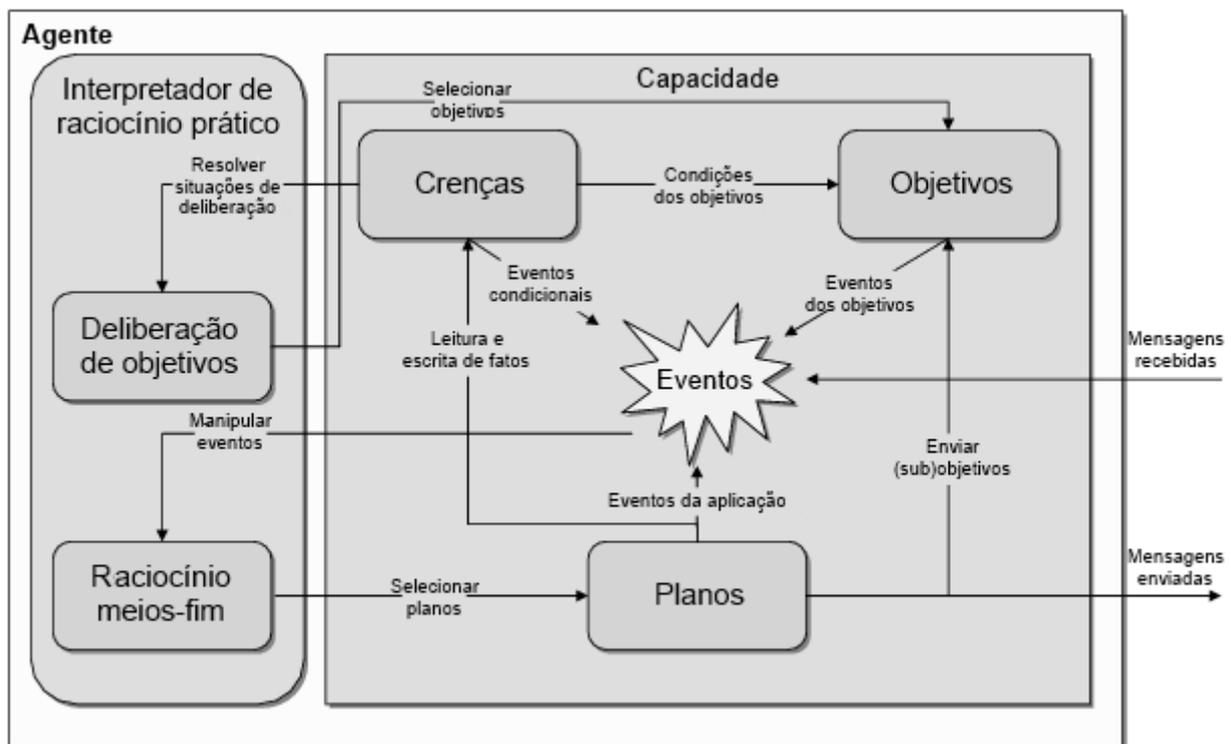


Figura 2.10: Arquitetura abstrata da plataforma Jadex, adaptada de Pokahr et al. (2005)

### 2.4.3 Plataformas

Após a definição de uma linguagem para a programação de agentes deliberativos, é necessário prover um interpretador ou plataforma para a execução da linguagem adotada. Shoham (1993) define um interpretador para a linguagem Agent-0, enquanto Rao (1996) descreve um interpretador abstrato da linguagem AgentSpeak. Jason (Bordini et al., 2007) é uma plataforma de desenvolvimento de SMA baseada em um interpretador para uma versão estendida da linguagem AgentSpeak.

Outras plataformas, no entanto, utilizam linguagens de propósito geral na implementação de uma plataforma de desenvolvimento multiagente. JACK (Howden et al., 2001) é uma plataforma comercial, que utiliza uma abordagem orientada a objetos baseada na linguagem Java. Jadex (Pokahr et al., 2005) é outra plataforma baseada em orientação a objetos que provê um mecanismo de raciocínio BDI. A Figura 2.10, adaptada de (Pokahr et al., 2005), apresenta a sua arquitetura abstrata, que é muito próxima daquela apresentada anteriormente na Figura 2.8.

Jadex não utiliza linguagens específicas para a programação de agentes. Um arquivo de definição de agente, escrito em XML, é utilizado para especificar crenças, objetivos, eventos e a parte declarativa dos planos. O Código 2.4 apresenta um exemplo da definição da cabeça de um plano e do evento que o ativa.

#### Código 2.4: Definição da cabeça de um plano na plataforma Jadex

```
<agent ...> ...
  <plans>
    <plan name="ping">
      <body impl="PingPlan"/>
      <trigger><messageevent ref="query_ping"/></trigger>
    </plan>
  </plans> ...
  <events><messageevent name="query_ping" type="fipa"> ... </
    messageevent></events> ...
</agent>
```

---

O corpo dos planos, que representa a parte procedural, é implementado utilizando a linguagem Java, com acesso aos elementos da arquitetura BDI por meio de uma API. O Código 2.5 apresenta um exemplo da definição do corpo do plano, incluindo código para os casos em que o plano tem sucesso, falha ou é abortado.

#### Código 2.5: Definição do corpo de um plano na plataforma Jadex

```
public class PingPlan extends Plan {
  public void body() {
    // Código principal de execução do plano.
  }
  public void passed() {
    // Código para o caso de sucesso do plano.
  }
  public void failed() {
    // Código para o caso de falha do plano.
  }
  public void aborted() {
    // Código para o caso do plano ser abortado.
  }
}
```

---

Como apresentado neste capítulo, ambientes abertos e dinâmicos representam um fator de grande complexidade em SMA. A interação entre agentes nesses ambientes requer deliberação sobre os riscos envolvidos na cooperação. Como os potenciais parceiros e suas intenções não são conhecidos *a priori*, há uma chance de que possam agir maliciosamente em benefício próprio e em detrimento dos demais agentes envolvidos. O Capítulo 3 mostra como os conceitos de Confiança e Reputação (C&R) são incorporados em modelos computacionais como forma de mensurar esses riscos, permitindo que o agente possa avaliar melhor suas intenções de cooperação.

# Capítulo 3

## Confiança e reputação

*Este capítulo descreve os aspectos gerais dos modelos computacionais de confiança e reputação. É realizada uma revisão dos modelos computacionais propostos na literatura e uma análise de suas características.*

### 3.1 Confiança

Marsh (1994) aponta que o conceito de confiança é estudado, em diferentes níveis de profundidade, por diversas áreas do conhecimento, como sociologia, psicologia, economia, história e filosofia. A definição mais amplamente citada nos trabalhos relacionados a modelos computacionais de C&R é a oferecida por Gambetta (2000):

“confiança (ou, simetricamente, desconfiança) é um nível particular de probabilidade subjetiva com o qual um agente avalia que outro agente ou grupo de agentes irá realizar uma ação em particular, antes que ele possa monitorar tal ação (ou independentemente da sua capacidade de monitorá-la) em um contexto que afeta sua própria ação” (Gambetta, 2000, p.216).

Castelfranchi e Falcone (2001) afirmam que essa definição é “pobre”, por considerar apenas o aspecto da previsibilidade. Para eles, a expressão “probabilidade subjetiva” esconde parâmetros e crenças importantes, pois não explica em que essa avaliação é baseada. Para Jøsang et al. (2007), a noção de confiança envolve mais do que os conceitos de dependência e confiabilidade (*reliability*), expressos na definição de Gambetta (2000), uma vez que ela não considera a influência do risco na disposição de o agente confiar em outros. Seguindo essa ideia, Keung e Griffiths (2010) estendem a definição anterior acrescentando que a confiança é também “um nível mensurável de risco”. Jøsang et al. (2007) oferecem a seguinte definição:

“confiança é a medida em que uma das partes está disposta a depender de algo ou alguém em uma dada situação, com uma sensação de relativa segurança, apesar de consequências negativas serem possíveis” (Jøsang et al., 2007, p.621).

Por serem complementares, ambas as definições são adotadas neste trabalho. Cabe, portanto, destacar algumas propriedades da confiança: uma relação de confiança não é simétrica, nem transitiva (Marsh, 1994). Um agente *a* pode confiar no agente *b*, enquanto o inverso pode não ser verdade. Da mesma forma, se *a* confia em *c* e *b* confia em *a*, então *b* não necessariamente confiará em *c*. Essas propriedades destacam o caráter subjetivo e individual da confiança, em que os agentes mantem sua própria avaliação do risco de confiar em um outro agente. Duas categorias principais de confiança são identificados por Griffiths (2005): confiança com base na experiência própria e confiança baseada em informações compartilhadas. Esse compartilhamento leva ao conceito de reputação.

A utilização dos conceitos de C&R não se restringe apenas a SMAs, sendo utilizada também no contexto de segurança de aplicações e ambientes computacionais em geral (Grandison e Sloman, 2000). Jøsang et al. (2007) fazem uma distinção entre classes de confiança, baseada na proposta de Grandison e Sloman (2000). As cinco classes de confiança propostas são:

1. provisão: descreve a relação de confiança da parte dependente em um provedor de recursos ou serviços (ex.: existência de um acordo de nível de serviço);
2. acesso: descreve a confiança em elementos voltados para acessar recursos de propriedade ou sobre responsabilidade da parte que confia (ex.: controle de acesso a sistemas computacionais);
3. delegação: descreve a confiança no agente delegado, que age e toma decisões em nome do agente que confia – a provisão pode ser considerada um caso especial de delegação;
4. identidade: descreve a crença de que a identidade do agente é autêntica – é discutida principalmente no âmbito da segurança da informação, por meio de esquemas de autenticação como certificados digitais;
5. contexto: descreve a extensão em que a parte confiante acredita que os sistemas e instituições necessárias estão em vigor, garantindo sua segurança no caso de algum evento negativo.

No contexto dos SMAs, Castelfranchi e Falcone (2001) diferenciam quatro tipos de confiança: (i) no ambiente e na infraestrutura, (ii) no próprio agente e nos agentes mediadores, (iii) nos parceiros em potencial e (iv) em fiadores e autoridades (se houver). Em comparação com as classes de Grandison e Sloman (2000), percebe-se que o primeiro e quarto tipos são correspondentes à classe de confiança no contexto. O segundo e terceiro tipos estão

divididos entre as classes de provisão e delegação, embora a confiança no próprio agente não seja considerada na primeira classificação. Por fim, as classes de confiança no acesso e na identidade não têm uma relação direta com os quatro tipos propostos por Castelfranchi e Falcone (2001), sendo discutidos principalmente pela comunidade de segurança da informação (Jøsang et al., 2007).

## 3.2 Reputação

Reputação é definida por Keung e Griffiths (2010) como “a informação recebida de terceiros sobre o comportamento de seus parceiros”. Griffiths (2005) considera que a reputação de um agente inclui recomendações recebidas de outros que interagiram diretamente com ele, ou mesmo indiretamente pela propagação da reputação entre os agentes. Teacy et al. (2006) alertam que “um agente não deve assumir que as opiniões de outros são precisas ou baseadas em experiências reais”. A eficácia de um sistema de reputação é, portanto, baseada na premissa de que a reputação do agente reflete, mesmo que de maneira imprecisa, a qualidade de interações anteriores e pode ser usada como estimativa, mas não garantia, de sua qualidade.

Para Jøsang et al. (2007), a reputação pode ser vista como uma “medida coletiva de confiabilidade baseada nas referências ou avaliações dos membros em uma comunidade”. Conseqüentemente, a credibilidade desses membros afeta a confiabilidade da reputação como fator de decisão da confiança. A teoria cognitiva da reputação (Conte e Paolucci, 2002) divide essa avaliação social em dois conceitos: imagem e reputação. Como definido por Catadau (2011), “imagem é uma crença avaliativa para um contexto específico”, e “reputação é uma crença sobre a existência de uma avaliação comunicada”. Assim, esses conceitos estão relacionados, já que a imagem é a avaliação interna que um indivíduo faz de outro, enquanto a reputação é o compartilhamento dessa imagem na sociedade. Vale destacar que a maioria dos modelos computacionais não faz essa distinção.

A noção de reputação tem grande importância nas relações comerciais e sociais, uma vez que informações sobre a reputação de um terceiro podem ser usadas por um agente para definir suas próprias ações, como contratar ou não serviços deste. A reputação pode ser utilizada como complemento na avaliação da confiança depositada em um agente, na ausência de interações anteriores ou recentes. Caso o agente  $a$  não tenha ainda interagido com o agente  $b$ , não poderá estabelecer um grau de confiança específico para essa relação. Nesse caso, pode utilizar as informações de reputação de  $y$  fornecidas por terceiros. Mesmo no caso em que  $x$  possui experiências anteriores com  $y$ , tais experiências podem ser antigas e não corresponderem ao nível de confiança esperado de  $y$  no presente. Dessa forma, é interessante utilizar informações de reputação para complementar a noção de confiança que o próprio agente mantém (Fullam, 2007).

### 3.3 Modelos computacionais de C&R

Seigneur e Dondio (2011) apresentam uma visão de alto nível de um mecanismo de confiança, como visto na Figura 3.1. Ao receber uma requisição, um módulo de reconhecimento de entidades é utilizado para identificar o requisitante com base em uma das suas identidades virtuais. O processo de tomada de decisão depende do cálculo do valor da confiança – com base nas evidências armazenadas – e da análise do risco. Por fim, a decisão tomada, no que tange à confiabilidade, é comunicada ao requisitante.

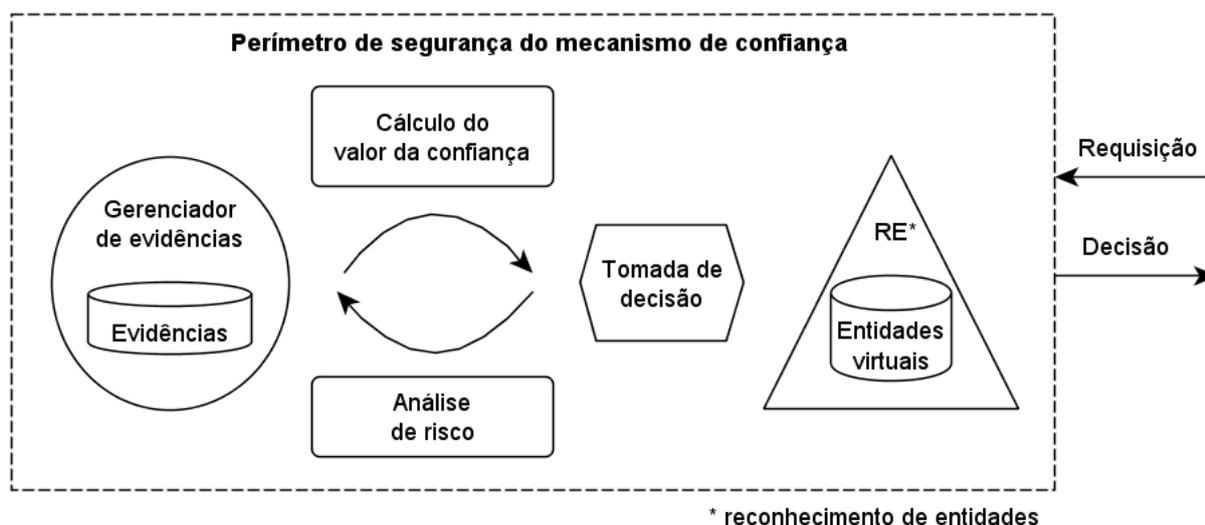


Figura 3.1: Visão de alto nível de um mecanismo de confiança, adaptada de Seigneur e Dondio (2011)

Staab e Muller (2012) apresentam uma outra visão da cadeia de informação da confiança, vista na Figura 3.2, baseada no modelo BDI, descrito na Seção 2.4. Inicialmente, o agente faz suas observações do ambiente, que são avaliadas para gerar crenças associadas à confiança. Essas crenças são utilizadas, então, para constituir as intenções de confiança que, após o processo de tomada de decisão, se concretizarão em atos de confiança ou desconfiança. Esse fluxo do ponto de vista de um agente deliberativo pode ser generalizado para modelos que seguem outras abordagens (Staab e Muller, 2012).

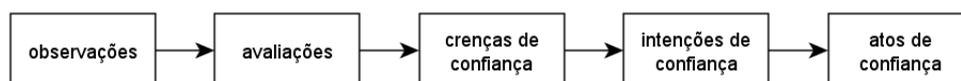


Figura 3.2: Cadeia de informação da confiança, adaptada de Staab e Muller (2012)

Ainda em uma visão cognitiva, Castelfranchi (2008) afirma que a confiança não pode ser limitada à existência de uma avaliação positiva e da disposição de depender das ações

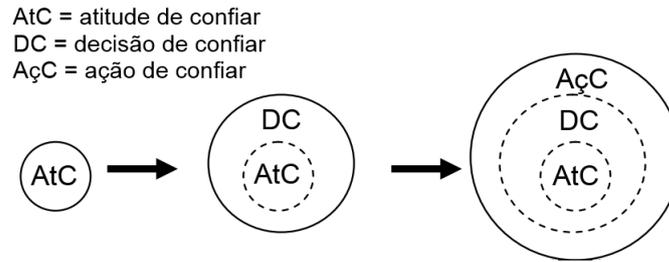


Figura 3.3: Atitude, decisão e ação de confiar, adaptada de Castelfranchi (2008)

de outro agente. Segundo os autores, “confiar também é uma decisão e uma ação”. A Figura 3.3 ilustra essa ideia.

Na execução do fluxo apresentado na Figura 3.2, o modelo computacional de C&R deve definir como realizar suas observações (quais serão suas fontes de informação), como realizar suas avaliações e como raciocinar sobre a decisão de confiar ou não. Segundo Pinyol e Sabater-Mir (2009), um agente pode tomar três tipos de decisões baseado nas avaliações de C&R:

1. decisões epistêmicas, que definem a geração e atualização das avaliações;
2. decisões pragmático-estratégicas, que definem como se comportar com parceiros potenciais usando essas avaliações;
3. decisões meméticas, que definem como e quando propagar essas avaliações.

Com relação às fontes de informação, pode-se fazer uma distinção entre modelos baseados exclusivamente na confiança, ou seja, que consideram apenas a experiência direta e não utilizam informações obtidas de terceiros; modelos baseados apenas em reputação, ou seja, que não mantêm avaliações próprias, utilizando apenas aquelas fornecidas por terceiros; e modelos que fazem uso de ambas as fontes de informação (Sabater e Sierra, 2005). O uso de várias fontes de informação visa a aumentar a confiabilidade da estimativa da confiança, mas também aumenta a complexidade do modelo, exigindo critérios para combinar informações potencialmente imprecisas e até mesmo conflitantes.

Na realização das avaliações e na tomada de decisão, dois tipos de abordagens distintas podem ser identificadas: cognitivas e numéricas (ou matemáticas) (Esfandiari e Chandrasekharan, 2001; Sabater e Sierra, 2005; Pinyol e Sabater-Mir, 2011). Esfandiari e Chandrasekharan (2001) apontam que em modelos cognitivos, a confiança é o resultado de uma função baseada em crenças (como aquelas utilizadas no modelo BDI da Seção 2.4). Nos modelos numéricos, a confiança é resultado da avaliação de funções de utilidade ou de distribuição de probabilidades. O primeiro busca reproduzir o raciocínio humano, de forma que as crenças que resultam na confiança e na reputação são os elementos principais. Enquanto

isso, no segundo caso, as crenças são substituídas por métricas, tais como a utilidade e a importância da situação (Marsh, 1994), que permitam o cálculo de um valor numérico.

Em relação ao armazenamento das informações de reputação, duas abordagens são utilizadas: centralizada e distribuída. A primeira representa uma classe extensa de modelos utilizados no comércio eletrônico, uma vez que, nesse domínio, uma única entidade (como o *site* de uma loja virtual) é responsável por receber as avaliações de diversos clientes para fornecer um valor final de reputação. Jøsang et al. (2007) ilustram as diferenças entre sistemas de reputação centralizados e distribuídos, exibidos, respectivamente, nas Figuras 3.4 e 3.5.

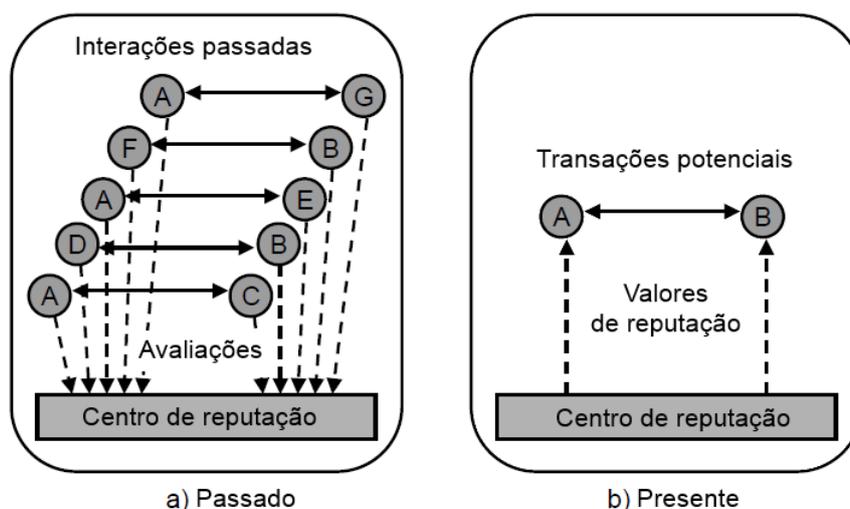


Figura 3.4: Sistema de reputação centralizado, adaptada de Jøsang et al. (2007)

Na abordagem centralizada, as interações dos pares de agentes são enviadas para um centro de reputação, que posteriormente fornece os valores de reputação para as partes envolvidas em potenciais transações. Já na abordagem distribuída, cada agente armazena consigo o resultado das próprias interações. Posteriormente, cada uma das partes interessadas em uma potencial transação consulta suas fontes de informação.

### 3.4 Revisão dos modelos da literatura

Esta seção apresenta a revisão de diversos modelos propostos na literatura, que ilustram a diversidade das abordagens segundo as características descritas na Seção 3.3. Apesar de extensa, a revisão a seguir não aborda a totalidade dos modelos propostos, nem todos os detalhes de cada modelo revisado. A escolha dos modelos foi feita com base no nível de detalhe de sua definição, nas características que os diferenciam dos demais e nas referências

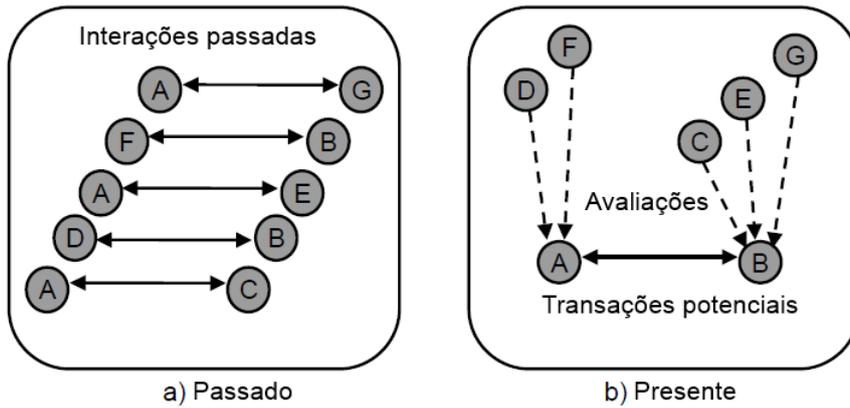


Figura 3.5: Sistema de reputação distribuído, adaptada de Jøsang et al. (2007)

comuns a outras revisões, tais como as realizadas por Sabater e Sierra (2005), Jøsang et al. (2007), Keung e Griffiths (2010) e Pinyol e Sabater-Mir (2011).

Para os fins deste trabalho, a revisão dos modelos propostos tem como objetivo identificar elementos comuns aos modelos, que possam ser generalizados em um metamodelo, que permita ao agente raciocinar sobre o uso da C&R em face da dinamicidade do ambiente. Por isso, a diversidade dos componentes (algoritmos, funções e parâmetros) utilizados nos modelos e sua relação com aspectos do ambiente também são importantes. Com esse conhecimento, o agente pode raciocinar sobre as opções de ajuste ou modificação dos modelos em uso para melhor se ajustarem à situação atual. Um resumo das características dos modelos estudados é apresentado na Seção 3.5.

## Modelo de Marsh

O modelo proposto por Marsh (1994) é um modelo numérico baseado apenas no conceito de confiança. Logo, considera apenas a confiança estabelecida por meio da interação direta com outros agentes. O modelo considera três aspectos de confiança. Em primeiro lugar, a existência de uma disposição básica de confiar em qualquer agente com base em todas as experiências anteriores. Para confiar em um agente específico, há um valor de confiança geral, independente do contexto de interação. Finalmente, há um valor de confiança para uma situação específica, que considera a utilidade e a importância da situação. Os três valores são considerados no intervalo numérico  $[-1, +1]$ .

A confiança situacional é dada pela Expressão 3.1, em que  $U_x(\alpha)^t$  representa a utilidade  $x$  obtida da situação  $\alpha$ ,  $I_x(a)^t$  é a importância da situação  $\alpha$  para o agente  $x$  e  $\widehat{T_x(y)}^t$  é uma estimativa da confiança geral após levar em conta todos os dados relevantes com relação à confiança situacional em interações passadas. Para calcular essa estimativa, o autor sugere o uso de umas das abordagens: otimista, pessimista ou realista. Elas consideram,

respectivamente, o máximo, o mínimo e a média dos valores das interações anteriores. Segundo Griffiths (2005), a principal desvantagem da confiança situacional é a complexidade de identificar e manter valores de confiança para situações similares específicas.

$$T_x(y, \alpha)^t = U_x(\alpha)^t \times I_x(a)^t \times \widehat{T_x(y)}^t \quad (3.1)$$

O tempo também é considerado no modelo, uma vez que a confiança muda com o tempo. Ela muda não só como consequência de novas interações, mas também como reflexo da extensão da memória do agente. Agentes podem escolher considerar apenas uma porção das interações mais recentes nas suas avaliações. Na Expressão 3.1, a confiança é relativa a um tempo específico, indicado por  $t$ .

A disposição dos agentes em confiar, seja de forma pessimista ou otimista, define seu comportamento no sistema. Os agentes otimistas devem ser mais permissivos com relação a falhas, com decréscimos menores na confiança. No caso dos agentes pessimistas, por outro lado, falhas na cooperação podem levar a uma forte redução da confiança. O agente realista estaria entre esses dois extremos.

Após o cálculo da confiança situacional no parceiro, o agente deve decidir se confiará ou não nele. Marsh (1994) define um limiar de cooperação que determina o nível suficiente de confiança para cooperação. Se a confiança estiver acima do limiar, a cooperação ocorre. A Expressão 3.2 mostra o cálculo desse limiar, na qual  $CT_x(y, \alpha)$  é o limiar de cooperação (*Cooperation Threshold*) usado pelo agente  $x$  para confiar em  $y$  na situação  $\alpha$ . Ele depende em como  $x$  percebe o risco e a competência de  $y$  nessa situação.

$$CT_x(y, \alpha) = \frac{Risk_x(\alpha)}{Competence_x(y, \alpha) + \widehat{T_x(y)}} \times I_x(\alpha) \quad (3.2)$$

A definição de um limiar ótimo variará não só devido a predisposições individuais, mas também devido a circunstâncias objetivas, como o custo de confiar equivocadamente (Marsh, 1994). Riscos maiores reduzem a chance de cooperação, mas uma confiança maior a aumenta.

O formalismo apresentado por Marsh (1994) não considera as recomendações de terceiros, o que limita a avaliação da confiabilidade dos agentes na ausência de interações diretas no passado. Nesse caso, a cooperação é baseada apenas na percepção da competência do potencial parceiro, que é obtida considerando a percepção observada no passado em situações similares ou distintas. Se um agente é desconhecido, a disposição básica de confiar e a importância da situação podem ser usadas como estimativa.

O uso de disposições estáticas, proposto no modelo, não é adequado para ambientes dinâmicos. Como exemplo, é fácil observar que um agente permanentemente otimista não é

adequado para um sistema com taxas crescentes de falha. Nesse caso, o agente continuará considerando o valor máximo de interações passadas, mesmo que elas não reflitam o desempenho atual do parceiro. Para evitar perda de utilidade devido a mudanças no ambiente, o agente deve ser capaz de ajustar essa disposição dinamicamente.

## Castelfranchi e Falcone

O modelo proposto por Castelfranchi e Falcone (2001) é um modelo cognitivo, no qual a confiança é justificada por um conjunto de crenças e objetivos. Ela é composta por três elementos: (i) confiança central (*core trust*), que representa a avaliação do agente confiado, (ii) dependência na confiança estabelecida (*reliance*) e (iii) delegação (*delegation*), que é o ato de confiar propriamente dito. Esse modelo é independente de domínio. Para construir a confiança em outro agente, crenças correspondentes a esses três componentes da confiança são necessárias, embora o modelo não especifique como tais crenças são obtidas (Catadau, 2011).

A confiança central depende de duas crenças:

1. competência (habilidade), que é uma avaliação positiva da habilidade do agente confiado em produzir o resultado esperado;
2. disposição, quando acredita-se que o agente confiado realizará a tarefa necessária.

Para que o agente estabeleça a dependência na confiança, ele deve ter uma crença adicional de dependência, na qual ele crê existir a necessidade da ajuda do agente confiado, seja por faltarem alternativas ou por ser a opção mais vantajosa em comparação com a opção de não trabalhar com ele. Com base nas crenças citadas, surge, também, a crença de realização, ou seja, que o agente confiado buscará o objetivo e o alcançará.

O terceiro elemento do modelo, a delegação, é classificada em duas formas: forte e fraca. Na delegação forte, o agente confiado tem ciência de que outro agente confia e depende de suas ações. Na delegação fraca, essa situação não é explícita para o agente confiado. Segundo Castelfranchi e Falcone (2001), isso leva novamente a um conjunto distinto de crenças. No caso da delegação fraca são os seguintes:

1. complacência: modela a mente do confiado na intenção de trabalhar em direção a um certo objetivo;
2. persistência: o agente que confia acredita que o confiado tem uma intenção verdadeira de realizar uma tarefa;
3. auto-confiança: que o confiado tem em si mesmo de que pode realizar a tarefa.

No caso da delegação forte, mais uma crença é necessária: motivação, na qual um agente acredita que o agente confiado tem motivos para ajudá-lo na realização do seu objetivo.

O conceito de confiança recíproca também é proposto pelos autores. Ela é definida como um entendimento mútuo e explícito entre dois agentes que irão se ajudar em pontos diferentes do tempo.

Castelfranchi (2008) diferenciam a atribuição interna e externa de confiança, como formas complementares de confiança. A atribuição interna diz respeito às características de vontade, persistência, engajamento e competência que são avaliadas em relação a um agente. A atribuição externa envolve a confiança nas condições do ambiente, tais como oportunidades, disponibilidade de recursos e possíveis interferências. A avaliação da confiança leva em consideração os dois aspectos. Logo, um agente pode confiar nas características de outro, mas mesmo assim não interagir com ele por não confiar nas condições externas.

Castelfranchi e Falcone (1998) discutem o caso da confiança como uma relação envolvendo uma terceira parte. A Figura 3.6 ilustra essa ideia. Nela, a confiança de  $x$  em  $y$  passa pelo medo que  $y$  tem da autoridade  $A$  e pela confiança de  $x$  em  $A$ . Como exemplo dessa situação, os autores citam os contratos e as promessas com testemunhas. Em ambos os casos, um terceiro elemento é necessário a fim de garantir esse adicional de confiança. No caso dos contratos, a autoridade pode punir  $y$  caso ele não cumpra sua parte. No caso da promessa,  $A$  age como testemunha e no caso de  $y$  não cumpri-la, a reputação de  $y$  ficaria prejudicada pela avaliação de  $A$ .

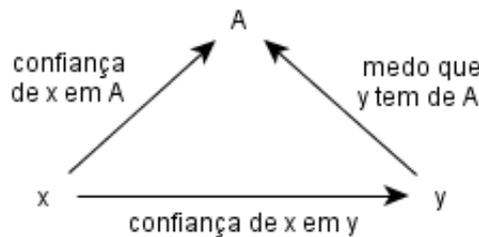


Figura 3.6: Confiança como uma relação de três partes

No processo de tomada de decisão, o modelo avalia os caminhos possíveis do agente, mostrados na Figura 3.7. A utilidade das demais opções é dada pelo conjunto de equações 3.3, adaptadas de Castelfranchi e Falcone (2001), onde  $V(g)$  é o valor obtido por atingir o objetivo  $g$ ,  $C$  é o custo associado com escolha de uma das opções,  $P(X, t)$  indica a realização da tarefa  $t$  diretamente pelo agente  $X$ ,  $D(X, Y, t)$  indica que  $X$  delega a tarefa  $t$  para o agente  $Y$  e  $F(t)$  representa um dano adicional pela falha na execução da tarefa  $t$ . A opção de permanecer ocioso é considerada uma opção sem custo associado, sendo omitida posteriormente do processo de decisão.

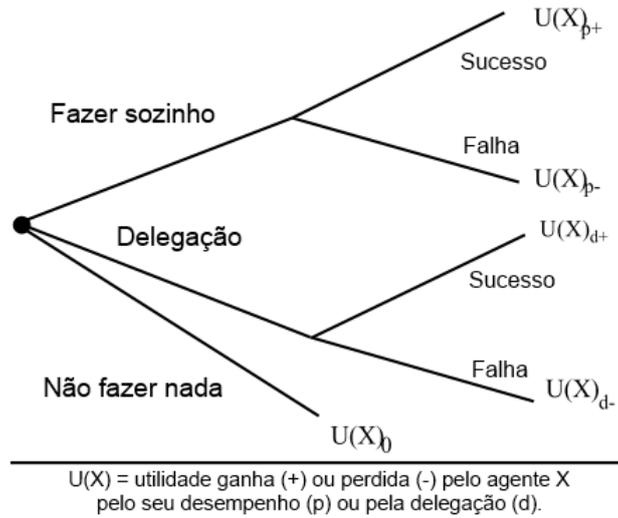


Figura 3.7: Caminhos possíveis para alcançar um objetivo, adaptada de Castelfranchi e Falcone (2001)

$$\begin{aligned}
 U(X)_{p+} &= V(g) + C[P(X, t)] \\
 U(X)_{p-} &= C[P(X, t)] + F(t) \\
 U(X)_{d+} &= V(g) + C[D(X, Y, t)] \\
 U(X)_{d-} &= C[D(X, Y, t)] + F(t)
 \end{aligned} \tag{3.3}$$

Uma condição necessária (mas não suficiente) para a escolha de um dos caminhos é que a utilidade do sucesso da mesma seja maior do que as demais opções. Além disso, é necessário considerar a incerteza e o risco associado a cada escolha. O modelo adota o conceito de limiar de aceitação de risco, semelhante ao definido por Marsh (1994). Portanto, para escolher um caminho, é necessário que o grau de confiança  $T$  seja maior do que o limiar de risco. Os autores notam que é possível que, mesmo com um nível de confiança positivo (baseado nas crenças citadas) e uma utilidade muito grande no caso de sucesso, se o dano no caso de falha for muito alto (mesmo que a probabilidade de falha seja muito baixa), o caminho não será escolhido.

O grau de confiança do agente  $X$  em  $Y$ , apresentado na Expressão 3.4, é definido em função da confiabilidade  $Cr$  das crenças relacionadas, citadas anteriormente: oportunidade ( $Opt$ ), habilidade ( $Hab$ ) e disposição ( $Dsp$ ) de realizar a tarefa  $t$  para atingir o objetivo  $g$ . Assim como Marsh (1994), esse modelo define um limiar de confiança que varia de agente para agente, dependendo não só da personalidade do agente (aversão a risco), como da relação dano/recompensa das situações (Castelfranchi e Falcone, 2001). Se o grau de confiança

for maior que esse limiar, então o agente estabelece sua disposição de confiar.

$$T(X, Y) = Cr_X[Opt_Y(t, g)] \cdot Cr_X[Hab_Y(t)] \cdot Cr_X[Disp_Y(t, g)] \quad (3.4)$$

## SPORAS

SPORAS (Zacharia e Maes, 2000) é um modelo de reputação para comunidades *online* fracamente conectadas. É um modelo numérico que utiliza apenas o conceito de reputação, no qual agentes enviam avaliações sobre os outros para um sistema centralizado. Apenas a avaliação mais recente dada por um agente sobre outro é considerada. Essas avaliações são então combinadas para calcular a reputação. Novos agentes começam com reputação zero (o valor mínimo), de forma que não é vantajoso para um agente abandonar sua identidade com o intuito de melhorar sua reputação. O valor máximo da reputação depende da escala usada pela aplicação.

A reputação de uma agente no tempo  $t = i$  é dada pela Expressão 3.5, na qual  $\theta$  é o número de avaliações consideradas no cálculo,  $\Phi$  é uma função de amortecimento,  $\sigma$  é o fator de aceleração de  $\Phi$ , e  $R_i^{other}$  é a reputação do agente que forneceu a avaliação  $W_i$ . O valor de  $\theta$  pode ser utilizado para ajustar a extensão da memória do agente, considerando apenas uma parte das avaliações mais recentes.

$$R_i = R_{i-1} + \frac{1}{\theta} \cdot \Phi(R_{i-1}) R_i^{other} (W_i - R_{i-1}) \quad (3.5)$$

A função de amortecimento, definida na Expressão 3.6, ajusta como a reputação é atualizada. Agentes com reputação muito alta sofrem menores mudanças na reputação.

$$\Phi(R_{i-1}) = 1 - \frac{1}{1 + e^{\frac{-(R_{i-1}-D)}{\sigma}}} \quad (3.6)$$

SPORAS também calcula o desvio da reputação como uma medida de confiabilidade do valor obtido. O desvio, no tempo  $t = i$ , utiliza um cálculo de mínimos quadrados recursivo, dado pela Expressão 3.7, onde  $\lambda < 1$  é um fator de esquecimento do desvio da reputação  $RD_{i-1}^2$  e  $T_O$  é o número efetivo de observações.

$$RD_i^2 = \lfloor \lambda \cdot RD_{i-1}^2 + (R_i^{other} (W_i - R_{i-1}))^2 \rfloor / T_O \quad (3.7)$$

As consequências de definir parâmetros como  $\sigma$ ,  $\theta$ , e  $\lambda$  para valores maiores ou menores são discutidas pelos autores, mas o modelo não define sob quais circunstâncias esses parâmetros devem ser ajustados e para quais valores.

A abordagem centralizada do SPORAS não é totalmente adequada para SMA abertos. Agentes entrando no ambiente teriam que determinar quão confiáveis são as avaliações do sistema de reputação e se eles estariam dispostos a participar contribuindo com suas próprias avaliações.

## ReGreT

Sabater (2002) apresenta ReGreT, um modelo numérico que também utiliza conhecimento sobre a estrutura social do SMA como uma forma de superar a falta de experiências diretas e avaliar a credibilidade de testemunhas. Com base no grupo ao qual o indivíduo pertence, o modelo propõe uma avaliação da confiabilidade das informações obtidas, considerando que membros do mesmo grupo não manipulam informações. Ele não leva em consideração o cenário em que um agente pertença a mais de um grupo e, por isso, tenha incentivos para manipular a reputação de terceiros.

O modelo foi avaliado em ambientes de comércio eletrônico em que as relações sociais têm um papel importante. Ele provê um grau de confiabilidade (*reliability*) para os valores de confiança, reputação e credibilidade. A reputação é dividida em três dimensões: individual, social e ontológica. As avaliações das interações utilizam o intervalo numérico  $[-1, 1]$ .

A dimensão individual, considerada a dimensão mais confiável da reputação, modela as interações diretas entre dois agentes. A confiança direta é calculada como uma média ponderada dos resultados das interações (chamadas de impressões do resultado) e está sempre associada ao que os autores chamam de aspectos comportamentais ( $\varphi$ ), que especificam o contexto da confiança.

A Expressão 3.8 mostra como calcular a confiança direta ( $DT$ ) do agente  $a$  no agente  $b$ . Visando a uma maior concisão, a notação utilizada originalmente foi simplificada, sem afetar o funcionamento do modelo. O agente  $a$  calcula  $DT$  baseado em todos os resultados anteriores envolvendo  $b$  ( $O^{a,b}$ ), relacionados ao aspecto  $\varphi$ .

$$DT_{a \rightarrow b(\varphi)} = \sum_{o_i \in O_{\varphi}^{a,b}} \rho(t, t_i) \cdot Imp(o_i, \varphi) \quad (3.8)$$

A Expressão 3.8 apresenta a função  $\rho(t, t_i)$ , que é usada para ajustar os resultados como reflexo do tempo. Uma função dependente do tempo  $f(t_i, t)$  é usada para dar maior relevância a resultados recentes. O autor utiliza, como exemplo, a função  $f(t_i, t) = \frac{t_i}{t}$ .

$$\rho(t, t_i) = \frac{f(t_i, t)}{\sum_{o_j \in O_{\varphi}^{a,b}} f(t_j, t)} \quad (3.9)$$

A impressão do resultado  $o$  é calculada usando  $Imp(o, \varphi) = g(v_o)$ , onde a função  $g$  modela a disposição do agente de confiar após a avaliação do resultado  $v_o$ . O autor cita, como exemplo, a função  $g(x) = \sin(\frac{\pi}{2}x)$ . O cálculo de  $v_o$  depende das funções usadas para comparar o resultado esperado e o obtido com relação ao aspecto  $\varphi$ .

A confiabilidade do valor da confiança direta é similar ao utilizado no SPORAS, uma vez que considera o número de resultados usado no cálculo do valor da confiança e sua variabilidade. Para simplificar as equações a seguir, considere  $O_\varphi^{a,b} = \alpha$  e  $|\alpha|$  o número de resultados envolvendo  $a$  e  $b$  com relação ao aspecto  $\varphi$ .

O fator do número de resultados  $No$  é calculado pela Expressão 3.10. O valor  $itm$  define um nível de intimidade de interações. Após esse nível ser atingido, o fator  $No$  é sempre igual a um. A ideia é que interações iniciais não são suficientes para estabelecer medidas confiáveis do valor da confiança. Conforme a *intimidade* aumenta entre os agentes, essa *suspeita* é descartada. A função  $g$  é usada novamente para garantir que  $No(\alpha) = 0$ , se  $|\alpha| = 0$  e  $No(\alpha) = 1$ , quando  $|\alpha| = itm$ . Esse número depende principalmente da frequência de interação entre os agentes.

$$No(\alpha) = \begin{cases} \sin(\frac{g(|\alpha|)}{itm}) & \text{se } \alpha < itm \\ 1 & \text{caso contrário.} \end{cases} \quad (3.10)$$

O desvio dos resultados,  $Dv \in [0, 1]$ , é dado pela Expressão 3.11. Quanto menor for a diferença entre o valor esperado dado por  $DT$  e o valor obtido do resultado dado por  $Imp(o_i, \varphi)$ , maior é a credibilidade do valor da confiança direta.

$$Dv(\alpha) = \sum_{o_i \in \alpha} \rho(t, t_i) \cdot |Imp(o_i, \varphi) - DT_{a \rightarrow b}(\varphi)| \quad (3.11)$$

Por fim, a confiabilidade da relação de confiança direta ( $DTRL$ ) é dada pela Expressão 3.12. Cabe observar que após atingir o nível de intimidade citado anteriormente, o valor de  $DTRL$  dependerá apenas de  $Dv(\alpha)$ .

$$DTRL_{a \rightarrow b}(\varphi) = No(\alpha) \cdot (1 - Dv(\alpha)) \quad (3.12)$$

A dimensão social diz respeito às interações indiretas. Três tipos de reputação social são utilizados com base em:

1. reputação de testemunhas – a partir de agentes que interagiram diretamente com o agente de interesse;
2. reputação da vizinhança – a partir das ligações dos agentes vizinhos ao agente de interesse;

3. reputação do sistema – a partir do conhecimento comum do papel desempenhado pelo agente de interesse.

A reputação por testemunhas é baseada na informação fornecida por terceiros que interagiram diretamente como o agente-alvo. Essa informação está sujeita a vieses, omissões e incorreções. Consequentemente, o cálculo da confiabilidade dessas informações é muito importante. ReGreT assume que uma testemunha  $w$  provê tanto o valor da reputação que tem em um agente  $b$  ( $Trust_{w \rightarrow b}(\varphi)$ ) e o quão confiante está quanto a esse valor ( $TrustRL_{w \rightarrow b}(\varphi)$ ).

Baseado na informação obtida de testemunhas, o agente pode calcular o valor da reputação. Um agente  $a$  calcula a precisão de uma testemunha  $w$  com relação ao agente  $b$ , comparando as informações fornecidas por  $w$  sobre  $b$  e a confiança direta resultante da interação de  $a$  e  $b$ . Como no SPORAS, apenas a informação mais recente de  $w$  sobre  $b$  é armazenada por  $a$ . A Expressão 3.13 é utilizada para obter a credibilidade da testemunha.

Seja  $\beta = \sum_{i \in I_{\rho > 0.5}^{a,w}} \rho_i$ , em que  $I^{a,w}$  é o conjunto de informações de testemunhos fornecidos por  $w$ . Seja  $\rho_i = TrustRL_{w \rightarrow b}(\varphi) \cdot DTRL_{a \rightarrow b}$ , a relevância de uma informação  $i$ . A restrição  $\rho > 0.5$  é usada para eliminar informação de menor qualidade (que nem  $w$ , nem  $a$ , tem muita confiança). Isso é semelhante ao limiar de cooperação, definido por Marsh, porém relacionada à disposição de confiar na informação de uma testemunha.

$$infoCr(a, w) = \frac{\sum_{i \in I_{\rho > 0.5}^{a,w}} \rho_i \cdot Ap_0(Trust_{w \rightarrow b}(\varphi) - DT_{a \rightarrow b}(\varphi))}{\beta} \quad (3.13)$$

A função  $Ap_0 \in [0, 1]$  é usada para avaliar se a experiência da testemunha com  $b$  corresponde a experiência de  $a$ . Quanto menor a diferença, maior o valor de  $Ap_0$ . Se ambos os valores coincidirem,  $Ap_0 = 1$ . A medida de confiança na testemunha ( $infoCr$ ) é dada pela Expressão 3.14, onde  $Ni$  e  $Dv$  são análogos às Equações 3.10 e 3.11.

$$infoCrRL(a, w) = Ni(\beta) \cdot (1 - Dv(\beta)) \quad (3.14)$$

Se  $infoCrRL(a, w) > 0.5$ , a credibilidade da testemunha  $witnessCr(a, w_i, b)$  é igual a  $infoCr(a, w)$ . Caso contrário, ela não é suficiente para fazer uma avaliação apropriada da credibilidade de  $w$ . Nesse caso,  $infoCr$  é definido em 0.5, ou outro valor indicando o quão crédulo o agente é.

Para obter o valor da reputação das testemunhas  $R_{a \rightarrow b}(\varphi)$ , a credibilidade normalizada  $\omega^{w_i b}$  de cada testemunha é utilizada para pesar suas opiniões. O mesmo peso é usado no cálculo de confiabilidade do valor da reputação. Logo, a reputação por testemunhas é obtido

utilizando a Expressão 3.15.

$$R_{a \rightarrow b}^w(\varphi) = \sum_{w_i \in W} \omega^{w_i b} \cdot Trust_{w_i \rightarrow b}(\varphi) \quad (3.15)$$

A confiabilidade do valor da reputação é dado pela Expressão 3.16.

$$RL_{a \rightarrow b}^w(\varphi) = \sum_{w_i \in W} \omega^{w_i b} \cdot \min(witnessCr(a, w_i, b), Trust_{w_i \rightarrow b}(\varphi)) \quad (3.16)$$

Para combinar e associar os valores de C&R relacionados aos vários aspectos comportamentais, o modelo propõe o uso de uma dimensão ontológica. Nessa dimensão, conceitos de uma ontologia são relacionados em uma estrutura de grafo. Nesse grafo, um aspecto mais geral, como *bom vendedor*, pode ser avaliado por meio dos aspectos relacionados, tais como: *entrega rapidamente* e *oferece bons preços*. Eles são combinados calculando a média ponderada dos aspectos utilizando pesos que são especificados nas arestas que os conectam.

## PeerTrust

Xiong e Liu (2004) propõem PeerTrust, um modelo numérico para comunidades *online Peer-to-Peer* (P2P). Ao contrário do SPORAS, esse é um modelo descentralizado. Sua principal preocupação é com agentes que manipulam o mecanismo de reputação para agir de forma maliciosa. Por exemplo, um agente que se comporte bem em interações de menor importância, mas que se aproveite de sua boa reputação para tirar proveito em uma oportunidade maior. O modelo considera fatores já citados como número de transações, credibilidade do *feedback* e contexto das transações. Um fator de contexto comunitário é proposto para recompensar agentes que fornecem *feedback* das interações e para definir *peers* confiáveis (certificados pela comunidade) que estão disponíveis.

Duas abordagens são propostas para o cálculo do valor da confiança: dinâmica e aproximada. A dinâmica utiliza dados recentes, coletados em tempo de execução. A aproximada utiliza um *cache* de memória para acelerar os cálculos. Assim, se o agente já tiver um registro recente da reputação do agente *a* segundo o *peer b*, bem como a credibilidade de *b*, ele não precisará buscar essa informação novamente, reduzindo o custo de aquisição de informação.

O modelo propõe uma janela adaptativa de tempo para impedir que agentes com história longa de boa reputação, explorem essa reputação no presente de forma maliciosa. Quando o desempenho do agente cai abaixo de um determinado limite, a janela de tempo é reduzida. A decisão de confiar é baseada em um limite semelhante ao proposto por Marsh (1994).

Segundo Xiong e Liu (2004), a sobrecarga causada pela avaliação da confiança em tempo de execução é causada principalmente pela busca da informação necessária para a avaliação da reputação. Por se tratar de uma rede P2P, esse custo é composto pelo número de buscas e o custo de cada busca determinado pelo esquema subjacente de tabela distribuída de *hashes* (DHT). No caso da abordagem com *cache*, há ainda um custo inicial de preenchimento desse *cache* para permitir o cálculo da credibilidade.

## FIRE

Huynh et al. (2006) propõem um modelo denominado FIRE, projetado para SMAs abertos. O modelo assume que os agentes são auto-interessados e, por isso, não são completamente confiáveis no compartilhamento de informações de confiança e reputação. FIRE utiliza quatro fontes diferentes de confiança e reputação, baseadas em: interação direta, papel do agente, reputação obtida de testemunhas e reputação certificada.

A confiança baseada na interação direta é aproveitada da dimensão individual proposta pelo modelo ReGreT. A confiança baseada na relação entre os papéis que dois agentes desempenham é definida por regras que determinam o valor desse tipo de confiança.

Para obter informações de reputação de testemunhas, o FIRE utiliza o sistema de referências (*referral system*) proposto por Yu e Singh (2003). Nesse sistema, o agente consulta alguns dos seus agentes conhecidos mais próximos, chamados de *vizinhos*, por informações sobre o agente-alvo. A resposta pode incluir a informação desejada, se o vizinho estiver confiante na sua resposta, ou uma referência para outro agente, se o vizinho que estiver confiante sobre a relevância do agente indicado (Yu e Singh, 2003). Para utilizar o sistema, o agente deve decidir quantos vizinhos deseja consultar (chamado *fator de ramificação*) e o número máximo de referências a seguir (chamado *limiar de comprimento de referência*).

Nesta seção, é dada ênfase ao conceito de reputação certificada (*Certified Reputation* – CR), proposto pelo FIRE, e que difere dos demais modelos. Após cada transação, o agente *a* recebe uma referência certificada pelo agente *b*, com a avaliação de *b* sobre a performance de *a*. Mais tarde, o agente *a* pode apresentar essa e outras referências para um agente *c* como prova do seu desempenho pela ótica dos parceiros anteriores. É importante notar que o agente *a* pode omitir avaliações negativas com o intuito de aumentar sua reputação certificada.

O componente CR é um complemento interessante para as outras fontes de informação, especialmente em situações em que a obtenção de informações de reputação tem alto custo. Sem a necessidade de buscar testemunhas, o processo do CR é mais rápido (Huynh, 2006). A reputação certificada requer que após cada transação, agentes troquem essas referências.

O modelo assume que essas referências não podem ser adulteradas. Um mecanismo de segurança para garantir isso, tal como o uso de assinaturas digitais, adiciona custo à verificação da autenticidade e integridade das referências.

Para obter o valor final da confiança, FIRE considera a média ponderada dos valores dados por cada componente. Os pesos consideram a confiabilidade de cada medida e um coeficiente do componente que é configurado pelo usuário de acordo com a aplicação específica. Esse valor composto da confiança também possui uma medida de confiabilidade, calculada considerando a média ponderada da confiabilidade de cada componente utilizando-se os coeficientes mencionados como pesos.

Na metodologia de avaliação do FIRE, alguns fatores de dinamismo encontrados em SMAs abertos são considerados, tais como mudanças na população (agentes entrando e saindo do sistema), na localização dos agentes (agentes se movimentando em um mundo esférico) e o desempenho dos provedores de serviço. Segundo Wang e Hang (2011), o experimentos realizados por Huynh et al. (2006) consideram apenas modificações menores com chances extremamente pequenas de ocorrência.

Diferentemente do ReGreT, FIRE parametriza explicitamente os elementos do modelo para permitir a configuração para um ambiente específico. Huynh et al. (2006) apresenta algumas heurísticas para a adaptação de alguns desses parâmetros, incluindo o peso de cada componente no cálculo da reputação.

## LIAR

Vercouter e Muller (2010) propõem um modelo denominado LIAR (*Liar Identification for Agent Reputation*), projetado com o intuito de implementar o controle social em SMAs abertos e descentralizados. Segundo os autores, a natureza descentralizada inviabiliza uma visão centralizada global. Portanto, os agentes modelam as normas e políticas sociais que regem suas interações. A Figura 3.8 apresenta os componentes do modelo.

Um agente modela as interações que observa como compromissos sociais. Esses compromissos são comparados com as normas sociais pelo processo de avaliação. As avaliações que resultam desse processo tomam a forma de políticas sociais. As reputações são definidas e atualizadas pelo processo de punição utilizando as políticas sociais. Quando não há informação sobre a reputação, esta é definida pelo processo de inicialização.

A reputação é utilizada pelo processo de raciocínio, em conjunto com alguma representação do contexto atual. Esse processo corrige as intenções de confiança do agente. Com base nessas intenções e no contexto, o processo de decisão atualiza os estados mentais do agente para a construção de intenções sobre as sanções a serem executadas. Vercouter e Muller (2010) citam algumas possibilidades de sanção, tais como: responder negativamente

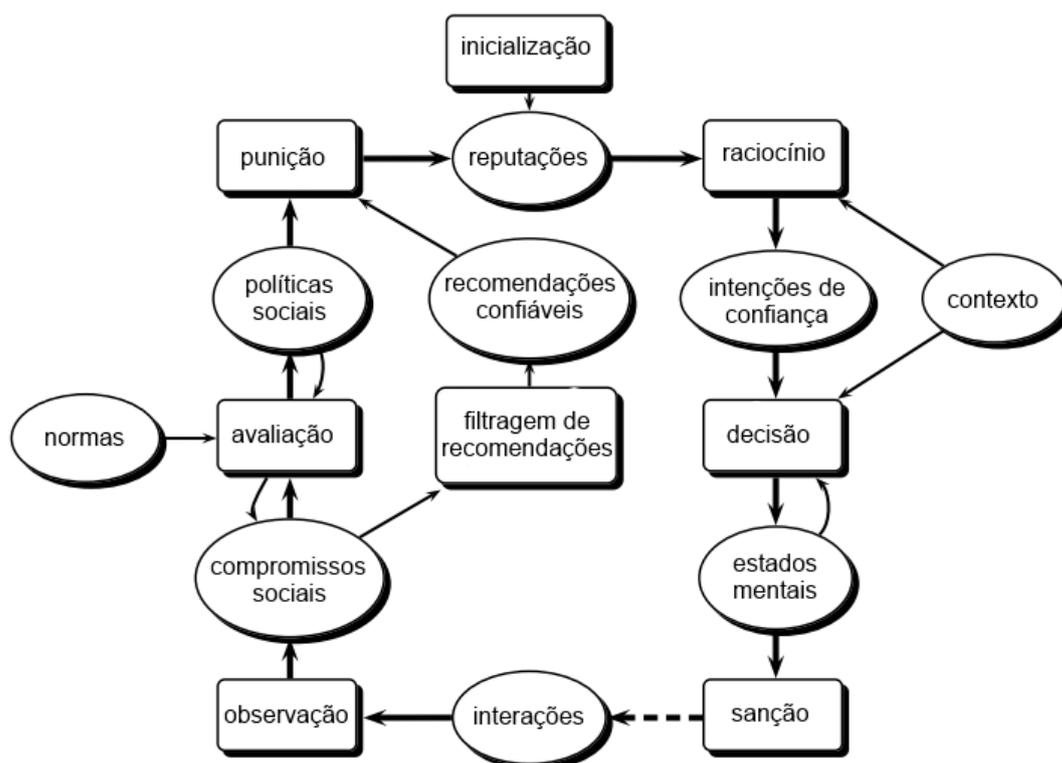


Figura 3.8: O modelo LIAR, adaptada de Vercouter e Muller (2010)

a outro agente (não acreditar no que ele disser ou se recusar a cooperar com ele), ignorar as suas mensagens (não responder) ou propagar informações sobre esse agente para outro, por meio de recomendações. As sanções, portanto, influenciam a maneira como as interações ocorrem. Recomendações recebidas de outros agentes são usadas no processo de punição, após um processo de filtragem que mantém apenas as recomendações confiáveis. Essas recomendações são entradas adicionais do processo de punição para acelerar a aprendizagem da reputação.

Vercouter e Muller (2010) sugerem sete papéis no processo de reputação do modelo:

1. alvo: agente que está sendo avaliado;
2. participante: agente que interage com o alvo;
3. observador: agente que observa uma mensagem e a interpreta como um compromisso social;
4. avaliador: agente que gera políticas sociais a partir de compromissos sociais e normas;
5. penalizador: agente que calcula os níveis de reputação de outros com base nas políticas sociais e possui o poder de penalizar agentes que as infringem;
6. beneficiário: agente que raciocina e decide baseado nos níveis de reputação;

7. propagador: agente que envia recomendações (mensagens sobre as mensagens observadas, políticas sociais ou níveis de reputação).

Com isso, o modelo define cinco tipos de reputação, dependendo de quais agentes desempenham os papéis citados. Esses tipos são:

1. interação direta: o mesmo agente é participante, observador, avaliador, penalizador e beneficiário; não há propagador;
2. interação indireta: o participante é diferente do agente observador, avaliador, penalizador e beneficiário; não há propagador;
3. recomendação por observações: um agente observador e propagador fornece recomendações ao agente beneficiário, penalizador e avaliador; o participante é outro agente que não o beneficiário;
4. recomendação por avaliações: um agente avaliador e propagador informa políticas sociais ao agente beneficiário e penalizador; o participante e o observador podem ser quaisquer agentes;
5. recomendação por reputação: um agente propagador informa níveis de reputação ao agente beneficiário, enquanto outro agente faz os papéis de penalizador e propagador. O avaliador, observador e participante podem ser quaisquer agentes.

O modelo define dois limiares – um de confiança e outro de desconfiança – para cada um dos tipos de reputação citados. No processo de decisão, o valor de cada tipo é avaliado em sequência. Se uma das avaliações estiver abaixo do limiar de desconfiança, o agente não irá confiar no outro. Caso uma delas esteja acima do limiar, o agente irá estabelecer uma intenção de confiar, com uma intensidade baseada nos valores de reputação considerados. Se todos os valores estiverem entre esses limiares, não sendo possível estabelecer uma intenção, uma disposição geral de confiar é usada. Trata-se de um valor booleano que indica a disposição do agente em confiar em agentes que não são claramente confiáveis. Se o valor for verdadeiro, a intenção de confiar é definida. Caso contrário, a intenção será de desconfiar. Segundo os autores, essa disposição seria uma “reputação padrão” (Vercouter e Muller, 2010).

O modelo estabelece duas políticas de compartilhamento de reputação: uma de envio espontâneo de recomendações para alguns dos agentes conhecidos (*push*) e outra de requisição de informações (*pull*). Segundo Vercouter e Muller (2010), o primeiro método pode ser limitado a um conjunto de agentes conhecidos por serem bons recomendadores, para evitar a sobrecarga da rede de comunicação. No segundo caso, há a dificuldade do solicitante encontrar um agente que tenha a informação desejada e que esteja disposto a fornecê-la corretamente.

### Código 3.1: Imagem e reputação no modelo BDI+Repage

```
B(comprar(alice),vendeVinho ^ preço(1000), 1)
B(comprar(charlie),vendeVinho ^ preço(400), 1)
Img(charlie, vendedor(qualidade), [.2, .2, .2, .2, .2])
Img(charlie, vendedor(tempo), [.25, .25, .1, .15, .25])
Rep(charlie, vendedor(qualidade), [.4, .3, .1, .1, .1])
Rep(alice, vendedor(qualidade), [.0, .2, .3, .3, .2])
```

---

## Repage

Repage, proposto por Sabater-Mir et al. (2006), é um modelo que faz distinção entre imagem e reputação. A imagem é definida como uma crença sobre o agente ser bom ou ruim em um certo contexto (ou papel). A reputação, portanto, seria uma “metacrença”, que diz o que outros agentes pensam do agente alvo em um dado contexto. Assim, um agente  $X$  pode ter uma boa imagem de  $Y$  em certo papel, ao mesmo tempo que  $Y$  tem uma reputação ruim naquele mesmo papel.

As avaliações sociais do agente são baseadas em predicados de primeira ordem que contêm a avaliação do agente em um papel específico. Essa avaliação é uma quintupla cuja soma é igual a um. Cada valor está associado a um rótulo de uma escala de valores: muito ruim, ruim, neutro, bom e muito bom. Essa representação permite a modelagem de uma distribuição de probabilidade para cada rótulo.

Predicados associados à imagem são compostos por meio das experiências diretas entre os agentes e do compartilhamento de informações de imagem. No caso da reputação, apenas a troca de informações de reputação tem influência sobre os respectivos predicados. Embora essa distinção entre imagem e reputação seja bem definida, os autores não especificam como essa informação é usada na tomada de decisão pelos agentes.

Uma extensão posterior desse modelo, chamada BDI+Repage (Pinyol e Sabater-Mir, 2009), integra o modelo Repage em uma arquitetura BDI. O modelo é composto de diversos contextos. Cada atitude (crença, desejo, intenção) é separada em um contexto, enquanto o modelo Repage ocupa outro contexto. Dois contextos funcionais, de planejamento e comunicação, completam o sistema. Regras são usadas para interligar os contextos como, por exemplo, transformar as informações de reputação e imagem em crenças.

O Código 3.1 apresenta exemplos da representação de imagem (*Img*) e reputação (*Rep*) no modelo BDI+Repage. As duas primeiras linhas apresentam a definição de duas crenças ( $B$ ), que têm confiabilidade máxima (igual a 1) sobre a ação de comprar com cada um dos vendedores. Os valores nas linhas seguintes são relativos ao percentual de interações avaliadas segundo a escala citada anteriormente. O agente é avaliado em um papel (vendedor), segundo as dimensões especificadas entre parênteses.

## TRAVOS

Teacy et al. (2006) propõem um modelo de confiança e reputação para organizações virtuais chamado TRAVOS (*Trust and Reputation model for Agent-based Virtual OrganizationS*). O modelo utiliza teoria de probabilidades para calcular a confiança com base nas interações passadas entre agentes. Na falta de experiências diretas, o modelo utiliza também reputação obtida de terceiros e lida com o risco de imprecisão dessa informação. Três requisitos são definidos para o modelo:

- a métrica de confiança deve representar o nível de confiança em um agente, tanto na presença quanto na ausência de experiência pessoal, e será usada para avaliar a confiabilidade de diferentes agentes;
- o modelo deve refletir a convicção de um agente no seu nível de confiança em outro agente;
- o modelo deve lidar com informações imprecisas de outros agentes, descontando essas opiniões do cálculo da reputação.

A história de interação de dois agentes é registrada como o número de sucessos e falhas. Com isso, a probabilidade de que o agente confiado realizará suas obrigações pode ser calculada. Um grau de certeza na avaliação do agente confiado também é definido de tal forma que, caso não tenha convicção nessa avaliação, o agente pode buscar opiniões de terceiros. Os resultados experimentais demonstram que a reputação pode melhorar o desempenho, mesmo com os efeitos negativos de opiniões imprecisas.

Os autores definem duas condições para que os valores de reputação sejam tão confiáveis quanto os obtidos diretamente pelo agente. A primeira estabelece que o comportamento do confiado deve ser independente da identidade daquele que confia. A segunda estabelece que o provedor da informação de reputação deve fornecer observações precisas e verdadeiras. No entanto, em um SMA aberto, nem sempre essas condições podem ser garantidas.

Para filtrar informações imprecisas, o modelo considera a precisão de informações passadas. A probabilidade de um agente fornecer informações precisas é calculada, portanto, com base nas opiniões emitidas anteriormente e nas observações subsequentes. Com isso, a influência do provedor de opinião sobre a avaliação do agente que confia é reduzida.

O modelo assume que o comportamento dos agentes permanece o mesmo, o que é uma simplificação que não se aplica a um SMA aberto. O grau de confiança nos valores é calculado como um desvio da distribuição de probabilidade, ou seja, se os valores da confiança estão dentro de uma margem aceitável de erro, embora não seja definida claramente qual margem seria considerada aceitável.

Recomendações de terceiros são obtidas dos agentes que interagiram diretamente com o agente de interesse. O modelo não considera recomendações indiretas. Um exemplo de

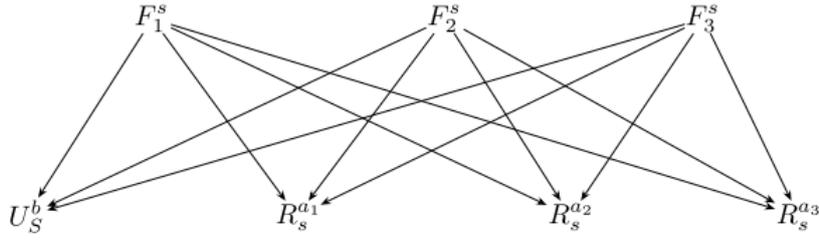


Figura 3.9: Rede bayesiana do modelo Blade (Regan et al., 2006)

recomendação indireta é quando um agente  $b$  recomenda um agente  $c$  ao agente  $a$ , por meio da recomendação recebida de  $d$ , sendo que  $b$  pode não ter interagido diretamente com  $c$  no passado. Esse tipo de recomendação seria útil na ausência de interações diretas.

## BLADE

Regan et al. (2006) apresentam o modelo BLADE (*Bayesian Learning to Adapt to Deception in E-Marketplaces*), para agentes compradores que avaliam vendedores em um mercado eletrônico. O modelo utiliza uma abordagem bayesiana que modela probabilisticamente o comportamento dos vendedores e dos assessores (outros agentes compradores que compartilham suas opiniões). O modelo não define como é realizada a seleção dos assessores, nem dos vendedores.

Os autores criticam as abordagens que descontam ou filtram avaliações não confiáveis (como ReGreT e FIRE), pois, segundo eles, elas “perdem” informações úteis. Os experimentos realizados, no entanto, apenas comparam seu desempenho com o de outros modelos bayesianos (BRS e TRAVOS). Aos contrário desses dois modelos, BLADE não utiliza avaliações binárias (satisfatória ou insatisfatória) para construir uma distribuição beta representando a reputação do vendedor.

O modelo utiliza distribuições multinomiais para modelar um conjunto de características do agente vendedor, como, por exemplo, o tempo de entrega. Assim, cada uma dessas características é modelada como uma variável aleatória. As avaliações dos assessores são modeladas da mesma forma. A Figura 3.9 apresenta as dependências entre as variáveis utilizadas pelo comprador  $b$  no cálculo da utilidade  $U$  do vendedor  $s$ . As características do vendedor são representadas por  $F_1, F_2, F_3$ , enquanto  $R$  são as avaliações dos assessores  $a_1, a_2$  e  $a_3$ .

Após um grande número de interações, o agente obtém um modelo preciso de uma característica do vendedor. No entanto, se essa característica muda, um grande número de novas evidências seria necessário para alterar a distribuição obtida. Para resolver esse problema, o modelo introduz um parâmetro que altera o peso das evidências, baseado na

intuição de que evidências mais recentes são mais representativas que as observadas no passado.

## HABIT

O modelo HABIT (*Hierarchical And Bayesian Inferred Trust*), proposto por Teacy et al. (2012) é outro modelo probabilístico, semelhante ao BLADE. A contribuição principal do modelo é a capacidade de avaliar a reputação de fontes que não compartilham a mesma representação ou o mesmo conjunto de dimensões da avaliação (como parâmetros de qualidade de serviço).

Para os autores, como cada fonte de informação avalia um agente com base em suas próprias preferências e representações, o modelo não deve assumir nenhuma interpretação particular da reputação, mas aprendê-la a partir dos dados. Para sanar o problema da falta de experiência direta, o modelo busca correlações no comportamento de grupos de agentes conhecidos e as utiliza para prever o comportamento de agentes com atributos similares (como papel em uma organização ou serviço oferecido). O modelo também aprende sobre a confiabilidade de agentes desconhecidos que acabaram de entrar no sistema, podendo, portanto, adaptar suas decisões com base no que observou anteriormente, em vez de classificar esse tipo de agente como não confiável.

Para tomar uma decisão, o modelo utiliza uma função de utilidade que quantifica as preferências do agente e depende da distribuição de probabilidade dos possíveis resultados. Esses dois elementos dependem da aplicação. Assim é possível avaliar a utilidade esperada para cada ação. O modelo utiliza três fontes de informação: experiência direta, reputação e observação do comportamento de agentes semelhantes.

A Figura 3.10 apresenta o modelo HABIT visto como uma rede bayesiana, em que o modelo de reputação é composto por diversos submodelos. Os agentes  $tr_1$  e  $tr_2$  mantêm uma distribuição de probabilidade, caracterizada pelos parâmetros  $\theta$ , do comportamento dos agentes  $te_1$  e  $te_2$ , e baseada nas observações  $O$ . Por exemplo, se uma distribuição normal for utilizada para modelar o comportamento de um parceiro,  $\theta$  conterá a média  $\mu$  e a variância  $\sigma^2$ . Os agentes  $tr_1$  e  $tr_2$  podem, inclusive, utilizar modelos diferentes para avaliar um mesmo parceiro.

Os autores lembram que a escolha dos parâmetros  $\theta$  a serem utilizados dependem do quanto as distribuições escolhidas se aproximam das propriedades do domínio, dos recursos computacionais e do tempo disponível para o agente tomar suas decisões.

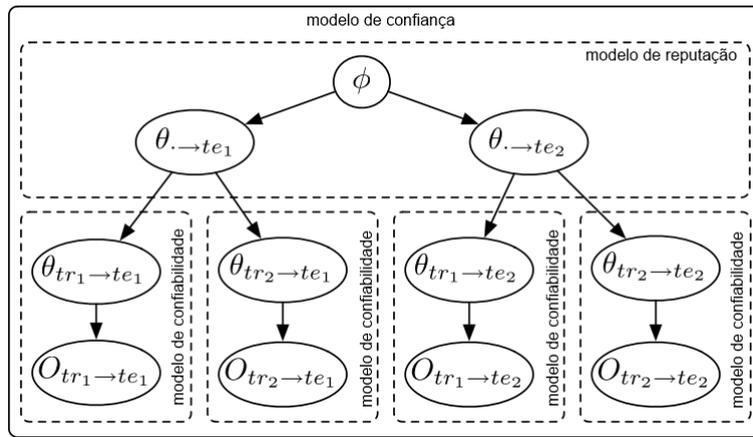


Figura 3.10: Modelo HABIT visto como rede bayesiana, adaptado de Teacy et al. (2012)

## Outros modelos

Esta seção descreve outros modelos que compartilham várias características com os modelos já apresentados. Por isso, são descritas apenas suas principais características e diferenças. Todos os modelos a seguir são numéricos.

O modelo de Schillo et al. (2000) é aplicado a situações em que o resultado da interação entre dois agentes, do ponto de vista da confiança, é binário. Não há graus de satisfação e o resultado pode ser apenas bom ou ruim. O modelo é probabilístico e utiliza uma série de interações baseadas no dilema do prisioneiro. Cada agente recebe o resultado dos jogos envolvendo seus vizinhos. Com isso, o agente pode construir uma impressão da honestidade do parceiro, comparando o que o agente prometeu fazer e o que efetivamente fez. A ideia é que o agente possa calcular a probabilidade de o agente agir honestamente na próxima interação. Cada agente pode ainda entrevistar os outros para obter informações sobre terceiros. Os agentes devem informar o resultado de cada interação e não somente um resumo delas. Eles podem, no entanto, omitir informações. O modelo não especifica como combinar a informação recebida de terceiros com a obtida pela interação direta. O modelo não define contextos ou dimensões para a avaliação da confiança.

Abdul-Rahman e Hailes (2000) propõem um modelo de C&R para comunidades virtuais, que utiliza uma escala de quatro valores: muito confiável, confiável, não confiável (*untrustworthy*) e desonesto. O modelo utiliza a confiança direta e recomendações de terceiros. O resultado das interações também é avaliado em quatro graus: muito bom, bom, ruim e muito ruim. O agente mantém, para cada parceiro, uma contagem do número de interações em cada um desses graus, que é usada para avaliar a confiança final com base na predominância de interações boas ou ruins. Com relação à inicialização, o modelo sugere que os agentes tenham um conjunto de parceiros e de recomendadores confiáveis pré-definidos, que podem ser usados nas interações iniciais.

Esfandiari e Chandrasekharan (2001) propõem um modelo de C&R que utiliza observação e interação direta. No primeiro caso, uma rede bayesiana é montada com base na observação das interações. No segundo caso, dois protocolos são usados: exploratório, em que um agente pergunta a outro sobre coisas conhecidas para avaliar seu grau de confiabilidade, e de consulta, no qual o agente pede recomendações de agentes confiáveis. A informação obtida de testemunhas é representada por um grafo direcionado cujos nós representam agentes e as arestas representam a confiança entre dois deles. Se não houver uma aresta, o valor é desconhecido. O modelo permite separar a confiança em vários contextos, por meio das cores das arestas. Assim, a confiança só é propagada por arestas da mesma cor. Semelhante a reputação do sistema, proposta pelo ReGreT, o modelo propõe o conceito de confiança institucional, que explora a estrutura das instituições no SMA para determinar os valores de confiança. O modelo não especifica como combinar os valores de confiança obtidos dos diferentes mecanismos.

O BRS (*Beta Reputation System*), proposto por Jøsang e Ismail (2002), é um modelo centralizado de confiança, baseado na função de densidade da distribuição beta. Esse tipo de função é usado para representar a distribuição de probabilidade de eventos binários. Logo, as interações entre agentes nesse modelo só podem resultar em dois valores: satisfatório ou insatisfatório. Na avaliação da reputação, o número de avaliações positivas e negativas é utilizado. As opiniões de agentes com melhor reputação têm maior peso. O modelo também define um fator de esquecimento  $\lambda^{n-i}$ , em que  $i$  indica o quão distante a avaliação está do tempo atual  $n$ . Se  $\lambda$  for igual a zero, apenas a última avaliação será usada. Se seu valor for igual a um, então nada é esquecido.

AFRAS (Carbo et al., 2002) apresenta um modelo similar ao SPORAS, mas que utiliza lógica fuzzy na representação da reputação. O modelo utiliza o conceito de recordação (*rememberance*) para definir o peso das interações passadas. Se a reputação passada for igual à atual, o peso das interações passadas aumenta. Se elas forem diferentes, maior peso é dado às interações recentes. O modelo, quando comparado com SPORAS, apresentou uma melhoria significativa nos casos de queda súbita no desempenho dos agentes, já que a função de amortecimento utilizada no SPORAS não permite reduções bruscas em uma reputação bem estabelecida.

O modelo proposto por Sen e Sajja (2002) utiliza aprendizagem por reforço para atualizar o valor da reputação. Duas classes de provedores de serviço existem no ambiente: os de alto e os de baixo desempenho. O objetivo do modelo é testar o quão robusta é a confiança baseada somente na reputação. A interação direta é utilizada apenas para obter a evidência a ser compartilhada com outros agentes. A informação obtida de testemunhas nesse modelo é simplesmente um valor booleano que diz se um parceiro é bom ou não. O modelo assume a existência de agentes que mentem de forma consistente, ou seja, sempre

que questionados sobre um parceiro bom, respondem que ele é ruim, e vice-versa. Além disso, o agente tem conhecimento do percentual de agentes que mentem na população. Com isso, ele pode determinar o número de testemunhas necessário para garantir um certo nível de confiabilidade do valor da reputação.

Yu e Singh (2002) propõem um modelo distribuído de reputação baseado na teoria da evidência de Dempster-Shafer. As avaliações são divididas por parâmetros de qualidade do serviço e o modelo adota conceito de limiar de confiança proposto por Marsh (1994) para a tomada de decisão. Na ausência de interações diretas, os agentes cooperam trocando referências entre si por meio de uma rede de referências. Essa rede é um grafo direcionado ligando o agente solicitante, que pede informação sobre a reputação de outro, aos agentes recomendadores. O pedido de recomendação pode ser propagado para outros agentes até um limite de profundidade no grafo. Para inicializar a rede, um anel com o primeiro nível de vizinhança é definido previamente. Essa rede de referências é aquela utilizada pelo modelo FIRE para obter a reputação de testemunhas.

O modelo apresentado por Reháček et al. (2005) considera apenas a confiança geral definida por Marsh (1994) e utiliza uma representação *fuzzy* para valores de confiança no intervalo  $[0, 1]$ . O modelo é aplicado em um ambiente de coalizão, em que um grupo de agentes colabora. Por isso, ao avaliar o resultado de uma colaboração, o agente também avalia a confiança que tem em si mesmo. Se o agente tiver auto-confiança, ele pode até terminar sua própria operação para não prejudicar os demais agentes. O modelo define apenas dois intervalos *fuzzy*: confiança baixa e alta. Um agente é considerado confiável, se a incidência de interações no intervalo da confiança alta for maior que no da confiança baixa.

No modelo Poyraz, proposto por Şensoy et al. (2009), uma ontologia é usada para descrever as avaliações de reputação em detalhes, tal que um agente que esteja interessado naquelas avaliações possa decidir por si mesmo como avaliar cada transação. Isso porque cada agente realiza sua avaliação baseado em diferentes contextos e critérios de satisfação. Para que o modelo funcione, os agentes avaliadores teriam que detalhar sua experiência ao máximo para tentar reduzir a subjetividade. Nos experimentos realizados pelos autores, o modelo foi comparado com os modelos FIRE, TRAVOS e BRS, obtendo os melhores resultados, uma vez que os outros modelos não consideram avaliações distorcidas pela subjetividade das dimensões avaliadas.

Wang e Hang (2011) propõem um modelo probabilístico semelhante aos demais apresentados anteriormente (BRS, TRAVOS), que utiliza apenas o número de interações satisfatórias ou insatisfatórias. Os autores introduzem o conceito de confiança na história. Para evitar definir heurísticamente um desconto e um peso para as experiências passadas, a confiança na história define uma testemunha “fantasma” que representa essa informação e é considerada juntamente com as outras testemunhas. Assim, a confiança na história é

ajustada dinamicamente, segundo sua precisão. Se o comportamento do parceiro mudar muito, de forma que a sua história não seja uma fonte precisa de informação, seu peso será reduzido.

### 3.5 Resumo dos modelos

A partir dos modelos revisados, é possível observar diferenças e semelhanças entre os diversos modelos. Nesta seção, é apresentado um resumo dos modelos segundo os seguintes aspectos:

- tipo de modelo: confiança, reputação ou ambos;
- paradigma usado: numérico ou cognitivo;
- formas de representação das avaliações de C&R;
- separação (ou não) da C&R segundo o contexto da interação;
- fontes de informação usadas: experiência direta, informação de testemunhas, etc.;
- forma de armazenamento e avaliação: centralizada ou distribuída;
- consideração sobre a existência de agentes maliciosos;
- definição de uma medida de confiabilidade para as avaliações feitas;
- prioridade dada a interações mais recentes;
- especificação dos métodos de aquisição de informação sobre reputação;
- definição explícita dos mecanismos de tomada de decisão sobre a confiança;
- especificação dos procedimentos de atualização e manutenção das informações de C&R;
- processo de inicialização usado por novos agentes.

A Tabela 3.1 apresenta as legendas utilizadas nas tabelas apresentadas nesta seção, relacionadas à análise desses aspectos.

Inicialmente, é possível distinguir os modelos pelo tipo de representação utilizada dos valores de confiança e reputação. Catadau (2011) enumera algumas formas de representação:

- booleana: apenas dois valores (bom/ruim, satisfatório/insatisfatório) são utilizados para avaliar um agente ou o resultado de uma interação;
- intervalo numérico: um intervalo numérico simétrico é utilizado, geralmente entre  $[0..1]$  ou  $[-1..1]$ , onde o meio do intervalo indica uma posição neutra;
- conjuntos discretos: um conjunto ordenado de rótulos é utilizado como, por exemplo,  $\{ruim, neutro, bom\}$  ou  $\{não\ confiável, confiável\}$ .

Tabela 3.1: Legenda das tabelas da Seção 3.5

Tipo de modelo	C – Confiança R – Reputação CR – Confiança e Reputação
Paradigma	Num. – Numérico Cog. – Cognitivo
Contexto	U – Único M – Múltiplo
Fonte de informação	D – Interação direta T – Inf. de testemunhas O – Observação direta + – outras fontes

Como visto nos modelos, sobre essas representações podem ser construídas outras formas, tais como:

- distribuições de probabilidade: associando uma função de distribuição de probabilidade a um conjunto de medidas, por exemplo, à contagem de interações classificadas como boas ou ruins;
- conjuntos *fuzzy*: podem ser aplicados aos conjuntos discretos ou serem sobrepostos a um intervalo numérico.

Kinateder et al. (2005) e Catadau (2011) propõem mecanismos para a adaptação e conversão das representações acima com o intuito de obter um nível mínimo de interoperabilidade das avaliações numéricas.

Sobre essas representações, os modelos cognitivos podem estabelecer suas crenças. No modelo Repage, as crenças tem uma distribuição de probabilidade associada, enquanto no modelo de Castelfranchi e Falcone (2001), um valor numérico no intervalo  $[0, 1]$  define o nível de credibilidade de cada crença.

Alguns modelos utilizam representações distintas para a confiança mantida pelo agente e aquela compartilhada entre agentes. O modelo de Sen e Sajja (2002), por exemplo, utiliza o intervalo numérico  $[0, 1]$  para representar a confiança, enquanto os agentes apenas compartilham avaliações booleanas (*bom/ruim*).

Além da forma de representação, o modelo pode também considerar a separação dos valores de C&R, segundo o contexto da interação. No modelo de Marsh (1994), isso é ilustrado pelo conceito de confiança situacional, ou seja, correspondente a uma situação específica.

A Tabela 3.2 apresenta um resumo das características básicas (tipo, paradigma, representação e contexto) dos modelos revisados na Seção 3.4. Pode-se observar a predominância dos modelos numéricos, o que também é verificado em outras revisões (Sabater e Sierra, 2005; Jøsang et al., 2007; Keung e Griffiths, 2010; Pinyol e Sabater-Mir, 2011).

Tabela 3.2: Características básicas dos modelos revisados

<b>Modelo</b>	<b>Tipo</b>	<b>Paradigma</b>	<b>Representação</b>	<b>Contexto</b>
Marsh	C	Num.	$[-1,1)$	M
Castel. e Falcone	C	Cog.	Crenças	M
SPORAS	R	Num.	$[0,X]$	U
ReGreT	CR	Num.	$[-1,1]$	M
PeerTrust	CR	Num.	$[0,1]$	U
FIRE	CR	Num.	$[-1,1]$	M
LIAR	CR	Num.	$[-1,1]$	U
Repage	R	Cog./Num.	Crenças	U
BDI+Repage	CR	Cog./Num.	Crenças	M
TRAVOS	CR	Num.	Distr. binomial	U
BLADE	CR	Num.	Distr. multinomial	M
HABIT	CR	Num.	Distr. multinomial	M
Schillo	C	Num.	Booleana	U
Rahman	CR	Num.	Conj. discreto (4 valores)	M
Esfandiari	C	Num.	$[0,1]$	U
BRS	R	Num.	Distr. binomial	U
AFRAS	R	Num.	Conj. fuzzy	M
Sen e Sajja	R	Num.	$[0,1]$	M
Yu e Singh	CR	Num.	Conj. discreto (10 valores)	U
Rehak	C	Num.	Conj. fuzzy (2 valores)	M
Poyraz	C	Num.	Distr. binomial	M
Wang e Singh	CR	Num.	Distr. binomial	U

Com relação às fontes de informação usadas, as duas fontes mais comuns são a interação direta e a informação obtida de testemunhas. Alguns modelos também consideram a possibilidade de observar e avaliar interações entre outros agentes. Outros sugerem fontes diferentes como o uso da estrutura social do SMA (ReGreT). O modelo de Castelfranchi e Falcone (2001) não explicita as fontes de informação usadas para formar as crenças do agente. Com relação à distribuição do armazenamento e avaliação dessas informações, apenas o modelo SPORAS é estritamente centralizado.

Nem todos os modelos consideram a possibilidade de agentes maliciosos como fornecedores de informações de reputação. A existência de agentes desse tipo afeta tanto modelos

centralizados quanto distribuídos. Alguns modelos, como TRAVOS, consideram que os agentes mentem de forma consistente (e sem que seu comportamento mude ao longo do tempo). Independentemente de considerar explicitamente ou não essa possibilidade, alguns modelos fornecem uma medida de confiabilidade para suas avaliações de C&R. Como discutido anteriormente, a reputação de um agente não é uma garantia de resultados futuros da interação com ele. Essa incerteza pode ser resultado de mudanças no comportamento do agente ou de conhecimento insuficientes dos agentes recomendadores sobre esse agente (e não necessariamente de uma mentira deliberada). Além disso, alguns modelos dão maior ênfase a interações recentes, que têm maior peso em relação a experiências e informações mais antigas.

A Tabela 3.3 apresenta um resumo dos modelos revisados com relação às fontes de informação usadas, se o modelo considera a existência de agentes maliciosos como provedores de informação (*Ag.Mal.*), se fornece uma medida de confiabilidade das avaliações (*M.Conf.*) e se considera a recência como um fator de diferenciação das informações.

Além das características apresentadas nas Tabelas 3.2 e 3.3, podem ser citadas aquelas relacionadas à operação dos modelos: a forma de aquisição de informações de reputação (*Aq.Info.*), a definição dos mecanismos de tomada de decisão (*Tom.Dec.*) em relação à confiança, os procedimentos realizados sobre os dados (*Proc.*) e o processo de inicialização (*Inic.*). A Tabela 3.4 apresenta essas características para os modelos revisados.

Conforme observado por Catadau (2011), a maioria dos modelos computacionais atuais tem foco apenas nos aspectos epistêmicos, definidos pelos procedimentos realizados sobre os dados (*Proc.*). O processo de aquisição de informação, por exemplo, é considerado em detalhe por poucos modelos, que especificam como os agentes buscam suas fontes de informação para obter dados de reputação. Esse processo não se aplica (*n/a*) aos modelos baseados somente na experiência direta. A maioria dos modelos também não especifica o processo de tomada de decisão em relação à confiança. Logo, não fica claro qual deve ser a decisão do agente após avaliar as informações disponíveis. No caso do modelo de Marsh (1994), por exemplo, um limiar de cooperação claro é definido para testar se a confiança é suficiente para que a cooperação ocorra. Por fim, o processo de inicialização nem sempre é definido pelo modelo. Alguns fornecem definições parciais, como qual valor de reputação considerar para agentes desconhecidos, mas não definem os passos iniciais que um agente recém-chegado deve dar para estabelecer a confiança nos agentes (e fontes de informação) desconhecidos. Outros consideram condições iniciais arbitrárias. O modelo de Yu e Singh (2002), por exemplo, define que um agente, inicialmente, deve ter um círculo de agentes conhecidos para pedir recomendações.

Como visto, os modelos apresentam uma grande variação no nível de detalhamento de sua operação e manutenção. Além disso, é possível observar que os modelos não têm foco

Tabela 3.3: Fontes de informação e aspectos correlatos dos modelos revisados

Modelo	Fontes	Ag.Mal.	M.Conf.	Recência
Marsh	D	-	-	-
Castelfranchi e Falcone	-	-	-	-
SPORAS	T	-	✓	✓
ReGreT	D,T,+	✓	✓	✓
PeerTrust	T	✓	-	✓
FIRE	D,T,+	-	✓	✓
LIAR	D,O	✓	✓	-
Repage	D,T	✓	✓	-
BDI+Repage	D,T	✓	✓	-
TRAVOS	T	✓	✓	-
BLADE	D,T	✓	✓	✓
HABIT	T	✓	✓	-
Schillo	D,T,O	-	-	-
Rahman	DT	-	-	-
Esfandiari	D,T,O,+	-	-	-
BRS	T	✓	✓	✓
AFRAS	D,T	✓	✓	✓
Sen e Sajja	D,T,O	✓	-	-
Yu e Singh	D,T	-	-	-
Rehak	D	-	-	-
Poyraz	T	✓	✓	✓
Wang e Singh	T	✓	✓	✓

nos aspectos ambientais, concentrando-se principalmente no aspecto da confiança na delegação. Com isso, crenças (ou parâmetros) relacionadas ao ambiente não são consideradas explicitamente nos modelos. O modelo de Castelfranchi e Falcone (2001), por exemplo, cita a confiança no ambiente e na infraestrutura, mas não a consideram explicitamente na avaliação da confiança. Os autores exemplificam o impacto do ambiente na confiança, afirmando que se as condições do ambiente forem seguras e confiáveis, a confiança necessária para a delegação (ou uma transação) ocorrer será menor.

Da mesma forma, poucos modelos (Catadau, 2011; Wang e Hang, 2011) consideram aspectos de dinamicidade do ambiente que exijam a adaptação dos modelos. SPORAS e ReGreT, por exemplo, definem parâmetros que dependem da frequência das transações no sistema. No entanto, esse valor é predefinido. Dessa forma, o modelo é adequado apenas para ambientes estáticos, caso contrário, o parâmetro teria de ser ajustado manualmente sempre que essa frequência mudasse. Huynh et al. (2006) observam que o processo de lo-

Tabela 3.4: Características operacionais dos modelos revisados

Modelo	Aq.Info.	Tom.Dec.	Proced.	Inic.
Marsh	n/a	✓	parcial	parcial
Castelfranchi e Falcone	-	✓	-	-
SPORAS	-	-	-	-
ReGreT	✓	-	✓	✓
PeerTrust	✓	✓	✓	-
FIRE	✓	-	✓	✓
LIAR	✓	✓	✓	-
Repage	-	-	✓	-
BDI+Repage	-	✓	✓	-
TRAVOS	-	-	✓	parcial
BLADE	-	-	✓	parcial
HABIT	-	-	✓	parcial
Schillo	✓	-	✓	✓
Rahman	-	-	parcial	-
Esfandiari	✓	-	✓	✓
BRS	-	-	✓	parcial
AFRAS	-	-	✓	-
Sen e Sajja	✓	✓	✓	-
Yu e Singh	✓	✓	✓	✓
Rehak	n/a	✓	-	-
Poyraz	-	-	✓	-
Wang e Singh	-	-	✓	parcial

calizar testemunhas para fornecer informações de reputação está limitado pelos recursos disponíveis para o agente, incluindo o custo de comunicação. Logo, o uso de informações de testemunhas está condicionado, por exemplo, a esse custo que, em um ambiente dinâmico, deve ser flutuante. O modelo FIRE, por exemplo, utiliza parâmetros que podem ser ajustados em resposta a mudanças nesse custo, embora o modelo não discuta como esse ajuste deve ser feito e sob quais circunstâncias.

Neste capítulo foram apresentadas definições dos conceitos de C&R, as características gerais dos modelos computacionais e uma revisão dos modelos propostos na literatura. Pode-se observar que esses modelos compartilham um conjunto de características gerais, apesar das diferentes abordagens e níveis de detalhamento. Também observa-se uma limitação comum no que diz respeito à adaptabilidade dos modelos, uma vez que os mesmos não definem estratégias de adaptação para os algoritmos, funções ou parâmetros estabelecidos. Em geral, os modelos são concebidos para serem utilizados em ambientes estáticos, com

características bem definidas como uma rede de comunicação pré-estabelecida, presença (e percentual) de agentes maliciosos ou disponibilidade de informações *ad hoc* sobre confiança (como o papel do agente na sociedade). Em ambientes dinâmicos, típicos de SMAs abertos, a capacidade de adaptação dos modelos de C&R é essencial para que o mesmo se ajuste às condições ambientais atuais. No Capítulo 4, é apresentada a proposta deste trabalho, que tem como objetivo principal permitir ao agente raciocinar sobre as características dos modelos de C&R, de forma que possa realizar sua adaptação em resposta à dinamicidade do ambiente.

# Capítulo 4

## Metamodelo proposto

*Este capítulo apresenta em detalhes o metamodelo proposto para adaptação de confiança e reputação em sistemas multiagente dinâmicos.*

### 4.1 Visão geral

Os modelos apresentados na Seção 3.4 ilustram a diversidade, mas também as similaridades nas abordagens de C&R propostas na literatura. No intuito de estudar como um agente deliberativo pode adaptar seus modelos para melhor atender suas necessidades, maior atenção é dada aos elementos comuns que podem ser generalizados para a maioria dos modelos, independentemente do domínio envolvido.

Ambos os conceitos de C&R são adaptativos no sentido de que mudanças no comportamento e desempenho dos agentes são refletidos em suas avaliações. Assim, se um agente que era confiável no passado, reduz seu desempenho, essa confiança será afetada. O mesmo acontece a uma testemunha cujas informações tornam-se menos confiáveis com o tempo. No entanto, C&R também são afetadas por aspectos ambientais que têm impacto sobre o funcionamento dos modelos, tais como a escala de tempo e a frequência das transações no sistema. Esses aspectos têm impacto não só sobre o desempenho dos modelos, mas sobre os custos de empregá-los. Raja e Lesser (2007) notam que um agente deliberativo não está se comportando racionalmente se ele falha em considerar todos os custos envolvidos para alcançar o objetivo desejado.

Neste trabalho, é proposto um metamodelo para guiar a adaptação da C&R em SMAs dinâmicos. O objetivo é permitir que um agente raciocine sobre seus modelos e os ajuste em resposta a modificações no seu desempenho e no ambiente.

Metamodelos são mais comumente utilizados na engenharia de software orientada a modelos. Um metamodelo, de acordo com Seidewitz (2003), “faz declarações sobre o que

pode ser expresso nos modelos válidos de uma determinada linguagem de modelagem”. Na engenharia de SMAs, um metamodelo pode ser usado para separar representações abstratas das implementações concretas, como exemplificado por Ferber e Gutknecht (1998). Os autores propõem um metamodelo para análise e projeto de organizações multiagente dividido em dois níveis: abstrato, que define possíveis papéis, interações e organizações; e concreto, que descreve uma organização real.

Para o propósito de adaptação de um modelo de C&R, o metamodelo aqui proposto também é dividido em dois níveis: metanível, que consiste em representações abstratas de elementos comuns utilizados nos modelos de C&R, e nível de implementação, que inclui a realização concreta, específica de um modelo, desses elementos. O metamodelo é apresentado na Figura 4.1, dentro do modelo básico de agente, visto na Figura 2.1. Ele é composto de três componentes principais: metamodelo de C&R, metamodelo do ambiente e modelo de adaptação.

O metamodelo de C&R é dividido em três submodelos que englobam os elementos de confiança, reputação e exploração que podem ser adaptados em resposta a mudanças nas condições ambientais. O modelo de adaptação conecta ambos os níveis, provendo um componente de raciocínio BDI que executa o processo de deliberação e adaptação. As seções seguintes discutem cada parte do metamodelo proposto em detalhes.

## 4.2 Metamodelo de C&R

O metamodelo de C&R proposto, mostrado na Figura 4.1, é dividido em três submodelos que representam os elementos de confiança, reputação e exploração que estão sujeitos à adaptação. O metamodelo é definido na Expressão 4.1.

$$m_{meta} = \{m_{conf}, m_{rep}, m_{expl}\} \quad (4.1)$$

A Figura 4.2 mostra a divisão do metamodelo e os componentes contidos em cada submodelo. Cada um desses componentes é uma generalização de funções, algoritmos e crenças propostos nos modelos encontrados na literatura.

Para Pinyol e Sabater-Mir (2011), “a confiança pode ser vista como um processo de raciocínio prático que leva à decisão de interagir com alguém”. Seguindo essa ideia, no modelo de confiança  $m_{conf}$  estão os elementos necessários para esse raciocínio: a interação direta ( $id$ ), o uso de vieses ( $v$ ) e normas ( $n$ ), dimensões e contextos ( $dc$ ) considerados nas observações e avaliações, como é feita a avaliação da confiança ( $ac$ ) e como o seu resultado na tomada de decisão em relação à confiança ( $td$ ). O modelo é definido na Expressão 4.2.

$$m_{conf} = \{id, v, n, dc, ac, td\} \quad (4.2)$$

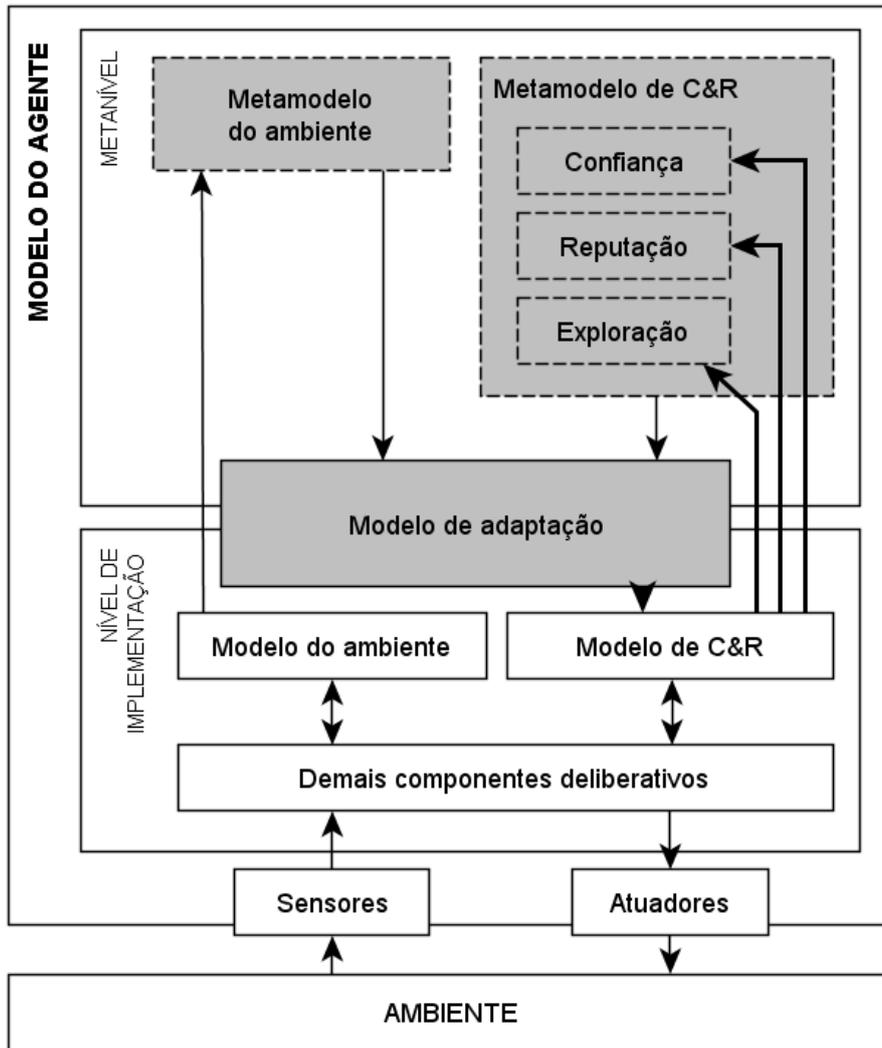


Figura 4.1: Modelo de agente que inclui a adaptação de C&R

Cabe enfatizar que, como ilustrado na Figura 4.1, o raciocínio do agente não depende somente do seu modelo de C&R, mas também de outros componentes que podem influenciar sua decisão final. Portanto, a saída do componente  $td$  do modelo  $m_{conf}$  diz respeito somente à decisão de confiar ou desconfiar segundo a avaliação do modelo utilizado. Outros aspectos podem interferir na decisão final do agente, inclusive mudanças no ambiente ocorridas durante o processo de deliberação da confiança, como alteração na disponibilidade do parceiro escolhido. Logo, esse componente pode ser visto como um elemento a mais do processo de deliberação global do agente, podendo servir com filtro (anterior ou posterior) de intenções de cooperação com outros agentes.

O modelo de reputação  $m_{rep}$  inclui elementos relacionados com as fontes de informação ( $FI$ ) utilizadas na avaliação da reputação. O gerenciamento das fontes de informação ( $gf$ ) e a forma de avaliação da reputação ( $ar$ ) também são parte desse modelo. Logo, o modelo

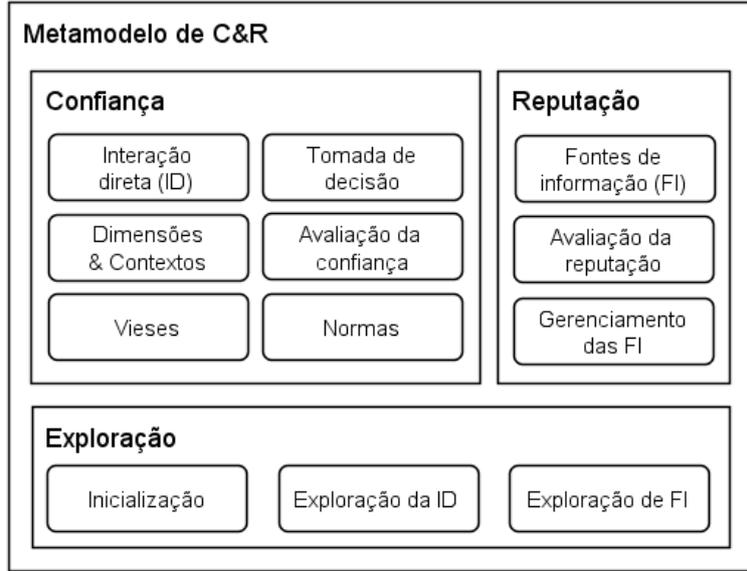


Figura 4.2: Metamodelo de C&R

de reputação é definido na Expressão 4.3.

$$m_{rep} = \{FI, gf, ar\} \quad (4.3)$$

Por fim, o modelo de exploração  $m_{expl}$  define como inicializar o modelo de C&R ( $ini$ ) e os métodos para explorar novas interações diretas ( $exid$ ) e fontes de informação ( $exf$ ). Como visto, a maioria dos modelos propostos na literatura não define esses aspectos, pois consideram configurações pré-existentes (como a existência de certas fontes de informação) que não mudam ao longo do tempo. Por essa razão, o modelo de exploração é incluído como um componente separado, que indica claramente se o modelo define esses elementos. Em um ambiente aberto e dinâmico, a capacidade de buscar novos parceiros e fontes de informação é essencial para a adaptabilidade, um vez que agentes entram e saem (ou tornam-se indisponíveis) do sistema a qualquer tempo. A Expressão 4.4 define o modelo de exploração.

$$m_{expl} = \{ini, exid, exf\} \quad (4.4)$$

Os modelos  $m_{conf}$  e  $m_{rep}$  consideram aspectos mais detalhados de suas fontes de informação, apresentados na Figura 4.3. Esses aspectos incluem a informação usada (memória,  $mem$ ), considerações sobre sua recência ( $rec$ ), os métodos de aquisição ( $ai$ ) e compartilhamento de informação ( $ci$ ), como é avaliada a credibilidade da fonte ( $cred$ ) e a confiabilidade ( $rel$ ) do valor obtido. Uma fonte de informação  $fi$  é definida pela Expressão 4.5. Em  $m_{conf}$ , isso se aplica a três componentes: interação direta, vieses e normas. Em  $m_{rep}$ , o componente

$FI$  representa um conjunto dessas fontes de informação.

$$fi = \{rec, mem, cred, rel, ai, ci\} \quad (4.5)$$

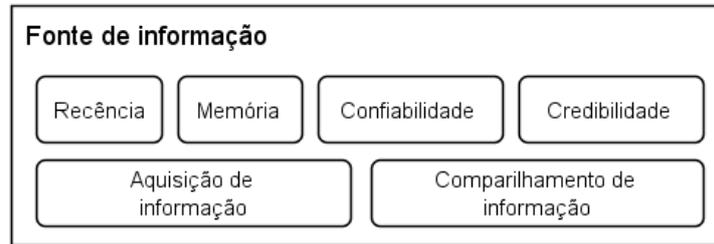


Figura 4.3: Metamodelo de uma fonte de informação

O metamodelo apresentado nesta seção é voltado para a adaptação de C&R e não tem por objetivo ser um metamodelo geral de C&R. Por essa razão, ele não compreende aspectos sobre como os agentes representam os valores de C&R internamente (valores booleanos, intervalos numéricos, crenças, etc.). Ele também assume a existência de uma interoperabilidade mínima entre os modelos, sem explicitamente representar esse componente, uma vez que o custo de interoperabilidade é considerado parte do processo de aquisição e compartilhamento de informação.

Nas seções seguintes, os componentes de cada modelo são apresentados juntamente com uma discussão sobre como eles são afetados em um ambiente dinâmico.

### 4.2.1 Fontes de informação

Modelos dependem de fontes de informação distintas para calcular os valores de C&R. Como visto na Seção 3.4, as duas fontes principais de informação são a interação direta e a informação de testemunhas. Em sociedades maiores, a utilização apenas da interação direta é inviável. O agente demoraria tempo demais para interagir com todos os outros agentes e ainda mais para estabelecer confiança neles. Nesses casos, buscar informação de testemunhas fornece uma forma mais rápida de aprender sobre outros agentes. Isso, no entanto, leva a um problema adicional: avaliar o custo de tal informação e saber o quão confiável ela é. Como apontado por Fullam e Barber (2007), “altos custos de reputação podem tornar a modelagem da confiança baseada em reputação inviável, até mesmo quando as reputações são muito precisas e modelos de confiança baseados na experiência não são robustos”. Além disso, um agente entrando no sistema não tem conhecimento dos outros para interagir diretamente, mas também não tem conhecimento suficiente sobre os agentes que fazem recomendações para confiar na informação que eles proveem. Essa questão é discutida na Seção 4.2.1.2.

Outras fontes de informação são propostas por autores diversos. FIRE (Huynh e Jennings, 2006) sugere o conceito de reputação certificada como uma outra fonte. Modelos propostos por Schillo et al. (2000), Esfandiari e Chandrasekharan (2001) e Vercouter e Muller (2010) consideram a possibilidade de observação da interação (observação direta) como fonte de informação. Nesse caso, um agente pode observar outros interagindo para avaliar seu comportamento e desempenho.

O preconceito é outra fonte proposta, mas pouco usual (Esfandiari e Chandrasekharan, 2001; Sabater, 2002). Em sociedades humanas, o termo *preconceito* possui uma conotação bastante negativa. Para os propósitos desse trabalho, utilizar-se-á o conceito de viés (*bias*), presente na Figura 4.2, uma vez que pode ser usado para representar tanto preferências negativas quanto positivas. Vieses representam preferências internas do agente, baseadas na generalização de experiências prévias ou regras específicas pré-existentes. No modelo ReGreT (Sabater, 2002), o preconceito é usado como uma forma de avaliar agentes desconhecidos com base em características conhecidas (como o local de origem do agente).

As relações sociais envolvendo os agentes também podem ser usadas como fonte de informação, com o intuito de reduzir a incerteza sobre a reputação, utilizando conhecimento *a priori* (Sabater, 2002). Funciona, portanto, como uma forma de viés. Uma vez que se aplica a situações específicas, esse tipo de fonte tem aplicabilidade limitada. Por exemplo, em um sistema hierárquico, um subordinado pode ser programado para assumir que seus superiores sempre têm credibilidade máxima.

Normas e leis sociais, quando empregadas no sistema, também podem ser usadas como fontes. No modelo LIAR (Vercouter e Muller, 2010), a violação ou respeito às normas sociais têm impacto direto na reputação dos agentes. Segundo Dignum et al. (2005), em um SMA aberto, normas podem “inspirar confiança nos agentes que irão se juntar a ele”. Uma norma só será confiável se for devidamente aplicada, caso contrário, sua credibilidade será diminuída até o ponto em que já não inspirará qualquer confiança adicional. O modelo de Castelfranchi e Falcone (1998) apresenta outros exemplos que dependem de uma autoridade garantidora (vide Figura 3.6), como contratos e promessas com testemunhas. Logo, um contrato pode ser considerado uma fonte de informação, cuja confiabilidade da capacidade dessa autoridade de garantir a execução do contrato.

Os diferentes tipos de fontes de informação são exemplificados na Figura 4.4. Os agentes *a* e *c* interagem diretamente com o agente *b*. Para estimar a confiança em *b*, o agente *a* pode utilizar, além da interação direta (*ID*), informação de testemunhas (*IT*) fornecida por *c* e reputação certificada (*RC*) fornecida por *b*. Se possível, o agente *a* pode também observar diretamente (*OD*) a interação entre *b* e *c* para obter mais informações. Na ilustração, o agente *e* funciona como um agregador de reputação, semelhante a um modelo centralizado como SPORAS (Zacharia e Maes, 2000). Apesar de não ter interagido diretamente com

$b$ , ele recebe informações de  $c$  e  $d$  e provê uma recomendação indireta para  $a$ . Por fim, a confiança resultante depende de qualquer viés ( $V$ ) que o agente  $a$  possa ter e das normas ( $N$ ) em efeito no sistema que afetam a percepção de  $a$  sobre  $b$ .

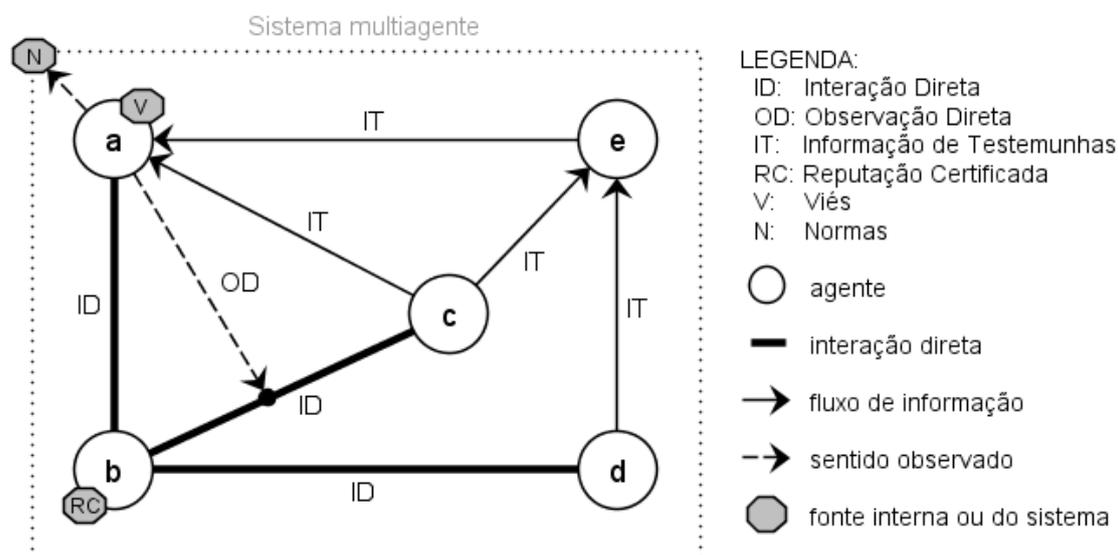


Figura 4.4: Interação com base nas fontes de informação

Com diversas fontes de informação disponíveis, o agente deve decidir quais utilizar e combiná-las com suas fontes internas, como a interação direta. O custo de utilização de cada uma das fontes irá variar de acordo com o ambiente e a implementação. Um viés, por exemplo, é uma fonte interna para o agente  $e$ , como tal, tem um custo mínimo de utilização. Informações de testemunhas, por outro lado, têm custos de comunicação mais elevados para contatar as testemunhas para obter informações.

A disponibilidade das fontes também varia. Considere o exemplo da observação direta. Em um ambiente com muito ruído, a observação das interações de outros agentes pode não ser possível e, mesmo se possível, sua confiabilidade será afetada negativamente. Do mesmo modo, a confiabilidade da informação de testemunhas depende da disponibilidade das melhores testemunhas. Reputação certificada, proposta pelo FIRE, nem sempre é possível, uma vez que depende da cooperação de agentes de apresentar as referências certificadas e a existência de mecanismos para verificar a autenticidade das referências. Mesmo a interação direta nem sempre está disponível, tal como no caso de um agente recém-chegado, que ainda não teve nenhuma interação com os agentes do sistema.

#### 4.2.1.1 Memória e recência

A confiança se estabelece ao longo do tempo como resultado das interações anteriores. Conseqüentemente, considerações temporais são necessárias em modelos de C&R. Ao con-

siderar experiências passadas, o agente deve definir o quão para trás irá olhar e quanta ênfase colocará nas interações mais recentes. Essas duas definições se aplicam a quaisquer fontes de informações usadas na avaliação da C&R. Elas são apresentadas na Figura 4.3 como memória e recência.

Marsh (1994) discute o conceito de memória e como ela afeta a disposição do agente em confiar. A memória é um recurso limitado e, portanto, pode ser restringida a um intervalo de tempo ou um número de interações. Dependendo da extensão da memória do agente, o desempenho passado de uma parceiro pode ser esquecido após um período de tempo. No modelo de Marsh (1994), os agentes assumem três disposições: (i) otimista, que considera o valor máximo da confiança em sua memória, (ii) pessimista, que considera o pior valor possível e (iii) realista, que considera a média da experiência em sua memória. Esse modelo não considera a recência da experiência, uma vez que cada experiência na extensão da memória do agente é igualmente considerada.

A Figura 4.5 ilustra como essas disposições alteram a percepção da confiança. A curva da memória representa os resultados das interações ao longo do tempo em uma escala não especificada. O agente otimista considera o valor máximo das últimas cinco interações, enquanto o pessimista considera o valor mínimo. Duas posturas realistas, utilizando as médias das últimas três e cinco interações, ilustram o impacto de diferentes extensões de memória. É evidente que as disposições otimista e pessimista demoram mais tempo para reagir a mudanças no desempenho do parceiro. Na postura realista, quanto menor a extensão da memória usada para calcular a média, mais a confiança se aproxima do resultado mais recente.

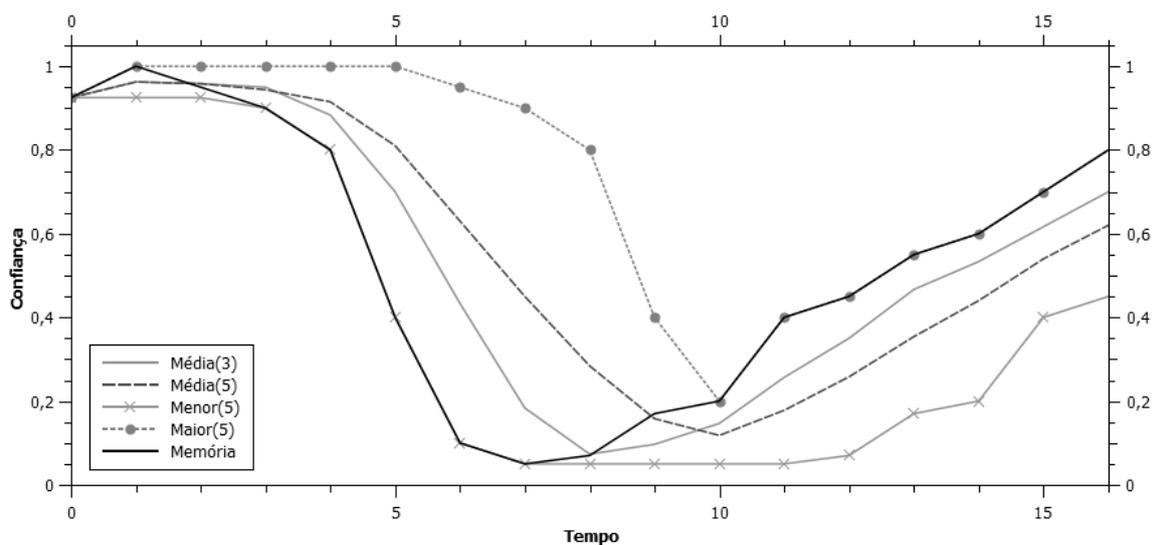


Figura 4.5: Efeitos da memória sobre a confiança

SPORAS trata a questão da recência considerando apenas a avaliação mais recente feita por um agente sobre outro. O número de avaliações consideradas no cálculo da reputação pode ser definido, limitando assim a extensão da memória do agente. Outros modelos, como ReGreT (Sabater, 2002) usam uma função dependente do tempo para enfatizar transações recentes sem delimitar explicitamente a extensão da memória. O modelo FIRE (Huynh et al., 2006) aperfeiçoa a abordagem do ReGreT, introduzindo um fator de escala da recência  $\lambda$  que pode ser ajustado dependendo da granularidade temporal do ambiente.

Ambientes com maior frequência de transações permitem uma extensão de memória menor com maior ênfase em interações recentes, uma vez que novas evidências sobre a C&R dos agentes é abundante (Fullam e Barber, 2007). Uma frequência menor requer uma extensão maior, com menos ênfase na recência. Em um ambiente dinâmico onde essa granularidade se altera com o tempo, uma política fixa sobre esses elementos pode afetar negativamente o desempenho do agente. Portanto, o agente deve ajustar a escala de tempo em resposta a mudanças na granularidade temporal, possivelmente afetando também a extensão da memória.

#### 4.2.1.2 Credibilidade e confiabilidade

Cada fonte de informação possui um nível de confiabilidade (*reliability*) distinto, que indica o quanto as avaliações feitas a partir das informações obtidas dessa fonte correspondem ao resultado observado na interação direta. Além da confiabilidade, alguns modelos definem também o conceito de credibilidade, que define a disposição do agente em acreditar em uma fonte de informação, levando em consideração o que é informado por ela. Mudanças na credibilidade de uma fonte de informação não só devem mudar o peso de suas contribuições no valor final, mas também devem mudar a frequência com que a fonte é consultada. Com várias fontes para escolher, a credibilidade é um discriminante importante de quão valiosa é uma fonte. Esses elementos são apresentados na Figura 4.3.

Na interação direta, um agente deve estabelecer um grau de confiança nos outros. Considere um agente que confia igualmente em outros dois, mas com um número diferente de interações envolvendo-os. Para escolher um deles, uma medida de confiabilidade pode ser usada. Dois fatores podem ser considerados nessa medida: o número de interações e o desvio no desempenho. O modelo ReGreT (Sabater, 2002) ilustra esses dois fatores. Ele define um nível de intimidade (*itm*), como um valor dependente de domínio, que é afetado pela frequência de interação entre indivíduos. Um número de interações abaixo de *itm* reduz a confiabilidade na avaliação da interação direta. Além disso, o desvio no desempenho também é considerado na medida de confiabilidade. Quanto mais os resultados de um agente variarem em relação ao valor esperado, calculado pela confiança, menor é a confiabilidade. A Figura 4.6 exemplifica o cálculo da confiabilidade utilizando a função  $\text{sen}(n \cdot \pi / (2 \cdot itm))$ ,

onde  $n$  é o número de interações diretas entre dois agentes, para valores diferentes de  $itm$ . Após o nível de intimidade ser alcançado, o fator de confiabilidade é sempre igual a um.

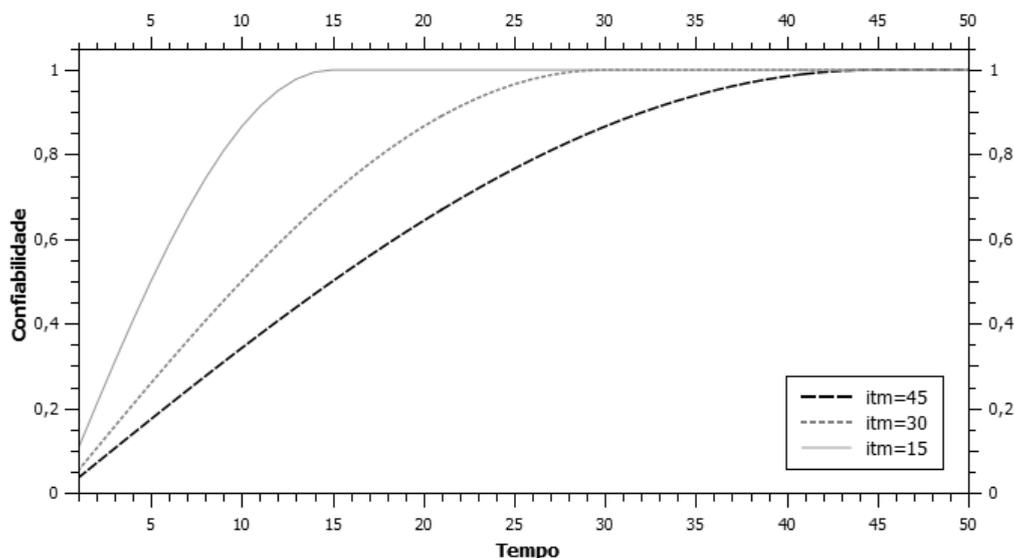


Figura 4.6: Confiabilidade da interação direta no ReGreT

Uma vez mais, a frequência das interações é citada como um fator ambiental importante no ajuste do modelo. Em um ambiente com maior frequência de interações, pode ser usado um limiar mais elevado de intimidade. Outro fator é o desvio em relação ao desempenho. Como mencionado antes, as mudanças no ambiente, tais como alterações nos custos de comunicação têm um impacto sobre o desempenho do agente. Por conseguinte, um desvio mais forte será observado.

De acordo com Keung e Griffiths (2010), no caso da reputação, duas técnicas são usadas para avaliar a confiabilidade das informações recebidas de terceiros: métodos endógenos, que identificam informação incerta com base nas propriedades estatísticas das avaliações, e os métodos exógenos, que consideram outras informações, tais como o papel que o agente desempenha no sistema. As fórmulas do SPORAS e do ReGreT, apresentadas na Seção 3.4, ilustram o método endógeno, enquanto a confiança baseada em papéis do FIRE ilustra o método exógeno.

Outros modelos propostos na literatura têm foco na questão da credibilidade e confiabilidade das medidas de C&R usando uma abordagem probabilística. Esses modelos buscam substituir as abordagens heurísticas comuns nos modelos anteriormente mencionados, propondo uma abordagem probabilística. Nos modelos probabilísticos, as dimensões de confiança são modeladas como variáveis aleatórias utilizando distribuições probabilísticas diferentes. Os modelos BRS (Jøsang e Ismail, 2002) e TRAVOS (Teacy et al., 2006) são baseados na distribuição beta e consideram, como entrada, apenas o número de resultados

positivos e negativos. BLADE (Regan et al., 2006) utiliza uma abordagem similar que pode trabalhar com representações discretas de múltiplos valores, enquanto HABIT (Teacy et al., 2012) permite que vários modelos de confiabilidade sejam usados e combinados no modelo de reputação.

Concluindo, a escolha do modelo de credibilidade, probabilístico ou não, depende do tipo e quantidade de informação que pode ser trocada entre os agentes. Alguns modelos, como o BRS (Jøsang e Ismail, 2002), requerem apenas o número de interações satisfatórias e insatisfatórias. Essa abordagem binária é bastante simples, com baixo custo de transferência e armazenamento de informações, mas é também muito limitado para representações mais sofisticadas, como as multidimensionais. Outros modelos requerem que o agente informe, além do valor da confiança, a sua medida de confiabilidade nesse valor. Isso depende da disposição dos agentes em fornecer tal informação para que se possa obter uma estimativa adequada da confiabilidade da reputação calculada.

#### **4.2.1.3 Aquisição e compartilhamento de informações**

Outro elemento importante dos modelos de C&R é o processo de aquisição e compartilhamento de informação. Em um SMA aberto e dinâmico, informações recentes sobre o desempenho do agente-alvo são essenciais para o cálculo confiável da reputação. Para obter essas informações, o agente deve consultar as fontes de informação disponíveis. O agente pode, também, compartilhar essas informações com outros. Cada tipo de fonte de informação possui um método de aquisição e compartilhamento de informação, como mostrado na Figura 4.3. Além disso, o agente deve decidir quais fontes consultar, considerando sua disponibilidade, credibilidade e custos envolvidos. Esse processo é representado separadamente, na Figura 4.2, pelo componente de gerenciamento de fontes de informação.

Uma abordagem centralizada, como aquela utilizada em SPORAS, pode oferecer uma fonte de informação muito acessível, que recebe classificação de várias fontes. No entanto, em SMAs abertos, não se pode assumir que todo agente irá compartilhar suas avaliações e mesmo aceitar os resultados desse sistema. Em uma abordagem distribuída, os agentes individuais armazenam suas observações localmente e consultam os vizinhos sobre a reputação de outro agente (Huynh, 2006). Num sistema com grande número de agentes, poderia revelar-se difícil encontrar alguém com informações sobre o agente desejado.

Uma abordagem distribuída viável com base em uma rede de referências é proposta por Yu e Singh (2003). Conforme o agente recebe informações de fontes externas, estabelece uma rede de referências. Depois de avaliar a confiabilidade de suas fontes de informação, o agente deve escolher quais fontes consultar. Com o tempo, o agente descobre quem procurar para obter informações sobre uma agente específico. Contudo, num ambiente dinâmico, a disponibilidade da fonte de informação preferida não é garantida.

Além disso, os custos de aquisição da informação devem ser considerados. Se a obtenção de informações sobre reputação fosse gratuita, um agente seria capaz de consultar periodicamente o sistema inteiro para obter informações atualizadas sobre um agente. De maneira realista, é preciso considerar o tempo que será gasto à espera da informação e, em alguns casos, o custo a ser pago por ela. De outro ponto de vista, o agente pode, ainda, se beneficiar no papel de propagador da reputação, auferindo alguma utilidade do compartilhamento de informações. Como descrito na Seção 3.3, segundo Pinyol e Sabater-Mir (2009), essa é uma decisão memética, ou seja, que define como e quando propagar a reputação.

O modelo de Yu e Singh (2003) define dois parâmetros relacionados ao processo de referenciação: fator de ramificação (*branching factor*) e limite de comprimento da referência (*referral length threshold*). Eles têm impacto direto sobre o custo da aquisição de informação, uma vez que definem o número de fontes a serem consultadas para encontrar a informação desejada. Um custo maior de comunicação, por exemplo, forçaria o agente a reduzir o valor de ambos.

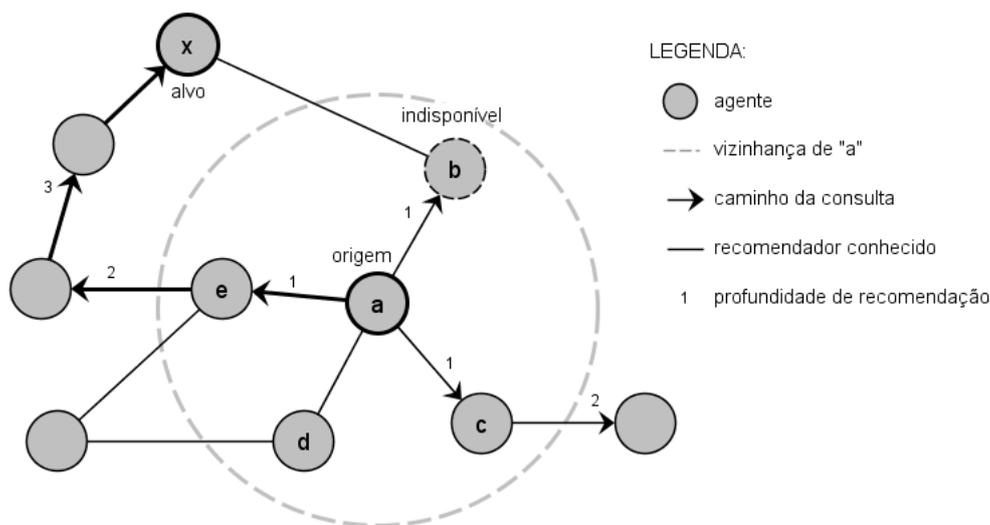


Figura 4.7: Exemplo de processo de aquisição de informação

O processo de aquisição de informação em um ambiente dinâmico é ilustrado pela Figura 4.7. Nesse exemplo, o agente *a* decide consultar sua vizinhança com fator de ramificação igual a 3. Com isso, ele escolhe *b*, *c* e *e*. Ele também define um limite de comprimento igual a 3, como indicado pelos números no grafo. Uma vez que o ambiente é dinâmico, a agente *b*, nesse caso, não está disponível e, logo, *a* não recebe resposta dele. O agente *c* responde que não conhece o agente *x*. O agente *e* utiliza o comprimento máximo permitido para encontrar informação sobre *x*, encaminhando a consulta para outros agentes conhecidos. Perceba que o agente *a* poderia ter escolhido o agente *d* em vez de *e* e, como resultado, não obteria informação sobre *x*. Isso demonstra como a aquisição de informação está sujeita à dinâmica

do ambiente, tal como quão esparsas são as conexões entre os agentes e a disponibilidade dos mesmos para prover informação.

## 4.2.2 Dimensões e contexto

Tanto a confiança, quanto a reputação, podem ser vistas como elementos multidimensionais que dependem do contexto da interação (Griffiths, 2005). Os agentes definem como diferentes aspectos da interação contribuem para a avaliação da confiança e sob qual contexto foram observados. Na Figura 4.2, isso é representado pelo componente Dimensões & Contextos (*D&C*).

Em relação ao contexto, Marsh (1994) define confiança situacional, que leva em conta interações passadas em uma situação específica. Na ausência de experiências anteriores na mesma situação, o agente pode considerar a confiança obtida em outras situações como uma estimativa. O modelo FIRE define um tipo de confiança, baseada no papel dos agentes no sistema, como maneira de definir formas específicas de domínio para o cálculo da confiança (Huynh et al., 2006). ReGreT (Sabater, 2002) avalia a confiança considerando um aspecto comportamental específico e define uma dimensão ontológica que decompõe a confiança como um grafo de aspectos relacionados (ex.: tempo de entrega, qualidade, preço). Para calcular a confiança, os valores de cada nó devem ser combinados, por exemplo, por meio de uma média ponderada. A Figura 4.8 ilustra o conceito de confiança multidimensional. A confiança em um agente vendedor é composta por três dimensões: tempo de entrega, qualidade do produto e preço. A qualidade do produto é dividida em mais duas dimensões: durabilidade e desempenho. Os números nas arestas indicam o peso de cada dimensão na composição das dimensões superiores.

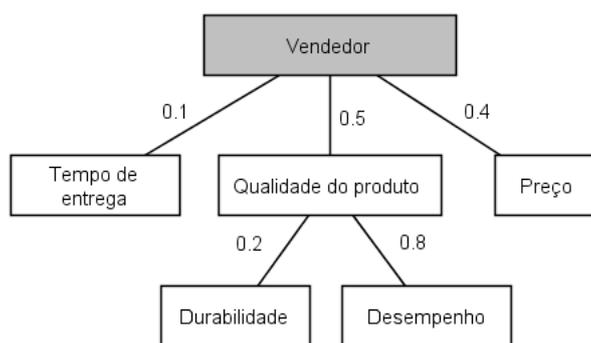


Figura 4.8: Confiança multidimensional

A reputação de uma agente em um ambiente orientado a serviços, por exemplo, pode ser vista em termos dos aspectos da qualidade do serviço (*Quality of Service* – QoS) que provê,

como a correção e a tempestividade dos resultados. Esses aspectos podem ser considerados para determinar a reputação total do agente.

Quando considerado o contexto, agentes podem prover informações mais precisas sobre a reputação de outros. Por exemplo, considere um agente que fornece dois serviços, um com alta QoS e outro com baixa qualidade. Nesse caso, a reputação total não é um bom parâmetro de decisão para um agente interessado especificamente em um dos serviços.

A Expressão 4.6 mostra uma das possíveis formas de combinar as dimensões em um valor único de confiança multidimensional ( $MDT$ ) do agente  $a$  em  $b$ , onde  $q_i \in Q$  é uma dimensão correspondente a um parâmetro de QoS e  $w_{q_i}$  é o peso desse parâmetro (Griffiths, 2005).

$$MDT(a, b) = \sum_{i=1}^{|Q|} w_{q_i} \times T_{q_i}(a, b) \quad (4.6)$$

Confiança multidimensional e contextual são mais adequadas para ambientes dinâmicos, uma vez que mudanças no ambiente podem afetar uma ou mais dimensões e, conseqüentemente, ter um reflexo no valor da confiança. Por exemplo, em um sistema distribuído, mudanças nas condições de rede podem impactar a dimensão *tempo de resposta*, causando redução da confiança nos agentes afetados.

Utilizar uma representação particular, incluindo a multidimensionalidade, para os valores de C&R aumenta a dificuldade na interoperabilidade de modelos. Considere o exemplo anterior em que o agente utiliza um modelo multidimensional que mantém valores separados para cada parâmetro de QoS utilizado no sistema. Se outros agentes não compartilham a mesma representação, quando consultados sobre dimensões específicas, só poderão retornar o valor geral da reputação, sem o valor específico desejado.

A questão de alinhamento semântico das dimensões de confiança e interoperabilidade de modelos de C&R está além do escopo deste trabalho. Trabalhos nesse sentido podem ser encontrados em Nardin et al. (2008), Şensoy et al. (2009) e Koster et al. (2010).

Para os propósitos da abordagem deste trabalho, o componente D&C assume a existência de interoperabilidade mínima que permita a troca de informação. Dificuldades de interoperabilidade terão reflexo na utilidade da fonte de informação. Se uma informação sobre reputação trocada não puder ser corretamente interpretada, então a confiabilidade da fonte será impactada. Por outro lado, se dois agentes compartilham os mesmos elementos de  $D&C$ , o compartilhamento de informação sobre reputação será melhorado.

### 4.2.3 Inicialização e exploração

Na maioria dos modelos de C&R, a questão de como um modelo inicia sua operação (*bootstrapping*) na ausência de informação prévia é ignorada (Pinyol e Sabater-Mir, 2011).

Como visto na Seção 3.4, alguns modelos assumem a presença de fontes de informação pré-existentes que são acessíveis ao novo agente, sem a necessidade de descobrir gradualmente suas fontes de informação. Em ambientes dinâmicos, os agentes encontram essa situação com maior frequência devido a mudanças na população e na disponibilidade das fontes.

O modelo de Marsh (1994) considera apenas a interação direta para estabelecer a confiança. Uma vez que o modelo não considera o uso de reputação, na ausência de experiências anteriores, ele deve estabelecer critérios para decidir quando confiar em um agente desconhecido. O modelo apresenta o conceito de confiança básica, que representa uma disposição geral de confiar baseada nas experiências anteriores e é alterada pelas posturas otimista, pessimista e realista do agente. Essa ideia pode ser vista como uma política rudimentar de inicialização, na qual um agente decide confiar em agentes desconhecidos com base no desempenho dos agentes conhecidos.

O modelo HABIT (Teacy et al., 2012) propõe uma abordagem similar ao modelo de Marsh, porém mais sofisticada. Na ausência de experiências anteriores com um novo agente, HABIT prediz seu comportamento com base nas interações passadas de agentes com características similares. O modelo aprende sobre a confiabilidade de novatos em geral, considerando o desempenho médio de agentes similares já presentes no sistema. Isso introduz a dificuldade de encontrar grupos similares de agentes, mas resulta em estimativas mais confiáveis.

No SPORAS, um novato tem reputação igual a zero, o menor valor possível. O raciocínio por trás dessa decisão é que um agente não tem incentivos para assumir uma nova identidade, uma vez que sua reputação não poderá melhorar com isso. Confiar em um novato, nesse caso, depende somente da disposição dos agentes em tentar uma interação direta sem qualquer informação de reputação.

Burnett et al. (2010) propõem o uso de estereótipos para inicializar as avaliações da confiança. Estereótipos, nesse contexto, generalizam experiências anteriores com parceiros conhecidos, que podem se aplicar a agentes novos. A proposta funciona sob a suposição de que há uma correlação entre as características dos parceiros e seu desempenho. Como o viés mencionado na Seção 4.2.1, essa abordagem também utiliza suposições *a priori*. Ela requer um tempo para construir os estereótipos pela observação. Segundo Burnett et al. (2010), se esse intervalo for muito curto, o estereótipo gerará expectativas imprecisas sobre o desempenho dos agentes estereotipados. Se o intervalo for muito grande, o estereótipo será insensível a mudanças.

Em suas simulações, FIRE (Huynh et al., 2006) utiliza uma estratégia de exploração de Boltzmann para permitir que agentes escolham parceiros desconhecidos de acordo com um parâmetro de temperatura que é reduzido com o tempo. Inicialmente, os agentes arriscam perder utilidade por confiar em um agente desconhecido, mas eles também têm a chance de

descobrir novos, e possivelmente melhores, parceiros. O mesmo é válido para as recomendações. Agentes precisam descobrir novos recomendadores para estender a rede de referências e aumentar a qualidade da reputação obtida. Com o decréscimo da temperatura, os agentes restringem cada vez mais suas escolhas aos parceiros e recomendadores conhecidos.

Na Figura 4.2, três componentes constituem o modelo de exploração: (i) inicialização, que define a exploração inicial do ambiente, (ii) exploração da interação direta, usada para explorar novas parcerias diretas, e (iii) exploração de fontes de informação, usada para conhecer novos recomendadores e fontes de informação. Esses são componentes essenciais para a adaptabilidade. Em um ambiente dinâmico, sujeito a mudanças severas e súbitas, tais como migração do agente para uma nova plataforma ou perda de conectividade com uma porção significativa do sistema, o agente pode ser forçado a retornar para um estado de exploração. Ademais, após utilizar continuamente um número limitado de fontes, o agente pode perder a perspectiva de outras, potencialmente melhores, fontes. Essa situação está relacionada aos componentes de memória e recência, discutidos na Seção 4.2.1.1, que tendem a “esquecer” interações mais antigas, reduzindo assim a credibilidade e confiabilidade das fontes não utilizadas.

#### 4.2.4 Avaliação e decisão de confiar

O resumo dos modelos apresentado na Seção 3.5 mostra que nem todo modelo tem uma definição clara de como a decisão de confiar em outro agente é tomada. Marsh (1994) define um limiar de cooperação claro, que pode ser calculado utilizando a Expressão 3.2, apresentada anteriormente. No entanto, outros modelos apresentados na Seção 3.4 não especificam como utilizar as avaliações obtidas para determinar se confiam no agente (e em qual deles confiar).

Por exemplo, se um agente  $a$  tem um valor de confiança 0,7 (com confiabilidade desse valor de 0,9) e um agente  $b$  com valor de confiança 0,9 (e confiabilidade 0,6), o componente de tomada de decisão define qual será escolhido. Ele poderia escolher  $b$ , uma vez que possui o maior valor de confiança; poderia escolher  $a$ , se considerasse que a medida de  $b$  não fosse suficientemente confiável; ou poderia utilizar a multiplicação de ambos os valores para obter uma estimativa da confiança, o que também resultaria na escolha de  $a$ .

Em contraste com o componente de tomada de decisão do modelo de Marsh (1994), que define apenas um limiar, o modelo LIAR define dois limiares para cada tipo de fonte de informação usada. Caso o valor avaliado esteja acima do limiar superior  $\theta_{fonte}^{trust}$  (de confiança) para aquela fonte, a intenção de confiar é estabelecida. Caso o valor esteja abaixo do limiar inferior  $\theta_{fonte}^{distrust}$  (de desconfiança), a intenção de desconfiar é estabelecida. Caso o valor esteja entre os dois limites, outro tipo de fonte é avaliado da mesma maneira. O processo

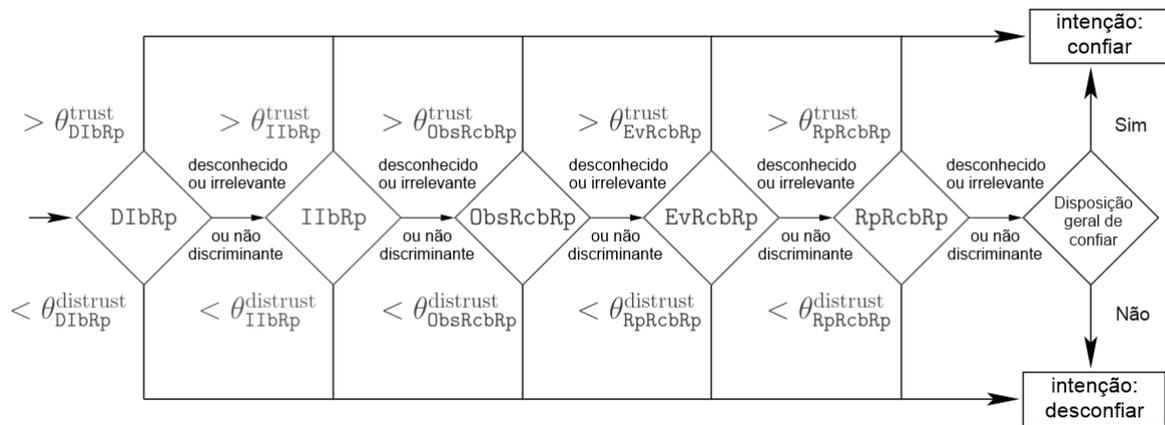


Figura 4.9: Tomada de decisão no LIAR, adaptada de Vercouter e Muller (2010)

de tomada de decisão no modelo LIAR (Vercouter e Muller, 2010), descrito em mais detalhes na Seção 3.4, é apresentado na Figura 4.9.

A decisão de confiar ou desconfiar depende, antes de tudo, dos componentes de avaliação de C&R. Esses componentes avaliam a C&R obtida das fontes de informação, considerando as dimensões e os contextos aplicáveis. Assim, eles devem considerar as características de cada fonte para ponderar ou mesmo filtrar as avaliações disponíveis. Por exemplo, no modelo ReGreT (Sabater, 2004), fontes com credibilidade abaixo de um limite poderiam ser desconsideradas, enquanto as fontes restantes poderiam ser ponderadas de acordo com a sua credibilidade. No caso da avaliação da confiança, o componente deve definir, também, como a avaliação da reputação será considerada. No modelo FIRE, isso é feito considerando o peso de cada fonte de informação de reputação (reputação de testemunhas ou reputação certificada).

### 4.3 Fluxo de informação e deliberação

A Seção 3.3 apresenta o fluxo de informação e deliberação da confiança, sob a visão do modelo BDI, proposto por Staab e Muller (2012). Nesta seção, os componentes apresentados anteriormente são posicionados na sequência de fases desse fluxo, com a adição de três fases complementares, que consideram decisões anteriores às observações e posteriores aos atos de confiança. A Figura 4.10 apresenta o fluxo modificado, com destaque para as fases adicionais.

A Figura 4.11 destaca as fases de exploração e seleção. Na fase de exploração, os componentes do modelo de exploração  $m_{expl}$  decidem sobre a exploração das fontes de informação disponíveis, incluindo a exploração inicial feita pelo agente ao entrar no sistema. Em seguida, na fase de seleção, as fontes a serem utilizadas são escolhidas. No caso das

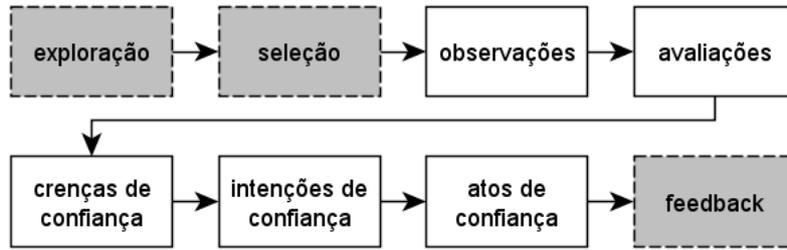


Figura 4.10: Fluxo de informação e deliberação da confiança

fontes de reputação, a escolha é feita pelo componente de gerenciamento das fontes de informação ( $gf$  do modelo  $m_{rep}$ ). Em seguida, são realizadas as observações das fontes escolhidas.

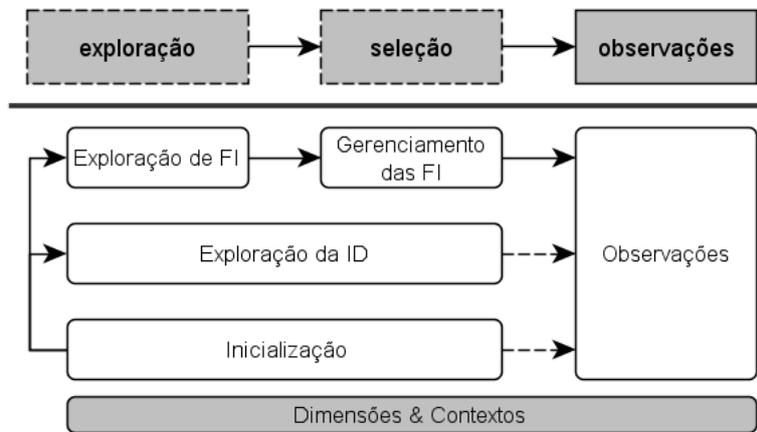


Figura 4.11: Fases de exploração, seleção e observações

O componente de dimensões e contextos ( $dc$ ) do modelo de confiança permeia cada uma dessas fases, bem como as fases posteriores. Isso porque os demais componentes podem fazer uso dele para guiar suas ações, como, por exemplo, distinguir observações e avaliações considerando o contexto. A Figura 4.12 apresenta a maioria das fases – das observações até as intenções de confiança. A fase das observações inclui os componentes que correspondem a fontes de informação tanto do modelo de confiança  $m_{conf}$  quanto do modelo de reputação  $m_{rep}$ . Na fase de avaliação, cada fonte de informação de  $m_{trust}$  realiza sua avaliação, enquanto o componente de avaliação da reputação ( $ar$ ) considera suas próprias fontes de informação.

Na próxima fase, as crenças de confiança são estabelecidas com base no componente de avaliação da confiança ( $ac$ ), que leva em consideração as avaliações realizadas anteriormente. Em seguida, as intenções de confiança são estabelecidas com base no resultado da avaliação de confiança, por meio do componente de tomada de decisão ( $td$ ).

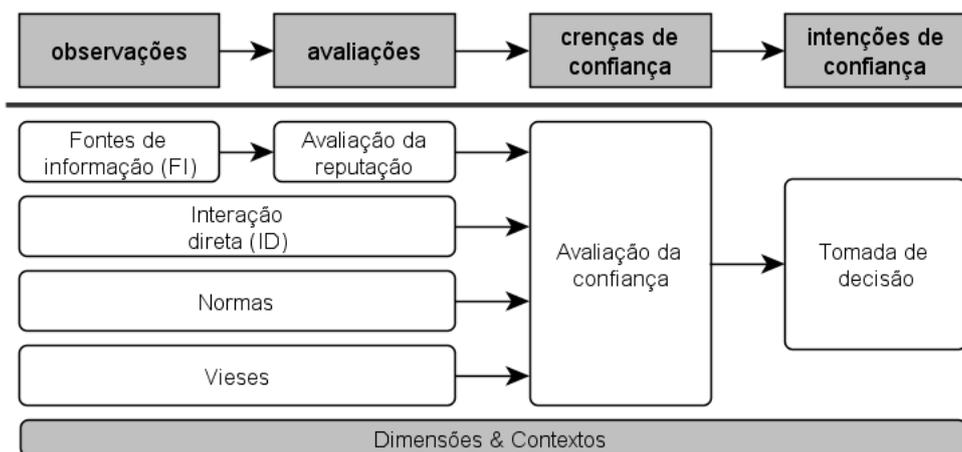


Figura 4.12: Fluxo de informação no metamodelo proposto

A Figura 4.13 detalha as fases de observações e avaliações do ponto de vista de uma fonte de informação. A observação é feita segundo o procedimento estabelecido pelo componente de aquisição de informação (*ai*). O resultado é armazenado no componente de memória (*mem*), que pode ter um limite de capacidade ou eliminar observações muito antigas. Na fase da avaliação, as observações disponíveis são consideradas segundo os componentes de recência (*rec*), credibilidade e confiabilidade. O componente *rec* pode estabelecer uma avaliação diferenciada para as observações segundo sua idade, privilegiando, por exemplo, observações mais recentes. O componente de credibilidade avalia o quanto o agente está disposto em acreditar naquela fonte de informação levando em consideração, por exemplo, o tempo de interação entre eles e a variabilidade do seu desempenho. Por fim, o componente de confiabilidade (*rel*), com base nos resultados de interações anteriores, estima a confiabilidade da observação daquela fonte. Após passar por esses componentes, os resultados da avaliação são fornecidos para o componente *ac*. No caso das fontes de informação de reputação, antes da avaliação de *ac*, o componente de avaliação da reputação (*ar*) combina os resultados das suas fontes.

O componente de tomada de decisão (*td*) é o responsável por decidir sobre a concretização das intenções de confiança em atos de confiança. A Figura 4.14 ilustra essas fases. Após a decisão de confiar ou não ser determinada, o agente realiza o ato escolhido (considerando a deliberação adicional do agente em face de outras intenções externas ao modelo de confiança) e obtém a respectiva utilidade. Em caso de falha, tal utilidade pode ser negativa. Mesmo o ato de não confiar pode resultar em perda de utilidade, pelo gastos do processo ou decorrentes da ociosidade resultante. Em qualquer um dos casos, o resultado é utilizado para atualizar as crenças do metamodelo de C&R, na fase de *feedback*.

A fase de *feedback*, ilustrada pela Figura 4.15, utiliza o resultado dos atos de confiança para atualizar as crenças sobre as fontes de informação utilizadas. Esse resultado afeta

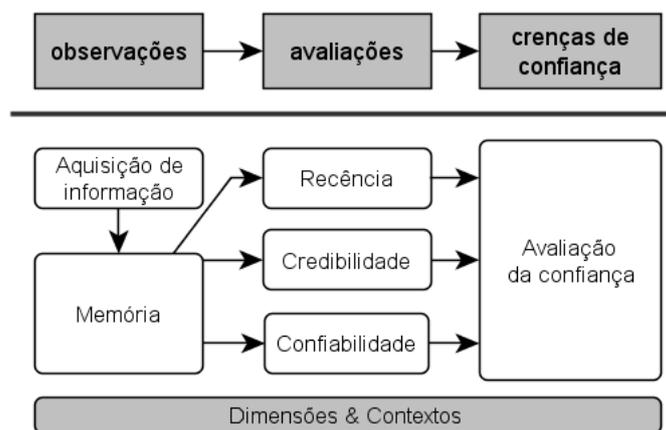


Figura 4.13: Fases de observações e avaliações na visão da fonte de informação

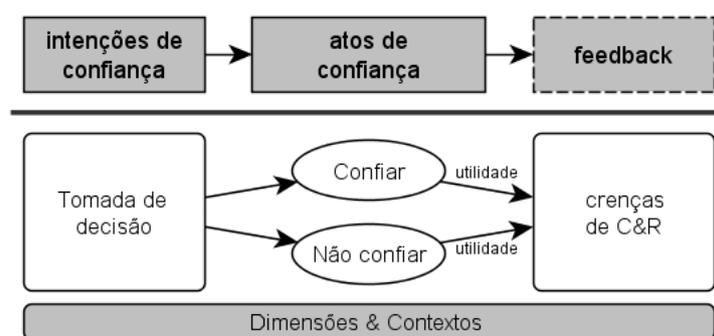


Figura 4.14: Fases de intenções e atos de confiança

a credibilidade e confiabilidade da fonte, bem como sua memória (que agora armazena o novo resultado). Por fim, após a interação, o agente pode utilizar o componente de compartilhamento de informação (*ci*) para distribuir o resultado para outros agentes e fontes.

O compartilhamento de informações pode ser realizado em qualquer fase, segundo a especificação do componente de gerenciamento de fontes de informação (*gf*), para, por exemplo, atender ao pedido de informação de outro agente. O componente *ci* é apresentado especificamente na fase de *feedback* porque é a fase em que a informação sobre a interação mais atual torna-se disponível no modelo. A Tabela 4.1 apresenta um resumo das fases descritas nesta seção. A Tabela C.1, presente no Apêndice C, define formalmente as entradas e saídas dos componentes de cada fase.

## 4.4 Metamodelo do ambiente

O metamodelo do ambiente é outro elemento importante do metanível da arquitetura apresentada na Figura 4.1. Esse modelo é usado para traduzir as percepções dos agentes

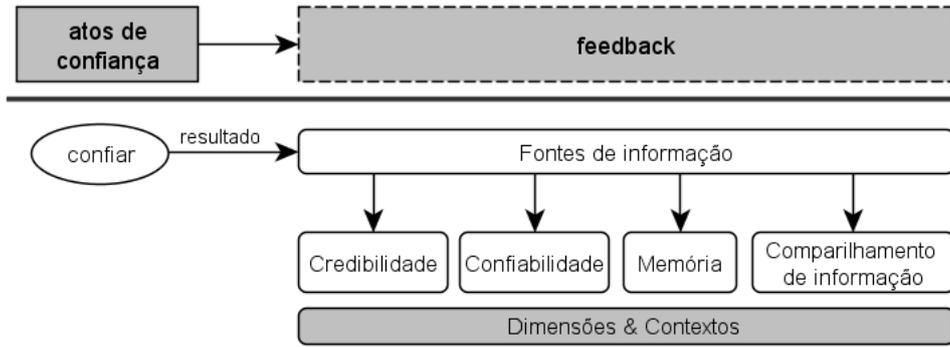


Figura 4.15: Fase de *feedback* do fluxo de informação

do ambiente real para a representação interna do agente para fins de adaptação da C&R. Como discutido na Seção 4.2, vários elementos de modelos de C&R são afetados por aspectos ambientais. Modelar esses aspectos permite que o agente perceba e reaja corretamente às mudanças no ambiente.

Para fins de adaptação, nem todo aspecto do modelo do ambiente precisa ser representado no metanível. O tamanho da população, por exemplo, não é explicitamente considerado no metanível, uma vez que os agentes não deliberam sobre o tamanho da população diretamente, mas sobre os aspectos afetados por ela (como disponibilidades dos agentes).

A Figura 4.16 apresenta o metamodelo do ambiente e seus componentes. Estes foram identificados a partir das características dos modelos estudados, representadas no metamodelo de C&R, que são afetadas pela dinamicidade do ambiente.

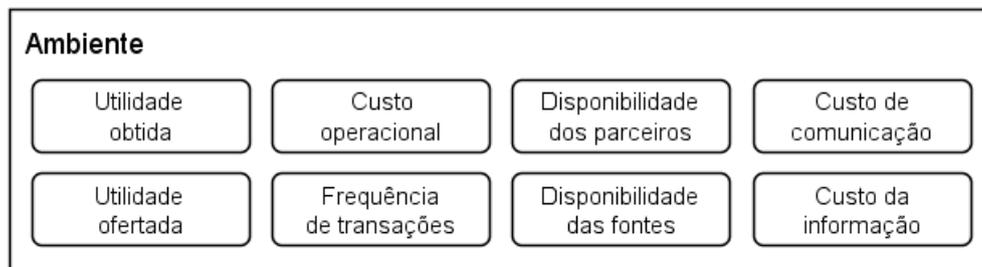


Figura 4.16: Metamodelo do ambiente

Portanto, o ambiente, no metanível, é uma representação abstrata que generaliza os aspectos independentes de domínio que são parte do processo de adaptação. O metamodelo do ambiente  $Env$  é definido pela Expressão 4.7, em que cada componente é descrito na Tabela 4.2.

$$Env = \{U_{total}, U_{obt}, C_{op}, F, D_{pc}, D_{fi}, C_{com}, C_{inf}\} \quad (4.7)$$

É importante notar que aspectos específicos do domínio contidos no modelo concreto do ambiente podem ser mapeados para um ou mais aspectos do metanível. Por exemplo,

Tabela 4.1: Fases da deliberação da confiança

Fase	Descrição
Exploração	Decisões sobre a exploração das fontes de informação disponíveis, incluindo como iniciar a operação no ambiente.
Seleção	Decisão sobre o que observar; em especial, seleciona quais fontes de reputação serão consultadas.
Observações	Realização das observações associadas a cada fonte de informação, segundo sua forma de aquisição e armazenamento (memória).
Avaliações	Realização das avaliações para cada fonte de informação, considerando aspectos de recência, credibilidade e confiabilidade.
Crenças de confiança	Estabelecimento de crenças a partir da avaliação da confiança.
Intenções de confiança	Estabelecimento das intenções de confiança a partir do processo de tomada de decisão.
Atos de confiança	Concretização de uma intenção de confiança.
<i>Feedback</i>	Atualização das crenças do modelo de C&R com base no resultado de um ato de confiança, incluindo o compartilhamento desse resultado com outros agentes.

considere a condição climática como um aspecto ambiental de domínio específico. Se ela interromper a comunicação entre um agente e suas fontes de informação, o componente de disponibilidade ( $D_{fi}$ ) refletirá essa situação. O metanível, portanto, permite que o processo de adaptação delibere sobre os componentes impactados que são livres de domínio. Mais tarde, no processo de adaptação, aspectos específicos de domínio podem ser novamente reintroduzidos por meio dos planos de adaptação, descritos na Seção 4.5. As seções seguintes discutem cada um dos componentes do metamodelo do ambiente.

#### 4.4.1 Custo operacional

Ao buscar cooperação, um agente pode optar por não confiar em qualquer um dos parceiros disponíveis e esperar por uma opção mais confiável se tornar disponível. Castelfranchi e Falcone (2001) citam “não fazer nada” (Figura 3.7) como uma opção válida quando o agente busca cooperação. Essa escolha é representada como uma escolha neutra em termos de utilidade e, como tal, é omitida posteriormente pelos autores. No entanto, em um SMA real, um agente dispõe de recursos que têm um custo associado, independente da eficiência com que o agente os utiliza.

Tabela 4.2: Componentes do metamodelo do ambiente

Componente	Símbolo
Utilidade ofertada no sistema	$U_{total}$
Utilidade obtida	$U_{obt}$
Custo operacional	$C_{op}$
Frequência das transações	$F$
Disponibilidade dos parceiros confiáveis	$D_{pc}$
Disponibilidade das fontes de informações	$D_{fi}$
Custos de comunicação	$C_{com}$
Custos de informação	$C_{inf}$

O custo operacional ( $C_{op}$ ), portanto, representa um valor pago pelo agente pelo direito de utilizar um recurso. Isso significa que, estando o agente ocupado ou não, esse custo será descontado de sua utilidade. A existência desse custo básico tem um impacto sobre a disposição de confiar do agente, uma vez que adiciona um senso de urgência para a decisão de confiar. Sem essa urgência, o agente poderia esperar indefinidamente pelo agente mais confiável, minimizando seus riscos ao custo de potenciais ganhos de utilidade com outros agentes. Considere o conceito de *limiar de cooperação*, proposto por Marsh (1994). Ao avaliar o risco da parceria, se o custo de não fazer nada for alto o suficiente, é melhor para o agente correr o risco de cooperação. O real peso desse custo, depende de dois outros aspectos do ambiente: os ganhos de utilidade esperados e a frequência das transações.

#### 4.4.2 Utilidade e frequência de transações

Para melhor raciocinar sobre os riscos de cooperação, um agente deve perceber quanta utilidade espera obter. Isso permite que o agente possa colocar outros custos em perspectiva, a fim de avaliar se uma ação é barata ou cara. Por exemplo, em sistemas orientados a serviços, a utilidade é um valor dinâmico, dependendo da demanda por serviços. Um agente que oferece um serviço com menor demanda, obterá menos utilidade por unidade de tempo ( $U_{obt}$ ). Como resultado, o  $C_{op}$  desse agente será proporcionalmente maior em relação a um agente com o mesmo  $C_{op}$  que obtiver mais utilidade. Um agente com pouca  $U_{obt}$  também pode ter modelos de C&R restritos, uma vez que as ações mais caras (como entrar em contato com um grande número de agentes para obter informações de reputação) pode não ser viável. Em um ambiente dinâmico, as mudanças na relação entre  $U_{obt}$  e  $C_{op}$  exigem que o agente modifique seus modelos de C&R para se adaptar às novas condições. A utilidade auferida pelo agente ( $U_{obt}$ ) se diferencia da utilidade total oferecida no sistema

( $U_{total}$ ). A relação entre  $U_{obt}$  e  $U_{total}$  pode indicar o nível de competitividade no sistema. Quanto maior for  $U_{obt}$  em relação a  $U_{total}$ , mais competitivo é o agente.

A frequência das transações ( $F$ ) é um aspecto complementar da utilidade. O agente deve perceber quantas oportunidades por unidade de tempo ele tem. Utilidade por si só não é suficiente para caracterizar com precisão o ambiente. Como visto na Seção 4.2, a frequência das transações afeta elementos distintos dos modelos de C&R, como extensão da memória e medidas de credibilidade. Considere um ambiente no qual  $U_{total} = 100/hora$  e  $F = 2/hora$ , o que significa que, em média, apenas duas transações são oferecidas com uma utilidade total de 100. Agora, considere um ambiente com os mesmos  $U_{total}$  e  $F = 10/hora$ . O senso de urgência para confiar é maior no primeiro caso, já que as oportunidades são escassas.

### 4.4.3 Disponibilidade dos agentes

A disponibilidade de parceiros de confiança é, igualmente, um aspecto a ser considerado. Burnett et al. (2010) afirmam que a seleção do agente mais confiável é o método mais comumente encontrado na literatura. No entanto, em um SMA dinâmico, o agente mais confiável pode não estar disponível. É razoável esperar que os agentes com melhor reputação estejam mais ocupados do que os outros. O mesmo pode ser dito sobre as fontes de informação: em uma rede de referências, os agentes que fornecem as melhores recomendações podem não estar disponíveis o tempo todo. Portanto, o agente não pode assumir que a melhor opção estará sempre disponível. Ao considerar a próxima opção disponível, os riscos aumentam e o dilema de assumir o aumento do risco em relação à espera de uma oportunidade melhor torna-se mais evidente. A disponibilidade dos parceiros é indicada por  $D_{pc}$ , enquanto a disponibilidade das fontes de informação é indicada por  $D_{fi}$ .

A disponibilidade também pode estar relacionada a outros aspectos ambientais, como a localização. Em suas configurações experimentais, os autores do modelo FIRE (Huynh et al., 2006) definem a disponibilidade dos provedores de serviços como a sua distância para o agente em um mundo esférico. Como as coordenadas dos agentes e dos provedores podem mudar, eles podem tornar-se demasiadamente distantes e, conseqüentemente, indisponíveis. Em outros cenários, os custos de comunicação podem desempenhar o mesmo papel.

Finalmente, a disponibilidade do provedor de serviço pode ser restrita pela sua capacidade limitada. Então, se o fornecedor mais confiável não pode atender ao pedido do agente, este deve, mais uma vez, escolher a segunda melhor opção ou simplesmente esperar o parceiro preferido ficar disponível novamente. Em ambientes dinâmicos, a disponibilidade de um provedor de serviço pode mudar devido a flutuações na demanda por seus serviços.

#### 4.4.4 Custos de comunicação

Troca de informações é parte central da reputação. Como tal, há custos de comunicação ( $C_{com}$ ) envolvidos. Como visto na Seção 4.2, existem vários tipos de fontes de informação com diferentes graus de confiabilidade e complexidade. Um agente deve ser capaz de escolher fontes de informação cujos benefícios superem os custos de aquisição e manutenção de informações (Castelfranchi e Falcone, 2001; Teacy et al., 2006). Outro aspecto que pode amplificar o  $C_{com}$  é a frequência das transações ( $F$ ). Se  $F$  é alta, o  $C_{com}$  envolvido no pedido constante de novas informações sobre a reputação de agentes também aumentaria. Nesse caso, há uma troca entre o  $C_{com}$  e ter sempre as últimas informações disponíveis.

Considerando um exemplo extremo, em que uma falha de rede temporária resulta em um  $C_{com}$  muito alto. Nesse cenário, a consulta a fontes externas de informação poderia se tornar inviável. Da mesma forma, se o agente ou sua fonte de informação mais confiável mudarem de localização, o aumento resultante no  $C_{com}$  pode forçar o agente a procurar novas fontes menos conhecidas.

Uma vez que as fontes de informação têm diferentes  $C_{com}$ , os agentes podem modificar a sua escolha de acordo com a situação, buscando uma fonte de menor confiabilidade, mas com um  $C_{com}$  menor. Obviamente, a escolha de uma fonte menos confiável com custo mais baixo deve ser feita somente se o risco adicional valer a pena. Por exemplo, para reduzir  $C_{com}$ , em vez de consultar a reputação com várias testemunhas conhecidas, o agente pode escolher um agregador de reputação. Em um sistema centralizado, como SPORAS e outros sistemas de reputação utilizados em mercados eletrônicos, os avaliadores são muitas vezes desconhecidos para o agente. Consequentemente, o agente não pode avaliar a credibilidade de cada um. Por outro lado, o agregador potencialmente concentra mais avaliações do que as que seriam obtidas pela rede de referências do agente e o  $C_{com}$  necessário para consultá-lo é mais baixo.

#### 4.4.5 Custo da informação

Modelos que enfatizam o uso de informações de reputação desconsideram os custos envolvidos na sua aquisição e verificação. A importância de conhecer a reputação de outro agente, na ausência de experiência direta é inegável, conforme demonstrado pelos modelos apresentados na Seção 3.4. No entanto, o custo pago para obter essa informação ( $C_{inf}$ ) pode restringir as opções do agente.

Se um agente de  $a$  consulta  $b$  sobre a reputação de um outro agente,  $b$  pode solicitar um pagamento em troca da informação. Ao receber uma compensação adequada, mesmo que  $b$  não tenha qualquer informação, pode encaminhar a consulta a outros agentes conhecidos, deduzindo os custos de sua remuneração inicial.

Verificar as informações recebidas também é outro custo. Por exemplo, na reputação certificada, proposta no modelo FIRE (Huynh et al., 2006), o agente  $a$  recebe referências das interações anteriores de  $b$  que são certificadas por outros agentes. Para verificar essas referências, caso considere necessário,  $a$  deve verificar sua autenticidade contactando diretamente as referências ou usando um mecanismo de segurança (como assinaturas digitais). Ambas as formas geram custos adicionais.

Na rede de referências proposta por Yu e Singh (2003), uma recomendação indireta também pode exigir verificação. Suponha que  $b$ , como recomendador, encaminhe a outros agentes a consulta de  $a$  sobre a reputação de  $c$ . Mais tarde,  $b$  fornece ao agente  $a$  uma informação sobre  $c$  dada pelo agente  $x$ , que não é conhecido por  $a$ . O agente  $a$  poderia decidir entrar em contato com  $x$  para verificar as informações, para se certificar de que  $x$  realmente forneceu essas informações e se a informação não foi adulterada por  $b$  ou qualquer outro agente no caminho das referências. Mais uma vez, esse procedimento aumentaria o custo da informação.

## 4.5 Modelo de adaptação

Os metamodelos de C&R e do ambiente abstraem elementos dos seus respectivos modelos utilizados no nível de implementação. Baseado nesses dois componentes do metanível, o modelo de adaptação tem como função prover a capacidade de ajustar o modelo.

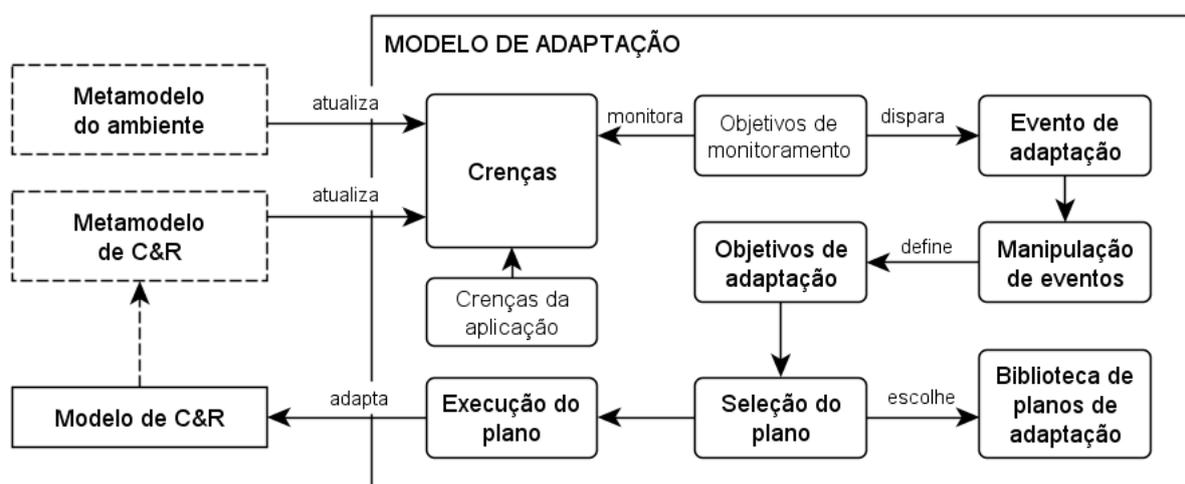


Figura 4.17: Modelo de adaptação proposto

O modelo de adaptação, mostrado na Figura 4.17, segue o modelo BDI apresentado na Seção 2.4. As crenças representam fatos sobre o ambiente e sobre a C&R, como representados pelos respectivos metamodelos. O Código 4.1 apresenta três exemplos de crenças,

#### Código 4.1: Exemplos de crenças do modelo de adaptação

```
custoOperacional(10, hora).  
credibilidade(fonte, 0.75).  
tomadaDeDecisao(marsh_ct).
```

---

definidos na linguagem AgentSpeak. Essa linguagem, apresentada na Seção 2.4.2, é utilizada nesta seção para especificar as crenças, desejos e intenções utilizados no modelo. O primeiro exemplo ilustra um aspecto do ambiente, o custo operacional. O segundo exemplifica um elemento do metamodelo de C&R, indicando a credibilidade de uma fonte de informação. Já o terceiro ilustra a configuração do componente de tomada de decisão apresentado no metamodelo da confiança, indicando o uso do limiar de cooperação definido no modelo de Marsh (*marsh\_ct*). O Apêndice C apresenta uma relação das crenças derivadas do metamodelo de C&R.

Dois tipo de objetivos são definidos para expressar os desejos dos agentes: objetivos de monitoramento ( $G_M$ ) e objetivos de adaptação ( $G_A$ ). Os objetivos de monitoramento estão relacionados à detecção de mudanças que sinalizem a necessidade de ajustar o modelo de C&R em uso. Eles são definidos a partir das crenças obtidas dos metamodelos e da aplicação. Um objetivo  $g \in G_M$ , portanto, é definido pela Expressão 4.8, em que  $Env'$  e  $m'$  são um subconjunto dos aspectos ambientais e dos componentes do metamodelo de C&R referenciados na declaração do objetivo  $\langle decl \rangle$ .

$$g = \{Env' \subseteq Env, m' \subseteq m_{meta}, \langle decl \rangle\} \quad (4.8)$$

#### Código 4.2: Exemplos de objetivos de monitoramento do modelo de adaptação

```
?custoOperacionalAbaixoDe(0.5, utilidadeObtida).  
?credibilidadeAcimaDe(reputacaoCertificada, 0.9).  
?disponibilidadeMinima(parceiro, 0.25).
```

---

A declaração do objetivo  $\langle decl \rangle$  depende da lógica utilizada pelo agente. No nível de implementação, depende da plataforma do agente e do seu raciocinador. Exemplos de objetivos de monitoramento definidos em AgentSpeak são apresentados no Código 4.2. Na primeira linha, o agente testa se o custo operacional está abaixo de 50% da utilidade obtida no último intervalo de tempo. Na segunda, o agente testa se a credibilidade de um determinado tipo de fonte de informação (ex.: reputação certificada) está acima de 90%. Em terceiro, ele verifica se um parceiro esteve disponível em pelo menos 25% das oportunidades passadas. Quando uma dessas condições falha, um evento de adaptação, definido na

Expressão 4.9 é gerado.

$$evt = \{t, g \in G_M, env_t\} \quad (4.9)$$

O evento  $evt$  especifica o tempo ( $t$ ) em que o evento ocorreu, o objetivo que o disparou ( $g \in G_M$ ) e as condições do ambiente naquele momento ( $env_t$ ). Múltiplos eventos podem ser gerados em um dado intervalo de tempo. O Processo de Manipulação de Eventos (PME) é responsável por analisar a fila de eventos e definir os objetivos de adaptação. Isso inclui a eliminação de objetivos conflitantes e a fusão de objetivos duplicados. Por exemplo, considere um objetivo  $g$  que monitore se o custo de comunicação está abaixo de uma certa porcentagem (ex.: 5%) da utilidade obtida no último intervalo de tempo. Se esse custo cruzar o limite definido, um evento  $evt_1 = \{t_1, g, env_{t_1}\}$  será gerado. Então, o PME gera um objetivo candidato  $g'$  para reduzir o custo de comunicação novamente abaixo do limite definido. Suponha agora que um segundo evento  $evt_2 = \{t_2, g, env_{t_2}\}$  seja disparado posteriormente pelo mesmo objetivo após outro aumento no custo de comunicação. Uma vez que o mesmo objetivo candidato é gerado, o PME pode unir os objetivos.

Dependendo da frequência com que o PME seja executado, alguns objetivos podem ser alcançados devido a própria dinâmica do ambiente. Nesse exemplo, se o custo de comunicação retornar para um nível abaixo do limite estabelecido, o objetivo  $g'$  seria alcançado sem a necessidade de adaptação. Após analisar os eventos pendentes, o PME define os objetivos de adaptação ( $G_A$ ) com os quais o agente irá se comprometer. Esses objetivos são definidos de forma análoga à Expressão 4.8.

Com os objetivos de adaptação definidos, o Processo de Seleção de Planos (PSP) avalia a biblioteca de planos de adaptação ( $P$ ). Um plano  $p \in P$  é definido pela Expressão 4.10, em que  $\langle precond \rangle$  especifica um conjunto de pré-condições exigidas pelo plano,  $\langle corpo \rangle$  é a declaração do corpo do plano e a função  $f$  que avalia a utilidade do plano segundo a união dos subconjuntos relevantes de crenças relativas ao ambiente e à C&R.

$$p = \{\langle precond \rangle, \langle corpo \rangle, f : Env' \cup m' \rightarrow \mathbb{R}\} \quad (4.10)$$

Uma vez que mais de um plano pode ser adequado à mesma situação, o PSP constrói uma lista de planos candidatos ( $P' \subseteq P$ ), que pode ser usada para alcançar esses objetivos. No exemplo anterior, para alcançar o objetivo de reduzir o percentual do custo de comunicação, um plano válido seria reduzir o número de fontes utilizadas para obter informações de reputação. Outro plano seria a introdução de uma viés para privilegiar agentes mais próximos. Se mais de um plano candidato estiver disponível, o PSP escolherá o plano que tiver a maior estimativa de utilidade associada para o estado atual do sistema. O cálculo dessa utilidade depende de uma estimativa prévia ou de um processo de aprendizagem do agente, descrito na Seção 4.7.

Por fim, o Processo de Execução de Planos (PEP) implementa as adaptações no modelo concreto de C&R. O corpo do plano de adaptação pode ser dividido em duas partes: uma independente de modelo, que referencia apenas elementos do metamodelo de C&R, e uma específica, que usa funções e parâmetros do modelo concreto. Como resultado do PEP, o modelo adaptado é obtido e as crenças relacionadas são atualizados por meio do metamodelo de C&R.

## 4.6 Aplicação do metamodelo

Para aplicar o metamodelo aos modelos existentes, os parâmetros, funções, algoritmos ou crenças devem ser mapeados nos componentes do metamodelo. A Figura 4.18 mostra o mapeamento de alguns dos componentes do modelo de Marsh (1994). Uma vez que o modelo de Marsh não faz uso de reputação, os componentes associados não foram mapeados. Nesse mapeamento, a confiança básica foi considerada como um componente de inicialização, em que a confiança em um agente desconhecido é baseada na experiência com os demais agentes.

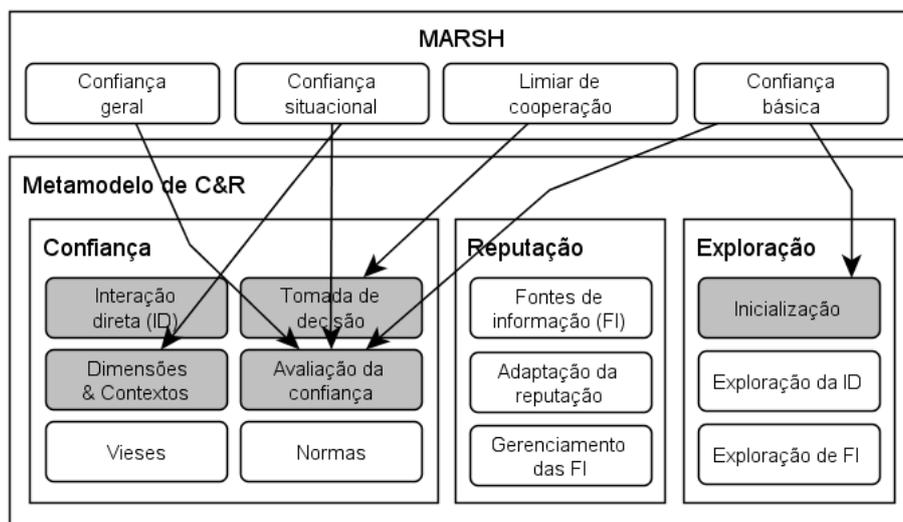


Figura 4.18: Mapeamento do modelo de Marsh no metamodelo

O mapeamento é feito definindo, para cada componente dos submodelos e fontes de informação, um conjunto de elementos relacionados. O conjunto de expressões 4.11 representa o mapeamento exibido na Figura 4.18. Cada expressão corresponde à instanciação das expressões 4.1, 4.2, 4.3 e 4.4 para o modelo de Marsh. Os componentes do modelo são identificados por suas iniciais. A fonte de informação *Interação Direta (id)*, especifica apenas a implementação do componente de memória do metamodelo, definido pelo componente

de *Extensão da memória* ( $em$ ).

$$\begin{aligned}
m_{meta}(marsh) &= \{m_{conf}(marsh), \emptyset, m_{expl}(marsh)\} \\
m_{conf}(marsh) &= \{id(marsh), \emptyset, \emptyset, \{cs\}, \{cb, cs, cg\}, \{lc\}\} \\
id(marsh) &= \{\emptyset, \{em\}, \emptyset, \emptyset, \emptyset, \emptyset\} \\
m_{expl}(marsh) &= \{\{cb\}, \emptyset, \emptyset\}
\end{aligned} \tag{4.11}$$

O mapeamento permite que o modelo de adaptação utilize somente objetivos e planos aplicáveis ao modelo de C&R em uso, já que crenças associadas aos componentes que não são implementados não estarão definidas para o raciocínio do agente. O Código 4.3 apresenta algumas das crenças, na linguagem AgentSpeak, definidas a partir do mapeamento do modelo de Marsh. As crenças informam que os modelos de confiança e de exploração são implementados e que apenas uma fonte de informação ( $id$ ) é utilizada. Para essa fonte, um componente de memória ( $em$ ) foi definido. Duas crenças associadas a  $em$  também são definidas: o tamanho da memória e sua ocupação. Note-se que não há crença definida quanto ao modelo de reputação, que não é implementado.

#### Código 4.3: Crenças relacionadas ao mapeamento de componentes

```

modeloConfianca("Marsh").
modeloExploracao("Marsh").
fontesDeInformacao([id]).
memoriaComponente(em, id).
memoriaTamanho(em, 10).
memoriaOcupacao(em, 7).

```

A Figura 4.19 mostra o caso de o modelo SPORAS (Zacharia e Maes, 2000), que utiliza apenas componentes relacionados à reputação. Note que o modelo não fornece detalhes sobre como a aquisição de informação ocorre. A figura mostra como os componentes do modelo são mapeados nos componentes das fontes de informação. O conjunto de expressões 4.12 apresenta esse mapeamento. Novamente, os componentes são identificados pelas suas iniciais na Figura 4.19.

$$\begin{aligned}
m_{meta}(sporas) &= \{\emptyset, m_{rep}(sporas), \emptyset\} \\
m_{rep}(sporas) &= \{\{fnt\}, \emptyset, \{ar\}\} \\
fnt &= \{\{fa\}, \{no\}, \{ra\}, \{dr\}, \emptyset, \emptyset\}
\end{aligned} \tag{4.12}$$

A Figura 4.20 exhibe o mapeamento de alguns componentes definidos pelo modelo FIRE (Huyh et al., 2006). O mapeamento do componente *Interação Direta* representa o fato do

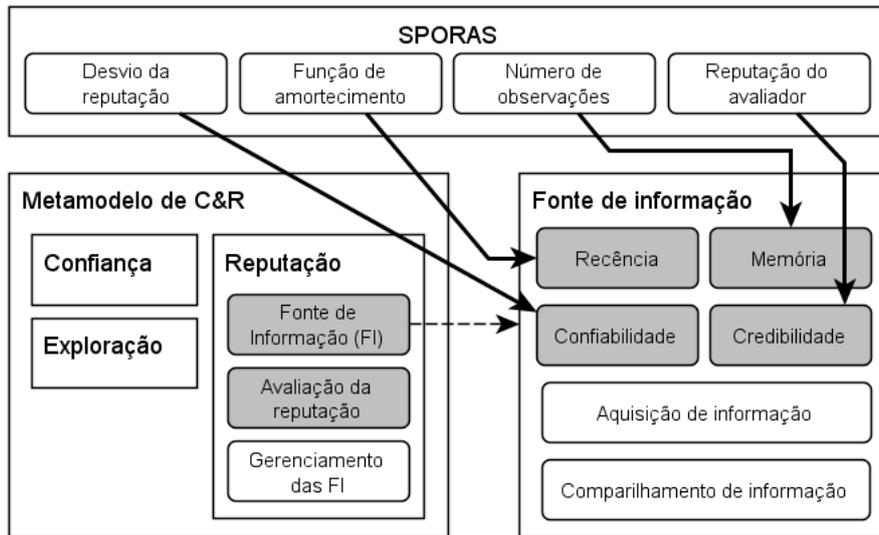


Figura 4.19: Mapeamento do modelo SPORAS no metamodelo

modelo adotar o componente do ReGreT. Notadamente, o modelo não define um componente de tomada de decisão.

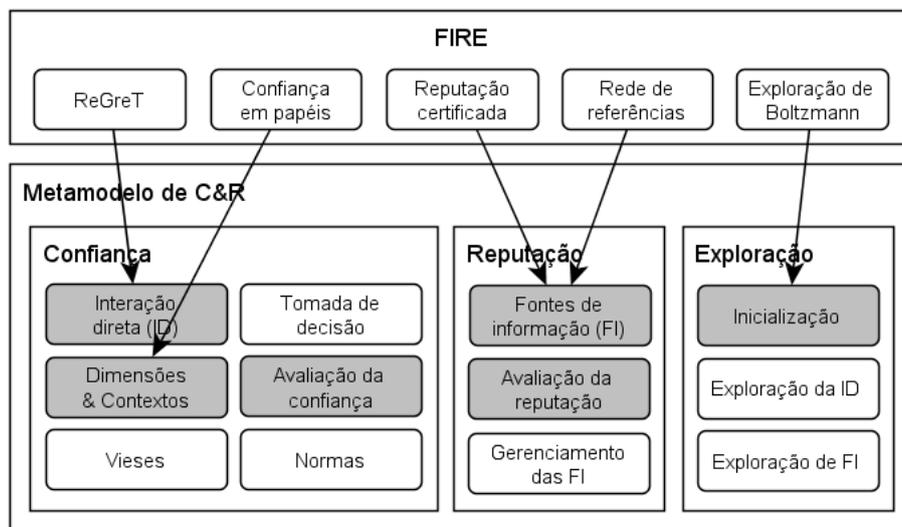


Figura 4.20: Mapeamento dos modelo FIRE no metamodelo

Esses mapeamentos demonstram que nem todo modelo implementa todos os componentes especificados. Eles também revelam que os modelos podem compartilhar elementos. Isso sugere a possibilidade de adaptação dos modelos, além de simples ajustes de parâmetros, pela substituição de componentes e implementação de características ausentes. Por exemplo, o modelo simples de inicialização do modelo de Marsh (baseado na confiança básica) poderia ser substituído por uma estratégia de exploração mais sofisticada, como a exploração de Boltzmann usada nos experimentos do modelo FIRE (Huynh et al., 2006). De forma

#### Código 4.4: Exemplos de objetivos de adaptação

```
!confiabilidadeFonteAbaixoDe(contrato, 0.5).  
!disponibilidadeParceiroAbaixoDe(agente, disponibilidadeMinima);  
!custoOperacionalAbaixoDe(custoLimite, utilidadeObtida).
```

---

similar, o componente de tomada de decisão do modelo de Marsh (o limiar de cooperação) poderia ser utilizado para complementar o FIRE, uma vez que ele não possui esse componente. Essa possibilidade é especialmente interessante para incorporar abordagens que tem foco em componentes específicos e que, portanto, não têm a intenção de definir um modelo completo de C&R, envolvendo todos os aspectos enumerados na Seção 3.3: epistêmicos, pragmático-estratégicos e meméticos (Pinyol e Sabater-Mir, 2011).

### 4.6.1 Objetivos e planos

Como mencionado na Seção 4.5, os objetivos de monitoramento e adaptação são definidos utilizando os componentes dos metamodelos do ambiente e de C&R. Assim, os objetivos podem ser definidos de maneira generalizável para as instâncias concretas de cada componente do metamodelo. O Código 4.4 apresenta exemplos de objetivos de adaptação, na linguagem AgentSpeak, que ilustram essa generalização. A primeira linha apresenta um objetivo de adaptação para uma fonte de informação, *contrato*, que está com uma confiabilidade abaixo de 0,5. A segunda apresenta um objetivo relativo ao fato de a disponibilidade do *agente* estar abaixo da disponibilidade mínima estabelecida. A terceira é um objetivo associado à redução do custo operacional abaixo do custo limite estabelecido.

Embora esses componentes sejam independentes do modelo concreto e do domínio, as condições expressas nos objetivos podem variar com a aplicação. Isso porque elas dependem de aspectos como os níveis aceitáveis de desempenho (limitando os custos do modelo de C&R) e os recursos que são alocados para o processo de raciocínio do agente (o que limita a quantidade ou frequência de deliberação no modelo de adaptação). Na Listagem 4.4, isso é ilustrado pela *disponibilidadeMinima* e pelo *custoLimite*, que definem crenças da aplicação, vistas no modelo de adaptação apresentado na Figura 4.17.

Além da definição dos mapeamentos e dos objetivos, um conjunto de configurações válidas para cada componente também deve ser especificado. No caso do modelo de Marsh, o conjunto de configurações válidas incluiria o intervalo da extensão de memória, os valores do limiar de cooperação e possíveis variações dos cálculos da confiança básica e situacional. No caso do SPORAS, essas configurações poderiam incluir as funções utilizadas no modelo e o número de observações utilizado nelas. Da mesma forma, outros modelos definem

vários parâmetros, funções e algoritmos, que permitem que diferentes configurações sejam utilizadas.

A definição de configurações válidas e os mapeamentos acima mencionados permitem que o modelo de adaptação defina potenciais planos de adaptação. Formalmente, para cada elemento  $e$  contido no mapeamento, um conjunto  $Cf(e)$  de configurações seria definido. A Expressão 4.13 ilustra essa definição para o limiar de cooperação ( $lc$ ) do modelo de Marsh (1994). A especificação de configurações válidas pode ser tão simples como a definição de um intervalo numérico ou usar algoritmos específicos ( $alg_1$ ) que considerem os aspectos ambientais. O modelo ReGreT (Sabater, 2004), por exemplo, utiliza a frequência das interações para definir o que chama de nível de intimidade, usado no cálculo da credibilidade da interação direta.

$$Cf(lc) = \{0.3, 0.5, 0.7, alg_1\} \quad (4.13)$$

Posteriormente, o modelo de adaptação pode verificar se uma configuração que é mais adequada para as condições atuais está disponível e aplicá-la ao modelo de C&R. Para decidir qual plano executar e, conseqüentemente, qual configuração adotar, deve ser definido um critério de avaliação para o processo de adaptação. Esse critério é descrito na Seção 4.6.2. Os planos também podem ser definidos manualmente, considerando as especificidades de cada modelo.

#### 4.6.2 Critério de avaliação do modelo de adaptação

Para avaliar o desempenho de uma configuração do modelo  $m$  sob as condições ambientais  $env$ , o modelo de adaptação considera os custos associados a cada submodelo do metamodelo de C&R: (i) o custo associado ao modelo de confiança ( $C_{conf}$ ), (ii) o custo associado ao modelo de reputação ( $C_{rep}$ ), e (iii) o custo de exploração ( $C_{expl}$ ). Naturalmente, esses custos são resultados dos componentes individuais de cada modelo. Dois custos adicionais devem ser considerados: o custo de permanecer ocioso devido à decisão de não confiar em um dos parceiros disponíveis ( $C_{ocio}$ ) e o custo de deliberação ( $C_{del}$ ).

O custo de permanecer ocioso ( $C_{ocio}$ ) depende de vários fatores ambientais: o custo operacional, a frequência das transações e a disponibilidade de agentes confiáveis. A partir desses fatores é possível estimar o tempo que o agente ficará ocioso se nenhum parceiro adequado estiver disponível e ele decidir não buscar outras oportunidades. O custo operacional não está sob controle direto do agente. Para modificar esse custo, o agente teria de negociar seus valores ou migrar para um recurso com menor custo. Em ambos os casos, a solução não pode ser alcançada somente pela adaptação do modelo de C&R.

O custo de deliberação ( $C_{del}$ ) depende da complexidade do raciocínio do agente e da quantidade de evidências utilizadas. É o custo associado à avaliação da C&R utilizando

informações já disponíveis para cada tipo de fonte de informação. Logo, esse custo é afetado por componentes mostrados na Figura 4.3, como memória e recência, e também pelos componentes de avaliação da confiança e tomada de decisão.

O custo associado aos componentes do modelo de confiança ( $C_{conf}$ ) é baseado na perda de utilidade devido a falhas na confiança, resultado dos componentes de tomada de decisão e avaliação da confiança mostrados na Figura 4.2. Uma estimativa da perda de utilidade depende do valor da confiança (e da sua medida de confiabilidade) e da disponibilidade de agentes confiáveis. Se o processo de adaptação do modelo piorar o seu desempenho (comparado com a configuração anterior),  $C_{conf}$  será afetado.

O custo associado aos componentes do modelo de reputação  $C_{rep}$  está relacionado, principalmente, ao componente de gerenciamento das fontes de informação, que estabelece a aquisição e o compartilhamento de informações de reputação. Esses processos dependem do custo de comunicação e do custo da informação para cada fonte de informação usada pelo agente.

Por fim, o custo de exploração ( $C_{expl}$ ) indica o custo de se buscar novos parceiros e fontes de informação. O custo é calculado como a diferença entre os custos de confiança e reputação antes e durante o processo de exploração. Por exemplo, a exploração de uma nova fonte de informação aumentaria  $C_{rep}$ , uma vez que novos agentes seriam contatados e novas informações adquiridas. Da mesma maneira, a exploração da interação direta poderia resultar em um perda de utilidade por confiar em agentes desconhecidos. Por outro lado, se o processo de exploração for bem sucedido,  $C_{conf}$  pode ser positivamente afetado pela descoberta de melhores parceiros e de fontes de informação mais confiáveis. Nesse caso,  $C_{expl}$  teria um valor negativo.

A soma desses custos é utilizada para obter uma avaliação final, mostrada na Expressão 4.14. Naturalmente, esses custos devem ser medidos utilizando a implementação concreta do modelo de C&R. Por exemplo,  $C_{com}$  e  $C_{inf}$  dependem da estratégia de aquisição de informação, incluindo o número e o tipo de fontes de informação utilizadas. A minimização desses custos pode ser utilizada como guia do processo de adaptação, já que mudanças em um aspecto do modelo de C&R pode ter impacto no custo de outros.

$$eval(m, env) = (C_{conf} + C_{rep} + C_{expl}) + C_{ocio} + C_{del} \quad (4.14)$$

Apesar desses custos poderem ser minimizados, eles não podem ser completamente eliminados. Um valor menor ou igual a zero na Expressão 4.14 seria possível apenas se as seguintes condições fossem verdadeiras simultaneamente.

- $C_{ocio}$ : o custo operacional é zero e um agente confiável está sempre disponível;

- $C_{conf} + C_{del}$ : um agente complemente confiável está sempre disponível (e nenhuma deliberação é necessária para escolhê-lo);
- $C_{rep}$ : os custos de aquisição de informação são zero;
- $C_{expl}$ : nenhuma exploração é realizada, ou a exploração encontra um agente ainda melhor (e também totalmente confiável e disponível) sem ter custos nessa descoberta.

## 4.7 Aprendizagem de planos de adaptação

Os diferentes valores possíveis para cada um dos aspectos ambientais, bem como os diferentes componentes dos modelos de C&R, geram um número infinito de cenários possíveis de adaptação. Embora um plano possa ser aplicado a vários desses cenários, seu impacto pode variar de um para outro. Por isso, o agente deve aprender a selecionar os planos mais adequados para um dado cenário. O agente pode fazer a avaliação de um plano após utilizá-lo, conforme a avaliação dos custos apresentada na Seção 4.6.2, ou fazer uma estimativa desses custos em uma abordagem de aprendizagem *offline* (Zimmerman e Kambhampati, 2003).

Neste trabalho, a aprendizagem *offline* dos planos de adaptação tem como objetivo estimar o seu impacto em configurações diversas do ambiente e do modelo de C&R. A Figura 4.21 apresenta a arquitetura de aprendizagem proposta. Com base nas diferentes configurações válidas para cada modelo, discutidas na Seção 4.6.1, um conjunto de planos candidatos é elaborado para um determinado objetivo de adaptação. Com base nas crenças do ambiente e do modelo de C&R, o mecanismo de aprendizagem avalia o plano segundo o critério especificado. Essas crenças definem o conjunto de diferentes configurações para cada aspecto do ambiente e de aspectos relacionados à C&R como, por exemplo, a confiabilidade dos parceiros e das fontes de informação. Como resultado, uma estimativa da utilidade do plano em diversas configurações é obtida e utilizada na seleção de planos. Essa estimativa corresponde à função  $f : Env' \cup m' \rightarrow \mathbb{R}$ , apresentada na definição de um plano (Expressão 4.10).

É importante notar que o mecanismo de aprendizagem apresentado na Figura 4.21 é um componente abstrato que pode ser instanciado com abordagens diversas propostas na literatura, tais como aprendizagem por reforço, heurísticas e redes neurais (Russell e Norvig, 2002; Wooldridge, 2009). Isso permite que várias formas de aprendizagem para um modelo ou componente específico possam ser incorporados no modelo, uma vez que, para a deliberação do agente durante o PSP, a utilidade estimada do plano, segundo os critérios de avaliação estabelecidos, é mais importante que a forma de aprendizagem em si.

Uma das dificuldades da aprendizagem é a delimitação do número de cenários a serem testados, dado o número de variáveis envolvidas e dos seus valores possíveis. Para reduzir

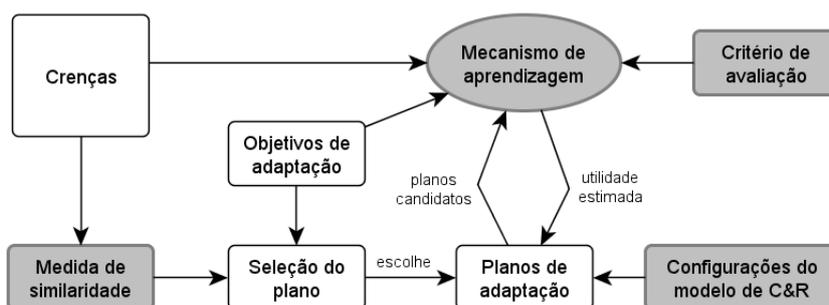


Figura 4.21: Aprendizagem de planos de adaptação

a dimensão do espaço de busca, Raja e Lesser (2007) propõem a restrição das variáveis do processo de aprendizagem a características independentes entre si, consideradas apenas em um conjunto limitado de valores. Em sua proposta, que utiliza aprendizagem por reforço para políticas de agendamento de tarefas (*scheduling*), apenas três valores são considerados para as variáveis numéricas: baixo, médio e alto.

Nesta pesquisa, para limitar o espaço de busca, alguns aspectos ambientais, enumerados na Seção 4.4, são representados em termos de outros. Por exemplo, os custos são expressos em relação à utilidade obtida pelo agente, que por sua vez é expresso em relação à utilidade ofertada no sistema. Assim, os agentes não aprendem planos para valores específicos, mas para intervalos (muito baixo, baixo, médio, alto, muito alto) da razão entre esses valores. Esses intervalos também são definidos como crenças da aplicação. A Tabela 4.3 apresenta as características do ambiente utilizadas na aprendizagem e suas dependências de outros fatores para determinar seu valor.

Tabela 4.3: Características do ambiente e suas dependências

Característica	Dependência
Custo operacional	Utilidade oferecida
Utilidade obtida	Utilidade oferecida
Custo de comunicação	Utilidade oferecida
Custo da informação	Utilidade oferecida
Frequência transações	Aplicação (tempo)
Disponibilidade de parceiros	Aplicação (população)
Disp. de fontes de informação	Aplicação (população)
Disp. da fonte específica	Aplicação (população)

No caso das crenças do modelo de C&R, como os agentes e as fontes de informação, bem como sua confiabilidade, podem variar muito, apenas valores agregados, como máximo e mínimo, são considerados no processo de aprendizagem. Assim, o tamanho da população

e a confiança em cada agente não são utilizados individualmente como entrada do processo de aprendizagem.

O mapeamento de valores reais em intervalos também depende da aplicação. Por exemplo, se duas fontes de informação estão disponíveis em um sistema, essa quantidade pode representar um valor *alto* de disponibilidade para um tipo de aplicação e *baixo* para outra. Essa correspondência é realizada na medida de similaridade, apresentada na Seção 4.7.1, que identifica a configuração atual do ambiente com base nos intervalos definidos nas crenças da aplicação. Além disso, a aprendizagem pode ser realizada considerando um subconjunto de características, de forma a reduzir a dimensionalidade do problema, mas arriscando um impacto negativo devido aos aspectos não considerados.

Embora cada característica possa ser limitada inicialmente a uma quantidade reduzida de valores, é possível refinar a aprendizagem aumentando essa quantidade. Uma faixa de valor *baixo* para credibilidade, por exemplo, poderia ser dividida em outra faixa para obter uma maior aproximação das condições da simulação para o valor real encontrado no sistema.

### 4.7.1 Medida de similaridade

Mesmo após a aprendizagem, é possível que um agente não possua uma estimativa da utilidade de um plano em um determinado cenário. Nesse caso, por meio de uma medida de similaridade, ele pode procurar por planos que foram avaliados em condições semelhantes. O conjunto de expressões 4.15 ilustra um cenário  $cen = Env' \cup m'$  definido por três aspectos: maior valor da confiança ( $max(t)$ ), confiabilidade da avaliação da reputação ( $rel(ar)$ ) e custo de comunicação ( $c_{com}$ ). O cenário  $cen_O$  representa o cenário observado atualmente no sistema. Os cenários  $cen_A$  e  $cen_B$  apresentam dois cenários aprendidos para os quais existem planos com estimativas de utilidade, mas que não são exatamente iguais a  $Cen_O$ . No caso de  $cen_A$ , a aprendizagem não considerou o aspecto  $c_{com}$ .

$$\begin{aligned}
 cen &= \{max(t), rel(ar), c_{com}\} & (4.15) \\
 cen_O &= \{alto, alto, alto\} \\
 cen_A &= \{alto, baixo, \langle ? \rangle\} \\
 cen_B &= \{baixo, alto, alto\}
 \end{aligned}$$

Elementos não definidos no cenário aprendido podem ser substituídos por outras estimativas para fins de cálculo da similaridade. Nesse caso, o valor indefinido de  $c_{com}$  em  $cen_A$  poderia ser substituído, em uma abordagem otimista, pelo valor encontrado em  $cen_O$ , o que não prejudicaria a medida de similaridade de  $cen_A$  em relação a  $cen_O$ . Da mesma forma, assumindo o pior caso, o valor mais distante de  $cen_O$  poderia ser considerado, reduzindo

ao máximo a similaridade. Considerando apenas a contagem de aspectos de igual valor, na primeira abordagem,  $cen_A$  e  $cen_B$  teriam a mesma similaridade em relação a  $cen_O$ , enquanto na segunda,  $cen_B$  teria uma similaridade maior.

Liao et al. (1998) enumeram diversas medidas de similaridade que podem ser utilizadas na comparação de dois cenários. Nesta seção é utilizada a distância euclidiana, na qual a distância  $d$  entre dois vetores  $X$  e  $Y \in \mathbb{R}^n$  é obtida pela Expressão 4.16. A Tabela 4.4 apresenta um exemplo de cálculo dessa distância entre  $X$  e outras configurações do ambiente. Todos os valores estão representados no intervalo  $[0, 1]$ . A configuração com maior similaridade em relação a  $X$  é, portanto, aquela que apresenta a menor distância  $d$  (nesse caso,  $Y_3$ ).

$$d(X, Y) = \left( \sum_{i=1}^n |x_i - y_i|^2 \right)^{1/2} \quad (4.16)$$

Tabela 4.4: Similaridade entre características de ambientes

<b>Característica</b>	<b>Vetor <math>X</math></b>	<b>Vetor <math>Y_1</math></b>	<b>Vetor <math>Y_2</math></b>	<b>Vetor <math>Y_3</math></b>
Utilidade obtida	0,10	0,50	0,60	0,11
Frequência	0,35	0,41	0,23	0,4
Custo operacional	0,70	0,90	0,90	0,66
Custo de comunicação	0,10	0,30	0,25	0,02
Custo da informação	0,02	0,05	0,00	0,01
Disponibilidade de parceiros	0,40	0,20	0,00	0,40
Disp. de fontes de informação	0,20	0,60	0,00	0,20
Distância euclidiana de $X$	–	0,667	0,726	0,103

Como os valores estão representados no mesmo intervalo, eles têm o mesmo peso no cálculo da distância. Logo, caso deseje-se dar uma ênfase maior a uma dada característica, pesos podem ser utilizados para multiplicar cada elemento do vetor, diferenciando seu impacto no resultado. Nesse exemplo, foram utilizados valores numéricos contínuos, sem a atribuição de intervalos. No caso da aplicação de intervalos, o uso de uma fórmula numérica requer a conversão dos intervalos para os valores numéricos correspondentes. Para fins do processo de aprendizagem, o uso de intervalos reduz a dimensionalidade do espaço de busca, mas, conforme o agente aprende novos cenários (seja *offline* ou durante sua execução) torna-se necessário distinguir entre dois cenários que, apesar de serem iguais em termos de intervalos, são numericamente diferentes.

## 4.8 Trabalhos correlatos

Em uma abordagem mais geral, Raja e Lesser (2007) propõem uma arquitetura para o controle em metanível. Os autores propõem uma extensão do modelo de agente (Russell e Norvig, 2002), adicionando uma camada de controle no metanível para que o agente raciocine sobre suas ações de controle tais como obter informações sobre outros agentes e o ambiente, planejamento, agendamento e coordenação. Um controlador no metanível utiliza o estado atual do agente para tomar decisões apropriadas. Os autores apontam que a complexidade do estado real do agente pode levar a um espaço de busca muito grande. Para limitar esse espaço, eles sugerem a simplificação de características, como torná-las independentes do tempo, por exemplo.

Dowling e Cahill (2001) propõem uma metamodelo de arquitetura para *software* auto-adaptável. Nesse modelo, o código de monitoramento detecta modificações nos modos de operação do sistema e dispara eventos de adaptação que indicam a necessidade de reconfigurar o sistema para um novo modo. Contratos de adaptação são usados para descrever as transformações válidas no grafo de configuração do sistema. Nesse grafo, as partes abstratas do modelo (o metanível) são preservadas durante a transformação do grafo, enquanto as instâncias concretas dos componentes são modificadas.

Com relação à generalização de modelos de C&R, Kinateder et al. (2005) apresentam um modelo chamado UniTEC, cujo objetivo é fornecer uma representação comum da confiança para uma classe de algoritmos de atualização da confiança. Os autores exemplificam como outros modelos podem ser integrados, com foco na adaptação da representação dos valores de confiança para um intervalo real  $[0, 1]$ . O modelo generaliza alguns parâmetros relacionados a memória e recência, mas não os utiliza de nenhuma forma na adaptação dos modelos. Experimentos comparando os algoritmos de atualização da confiança de vários modelos, incluindo ReGreT (Sabater, 2002) e BRS (Jøsang e Ismail, 2002), mostram como o desempenho dos modelos varia devido às condições de teste e parâmetros dos modelos.

Staab e Muller (2012) propõem MITRA, um metamodelo para o fluxo de informação em modelos de C&R. O modelo generaliza como a informação flui dentro do agente e entre agentes, dividindo o processo de modelagem da confiança em quatro partes consecutivas: observação, avaliação (das próprias observações), fusão (combinação das avaliações de C&R) e tomada de decisão. Como o modelo tem foco no fluxo de informação, ele não considera o aspecto de adaptação.

Huynh (2009) propõe uma arquitetura personalizada para avaliação de confiança (PTF, *Personalized Trust Framework*), cujo objetivo é auxiliar na escolha e adaptação de um modelo de confiança dado um conjunto de requisitos de modelagem da confiança de um domínio ou aplicação específica. Nessa proposta, um usuário humano deve especificar como

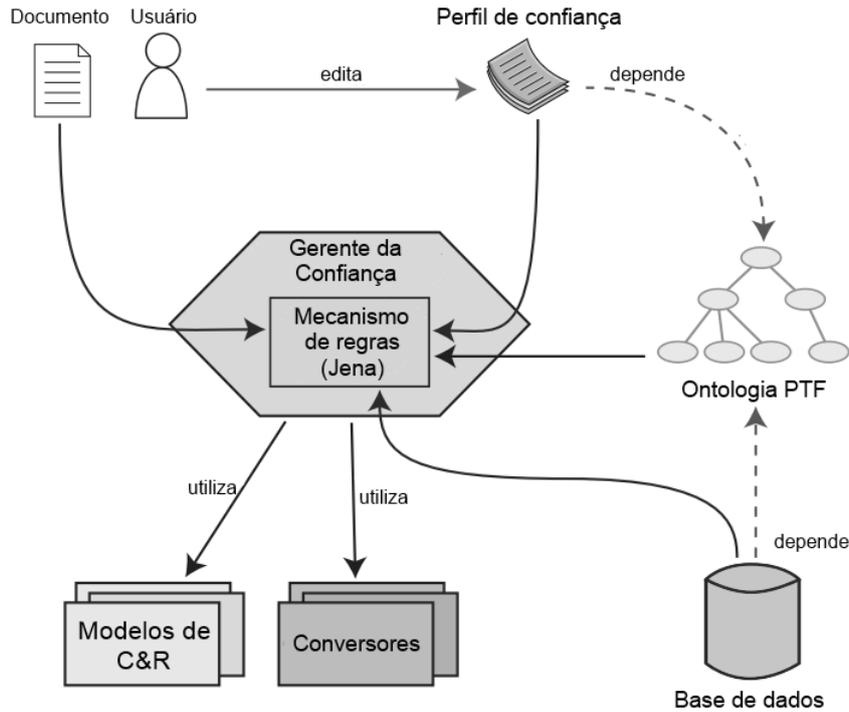


Figura 4.22: Componentes do PTF, adaptada de Huynh (2009)

ele realiza sua avaliação de confiança de um documento para que o processo possa ser replicado pelo computador. A arquitetura, então, faz o mapeamento dos aspectos do domínio considerados na avaliação da confiança para as entradas dos modelos de confiança disponíveis. A adaptação, nesse caso, refere-se, principalmente, ao uso de uma ontologia para permitir esse mapeamento e à definição de conversores do tipo de representação usado nas avaliações. A Figura 4.22 ilustra esse modelo.

Na adaptação de modelos de C&R, Fullam e Barber (2007) utilizam aprendizagem por reforço, especificamente *Q-learning*, para aprender dinamicamente a escolher entre a experiência e a reputação como fonte de informação, dependendo das condições do ambiente. A Figura 4.23 apresenta o processo de decisão do agente. A recompensa esperada pelo agente para cada situação é estimada a partir dos valores  $Q(T)$  aprendidos. Na aprendizagem, o modelo considera variações na frequência das transações, confiabilidade dos parceiros e precisão da reputação. Fullam (2007) também propõe um algoritmo de seleção de custos adaptativo, para avaliar o valor da informação de reputação e decidir qual informação adquirir. Essa proposta pode ser utilizada como uma implementação concreta do processo de adaptação para o componente de gerenciamento de fontes de informação, que decide sobre a aquisição de informações de reputação.

Koster et al. (2012) propõem uma arquitetura baseada no modelo BDI para permitir que agentes raciocinem sobre seus modelos de C&R. A arquitetura é inspirada na abordagem

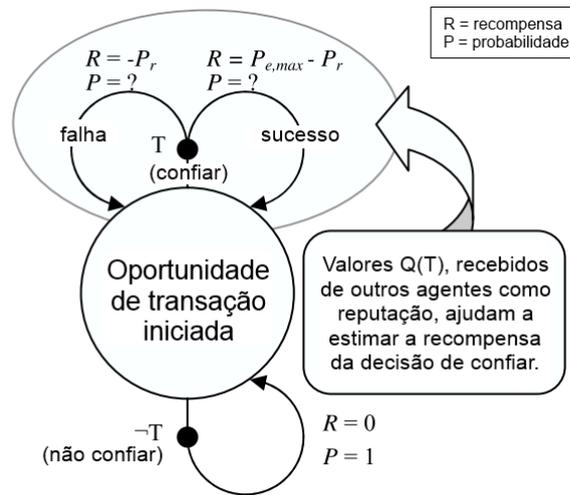


Figura 4.23: Processo de decisão da confiança, adaptada de Fullam e Barber (2007)

do modelo BDI+Repage (Pinyol e Sabater-Mir, 2009), que divide as crenças, objetivos e intenções em contextos diferentes com lógicas próprias, que são interligados por meio de regras. Apesar da aparente semelhança com a proposta deste trabalho, essa arquitetura tem foco na definição dos componentes de avaliação e tomada de decisão dentro do modelo BDI, de tal forma que um agente deliberativo possa unificar a representação das suas crenças, objetivos e intenções com o resultado de avaliações obtidas de modelos numéricos. A adaptação proposta pelos autores se limita aos aspectos de avaliação, como o peso dado às dimensões avaliadas. Logo, não são considerados aspectos de dinamicidade do ambiente ou custos envolvidos no modelo.

Neste capítulo, foram apresentados os detalhes de cada um dos componentes do meta-modelo proposto para adaptação de confiança e reputação em SMAs dinâmicos. Com a utilização dos metamodelos de C&R e do ambiente, o agente pode raciocinar sobre o uso da C&R de maneira independente de domínio e da implementação concreta do modelo de C&R. O agente utiliza um modelo de adaptação, baseado na arquitetura BDI, para monitorar a necessidade de ajustes devido à dinamicidade do ambiente. Ao identificar essa necessidade, o agente avalia os planos disponíveis para adaptar o modelo concreto utilizado. Com isso, o agente deliberativo mantém sua característica de autonomia, ao raciocinar explicitamente sobre a adaptação da C&R, em vez de contar com o grau de adaptabilidade limitado do próprio modelo, que não considera aspectos ambientais importantes que afetam a utilidade do uso de C&R em um SMA dinâmico. Por fim, um processo de aprendizagem de planos de adaptação é definido para permitir o cálculo da utilidade estimada das configurações de um modelo específico em um determinado cenário. O Apêndice A contém tabelas com o resumo dos modelos, componentes e demais elementos definidos neste capítulo.



# Capítulo 5

## Avaliação experimental

*Este capítulo apresenta a metodologia utilizada na avaliação experimental da proposta, os experimentos realizados e seus resultados.*

### 5.1 Plataforma experimental

Antes de realizar os experimentos, foram avaliadas plataformas de teste propostas na literatura para modelos diversos de C&R e para modelos específicos. Em seguida, foi definida uma plataforma experimental, baseada na simulação de um ambiente dinâmico, para permitir a avaliação do metamodelo proposto, apresentado no Capítulo 4.

#### 5.1.1 Plataformas para modelos diversos

Duas plataformas de teste de modelos de C&R foram avaliadas: ART (Fullam et al., 2005) e TREET (Kerr e Cohen, 2010). A plataforma de teste ART (*Agent Reputation and Trust testbed*), descrita em Fullam et al. (2005), é a mais conhecida, tendo sido utilizada em competições entre 2006 e 2008. No entanto, ela não é mais mantida (ART, 2013).

A plataforma ART define um cenário de domínio específico e um conjunto de regras que determinam as formas de interação e comunicação entre os agentes. Segundo essas regras, agentes atuam como avaliadores de pinturas artísticas com diferentes níveis de especialidade em pinturas de várias épocas. Pagando uma taxa, um cliente gerado pela simulação solicita a avaliação de uma pintura. O agente pode gerar sua própria avaliação (chamada de opinião) ou, se não tiver a capacidade necessária, pode solicitar opiniões de outros agentes, pagando um custo fixo. Agentes com avaliações mais precisas recebem um maior número de clientes nas iterações futuras e, portanto, obtêm maior lucro com as taxas pagas. O agente vencedor é o que tiver o maior saldo ao final do jogo. A Figura 5.1 apresenta os protocolos de interação da plataforma.

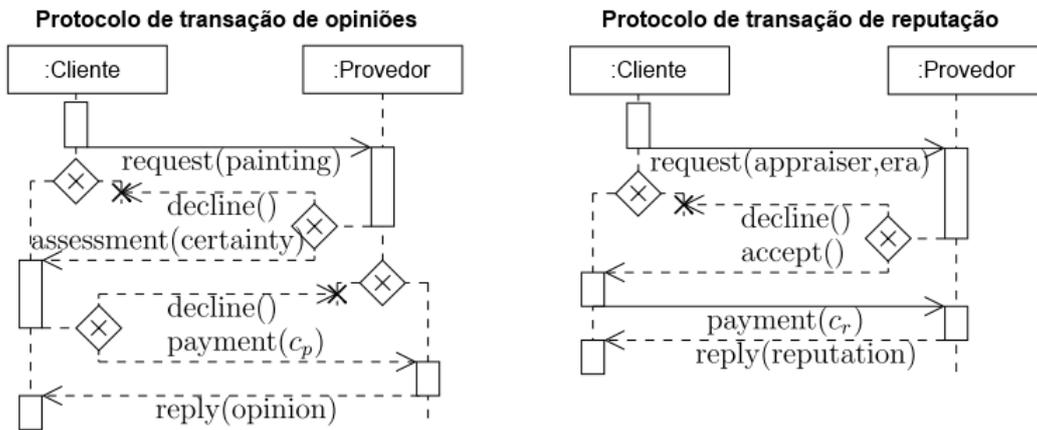


Figura 5.1: Protocolos de interação da plataforma de avaliação ART, adaptada de Fullam et al. (2005)

As especialidades dos agentes são geradas com base em uma distribuição normal do erro entre a avaliação correta (conhecida apenas pelo simulador) e a opinião do agente. Depois disso, as especialidades são distribuídas uniformemente entre os agentes. Um fator de precisão da opinião relaciona o custo que o agente teve para avaliar uma pintura e a precisão da avaliação. Assim, se o agente gasta mais tempo em uma avaliação, a precisão dela aumenta até o limite da especialidade do agente naquele tipo de pintura.

Se o agente requisitar a opinião de outros, a avaliação final será a média ponderada dessas opiniões, na qual o peso é definido pela confiança que o agente tem nos outros. Posteriormente, o agente recebe o resultado da avaliação real da pintura e pode usar a diferença da avaliação calculada para atualizar os seus valores de confiança.

O agente que recebe um pedido de opinião de outro, tem que pesar o custo de avaliar a pintura, seu impacto na precisão da avaliação e o valor que será recebido pela opinião. Por fim, por um determinado custo, um agente pode pedir informações sobre a reputação de outro, que não precisam ser, necessariamente, verdadeiras ou precisas. A Figura 5.1 apresenta os protocolos de interação da plataforma para transação de opiniões e reputação.

Inicialmente, todos os agentes avaliadores começam com o mesmo número de clientes. Posteriormente, um fator é utilizado para calcular quantos clientes o agente terá na rodada seguinte, com base no seu desempenho e no número de clientes da rodada anterior. Na competição de 2007, quinze agentes simulados, além dos cinco competidores, foram incluídos no jogo, sendo cinco trapaceiros, cinco neutros e cinco honestos. A Tabela 5.1 apresenta os parâmetros da competição de 2007 da plataforma ART (Fullam, 2007).

Kerr e Cohen (2010) apontam várias limitações da plataforma ART, como a rigidez da plataforma, seu domínio restrito e a impossibilidade de testar vulnerabilidade nos modelos

Tabela 5.1: Parâmetros da competição de 2007 da plataforma ART (Fullam, 2007)

<b>Parâmetro</b>	<b>Valor</b>
Número médio de clientes por agente	20
Número de iterações por jogo	200
Número de competidores por jogo	5
Fator de precisão da opinião	0,5
Influência do número de clientes	0,1
Taxa do cliente	100
Custo da opinião	10
Custo da reputação	0,1

de reputação. Para esse fim, eles propõem a plataforma TREET (*Trust and Reputation Experimentation and Evaluation Testbed*), com foco nas vulnerabilidades de segurança em sistema de C&R para mercados eletrônicos. A Figura 5.2 apresenta a arquitetura de simulação da plataforma TREET.

A simulação ocorre em um modelo de mercado, no qual entidades compradoras e vendedoras têm uma ou mais contas. O resultado das interações entre compradores e vendedores no mercado afetam essas contas positiva ou negativamente e, também, tem reflexo na C&R representada pelos modelos em utilização. Adicionalmente, a entidade do mercado pode definir um sistema de C&R que regule as interações entre ambas as partes.

O objetivo principal da proposta é observar vulnerabilidades nos modelos de C&R, tais como a exploração da boa reputação (na qual um agente constrói uma boa reputação em transações menores para aplicar um golpe em uma transação maior) e atraso da reputação (no qual um agente realiza vários golpes enquanto sua reputação não é afetada pelo atraso na propagação entre os agentes).

Após avaliar as duas plataformas, observa-se que nenhuma delas considera a dinamicidade dos aspectos ambientais e os custos envolvidos na avaliação dos modelos de C&R. A plataforma TREET não possui versão pública disponível que permitisse avaliar uma possível introdução desses elementos. No caso da plataforma ART, os custos e o número de clientes fixos levam a um cenário quase estático, que não é compatível com a dinamicidade de SMAs abertos, em que novos competidores podem entrar a qualquer momento e o número de clientes e os custos são variáveis. Apesar de o código da plataforma estar disponível, ainda que sem manutenção há vários anos, o código-fonte dos agentes participantes das competições não está. Assim, mesmo que a plataforma fosse alterada para incluir os fatores de dinamicidade necessários, os agentes não seriam mais compatíveis, nem poderiam ser alterados.

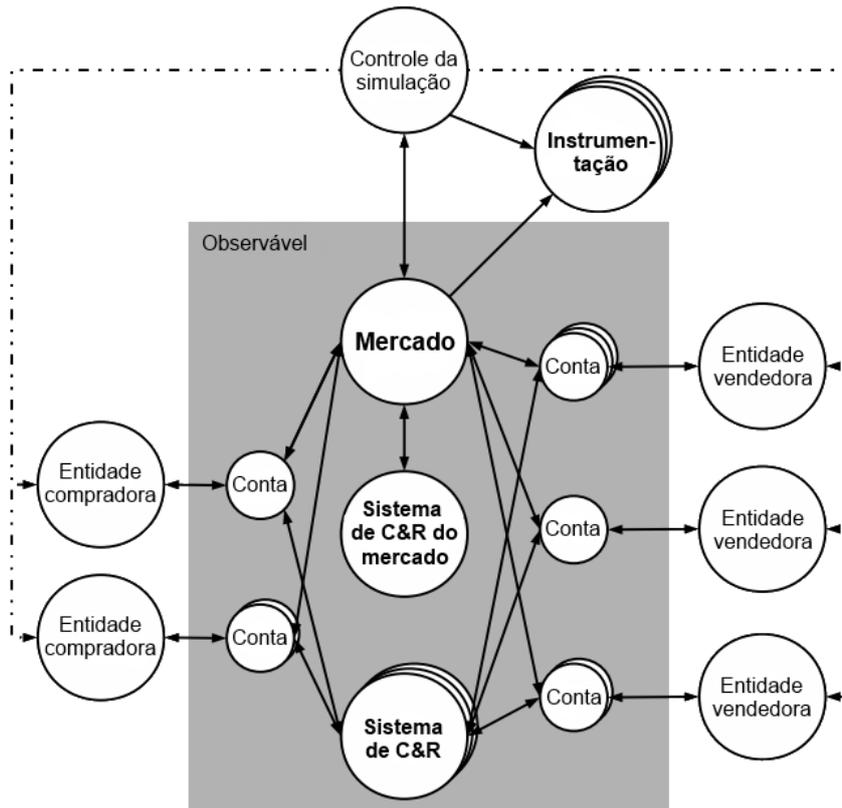


Figura 5.2: Arquitetura de simulação da plataforma TREET, adaptada de Kerr e Cohen (2010)

### 5.1.2 Plataformas para modelos específicos

Nos experimentos de Sabater (2002) e Huynh (2006), duas plataformas de teste são propostas em domínios distintos. Sabater (2002) propõe um domínio de produtores (fornecedores) e fabricantes, ilustrado na Figura 5.3. Nele, agentes produtores ( $P$ ) recebem matéria-prima para gerar componentes que serão vendidos aos fabricantes ( $M$ ). No passo 3, fabricantes se encontram para trocar informações sobre os produtores. No passo 4, agentes dos dois tipos negociam a compra dos produtos. Nos passos seguintes, é a vez de os fabricantes gerarem seus produtos (passo 5) e os venderem ao consumidor final (passo 6).

O foco dos testes de Sabater (2002) é no papel do fabricante. Por isso, os produtores são sempre capazes de atender à demanda do fabricante, ou seja, não há limitação à disponibilidade dos produtores. Há cinco tipos de produtores: bom, neutro, mau, benevolente ou trapaceiro. O neutro sempre entrega os produtos conforme o negociado (em termos de preço e qualidade). O bom e o benevolente, em 30% dos casos, favorecem o fabricante, melhorando as condições negociadas (reduzindo o preço e/ou aumentando a qualidade). O mau e o trapaceiro, em 75% dos casos, prejudicam o fabricante, piorando as condições (aumentando o preço e/ou reduzindo a qualidade).

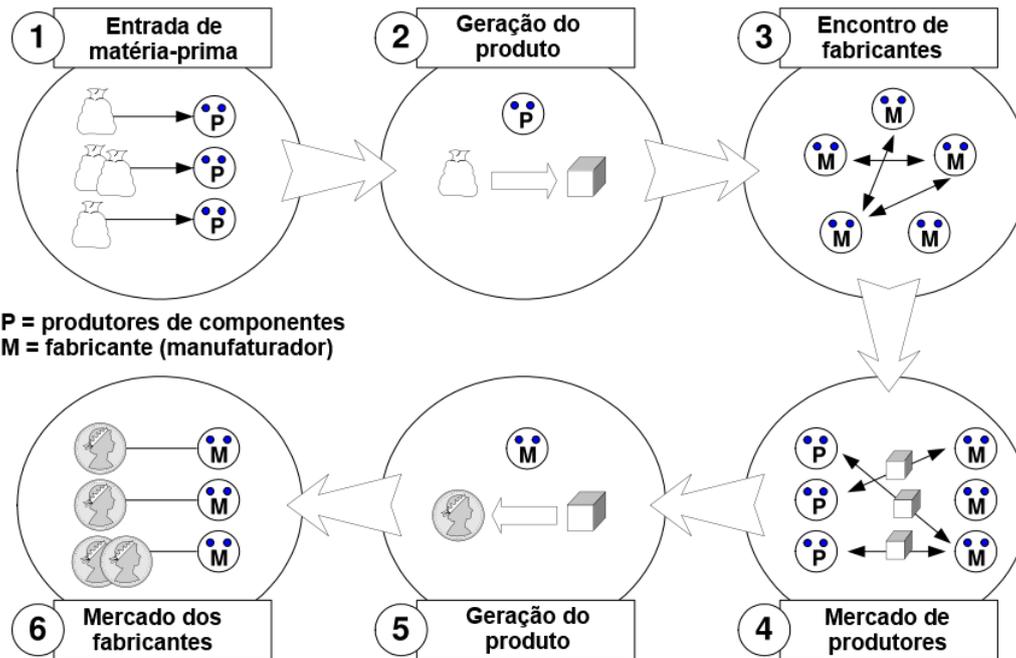


Figura 5.3: Cenário de teste do modelo ReGreT, adaptada de Sabater (2002)

Nesse cenário, os experimentos comparam quatro tipos de agente: o que sempre negocia com os produtores, o que utiliza apenas a confiança na interação direta, o que considera a interação direta e a informação de testemunhas e os que mentem para outros fabricantes quando perguntados sobre a reputação de um produtor. Cabe observar que os três primeiros tipos são testados apenas na ausência do quarto.

Os experimentos de Sabater (2002) são realizados em 50 rodadas – 30 de preparação do mercado e 20 de observação. Na fase de preparação, os agentes usam apenas a interação direta aleatória, sendo que o desempenho nessa fase de inicialização não é considerado. São utilizados 16 produtores e 64 agentes fabricantes, dos quais 10 são escolhidos para serem monitorados. Os experimentos são realizados em cinco configurações distintas da população de produtores: 100% trapaceiros; 100% maus; 50% neutros e 50% trapaceiros; 50% neutros e 50% maus; 50% neutros, 30% maus e 20% trapaceiros. Em todos os cenários, o agente fabricante que combina a interação direta e a informação de testemunhas alcança os melhores resultados em termos de lucro durante as rodadas monitoradas.

Huynh (2006) propõe um domínio de provedores de serviço e consumidores localizados em um mundo esférico de raio  $r = 1$ . Apenas um serviço é fornecido pelos provedores, mas o desempenho deles varia. A Figura 5.4 ilustra o cenário proposto. Cada agente tem um raio de operação  $r_o$  que define sua capacidade de interagir com os demais agentes. Os que estão dentro do raio são considerados agentes conhecidos para fins de obtenção de informações de reputação. No caso do provedor, consumidores fora do seu raio têm a qualidade de

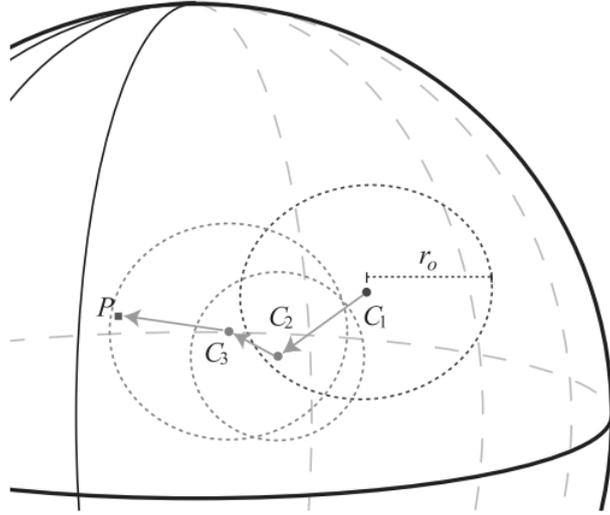


Figura 5.4: Cenário de teste do modelo FIRE, adaptada de Huynh (2006)

serviço gradualmente diminuída. Essas condições se encaixam nos aspectos de custo de comunicação e disponibilidade discutidos na Seção 4.4.

Da mesma maneira, os experimentos são conduzidos em rodadas, nos quais o número da rodada é considerado como o tempo de ocorrência de um evento. Em cada rodada, se um consumidor precisar de um serviço, ele contata o ambiente para localizar provedores próximos. A escolha do provedor depende do modelo de confiança.

O consumidor pode escolher um provedor desconhecido (a única opção inicial) ou um já conhecido. Para isso, o autor propõe uma estratégia de exploração de Boltzmann (Carmel e Markovitch, 1999), definida na Expressão 5.1. Nela, a probabilidade  $Pr$  de o agente escolher um provedor desconhecido ( $a_i$ ) leva em conta a utilidade esperada da ação  $U_i$  e um parâmetro de temperatura  $T$ . Quanto maior for  $T$ , maior é  $Pr$ . Com o passar do tempo,  $T$  é diminuída e o agente passa a escolher um provedor conhecido. Esse é um exemplo do componente de inicialização do modelo de exploração.

$$Pr(a_i) = \frac{e^{U_i/T}}{\sum_{j=1}^n e^{U_j/T}} \quad (5.1)$$

Os provedores são diferenciados em três perfis (bom, comum, mau), cuja utilidade tem uma distribuição normal sobre uma faixa de cinco valores: perfeita, boa, adequada, ruim ou pior. A utilidade resultante de provedor bom só pode ser boa ou perfeita; do comum é adequada ou boa; e do ruim vai de pior a adequada. Os experimentos realizados em ambientes estáticos comparam agentes consumidores que utilizam o FIRE, o SPORAS ou nenhum modelo de confiança em um ambiente contendo 500 consumidores e 100 provedores

em diferentes configurações da proporção dos três perfis mencionados. Segundo Huynh (2006), “o espaço de possíveis atribuições de parâmetros é vasto e avaliar compreensivamente o FIRE nesse espaço é impossível”. Assim, apenas uma configuração fixa do modelo é utilizada nos testes.

Os modelos também são comparados em um ambiente dinâmico, cujos fatores de dinamismo incluem mudanças na população de agentes, localização dos agentes e desempenho dos provedores. Wang e Hang (2011) criticam a intensidade do dinamismo explorado por Huynh (2006), uma vez que as mudanças introduzidas de uma rodada para outra são muito pequenas, não afetando significativamente a condição encontrada pelo agente. A população de provedores, por exemplo, muda, no máximo, 2% a cada rodada. Logo, em uma população de 100 provedores, apenas dois provedores serão modificados, o que pode não afetar de forma alguma um agente distante do local da mudança. Como esperado, o modelo FIRE, que combina diversas fontes de informação não consideradas pelo SPORAS, se sobressai na grande maioria das situações.

### 5.1.3 Plataforma proposta

Considerando as limitações das plataformas de teste avaliadas (ART e TREET) e daquelas sugeridas por Sabater (2002) e Huynh (2006), neste trabalho é proposta uma plataforma de teste para simular um ambiente multiagente dinâmico, a fim de testar e avaliar a utilização do metamodelo proposto. Vários elementos das plataformas citadas são aproveitados, com adaptações para permitir a introdução da dinamicidade e dos aspectos ambientais considerados no metamodelo.

Dessa forma, o domínio dos experimentos é baseado em uma rede de entrega de conteúdo (*Content Delivery Network* – CDN), em que cada nó da rede é controlado por um agente autônomo. Uma CDN, segundo Pathan et al. (2008), é uma coleção colaborativa de elementos de rede utilizada para realizar a entrega transparente e eficaz de conteúdo para os usuários finais. Na Internet, uma CDN é usada, comumente, para servir conteúdo estático, como imagens e vídeos, em nome do provedor de conteúdo. Ao delegar a entrega de conteúdo a um ou mais parceiros, o agente provedor visa a obter, entre outras coisas, escalabilidade e disponibilidade em um nível que está além da sua capacidade individual.

Em uma configuração multiagente, mostrada na Figura 5.5, um Agente Provedor de Conteúdo (APC) decide o que deseja delegar para um Agente Entregador de Conteúdo (AEC) para atender às requisições dos seus clientes. A habilidade do AEC de fornecer o conteúdo dentro dos parâmetros acordados de qualidade tem reflexo na avaliação de C&R. Posteriormente, o cliente avalia o AEC e fornece informação como testemunha de volta para o APC. Os protocolos básicos de interação entre os agentes são os mesmos utilizados na

plataforma ART, mostrados na Figura 5.1, mas tanto os papéis quanto a interação entre eles são diferentes.

Em contraste com os domínios citados anteriormente, nesse caso, há maior destaque na confiança na delegação, em vez da confiança na provisão. Isso porque o agente delegado (AEC) age representando o APC (e afetando sua reputação) perante o cliente. Outra diferença é a utilização de uma testemunha, o cliente, que possui um papel diferente daquele do agente que confia (no caso, o APC). Essa é uma situação comum na delegação, uma vez que a avaliação do APC sobre o AEC é diferente da avaliação do cliente. Além disso, em alguns domínios, o compartilhamento de informações entre agentes do mesmo tipo, como dois APCs, pode não ser possível. Lojas virtuais, por exemplo, não costumam compartilhar entre si informações sobre a avaliação de produtos feitas por seus clientes.

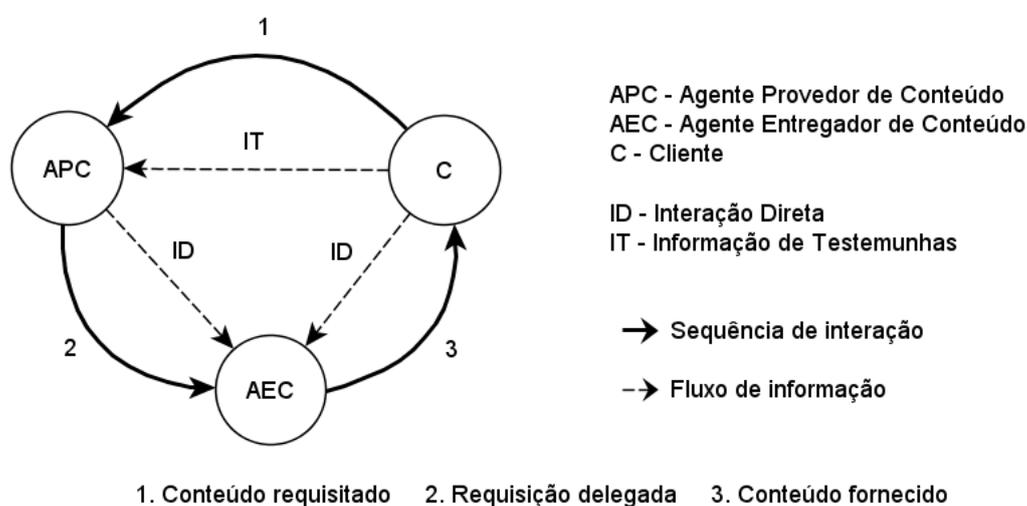


Figura 5.5: Rede de entrega de conteúdo multiagente

Como o objetivo da avaliação está na adaptabilidade do raciocínio do agente sobre o modelo de C&R, outros tipos de fontes de informação não foram definidos. Não é objetivo deste trabalho comparar as diversas fontes propostas na literatura em termos da sua confiabilidade ou mesmo do seu custo, mas demonstrar que um agente utilizando o metamodelo é capaz de raciocinar sobre as fontes disponíveis e suas características, independentemente do que a fonte represente (norma, viés, observação, etc.). Nesse caso, sem perda de generalidade, cada cliente representa uma fonte de informação dotada das características comuns às demais fontes, como proposto na Seção 4.2.1. Seguindo a mesma ideia, representações específicas de dimensões e contextos não são representadas.

Com relação ao metamodelo do ambiente, ele é instanciado para esse domínio da seguinte maneira:

- custo operacional: o agente APC paga um custo fixo por unidade de tempo para a utilização dos recursos computacionais disponíveis;
- utilidade ofertada e obtida: a visualização de conteúdo gera utilidade, que pode ser obtida pelo APC, caso o cliente seja atendido dentro dos quesitos de qualidade;
- frequência das transações: número de requisições recebidas dos clientes por unidade de tempo;
- disponibilidade dos AECs: esses agentes têm capacidade limitada e, conseqüentemente, restrições na disponibilidade para atender todas as delegações dos APCs;
- disponibilidade do cliente como testemunha: disposição do cliente em fornecer a informação da reputação de AEC;
- custo de comunicação: custo envolvido na comunicação com as testemunhas (o custo de comunicação com o AEC é descontado da utilidade obtida);
- custo da informação: custo pago ao cliente para que ele forneça informações sobre o resultado da interação com o AEC escolhido.

A Figura 5.6 ilustra a configuração e a geração do ambiente de simulação. As configurações e modelos utilizados nos experimentos são apresentados na Seção 5.3. Os critérios de avaliação são os mesmos apresentados na Seção 4.6.2 pela Expressão 4.14. Esse modelo de simulação também é utilizado na implementação do processo de aprendizagem descrito na Seção 4.7. Para gerar a população de agentes, é necessário especificar características da confiabilidade e disponibilidades dos mesmos, bem como o custo de comunicação entre eles. Nos experimentos, essas características são definidas em termos de funções de distribuição normais, com média e desvio-padrão definidos, em vez de definir percentuais de ocorrência em intervalos discretos (bom, neutro, ruim).

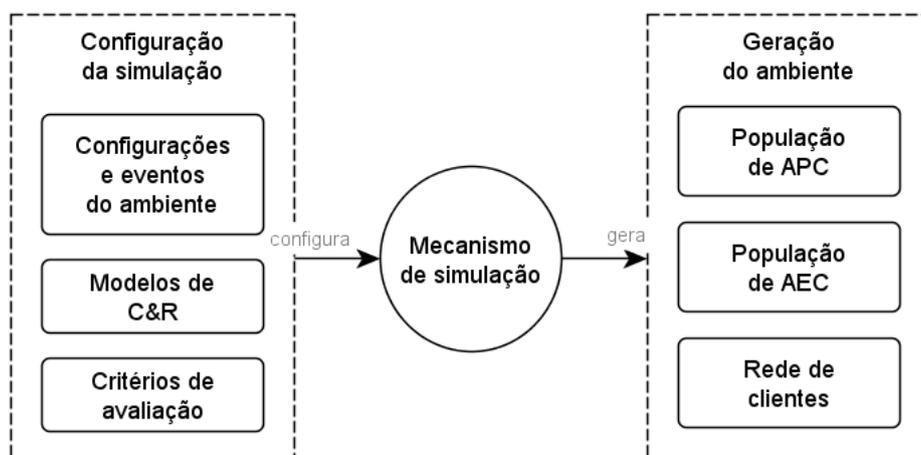


Figura 5.6: Configuração e geração do ambiente de simulação

A Figura 5.7 apresenta um diagrama de sequência UML, que ilustra a interação en-

tre o mecanismo de simulação e os agentes no sistema. Ele é similar à Figura 5.5, com o acréscimo das interações relativas ao mecanismo de simulação. O mecanismo é responsável por selecionar os clientes que farão as requisições de acordo com as configurações do ambiente. Também executa os eventos de dinamicidade que alteram aspectos do ambiente e do desempenho dos agentes. Por exemplo, tanto os clientes quanto os AECs podem ter sua confiabilidade e disponibilidade modificadas. Esse modelo de simulação é semelhante ao das plataformas apresentadas anteriormente, em que a simulação é realizada em um número discreto de rodadas, em que cada rodada contém um ciclo de interação entre os agentes do sistema

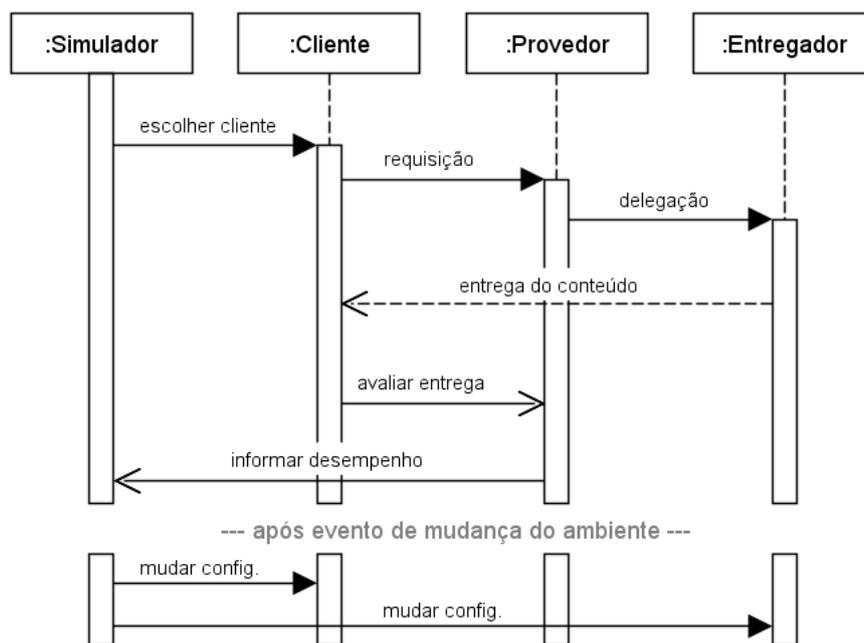


Figura 5.7: Diagrama de sequência do processo de simulação

## 5.2 Metodologia

Na avaliação experimental do modelo FIRE, Huynh (2006) utiliza simulações para avaliar o modelo sob diferentes condições e configurações. São utilizados testes de hipótese para avaliar a significância estatística dos resultados obtidos. O objetivo é comparar o desempenho de um agente utilizando o modelo FIRE com o de agentes que não utilizam um modelo de confiança ou que usam outros modelos. Nesse caso, utilizou-se o modelo SPORAS para essa comparação. A mesma abordagem é aplicada por Sabater (2002), mas sem realizar a comparação com outro modelo. Apenas uma estratégia sem uso de C&R é usada como base para comparação. O autor também não realiza a análise da significância estatística dos resultados.

Tabela 5.2: Termos utilizados no teste de hipótese, adaptada de Huynh (2006)

Termo	Descrição
$Base$	O nome do grupo de agentes utilizando o modelo base.
$Adapt$	O nome do grupo de agentes utilizando o modelo em conjunção com o metamodelo.
$n$	O número de iterações que define o período de teste.
$N_{Adapt}$	Número de agentes no grupo $Adapt$ .
$N_{Base}$	Número de agentes no grupo $Base$ .
$\mu_{Adapt}$	O desempenho médio da população $Adapt$ , obtido pela medida dos agentes do grupo após $n$ iterações e em todos os ambientes possíveis.
$\mu_{Base}$	O desempenho médio da população $Base$ , obtido de forma análoga.
$\bar{P}_{Adapt}$	O desempenho médio de uma amostra do grupo $Adapt$ após $n$ iterações.
$\bar{P}_{Base}$	O desempenho médio de uma amostra do grupo $Base$ após $n$ iterações.
$s_{Adapt}$	A variância do desempenho dessa amostra do grupo $Adapt$ .
$s_{Base}$	A variância do desempenho dessa amostra do grupo $Base$ .

É importante ressaltar que as “diferentes condições e configurações” mencionadas dizem respeito apenas aos parâmetros dos modelos e ao comportamento dos demais agentes. Os aspectos ambientais citados na Seção 4.4 não são considerados nos experimentos desses autores.

Uma vez que o foco deste trabalho está no uso adaptativo da C&R, a hipótese a verificar na avaliação experimental é se, em um dado ambiente dinâmico, um modelo de C&R adaptado com o uso do metamodelo provê maior utilidade do que o modelo original.

A Tabela 5.2 apresenta uma descrição dos termos utilizados na definição do teste de hipótese, de forma análoga ao utilizado por Huynh (2006) para o modelo FIRE.

Após a definição dos termos, o procedimento de verificação da hipótese utilizado nos experimentos é apresentado a seguir, seguindo Cohen (1995).

1. Formular a hipótese nula  $H_0 : \mu_{Adapt} = \mu_{Base}$ .
2. Formular uma hipótese alternativa  $H_1 : \mu_{Adapt} > \mu_{Base}$ .
3. Obter amostras do desempenho de agentes em ambos os grupos após  $n$  iterações, cujos tamanhos são indicados por  $N_{Adapt}$  e  $N_{Base}$ .
4. Calcular o desempenho médio de cada grupo:  $\bar{P}_{Adapt}$  e  $\bar{P}_{Base}$ .
5. Assumindo  $H_0$  como verdadeira, calcular a probabilidade de obter  $\bar{P}_{Adapt}$  e  $\bar{P}_{Base}$ .
6. Se a probabilidade for muito pequena,  $H_0$  é rejeitada.

Utilizando o mesmo critério aplicado por Huynh (2006) na avaliação do FIRE,  $H_0$  é rejeitada se a sua probabilidade for menor que 5%. Assim, é possível considerar a hipótese

alternativa  $H_1$  com um nível de confiança igual ou superior a 95%. Nesse caso, conclui-se que o desempenho do modelo adaptado, por meio do plano de adaptação utilizado, é significativamente melhor que o modelo base no cenário do experimento. É importante ressaltar essa limitação na significância do resultado, já que não é possível afirmar que um modelo, mesmo que adaptado, será sempre superior ao modelo original. Os experimentos de Huynh (2006), por exemplo, mostram momentos em que o modelo SPORAS supera o modelo FIRE, mesmo que apenas em situações específicas e temporárias.

Cabe enfatizar que o objetivo principal deste trabalho não é propor planos de adaptação, mas de permitir ao agente raciocinar sobre as possibilidades de adaptação disponíveis. Logo, se a configuração original de um modelo é a mais adequada em uma determinada situação, o agente deve ser capaz de utilizá-la para seu benefício.

### 5.2.1 Escopo da experimentação

O metamodelo proposto é formado por diversos componentes: metamodelo do ambiente, metamodelo de C&R, modelo de adaptação e mecanismo de aprendizagem. Ambos os metamodelos e seus componentes foram definidos, justificados e exemplificados com base nos elementos contidos nos diferentes modelos de C&R revisados na Seção 3.4. Portanto, durante os experimentos, sua aplicação é feita com o intuito de ilustrar seu uso associado aos modelos escolhidos para os testes. O mapeamento dos componentes do metamodelo do ambiente é apresentado na Seção 5.1.3, na descrição do domínio utilizado nos experimentos.

Com relação ao modelo de adaptação, os experimentos não têm como objetivo avaliar a qualidade dos objetivos e planos de adaptação individuais, mas de avaliar se o uso do metamodelo permite ao agente adaptar seu modelo de C&R em resposta às mudanças nas condições do ambiente e do desempenho dos demais agentes. Para isso, modelos de C&R foram selecionados para sofrer adaptações de determinados componentes associados a um subconjunto de aspectos ambientais.

Para isso, uma prova de conceito do metamodelo foi implementada em Java, utilizando Jason (Bordini et al., 2007) como interpretador da linguagem AgentSpeak, usada na definição dos elementos do modelo BDI usados no modelo de adaptação. O Apêndice B apresenta diagramas UML das interfaces utilizadas para definir o metamodelo e exemplos do seu uso.

### 5.2.2 Algoritmos genéticos

Como prova de conceito do mecanismo de aprendizagem dos planos de adaptação, este trabalho utiliza uma abordagem baseada em Algoritmos Genéticos (AG). A ideia geral de um AG é apresentado no Código 5.1 (Luke, 2013). Uma população inicial  $P$  de soluções

### Código 5.1: Algoritmo genético – adaptado de Luke (2013)

```
1 popsize ← tamanho da população
2 config ← configurações do cenário
3 P ← {}
4 enquanto  $|P| < \textit{popsize}$  faça:
5     P ← P ∪ {novo indivíduo}
6 Melhor ← □
7 repita:
8     para cada indivíduo  $P_i \in P$  faça:
9         AvaliarFitness(Pi, config)
10        se Melhor = □ ou Fitness(Pi) > Fitness(Melhor) então
11            Melhor ← Pi
12    Q ← {}
13    faça popsize/2 vezes:
14        Pai Pa ← SeleçãoComSubstituto(P)
15        Pai Pb ← SeleçãoComSubstituto(P)
16        Filhos Ca, Cb ← Cruzamento(Cópia(Pa), Cópia(Pb))
17        Q ← Q ∪ {Mutaçãõ(Ca), Mutaçãõ(Cb)}
18    P ← Q
19 até que Melhor seja a solução ideal ou o tempo tenha se esgotado
20 retorne Melhor
```

é gerada aleatoriamente. Cada indivíduo da população, chamado de cromossomo, codifica uma configuração possível para um modelo concreto de C&R. Ele é um vetor, no qual cada posição (chamada gene), possui o valor de um parâmetro. Portanto, cada cromossomo representa uma configuração do modelo, que deve ser avaliada em um dado cenário.

Neste trabalho, a linha `AvaliarFitness(Pi, config)` consiste na simulação do indivíduo *P<sub>i</sub>* no cenário especificado por *config* (que especifica o cenário dado por  $Env' \cup m'$ ). Após avaliar a adequação de cada um deles, os indivíduos são selecionados em pares para serem combinadas por meio da operação de cruzamento (*crossover*), dando origem a duas novas soluções filhas. A combinação dos genes na operação de cruzamento é feita dividindo os cromossomos pais em um ponto aleatório, tal que os genes da primeira metade de um dos pais são combinados com os genes da segunda metade do outro pai, e vice-versa.

Além da operação de cruzamento, também são realizadas duas operações sobre a população: elitismo e mutação. No elitismo, um percentual dos cromossomos com as melhores adequações é selecionado para estar presente na próxima geração. Na mutação, um cromossomo tem um dos seus genes alterados aleatoriamente, introduzindo uma chance, ainda que pequena, de que essa mudança seja benéfica. Ao final dessas operações, a nova população substitui a geração anterior. Esse processo se repete até que uma solução ideal seja obtida ou o tempo se esgote e a melhor solução até então seja considerada apta.

A implementação da prova de conceito foi feita com base na biblioteca JGAP<sup>1</sup>, utilizando

---

<sup>1</sup><http://jgap.sourceforge.net/>

a linguagem Java. A Seção 5.4 apresenta os experimentos realizados com o mecanismo de aprendizagem.

### 5.3 Experimentos de adaptação

Para realização dos experimentos, foram escolhidos três modelos: o modelo de Marsh (1994), o modelo ReGreT (Sabater, 2002) e FIRE (Huynh et al., 2006). Os três modelos definem a grande maioria dos componentes presentes no metamodelo de C&R proposto.

Em cada uma das seções subsequentes, demonstra-se como o raciocínio do agente deliberativo, utilizando o modelo BDI, é feito independentemente do modelo de C&R em utilização. Desde a percepção do ambiente e das condições de C&R no sistema até a seleção de um plano de adaptação, o agente raciocina apenas sobre elementos abstratos definidos no metanível. Os planos de adaptação, por fim, dependem dos elementos específicos do modelo de C&R.

A Tabela 5.3 apresenta um resumo dos experimentos de adaptação apresentados nesta seção. São avaliados fatores de dinamicidade diversos e o impacto sobre os componentes testados de cada modelo. Os experimentos envolvem sempre agentes provedores de conteúdo (APC), que interagem com agentes em outro papel (AEC ou cliente), seja pela interação direta ou pela troca de informação de reputação.

Tabela 5.3: Resumos dos experimentos

Exp.	Fonte	Componente	Modelo(s)	Fator de dinamicidade
1	AEC	Memória e recência	Marsh e FIRE	Confiabilidade
2	AEC	Tomada de decisão	Marsh	Custo operacional
3	AEC	Credibilidade e confiabilidade	ReGreT	Confiabilidade
4	Clientes	Aquisição de informação	FIRE	Custos de aquisição
5	Ambas	Exploração	Marsh/FIRE	Disponib./Confiab.

O Apêndice D apresenta o código utilizado para definir as crenças, objetivos e planos na linguagem AgentSpeak. Uma avaliação da significância estatística dos resultados obtidos com o uso dos planos de adaptação é apresentado no Apêndice E. Na seções seguintes, afirmações sobre resultados significativamente melhores referem-se a essa avaliação com nível de confiança igual ou superior a 95%.

#### Memória e recência

Conforme ilustrado na Figura 4.13, em uma fonte de informação, a memória é o primeiro componente a ser acionado após a aquisição de informação. O componente de memória

define a extensão das informações passadas que é utilizada na avaliação da confiança segundo a visão daquela fonte. Essa extensão pode ser delimitada, por exemplo, pelo tempo (ex.: memória dos últimos 30 dias) ou pela capacidade de armazenamento (ex.: últimas 100 transações). O modelo FIRE define um parâmetro  $H$ , chamado de tamanho da história de avaliação, que armazena as  $H$  últimas avaliações de um parceiro. Marsh (1994) utiliza o termo extensão da memória para definir o mesmo elemento.

O componente de recência define um peso diferenciado para a informação obtida dependendo do quão recente ela é. Assim como a memória, a recência de cada informação pode ser calculada com base na distância em relação ao tempo ou iteração atual. No caso do modelo de Marsh, não há nenhum componente associado à recência, assim todas as informações na memória são igualmente consideradas. No FIRE, o componente da recência é definido por um parâmetro  $\lambda$ , chamado de fator de escala da recência. O peso da recência  $w$  de uma informação  $i$  é calculado pela Expressão 5.2, onde  $\Delta t(i)$  é a distância do tempo associado a informação  $i$  do tempo atual. Segundo Huynh (2006),  $\lambda$  é escolhido manualmente para uma aplicação dependendo da escala de tempo utilizada. Por exemplo, para que uma informação perca metade do peso quando  $\Delta t(i) = n$ , utiliza-se  $\lambda = -n/\ln(0.5)$ .

$$w(i) = e^{-\frac{\Delta t(i)}{\lambda}} \quad (5.2)$$

Utilizando a plataforma de testes proposta para a realização dos experimentos, avaliou-se a aplicação dos componentes de memória e recência pelo APC, que os utiliza para determinar sua confiança em um AEC, por meio da interação direta. Como esses componentes são parte de qualquer fonte de informação do metamodelo de C&R, este experimento é generalizável para outras fontes, como a reputação dos AEC que é fornecida ao APC pelos seus clientes.

A Tabela 5.4 apresenta as configurações do Experimento 1. Na primeira parte desse experimento, quatro agentes são empregados, utilizando, respectivamente:

1. modelo de Marsh com escolha otimista, que considera a melhor avaliação disponível na memória;
2. modelo de Marsh com escolha pessimista, que considera a pior avaliação da memória;
3. modelo de Marsh com escolha realista, que considera a média das avaliações da memória e
4. modelo FIRE utilizando a média ponderada pelo fator de recência.

A Figura 5.8 apresenta os resultados obtidos pelos quatro agentes em um ambiente no qual a confiabilidade não varia. O resultado representa o custo da confiança  $C_{conf}$ , como a diferença normalizada entre a confiança representada pela memória e aquela observada na iteração. Portanto, quanto maior o valor, pior é a correspondência entre a avaliação

Tabela 5.4: Configurações do Experimento 1

Parâmetro	Valor
Número de APCs	4
Número de AECs	50
Número de iterações	2400
Tamanho da memória inicial	200
Fator de recência inicial	$\lambda = -100/\ln(0,5)$
Confiabilidade estática (média/desvio)	0,65 / 0,05
Confiabilidade dinâmica - inicial	0,90 / 0,02
Confiabilidade dinâmica - final	0,25 / 0,05

baseada na memória do agente. É possível observar que a aplicação do fator de recência do modelo FIRE obtém melhores resultados em comparação com as abordagens do modelo de Marsh. Neste último, o melhor resultado é obtido com a utilização do valor médio de confiança presente na memória.

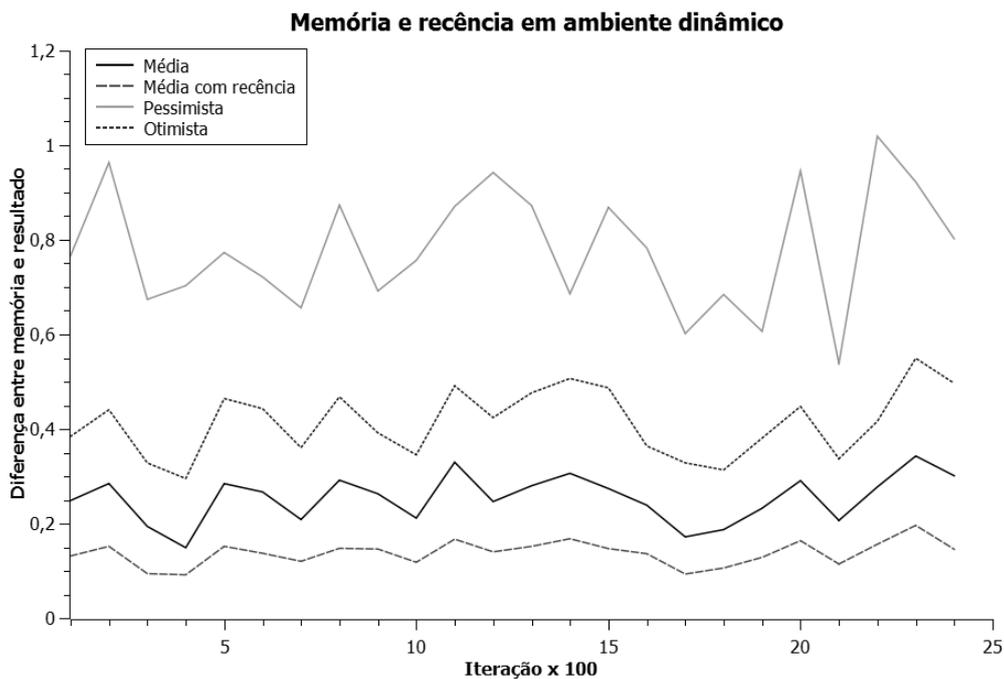


Figura 5.8: Memória e recência sem adaptação

Na segunda parte do experimento, os agentes 3 e 4 são avaliados com e sem o uso do metamodelo em um ambiente dinâmico, no qual se observa a necessidade de adaptação da memória e da recência em resposta a mudanças na confiabilidade dos AEC. Para isso, um objetivo de monitoramento é definido, no qual observa-se a variação na média da confiança

em um AEC. Se a variação for superior a 20% do valor inicial, um objetivo de adaptação é estabelecido.

Um plano de adaptação é estabelecido para cada agente. Para o agente 3, o plano faz a diminuição gradual da extensão da memória (em dez unidades) quando observa a redução da confiança no AEC. No caso do agente 4, o plano aumenta o peso recência (reduzindo  $\lambda$ ) com a diminuição da confiança. Alterações são introduzidas a cada 100 iterações, reduzindo a confiabilidade do AEC do valor inicial até atingir o valor final, além de aumentar sua variância.

A Figura 5.9 apresenta os resultados obtidos com e sem a aplicação do metamodelo e dos respectivos planos de adaptação. Os resultados foram normalizados utilizando a mesma escala da primeira parte do experimento. Portanto, pode-se observar que o ajuste da recência, utilizado pelo agente 4, foi capaz de obter resultados finais próximos aos do obtidos no ambiente estático. A melhoria, nesse caso, foi significativa em relação ao mesmo agente sem o uso da adaptação. O valor inicial do fator de recência, apresentado na Tabela 5.4, é o mesmo proposto nos experimentos do modelo FIRE realizados por Huynh (2006). Os resultados obtidos pelo agente 3 com a redução dinâmica da extensão da memória também foram significativamente melhores que sem o uso de adaptação, embora não tenham ficado tão próximos ao resultado obtido no ambiente estático.

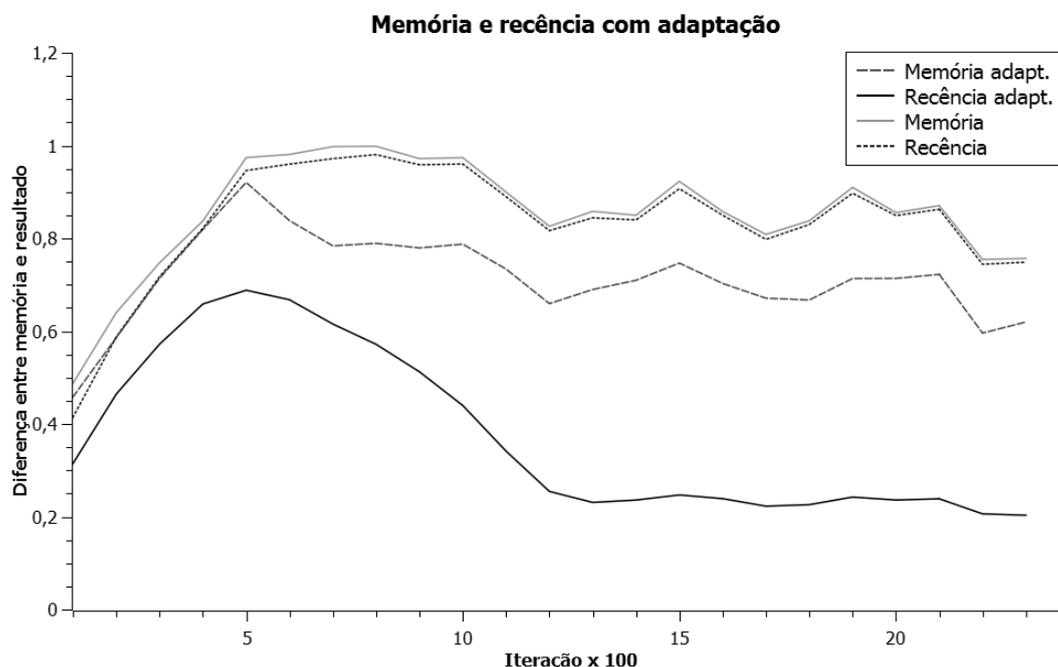


Figura 5.9: Memória e recência com adaptação

Cabe ressaltar, que o plano utilizado pelo agente 3 também pode ser utilizado pelo agente 4, sem modificações, um vez que o tamanho da memória é definido como uma crença

associada ao metamodelo de C&R e, portanto, pode ser alterada pelo plano de adaptação sem necessidade de fazer referência à implementação específica do modelo em uso. Isso demonstra a capacidade do metamodelo de generalizar o raciocínio sobre C&R além dos aspectos concretos de implementação de cada modelo. No caso do plano utilizado pelo agente 4, o fator  $\lambda$  é introduzido como uma crença específica do modelo que é utilizada apenas na execução do plano de adaptação específico para o modelo FIRE.

## Tomada de decisão

No Experimento 2, é observado como mudanças no custo operacional afetam o modelo de Marsh. Esse modelo é utilizado porque define explicitamente um componente de tomada de decisão, o que não é feito pelo ReGreT, nem pelo FIRE. O limiar de cooperação (LC) é usado para determinar se um agente irá confiar em outro. Se a confiança estiver abaixo do LC definido, a cooperação não ocorre.

Neste experimento, uma população de quatro APCs com diferentes valores de LC são utilizados. Para os parceiros em potencial (os AECs), uma população de cinquenta agentes é gerada de acordo com uma distribuição normal de disponibilidade e confiabilidade. A cada interação, os quatro agentes são apresentados ao parceiro mais confiável disponível. Cada agente então escolhe se confia nele ou não baseado no seu LC. Se o agente confiar no parceiro e a delegação for executada com sucesso, o agente ganha a utilidade da tarefa. Em caso de falha, o agente perde essa utilidade. Se o agente decidir não confiar, ele paga o custo operacional atual.

O custo operacional inicia em 1% da utilidade de uma tarefa. Após cada 5.000 interações, ele é aumentado em 10%. O custo  $C_{ocio}$  é calculado como o número de oportunidades ignoradas (em que a escolha foi não confiar) multiplicada pelo custo operacional. O custo  $C_{conf}$  é calculado como o número de delegações que resultaram em falha (entrega fora da qualidade acordada) multiplicado pela utilidade unitária da tarefa.

Uma crença da aplicação é usada para limitar o valor de  $C_{ocio}$  na aplicação a 15% da utilidade obtida. O plano de adaptação usado nesse experimento reduz gradualmente o LC para alcançar  $g_a$ , que depende do limite definido pela aplicação. A Tabela 5.5 apresenta as configurações utilizadas no Experimento 2.

A Figura 5.10 apresenta como a utilidade é reduzida cada vez que o custo operacional é aumentado (nesse caso, a cada 12000 interações). Agentes com LCs menores sofrem uma perda maior, uma vez que permanecem mais tempos ociosos.

A Figura 5.11 mostra como o uso do plano de adaptação resulta em aumento de utilidade. Mais uma vez, os agentes aumentam seu LC quando o custo operacional é aumentado e ultrapassa o limite definido. O plano tem um impacto maior em agentes com um LC

Tabela 5.5: Configurações do Experimento 2

Parâmetro	Valor
Número de APCs	4
Número de AECs	50
LC (agentes 1 a 4)	[0,90 0,85 0,75 0,60]
Utilidade unitária da tarefa	100
Limite de $C_{ocio}$ (% de $U_{obt}$ )	15%
Disponibilidade (média/desv.pad.)	0,65 / 0,05
Confiabilidade (média/desv.pad.)	0,65 / 0,05

menor, uma vez que eles têm uma intervalo maior para aumentar o LC. Como o plano afeta apenas o LC, após um certo ponto ele não pode fazer nada para melhorar a utilidade que está sendo reduzida pelo aumento do custo operacional. Por volta de 30000 iteração, os agentes tem um valor bem similar de LC.

Nesse experimento, é possível observar que os agentes com LC estático não respondem a mudanças no custo operacional e, por isso, sua utilidade é reduzida logo que o custo aumenta. Utilizando o metamodelo, os agentes raciocinam sobre o efeito da mudança do custo sobre o processo de tomada de decisão, conseqüentemente mudando seu LC. Obviamente, há um limite para o quanto os agentes podem amortizar o custo operacional com o ajuste do LC, já que um valor muito alto significa que o agente confiar em qualquer um e isso ocasiona perda de utilidade proporcional à confiabilidade média. Um ambiente com  $C_{op}$  alto e transações muito frequentes pode justificar a política de confiar deliberadamente na maioria dos agentes, uma vez que o custo da ociosidade pode não compensar a eventual perda de utilidade, que depende da confiabilidade média.

## Credibilidade e confiabilidade

No Experimento 3, o modelo ReGreT é utilizado para avaliar a adaptação a mudanças na confiabilidade de uma fonte de informação, utilizando o componente de credibilidade. Nesse modelo, a disposição de um agente de acreditar no desempenho de outro depende do nível de intimidade ( $itm$ ) entre os agentes (descrito na Seção 3.4).

Na plataforma de testes utilizada nesses experimentos, a credibilidade de um AEC perante o APC aumenta conforme o número de interações entre os dois aumenta. Logo, nesse experimento, a fonte de informação usada é a interação direta.

A Figura 5.12 apresenta o impacto do uso desse critério de intimidade sobre a escolha dos AECs. Nesse teste, um APC tem 50 AECs inicialmente desconhecidos para escolher. Após

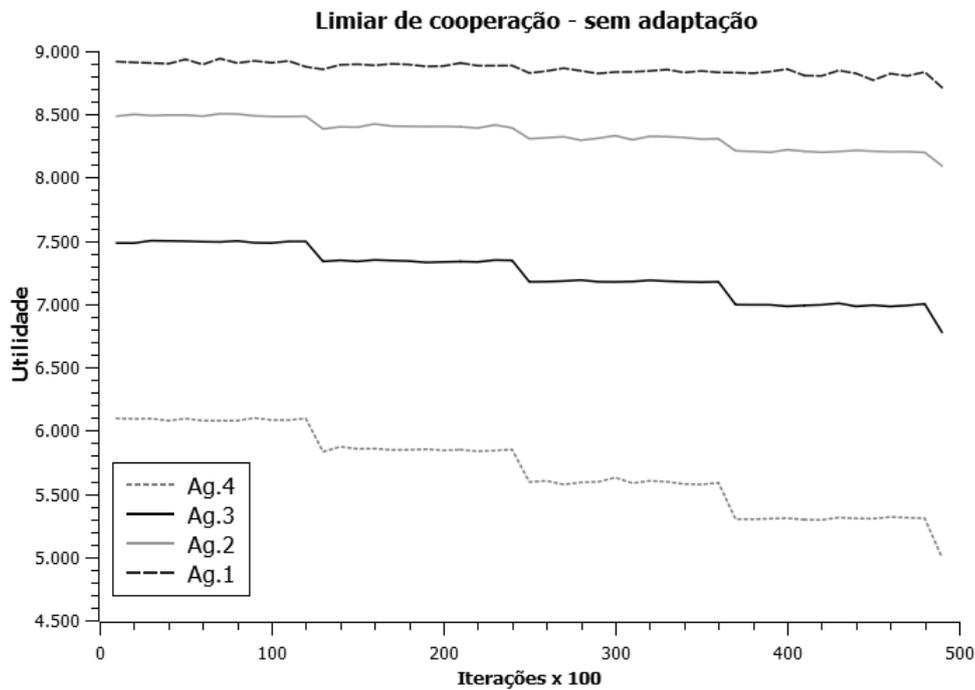


Figura 5.10: Limiar de cooperação sem adaptação

escolher um deles, o provedor pode avaliar a confiabilidade do AEC com base no resultado obtido. Sem o uso do critério da intimidade, na iteração seguinte, a chance do mesmo AEC ser escolhido novamente depende do seu desempenho anterior e do nível de credibilidade atribuído pelo APC aos AECs desconhecidos. Isso pode levar a uma concentração em um grupo limitado de AECs. Com o uso do critério de intimidade, a credibilidade de um AEC que teve apenas uma interação é um pouco maior que a credibilidade dos desconhecidos. Com isso, a chance de escolher um AEC desconhecido é maior, resultando em um grupo maior de agentes conhecidos.

A Figura 5.13 apresenta os resultados obtidos em um ambiente estático, com diferentes parâmetros de disponibilidade ( $d$ ) e confiabilidade ( $c$ ) dos agentes. Os valores de  $c$  e  $d$  são percentuais. Por exemplo,  $d = 65$  indica que o agente escolhido estará disponível 65% das vezes. O experimento é realizado em um horizonte de 5000 iterações e o valor de  $itm$  varia de 5 a 80. Os resultados normalizados mostram que os maiores valores de  $itm$  têm resultados melhores, que são afetados principalmente pela queda na confiabilidade do AEC. No entanto, o valor de  $itm$  não pode ser aumentado indefinidamente, caso contrário, a redução na intimidade entre os agentes pode afetar a diferença observada na confiabilidade. Consequentemente, um agente que já havia se estabelecido como confiável há várias iterações, tem sua credibilidade (e sua chance de ser selecionado) reduzida ao ponto de não ser mais confiável que um desconhecido. O efeito, portanto, é igual a não usar o critério da intimidade.

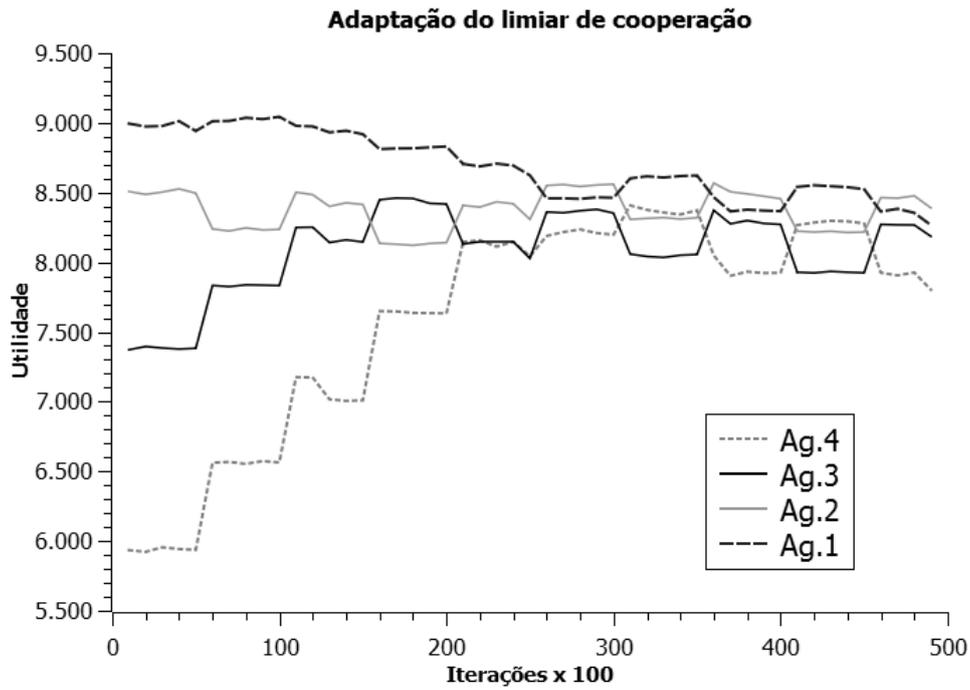


Figura 5.11: Limiar de cooperação com adaptação

A adaptação do nível de intimidade depende da confiabilidade dos agentes no ambiente da informação obtida no ambiente. Assim, se muitos agentes trapaceiros (ou incompetentes) estiverem no ambiente, o valor de *itm* deve ser aumentado. Como discutido, o limite para *itm* deve ser definido observando a existência de fontes confiáveis acima do valor mínimo de credibilidade que é usado para os agentes desconhecidos. O objetivo de monitoramento definido nesse experimento, portanto, é observar a confiabilidade do agente com maior credibilidade. Sempre que a confiabilidade do agente de maior credibilidade cair mais do que 2% desde o último intervalo, o objetivo de adaptação para ajustar o cálculo da credibilidade é gerado.

O plano de adaptação utilizado consiste em aumentar gradualmente o valor de *itm* e

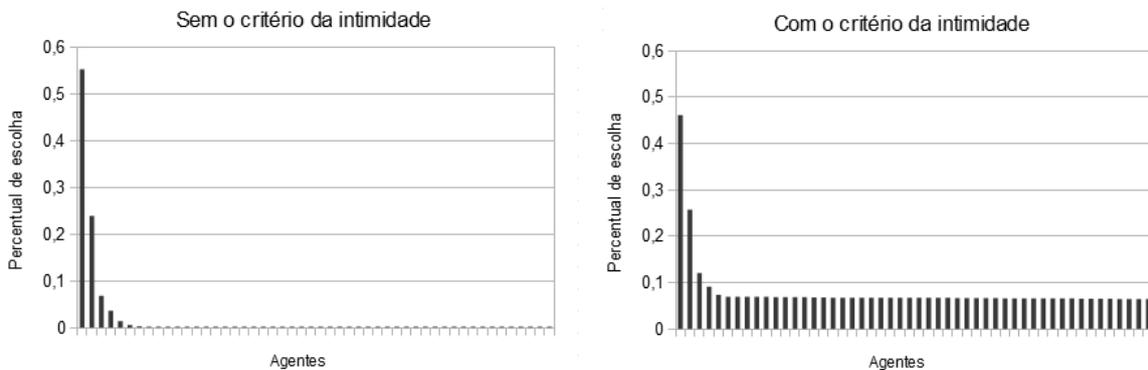


Figura 5.12: Escolha de agentes e o critério da intimidade

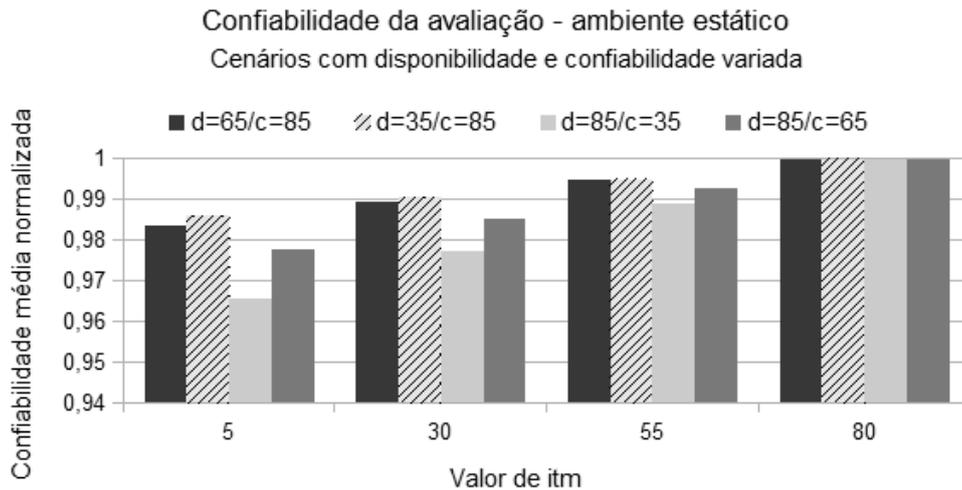


Figura 5.13: Nível de intimidade em ambientes estáticos diversos

Tabela 5.6: Configurações do Experimento 3

Parâmetro	Valor
Número de APCs	4
Número de AECs	50
Número de iterações	20.000
Confiabilidade dos AECs (média/desv.pad.)	0,90 / 0,02
Confiabilidade final	0,70
Disponibilidade dos AECs (média/desv.pad.)	0,75 / 0,05
Valor de <i>itm</i> (Ag.1/Ag.2)	25 / 80
Fator de aumento de <i>itm</i> (Ag.1/Ag.2)	25% / 15%

também reduzir a contagem de iterações para os AECs não disponíveis. Isso visa acelerar o ajuste da credibilidade, reduzindo mais rapidamente seu valor para os AECs que ficaram muito tempo sem interagir. A Tabela 5.6 apresenta as configurações utilizadas no Experimento 3. Dois agentes são avaliados com e sem o uso da adaptação. Cada um tem um valor inicial para *itm*. Após 1000 iterações (para permitir o estabelecimento dos relacionamentos entre os agentes), a confiabilidade do AEC de maior credibilidade é alterada, impactando assim, a confiabilidade da interação direta com os APCs. O processo é repetido a cada 500 iterações.

A Figura 5.14 apresenta os resultados obtidos com esse plano de adaptação. Observa-se que os agentes sem adaptação têm a confiabilidade média da interação direta reduzida ao longo do tempo. Enquanto isso, os agentes com adaptação, conseguem evitar os agentes com queda de confiabilidade e utilizar os agentes que mantiveram sua credibilidade alta. O primeiro agente, que inicia com um valor menor de *itm* tem os melhores resultados após

a adaptação, terminando com  $itm$  acima de 2000. Enquanto isso, o segundo agente inicia com  $itm$  maior, mas termina com ele perto de 1200, devido ao fator de aumento menor. Nesse caso, o plano de adaptação tem impacto sobre  $C_{conf}$ , reduzindo significativamente a perda de utilidade pelo uso de parceiros não confiáveis.

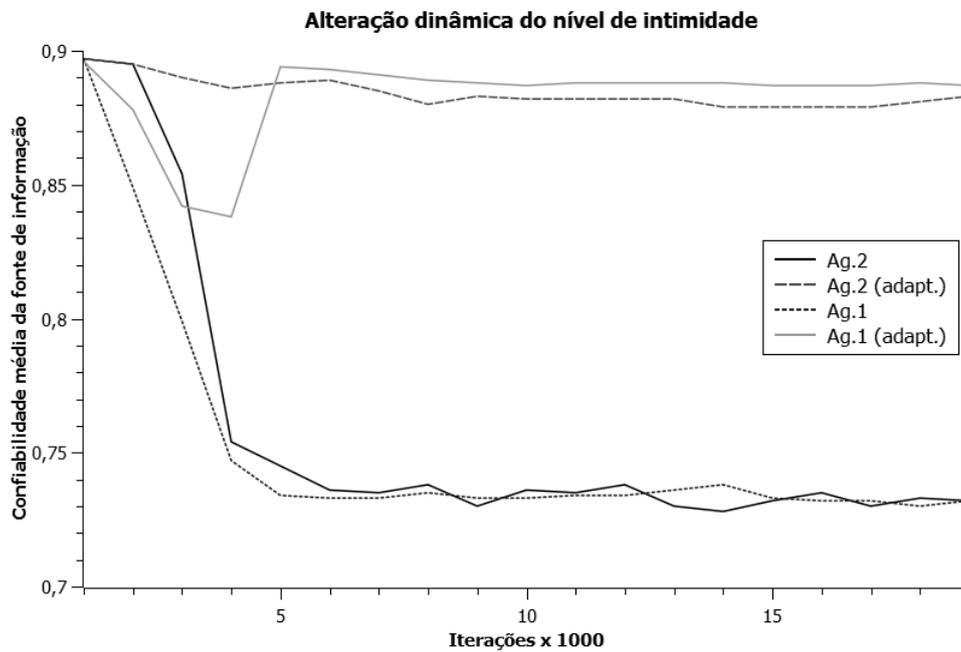


Figura 5.14: Adaptação do nível de intimidade no cálculo da credibilidade

Em ambientes mais confiáveis, o valor de  $itm$  pode ser diminuído, embora o maior ganho de utilidade, nesse caso, venha do aumento da confiabilidade dos agentes, mais do que do ajuste de  $itm$ . A mudança na frequência das transações também tem impacto sobre  $itm$ , alterando o tempo necessário para que os agentes alcancem o nível de intimidade. Nesse caso, é de se esperar que a variabilidade em transações mais próximas seja menor (por ter menos tempo para ser afetada pela dinamicidade do ambiente). Com isso, a credibilidade dos agentes seria muito parecida e esse componente perderia a capacidade de discriminar os melhores agentes dos piores. Por isso, o parâmetro  $itm$  também pode ser alterado em função da frequência de transações.

## Aquisição de informação

No Experimento 4, é observado o impacto dos custos de comunicação ( $C_{com}$ ) e custo da informação ( $C_{inf}$ ) no processo de aquisição de informação de reputação. Para isso, é utilizado o mecanismo do modelo FIRE para obtenção de informação de testemunhas. Nesse caso, trata-se da obtenção de informação desejada pelo APC sobre um determinado AEC,

por meio dos clientes que interagiram com este. De forma similar ao Experimento 2, o custos são alterados a cada 12.000 interações.

Quatro agentes com diferentes configurações de aquisição de informação são utilizados. Cinquenta agentes são utilizados como clientes, que tem disponibilidade e confiabilidade definidas por distribuições normais. A Tabela 5.7 apresenta as configuração do Experimento 4.

Tabela 5.7: Configurações do Experimento 4

<b>Parâmetros</b>	<b>Valores</b>
Número de APCs	4
Número de clientes	50
Número de iterações	480.000
Limite de comprimento das ref. (agentes 1 a 4)	[2,3,4,5]
Fator de ramificação (agentes 1 a 4)	[2,3,4,5]
Disponibilidade (média/desv.pad.)	0,65 / 0,05
Confiabilidade (média/desv.pad.)	0,65 / 0,05
$C_{rep}$ inicial (% de $U_{obt}$ )	1%
$C_{rep}$ final (% de $U_{obt}$ )	25%

O plano de adaptação usado nesse experimento, modifica dois parâmetros do processo de aquisição de informação em redes de referências: o fator de ramificação (o número de agentes contatados diretamente) e o limite de comprimento das referências (o número máximo de agentes no caminho de uma recomendação). O agente primeiro reduz o comprimento e depois reduz o fator de ramificação, reduzindo assim os custos envolvidos. A redução do número de clientes consultados só é possível se a credibilidade dos clientes restantes (ou de outra fonte de informação) for suficiente para manter uma boa confiabilidade da informação de reputação.

A Figura 5.15 mostra o resultado para o primeiro agente com e sem o uso do plano de adaptação. Após a primeira mudança no custo de informação de reputação (com 12.000 iterações), o agente utilizando o plano reduz gradualmente o número de clientes utilizado, enquanto o outro sofre com a perda de utilidade causada pelo aumento dos custos.

O custo normalizado da informação de reputação para cada agente é mostrado na Figura 5.16 em três configurações: sem adaptação, com adaptação quando o custo atinge 5% e 15% da utilidade obtida. Naturalmente, o último agente possui um custo maior, uma vez que usa mais clientes, mesmo após a adaptação. Agentes que fazem a adaptação mais cedo, quando o custo ainda é baixo (em 5%), têm um custo total da reputação menor.

Ao utilizar o metamodelo para raciocinar sobre o número de clientes utilizados no processo de aquisição de informação de reputação, os agentes foram capazes de reduzir o custo

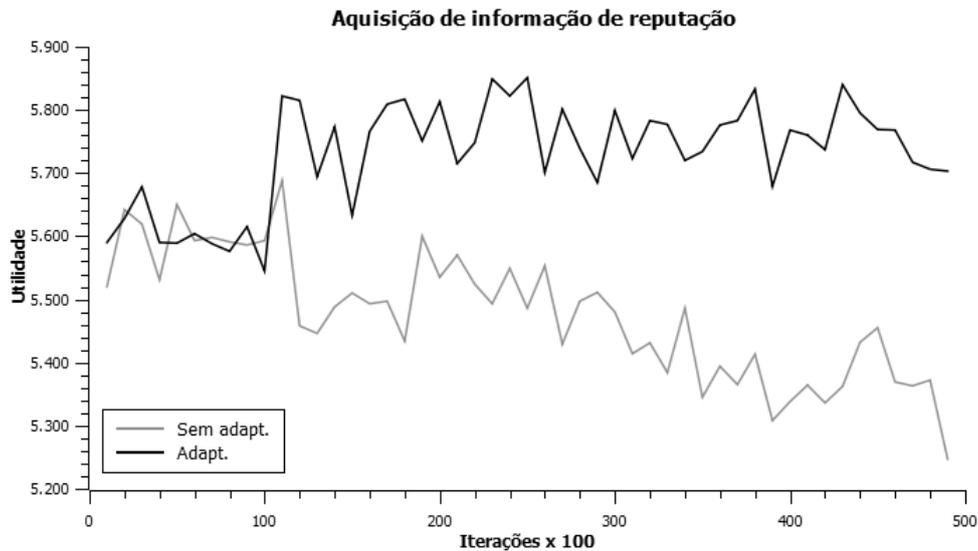


Figura 5.15: Aquisição de informação de reputação e utilidade

envolvido sem perda significativa de utilidade. O mesmo raciocínio se aplica a outras fontes de informação: deve-se avaliar se o custo de obtenção da informação não é maior do que a utilidade trazida por ela. O compartilhamento de informação pode ser avaliado e adaptado da mesma maneira, embora possa ser mais difícil avaliar o benefício concreto de compartilhar ou não informações com outros agentes. O agente pode, por exemplo, compartilhar informações para receber recursos que amortizem o custo de aquisição das informações desejadas, reduzindo o custo da reputação.

## Exploração

O Experimento 5 tem como objetivo testar componentes do modelo de exploração do metamodelo de C&R e ilustrar a possibilidade de utilização do metamodelo para estender modelos já existentes. O experimento é dividido em duas partes. Na primeira, um componente de exploração de fontes de informação é definido para o modelo FIRE. Na segunda, um componente de exploração da interação direta é definido para o modelo de Marsh.

Na implementação utilizada para o modelo FIRE, um APC escolhe um novo cliente aleatoriamente para substituir a fonte com menor credibilidade. Assim, as fontes são substituídas gradualmente, sem grandes alterações no custo de comunicação. Com isso, o agente busca melhorar a credibilidade média das fontes e, conseqüentemente, a confiabilidade da reputação fornecida pelos clientes. São utilizados quatro APCs nesse experimento, que escolhem dez clientes como fonte de informação de reputação.

Cada APC utiliza uma política de exploração diferente. O primeiro, busca suas fontes de forma aleatória e as mantém até o fim da execução. Logo, utiliza apenas o componente

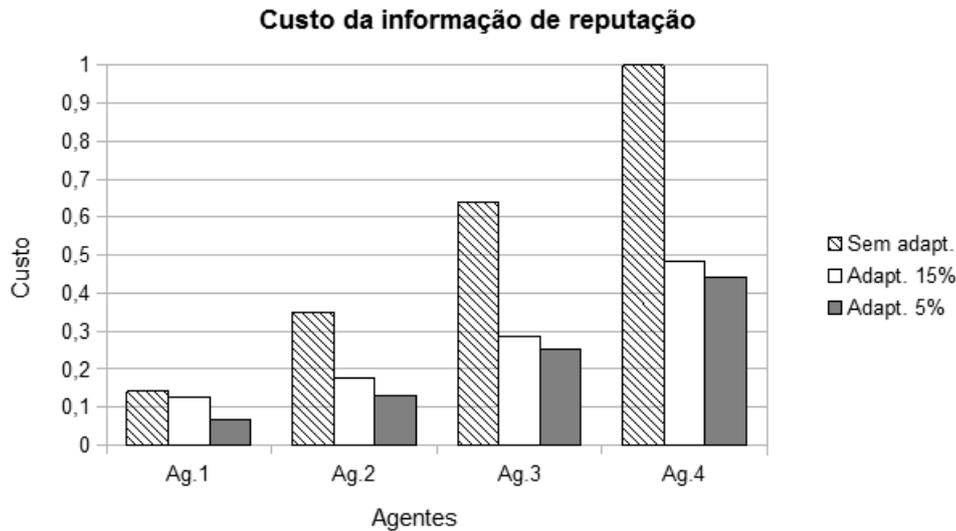


Figura 5.16: Custo da informação de reputação

de inicialização, sem adaptação, para efeitos de comparação com os demais agentes. O segundo e o terceiro consultam um novo cliente para substituir a pior fonte sempre que a confiabilidade da reputação, calculada como a diferença entre a informação dada pelo cliente e a observada posteriormente, fica abaixo de 25% e 45%, respectivamente. O quarto APC utiliza a exploração de Boltzmann para substituir suas fontes, de forma similar à utilizada na inicialização do modelo FIRE (descrita na Seção 5.1.2). Nesse caso, no entanto, a estratégia é utilizada sempre que uma alteração na credibilidade média é percebida. Quando isso acontece, o parâmetro de temperatura do algoritmo é aumentado, tal que a probabilidade de um novo cliente ser selecionado como fonte é aumentada. A temperatura é reduzida até que o agente passe a utilizar um conjunto estável de clientes.

As configurações do Experimento 5 são apresentadas na Tabela 5.8. A cada 200 iterações, a confiabilidade de um dos clientes utilizados como fonte pelos APC é reduzida gradualmente até o limite inferior estabelecido, afetando, portanto, sua credibilidade. Com isso, buscou-se garantir que o efeito da dinamicidade do ambiente afetasse diretamente o APC, em vez da abordagem utilizada por Huynh (2006), onde, entre uma observação e outra, apenas 2% de todos agentes são afetados. Wang e Hang (2011) aponta que esse nível de dinamicidade é muito pequeno. De fato, nessas condições, apenas um cliente seria afetado por vez e, possivelmente, nenhum dos APCs seria afetado, dada a probabilidade do agente não ser escolhido como fonte.

A confiabilidade dos clientes não escolhidos inicialmente permanece inalterada até que eles sejam escolhidos para substituir outro cliente. A partir daí, eles podem ser escolhidos para terem a sua confiabilidade alterada. Isso visa a permitir que os APC tenham opções de outras fontes confiáveis. Se a confiabilidade média da população de clientes for pior

Tabela 5.8: Configurações do Experimento 5a

Parâmetros	Valores
Número de APCs	4
Número de clientes	50
Confiabilidade inicial (média/desv.)	0,75 / 0,05
Confiabilidade final (média/desv)	0,20 / 0,05
Custo de comunicação	1% de $U_{obt}$
Temperatura inicial	50
Acréscimo da temperatura	30
Fator de redução da temperatura	0,95

que o limiar estabelecido pelo APC, então a probabilidade da exploração descobrir fontes melhores é baixa.

A Figura 5.17 apresenta o resultado obtido na exploração de fontes de informação para cada APC. O primeiro agente (Ag.1), que não faz a substituição das fontes, sofre com a degradação da confiabilidade, conforme demonstrado pela credibilidade média que o agente tem nas suas fontes. O segundo (Ag.2), espera a redução da credibilidade média até 25%, então não chega a realizar a exploração das fontes no intervalo do experimento. O terceiro (Ag.3), consegue substituir as fontes e manter o nível de credibilidade acima do limite estabelecido de 45%. Por fim, o quarto agente (Ag.4) obtém os melhores resultados. Sempre que a confiabilidade das fontes é reduzida, aumenta a chance de procurar uma nova fonte. Com isso, as fontes menos confiáveis são substituídas com maior frequência.

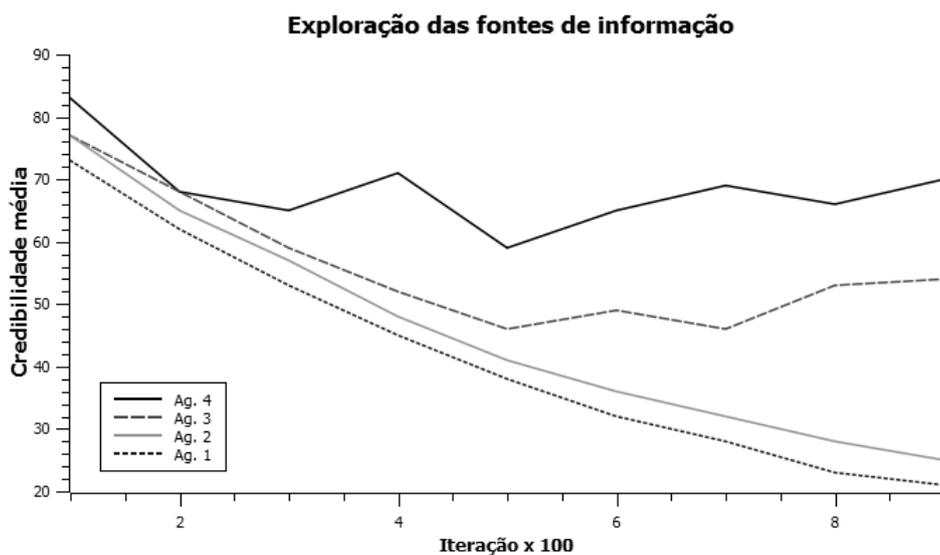


Figura 5.17: Exploração das fontes de informação

A Figura 5.18 apresenta o custo normalizado de exploração ( $C_{exp}$ ) associado a cada estratégia, em comparação com o resultado obtido pelo primeiro agente. Nesse caso, o custo é a soma da perda de utilidade resultante da baixa confiabilidade com o custo de comunicação para a troca de fontes. Em todos os casos, o custo de comunicação baixo (de 1%) afetou pouco o resultado. No caso do quarto agente, o custo de comunicação foi cerca de cinco vezes maior, uma vez que entra em contato com muito mais fontes durante o processo de exploração. Portanto, essa estratégia pode ser limitada pelos custos de comunicação. Nesse caso, um parâmetro de temperatura mais baixo pode ser usado para reduzir o número de iterações exploratórias ou um limite pode ser imposto a esse número.

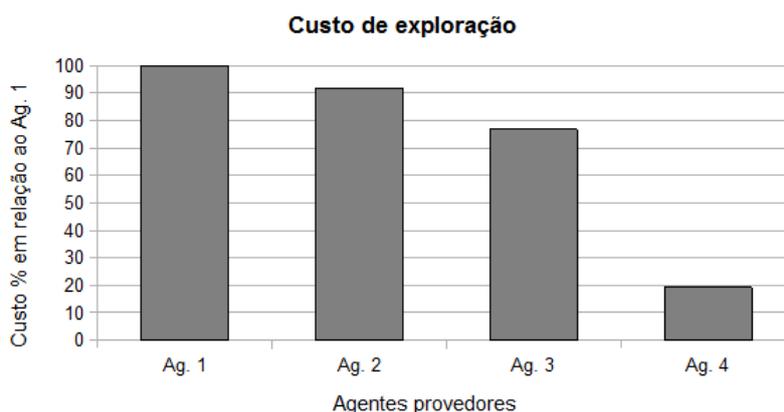


Figura 5.18: Custo da exploração

Na segunda parte do experimento, a mesma abordagem foi experimentada com o modelo de Marsh, para a exploração da interação direta. Nesse caso, no entanto, a disponibilidade dos AECs é avaliada. Assim, um APC busca um novo AEC para substituir outro que apresente baixa disponibilidade. A Tabela 5.9 apresenta as configurações do experimento.

Tabela 5.9: Configurações do Experimento 5b

Parâmetros	Valores
Número de APCs	4
Número de AECs	50
Disponibilidade inicial (média/desv.)	0,50 / 0,05
Disponibilidade final (média/desv.)	0,20 / 0,05
Temperatura inicial	50
Acréscimo da temperatura	30
Fator de redução da temperatura	0,95

A Figura 5.19 apresenta os resultados obtidos. Nesse experimento, o agente 3 obtém resultados melhores do que agente 4, que apresenta resultados próximos. O agente 2 também

obteve melhores resultados, conseguindo manter a disponibilidade média acima do limiar inferior de 25%.

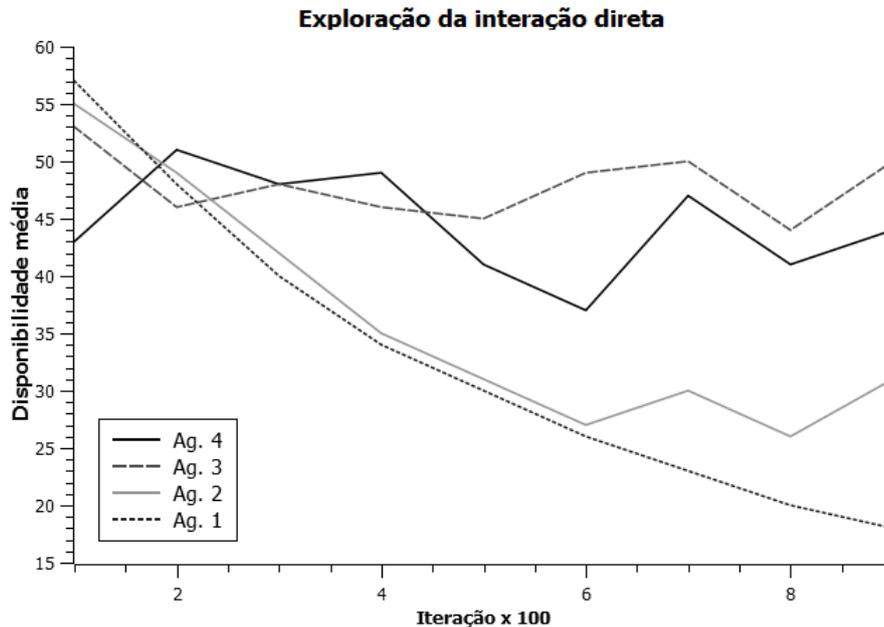


Figura 5.19: Exploração da interação direta

Os resultados demonstram a importância dos componentes de exploração em um ambiente dinâmico. Cabe ressaltar que esses componentes, embora utilizados em modelos específicos, foram definidos de forma independente de modelo. Todos os componentes utilizados na sua definição são parte dos metamodelos de C&R e do ambiente. Uma fonte de informação, seja interação direta ou informação de testemunhas, define o componente de aquisição de informação, que abstrai a forma com que os agentes a utilizam. Logo, o componente de exploração precisa definir apenas em qual situação (ex.: baixa credibilidade, baixa disponibilidade, baixa confiança, custo de comunicação alto) deseja consultar a fonte.

Nesse experimento, o modelo de adaptação não foi utilizado, mas, assim como os demais componentes do metamodelo de C&R, os componentes de exploração também estão sujeitos à necessidade de adaptação para, por exemplo, definir com mais precisão quando a exploração será realizada.

## 5.4 Experimentos de aprendizagem

Como descrito na Seção 5.2.1, a avaliação experimental do mecanismo de aprendizagem dos planos de adaptação é realizada com base em uma prova de conceito utilizando AG. Nesse caso, o processo de aprendizagem é realizado para um modelo específico, baseado em

seus componentes e parâmetros próprios. Para essa avaliação, o FIRE é utilizado, uma vez que o modelo define claramente os parâmetros dos seus componentes (Huynh, 2006). Para a utilização no AG, os parâmetros do FIRE são codificados em um cromossomo.

A Tabela 5.10 apresenta os parâmetros do modelo FIRE e o conjunto de valores utilizados no aprendizado. Os valores padrão são baseados nos parâmetros utilizados por Huynh (2006) na avaliação experimental do modelo.

Tabela 5.10: Parâmetros do modelo FIRE

<b>Parâmetro</b>	<b>Valores</b>	<b>Valor padrão</b>
Tamanho da história local de avaliações – H	(2, 20)	10
Fator de escala da recência – $\lambda$	(1, H)	H/2
Fator de ramificação	(0, 3)	2
Limiar do comprimento das referências	(1, 5)	5
Limiar de tolerância de imprecisão – $\iota$	(0, 1)	0.5
Valor padrão de credibilidade	(0, 1)	0.4

Como apontado por Huynh (2006), a grande diversidade de valores para cada parâmetro torna inviável a aprendizagem para cada valor e cenário possível. Portanto, para fins de avaliação do mecanismo de aprendizagem, a quantidade de valores possíveis para cada parâmetro, bem como para os aspectos ambientais e crenças derivadas da C&R, foi limitada. A Tabela 5.11 apresenta os valores utilizados para gerar os cenários de teste. A combinação desses valores resulta em 52.488 cenários distintos.

Tabela 5.11: Cenários de teste da aprendizagem

<b>Parâmetro</b>	<b>Valores</b>
Custo operacional	10, 35, 60
Frequência das transações	1, 2, 4
Utilidade da transação	100
Custo da info. de reputação	0, 2, 4
Custo de deliberação	0, 2, 4
Custo de comunicação	0, 2, 4
Disponibilidade dos agentes (média)	0.30, 0.55, 0.80
Confiabilidade dos AECs (média)	0.30, 0.55, 0.80
Confiabilidade dos clientes (média)	0.30, 0.55, 0.80
Desvio-padrão das médias	0.02 e 0.04

### 5.4.1 Configuração do algoritmo genético

A Tabela 5.12 apresenta a configuração utilizada no AG para aprendizagem de planos de adaptação com o modelo FIRE. Uma população de 50 cromossomos é gerada aleatoriamente com os parâmetros do modelo, dentro dos valores estabelecidos. A cada geração, a adequação (*fitness*) desses cromossomos é avaliada segundo o critério de avaliação estabelecido na Seção 4.6.2, que considera a soma dos custos envolvidos na utilização do modelo de C&R.

Tabela 5.12: Configuração do algoritmo genético

Parâmetro	Valor
Tamanho da população	50
Número máximo de gerações	100
Percentual de cruzamento	80%
Percentual de elitismo	5%
Percentual de mutação	1%
Operador de seleção	Torneio

Após avaliá-los, eles são selecionados para a operação de cruzamento, que consiste na seleção de dois cromossomos pais, e na combinação dos seus genes para gerar dois novos filhos. Como operador de seleção de cromossomos, foi utilizado o método do torneio (Luke, 2013). No cruzamento, foi utilizado um ponto aleatório para divisão dos cromossomos pais. Por fim, o operador de mutação é utilizado.

Outras configurações foram experimentadas para o AG, incluindo variações entre os percentuais iniciais e finais, com resultados significativamente próximos, apresentados no Apêndice F. Os melhores resultados foram obtidos com a configuração exibida na Tabela 5.12.

### 5.4.2 Resultados da aprendizagem

O AG foi executado em cada um dos 52488 cenários distintos gerados a partir dos parâmetros do ambiente e de C&R. Sua saída, para cada cenário, é a configuração do algoritmo FIRE, melhor avaliada na simulação do ambiente ao longo de 5000 iterações sem dinamicidade.

A saída do AG corresponde a um plano de adaptação que pode ser utilizado em uma situação similar (Seção 4.7.1). O agente deve determinar um valor mínimo de similaridade para considerar um plano, descartando assim os planos aplicáveis a cenários muito distintos do atual. Com isso o agente pode escolher um dos planos mais similares e com melhor

expectativa de utilidade (que pode variar devido às diferenças nas condições do cenário). A Figura 5.20 apresenta a quantidade média de planos similares, entre os planos aprendidos, utilizando diferentes limites inferiores de similaridade. Ela também compara as quantidades obtidas para dois cenários aleatórios, que são bem menores, não apresentando planos com mais de 90% de similaridade.

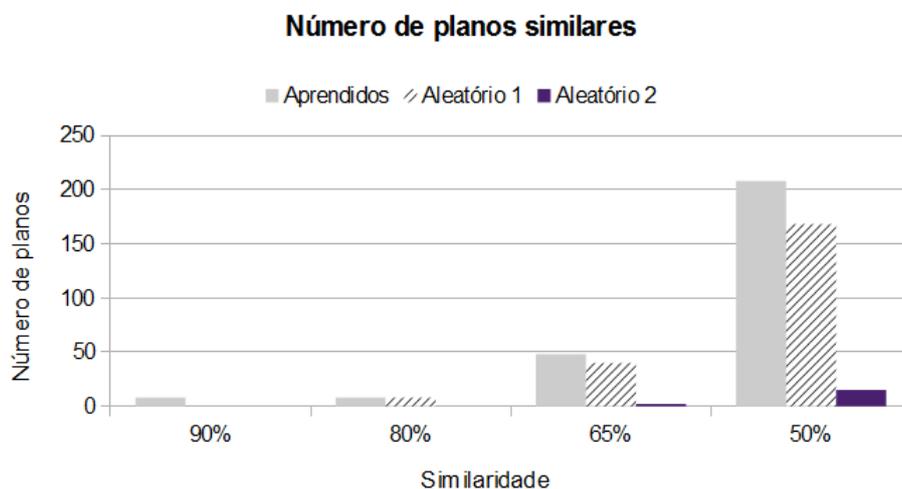


Figura 5.20: Número de planos para cenários similares

Os planos similares encontrados para os dois cenários aleatórios foram neles aplicados. Suas utilidades foram comparadas com aquela que seria obtida após a aprendizagem de planos para os dois cenários específicos. A Figura 5.21 apresenta os resultados obtidos. Nos planos com similaridade acima de 80%, a média da adequação ficou acima de 90% daquela que seria obtida com a aprendizagem do cenário específico.

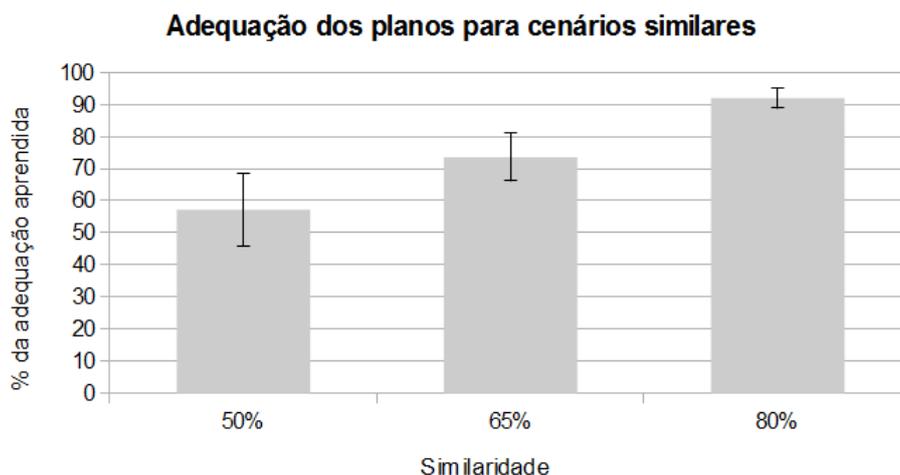


Figura 5.21: Adequação dos planos para cenários similares

Como observado, planos de adaptação de cenários similares têm desempenho próximo. Por isso, o mecanismo de aprendizagem proposto é viável, na ausência de planos específicos, especialmente devido ao grande número de cenários possíveis. Com o uso da similaridade, o agente não precisa aprender planos para a transição entre dois cenários específicos, o que levaria a um espaço de busca ainda maior. Além disso, o agente deve, durante a execução, observar a utilidade obtida pela sua configuração, de forma a aprender outros planos além dos aprendidos *offline*.

Embora a aprendizagem seja feita *offline*, a comparação de similaridade, durante a execução, para recuperação dos planos aprendidos representa um acréscimo ao custo de deliberação. Quanto maior o número de planos aprendidos, mais tempo é gasto na busca pelo plano mais similar. A limitação do custo de deliberação pode, portanto, restringir a frequência com que o agente busca esses planos. Portanto, a utilização dos planos aprendidos não dispensa completamente o uso de planos pontuais, como os utilizados nos experimentos de adaptação.

A população utilizada no AG se assemelha a uma representação simplificada de uma população de agentes, na qual cada agente possui uma configuração diferente para o seu modelo de C&R. No entanto, no AG, o “compartilhamento” de informações é feito de forma centralizada, enquanto em um SMA, isso ocorre de forma distribuída. Essa observação sugere que a mesma ideia possa ser aplicada futuramente em um SMA, por meio do compartilhamento das configurações entre os agentes. Naturalmente, as mesmas questões de confiança se aplicariam na decisão de adotar uma configuração sugerida por outro agente.



# Capítulo 6

## Conclusões

Para permitir que agentes deliberativos sejam capazes de raciocinar sobre os componentes dos modelos de C&R, ajustando-os em resposta à dinamicidade do ambiente, foi proposto um metamodelo para adaptação de C&R em SMAs dinâmicos. O metamodelo proposto divide o raciocínio do agente em dois níveis: o metanível, que define elementos generalizados de C&R e do ambiente que são relevantes para o processo de adaptação, e o nível de implementação, que realiza o processo de adaptação para o modelo concreto que está sendo utilizado.

A definição do modelo de adaptação na arquitetura BDI permite ao agente deliberar sobre sua capacidade de adaptação, transformando sua percepção do sistema em crenças e definindo objetivos relacionados ao desempenho do modelo de C&R. Isso permite que o agente opere com maior autonomia em ambientes dinâmicos, tais como SMAs abertos, e desenvolva um raciocínio sobre C&R independente de modelo.

Os resultados experimentais mostram a importância do modelo de adaptação como um complemento dos modelos propostos na literatura. Agentes que adaptam seus modelos às condições ambientais melhoram a utilização dos recursos limitados, reduzindo os custos associados à aplicação do modelo de C&R. Isso confirma o ponto de vista de Raja e Lesser (2007), que afirmam que “o uso eficiente e de baixo custo de controle no metanível, que raciocina sobre custos e benefícios de computações alternativas, leva a um desempenho melhorado do agente em ambientes com recursos limitados”.

Em todos os experimentos de adaptação realizados, foi possível definir planos de adaptação que, quando aplicados ao modelo original por meio do metamodelo, obtiveram resultados significativamente melhores em ambientes dinâmicos do que aqueles obtidos pelo uso do modelo original.

Os experimentos realizados utilizaram os principais componentes que compõem uma fonte de informação do metamodelo. Apesar do uso apenas da interação direta e da informação de testemunhas – que são as principais fontes da maioria dos modelos propostos na

literatura –, a abordagem baseada nos componentes abstratos do metamodelo permite que as mesmas ideias sejam aplicadas a qualquer outra fonte.

O metamodelo de C&R também mostrou-se útil na implementação de componentes ausentes. Como visto no Capítulo 5, foram implementados componentes de exploração para os modelos FIRE e de Marsh. Cabe ressaltar que esses componentes podem ser utilizados em outros modelos, uma vez que dependem apenas de componentes e crenças definidas no metanível. Isso sugere a possibilidade de usar o metamodelo para guiar a implementação de componentes que possam ser usados para complementar mais de um modelo de C&R.

Considerando os requisitos desejáveis, inicialmente definidos para a solução proposta, temos que:

- a solução mostrou-se aplicável em ambientes dinâmicos e não introduz crenças específicas de domínio, apesar de crenças específicas de aplicação (que estão relacionadas apenas com componentes do metamodelo) terem sido necessárias para adequar o processo de adaptação a limites específicos, por exemplo, de custos;
- o raciocínio do agente é realizado de forma independente do modelo específico de C&R em uso, incluindo a seleção do plano de adaptação; apenas a execução do plano (portanto, após a conclusão do raciocínio) pode depender de elementos próprios de um modelo específico;
- os aspectos ambientais que impactam o modelo são aplicáveis independentemente do domínio, por meio do mapeamento de aspectos do domínio nos componentes do metamodelo do ambiente;
- a solução estabeleceu um critério de avaliação, que permite ao agente identificar os custos de aplicação de um modelo em uma dada configuração e avaliar as possibilidades de adaptação;
- a solução permite, por meio do mecanismo de aprendizagem, que o agente aprenda novas formas de adaptar o modelo, considerando as condições atuais do ambiente.

Dentre as principais contribuições deste trabalho, está a incorporação da capacidade de deliberação sobre adaptação da C&R diretamente no modelo de um agente. Embora alguns poucos modelos de C&R apresentem alguma capacidade de adaptação, essa capacidade até então não havia sido incorporada a um agente deliberativo para permitir que o próprio agente pudesse realizar o processo de adaptação, independentemente do modelo usado e do domínio envolvido. Assim, mesmo modelos completamente desprovidos de adaptabilidade podem ter suas configurações ajustadas a partir da percepção e raciocínio do agente. Isso permite superar várias das limitações de modelos que não são adequados para ambientes dinâmicos.

A definição de um metamodelo para o ambiente permitiu superar a limitação dos modelos de C&R encontrados na literatura, que não consideram explicitamente o impacto de aspectos ambientais sobre a operação do modelo. Isso permitiu a concepção de planos de adaptação para evitar situações potencialmente prejudiciais aos agentes, como excesso de ociosidade devido a um nível alto de desconfiança ou gastos excessivos com aquisição de informações de reputação.

Por isso, outra contribuição relevante é a proposta de um critério de avaliação além da utilidade obtida com o uso do modelo. O critério proposto considera os custos, incluindo a perda de utilidade, de cada componentes do metamodelo de C&R, bem como o custo do próprio processo de deliberação e da ociosidade resultante da desconfiança. Dessa forma, o agente pode avaliar realmente se o uso do seu modelo de C&R, nas configurações atuais, traz benefícios reais. Dependendo das condições ambientais, o agente pode até decidir que o uso de um modelo de C&R é desnecessário, um vez que o custo de aplicação do modelo pode ser maior do que a expectativa de perda de utilidade. Logo, a proposta deste trabalho realça o aspecto de autonomia do agente na decisão da aplicação e adaptação do modelo de C&R.

O mecanismo de aprendizagem proposto também é uma importante contribuição, tendo em vista a limitação na adaptabilidade dos modelos de C&R e conseqüente inexistência de planos de adaptação pré-existentes. O mecanismo proposto pode ser aplicado em qualquer modelo de C&R, para permitir o aprendizado de novas formas de adaptação, considerando os aspectos ambientais mencionados. Anteriormente, apenas heurísticas de aprendizagem para características pontuais de modelos específicos haviam sido propostas na literatura. A prova de conceito, implementada como um AG, demonstrou a possibilidade de se utilizar uma abordagem de aprendizagem *offline*, na qual o agente aprende sobre a utilidade aproximada de um plano de adaptação para um cenário igual ou similar ao observado no ambiente. Os resultados obtidos com o uso da prova de conceito mostram que o uso desse mecanismo não dispensa o uso de outras formas de aprendizagem ou de heurísticas desenvolvidas manualmente para situações específicas de uma aplicação em particular.

## Trabalhos futuros

O metamodelo proposto aponta para várias possibilidades de trabalhos futuros. Uma delas é a extensão do metamodelo de C&R para incluir aspectos de representação, fluxo de informação e interoperabilidade. Com a adição desses elementos, o metamodelo passaria a conter todos os componentes necessários para a definição de um modelo completo de C&R. O modelo de interoperabilidade, por exemplo, poderia ser definido de forma semelhante ao

modelo de adaptação, baseando-se no componente de dimensões e contextos do metamodelo de C&R, com o acréscimo de um componente de representação.

Com um maior número de modelos e de configurações possíveis, aumenta também a diversidade de opções para o processo de adaptação. Por isso, outra possibilidade futura é o aperfeiçoamento do mecanismo de aprendizagem, a partir da experimentação de outros métodos, tais como aprendizagem por reforço e redes neurais, na descoberta de planos de adaptação para componentes específicos. O compartilhamento de planos de adaptação entre agentes é mais uma possibilidade que pode ser explorada. Utilizando um metamodelo e um critério de avaliação comuns, os agentes podem trocar informações sobre a utilidade de um plano em um determinado cenário, acelerando assim a aprendizagem.

A utilização do metamodelo para compor um modelo de C&R híbrido, que utilize componentes provenientes de vários outros modelos, é outra possibilidade interessante. Por exemplo, o componente de credibilidade poderia ser modificado dependendo do tipo de informação de reputação disponível. Se as interações forem binárias (apenas sucesso ou falha), um modelo baseado na distribuição beta, como BRS (Jøsang e Ismail, 2002) ou TRAVOS (Teacy et al., 2006) poderia ser aplicado, sem modificar os demais componentes do modelo original. Diferentes protocolos para aquisição e compartilhamento da reputação, com complexidade e custos diferentes, poderiam ser utilizados dependendo da situação. Esse tipo de composição seria possível, uma vez que o metamodelo delimita e abstrai a implementação dos componentes dos modelos. No entanto, para que isso se torne possível, as questões de interoperabilidade levantadas no trabalho deveriam ser incorporadas ao metamodelo.

A proposição de novos planos de adaptação e a aplicação do metamodelo proposto em outras aplicações, além da plataforma de testes utilizada neste trabalho, são relevantes para trabalhos futuros. A perspectiva de um mundo cada vez mais conectado e povoado por entidades computacionais autônomas, requer o aperfeiçoamento dos modelos computacionais de C&R, ampliando cada vez mais sua área de aplicação. Nesse cenário, é fundamental que os agentes deliberativos sejam capazes de raciocinar adequadamente sobre C&R, para avaliar os riscos de cooperação com agentes potencialmente autointeressados (ou até mal intencionados) e, ao mesmo tempo, se adaptar às características dinâmicas do mundo ao seu redor.

O domínio desses conceitos por agentes inteligentes é um aspecto importante para permitir sua autonomia em um sistema aberto, sem a necessidade de interferência humana para ajustar seus parâmetros durante sua operação. Com o aumento da autonomia e da robustez do raciocínio desses agentes, aumenta também a confiança dos agentes humanos na delegação de tarefas aos agentes computacionais, fazendo valer o adágio: “confiança gera confiança”.

# Referências bibliográficas

- ART Testbed, 2013. URL <http://megatron.iiia.csic.es/art-testbed/>. Último acesso em 06/05/2013.
- Alfarez Abdul-Rahman e Stephen Hailes. Supporting trust in virtual communities. *Proceedings of the 33rd Annual Hawaii International Conference on System Sciences*, 2000.
- Rafael H. Bordini, Jomi Fred Hübner e Michael Wooldridge. *Programming Multi-Agent Systems in AgentSpeak using Jason*. Wiley, 2007.
- M. E. Bratman. *Intentions, Plans, and Practical Reasoning*. Harvard University Press, Boston, MA, 1987.
- Michael E. Bratman, David J. Israel e Martha E. Pollack. Plans and Resource-Bounded Practical Reasoning. *Computational Intelligence*, 4(4):349–355, 1988.
- L. Braubach, A. Pokahr e W. Lamersdorf. A universal criteria catalog for evaluation of heterogeneous agent development artifacts. *Sixth International Workshop From Agent Theory to Agent Implementation*, 2008.
- Chris Burnett, T. J. Norman e Katia Sycara. Bootstrapping trust evaluations through stereotypes. *Proceedings of the 9th International Conference on Autonomous Agents and Multiagent Systems*, 1(1):241–248, 2010.
- Javier Carbo, Jose M. Molina, Jorge Davila e Monte Madrid. Comparing predictions of SPORAS vs. a Fuzzy Reputation System. *3rd WSEAS International Conference on Fuzzy Sets and Fuzzy Systems*, pp. 4561–4566, 2002.
- David Carmel e Shaul Markovitch. Exploration Strategies for Model-based Learning in Multi-agent Systems. *Autonomous Agents and Multi-agent Systems*, 2(2):141–172, 1999.
- Cristiano Castelfranchi. Trust and reciprocity: misunderstandings. *International Review of Economics*, 55(1-2):45–63, fevereiro 2008.

- Cristiano Castelfranchi e Rino Falcone. Principles of trust for MAS: cognitive anatomy, social importance, and quantification. *Proceedings International Conference on Multi Agent Systems*, pp. 72–79. IEEE Comput. Soc, 1998.
- Cristiano Castelfranchi e Rino Falcone. Social trust: A cognitive approach. *Trust and deception in virtual societies*, pp. 55–90, 2001.
- Isaac Pinyol Catadau. *Milking the Reputation Cow: Argumentation, Reasoning and Cognitive Agents*. Consell Superior d’Investigacions Científiques, Barcelona, Espanha, 2011.
- Paul R. Cohen. *Empirical Methods for Artificial Intelligence*. The MIT Press, 1995.
- Philip R. Cohen e Hector J. Levesque. Intention is choice with commitment. *Artificial Intelligence*, 42(2-3):213–261, março 1990.
- Rosaria Conte e Mario Paolucci. *Reputation in artificial societies: Social beliefs for social order*. Springer, 2002.
- Murat Şensoy, Jie Zhang, Pinar Yolum e Robin Cohen. Poyraz: Context-Aware Service Selection Under Deception. *Computational Intelligence*, 25(4):335–366, 2009.
- V. Dignum, J. Vázquez-Salceda e Frank Dignum. Omni: Introducing social structure, norms and ontologies into agent organizations. *Programming Multi-Agent Systems*, pp. 181–198, 2005.
- Mark D’Inverno, Michael Luck, Michael Georgeff, David Kinny e Michael Wooldridge. The dMARS Architecture: A Specification of the Distributed Multi-Agent Reasoning System. *Autonomous Agents and Multi-Agent Systems*, 9:5–53, julho 2004.
- Jim Dowling e Vinny Cahill. The k-component architecture meta-model for self-adaptive software. *Metalevel Architectures and Separation of Crosscutting Concerns*, pp. 81–88, 2001.
- Babak Esfandiari e Sanjay Chandrasekharan. On how agents make friends: Mechanisms for trust acquisition. *Proceedings of the Fourth Workshop on Deception, Fraud and Trust in Agent Societies*, 2001.
- J. Ferber e O. Gutknecht. A meta-model for the analysis and design of organizations in multi-agent systems. *International Conference on Multi Agent Systems*, pp. 128–135. IEEE Comput. Soc, 1998.
- David Fitoussi e Moshe Tennenholtz. Choosing social laws for multi-agent systems: Minimality and simplicity. *Artificial Intelligence*, 119(1-2):61–101, maio 2000.

- Karen K. Fullam e K. Suzanne Barber. Dynamically Learning Sources of Trust Information: Experience vs. Reputation. *Proceedings of the 6th International Conference on Autonomous Agents and Multiagent Systems*, volume 5, pp. 1055–1062, 2007.
- Karen K. Fullam, Marco Voss, Tomas B. Klos, Guillaume Muller, Jordi Sabater, Andreas Schlosser, Zvi Topol, K. Suzanne Barber, Jeffrey S. Rosenschein e Laurent Vercouter. A specification of the Agent Reputation and Trust (ART) testbed. *Proceedings of the fourth international joint conference on Autonomous agents and multiagent systems - AAMAS '05*, p. 512, New York, New York, USA, 2005. ACM Press.
- Karen Katherine Fullam. *Adaptive Trust Modeling in Multi-Agent Systems: Utilizing Experience and Reputation*. Doctoral thesis, University of Texas, 2007.
- Diego Gambetta. Can We Trust Trust? *Trust: Making and Breaking Cooperative Relations*, Capítulo 13, pp. 213–237. University of Oxford, 2000.
- Michael Georgeff, Barney Pell, Martha Pollack, Milind Tambe e Michael Wooldridge. The belief-desire-intention model of agency. *Intelligent Agents V: Agents Theories, Architectures, and Languages*, pp. 1–10. Springer, 1999.
- Michael P. Georgeff e Amy L. Lansky. Reactive reasoning and planning. *Proceedings of the Sixth National Conference on Artificial Intelligence - Volume 2*, pp. 677–682. AAAI Press, 1987.
- Tyrone Grandison e Morris Sloman. A Survey of Trust in Internet Applications. *IEEE Communications Surveys and Tutorials*, 2000.
- Nathan Griffiths. Task delegation using experience-based multi-dimensional trust. *Proceedings of the fourth international joint conference on Autonomous agents and multiagent systems - AAMAS '05*, pp. 489–496, New York, New York, USA, 2005. ACM Press.
- Koen V. Hindriks, Frank S. De Boer, Wiebe Van Der Hoek e John-Jules Ch. Meyer. Agent Programming in 3APL. *Autonomous Agents and Multi-Agent Systems*, 2:357–401, 1999.
- Bruno W. P. Hoelz e Célia Ghedini Ralha. A Coalition Formation Mechanism for Trust and Reputation-Aware Multi-Agent Systems. Leliane N. Barros, Marcelo Finger, Aurora T. R. Pozo, Gustavo A. Giménez-Lugo e Marcos Castilho, editores, *Advances in Artificial Intelligence - SBIA 2012*, Capítulo 4, pp. 162–171. Springer, 2012.
- Brian Horling e Victor Lesser. A survey of multi-agent organizational paradigms. *The Knowledge Engineering Review*, 19(04):281, novembro 2005.

- Nick Howden, Ralph Rönquist, Andrew Hodgson e Andrew Lucas. JACK Intelligent Agents - Summary of an Agent Infrastructure. *5th International Conference on Autonomous Agents*, 2001.
- Michael N. Huhns e Larry M. Stephens. Multiagent Systems and Societies of Agents. Gerhard Weiss, editor, *Multiagent Systems - A Modern Approach to Distributed Modern Approach to Artificial Intelligence*, Capítulo 2, pp. 79–120. The MIT Press, 1999.
- T. D. Huynh e N. R. Jennings. Certified reputation: how an agent can trust a stranger. *The Fifth International Joint Conference on Autonomous Agents and Multiagent Systems*, pp. 1217–1224, 2006.
- Trung Dong Huynh. *Trust and reputation in open multi-agent systems*. Doctoral thesis, University of Southampton, 2006.
- Trung Dong Huynh. A personalized framework for trust assessment. *Proceedings of the 2009 ACM symposium on Applied Computing - SAC '09*, p. 1302, New York, New York, USA, 2009. ACM Press.
- Trung Dong Huynh, Nicholas R. Jennings e Nigel R. Shadbolt. An integrated trust and reputation model for open multi-agent systems. *Autonomous Agents and Multi-Agent Systems*, 13(2):119–154, março 2006.
- N. R. Jennings. Commitments and conventions: The foundation of coordination in multi-agent systems. *Knowledge Engineering Review*, 8:223, 1993.
- Nicholas R. Jennings. On agent-based software engineering. *Artificial intelligence*, 117(2): 277–296, 2000.
- Audun Jøsang e Roslan Ismail. The beta reputation system. *Proceedings of the 15th Bled Electronic Commerce Conference*, Bled, Slovenia, 2002.
- Audun Jøsang, Roslan Ismail e Colin Boyd. A Survey of Trust and Reputation Systems for Online Service Provision. *Decision Support Systems*, 43(2):618–644, 2007.
- Reid Kerr e Robin Cohen. TREET: the Trust and Reputation Experimentation and Evaluation Testbed. *Electronic Commerce Research*, 10(3-4):271–290, agosto 2010.
- Sarah N. Lim Choi Keung e Nathan Griffiths. Trust and Reputation. Nathan Griffiths e Kuo-ming Chao, editores, *Agent-Based Service-Oriented Computing*, Capítulo 8, pp. 189–224. Springer, London, 2010.

- Michael Kinateder, Ernesto Baschny e Kurt Rothermel. Towards a generic trust model - comparison of various trust update algorithms. *Proceedings of the Third International Conference on Trust Management (iTrust2005)*. Springer, 2005.
- Manuel Kolp, Paolo Giorgini e John Mylopoulos. Multi-agent architectures as organizational structures. *Autonomous Agents and Multi-Agent Systems*, 13:3–25, 2006.
- Andrew Koster, Jordi Sabater-Mir e Marco Schorlemmer. Engineering trust alignment: a first approach. *13th Workshop on Trust in Agents Societies at AAMAS 2010*, pp. 111–122, 2010.
- Andrew Koster, Marco Schorlemmer e Jordi Sabater-Mir. Opening the black box of trust: reasoning about trust models in a BDI agent. *Journal of Logic and Computation*, 23(1): 25–58, março 2012.
- T. Warren Liao, Zhiming Zhang e Claude Mount. Similarity measures for retrieval in case-based reasoning systems. *Applied Artificial Intelligence*, 12(4):267–288, junho 1998.
- Sean Luke. Population Methods. *Essentials of Metaheuristics*, Capítulo 3, pp. 31–58. Lulu, 2a. edição, 2013.
- Stephen Paul Marsh. *Formalising trust as a computational concept*. Doctoral thesis, University of Stirling, United Kingdom, 1994.
- Luis G. Nardin, Anarosa A. F. Brand, Jaime S. Sichman e Laurent. Vercoouter. SOARI: A Service-Oriented Architecture to Support Agent Reputation Models Interoperability. Rino Falcone, Suzanne K. Barber, Jordi Sabater-Mir e Munindar P. Singh, editores, *Trust in Agent Societies*, volume 5396 of *Lecture Notes in Computer Science*. Springer, 2008.
- Mukaddim Pathan, Rajkumar Buyya e Athena Vakali. Content Delivery Networks: State of the Art, Insights, and Imperatives. Rajkumar Buyya, Mukaddim Pathan e Athena Vakali, editores, *Content Delivery Networks*, Capítulo 1, pp. 3–32. Springer, 2008.
- Isaac Pinyol e Jordi Sabater-Mir. Pragmatic-Strategic Reputation-Based Decisions in BDI Agents. *8th International Conference on Autonomous Agents and Multiagent Systems, AAMAS 2009*, pp. 1001–1008, 2009.
- Isaac Pinyol e Jordi Sabater-Mir. Computational trust and reputation models for open multi-agent systems: a review. *Artificial Intelligence Review*, julho 2011.
- Alexander Pokahr, Lars Braubach e Winfried Lamersdorf. Jadex: A BDI Reasoning Agent. *Multi-Agent Programming*, pp. 149–174. Springer, 2005.

- Anita Raja e Victor Lesser. A framework for meta-level control in multi-agent systems. *Autonomous Agents and Multi-Agent Systems*, 15(2):147–196, janeiro 2007.
- Anand S. Rao. AgentSpeak (L): BDI agents speak out in a logical computable language. *7th European Workshop on Modelling Autonomous Agents in a Multi-Agent World*, pp. 42–55, 1996.
- Anand S. Rao e Michael P. Georgeff. Modeling Rational Agents within a BDI-Architecture. *Second International Conference on Principles of Knowledge Representation and Reasoning*, pp. 473–484, 1991.
- Anand S. Rao e Michael P. Georgeff. BDI agents: From theory to practice. *First International Conference on Multi-Agent Systems (ICMAS-95)*, 1995.
- Kevin Regan, Pascal Poupart e Robin Cohen. Bayesian reputation modeling in e-marketplaces sensitive to subjectivity, deception and change. *Proceedings of the 21st National Conference on Artificial Intelligence*, pp. 1206–1212, 2006.
- Martin Reháč, Michal Pechoucek, Petr Benda e Lukás Foltýn. Trust in Coalition Environment: Fuzzy Number Approach. *Proceedings of the 4th International Joint Conference on Autonomous Agents and Multi-Agent Systems-Trust in Agent Societies Workshop*, pp. 119–131, 2005.
- Stuart Russell e Peter Norvig, editores. *Artificial intelligence: a modern approach*. Prentice Hall, 2a. edição, 2002.
- Jordi Sabater. *Trust and reputation for agent societies*. Tesi doctoral, Universitat Autònoma de Barcelona, Espanha, 2002.
- Jordi Sabater. Evaluating the ReGreT System. *Applied Artificial Intelligence*, 18(9):797–813, outubro 2004.
- Jordi Sabater e Carles Sierra. Review on Computational Trust and Reputation Models. *Artificial Intelligence Review*, 24(1):33–60, setembro 2005.
- Jordi Sabater-Mir, Mario Paolucci e Rosaria Conte. RePage: REPutation and ImAGE Among Limited Autonomous Partners. *Journal of Artificial Societies and Social Simulation*, 9(2), 2006.
- Sebastian Sardina e Lin Padgham. A BDI agent programming language with failure handling, declarative goals, and planning. *Autonomous Agents and Multi-Agent Systems*, 23(1):18–70, abril 2010.

- M. Schillo, P. Funk e M. Rovatsos. Using Trust for Detecting Deceitful Agents in Artificial Societies. *Applied Artificial Intelligence (Special Issue on Trust, Deception and Fraud in Agent Societies)*, 2000.
- Ed Seidewitz. What models mean. *IEEE Software*, 20(5):26–32, setembro 2003.
- Jean-Marc Seigneur e Pierpaolo Dondio. Trust and Reputation for Successful Software Self-organization. Giovanna Di Marzo Serugendo, Marie-Pierre Gleizes e Anthony Karageorgos, editores, *Self-organising Software - From Natural to Artificial Adaptation*, Natural Computing Series, Capítulo 8, pp. 163–192. Springer, Berlin, Heidelberg, 2011.
- Sandip Sen e Neelima Sajja. Robustness of reputation-based trust: Boolean case. *Proceedings of the first international joint conference on Autonomous agents and multiagent systems: Part 1*, pp. 288–293. ACM, 2002.
- Yoav Shoham. Agent-oriented programming. *Artificial Intelligence*, 60(1):51–92, março 1993.
- Eugen Staab e Guillaume Muller. MITRA: A Meta-Model for Information Flow in Trust and Reputation Architectures. *arXiv preprint arXiv:1207.0405*, p. 19, julho 2012.
- Katia P. Sycara. Multiagent systems. *AI Magazine*, 19(2):79–92, 1998.
- W. T. Luke Teacy, Jigar Patel, Nicholas R. Jennings e Michael Luck. TRAVOS: Trust and Reputation in the Context of Inaccurate Information Sources. *Autonomous Agents and Multi-Agent Systems*, 12(2):183–198, fevereiro 2006.
- W. T. Luke Teacy, Michael Luck, Alex Rogers e Nicholas R. Jennings. An efficient and versatile approach to trust and reputation using hierarchical Bayesian modelling. *Artificial Intelligence*, 193:149–185, 2012.
- Laurent Vercouter e Guillaume Muller. LIAR: Achieving Social Control in Open and Decentralised Multi-Agent Systems. *Applied Artificial Intelligence*, 24(8):723–768, 2010.
- Mirko Viroli, Tom Holvoet, Alessandro Ricci, Kurt Schelfhout e Franco Zambonelli. Infrastructures for the environment of multiagent systems. *Autonomous Agents and Multi-Agent Systems*, 14(1):49–60, agosto 2007.
- Yonghong Wang e C. W. Hang. A probabilistic approach for maintaining trust based on evidence. *Journal of Artificial Intelligence Research*, 40:221–267, 2011.
- Gerhard Weiss, editor. *Multiagent systems: a modern approach to distributed artificial intelligence*. The MIT Press, 1999.

- Danny Weyns, Andrea Omicini e James Odell. Environment as a first class abstraction in multiagent systems. *Autonomous Agents and Multi-Agent Systems*, 14(1):5–30, julho 2007.
- Michael Wooldridge. Intelligent Agents. Gerhard Weiss, editor, *Multiagent Systems - A Modern Approach to Distributed Modern Approach to Artificial Intelligence*, Capítulo 1, pp. 27–78. The MIT Press, 1999.
- Michael Wooldridge. *An Introduction to MultiAgent Systems*. Wiley, 2a. edição, 2009.
- Li Xiong e Ling Liu. PeerTrust: Supporting reputation-based trust for peer-to-peer electronic communities. *IEEE Transactions on Knowledge and Data Engineering*, 16(7): 843–857, 2004.
- Bin Yu e Munindar P. Singh. Distributed Reputation Management for Electronic Commerce. *Computational Intelligence*, 18(4):535–549, novembro 2002.
- Bin Yu e Munindar P. Singh. Searching Social Networks. *Proceedings of the Second International joint conference In Autonomous agents and multiagent systems - AAMAS '03* joint conference In Autonomous agents and multiagent systems - AAMAS '03, p. 65, New York, New York, USA, 2003. ACM Press.
- Giorgos Zacharia e Pattie Maes. Trust Management Through Reputation Mechanisms. *Applied Artificial Intelligence*, 14(9):881–907, outubro 2000.
- Terry Zimmerman e Subbarao Kambhampati. Learning-Assisted Automated Planning. *AI Magazine*, pp. 73–97, 2003.

# Apêndice A

## Resumo do metamodelo

Este apêndice apresenta um resumo dos elementos do metamodelo apresentado no Capítulo 4.

Tabela A.1: Componentes do metamodelo de confiança

<b>Componentes</b>	<b>Descrição</b>
Interação Direta (ID)	Cálculo da confiança pela interação direta*.
Normas	Normas utilizadas no sistema*.
Vieses	Regras pré-definidas (ou generalizadas da experiência) para aumentar ou reduzir a confiança*.
Avaliação da confiança	Define como a avaliação da confiança é realizada considerando a reputação e demais fontes de informação.
Dimensões e contextos	Especifica dimensões e contextos que diferenciam as observações e avaliações de C&R.
Tomada de decisão	Define como as intenções de confiar são consideradas na decisão final de confiar ou não.

\* é uma fonte de informação

Tabela A.2: Componentes do metamodelo de reputação

<b>Componentes</b>	<b>Descrição</b>
Fontes de Informação (FI)	Conjunto de fontes de informação baseadas em informações externas.
Avaliação da reputação	Especifica como cada uma das fontes é considerada na avaliação da reputação.
Gerenciamento das FI	Define como será a aquisição e o compartilhamento de informações considerando as fontes disponíveis.

Tabela A.3: Componentes do metamodelo de exploração

<b>Componentes</b>	<b>Descrição</b>
Inicialização	Como o agente realiza a exploração inicial do ambiente.
Exploração da ID	Estratégia de exploração da interação direta (descoberta de parceiros).
Exploração de FI	Estratégia de exploração de novas fontes de informação (ex.: descoberta de recomendadores).

Tabela A.4: Componentes das fontes de informação

<b>Componentes</b>	<b>Descrição</b>
Memória	Delimita o conjunto de percepções passadas usadas na avaliação.
Recência	Define se interações mais recentes são consideradas de forma diferenciada.
Credibilidade	Estabelece os critérios para acreditar na informação fornecida por essa fonte.
Confiabilidade	Determina o quanto a informação recebida é confiável, considerando o resultado observado.
Aquisição de informação	Como ocorre a aquisição de informação: quem e quantos agentes contatar, quanto pagar pela informação, etc.
Compartilhamento de info.	Como (com quem e se) a informação é compartilhada com outros agentes.

Tabela A.5: Componentes do metamodelo do ambiente

<b>Componente</b>	<b>Símbolo</b>
Utilidade total ofertada no ambiente	$U_{total}$
Utilidade obtida pelo agente	$U_{obt}$
Frequência das transações	$F$
Custo operacional	$C_{op}$
Custo de comunicação	$C_{com}$
Custo da informação	$C_{inf}$
Disponibilidade de parceiros confiáveis	$D_{pc}$
Disp. das fontes de informação	$D_{fi}$

Tabela A.6: Definições do modelo de adaptação

<b>Elemento</b>	<b>Definição</b>
Objetivo	$g = \{Env' \subseteq Env, m' \subseteq m_{meta}, \langle decl \rangle\}$
Evento	$evt = \{t, g \in G_M, env_t\}$
Plano	$p = \{\langle precond \rangle, \langle corpo \rangle, f : Env' \cup m' \rightarrow \mathbb{R}\}$
Critério de avaliação	$eval(m, env) = (C_{conf} + C_{rep} + C_{expl}) + C_{ocio} + C_{del}$
Cenário	$cen = \{Env' \subseteq Env \cup m' \subseteq m_{meta}\}$
Distância entre cenários	$d(X, Y) = \left( \sum_{i=1}^n  x_i - y_i ^2 \right)^{1/2}$



# Apêndice B

## Modelos UML

Este apêndice apresenta os modelos em UML dos componentes do metamodelo que foram utilizadas na implementação do protótipo Java utilizado na realização dos experimentos do Capítulo 5. Os componentes são definidos como interfaces que são implementadas pelos modelos e fontes de informação. A Figura B.1 apresenta as principais interfaces do metamodelo.

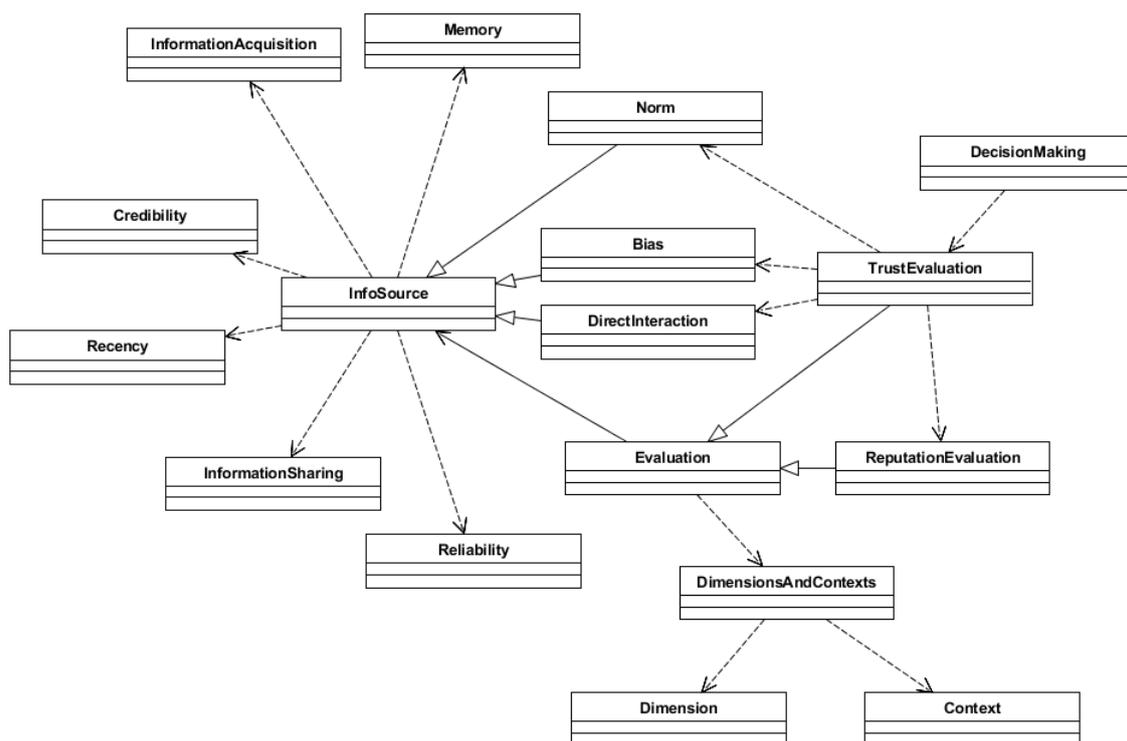


Figura B.1: Principais interfaces do metamodelo

As interfaces definem um conjunto mínimo de métodos para permitir a execução do processo de deliberação do agente, descrito na Seção 4.3. Para isso, elas definem como

as crenças podem ser obtidas para o modelo concreto implementado. Os métodos foram omitidos da figura para facilitar a visualização dos relacionamentos entre os componentes. Eles são ilustrados no trecho de código apresentado a seguir.

O código Java apresentado no Código B.1 ilustra a definição de fontes de informação, com base nas interfaces da Figura B.1, para vários modelos de C&R. O primeiro exemplo, define um fonte chamada *Contrato*, sugerida no modelo de Castelfranchi e Falcone (1998). A fonte é implementada como um tipo de norma, que define os componentes de memória, confiabilidade e aquisição de informação. Durante a execução, utilizando o operador *instanceof* da linguagem Java, é possível determinar os componentes implementados pela classe e com isso estabelecer as crenças associadas à fonte de informação. Para o componente de memória, por exemplo, dois métodos são definidos na interface *Memory* e implementados para permitir que as crenças de tamanho de memória e ocupação da memória sejam estabelecidas.

O segundo e terceiro exemplos ilustram a extensão da definição de uma fonte de informação com base em outra. No caso, o modelo de Yu e Singh (2002) define uma fonte chamada de rede de referências (*ReferralNetwork*), que é utilizada pelo modelo FIRE (Huynh et al., 2006) com a adição de outras características.

#### Código B.1: Definição de fontes de informação

```
@Model("castelfranchi-falcone")
class Contrato implements InfoSource, Norms,
    Memory, Reliability, InformationAcquisition {
    // definido na interface Memory
    int getMemoryOccupation() { ... }
    // definido na interface Memory
    int getMemorySize() { ... }
}

@Model("yu-singh")
class ReferralNetwork implements InformationSource,
    InformationAcquisition { ... }
}

@Model("fire")
class FireReferralNetwork extends ReferralNetwork
    implements Memory, Recency, Credibility, Reliability { ... }
```

---

As figuras B.2, B.3, B.4 apresentam, respectivamente, as interfaces utilizadas na definição do modelo de reputação, de exploração e do ambiente.

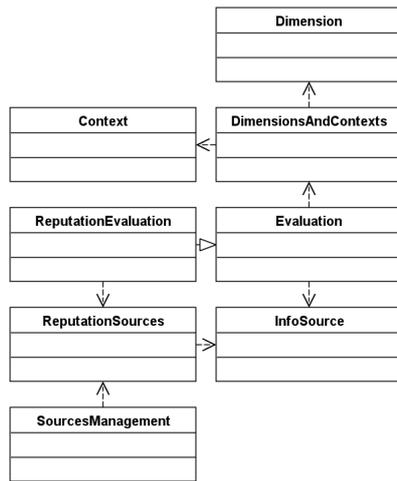


Figura B.2: Interfaces do modelo de reputação

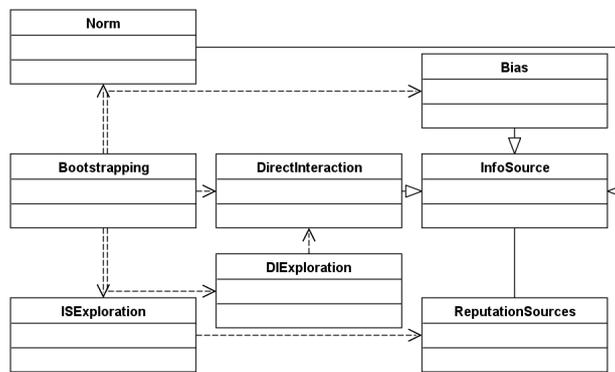


Figura B.3: Interfaces do modelo de exploração

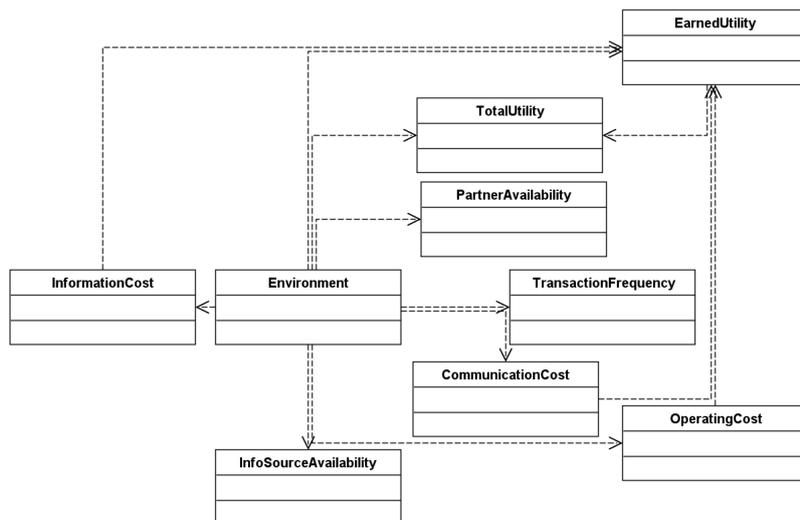


Figura B.4: Interfaces do metamodelo do ambiente



# Apêndice C

## Definição dos componentes

A Tabela C.1 define as entradas e saídas dos componentes do metamodelo de C&R nas fases do processo de deliberação (Seção 4.3). Os conjuntos  $A$  e  $FI$  definem, respectivamente, os agentes e as fontes de informação disponíveis. As seguintes variáveis e símbolos são usados:

- $\langle agente \rangle$  – agente avaliador;
- $a$  – ag. avaliado;
- $act$  – ação;
- $fi$  – fonte de informação;
- $id$  – interação direta;
- $int$  – intenção;
- $n$  – normas;
- $obs$  – observações;
- $rep$  – reputação;
- $t$  – confiança;
- $util$  – utilidade;
- $v$  – vieses.

Os parâmetros das entradas de uma fase subsequente que são iguais à saída da fase anterior são omitidos para facilitar a leitura. As demais siglas dizem respeito ao processo executado pelos componentes do metamodelo com as mesmas iniciais:  $ini, exid, exf, ai, mem, rec, rel, cred$ .

Tabela C.1: Entradas e saídas dos componentes nas fases do processo de deliberação

Componente	Entradas	Saída
Inicialização	$A, FI$	$exid(A^{ini} \subseteq A),$ $exf(FI^{ini} \subseteq FI)$
Exploração da interação direta	$A$	$\{a \in A^{expl} \subseteq A \mid$ $int(t(a), rel(t))\}$
Exploração de fontes de info.	$FI$	$FI^{expl} \subseteq FI$
Gerenciamento das fontes	$\{fi \in FI' \subseteq FI \mid rel(fi)\} \cup$ $\{fi \in FI^{expl}\} \rightarrow FI^{gf}$	$\{fi \in FI^{gf} \mid ai(a, fi)\}$
Aquisição de informação	$ai(a, fi)$	$rep(a, fi, rel(rep))$
Memória	$mem(a), rep$	$\{mem'(a) \subseteq mem(a) \cup$ $rep(a)\} \rightarrow obs(a)$
Recência	$obs$	$rec(obs)$
Credibilidade	$obs$	$cred(obs)$
Confiabilidade	$obs$	$rel(obs)$
Avaliação da reputação	$a, \{fi \in FI^{gf}\}, rec, cred, rel$	$rep(a, \langle agente \rangle, rel(rep))$
Avaliação da confiança	$a, \{fi \in \{id, n, v\} \mid$ $t(a, fi, rel(t))\}, rep$	$t(a, \langle agente \rangle, rel(t))$
Tomada de decisão	$t$	$int(t) \in \{\text{confiar},$ $\text{não confiar}\}$
Ação*	$Int \wedge int(t)$	$act(int(t))$
Resultado*	$util(act)$	$obs(a) \leftarrow util,$ $t(a, \langle agente \rangle, rel(t))$
Compartilhamento de informação	$t, FI^{gf}$	$\{fi \in FI^{gf} \mid$ $compartilhar(t, fi)\}$

\* evento externo ao modelo (não tem componente associado)

# Mapeamento

Cada um desses componentes pode estabelecer diversas crenças para serem utilizadas no processo de deliberação do agente. O primeiro conjunto de crenças a ser definido, diz respeito a quais partes do metamodelo são implementados pelo modelo de C&R. O Código C.1 apresenta essas crenças.

## Código C.1: Crenças do mapeamento do metamodelo

```
trustModel("nome do modelo").
reputationModel("nome do modelo").
explorationModel("nome do modelo").
environmentModel.
```

---

Em seguida, o mesmo é feito para os componentes de cada um desses modelos e para as fontes de informação. O Código C.2 apresenta essas crenças. Lembrando que nem todos os componentes definidos no metamodelo precisam ser definidos.

## Código C.2: Crenças do mapeamento de uma fonte de informação

```
decisionMakingComponent(componente1).
trustEvaluationComponent(componente2)
reputationEvaluationComponent(componente3).

// fontes de informação
infoSources([fonte1, fonte2, fonte3]).
memoryComponent(mem_componente, fonte1).
recencyComponente(rec_componente, fonte1).
```

---

Por fim, cada componente individual definição suas próprias crenças de C&R. Se o modelo define a crença de que um determinado componente é mapeado, então, para que todos os objetivos de monitoramento para esse componente possam ser utilizados, ele deve ser capaz de estabelecer todas essas crenças. Por exemplo, se uma fonte de informação implementa um componente de memória, então ela deve ser capaz de definir uma crença sobre a capacidade da memória, para que o processo de adaptação possa se basear nessa crença. Ainda assim, a definição dessas crenças, feitas pelo mapeamento do modelo de C&R no metamodelo, não é obrigatória. Apesar da restrição na capacidade de adaptação que isso gera, a não obrigatoriedade permite que outras novas crenças sejam definidas para um componente do metamodelo, aumentando as possibilidades de monitoramento e adaptação.

A seguir são listadas algumas das crenças derivadas dos componentes do metamodelo de C&R:

- ocupação da memória;
- capacidade da memória;
- número de interações com um agente;
- peso da recência na avaliação feita no tempo  $t$ ;
- credibilidade de uma fonte de informação;
- confiabilidade de uma medida de reputação segundo uma fonte;
- confiança em um agente;
- reputação de um agente;
- reputação de um agente segundo uma fonte;
- dados agregados (maior, menor, média, variância, etc.) para as medidas citadas.

Outras crenças, como aquelas derivadas do metamodelo do ambiente ou relacionadas aos custos relacionados à aplicação do modelo, não dependem do mapeamento do modelo de C&R e são definidos pelo agente deliberativo. As crenças relacionadas à aplicação, como limites para os custos mencionados, também não fazem parte do mapeamento.

# Apêndice D

## Código AgentSpeak

As seções seguintes apresentam o código, na linguagem AgentSpeak, utilizado nos experimentos do Capítulo 5. A sintaxe da linguagem é apresentada na Seção 2.4.2. Cabe ressaltar que as crenças utilizadas abaixo são apenas exemplos, uma vez que as crenças são obtidas a partir da percepção do ambiente e do metamodelo de C&R.

### Memória e recência

#### Código D.1: Código AgentSpeak do Experimento 1

```
// mapeamentos do metamodelo
trustModel("Marsh").
environmentModel.
infoSources(directTrust).
memoryComponent(mc, directTrust).
memorySize(mc, 10).
memoryOccupation(mc, 7).

// crenças de C&R
trustMean(0.7).
trustDeviation(0.02).
trustMax(ag1, 0.78).
trustMin(ag2, 0.62).
trustChange(0.7, 0.9).

// Parâmetro específico do modelo FIRE
fire_lambda(10).

start.
```

```

+start : (trustModel(X) | reputationModel(X) | explorationModel(X)) &
  environmentModel
<- loadPlans(X);
  ?trustReduction. // monitoring goal

+memoryComponent : true
<- !evalMemory.

+newMemory(X,Y) : true
<- !evalMemory(X,Y).

+!evalMemory(X, Y) : memorySize(C,W) & memoryOccupation(C,Z) & (W > Z)
<- addToMemory(X, Y);
  .print("New memory added! Ag. ", X, ", result = ", Y);
  -memoryOccupation(C,Z);
  +memoryOccupation(C,Z+1);
  .print("Memory occupation at ", Z+1);
  evalMemory.

+!evalMemory(X, Y) : memorySize(C,W) & memoryOccupation(C,Z) & (W <= Z)
<- .print("Memory full. Discarding older memory.");
  freeMemory;
  -memoryOccupation(C,Z);
  +memoryOccupation(C,Z-1);
  .print("Memory occupation at ", Z-1);
  !evalMemory(X, Y).

+?trustReduction : trustChange(T1, T2) & T1 < (0.8 * T2)
<- .print("Trust reduction observed.");
  !adjustMemory(T1, T2).

+!adjustMemory(T1, T2) : trustModel(W) & fire_lambda(Z)
  & memorySize(C,X) & trustMean(Y) & W == "FIRE"
<- .print("FIRE Adaptation Plan: adjusting lambda...");
  -fire_lambda(C,Z);
  +fire_lambda(-X / 10 * Y / -0.69).

+!adjustMemory(T1, T2) : memorySize(C,H) & H > 5
  & trustModel(W) & (W == "FIRE" | W == "Marsh")
<- .print("FIRE/Marsh adaptation Plan: adjusting memory size...");
  -memorySize(C,H);
  +memorySize(C,H * (T1/T2)).

```

---

## Tomada de decisão

### Código D.2: Código AgentSpeak do Experimento 2

```
// mapeamentos do metamodelo
trustModel("Marsh").
environmentModel.
infoSources(directTrust).
decisionMakingComponent(marsh_ct).

// crenças do ambiente
costThreshold(0.15).
utilityEarned(100).
idlenessCost(17).

// crenças de C&R
trustMean(0.65).
trustDeviation(0.05).
trustMax(ag1, 0.73).
availabilityMean(0.65).
availabilityDeviation(0.05).

// Parâmetro específico do modelo de Marsh
marsh_cooperationThreshold(0.75).

start.

+start : (trustModel(X) | reputationModel(X)
| explorationModel(X)) & environmentModel
<- loadPlans(X);
    ?idlenessLimit; // monitoring goal
    ?trust(ag1).

+?idlenessLimit : costThreshold(X) & utilityEarned(Y)
& idlenessCost(Z) & (Z > X*Y)
<- .print("Idle cost threshold exceeded.");
    !reduceIdleness.

-?idlenessLimit : costThreshold(X) & utilityEarned(Y)
& idlenessCost(Z) & (Z <= X*Y)
<- .print("Idle cost within threshold.").

// Adaptation goal
+!reduceIdleness : decisionMakingComponent(X)
<- !adjustDecisionMakingCriteria(X).
```

```

// Adaptation plan
+!adjustDecisionMakingCriteria(X) : X == marsh_ct
& marsh_cooperationThreshold(Y)
<- .print("Adapting Marsh's CT...");
  changeThreshold(Y);
  -marsh_cooperationThreshold(Y);
  +marsh_cooperationThreshold(Y * 0.95).

+?trust(X) : trustMax(X, Y) & marsh_cooperationThreshold(Z) & Y >= Z
<- .print("Will trust agent ", X);
  trust(X).

-?trust(X) : true
<- .print("Won't trust agent ", X).

```

---

## Credibilidade e confiabilidade

### Código D.3: Código AgentSpeak do Experimento 3

```

// mapeamentos do metamodelo
trustModel("ReGreT").
environmentModel.
infoSources(directTrust).
credibilityComponent(directTrust, [intimacyLevel, defaultCredibility]).

// crenças do ambiente
transactionFrequency(100).
availabilityMean(0.75).
availabilityDeviation(0.05).

// crenças de C&R
reliabilityMean(0.90).
reliabilityDeviation(0.025).
credibilityMax(t1, directTrust, ag1, 0.95).
credibility(ag1, 0.9).
reliability(directTrust, 0.9).
available(ag1).

// Parâmetro específico do modelo ReGreT
regret_intimateThreshold(10).
regret_defaultCredibility(0.5).
regret_interactionCount(ag1, 15).
regret_intimacyLevel(ag1, 0.45).

start.

```

```

+start : (trustModel(X) | reputationModel(X)
| explorationModel(X)) & environmentModel
<- loadPlans(X);
    ?reputationCostLimit. // monitoring goal

+?reputationCostLimit : credibilityMax(T, X, AG, Z)
    & credibility(AG, W) & (Z > 0.98 * W)
<- .print("Credibility reduction exceeded at time ", T);
    !adjustCredibility(X).

// Adaptation goal
+!adjustCredibility(X) : credibilityComponent(X, Y)
<- !adjustCredibilityComponent(X, Y).

// Adaptation plan
+!adjustCredibilityComponent(X, Y) : Y == [intimacyLevel,
    defaultCredibility]
& regret_intimateThreshold(A) & regret_defaultCredibility(B)
<- .print("Adapting credibility component for source: ", X);
    !increaseItm(A).

+!increaseItm(A) : transactionFrequency(F) & A < 10 * F
<- -regret_intimateThreshold(A);
    +regret_intimateThreshold(A*1.25).

+!updateIntimacy(X) : regret_intimateThreshold(A)
& regret_interactionCount(X, Y) & available(X)
<- .print("Updating iteration count for agent ", X);
    -regret_interactionCount(X, Y);
    updateIntimacy(X, Y+1);
    +regret_interactionCount(X, Y+1).

+!updateIntimacy(X) : regret_intimateThreshold(A)
& regret_interactionCount(X, Y) & not available(X)
<- .print("Agent unavailable. Reducing interaction count for agent ", X)
    ;
    -regret_interactionCount(X, Y);
    +regret_interactionCount(X, Y-1).

+regret_intimateThreshold(A) : true
<- .print("Intimate level set to ", A).

```

---

## Aquisição de informação

### Código D.4: Código AgentSpeak do Experimento 4

```
// mapeamentos do metamodelo
reputationModel("FIRE").
environmentModel.
infoSources(referralNetwork).
informationAcquisitionComponent(referralNetwork, fire_rn).

// crenças do ambiente
communicationCost(0.1).
informationPrice(0.025).
reputationCost(17).
costThreshold(0.15).
utilityEarned(100).

// crenças de C&R
credibilityMean(0.45).
credibilityDeviation(0.05).
credibilityMax(ag1, 0.55).
availabilityMean(0.80).
availabilityDeviation(0.02).

// Parâmetro específico do modelo FIRE
fire_branchingFactor(2).
fire_referralLength(5).

start.

+start : (trustModel(X) | reputationModel(X)
| explorationModel(X)) & environmentModel
<- loadPlans(X);
    ?reputationCostLimit. // monitoring goal

+?reputationCostLimit : costThreshold(X) & utilityEarned(Y)
& reputationCost(Z) & (Z > X*Y)
<- .print("Reputation acquisition cost exceeded.");
    !reduceReputationCost.

// Adaptation goal
+!reduceReputationCost : informationAcquisitionComponent(X, Y)
<- !adjustAcquisitionMechanism(X, Y).

// Adaptation plan
```

```
+!adjustAcquisitionMechanism(X, Y) : Y == fire_rn
& fire_branchingFactor(A) & fire_referralLength(B)
<- .print("Adapting info. acq. for source: ", X);
  !reduceRL(B).

+!reduceBF(A) : A > 0 & B == 0
<- -fire_branchingFactor(A);
  +fire_branchingFactor(A-1).

+!reduceRL(B) : B > 1 & fire_branchingFactor(A) & A > 0
<- -fire_referralLength(B);
  +fire_referralLength(B-1);
  !reduce(A).

+fire_branchingFactor(A) : true
<- .print("Branching factor set to ", A).

+fire_referralLength(B) : true
<- .print("Referral length set to ", B).
```

---



# Apêndice E

## Análise estatística dos resultados

As seções a seguir apresentam a análise estatística dos resultados dos experimentos realizados no Capítulo 5. Para isso, foi utilizado o teste t de Student para duas amostras (Cohen, 1995). O teste foi executado com o uso da ferramenta QtiPlot<sup>1,2</sup>. Em todos os testes o nível de significância utilizado foi de 0,05.

### Memória e recência

#### Código E.1: Análise estatística do Experimento 1 (Agente 4)

```
Two Sample Independent t-Test:
Sample          N          Mean          Standard Deviation
-----
M.Base          23          0,8345016722435    0,1317685196019
M.Adapt.        23          0,3750983277739    0,1762679958429
-----
                          Variance          Standard Error
M.Base          0,01736294275807    0,02747563565595
M.Adapt.        0,03107040635846    0,03675441787019
-----
Difference of Means:    0,4594033444696

Null Hypothesis:      Mean1 - Mean2 <= 0
Alternative Hypothesis: Mean1 - Mean2 > 0

t          DoF          P Value
10,01119267812    44          3,227223718295e-13
```

<sup>1</sup>A saída da ferramenta foi formatada para ser exibida corretamente na largura da página.

<sup>2</sup><http://soft.proindependent.com/qtiplot.html>

At the 0,05 level, the difference of the population means is significantly greater than the test difference (0).

Confidence Interval for Difference of Means:

Level	Lower Limit	Upper Limit
95	0,3669201974756	0,5518864914635

## Tomada de decisão

### Código E.2: Análise estatística do Experimento 2 (Agente 4)

Two Sample Independent t-Test:

Sample	N	Mean	Standard Deviation
--------	---	------	--------------------

M.Base	30	5.688,7333333333	215,1268965267
M.Adapt	30	7.893,5666666667	440,6261753877

	Variance	Standard Error
M.Base	46.279,5816092	39,27661798458
M.Adapt	194.151,4264368	80,44696522902

Difference of Means: -2.204,8333333333

Null Hypothesis: Mean1 - Mean2 >= 0

Alternative Hypothesis: Mean1 - Mean2 < 0

t	DoF	P Value
-24,62868106587	58	1,052345956107e-32

At the 0,05 level, the difference of the population means is significantly less than the test difference (0).

Confidence Interval for Difference of Means:

Level	Lower Limit	Upper Limit
95	-2.384,033081024	-2.025,633585643

## Credibilidade e confiabilidade

### Código E.3: Análise estatística do Experimento 3 (Agente 1)

Two Sample Independent t-Test:

Sample	N	Mean	Standard Deviation
--------	---	------	--------------------

M.Adapt	33	0,8888484848485	0,002587484445862
M.Base	33	0,7359090909091	0,01296717884787

```

-----
                Variance                Standard Error
M.Adapt          6,695075757576e-06      0,0004504232271574
M.Base           0,0001681477272727      0,002257296098196
-----
Difference of Means:  0,1529393939394

Null Hypothesis:      Mean1 - Mean2 <= 0
Alternative Hypothesis: Mean1 - Mean2 > 0

t                DoF      P Value
66,44349283874   64        0

At the 0,05 level, the difference of the population means
is significantly greater than the test difference (0).

Confidence Interval for Difference of Means:
Level   Lower Limit      Upper Limit
95      0,1483410269732    0,1575377609056

```

## Aquisição de informação

### Código E.4: Análise estatística do Experimento 4

```

Two Sample Independent t-Test:
Sample      N          Mean          Standard Deviation
-----
M.Base      38          5.440,289473684      80,36434192955
M.Adapt.    38          5.761,894736842      52,1426263729
-----
                Variance                Standard Error
M.Base          6.458,42745377      13,03681775605
M.Adapt.        2.718,853485064      8,45865095170
-----
Difference of Means:  -321,6052631579

Null Hypothesis:      Mean1 - Mean2 >= 0
Alternative Hypothesis: Mean1 - Mean2 < 0

t                DoF      P Value
-20,69464269392   74      8,421843149762e-33

At the 0,05 level, the difference of the population means
is significantly less than the test difference (0).

```

Confidence Interval for Difference of Means:

Level	Lower Limit	Upper Limit
95	-352,5704015562	-290,6401247596

---

# Apêndice F

## Configuração do algoritmo genético

A Tabela F.1 apresenta o resultado obtido com variações na configuração do AG utilizado na Seção 5.4. O *fitness* médio obtido para uma amostra de 1000 cenários utilizados na aprendizagem foi normalizado em relação ao maior valor, cuja configuração foi utilizada nos experimentos e é descrita na Tabela 5.12.

Tabela F.1: Avaliação de diferentes configuração para o AG

<i>Fitness</i> médio normalizado	Configuração
0,9938186813187	95% de crossover
0,9752747252747	30% de crossover
0,9800824175824	elitismo de 1% a 5%
0,9697802197802	mutação de 1% a 5%
0,9690934065934	população = 100
0,9821428571429	população = 30
1,0000000000000	(config. utilizada)
0,9979395604396	50% de crossover
0,9842032967033	mutação de 0,1% a 0,5%
0,9787087912088	elitismo de 0,1% a 0,5%

A Figura F.1 apresenta uma representação do tipo *box plot* dos valores da Tabela F.1. Os círculos representam o maior e o menor valor. O quadrado pequeno representa a média. O Código F.1 apresenta a saída da análise estatística dos dados da tabela citada.

A análise estatística dos resultados – utilizando o teste de chi-quadrado para variância com nível de significância  $\alpha = 0,05$  – mostra que a variância dos resultados obtidos com as configurações testadas não é significativamente maior que 0,0004 (um desvio-padrão de 2%). Os resultados da análise são apresentados no Código F.1.

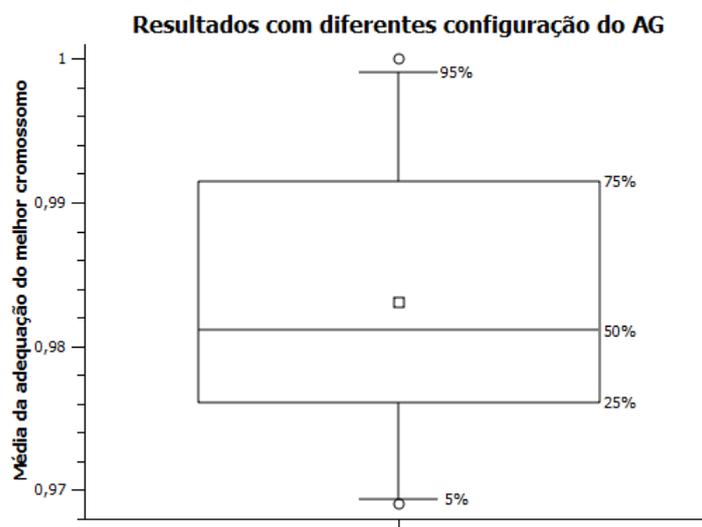


Figura F.1: Teste com diferentes configurações do AG

**Código F.1: Análise estatística dos resultados dos AGs**

Sample	N	Mean	Standard Deviation
Tabela_AG	10	0,9831043956044	0,01098519469754
		Variance	Standard Error
		0,0001206745025429	0,003473823578464

Null Hypothesis: Variance  $\leq$  0,0004  
 Alternative Hypothesis: Variance  $>$  0,0004

Chi-Square	DoF	P Value
2,715176307216	9	0,9745260236909

At the 0,05 level, the population variance is not significantly greater than the test variance (0,0004).

Confidence Intervals for Variance:

Level	Lower Limit	Upper Limit
95	5,709319140004e-05	0,0004021903221347

Statistics for Tabela\_AG:

Min = 0,97  
 D1 (1st decile) = 0,97  
 Q1 (1st quartile) = 0,98  
 Median = 0,98  
 Q3 (3rd quartile) = 0,99  
 D9 (9th decile) = 1,00  
 Max = 1  
 Size = 10