

Fabiano Azevedo Dorça

Uma Abordagem Estocástica Baseada em
Aprendizagem por Reforço para Modelagem
Automática e Dinâmica de Estilos de
Aprendizagem de Estudantes em Sistemas
Adaptativos e Inteligentes para Educação a
Distância

Uberlândia
2012

Fabiano Azevedo Dorça

Uma Abordagem Estocástica Baseada em
Aprendizagem por Reforço para Modelagem
Automática e Dinâmica de Estilos de
Aprendizagem de Estudantes em Sistemas
Adaptativos e Inteligentes para Educação a
Distância

Tese apresentada à Faculdade de Engenharia Elétrica da Universidade Federal de Uberlândia, como requisito parcial para a obtenção de Título de Doutor em Ciências.

Orientador: Prof. Dr. Luciano Vieira Lima

Área de Concentração: Processamento da Informação

**Uberlândia
2012**

Banca Examinadora:

Prof. Dr. Alexandre Cardoso (UFU)

Prof. Dr. Keiji Yamanaka (UFU)

Profa. Dra. Rosa Maria Esteves Moreira da Costa (UERJ)

Prof. Dr. Sérgio Crespo Coelho da Silva Pinto (UNISINOS)

Orientador - Prof. Dr. Luciano Vieira Lima (UFU)

Agradecimentos

Agradeço a todos aqueles que de alguma forma contribuíram e me apoiaram na execução deste trabalho. Aos professores do Programa de Pós-graduação em Engenharia Elétrica (PPGEEL) da UFU, pelos valiosos ensinamentos. Ao meu orientador, Prof. Dr. Luciano Vieira Lima, pela oportunidade, apoio, confiança, amizade e disponibilidade sempre que precisei. Aos membros da banca, professores Alexandre Cardoso, Keiji Yamanaka, Rosa Maria Esteves Moreira da Costa e Sérgio Crespo Coelho da Silva Pinto, pelas valiosas contribuições. Aos meus pais, Djalma de Oliveira Dorça e Marisa Azevedo Dorça, a toda minha família e amigos, pela amizade, pelo carinho, por compreenderem os meus momentos de ausência e por me incentivarem sempre. Aos meus colegas da FACOM/UFU, especialmente aos professores Carlos Roberto Lopes e Márcia Aparecida Fernandes, pelo incentivo no desenvolvimento deste trabalho. À minha esposa, Thaísa Malagoli, por estar sempre presente nos momentos mais críticos desta jornada, por se fazer parte dela, por compreender as suas dificuldades, e entender que estive em busca de um sonho.

Resumo

Uma característica importante em Educação à Distância é a assistência personalizada e inteligente, em que um importante aspecto a ser observado é que estudantes neste tipo de curso podem apresentar perfis bastante diferenciados. Em virtude disto, um desafio em pesquisa é o desenvolvimento de aplicações educacionais avançadas que possam oferecer algum grau de inteligência e adaptatividade. Um fator indispensável neste tipo de sistema é a identificação precisa de estilos de aprendizagem do estudante, de modo a fornecer conteúdo mais apropriado possível às necessidades individuais. A implementação deste tipo de sistema, fundamentada em uma abordagem probabilística para modelagem do estudante é um importante problema em pesquisas, já que estes modelos necessitam lidar com informações incompletas ou incertas sobre o estudante. Por isto, acreditamos fortemente que considerar processos estocásticos na modelagem do estudante e no fornecimento de adaptatividade é essencial. Especificamente, a abordagem proposta neste trabalho tem por objetivo detectar e corrigir incrementalmente, de forma automática e dinâmica, imprecisões e inconsistências nos estilos de aprendizagem armazenados no modelo do estudante, considerando-se que as preferências obtidas através de questionários psicométricos podem necessitar de revisões, por possuírem certo grau de incerteza. Neste contexto, este trabalho aborda e trata questões importantes da modelagem automática e dinâmica de estilos de aprendizagem, ignoradas pelas abordagens desenvolvidas até o momento e analisadas neste trabalho.

Palavras-chave: modelo do estudante; estilos de aprendizagem; detecção automática e dinâmica de estilos de aprendizagem; modelagem probabilística do estudante; sistemas adaptativos e inteligentes para educação.

Abstract

An important feature in Distance Education is the personal and intelligent assistance, in which an important aspect is that students may have quite different profiles. Thus, a course designed for a particular student may not be suitable for other students. Because of this, a challenge in research is the development of advanced educational applications that provide some degree of intelligence and adaptivity. An indispensable factor in this type of system is the accurate identification of students learning styles, in order to provide most suited content to their individual needs. The construction of this kind of system through a probabilistic process is an important research problem, because these systems need to deal with incomplete or uncertain information about students. Thus, adaptivity provided by these systems need to consider a certain level of uncertainty. So, we strongly believe that considering stochastic student modeling in these systems is essential. Therefore, the main goal of this work is to present an innovative stochastic approach, based on reinforcement learning, for providing adaptivity through probabilistic modeling of students learning styles, and to investigate its efficiency, effectiveness and reliability through a series of experiments. Specifically, the proposed approach aims to detect and correct, automatically and dynamically, inaccuracies and inconsistencies in learning styles stored in the student model, considering that preferences obtained through psychometric questionnaires may need review, by having some degree of uncertainty. In this context, this work discusses and addresses important issues on automatic and dynamic modeling of learning styles, most of them ignored by approaches developed so far.

Keywords: student model; learning styles; automatic and dynamic detection of learning styles; probabilistic student modeling; adaptive and intelligent educational systems.

Artigos Publicados

- Dorça, F. A.; Lima, L. V.; Fernandes, M. A.; Lopes, C. R. Detecção e Correção Automática de Estilos de Aprendizagem em Sistemas Adaptativos para Educação. *Revista de Informática Teórica e Aplicada*, v. 18, p. 178-204, 2011. ISSN 2175-2745.
- Dorça, F. A.; Lima, L. V.; Fernandes, M. A.; Lopes, C. R. A New Approach to Discover Students Learning Styles in Adaptive Educational Systems. In: 22o. Simpósio Brasileiro de Informática na Educação, 2011, Aracajú. *Anais do XXII SBIE - XVII WIE*, 2011. p. 70-79. ISSN: 2176-4301. Prêmio de melhor artigo do 22o. SBIE (2011) - Trilha 01 (Inteligência Artificial). CEIE - Comissão Especial de Informática na Educação da SBC.
- Dorça, F. A.; Lima, L. V.; Fernandes, M. A.; Lopes, C. R. A Stochastic Approach for Automatic and Dynamic Student Modeling in Adaptive Educational Systems. *Informatics in Education*, v. 11, No. 2, 2012. ISSN: 1648-5831.
- Dorça, F. A.; Lima, L. V.; Fernandes, M. A.; Lopes, C. R. Automatic Student Modeling in Adaptive Educational Systems Through Probabilistic Learning Style Combinations: A Qualitative Comparison Between Two Innovative Stochastic Approaches. *Journal of The Brazilian Computer Society*, 2012. Springer, 2012. DOI: 10.1007/s13173-012-0078-2. ISSN: 0104-6500 (versão impressa) ISSN: 1678-4804 (versão eletrônica).

Artigos Submetidos

- Dorça, F. A.; Lima, L. V.; Fernandes, M. A.; Lopes, C. R. Using a Simulated Student for Validating a Novel Approach to Automatic Detection of Learning Styles. *Revista IEEE América Latina*. ISSN: 1548-0992
- Dorça, F. A.; Lima, L. V.; Fernandes, M. A.; Lopes, C. R. Consistent Evolution of Student Models by Automatic Detection of Learning Styles. *Revista IEEE América Latina*. ISSN: 1548-0992
- Dorça, F. A.; Lima, L. V.; Fernandes, M. A.; Lopes, C. R. Automatic Student Modeling in Adaptive Educational Systems Through Probabilistic Learning Styles Combinations. *Computers e Education*. ISSN 0360-1315
- Dorça, F. A.; Lima, L. V.; Fernandes, M. A.; Lopes, C. R. EADS: Evolutionary Algorithm to Discover Students Learning Styles in Distance Education Systems. *International Journal of Distance Education Technologies*. ISSN: 1539-3100
- Dorça, F. A.; Lima, L. V.; Fernandes, M. A.; Lopes, C. R. Improving the Performance of EADS Using Genetic Operators. *International Journal of Information and Communication Technology*. ISSN online: 1741-8070. ISSN print: 1466-6642
- Dorça, F. A.; Lima, L. V.; Fernandes, M. A.; Lopes, C. R. Avaliação de Políticas de Aprendizagem por Reforço para Modelagem Automática e Dinâmica de Estilos de Aprendizagem: Uma Análise Experimental. 23o. Simpósio Brasileiro de Informática na Educação, 2012, Rio de Janeiro. <http://www.cbie.org.br/>
- Dorça, F. A.; Lima, L. V.; Fernandes, M. A.; Lopes, C. R. Comparing Strategies for Modeling Students Learning Styles through Reinforcement Learning in Adaptive and Intelligent Educational Systems: An Experimental Analysis. *Expert Systems with Applications*. ISSN: 0957-4174

Lista de Figuras

3.1	Exemplo de uma estratégia pedagógica baseada em EA	64
3.2	Exemplo de cadeia de Markov	71
3.3	AR utiliza uma estrutura composta de estados, ações e recompensas	74
4.1	Modelo markoviano do processo estocástico de seleção de uma CEA	95
4.2	Atualização do ME durante o processo de aprendizagem	102
4.3	Arquitetura resultante da integração de um SAIE com a abordagem proposta.	107
4.4	O conceito Servlet e respectivos objetos de aprendizagem associados	110
4.5	Parte do mapa conceitual de um curso de Programação Orientada a Objetos	111
4.6	Interface gráfica para testes	113
5.1	Atualização do ME no Experimento 1	126
5.2	Performances do estudante no Experimento 1	127
5.3	Médias de performances e problemas de aprendizagem no Experimento 1 .	127
5.4	Atualização do ME durante Experimento 2	128
5.5	Performances do estudante no Experimento 2	129
5.6	Médias de performances e problemas de aprendizagem no Experimento 2 .	130
5.7	Atualização do ME durante Experimento 3	131
5.8	Performances do estudante no Experimento 3	132
5.9	Médias de performances e problemas de aprendizagem no Experimento 3 .	133
5.10	Atualização do ME durante Experimento 4	134
5.11	Performances do estudante no Experimento 4	135

5.12	Médias de performances e problemas de aprendizagem no Experimento 4	135
5.13	Atualização do ME durante Experimento 5	136
5.14	Performances do estudante no Experimento 5	137
5.15	Médias de performances e problemas de aprendizagem no Experimento 5	138
5.16	Atualização do ME durante Experimento 6	139
5.17	Performances do estudante no Experimento 6	140
5.18	Médias de performances e problemas de aprendizagem no Experimento 6	140
5.19	Atualização do ME durante Experimento 7	141
5.20	Performances do estudante no Experimento 7	142
5.21	Médias de performances e problemas de aprendizagem no Experimento 7	143
5.22	Atualização do ME durante Experimento 8	144
5.23	Performances do estudante no Experimento 8	145
5.24	Médias de performances e problemas de aprendizagem no Experimento 8	145
5.25	Atualização do ME durante Experimento 9	146
5.26	Performances do estudante no Experimento 9	147
5.27	Médias de performances e problemas de aprendizagem no Experimento 9	148
5.28	Atualização do ME durante Experimento 10	148
5.29	Performances do estudante no Experimento 10	149
5.30	Médias de performances e problemas de aprendizagem no Experimento 10	150
5.31	Atualização do ME durante Experimento 11	151
5.32	Performances do estudante no Experimento 11	152
5.33	Médias de performances e problemas de aprendizagem no Experimento 11	152
5.34	Atualização do ME durante Experimento 12	153
5.35	Performances do estudante no Experimento 12	154
5.36	Médias de performances e problemas de aprendizagem no Experimento 12	155
5.37	Atualização do ME durante Experimento 13	156
5.38	Performances do estudante no Experimento 13	157
5.39	Médias de performances e problemas de aprendizagem no Experimento 13	157

5.40	Atualização do ME durante Experimento 14	158
5.41	Performances do estudante no Experimento 14	159
5.42	Médias de performances e problemas de aprendizagem no Experimento 14 .	159
5.43	Atualização do ME durante Experimento 15	160
5.44	Performances do estudante no Experimento 15	161
5.45	Médias de performances e problemas de aprendizagem no Experimento 15 .	162
5.46	Atualização do ME durante Experimento 16	163
5.47	Performances do estudante no Experimento 16	164
5.48	Médias de performances e problemas de aprendizagem no Experimento 16 .	164
5.49	Atualização do ME durante Experimento 16 com $\alpha = 0$	165
5.50	Performances do estudante no Experimento 16 com $\alpha = 0$	166
5.51	Médias de performances e problemas de aprendizagem no Experimento 16 com $\alpha = 0$	167
A.1	Atualização do ME no Experimento 1	204
A.2	Performances do estudante no Experimento 1	205
A.3	Médias de performances e problemas de aprendizagem no Experimento 1 .	205
A.4	Atualização do ME durante Experimento 2	206
A.5	Performances do estudante no Experimento 2	207
A.6	Médias de performances e problemas de aprendizagem no Experimento 2 .	207

Lista de Tabelas

3.1	Comparação entre os Modelos de Estilos de Aprendizagem	61
4.1	Modelo Estudante	86
4.2	Exemplo de Inicialização do ME utilizando o ILSQ	89
4.3	Exemplo de Inicialização do ME sem utilização do ILSQ	90
4.4	Distribuição de Probabilidades das CEAs	97
5.1	ME inicial	124
5.2	Resultados do Experimento 1	125
5.3	Resultados do Experimento 2	129
5.4	Resultados do Experimento 3	131
5.5	Resultados do Experimento 4	133
5.6	Resultados do Experimento 5	137
5.7	Resultados do Experimento 6	139
5.8	Resultados do Experimento 7	142
5.9	Resultados do Experimento 8	144
5.10	Resultados do Experimento 9	147
5.11	Resultados do Experimento 10	149
5.12	Resultados do Experimento 11	150
5.13	Resultados do Experimento 12	154
5.14	Resultados do Experimento 13	156
5.15	Resultados do Experimento 14	159

5.16	Resultados do Experimento 15	161
5.17	Resultados do Experimento 16	164
5.18	Resultados do Experimento 16 com $\alpha = 0$	166
A.1	ME inicial	203
A.2	Resultados do Experimento 1	204
A.3	Resultados do Experimento 2	206

Lista de Algoritmos

3.1	<i>Q-learning</i>	78
4.1	<i>Q-learning</i> aplicado à modelagem automática e dinâmica de EA	106

Sumário

1	Introdução	27
1.1	Objetivos	31
1.2	Justificativas	32
1.3	Metodologia	35
1.4	Estruturação da Tese	37
2	Trabalhos Relacionados e Estado da Arte	39
3	Referencial Teórico	51
3.1	Abordagens para Educação a Distância	51
3.2	Modelagem do Estudante	58
3.3	Estilos de Aprendizagem	60
3.3.1	Felder-Silverman Learning Style Model (FSLSM)	62
3.4	Processos Estocásticos e Cadeias de Markov	67
3.4.1	Cadeias de Markov	69
3.5	Aprendizagem por Reforço	73
3.6	Simulação Computacional de Estudantes	79
4	Abordagem Proposta	83
4.1	Modelo do Estudante	84
4.2	Módulo Pedagógico	91
4.3	Componente de Modelagem do Estudante	97

4.4	Arquitetura resultante da integração de um SAIE com a abordagem proposta	106
-----	--	-----

5 Verificação e Validação da Abordagem Proposta **115**

5.1	Metodologia Utilizada	115
5.2	Simulação de Aprendizagem em Estudantes	118
5.3	Experimentos e Análise dos Resultados Obtidos	123
5.3.1	Experimento 1	125
5.3.2	Experimento 2	128
5.3.3	Experimento 3	130
5.3.4	Experimento 4	133
5.3.5	Experimento 5	135
5.3.6	Experimento 6	138
5.3.7	Experimento 7	141
5.3.8	Experimento 8	143
5.3.9	Experimento 9	145
5.3.10	Experimento 10	147
5.3.11	Experimento 11	150
5.3.12	Experimento 12	152
5.3.13	Experimento 13	155
5.3.14	Experimento 14	157
5.3.15	Experimento 15	160
5.3.16	Experimento 16	162

6 Conclusões e Trabalhos Futuros **171**

Referências Bibliográficas **180**

A Experimentos considerando DEA=0 no ME inicial **203**

A.1	Experimento 1	204
A.2	Experimento 2	206

Capítulo 1

Introdução

Atualmente, os sistemas de gestão de aprendizagem, ou *Learning Management Systems* (LMS), fornecem grande apoio aos professores, visando auxiliá-los na autoria e realização de cursos *on-line*. Porém estes sistemas normalmente não consideram as diferenças individuais dos estudantes na composição e na estrutura de cursos. Eles fornecem somente um suporte limitado aos estudantes, e poucos sistemas são capazes de adaptar o conteúdo do curso a um estudante específico (Graf e Kinshuk, 2010a). De acordo com Lopes e Fernandes (2009), muitos dos sistemas de *e-learning* não consideram as características particulares dos estudantes e o mesmo conteúdo e estratégia pedagógica são comumente usadas para todos os estudantes.

Neste contexto, os tradicionais LMS fornecem exatamente o mesmo curso para cada estudante, incluindo a estrutura, composição e conteúdo, a exemplo de alguns sistemas amplamente conhecidos e utilizados, como Blackboard (Blackboard, 2010), WebCT (WebCT, 2010), SOLAR (SOLAR, 2012), Desire2Learn (Desire2Learn, 2012), DeskEaD (Silva et al., 2003), TelEduc (TelEduc, 2012) e Moodle (Moodle, 2010), não oferecendo nenhum nível de personalização. Mas, de acordo com Graf e Kinshuk (2010a), considerar diferenças em relação a, por exemplo, conhecimento prévio, estilos de aprendizagem, habilidades cognitivas, interesses, motivação, dentre outras (Brusilovsky e Millan, 2007), tem um efeito importante na melhoria do progresso dos estudantes e nos resultados de

aprendizagem. Desta forma, teorias pedagógicas modernas afirmam a necessidade de personalizar o curso, e sempre que possível atender as características de aprendizagem do estudante. Sistemas de aprendizagem adaptativos tratam exatamente deste problema, e visam, considerando características dos estudantes e necessidades individuais, adequar cursos, material didático e estratégias de aprendizagem a cada estudante.

Então, uma característica importante em Educação a Distância (EAD) é a assistência personalizada e inteligente, em que um relevante aspecto a ser observado é que estudantes neste tipo de curso podem apresentar perfis bastante diferenciados. Sendo assim, um determinado curso, projetado para um determinado estudante, pode não ser adequado a outros estudantes. Em virtude disto, um desafio em pesquisa é o desenvolvimento de aplicações educacionais avançadas, que possam oferecer algum grau de inteligência e adaptatividade.

Nesta perspectiva, com o objetivo de personalizar o processo de aprendizagem, um movimento crescente em direção à introdução de adaptatividade nestes sistemas pode ser observado nos últimos anos, a exemplo de diversos trabalhos¹, originando os chamados Sistemas Adaptativos e Inteligentes para Educação (SAIE) (Brusilovsky, 2001a; Brusilovsky e Peylo, 2003). Estes sistemas não representam uma categoria totalmente nova de sistemas educacionais, possuindo raízes em duas áreas: Sistemas Tutores Inteligentes (STI) e Sistemas de Hipermídia Adaptativa (SHA) (Iglesias et al., 2009a).

Os SAIE são em princípio superiores aos sistemas tradicionais de *e-learning*, na medida em que personalizam a experiência educacional. Sistemas educacionais que se adaptam às características individuais de um estudante tornam o processo de aprendizagem mais efetivo (Brusilovsky, 2001a). Nestes sistemas, o conteúdo é fornecido em conformidade com diversos aspectos. A adaptação nestes sistemas é tradicionalmente di-

¹Stern e Woolf (2000); Grigoriadou et al. (2001); Weber e Brusilovsky (2001); Wu (2002); Dorça et al. (2002); Queiroz, B. and Lopes, C. R. and Fernandes M. A. (2002); Dorça et al. (2003); Cristea e de Mooij (2003); Dorça (2004); Dorça et al. (2004); Karagiannidis e Sampson (2004); Benadi et al. (2004); Cristea (2005); Cristea e Stash (2006); De Bra et al. (2006); Paredes e Rodriguez (2006); Cristea (2007); Brown (2007); Graf e Kinshuk (2007); Sangineto et al. (2008); Limongelli et al. (2009); Graf e Kinshuk (2009a); Dorça et al. (2009); Lopes (2009); Botsios, S. and Georgiou, D. and Safouris, N. (2008); Iglesias et al. (2009a,b); Graf e Kinshuk (2010a); Graf et al. (2010)

vidida em adaptação de suporte à navegação e adaptação de apresentação de conteúdo (Wu et al., 2001; Brusilovsky, 1996; Wu, 2002; Brusilovsky e Peylo, 2003). De acordo com Tsiriga e Virvou (2004), adaptatividade é uma característica indispensável nestes sistemas, possibilitando o alcance de um grupo muito mais heterogêneo de estudantes. O mecanismo para personalização em SAIE é objeto de intensa pesquisa e discussão por parte de pesquisadores de uma diversidade de áreas.

Desta forma, muito se tem discutido sobre a modelagem do estudante (Brusilovsky e Millan, 2007; Martins et al., 2008; Graf et al., 2009a; Graf e Viola, 2009; Castillo et al., 2005; Souza, 2002; Gogvadze et al., 2011; Virvou e Troussas, 2011) baseada em Estilos de Aprendizagem (EA), de forma que preferências psicológicas são armazenadas em bases de dados e então utilizadas no fornecimento de estratégias de ensino personalizadas (Brown et al., 2006). Para Reid (1998), EA são características básicas de como se aprende uma nova informação, e não são perceptíveis de forma consciente pelos estudantes.

EA (Graf e Liu, 2008) e seus efeitos no processo de aprendizagem são cuidadosamente examinados por Coffield et al. (2009). EA, as correspondentes estratégias instrucionais, e sua contribuição na construção de SAIE têm sido intensamente estudadas. Graf et al. (2009a) afirmam que conhecer EA dos estudantes pode ajudar de muitas formas a melhorar o ensino e a aprendizagem nestes sistemas.

Ainda, muitos teóricos e pesquisadores da educação consideram que EA compõem um fator importante no processo de aprendizagem, e concordam que incorporá-los ao processo de ensino tem grande potencial na facilitação da aprendizagem (Graf et al., 2009a). De acordo com Bostrom (2011), a única maneira de melhorar o desempenho é melhorar o ensino. Se o sistema dá suporte a elevada qualidade de ensino, bons resultados são alcançados. De acordo com Gilbert e Han (1999), todos nós temos preferências de aprendizagem que nos permitem aprender de forma mais eficaz. Quando inseridos num ambiente de aprendizagem que apoia os seus estilos de aprendizagem, estudantes têm um maior nível de compreensão.

Desta forma, a modelagem do estudante exerce papel fundamental. Lopes e Fernan-

des (2009) atestam que EA são um dos mais importantes aspectos a serem considerados na modelagem do estudante. Pesquisadores da área sugerem que relacionar EA com estratégias de ensino apropriadas é um fator importante ao estímulo da aprendizagem, conforme alerta Coffield et al. (2009).

Um grande número de estudos atesta que a aprendizagem é facilitada se as estratégias pedagógicas estiverem de acordo com os EA do estudante, e afirmam que utilizar material e atividades instrucionais que vão ao encontro dos EA, torna o processo de aprendizagem mais efetivo e a performance do estudante é consideravelmente melhorada, conforme apresentado em diversos trabalhos². Neste contexto, a personalização automática de conteúdo baseada em EA é um aspecto fundamental em SAIE, sendo esta, atualmente, uma área sob intensa investigação e com grandes perspectivas de aplicação no fornecimento de adaptatividade neste tipo de sistema.

Brown et al. (2006) examinam como EA podem ser utilizados em SAIE com o objetivo de criar experiências individualizadas aos usuários. Alfonseca et al. (2006) discutem as principais questões relacionadas à aplicação de EA em SAIE. Na ocasião, é realizada uma análise sobre o impacto do uso de EA no processo de ensino, e também se descreve como estes sistemas podem tirar vantagem do uso de informações relacionadas à EA.

Brown et al. (2006) pontuam que novos métodos de adaptação têm sido propostos em uma tentativa de se aumentar a sofisticação e validade pedagógica do Modelo do Estudante (ME)(Brusilovsky e Millan, 2007). Desta forma, diversas pesquisas têm investigado como EA podem ser utilizados para fornecer conteúdo personalizado ao estudante. Conforme analisa Franzoni e Assar (2009), vários SAIE que levam em consideração EA dos estudantes têm sido criados. Conforme exposto por Franzoni e Assar (2009), uma das maiores dificuldades no desenvolvimento destes sistemas é o relacionamento de EA com as aplicações e recursos de hipermídia.

A maioria destes sistemas são baseados na noção de que relacionar estratégias de

² Haider et al. (2010); Graf et al. (2008); Kinshuk et al. (2009); Graf e Kinshuk (2009a); Graf e Liu (2008); Coffield et al. (2009); Alfonseca et al. (2006); Graf e Lin (2007); Graf e Kinshuk (2007); Bajraktarevic et al. (2003); Sangineto et al. (2008); Terry et al. (1995); Friedel e Rudd (2006); Vasilyeva et al. (2006); Graf et al. (2009a); Stash et al. (2004)

ensino com EA melhoram a performance dos estudantes. De acordo com Franzoni e Assar (2009), diferentes possibilidades existem para adaptar um curso aos EA dos estudantes. Ainda, conforme analisado por Franzoni e Assar (2009), a estratégia mais utilizada é relacionar diferentes tipos de mídias e materiais instrucionais às preferências e habilidades dos estudantes. Esta abordagem tem como objetivo imediato tornar o processo de aprendizagem mais adequado a cada estudante.

A capacidade de personalizar um curso aos EA de um estudante particular é apontada pela IMS Global Learning Consortium como um dos aspectos principais de um SAIE, conforme asseguram Sangineto et al. (2008).

1.1 Objetivos

Para que seja possível considerar EA em SAIE, é necessário conhecê-los primeiro. Então, o objetivo principal deste trabalho é apresentar uma abordagem estocástica para fornecimento de adaptatividade e personalização através da modelagem probabilística de EA do estudante, levando em consideração os resultados de suas performances enquanto utiliza o sistema para aprender.

Especificamente, a abordagem proposta tem por objetivo detectar e corrigir, de forma automática e dinâmica, inconsistências no ME em relação às preferências reais do estudante, no que diz respeito aos seus EA, considerando-se que as preferências obtidas através de questionários psicométricos podem necessitar de revisões, por possuírem certo grau de incerteza.

Então, ao identificar automaticamente os EA do estudante, torna-se possível a eliminação da necessidade de utilização de questionários psicométricos (Felder e Spurlin, 2005) para inicialização do ME. Tais questionários invariavelmente demandam conhecimento meta-cognitivo, além de tempo e paciência dos estudantes em seu preenchimento.

Uma característica da abordagem proposta neste trabalho é que o ME é atualizado automática e dinamicamente através de um processo estocástico (Pollard, 1984) iterativo e

interativo baseado na Combinação de Estilos de Aprendizagem (CEA) (Franzoni e Assar, 2009) e clusterização probabilística dos estudantes em categorias pedagógicas. Um questionário para auto-avaliação de EA, como o ILSQ (Index of Learning Styles Questionnaire) (Van Zwanenberg et al., 2000), pode ser aplicado inicialmente para inicializar o ME, mas isto não é obrigatório, já que o objetivo é criar uma abordagem que seja independente deste tipo de ferramenta.

Desta forma, o objetivo central deste trabalho é o diagnóstico automático e dinâmico de EA dos estudantes em SAIE, possibilitando a estes sistemas a seleção de estratégias pedagógicas (Iglesias et al., 2009a,b) mais apropriadas aos estudantes durante o processo de fornecimento de adaptatividade. Outro objetivo importante é considerar os aspectos não-estacionário e não-determinístico de EA, sabendo-se que EA podem sofrer alterações durante o processo de aprendizagem (não-estacionário), de forma não esperada e imprevisível (não-determinístico) (Graf e Kinshuk, 2009a; Graf et al., 2010). Desta forma, a abordagem proposta neste trabalho possibilita que SAIE aprendam incrementalmente sobre os EA dos estudantes, atualizando-os constantemente de acordo com o desempenho global do estudante.

Com o objetivo de possibilitar que a abordagem apresentada neste trabalho seja utilizada em qualquer LMS existente, um aspecto fundamental é que ela seja independente de um sistema específico, possibilitando sua fácil reutilização na construção de SAIE. Isto é obtido na abordagem proposta, já que esta não é baseada em recursos específicos de nenhum LMS específico. Com este intuito, apresenta-se neste trabalho um algoritmo e uma arquitetura gerais que mostram como a abordagem proposta se insere no contexto de um SAIE.

1.2 Justificativas

Para Trif et al. (2010), uma das principais características de SAIE é a identificação correta e contínua dos estilos de aprendizagem do estudante, com intuito de se proporcionar a

apresentação de conteúdo mais adequada a cada indivíduo. Mas, as abordagens tradicionais para detecção de EA se mostram ineficientes. Graf e Lin (2007) e Price (2004) comentam sobre a imprecisão e o grau de incerteza associados à questionários psicométricos para auto-avaliação de EA, como o ILSQ, em decorrência da dificuldade de auto-concepções pelo estudante, por demandarem conhecimento meta-cognitivo (Felder e Spurlin, 2005), além de tempo e paciência em seu preenchimento.

Então, as preferências obtidas através de questionários psicométricos podem necessitar de revisões, por possuírem certo grau de incerteza, conforme pode-se observar em análise desenvolvida por Price (2004), que identificou inconsistências entre os resultados dos questionários e o comportamento exibido pelo estudante. Em concordância com Price (2004), Roberts e Erdos (1993) tece um panorama sobre a aplicação, confiabilidade e validade do ILSQ, alertando sobre a limitação de testes psicométricos para detecção de EA.

De acordo com Graf et al. (2009a), abordagens automáticas para modelagem do estudante são livres de ocorrência de auto-concepções imprecisas ou inconsistentes. Além disto, permitem aos estudantes focar somente na aprendizagem, sem a necessidade de informar explicitamente suas preferências. Ainda, abordagens automáticas tendem a ser mais precisas e menos suscetíveis a erros, já que permitem analisar dados resultantes de um intervalo de tempo, ao invés de dados colhidos em um momento específico.

Neste contexto, abordagens automáticas para detecção de EA trazem diversas vantagens ao eliminar a necessidade de aplicação de questionários psicométricos, livrando o ME de auto-concepções imprecisas. Dependendo do tipo de público, este problema pode ocorrer em maior ou menor grau (Graf e Liu, 2008; Graf et al., 2009a; Graf e Viola, 2009; Graf e Kinshuk, 2010b; García et al., 2007; Graf, 2006). Desta forma, diversas abordagens para modelagem automática de EA têm sido propostas. Porém, tais abordagens apresentam uma diversidade de problemas que dificultam sua implementação, implantação e utilização, conforme analisa-se no capítulo 2 deste trabalho.

Além disto, Jones et al. (2003) detectaram em seu trabalho que EA podem ser

sensíveis ao domínio do conhecimento ou a outros aspectos. Na ocasião, observou-se que estudantes podem tender de um EA a outro, dependendo das estratégias de aprendizagem requeridas em uma situação particular. Isto torna ineficaz a utilização de técnicas estáticas para detecção de EA, já que na modelagem estática do estudante o ME é inicializado apenas uma vez, usualmente quando o estudante se cadastra no sistema.

Desta forma, é importante considerar que estas características são de algum modo dinâmicas, tornando necessário ajustar continuamente o ME para que se possa garantir sua permanente consistência, o que normalmente não é considerado (Graf et al., 2010). De acordo com Giraffa (1999) um modelo realista do aluno implica em uma atualização dinâmica enquanto o sistema avalia o desempenho do estudante.

De acordo com Graf e Lin (2007), um problema com abordagens automáticas é a obtenção de informação suficientemente confiável para se construir um ME robusto. Além disto, de acordo com Danine et al. (2006), a construção deste tipo de abordagem, fundamentada em um modelo probabilístico, é um importante problema em pesquisas. Isto porque estas abordagens necessitam lidar com informações incompletas ou incertas. Esta incerteza possui diversas razões: dificuldades na obtenção de informações, possibilidade de erros ou inconsistência nos dados, ambiguidade na representação da informação e incerteza sobre as relações entre as informações.

Em consequência deste cenário, o processo de adaptatividade fornecido por um SAIE precisa levar em consideração um certo nível de incerteza. As incertezas podem estar relacionadas ao conhecimento do estudante, seus EA e uma diversidade de outras características e preferências. Por isto, acreditamos fortemente que considerar processos estocásticos na modelagem do estudante, é essencial. Desta forma, propõe-se neste trabalho uma abordagem contrária às tradicionais abordagens determinísticas para modelagem de EA. O objetivo é possibilitar que SAIE possam, de forma eficiente, detectar precisamente os EA dos estudantes, eliminando diversos problemas discutidos no capítulo 2, ignorados por outras abordagens desenvolvidas até o momento.

1.3 Metodologia

O desenvolvimento deste trabalho se deu através de 3 componentes principais: o ME, o Módulo Pedagógico (MP) e o Componente de Modelagem do Estudante (CME), desenvolvidos nesta ordem, em decorrência da relação de dependência existente entre eles.

Em linhas gerais, a cada seção de aprendizagem, uma estratégia para provimento de adaptatividade é estocasticamente escolhida pelo MP, levando em conta os EA do estudante, armazenados em um ME probabilístico que considera as incertezas relacionadas à detecção automática de EA. Sem ter certeza do estado real do estudante em relação aos EA, não há também certeza de como estas escolhas influenciarão em seu desempenho. Este processo foi modelado através de Cadeias de Markov (Meyn et al., 2009), devido à sua simplicidade e aderência ao objetivo proposto.

À medida que o processo de aprendizagem evolui, o ME é atualizado pelo CME através de um método baseado em Aprendizagem por Reforço (AR) (Tesauro, 1995; Kaelbling et al., 1996; Russel e Norvig, 2004; Abramson e Wechsler, 2001; Iglesias et al., 2009a,b), tornando este processo cada vez mais bem adaptado ao estudante, e exercendo impacto positivo em sua performance, conforme apresentado neste trabalho através de resultados de diversos experimentos.

A teoria de EA que dá suporte a este trabalho é o modelo de EA proposto por Felder e Silverman (1988), o Felder-Silverman's Learning Styles Model (FSLSM). Diversas razões nortearam sua escolha, e tais razões são detalhadamente apresentadas no capítulo 3. Fundamentalmente, é importante considerar neste momento que o FSLSM considera EA como tendências, ou seja, estudantes possuem uma tendência por um EA, mas podem, conforme afirmam Kinshuk et al. (2009), agir diferente em situações particulares, ou seja, de forma não-determinística, o que é uma característica fundamental dos processos estocásticos, um dos pilares da abordagem proposta neste trabalho. Ainda, de acordo com Kinshuk et al. (2009), ao incorporar o conceito de tendências, a descrição de EA também permite considerar comportamento excepcional ou desvios comportamentais do estudante.

Desta forma, o FSLSM coloca em evidência o não-determinismo inerente ao comportamento do estudante, que passa a ser visto como probabilístico ao invés de determinístico, cujas probabilidades são dadas pelos pesos das preferências de EA em cada uma das quatro dimensões do FSLSM. Esta característica é um ponto fundamental para nossa abordagem, e outras teorias de EA não permitiriam sua implementação de forma tão direta como foi realizado neste trabalho. Ou seja, utilizar escalas que podem variar no tempo ao invés de tipos rígidos é uma característica crucial do FSLSM para a nossa abordagem, que é baseada em distribuições de probabilidades e processos estocásticos, conforme apresentado detalhadamente no capítulo 4. O FSLSM assume que estas tendências são mais ou menos estáveis mas podem se alterar ao longo do tempo, independentemente do domínio, que é uma questão intrinsecamente tratada pelo ME, MP e CME. Desta forma, consideramos EA dos estudantes como probabilidades no modelo quadridimensional de Felder-Silverman.

Mas, é importante ressaltar que o fato da abordagem proposta neste trabalho ser baseada em aprendizagem por reforço, que tem como característica fundamental a não utilização de conhecimento específico do domínio de aplicação, torna o método genérico, podendo este ser aplicado considerando-se outras teorias de estilos de aprendizagem.

Os experimentos foram realizados através da simulação de aprendizagem em estudantes com diferentes preferências de EA, considerando-se as 4 dimensões do FSLSM. Isto permitiu observar nitidamente o comportamento do modelo proposto em diferentes contextos e situações. Duas variáveis foram observadas e analisadas nos experimentos realizados: a consistência (os EA armazenados no ME convergiram eficientemente e se tornaram consistentes durante o processo de aprendizagem?) e a eficiência (convergiram em tempo razoável, tornando-se consistentes no início do processo de aprendizagem?). Os resultados obtidos através de experimentos, e apresentados no capítulo 5, mostram que, considerando-se essas variáveis, a abordagem proposta neste trabalho apresenta soluções aos problemas apontados neste capítulo, que são discutidos mais detalhadamente no capítulo 2.

1.4 Estruturação da Tese

Os demais capítulos que compõem esta tese são descritos a seguir. O capítulo 2 apresenta o estado da arte e analisa alguns dos principais trabalhos relacionados. O capítulo 3 apresenta o referencial teórico que fornece o embasamento conceitual à abordagem apresentada neste trabalho. O capítulo 4 apresenta em detalhes a implementação da abordagem proposta. O capítulo 5 apresenta e analisa os resultados obtidos através de uma diversidade de experimentos. Finalmente, o capítulo 6 apresenta as conclusões e discute trabalhos futuros.

Capítulo 2

Trabalhos Relacionados e Estado da Arte

Muitos SAIE que fornecem adaptatividade considerando EA utilizam questionários psicométricos para modelagem do estudante (abordagens estáticas e colaborativas). Recentemente, tem havido um incremento em pesquisas relacionadas ao desenvolvimento de abordagens para modelagem automática do estudante, levando-se em consideração seu comportamento, tal como propõe Virvou e Troussas (2011). Entretanto, estas abordagens tipicamente utilizam um conjunto pré-definido de dados comportamentais para modelagem do estudante, e não atualizam este modelo ao longo do curso, configurando, então, abordagens estáticas. Um número muito reduzido de pesquisas tem sido conduzidas na modelagem dinâmica e automática de EA do estudante (Graf et al., 2010).

Alguns trabalhos recentes têm apresentado propostas para detecção automática de EA (Cha et al., 2006b,a; Graf e Liu, 2008; Graf e Kinshuk, 2010b; Graf et al., 2009a; Graf e Viola, 2009; Limongelli et al., 2009). Estas propostas utilizam sistemas de inferência determinísticos baseados em padrões de comportamento pré-definidos do estudante, de forma que através de seu comportamento e ações no sistema, possam inferir seus EAs. Graf et al. (2009a); Graf e Viola (2009) discutem padrões de comportamento considerados relevantes para identificação de cada EA.

Limongelli et al. (2009) consideram uma abordagem que inicializa o ME através do ILSQ e, automática e dinamicamente, atualiza o ME de acordo com as características de EA inerentes a um nó de conhecimento, considerando o tempo gasto pelo estudante no nó e a pontuação obtida no pós-teste. Problemas com esta abordagem são a obrigatoriedade do uso do ILSQ e a característica determinística do processo de inferência de EA.

Graf e Liu (2008) apresentam uma abordagem para modelagem automática e estática de EA com base no FSLSM. Para isto, considera a observação das ações dos estudantes durante o curso, a fim de recolher pistas sobre seus EA. Para isto utiliza um mecanismo simples baseado em regras, que infere de forma determinística os EA com base nas pistas recolhidas. Uma vez inferido os EAs, eles não são mais atualizados, o que configura uma abordagem estática.

Em (Graf et al., 2010) esta abordagem adquire aspecto dinâmico, porém continua considerando a utilização de regras simples para realizar inferências determinísticas a respeito de EA dos estudantes. Uma crítica a estas abordagens é a dificuldade em se construir regras capazes de inferir eficientemente EAs a partir do comportamento do estudante, devido à sua complexidade e grande quantidade. Graf e Viola (2009) asseveram que estudantes com EAs diferentes se comportam de forma diferente em um SAIE. Mas, como garantir que dois estudantes diferentes, demonstrando o mesmo comportamento, possuem os mesmos EAs, já que uma diversidade de outros fatores podem influenciar em seus comportamentos, conforme alerta uma grande quantidade de pesquisas (Brusilovsky et al., 1998; Zakaria e Brailsford, 2002; Wu et al., 2001; Graf e Kinshuk, 2009a; Clifford, 2004; De Bra e Calvi, 1998; Brusilovsky et al., 1996a; Hook et al., 1997; Chen e Macredie, 2002; Jones et al., 2003).

Desta forma, fica claro a existência de uma grande quantidade de fatores e variáveis envolvidas na construção de um conjunto de regras determinísticas com este objetivo. Além disto, em muitos sistemas, tal como o AHA! (De Bra et al., 2006), estas regras precisam ser definidas pelo tutor, já que sua construção depende do seu conhecimento específico e do domínio do conhecimento do curso, o que sem dúvida cria um grande

empecilho quanto à utilização deste tipo de abordagem.

Ainda, outra crítica a estas abordagens é que elas apresentam um alto nível de acoplamento ao sistema para o qual foram desenvolvidos, já que são construídas levando em consideração os recursos e características específicos de um LMS. Graf e Liu (2008) propõe uma abordagem passível de ser aplicada em diversos LMSs, mas para isto considera apenas recursos e características comuns a todos eles, o que limita e dificulta ainda mais a expressão de padrões e regras de comportamento, e as torna ainda mais suscetível a inconsistências.

Além disto, sistemas de inferência determinísticos, baseados em padrões de comportamento pré-definidos, ignoram importantes considerações apresentadas por Graf e Liu (2008); Marzano e Kendall (2007); Messick (1976); Graf e Lin (2007); Van Zwanenberg et al. (2000); Felder e Spurlin (2005); Roberts e Erdos (1993) relacionadas aos aspectos dinâmicos e não-determinísticos de EA e do comportamento do estudante. Neste contexto, a abordagem apresentada neste trabalho apresenta avanços ao considerar de forma probabilística os EAs dos estudantes.

Abordagens diferentes são apresentadas em diversos trabalhos¹. Estas abordagens utilizam técnicas de aprendizagem supervisionada de máquina, tais como redes Bayesianas e redes neurais. Uma crítica a estas abordagens é sua alta complexidade de implementação e grande consumo de recursos computacionais, de forma que a presença simultânea de vários estudantes pode comprometer, ou mesmo inviabilizar seu uso.

Abordagens baseadas em redes Bayesianas apresentam consequentemente os problemas que incorrem de seu uso, por exemplo, dificuldades na representação (escolha do conjunto de variáveis relevantes que podem ser consideradas para descrever o comportamento do estudante, escolha de uma ordenação para as variáveis), demasiadas probabilidades, probabilidades não intuitivas, elevada complexidade e alto custo computacional na aprendizagem e na inferência (através de propagação de probabilidades e evidências,

¹ Kelly e Tangney (2005); García et al. (2007); Carmona e Castillo (2008); Cabada et al. (2009); Zatarain-Cabada et al. (2009); Zatarain et al. (2010); Carmona et al. (2007a,b); Stern e Woolf (2000); Castillo et al. (2005); Yannibelli et al. (2006); Villaverde et al. (2006); Murray et al. (2001); Safouris et al. (2007); Botsios e Georgiou (2008)

implementada através de diversas políticas). A aprendizagem de redes Bayesianas consiste em induzir, a partir de uma amostra de dados, as distribuições de probabilidades simples e condicionais, e identificar as relações de interdependência entre as variáveis de um domínio de dados, que se constitui na população de interesse. Mas, em se considerando comportamento do estudante e EA, a obtenção desta amostra de dados é, além de complexa, duvidosa, pois gera uma massa de dados com alto nível de incerteza e que pode conter inconsistências, o que pode resultar em treinamento equivocado da rede. A mesma observação deve ser considerada para abordagens que utilizam redes neurais.

Além disto, em geral estas abordagens apresentam um alto nível de acoplamento ao sistema para o qual foram desenvolvidos, tornando tais abordagens difíceis de se reutilizar em outros sistemas, já que consideram recursos específicos de um LMS específico. Em algumas destas abordagens, por exemplo em Castillo et al. (2005), uma vez inferidos, os EA do estudante permanecem os mesmos ao longo de todo o processo de aprendizagem, o que não condiz com sua natureza dinâmica.

Outro problema das técnicas de aprendizagem supervisionada de máquina são as complicações originadas pela ocorrência de *concept drift* e *concept shift* (Castillo et al., 2005), que surgem quando os dados para aprendizagem (pares de treinamento) são coletados durante um longo período de tempo, e mudanças ocorrem na distribuição destes dados, requerendo técnicas complexas para detecção e reajuste do processo de aprendizagem. Isto ocorre quando, durante o processo de ensino-aprendizagem, as preferências do estudante sofrem alterações (graduais ou abruptas), se tornando diferentes daquelas anteriormente determinadas (Castillo et al., 2005).

Como é explicado por Castillo *et al* (Castillo et al., 2005), técnicas de aprendizagem supervisionada assumem a estabilidade do conceito alvo. Então, em muitos problemas do mundo real, quando dados são coletados através de um longo período de tempo, a aprendizagem pode ser complicada por alterações nos dados ou mudanças no próprio conceito alvo. Este problema é conhecido como *concept drift*. Conforme afirmam Castillo et al. (2005), estes cenários requerem algoritmos de aprendizagem incremental, capazes de

ajustarem rapidamente a aprendizagem do conceito alvo. Dependendo da taxa com que ocorrem tais alterações, pode-se distinguir *concept drift* (mudanças graduais) de *concept shift* (mudanças abruptas) (Castillo et al., 2005).

Este tipo de problema ocorre porque os EAs diagnosticados precisam ser ajustados, ou porque os EAs do estudante se alteraram por alguma razão. Conforme alertam Castillo et al. (2005); Graf e Kinshuk (2009a); Graf et al. (2010), durante a interação com o sistema, o estudante pode ter seus EAs alterados, passando a ter preferências diferentes, em algum aspecto, daquelas inicialmente determinadas. Desta forma, acredita-se que técnicas de aprendizagem supervisionadas também não sejam aderentes ao problema que se propõe solucionar neste trabalho. Este contexto reforça ainda mais a consideração de que técnicas não-determinísticas sejam mais aderentes ao cenário do diagnóstico automático de EAs.

Especificamente, García et al. (2007) propõe um modelo baseado em uma rede Bayesiana, onde os nós da rede representam os diferentes comportamentos do estudante que determinam um dado EA. Os arcos representam os relacionamentos entre um EA e os fatores que o determinam. As informações utilizadas na construção do modelo foram obtidas através da análise de arquivos de *logs* dos estudantes, contendo registros das tarefas executadas pelos estudantes no sistema e sua participação em atividades, tais como *chat* e fóruns. Neste contexto, destaca-se aqui a elevada dificuldade e o alto grau de subjetividade na tarefa de se relacionar EA e os fatores que o identificam no estudante, conforme observa García et al. (2007).

Safouris et al. (2007) apresentam um sistema especialista baseado em redes Bayesianas que leva em consideração respostas de estudantes à questionários específicos, e também a classificação de estudantes que tenham sido previamente examinados, ou seja, conhecimento previamente acumulado. Mas se o processo de aprendizagem e comportamento são individuais, particulares a cada estudante, entendemos que não é coerente a utilização de conhecimento adquirido através da classificação de outros estudantes. Além disto, esta abordagem utiliza também *Fuzzy Cognitive Maps*, que incorpora complexidade adicional ao modelo, já que utilizam variáveis linguísticas, cujos valores precisam ser ma-

peados em funções de pertinência. O trabalho não apresenta resultados de experimentos que comprovem sua eficácia, e apenas alega que a abordagem parece funcionar.

Yannibelli et al. (2006) apresenta um algoritmo genético para identificar automaticamente EA baseado nas ações que o estudante executa durante o curso. O algoritmo tenta detectar as combinações de ações que o estudante frequentemente executa para aprender. Uma combinação de ações preferida pelo estudante é, então, mapeada em EA. Um problema com esta abordagem é a dificuldade em se mapear ações em EA, tratando o comportamento do estudante como evidências, e não como possibilidades.

Acredita-se que o conjunto de fatores e características comportamentais que indicam certas preferências não é necessariamente um padrão, pois não atuam da mesma forma em todos os estudantes. Então, propõe-se aqui que a maneira mais coerente de se identificar EA seria pela observação do desempenho global (resultado da avaliação do comportamento e do conhecimento) Lopes et al. (2008a) do estudante e, conseqüentemente, a modelagem evolutiva dos seus EA ao longo de um curso.

Também, as abordagens analisadas prezam a identificação de padrões comportamentais do estudante, e sua utilização na geração da próxima página de conteúdo, sendo, então, fortemente determinísticas, desprezando a natureza estocástica do comportamento e desempenho do estudante e da própria individualidade do processo de aprendizagem, já que inúmeros fatores (muitos desconhecidos) podem influenciar neste desempenho e variar de um estudante para outro. Tais abordagens exigem a identificação de um conjunto considerável de atributos capazes de representar adequadamente todos os possíveis padrões de comportamento dos estudantes. Nota-se certa dificuldade em identificar tais padrões e garantir que eles realmente representem o comportamento de todos os estudantes, em qualquer curso, e em qualquer circunstância.

Além disto, tais abordagens não expõem de forma clara como são obtidos tais padrões, e como são aplicados na construção de uma rede Bayesiana, no treinamento de uma rede neural, ou na criação de regras para inferência determinística de EA. Pela própria natureza destas abordagens, uma dificuldade inerente está em lidar com desvios de

comportamento dos alunos, por considerar padrões de comportamento de forma determinística na descoberta de EA, gerando a necessidade de se criar políticas complexas, como se observa em (Graf e Kinshuk, 2009b), na tentativa de manipular tais desvios de forma que não incorram na modelagem inconsistente do estudante. Considerar a ocorrência e manipular tais desvios adequadamente é um aspecto importante na modelagem dinâmica de EA do estudante, conforme apontado por Graf e Kinshuk (2009b).

Acredita-se que, neste contexto, uma abordagem estocástica que aprenda de forma não supervisionada, devido à sua própria natureza, elimina diversas dificuldades e problemas encontrados no processo de modelagem automática e dinâmica de EA, sendo, então, mais eficiente por considerar o aspecto não-determinístico inerente ao comportamento e desempenho do estudante e não utilizar inferências determinísticas no diagnóstico de EA, além de considerar que:

- vários fatores influenciam no comportamento e desempenho do estudante, e não apenas EA. Alguns destes fatores são delineados por Brusilovsky et al. (1998); Zakaria e Brailsford (2002); Wu et al. (2001); Graf e Kinshuk (2009a); Clifford (2004); De Bra e Calvi (1998); Brusilovsky et al. (1996a); Hook et al. (1997); Chen e Macredie (2002). Desta forma, acredita-se aqui que tal cenário dificulta, ou até mesmo impede, a realização de inferências determinísticas a cerca de EA do estudante diante de seu comportamento;
- não se pode ter certeza da influência que cada dimensão do FSLSM tem no desempenho e comportamento de um estudante, e se influenciam da mesma forma todos os estudantes (Botsios, S. and Georgiou, D. and Safouris, N., 2008);
- não se sabe como as preferências por EA de um estudante podem mudar ao longo do tempo, ou se esta mudança estará associada a outros fatores, por exemplo, conforme apontado por (Jones et al., 2003), o domínio sendo estudado. Isto torna os processos determinísticos, tal como aquele proposto por (Graf e Liu, 2008), mais suscetíveis a erros e inconsistências no processo de modelagem do estudante, já que suas regras

de inferência consideram a existência de um mesmo padrão de comportamento, independentemente do estudante, do tempo e do domínio de conhecimento sendo estudado;

- diante do resultado de um questionário psicométrico, é impossível saber o quão coerente está o resultado obtido. Além disto, um sistema que use um processo de adaptação determinístico tende a levar mais tempo na detecção de inconsistências, já que não analisa o desempenho do estudante frente a outros EAs que não aqueles previamente obtidos, o que dificulta a convergência do ME e a obtenção das preferências reais do estudante;
- não apenas a evolução das preferências de EA, mas vários outros aspectos do ME, tal como o grau de conhecimento do domínio, evoluem de maneira não-determinística, reforçando a natureza estocástica do processo de ensino-aprendizagem.

Desta forma, conclui-se que os trabalhos aqui analisados não abordam adequadamente o problema da modelagem automática e dinâmica de EA devido à utilização de inferência determinística, procurando determinar as preferências do estudante através dos tipos de conteúdos acessados, utilização de ferramentas de trabalho em grupo, estilo de navegação, dentre outros. Acredita-se aqui que este tipo de processo é mais suscetível a erros, primeiro pela quantidade de variáveis envolvidas e complexidade em sua análise, segundo por que geram atualizações determinísticas no ME de acordo com o comportamento do estudante, de forma que consideram que certo tipo de ação do estudante é determinante na identificação de certa preferência, o que acredita-se aqui ser uma questão mais complexa, devido às razões expostas anteriormente, o que torna um processo determinístico ineficaz neste contexto. Além disto, algumas abordagens analisadas nem mesmo se baseiam em alguma teoria educacional conhecida de EA, sendo baseados apenas em preferências (Chen e Macredie, 2002).

Pelo exposto, são vantagens da abordagem apresentada neste trabalho:

- eliminar a necessidade de se utilizar técnicas de aprendizagem supervisionada de

máquina, que são difíceis de serem implementadas e demandam maior poder computacional;

- eliminar a necessidade de se identificar padrões de comportamento a serem utilizados no treinamento supervisionado da rede, considerando que a obtenção de tais padrões, quase sempre, é difícil e cara;
- por não necessitar de treinamento, o modelo proposto não demanda processamento extra para tal fim, efetuando a convergência evolucionária dos EA do estudante desde o início do processo de ensino-aprendizagem;
- levar em consideração a natureza dinâmica dos EA do estudante, cujas preferências podem mudar quando o conteúdo varia (Kelly e Tangney, 2005), ou evoluir naturalmente ao longo do processo de ensino-aprendizagem (Messick, 1976) por razões desconhecidas (Castillo et al., 2005) (Lopes, 2009);
- detectar mudanças nas preferências de estilos de aprendizagem do estudante durante sua interação com o sistema e atualizar adequadamente o modelo do estudante, levando em consideração a evolução do estudante e o desenvolvimento de suas habilidades cognitivas, conforme apresenta (Messick, 1976) , evitando um processo de adaptação inapropriado;
- ser imune às complicações originadas pela ocorrência de *concept drift* e *concept shift*;
- considerar que não apenas a evolução das preferências por EA, mas vários outros aspectos do ME, tal como o grau de conhecimento no domínio, evoluem de maneira não-determinística, reforçando a natureza estocástica do processo de aprendizagem;
- eliminar a necessidade de descobrir padrões de comportamento dos estudantes, como em (García et al., 2007), considerando que a obtenção de tais padrões é difícil e pode conter alto grau de incerteza;

- como consequência do item anterior, ser independente de LMS, podendo ser facilmente utilizada em qualquer LMS, por não levar em consideração a associação de EA com ferramentas e recursos específicos de um sistema específico, como ocorre nas abordagens tradicionais, por exemplo, naquelas apresentadas em (García et al., 2007; Graf e Liu, 2008);

Por não depender explicitamente de relações existentes entre EA e os padrões de comportamento do estudante (Graf et al., 2006) em um sistema específico, conforme ocorre nas abordagens tradicionais, tais como (García et al., 2007; Graf e Liu, 2008), a abordagem proposta neste trabalho figura-se mais flexível, podendo ser utilizada por diferentes LMS. Ou seja, como a abordagem proposta para detecção de EA é baseada na performance global do estudante, e não em padrões de comportamento mapeados para recursos específicos de um LMS específico, ela se torna independente do LMS onde será utilizada, o que é uma característica importante da abordagem proposta.

Neste ponto, é preciso considerar que cada LMS implementa recursos e ferramentas diferentes, de formas diferentes, e que se concentrar apenas em recursos comumente utilizados na maioria dos sistemas, como propõe (Graf, 2006), pode desprezar fatores importantes na detecção e correção de EA do estudante, o que pode gerar resultados inconsistentes com a realidade, já que não leva em consideração todos os indicadores de comportamento na inferência destes resultados.

Existem diversas propostas para modelagem de características do estudante em SAIE. Em (Martins et al., 2008), uma visão geral destas propostas é apresentada, e pontos específicos de cada uma são discutidos. Também, em (García et al., 2007), o problema da modelagem do estudante é discutido em suas várias vertentes, e categoriza uma diversidade de propostas de acordo com diferentes fatores, por exemplo, o conteúdo do ME, o tipo de estudante a ser modelado, como o modelo é atualizado, com que finalidade o modelo é usado, dentre outros. Em relação à modelagem do estudante, um aspecto inovador é a modelagem probabilística de EA do estudante. Uma vantagem desta abordagem é que permite representar e tratar adequadamente os aspectos de incerteza discutidos.

Um outro aspecto importante deste trabalho em relação às abordagens analisadas é a utilização de Aprendizagem por Reforço (AR) para modelagem automática e dinâmica do estudante considerando EA, o que elimina a necessidade de aprendizagem supervisionada. Alguns trabalhos propõem abordagens baseadas em AR para seleção da melhor estratégia pedagógica para o estudante de acordo com seu estado cognitivo, em que as ações representam uma estratégia pedagógica adotada pelo tutor para guiar o aprendiz (Guelpli et al., 2003; Iglesias et al., 2009a,b). Mas nenhum deles considera EA. Além disto, (Guelpli et al., 2003) considera a classificação do estudante em apenas 4 categorias pedagógicas, enquanto (Iglesias et al., 2009a,b) considera apenas 3 categorias pedagógicas, ambas em relação ao nível cognitivo. Desta forma, a abordagem apresentada neste trabalho estende estas propostas ao considerar AR na modelagem automática e dinâmica de EA do estudante, além de possibilitar a seleção da melhor estratégia pedagógica considerando 16 categorias pedagógicas de EA, possibilitando o fornecimento de adaptatividade levando em consideração maior nível de personalização.

Além disto, a abordagem proposta neste trabalho suplanta as desvantagens apontadas em (Guelpli et al., 2003), em que: existe um número elevado de ações a serem tomadas em determinado estado cognitivo do estudante; dependendo do estado, podem existir diversas estratégias pedagógicas a serem adotadas; a interface com LMSs já existentes é difícil, devido à necessidade dos sistemas receberem os parâmetros do sistema de AR; verificou-se a lentidão de convergência do algoritmo.

O próximo capítulo apresenta o referencial teórico deste trabalho, discutindo conceitos fundamentais ao entendimento da abordagem proposta, que é detalhadamente apresentada no capítulo 4.

Capítulo 3

Referencial Teórico

Este capítulo apresenta os fundamentos teóricos que serviram como base fundamental para a construção da abordagem proposta neste trabalho. A seção 3.1 apresenta aspectos importantes sobre as principais abordagens para educação a distância que contextualizam este trabalho. A seção 3.2 discute a modelagem do estudante e suas principais características. A seção 3.3 agrega informações importantes sobre estilos de aprendizagem e suas contribuições para o presente trabalho. A seção 3.4 aborda questões fundamentais dos processos estocásticos e cadeias de Markov para o entendimento de nossa abordagem. A seção 3.5 apresenta características importantes da AR. Finalmente, a seção 3.6 discute aspectos da simulação computacional de estudantes e sua contribuição para este trabalho.

3.1 Abordagens para Educação a Distância

Logo após o surgimento da *web*, diversos grupos de pesquisadores têm implementado diferentes abordagens para SAIE. A heterogeneidade dos estudantes que interagem com o ambiente é um dos maiores problemas enfrentados por estes sistemas, já que o sistema precisa se adaptar a cada estudante, a cada passo da interação (Iglesias et al., 2009a). Estes sistemas não pertencem a um tipo totalmente novo de sistemas educacionais, possuindo raízes em duas áreas: STI e SHA.

Neste contexto, os SAIE (Papanikolaou et al., 2002) têm incorporado diversas tec-

nologias adaptativas e inteligentes advindas de STI e SHA, com intuito de prover personalização e assistência individualizada aos estudantes, tendo como característica principal a adaptação da estratégia de ensino a cada estudante de acordo com suas características de aprendizagem, através da aplicação de técnicas de Inteligência Artificial (IA) (Iglesias et al., 2009a). Papanikolaou et al. (2002) aponta algumas características específicas destes sistemas:

- sequenciamento de currículo: permite ao sistema fornecer ao estudante uma sequência adequada de unidades de conhecimento e atividades individualmente planejadas;
- apoio à resolução de problemas: permite ao sistema ajudar o estudante na resolução de um problema educacional;
- apresentação adaptativa: permite ao sistema adaptar o conteúdo de uma página de hipermídia a ser apresentada ao estudante de acordo com suas preferências e características particulares;
- apoio adaptativo à navegação: permite ao sistema ajudar o estudante a encontrar o caminho mais relevante no hiper-espço através da adaptação da aparência dos *links*.

A utilização de técnicas de IA em EAD é uma tentativa de levar o ensino tradicional para um ambiente computacional de forma dinâmica e individualizada, oferecendo ensino e acompanhamento personalizados através de um processo interativo. SAIE se adaptam ao objetivo do usuário, seus conhecimentos, experiências anteriores, preferências e características particulares, sem que para isso o usuário precise explicitamente alterar as configurações do sistema.

Identifica-se claramente quatro tarefas básicas no processo de ensino em um SAIE: aquisição de dados sobre o estudante, processamento dos dados, construção e atualização do ME, e personalização da estratégia de ensino de acordo com técnicas provenientes de STI e SHA (Iglesias et al., 2009a). Desta forma, um SAIE permite a adaptação do

conteúdo de uma página de hipermídia aos objetivos, conhecimento, preferências, e outras informações de cada estudante individualmente (Iglesias et al., 2009a).

Neste contexto, STI e SHA compartilham um dos problemas mais antigos em sistemas educacionais: o quê ensinar e como ensinar (Iglesias et al., 2009a). Em STI, o sequenciamento de conteúdo especifica a sequência individualmente planejada de unidades de conhecimento e de atividades instrucionais (exemplos, questões, problemas, dentre outros), chamados aqui de objetos de aprendizagem¹ (Dutra e Tarouco, 2006; Gomes et al., 2005; McGreal, 2004; Karagiannidis e Sampson, 2004; Hodgins, 2002; IEEE, 2010b), que são mais adequadas de acordo com as necessidades de aprendizagem do estudante em determinado momento. Ou seja, os STIs personalizam a estratégia pedagógica para cada estudante (Iglesias et al., 2009a).

De acordo com Brusilovsky et al. (1996b), as duas principais características de um STI são o sequenciamento de conteúdo personalizado e o suporte à solução interativa de problemas. Estas características diferenciam os STIs dos sistemas tradicionais de instrução assistida por computador, já que os STIs incorporam técnicas inteligentes que implementam os procedimentos de um tutor humano em um ambiente de ensino tradicional.

O sequenciamento de conteúdo descreve a ordem em que novas unidades de conhecimento, habilidades a serem aprendidas e operações de ensino correspondentes, por exemplo, demonstrações e exemplos, questionamentos, exercícios, testes, solução de problemas, são apresentadas a um estudante específico (Brusilovsky et al., 1996b). Estes sistemas alcançam sua inteligência através de decisões pedagógicas sobre como transmitir o conteúdo, baseando-se em informações sobre o estudante. Isto permite uma grande interatividade do sistema com o estudante. STIs têm sido apresentados como sendo altamente eficientes para a melhoria do desempenho e da motivação dos estudantes em cursos

¹O grupo de trabalho que estuda a padronização de metadados para Objetos de Aprendizagem, *Learning Object Metadata Working Group*, os define como sendo "qualquer entidade digital ou não digital que possa ser usada, reutilizada ou referenciada durante o uso de tecnologias que suportem o ensino" (Gomes et al., 2005). Os metadados de um objeto de aprendizagem definem o conjunto mínimo de propriedades necessárias para permitir o gerenciamento, a localização e a avaliação destes objetos (IEEE, 2010a,b; Hodgins, 2002).

à distância. A arquitetura e funcionamento de um STI é detalhadamente exposta por Costa (1999).

De acordo com Costa (1999), a arquitetura de um STI é composta pelos componentes: modelo do domínio, modelo do estudante, módulo pedagógico, módulo de interface com o usuário e módulo especialista. O modelo do domínio modela todo o conteúdo a ser ensinado pelo sistema, usualmente através de um mapa conceitual (Gomez et al., 1996) para organizar e representar o conhecimento. O modelo do estudante armazena informações sobre o comportamento, conhecimento e características diversas do estudante. O módulo pedagógico incorpora o conhecimento do sistema sobre as estratégias pedagógicas possíveis, selecionando o conteúdo a ser exibido e fornecendo assistência personalizada. O módulo especialista é um sistema especialista capaz de resolver problemas em um dado domínio, tendo como objetivo analisar como um estudante expressa seu conhecimento através do uso de suas habilidades dentro do domínio. Para isto, este módulo realiza a comparação das soluções dos estudantes com as do tutor. O módulo de interface com o usuário fornece interação personalizada com o estudante, interagindo diretamente com o aluno.

Neste contexto, SHA, segundo Palazzo (Palazzo, 2002), têm aplicação na interação personalizada com o estudante, principalmente no seu direcionamento pela informação de forma objetiva e personalizada através de técnicas da Hipermedia Adaptativa (HA). Desta forma, um SHA deve satisfazer a três critérios básicos: ser um sistema de hipermedia, possuir um modelo do estudante, e ser capaz de adaptar o conteúdo do sistema a tal modelo. Estes sistemas são constituídos por um conjunto de nós ou hiperdocumentos conectados por *links*. Cada nó contém alguma informação e *links* para outros nós relacionados.

Os SHA podem também incluir um índice ou um mapa com *links* para todos os nós disponíveis. Neste contexto, a adaptação pode ocorrer no conteúdo dos nós, *links*, índices e mapas. Os nós podem conter qualquer combinação personalizada de texto, imagens, som, vídeo, dentre outros, em que os *links* formam uma rede de conceitos conectados através de relacionamentos. Estes dois níveis de adaptação representam duas técnicas diferentes

da HA: apresentação adaptativa (*adaptive presentation*) e navegação adaptativa (*adaptive navigation support*) (Brusilovsky, 2001b; Palazzo, 2002).

A apresentação adaptativa tem por objetivo adaptar o conteúdo de um nó a um estudante específico, levando em consideração seu conhecimento, objetivos, preferências, dentre outras questões. Por exemplo, a um estudante experiente, apresenta-se conteúdo mais profundo e detalhado. Em contrapartida, a um iniciante apresenta-se conteúdo introdutório. Uma discussão interessante sobre técnicas de adaptação de apresentação em SAIE é fornecida por Brusilovsky e Vassileva (2003).

De acordo com Palazzo (2000), uma técnica simples, porém eficiente, para apresentação adaptativa é a de texto condicional. Com esta técnica é possível dividir a informação em diversas partes, e associar cada uma a condições. Ao apresentar o nó de conhecimento, o sistema mostra apenas as partes que tiveram suas condições satisfeitas, considerando-se as características específicas do usuário. Diversas outras técnicas são discutidas detalhadamente em (Palazzo, 2000).

Já a navegação adaptativa, tem por objetivo auxiliar os usuários na navegação pelo conteúdo através da adaptação da forma de apresentação dos *links* de acesso. É possível distinguir seis principais tecnologias para a apresentação dos *links* (Palazzo, 2002):

- 1. Orientação direta: Em cada ponto, qual o melhor caminho?
- 2. Classificação: Em que ordem os *links* devem ser apresentados?
- 3. Ocultação: Quais *links* não devem ser apresentados?
- 4. Anotação: Como agregar mais informação aos *links*?
- 5. Geração de *links*: Como *links* interessantes podem ser gerados?
- 6. Adaptação de mapas e índices: Como apresentar mapas e índices?

Algumas técnicas e métodos de navegação adaptativa, tais como condução global, condução local, suporte à orientação local e suporte à orientação global são discutidas por

Palazzo (2000). Brusilovsky (2001b) apresenta detalhadamente a taxonomia de tecnologias para hipermídia adaptativa. Oliveira e Fernandes (2002) descrevem uma arquitetura de adaptação em SAIE, separando claramente o papel dos diversos componentes envolvidos.

Entre os principais usos das técnicas da hipermídia adaptativa encontram-se hoje os SAIE. Neste contexto, SHA têm sido considerados a solução dos problemas dos sistemas de hipermídia tradicionais, caracterizados por conteúdo estático e falta de personalização em ambientes para EAD. O advento da *web* semântica (Davies, 2006) e a disponibilidade de ontologias em uma diversidade de domínios de conhecimento têm fomentado o desenvolvimento de SAIE.

Diversos trabalhos têm explorado a construção de arquiteturas para SAIE (De Bra e Calvi, 1998; De Bra et al., 1999; Wu, 2002; Dorça, 2004). A aplicação de técnicas de HA em SAIE é extensivamente explorada em diversos trabalhos, com diferentes propostas². Particularmente em (Graf e Kinshuk, 2010a), os autores apresentam um mecanismo para estender a funcionalidade de LMSs para fornecer aos estudantes cursos que se encaixem aos seus EA, utilizando a classificação e anotação adaptativa de *hyperlinks*, a fim de destacar os objetos de aprendizagem que melhor apoiam o processo de aprendizagem específico do estudante. O processo de autoria de SHA para educação, alguns dos seus pontos fundamentais e suas principais dificuldades são discutidas por Cristea (2007), Grigoriadou e Papanikolaou (2006), Cristea (2005) e Baldiris et al. (2009).

Desta forma, diversos trabalhos têm sido desenvolvidos principalmente no sentido de relacionar características individuais de EA às características dos objetos de aprendizagem, com o intuito de possibilitar a adaptação da apresentação de conteúdos considerando-

² Brusilovsky et al. (1998); Zakaria e Brailsford (2002); Clifford (2004); De Bra e Calvi (1998); Brusilovsky et al. (1996a); Brusilovsky (2001a); Cristea e Stash (2006); Stash et al. (2004); Specht e Oppermann (1998); Graf e Kinshuk (2007); Bajraktarevic et al. (2003); Sangineto et al. (2008); Limongelli et al. (2009); De Bra et al. (2006); Weber e Brusilovsky (2001); Cristea e de Mooij (2003); Paredes e Rodriguez (2006); Stern e Woolf (2000); Grigoriadou et al. (2001); Iglesias et al. (2009b,a); Martins et al. (2008); Brusilovsky e Millan (2007); Cristea (2007, 2005); Meccawy et al. (2006); Brown (2007); Trif et al. (2010); Karagiannidis e Sampson (2004); Botsios, S. and Georgiou, D. and Safouris, N. (2008); Paredes e Rodriguez (2004); Brusilovsky e Peylo (2003); Palazzo et al. (1999); Candotti et al. (2006); Oliveira e Fernandes (2002); Zanchett et al. (2004); Cristea e Calvi (2003)

se EA, conforme apresentado por Karagiannidis e Sampson (2004); Sangineto et al. (2008). Teorias de EA, em particular o modelo de Felder e Silverman (1988), têm sido consideradas no fornecimento de adaptatividade em SAIE. Velazquez e Assar (2007) apresentam como se pode utilizar EA para melhorar tais sistemas, e Franzoni et al. (2008) apresentam como é possível integrar mídias eletrônicas a EA, considerando o modelo de Felder e Silverman (1988).

A utilização de EA no fornecimento de adaptatividade em SAIE é apresentada em diversos trabalhos³. A união de técnicas e características de STI e SHA na construção de SAIE que forneçam adaptatividade baseada em EA pode ser identificada nestes trabalhos, em que a modelagem do estudante exerce papel fundamental.

Também, esforços tem sido feitos para relacionar as dimensões do FSLSM com mídias eletrônicas que forneçam suporte a tais dimensões, conforme pode-se notar em (Franzoni e Assar, 2009; Velazquez e Assar, 2007; Franzoni et al., 2008). Na oportunidade, os autores descrevem uma taxonomia de integração entre EA e estratégias de ensino, relacionando recursos eletrônicos de ensino aos estilos de aprendizagem do FSLSM.

Neste contexto, o trabalho de Franzoni e Assar (2009) descreve a taxionomia de integração entre EA e estratégias de ensino. Franzoni e Assar (2009) propõem o desenvolvimento de um meio eletrônico para facilitar a personalização dos processos de aprendizagem, com objetivo de possibilitar ao estudante uma melhor assimilação do conhecimento. Para isto, descrevem a combinação de recursos eletrônicos de ensino adequados a determinados estilos de aprendizagem que proporcionaram resultados mais eficientes em EAD. Para cada EA, existe uma ou mais estratégias pedagógicas que podem ser representadas por um ou mais recursos eletrônicos. A próxima seção apresenta conceitos e técnicas sobre modelagem do estudante.

³Brown (2007); Graf e Kinshuk (2009a); Cristea e Stash (2006); Franzoni e Assar (2009); Stash et al. (2004); Carver Jr et al. (2002); Graf e Kinshuk (2007); Sangineto et al. (2008); Vasilyeva et al. (2006); Paredes e Rodriguez (2004); Carver et al. (1999); Sangineto et al. (2008)

3.2 Modelagem do Estudante

De acordo com Thompson (1996), a principal característica de um SAIE é sua capacidade de adaptação aos estudantes. Souza (2002) afirma que o ME é tido como peça fundamental do comportamento individualizado deste tipo de sistema, que depende fortemente de como o conhecimento sobre o estudante é modelado internamente.

Neste contexto, o problema de modelagem do estudante é uma questão delicada no desenvolvimento deste tipo de sistema, exigindo assim uma atenção especial. Um dos problemas em SAIE é determinar e representar de forma efetiva o conhecimento atual do estudante em um determinado domínio, conforme alerta Thompson (1996).

Um ME ideal deve ser capaz de registrar toda informação sobre o estudante, inclusive aquela aparentemente irrelevante. Obviamente, um modelo absolutamente completo é impossível e impraticável, conforme afirma Valldeperas (2000). Botelho et al. (2009) reitera que o ME é uma representação explícita do que se acredita saber sobre o estudante a respeito do conhecimento, do progresso no conteúdo, preferências, EA, objetivos de aprendizagem, motivação, crenças e características pessoais do estudante.

De acordo com Graf et al. (2009a), duas abordagens para obtenção da informação para modelagem do estudante são possíveis: colaborativa e automática. Na abordagem colaborativa, os estudantes fornecem explicitamente informações que são utilizadas para construir e atualizar seu modelo, através do preenchimento de questionários psicométricos, como o ILSQ (Van Zwanenberg et al., 2000). Na abordagem automática, os processos de construção e atualização do ME são realizados automaticamente, baseado no comportamento e ações dos estudantes enquanto utilizam o sistema.

Graf et al. (2009a) atesta que a abordagem automática é livre do problema da ocorrência de auto-concepções imprecisas ou inconsistentes por parte dos estudantes. Além disto, permite aos estudantes focar somente na aprendizagem, sem a necessidade de informar explicitamente suas preferências. Ainda, abordagens automáticas tendem a ser mais precisas e menos suscetíveis a erros, já que permite analisar dados resultantes de um intervalo de tempo, ao invés de dados colhidos em um momento específico.

Não obstante, a modelagem do estudante pode ser classificada em estática ou dinâmica (Graf et al., 2010). A modelagem estática do estudante se refere a uma abordagem em que o modelo do estudante é inicializado apenas uma vez, usualmente quando o estudante se cadastra no sistema. De outro lado, a abordagem dinâmica para modelagem do estudante frequentemente atualiza as informações do estudante, e então permite ao sistema responder a alterações em suas características (Graf et al., 2010).

De acordo com Graf et al. (2010), a abordagem dinâmica possui vantagens sobre a abordagem estática, no contexto da identificação de EA: considerar comportamento excepcional do estudante e estender a modelagem estática do estudante através da melhoria incremental e ajuste fino dos EA em tempo real. Além disto, como muitas teorias cognitivas argumentam que EAs podem variar ao longo do tempo, a modelagem dinâmica do estudante permite considerar tais variações e atualizar o ME no momento em que elas ocorrem. De acordo com Giraffa (1999), um modelo realista do estudante requer atualização dinâmica enquanto o sistema avalia o seu desempenho.

De acordo com Palazzo (2002), há pelo menos cinco características associadas a um usuário que podem ser levadas em conta por um SAIE na construção do ME: conhecimento, objetivos, história, experiência, e preferências. Estas características são todas de algum modo dinâmicas, fazendo-se necessário ajustar continuamente o modelo do usuário, a fim de garantir sua permanente consistência em relação à realidade do estudante. Os objetivos do estudante são metas de aprendizagem. De acordo com Palazzo (2002), uma representação interessante usada para modelar os objetivos do estudante é obtida a partir de pares (*objetivo, valor*).

Uma das principais técnicas adotadas para a modelagem do conhecimento do estudante é a sobreposição (*overlay*) (Palazzo, 2002). Nesta abordagem considera-se que o conhecimento do estudante é um subconjunto do conhecimento do tutor. Desta forma, este tipo de modelagem supõe que todos os erros do estudante são decorrentes da falta de conhecimento ou falha de aprendizagem. Valldeperas (2000) e Souza (2002) comentam sobre outras abordagens, tais como o Modelo Baseado em Restrições, o Modelo de

Perturbação e o Modelo Diferencial.

Martins et al. (2008) afirma que, considerando-se SAIE, a ênfase é dada ao conhecimento do estudante no domínio e aos seus EA, para que se possa permitir que eles alcancem os objetivos de aprendizagem propostos com maior facilidade. A próxima seção apresenta conceitos fundamentais sobre EA para este trabalho, assim como o FSLSM, teoria que fundamenta a abordagem proposta.

3.3 Estilos de Aprendizagem

De acordo com (Lopes, 2009), a forma de ensino, seja ela presencial ou não, nos moldes como se encontra na atualidade, tende a desenvolver um processo de ensino-aprendizagem como se todos aprendessem de forma semelhante. No entanto, assim como as pessoas apresentam características físicas diferentes, elas apresentam características psicológicas diferentes. Para Do Rosário (2006) esta diferença é a responsável, na maioria dos casos, pelas reprovações e abandonos de curso.

Vários pesquisadores acreditam que existem diferenças entre as formas como as pessoas comumente pensam e lidam com as situações com as quais se defrontam. Assim, haveria tendências diferenciadas nas formas de aprender e relacionar os dados da realidade e de elaborar conclusões. Estas diferenças são uma junção de influências herdadas e experiências vividas. Em psicologia, as diferenças psicológicas apresentadas pelas pessoas são objeto de estudo, onde se busca encontrar padrões de comportamentos em tipos psicológicos que sirvam para melhor entender as diferentes formas de agir e de ser das pessoas, e assim prever de forma mais geral as ações de cada tipo.

Com isto, dependendo do tipo psicológico, pode-se dizer quais os prováveis tipos de ação e reação, tendência e aptidões de um indivíduo. Os tipos psicológicos são explicações da personalidade humana, e os estilos de aprendizagem derivam desta explicação. Dentro da comunidade acadêmica, considerável atenção tem sido dada à ideia de diferentes estilos de aprendizagem e à busca por melhores métodos de ensino para cada um (Lopes, 2009).

Várias definições para EA são encontradas na literatura. Felder e Brent (2005) definem EA como características cognitivas e comportamentos psicológicos que servem como um indicador de como o estudante percebe, interage e responde aos ambientes de aprendizagem. Para Reid (1998), EA são características básicas de como se armazenar e compreender uma nova informação, e que não são perceptíveis de forma consciente pelos estudantes.

Para Honey e Mumford (1992), EA podem ser vistos como uma descrição das atitudes e comportamentos que determinam a forma de aprender preferida por um estudante. Mas, o que se pode perceber, mesmo havendo certa diversidade de definições, é a concordância de que EA se referem à forma como a mente humana processa a informação. Lopes (2002) lembra que as preferências de EA apresentadas por um estudante não refletem a sua adequação ou inadequação para uma determinada disciplina, curso ou profissão.

Muitos modelos de EA foram propostos, como por exemplo (Myers e McCaulley, 1985), (Kolb et al., 1984), (Honey e Mumford, 1992), (Entwistle, 1981), (Pask, 1976) e (Felder e Silverman, 1988). Cada um destes modelos descrevem diferentes aspectos de como estudantes preferem aprender. Em (Coffield et al., 2009) os autores examinam os mais conhecidos e influentes modelos, apresentando uma revisão sistemática destes modelos. Lopes (2009) faz uma análise comparativa dos modelos de Myers-Briggs, Kolb e Felder-Silverman e seus respectivos estilos de aprendizagem, que pode ser vista na Tabela 3.1.

Tabela 3.1: Comparação entre os Modelos de Estilos de Aprendizagem

Felder e Silverman	Kolb	Myers-Briggs
Ativos	Experimentação Ativa	X
Reflexivos	Observação Reflexiva	X
Sensoriais	Experimentação Concreta	Sensação
Intuitivos	Conceitualização Abstrata	Intuição
Visuais	X	X
Verbais	X	X
Seqüenciais	X	X
Globais	X	X

O FSLSM descreve estilos de aprendizagem em mais detalhes (Graf e Kinshuk, 2009a) (Graf e Kinshuk, 2010a), baseado em uma escala de 4 dimensões (Felder e Silverman, 1988): ativo-reflexivo, sensitivo-intuitivo, visual-verbal, sequencial-global. Por isto, o FSLSM é comumente considerado na implementação de SAIE. A próxima seção descreve características importantes do FSLSM, teoria de EA tomada como base neste trabalho por uma diversidade de razões, expostas a seguir.

Mas, é importante ressaltar que o fato da abordagem proposta neste trabalho ser baseada em aprendizagem por reforço, que tem como característica fundamental a não utilização de conhecimento específico do domínio de aplicação, torna o método genérico, podendo este ser aplicado considerando-se outras teorias de estilos de aprendizagem.

3.3.1 Felder-Silverman Learning Style Model (FSLSM)

De acordo com Bostrom (2011), o termo EA pode incluir diversos modelos diferentes, com pressupostos conflitantes sobre aprendizagem. Neste trabalho, consideramos a definição de Felder e Silverman (1988), em que EA são definidos como as características, pontos fortes e preferências na maneira como as pessoas recebem e processam informações. Ou seja, refere-se ao fato de que cada estudante tem seu próprio método particular, ou conjunto de estratégias para aprender.

Conforme mencionado anteriormente, diversos modelos de EA estão dispostos na literatura. O FSLSM se destaca dos demais por combinar os principais modelos, tais como os modelos de Kolb et al. (1984), Pask (1976) e Myers et al. (1985), conforme mencionado por Kinshuk et al. (2009). Além disto, o FSLSM é um dos mais frequentemente utilizados em SAIE (Graf e Kinshuk, 2009a). Um importante aspecto associado ao uso frequente deste modelo é que ele é baseado em extensa experimentação, que validou as dimensões e classes de EA propostas em uma população de estudantes de engenharia.

Segundo Felder e Spurlin (2005), estudantes apresentam tendências de preferências em cada uma de quatro dimensões, que definem as formas de receber, processar, perceber e organizar a informação Felder e Silverman (1988):

- Dimensão de Percepção - Qual tipo de informação o estudante prefere receber?
Sensitivos: preferem fatos, datas, dados experimentais, exemplos, ligações com o mundo real, preferindo abstrair informações pelos seus sentidos (vendo, ouvindo, tocando). Intuitivos: preferem teorias, definições, informação simbólica, modelos matemáticos, abstrações.
- Dimensão de Entrada - Qual tipo de informação é mais efetivamente percebida?
Visuais: preferem figuras, diagramas, gráficos, linhas de tempo, filmes e demonstrações. Verbais: preferem explicação escrita ou falada, recordando com maior facilidade as informações que lêem e escutam, extraem mais informações em uma discussão.
- Dimensão de Processamento - Como o estudante prefere processar a informação?
Ativos: preferem experimentação ativa, discussões, trabalho em grupo, compreendendo melhor a informação fazendo, discutindo, aplicando ou explicando. Reflexivos: preferem introspecção e reflexão, trabalho individual, tendem a ser teóricos, fazem ligações teóricas com a fundamentação da matéria e não extraem muito quando não são levados a pensar.
- Dimensão de Organização - Como o estudante prefere progredir dentro do curso?
Sequenciais: preferem a progressão lógica e linear do conteúdo, tendem a seguir uma sequência para a solução de um problema, aprendem melhor quando o material é apresentado em uma progressão cuidadosa de complexidade e dificuldade. Globais: preferem uma visão geral do todo, aprendendo em saltos e aleatoriamente, preferem mais liberdade no processo de aprendizagem.

Neste contexto, espera-se que um SAIE, unindo técnicas de STI e SHA, considerando os objetos de aprendizagem associados a um conceito, o nível de conhecimento do estudante e seus estilos de aprendizagem preferidos, possa inferir uma sequência de objetos de aprendizagem a serem apresentados ao estudante e a forma como devem ser apresentados. Ou seja, deve ser capaz de inferir uma estratégia pedagógica personalizada

de acordo com os EA do estudante, provendo uma experiência individualizada através da utilização de técnicas de HA.

Um exemplo é apresentado na Figura 3.1. Neste caso, foi considerado um estudante com as seguintes preferências de EA: Intuitivo, Verbal, Reflexivo e Sequencial, considerando-se o FSLSM. Desta forma, o estudante prefere aprender através de princípios e teorias, aprende melhor quando a informação é apresentada de forma verbal (considerando que o primeiro objeto de aprendizagem da Figura 3.1 possui conteúdo textual), processa melhor a informação através da reflexão e necessita seguir uma linha ou sequência para a solução de um problema, aprendendo melhor quando o material é apresentado em uma progressão cuidadosa de complexidade e dificuldade.

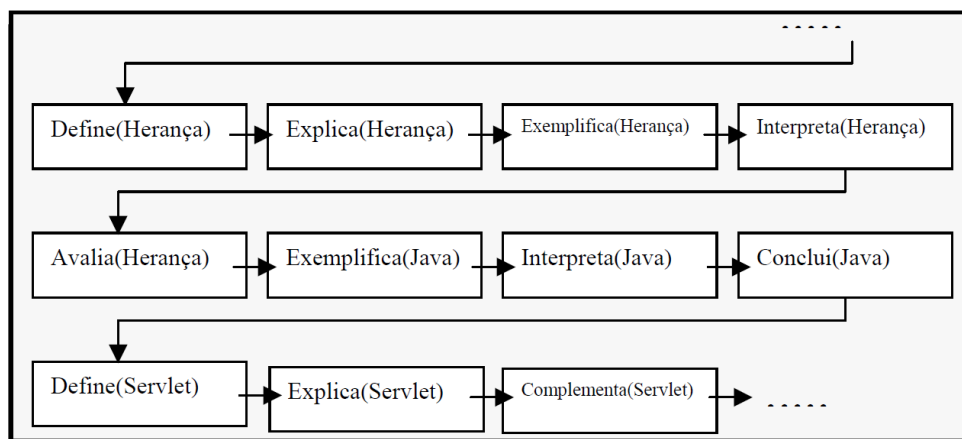


Figura 3.1: Exemplo de uma estratégia pedagógica baseada em EA

Os EA propostos pelo FSLSM foram, em sua maioria, derivados de outros modelos e teorias já existentes (Felder e Silverman, 1988). Os estilos Ativo e Reflexivo, referentes ao processamento da informação, foram derivados dos estilos Experimentação Ativa e Observação Reflexiva do Modelo de Kolb et al. (1984), conforme pontua Lopes (2009). Felder e Spurlin (2005) assevera que estudantes ativos e reflexivos estão respectivamente relacionados ao tipo Extrovertido e Introverso no modelo de Myers e McCaulley (1985). A dimensão referente à forma de percepção da informação teve origem no modelo de Myers-Briggs (Myers e McCaulley, 1985) e no modelo de Kolb et al. (1984).

O FSLSM descreve estilos de aprendizagem em mais detalhes quando comparado

a outros modelos, conforme atestam Graf e Kinshuk (2010a), e por isto, é comumente considerado na implementação de SAIE. Uma característica marcante do FSLSM, e fundamental para este trabalho, é que enquanto a maioria dos modelos classifica estudantes em tipos definidos, este é baseado na ideia de que cada estudante possui um grau de preferência por cada EA, medida em valores dentro do intervalo $[0,11]$, conforme propõem Felder e Silverman (1988).

Ao se utilizar escalas ao invés de tipos fixos, os pesos das preferências podem ser descritos, possibilitando distinguir-se entre preferências fortes, moderadas e leves (ou balanceadas) em todas as dimensões do modelo, conforme atesta Kinshuk et al. (2009). Desta forma, um suposto estudante pode ser considerado fortemente intuitivo, moderadamente visual, fortemente reflexivo e levemente sequencial. Isto permite maior flexibilidade no processo de fornecimento de adaptatividade por um SAIE.

O ILSQ é um instrumento desenvolvido por Felder et al. (1999) para avaliar, de forma colaborativa, as preferências de um estudante nas quatro dimensões do FSLSM. O ILSQ é composto por 44 perguntas, sendo 11 para cada dimensão do FSLSM. Cada pergunta contém duas opções, onde o estudante deve optar por uma delas, escolhendo a que mais se enquadra em sua realidade ou a que ocorre com mais frequência. A combinação das respostas determina os seus estilos de aprendizagem.

Lopes (2009) pondera que estes valores podem variar com o tempo, não podendo ser considerados características estáticas. Estes valores podem sofrer variações ao longo do tempo, influenciados por estratégias instrucionais vivenciadas. Portanto, os EA são quantidades contínuas, e não categorias únicas. Desta forma, os EA apresentados pelos estudantes podem servir como um indicador das ações instrucionais a serem aplicadas durante o processo de ensino, e como um indicador dos prováveis pontos fortes do estudante e possíveis tendências ou hábitos que poderiam estar conduzindo-o a dificuldades e problemas de aprendizagem.

Com isto, é possível, inicialmente, proporcionar ações instrucionais voltadas às necessidades dos estudantes e, posteriormente, desenvolver no estudante outras habilidades

que não fazem parte dos seus estilos preferidos, com o objetivo de desenvolver a destreza mental, além de estimular e fortalecer as suas habilidades menos desenvolvidas, conforme asseveram (Lopes, 2002; Messick, 1976).

Também, outra característica fundamental do FSLSM para este trabalho é que ele considera EA como tendências, ou seja, estudantes possuem uma tendência por um EA, mas podem, conforme alega Kinshuk et al. (2009), agir diferente em situações particulares, ou seja, de forma não-determinística, que é uma característica fundamental dos processos estocásticos, um dos pilares da abordagem proposta neste trabalho.

Ainda, de acordo com Kinshuk et al. (2009); Graf e Kinshuk (2010a), ao incorporar o conceito de tendências, o FSLSM também permite considerar comportamento excepcional ou desvios comportamentais do estudante. Desta forma, o FSLSM coloca em evidência o não-determinismo inerente ao comportamento do estudante, que passa a ser visto como probabilístico ao invés de determinístico, cujas probabilidades são dadas pelos pesos das preferências pelos estilos de aprendizagem em cada uma das quatro dimensões do FSLSM.

Desta forma, o modelo do estudante proposto neste trabalho leva em consideração este importante aspecto não-determinístico, permitindo levar em consideração a natureza dinâmica dos EA do estudante, cujas preferências podem mudar quando o conteúdo varia (Kelly e Tangney, 2005; Jones et al., 2003), ou evoluir naturalmente ao longo do processo de ensino-aprendizagem (Messick, 1976) por razões desconhecidas (Castillo et al., 2005) (Lopes, 2009);

Esta característica é fundamental para este trabalho, e outras teorias de EA não permitiriam sua implementação de forma tão direta. Ou seja, utilizar escalas que podem variar no tempo, ao invés de tipos rígidos de estilos de aprendizagem é uma característica crucial do FSLSM para a nossa abordagem, que é baseada em distribuições de probabilidades e processos estocásticos, conforme apresenta o capítulo 4.

Considerando o raciocínio probabilístico relacionado ao problema tratado neste trabalho, a teoria da probabilidade oferece uma maneira quantitativa de codificar incertezas, possuindo uma semântica clara. As probabilidades podem ser obtidas a partir de dados,

e a incorporação de novas evidências é fácil. Desta forma, um aspecto fundamental deste trabalho é lidar com incertezas relacionadas à modelagem de EA do estudante usando probabilidades. Por isto, o MP, parte fundamental da abordagem proposta neste trabalho, é modelado através de cadeias de Markov, cujos principais aspectos são discutidos na próxima seção.

3.4 Processos Estocásticos e Cadeias de Markov

A abordagem proposta neste trabalho para diagnóstico automático e dinâmico de EA é, em sua natureza, um processo estocástico que trabalha em um modelo de estudante probabilístico subjacente. Um processo aleatório, não-determinístico ou estocástico é tal que não é possível afirmar a priori o resultado que ocorrerá, podendo o resultado ser diferente mesmo ao se repetir o processo em condições praticamente inalteradas. Os resultados podem parecer erráticos nas primeiras tentativas, entretanto, após um grande número de repetições, aparecem regularidades (Gardiner, 1983).

Pode-se definir um processo estocástico como uma coleção de variáveis probabilísticas, ou aleatórias, que descrevem o processo executado por um sistema em um período de tempo. Em termos formais, uma variável randômica X_t representa o estado do sistema no tempo $t \in T$ (Pollard, 1984; Papoulis et al., 2002). Informalmente, um processo estocástico descreve uma história que se desenvolve de forma aleatória ao longo de um período de tempo representado por T . Ou seja, é um fenômeno que varia em algum grau, de forma imprevisível à medida que o tempo passa, constituído por uma coleção de variáveis aleatórias indexadas por um parâmetro $t \in \mathfrak{R}$, entendido como tempo. A variável aleatória X_t é definida em um espaço denominado de espaço de estados, conforme (3.1) (Albuquerque et al., 2008; Devore e da Silva, 2006; Walpole et al., 2009; Gardiner, 1983).

$$X_t = X_{t0}, X_{t1}, X_{t2}, \dots, X_{tn} \quad (3.1)$$

Desta forma, tem-se uma sequência de variáveis aleatórias X_1, X_2, \dots, X_n . O escopo

destas variáveis, isto é, o conjunto de valores que elas podem assumir, é chamado de espaço de estados, em que X_n denota o estado do processo no tempo n .

Um processo estocástico é estacionário se a distribuição conjunta de um número arbitrário de variáveis aleatórias se mantém quando são efetuados deslocamentos no tempo, ou seja,

$$P(X_1 = x_1, \dots, X_n = x_n) = P(X_{1+m} = x_1, \dots, X_{n+m} = x_n)$$

para qualquer deslocamento m e qualquer número de variáveis n , ou seja, mantém seu comportamento dinâmico invariante no tempo, em que x_1, x_2, \dots, x_n são estados do processo. Se $X_n = x_n$, dizemos que o processo no instante n está no estado x_n .

Um processo estocástico é dito discreto em relação aos estados se X_t é definido sobre um conjunto enumerável ou finito, e contínuo caso contrário. Em relação ao tempo, um processo estocástico é dito discreto se t é finito ou enumerável, e contínuo caso contrário (Albuquerque et al., 2008; Ross, 2010).

Como exemplo, seja X_t uma variável aleatória que indica se chove ou não num determinado dia, num dado local. A sequência X_1, X_2, \dots, X_n que indica o estado do tempo em dias consecutivos $1, \dots, n$, forma um processo estocástico não estacionário, pois as probabilidades variam ao longo do tempo. Já uma sequência de lançamentos de um dado forma um processo estocástico estacionário, pois as probabilidades são constantes ao longo do tempo. Chama-se distribuição estacionária a distribuição P de probabilidades de estados em que a distribuição no instante $n + 1$ é igual à distribuição no instante n (Clarke e Disney, 1979; Magalhães, 2006).

A imprevisibilidade nos processos estocásticos significa que ao se observar sequências inteiras do processo em diversas ocasiões diferentes, mas sob condições idênticas, as sequências resultantes da execução do processo são, em geral, diferentes. Desta forma, a probabilidade aparece, mas não no sentido de que cada resultado de uma experiência aleatória determine um valor único. Ao invés disto, o resultado do processo estocástico é uma sequência ou série de valores, uma função, e não apenas um valor único, e em cada instante de tempo t existe uma família de valores que a série pode assumir, aos quais

estão associadas probabilidades de ocorrência (Clarke e Disney, 1979).

3.4.1 Cadeias de Markov

Diz-se que um processo estocástico é um processo de Markov se cada variável aleatória depende da precedente e é condicionalmente independente das restantes (Meyn et al., 2009). Um processo de Markov é um processo estocástico com tempo e espaço de estados discretos, e que possui a propriedade de Markov dada por (3.2),

$$P(X_{n+1} = j | X_1, X_2, \dots, X_{n-1}, X_n) = P(X_{n+1} = j | X_n) \quad (3.2)$$

para x_1, \dots, x_n, j e todo instante $t = 1 \dots n, n+1$. Ou seja, a distribuição de probabilidade condicional de X_{n+1} nos estados passados é uma função apenas de X_n . Desta forma, a ocorrência de um estado futuro não depende do passado, apenas do presente, X_n , ou seja, do estado atual do processo, e não dos anteriores. Este tipo de processo é também denominado de *memoryless process* (processo sem memória), uma vez que o passado é desprezado, e o tempo que o processo está no estado atual é irrelevante (Meyn et al., 2009).

Para constatar a probabilidade de transição entre estados que evoluem de maneira estocástica, as cadeias de Markov, desenvolvidas pelo matemático Andrei Andreyevich Markov, foram criadas. Utilizando-as, é possível prever estados de um processo em andamento, conhecendo o estado atual e não sua trajetória, considerando-se um processo em que a sequência de variáveis aleatórias toma valores num alfabeto finito, funcionando como uma máquina de estados em que as transições são estocásticas. Desta forma, uma cadeia de Markov (Meyn et al., 2009) é um processo markoviano com as seguintes propriedades (Papoulis et al., 2002; Meyn et al., 2009):

- Cada resultado pertence a um conjunto finito de estados $(x_1, x_2, x_3, \dots, x_k)$, chamado espaço de estados do sistema. Se o estado resultante da n -ésima tentativa é x_j , então o sistema se encontra no estado x_j no instante n .

- O resultado de um ensaio depende apenas do resultado do ensaio imediatamente anterior. Desta forma, a cada par de estados (x_i, x_j) está associada uma probabilidade $p(x_j|x_i)$ de ocorrer x_j no instante n imediatamente após ter ocorrido x_i no instante $n - 1$, ou seja, $P(X_n = x_j|X_{n-1} = x_i)$

O espaço de estados de uma cadeia de Markov é indexado no tempo t por inteiros não negativos: $0, 1, 2, \dots, k$; X_n está no estado x_i se $X_n = x_i$. Os valores atribuídos a $p(x_j|x_i)$ correspondem à probabilidade de transição entre estados e formam uma matriz de transição de estados. Assim, a cada estado x_i corresponde a i -ésima linha $(p_{i1}, p_{i2}, \dots, p_{ik})$ da matriz de transição de estados. Esta linha representa as probabilidades de ocorrência de um estado x_j no instante n a partir do estado x_i , ocorrido no instante anterior, $n - 1$ (Papoulis et al., 2002; Meyn et al., 2009).

$$\begin{bmatrix} P(X_n|X_{n-1}) & X_n = x_0 & X_n = x_1 & X_n = x_2 & X_n = x_3 & \dots & X_n = x_k \\ X_{n-1} = x_0 & p_{00} & p_{01} & p_{02} & p_{03} & \dots & p_{0k} \\ X_{n-1} = x_1 & p_{10} & p_{11} & p_{12} & p_{13} & \dots & p_{1k} \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ X_{n-1} = x_k & p_{k0} & p_{k1} & p_{k2} & p_{k3} & \dots & p_{kk} \end{bmatrix}$$

As probabilidades p_{ij} satisfazem as condições (Papoulis et al., 2002; Meyn et al., 2009):

- $p_{ij} \geq 0$, para $i, j = 0, \dots, k$
- $\sum_{j=0}^k p_{ij} = 1$, para todo $i = 0, \dots, k$

Ou seja, a soma dos elementos em cada linha da matriz de transição deve ser igual a 1, sendo que cada uma representa as probabilidades do processo, a partir de um estado atual, atingir cada um dos demais estados. Ou seja, a soma destas probabilidades é 1, por que estamos considerando todos os próximos estados possíveis a partir do estado atual, ou seja, este vetor linha corresponde a uma distribuição de probabilidades. Uma matriz que

atenda a estas condições denomina-se matriz estocástica. A matriz de transição de uma cadeia de Markov é uma matriz estocástica. Considere a cadeia de Markov apresentada na Figura 3.2.

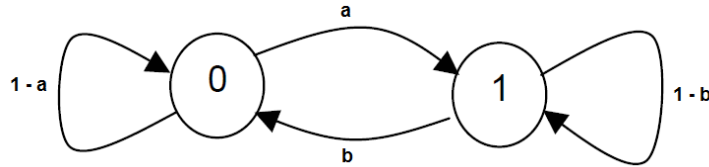


Figura 3.2: Exemplo de cadeia de Markov

A matriz de transição que representa as probabilidades de transição entre estados na cadeia dada pela Figura 3.2 é apresentada a seguir:

$$\begin{bmatrix} 1-a & a \\ b & 1-b \end{bmatrix}$$

Desta forma, um processo de Markov está completamente definido quando sua matriz de transição e seu estado inicial estão especificados. Desta forma, para especificar uma cadeia de Markov em tempo discreto, define-se (Papoulis et al., 2002; Meyn et al., 2009):

- 1. Espaço de estados S finito ou enumerável.
- 2. Probabilidade do estado inicial $P(X_0 = x)$ para $x \in S$.
- 3. Probabilidades de transição $P(x_j|x_i) = P(X_n = x_j|X_{n-1} = x_i)$ nos instantes $T = 1, 2, \dots, n$.

Um exemplo simples é apresentado a seguir. Três crianças A , B e C arremessam uma bola uma para a outra. A sempre arremessa para B ; B sempre arremessa para C ; e C arremessa para A ou para B , com a mesma probabilidade. Este processo pode ser representado através de uma cadeia de Markov, pois a criança que arremessa a bola num determinado instante não é influenciada por aquelas que arremessaram anteriormente, ou

seja, o próximo estado depende apenas do estado atual. O espaço de estados do sistema é $S = \{A, B, C\}$, e a matriz de transição é apresentada a seguir.

$$\begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ \frac{1}{2} & \frac{1}{2} & 0 \end{bmatrix}$$

A primeira linha da matriz corresponde ao vetor que indica que A sempre passa a bola para B; a segunda linha corresponde ao fato de que B sempre passa a bola para C; a última linha corresponde ao fato de que C arremessa a bola para A ou B com idênticas probabilidades, não ficando com a bola. Neste caso tem-se um exemplo de distribuição estacionária, ou seja, se a cadeia de Markov tem essa distribuição num dado instante t , então em todos os instantes posteriores terá a mesma distribuição, ou seja, é invariante no tempo.

Para entender a ideia dos modelos estocásticos, pode-se considerar que eles são o oposto dos modelos determinísticos. A maior parte da matemática elementar consiste em modelos determinísticos, onde a solução para um problema pode ter apenas uma resposta correta, e o gráfico de uma função pode ter apenas um conjunto específico de valores. Por outro lado, modelos estocásticos permitem variações em um problema matemático complexo para que se possa ver como a solução é afetada, e como converge em diversas repetições. Estas variações representam o aspecto aleatório ou a imprevisibilidade de eventos do mundo real e seus efeitos.

Neste contexto, o processo de aprendizagem, e conseqüentemente de modelagem do estudante, podem ser entendidos como processos estocásticos, devido ao efeito que variáveis randômicas ou desconhecidas podem ter sobre o comportamento e performance do estudante. A imprevisibilidade com que estas variáveis ou fatores afetam o desempenho do estudante deve ser considerada no ME para que se possa visualizar ou prever os efeitos dos problemas de aprendizagem no desempenho do estudante, planejando-se formas de minimizá-los (Geiss, 2009).

Desta forma, a utilização de AR na construção do ME se mostrou promissora no âmbito da abordagem proposta neste trabalho, em que a avaliação do ME ocorre sempre concorrentemente com a aprendizagem automática e dinâmica dos EAs do estudante, diferentemente das abordagens que se baseiam em aprendizagem supervisionada. Para que se possa compreender esta característica, apresenta-se, a seguir, os aspectos fundamentais da AR para este trabalho.

3.5 Aprendizagem por Reforço

Sutton e Barto (1998) afirmam que AR é uma técnica da IA que permite a um agente aprender a partir da sua interação com o ambiente no qual ele está inserido. A aprendizagem se dá através do conhecimento sobre o estado do indivíduo no ambiente, das ações efetuadas no ambiente e das mudanças de estado decorrentes das ações. Formalmente, AR utiliza uma estrutura composta de estados, ações e recompensas (Guelpeli et al., 2003).

De acordo com Coelho (2011), quando se deseja que o agente tenha autonomia total, significa que este deverá ser capaz de aprender com base em recompensas ou reforços fornecidos por um crítico ou pelo próprio ambiente. Em alguns casos, é possível que o próprio agente determine suas recompensas através da observação das transições de estados que realiza no ambiente, passando a experimentar autonomamente o ambiente onde está inserido.

AR é comumente aplicada quando não se consegue obter exemplos de comportamento correto nas situações que o agente deve enfrentar, ou quando o agente atuará em um ambiente desconhecido. Desta forma, não há apresentação de pares de entrada/saída. Ao invés disto, logo após tomar uma ação, o agente é informado sobre o seu resultado e sobre o estado subsequente alcançado pelo sistema, e desta forma ganha experiência sobre o ganho de suas ações em determinado estado. Então, a avaliação do sistema ocorre sempre concorrentemente com a aprendizagem, diferentemente da aprendizagem supervisionada (Kaelbling et al., 1996).

Desta forma, AR é uma técnica interessante quando não se pode realizar aprendizagem supervisionada, por não se ter uma fonte de conhecimento para informar os objetivos e as ações corretas, ou quando o domínio de aplicação não possibilita a realização de aprendizagem supervisionada, como é o caso da modelagem automática e dinâmica de EA. Isto é devido aos fatores relacionados à este processo específico, como não-determinismo, dificuldade em se modelar regras de comportamento determinísticas capazes de inferir EA, e demais questões expostas anteriormente.

A AR é baseada na existência de um crítico externo ao ambiente que avalia a ação tomada, mas sem indicar explicitamente a ação correta. Formalmente, AR utiliza uma estrutura composta de estados, ações e recompensas, conforme mostra a Figura 3.3 (Guelpe et al., 2003).

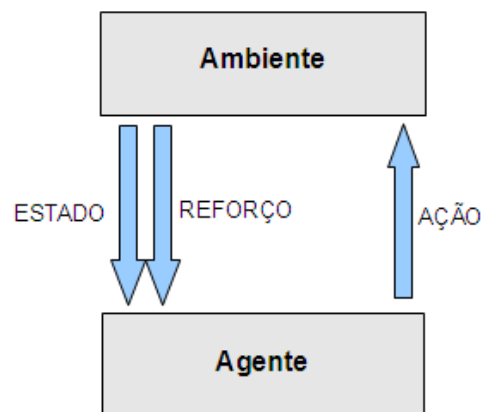


Figura 3.3: AR utiliza uma estrutura composta de estados, ações e recompensas

De acordo com Guelpe et al. (2003), o agente deve atuar em um ambiente descrito por um conjunto de possíveis estados, e pode executar, para cada estado, uma ação dentro de um conjunto de ações possíveis, recebendo um sinal de reforço a cada vez que executa uma ação. Este reforço indica o valor imediato da transição de estados em decorrência de uma ação. Ao longo do tempo, este processo produz uma sequência de pares (estado, ação) e seus respectivos valores de reforço, de forma que o objetivo do agente é aprender uma política que maximize uma soma esperada destes reforços em longo prazo.

Desta forma, um valor de reforço alto enviado pelo ambiente ao agente não significa

necessariamente que a ação tomada é recomendada. Uma ação é produto de uma decisão local no ambiente, sendo seu efeito imediato de natureza local. Entretanto, em um sistema baseado em AR, o intuito é alcançar objetivos globais. Ou seja, a qualidade das ações é medida em decorrência de soluções em longo prazo (Coelho, 2011).

De acordo com Coelho (2011), AR preocupa-se com o problema de um agente aprender a se comportar através de interações com um ambiente dinâmico através de tentativa e erro. De acordo com Iglesias et al. (2009a), AR lida com agentes conectados aos seus ambientes através de percepção e ação. A cada passo da interação, o agente recebe uma entrada proveniente do ambiente, uma indicação do estado corrente, s , e seleciona uma ação a , que representa sua saída.

A execução da ação produz uma transição de estados, e o ambiente fornece um sinal de reforço, r , indicando a qualidade da transição de estado dada pela ação. O objetivo final do agente é escolher as ações que tendem a elevar, em longo prazo, a soma dos valores dos sinais de reforço r , aprendendo a se comportar sistematicamente através de tentativa e erro, podendo este aprendizado ser guiado por uma variedade de políticas (Kaelbling et al., 1996).

De acordo com Iglesias et al. (2009a), problemas de AR são frequentemente modelados por processos de decisão markovianos⁴, em que o agente e o ambiente interagem em uma sequência discreta de passos no tempo, em que os estados S do ambiente, as ações A a serem executadas pelo agente, uma função de transição de estados T e o sinal de reforço R definem a dinâmica do processo:

- $R : S \times A \rightarrow \mathbb{R}$, em que um sinal de reforço é fornecido para cada estado $s \in S$ e cada ação $a \in A$.
- $T : S \times A \times S \rightarrow P$, em que para cada estado $s \in S$ e cada ação $a \in A$, uma distribuição de probabilidades é fornecida. $T(s, a, s')$ representa a probabilidade P

⁴É uma forma de modelar processos em que as transições entre estados são probabilísticas, em que é possível observar em qual estado o processo está, e é possível interferir no processo periodicamente, executando ações (Coelho, 2011)

de se transitar para um estado $s' \in S$ a partir de um estado $s \in S$, considerando-se a execução de uma ação $a \in A$ pelo agente.

O estado e a ação em dado instante determinam a distribuição de probabilidades para o estado seguinte e o reforço (Coelho, 2011). O objetivo do agente normalmente é escolher ações de modo a maximizar resultados subsequentes (Guelpli et al., 2003). Duas importantes propriedades da aprendizagem por reforço são a não utilização de conhecimento específico e o aprendizado incremental.

O processo de engenharia de conhecimento envolvido na construção de um agente aprendiz consiste apenas em codificar, de forma otimizada, as percepções e ações do agente e o reforço do ambiente, ou seja, definir que características do ambiente são relevantes para a tomada de decisão. Por outro lado, não é preciso codificar como o agente deve agir, nem mesmo que objetivo se deve alcançar, pois todo o aprendizado será automaticamente conduzido pelo reforço, de forma constante e incremental.

Essas características da AR a tornam uma opção naturalmente interessante para resolver o problema da modelagem automática e dinâmica de EAs em um Ambiente Virtual de Aprendizagem (AVA), que tem como fator crítico a necessidade de constante aprendizado. Além disso, a não utilização de conhecimento do domínio de aplicação torna o método genérico, podendo ter uma diversidade de aplicações. Guelpli et al. (2003) atesta que uma característica importante da AR é a aprendizagem automática em ambientes desconhecidos ou dinâmicos, como é o caso específico deste trabalho, estando esta técnica mais próxima da engenharia, estatística e teoria do controle, e mais relacionada a grandezas numéricas do que simbólicas.

De acordo com Guelpli et al. (2003), uma consideração importante a ser feita quando se lida com AR é o embate exploração *versus* exploração (Iglesias et al., 2009a). O agente deve decidir entre escolher a exploração de estados e ações desconhecidas, de modo a coletar novas informações, ou a exploração de estados e ações que já foram aprendidos e que irão gerar altas recompensas, de modo a maximizar seus reforços acumulados. Sendo assim, por um lado o agente deve aprender quais ações maximizam os valores das

recompensas obtidas no tempo, e, por outro, agir de forma a atingir esta maximização, explorando ações ainda não executadas ou regiões pouco visitadas do espaço de estados.

É importante, portanto, estabelecer uma política mista de exploração e exploração (política ϵ -greedy), que inclua a escolha intencional (com probabilidade ϵ) de se executar uma ação que não é considerada a melhor no estado atual, visando a aquisição de conhecimento. A escolha desta ação ocorre de forma aleatória. Em uma política de exploração pura (greedy) escolhem-se as ações que se julguem (talvez erroneamente, caso o algoritmo de AR ainda esteja longe da convergência) serem as melhores para resolver o problema (Guelpli et al., 2003).

De acordo com Kaelbling et al. (1996), o algoritmo *Q-learning* pode ser usado para definir a escolha da melhor ação. A escolha de uma ação é baseada em uma função de utilidade que mapeia estados e ações a um valor numérico. Cada valor $Q(s, a)$ representa a soma de reforços esperada ao se executar a ação a no estado s , seguindo-se uma política ótima a partir de então. Portanto, uma vez que os valores $Q(s, a)$ estejam bem estimados, a melhor ação a ser executada no estado s pode ser obtida através de (3.3), conforme alerta (Iglesias et al., 2009a), em que π^* representa a política de mapeamento de estados em ações que maximiza a medida de reforço em longo prazo, ou seja, a política ótima.

$$\pi^*(s) = \operatorname{argmax}_a Q^*(s, a) \quad (3.3)$$

A função valor ótima $Q^*(s, a)$ representa o reforço esperado de se tomar a ação ótima a no estado s , e então continuar escolhendo ações ótimas, e é definido recursivamente por (3.4), em que γ é um parâmetro de desconto que controla a importância relativa de recompensas de ações futuras em relação a novas ações, tal que $0 \leq \gamma < 1$ (Iglesias et al., 2009a). Desta forma, o objetivo do agente normalmente é escolher ações de modo a maximizar uma soma descontada dos reforços subsequentes.

$$Q^*(s, a) = R(s, a) + \gamma \sum_{s' \in S} T(s, a, s') \max_{a'} Q^*(s', a') \quad (3.4)$$

Políticas de atualização de Q baseadas em 3.4 fazem uso de informações relativas a todos os possíveis estados sucessores. Mas, uma política de atualização em que s' é selecionado a partir da distribuição $T(s, a, s')$ também pode ser utilizada. Neste caso, a regra de atualização do algoritmo Q -learning para aprendizagem é dada por (3.5), em que α é a taxa de aprendizagem, que indica quão rápido o sistema aprende, sendo $0 < \alpha < 1$ (Iglesias et al., 2009a).

$$Q(s, a) := Q(s, a) + \alpha(R(s, a) + \gamma(\max_{a'} Q(s', a') - Q(s, a))) \quad (3.5)$$

Na equação (3.5), s representa o estado antes da transição, a é a ação escolhida, $R(s, a)$ é o reforço recebido e s' é o próximo estado. A regra leva em consideração o melhor valor de $Q(s', a')$ a ser obtido no próximo estado, s' , de forma que quanto maior este valor, maior é a recompensa para $Q(s, a)$ (Kaelbling et al., 1996).

Como a função Q torna a ação explícita, pode-se estimar os valores de Q dinamicamente e utilizá-los para definir a política, já que uma ação pode ser escolhida apenas tomando-se o maior Q para o estado corrente s .

O algoritmo Q -learning, iterativamente, seleciona uma ação a , seguindo uma estratégia de exploração/exploração e a executa, recebe a recompensa r , e atualiza os valores $Q(s, a)$ de acordo com a equação (3.5). Com base nos valores de $Q(s, a)$, o algoritmo de AR estima dinamicamente a ação de maior valor de utilidade. O Q -learning é apresentado no Algoritmo 3.1, de acordo com (Iglesias et al., 2009a).

Algoritmo 3.1 Q -learning

Para cada par $(s \in S, a \in A)$, inicialize a tabela de valores $Q(s, a)$
 Observe o estado corrente, s
while s não seja o estado final **faça** **do**
 Selecione uma ação, a , e execute-a
 Receba a recompensa, r
 Observe o novo estado, s'
 Atualize a entrada da tabela para $Q(s, a)$ conforme 3.5
 Atribua s' a s
end while

A seleção da próxima ação a é muito importante para a convergência do algoritmo Q -

learning. A qualidade da estratégia de exploração/exploração selecionada é determinante na eficiência e na eficácia do processo de aprendizagem (Iglesias et al., 2009a). Em geral, o ambiente é não-determinístico, ou seja, tomar a mesma ação, no mesmo estado, em duas ocasiões diferentes, pode resultar em diferentes próximos estados e diferentes sinais de reforço. Isto ocorre no presente trabalho, devido ao aspecto não determinístico do processo de aprendizagem, conforme discute-se no capítulo 4.

Em detrimento de diversos fatores, a abordagem proposta neste trabalho foi testada através da simulação computacional de aprendizagem em estudantes. Desta forma, alguns aspectos relacionados a esta questão são tratados a seguir.

3.6 Simulação Computacional de Estudantes

Para avaliar a abordagem proposta neste trabalho, foram utilizadas técnicas de simulação computacional (Biermann e Ramm, 2001). Para Chwif e Medina (2007), a simulação é a imitação do funcionamento de um processo por meio do funcionamento de outro, com intuito de realização de testes, experiências e ensaios. A simulação nos permite observar como um sistema se comporta ao longo de uma sequência de passos, permitindo entender o sistema e prever seu comportamento, para que seja possível otimizar decisões de projeto, e até mesmo validar um modelo proposto (Chwif e Medina, 2007). Desta forma, um processo de simulação pode nos fornecer uma visão clara sobre o funcionamento de um sistema, para que se possa entendê-lo e testá-lo antes que seja implementado, o que pode demandar elevado investimento de recursos.

De acordo com (Biermann e Ramm, 2001), a metodologia para se construir um processo de simulação de um sistema computacional segue três passos principais:

- Especificar um modelo que capture a essência do sistema, sua ambientação, suas variáveis e modelos matemáticos que representem fielmente seu comportamento.
- Desenvolver uma função de evolução que mova o processo para o próximo estado do sistema. A entrada desta função é o conjunto das variáveis do sistema em determi-

nado momento. A saída é o próximo estado do sistema, ou seja, os novos valores destas variáveis, após transcorrido determinado intervalo de tempo.

- Atribuir um estado inicial ao modelo e aplicar a função de evolução repetidamente para que se possa analisar o comportamento do sistema ao longo do tempo e os resultados por ele gerados.

Prodan e Prodan (2001) defende que modelos estocásticos são ferramentas poderosas para a representação de processos e fenômenos do mundo real através de técnicas de simulação computacional. A modelagem estocástica é uma técnica que permite a apresentação de dados ou predição de eventos futuros que levam em consideração certo grau de aleatoriedade ou imprevisibilidade. Ao invés de utilizar variáveis determinísticas, como em outros tipos de modelos matemáticos, um modelo estocástico incorpora variáveis randômicas, implicando em comportamento não determinístico.

Sampaio (1997) coloca algumas questões para reflexão sobre a modelagem dinâmica computacional no processo de ensino-aprendizagem, e as possibilidades de construção de sistemas simplificados capazes de simular algumas características significativas de um sistema que pertence ao mundo real. Para Sampaio (1997), a simulação está associada à ideia de um componente de *software* que tem por objetivo imitar o comportamento de um certo domínio. Ou seja, a simulação infere um processo de iteração entre as estruturas que compõem o modelo, com o objetivo de criar um comportamento.

Em (Brusilovsky et al., 2004) os autores argumentam que o sucesso de um modelo de adaptação em SAIE depende de dois aspectos distintos: a modelagem do estudante e as decisões de adaptação. Neste contexto, é de fundamental importância que se possa testar e avaliar o modelo proposto, para que se possa detectar problemas e realizar ajustes e correções em todos os seus aspectos, validando-o antes de sua efetiva utilização em um sistema real utilizado por estudantes reais.

Para isto, a utilização de técnicas de simulação computacional é fundamental, já que a implementação e teste de novas abordagens em projetos de *e-learning* requerem quantias consideráveis de recursos financeiros, humanos e de tempo (Graf et al., 2009b). Esta

questão é ainda mais crítica ao considerar que a demanda por sistemas de *e-learning* é cada vez maior, e o número de estudantes que dependem destes sistemas cresce rapidamente (Graf et al., 2009b).

Alguns trabalhos, como aqueles desenvolvidos por Abdullah e Cooley (2002); Vanlehn et al. (1994); Vizcaino e du Boulay (2002); Virvou et al. (2003); Bravo e Ortigosa (2006); Mertz (1997); Iglesias et al. (2009b); Guelpeli et al. (2003) propõe diferentes abordagens para utilização de simulação de estudantes na avaliação de SAIE. Porém, nenhum destes trabalhos levam em consideração EA no processo de simulação.

O uso de simulação tem sido essencial para o ajuste e correção de problemas e aprimoramento da abordagem proposta neste trabalho, já que permite a avaliação imediata de modificações no modelo de forma rápida, enquanto que a execução de um único teste utilizando estudantes reais levaria meses, devido ao tempo, quantidade de material (por exemplo, objetos de aprendizagem) a ser produzido, envolvimento de muitas pessoas e, conseqüentemente, ao custo necessário para se executar um curso à distância através de um SAIE (Graf et al., 2009b).

Cabe ainda ressaltar que, de acordo com Iglesias et al. (2009a), muitos experimentos são necessários a fim de se obter conclusões sobre a avaliação de uma abordagem educacional e, portanto, uma grande quantidade de estudantes são necessários para interagir com o sistema durante os experimentos, que são de longo prazo. Ainda, conforme alertam Iglesias et al. (2009a), normalmente é difícil convencer um estudante a interagir com um sistema em avaliação, e é improvável convencer a quantidade de estudantes que se necessita para a execução dos experimentos. Assim, a maioria destes sistemas são avaliados através da utilização de simulação computacional de estudantes, o que também ocorre neste trabalho.

Capítulo 4

Abordagem Proposta

Esta seção apresenta em detalhes a abordagem proposta, considerando, inicialmente, o ME probabilístico utilizado como base para a modelagem automática e dinâmica de EA, na seção 4.1. Em seguida, na seção 4.2, apresenta-se detalhadamente o modelo estocástico para seleção de estratégias pedagógicas, baseado na combinação de estilos de aprendizagem (CEA) a serem aplicadas no fornecimento de adaptatividade, implementado através do Módulo Pedagógico (MP).

Uma característica desta abordagem é que o ME é atualizado gradualmente através de um processo estocástico (Pollard, 1984) iterativo e interativo (Franzoni e Assar, 2009) baseado em AR, implementado pelo Componente de Modelagem do Estudante (CME), apresentado na seção 4.3. Como consequência, tem-se a clusterização probabilística dos estudantes em categorias pedagógicas.

A integração de um SAIE com a abordagem proposta neste trabalho, considerando seus 3 componentes principais (ME, MP e CME), é apresentada na seção 4.4.

O processo é iterativo, já que se dá ao longo de vários ciclos de repetição em que ocorre a gradual convergência do ME em direção às preferências reais do estudante ao longo do processo de aprendizagem. O processo é interativo, porque, na prática, a cada iteração do processo de aprendizagem o desempenho do estudante deve ser avaliado, e muitas das vezes estas avaliações envolvem interação direta com o estudante através de

questionários de avaliação, o que não ocorreu nos experimentos realizados neste trabalho, em decorrência do uso de simulação computacional do processo de aprendizagem.

Desta forma, a avaliação de desempenho do estudante, que geralmente envolve avaliação de conhecimento e de comportamento, não é tratada neste trabalho, devido à sua complexidade, e por ser tratada de forma específica por uma diversidade de outros trabalhos, tais como (Dorça et al., 2009; Dorça, 2004; Lopes et al., 2008b). Desta forma, para realização de experimentos, este trabalho utiliza um modelo probabilístico para simular o desempenho do estudante e seu processo de aprendizagem.

4.1 Modelo do Estudante

De acordo com Gogvadze et al. (2011), a eficiência de um SAIE depende de forma crítica da qualidade de sua modelagem do estudante. O sistema pode implementar uma estratégia de adaptação precisa com o intuito proporcionar aos alunos conteúdos de aprendizagem personalizados. Mas, se as suas estimativas sobre conhecimento e preferências do estudante são inconsistentes, as intervenções de adaptação que ele produz não são eficientes. Neste caso, o conceito de consistência indica se o ME descreve corretamente as características do estudante.

A abordagem proposta neste trabalho utiliza informações sobre a performance do estudante para atualizar o ME frequentemente, enquanto o estudante utiliza o sistema para aprender. Desta forma, os EA são dinamicamente e constantemente atualizados. Pode-se concluir que este trabalho leva em consideração o desenvolvimento de uma abordagem avançada para modelagem do estudante, combinando os aspectos automático, dinâmico e global, como apontado por Graf e Kinshuk (2009a).

O aspecto automático existe porque o processo de construção e atualização do ME é feito automaticamente com base na performance (comportamento e conhecimento) do estudante enquanto o sistema é utilizado para aprendizagem. O sistema usa essas informações para inferir os EA através de um método baseado em AR. Portanto, os estudantes

precisam se concentrar apenas na aprendizagem, em vez de, adicionalmente, fornecer explicitamente informações sobre suas preferências.

O aspecto dinâmico desta abordagem para modelagem de estudante é responsável por utilizar as informações de performance para atualizar o ME frequentemente durante o processo de aprendizagem. Portanto, o sistema é capaz de melhorar e revisar as informações sobre EA dos estudantes e, conseqüentemente, corrigir dados inconsistentes no ME. Como consequência, obtém-se maior precisão dos EA identificados, e um processo de adaptatividade mais acurado.

O aspecto global da modelagem foca em considerar todos os componentes e serviços integrados no ambiente de aprendizagem para reunir dados sobre a performance do estudante, considerando uma diversidade de aspectos relacionados ao seu comportamento e nível cognitivo, conforme apresentado por Dorça et al. (2009), permitindo uma identificação mais precisa de EA do estudante.

Existem muitas características relacionadas ao estudante que podem ser consideradas por um SAIE (Brusilovsky, 2001b). Para alcançar os objetivos propostos neste trabalho, considera-se objetivos de aprendizagem, nível cognitivo e EA dos estudantes. Neste contexto, o ME utilizado neste trabalho utiliza a Taxonomia de Bloom (Krathwohl, 2002) para medição de conhecimento através de uma abordagem de sobreposição (*overlay*), onde o nível de conhecimento do estudante em cada conceito do domínio a ser aprendido (nível cognitivo) é armazenado e atualizado durante o processo de aprendizagem. Neste método, o conhecimento do estudante é visto como um subconjunto do conhecimento do sistema, e requer que o modelo do domínio represente conceitos individualmente.

Esta abordagem se mostrou aderente aos objetivos deste trabalho, devido à sua objetividade e transparência na representação do conhecimento do estudante, e desta forma mostrando eficiência e facilidade de implementação. De qualquer forma, o uso de outras abordagens na modelagem do conhecimento do estudante não causa impacto algum no processo de modelagem automática de EA proposta neste trabalho. Desta maneira, o ME definido nesta abordagem considera, de forma eficiente, EA, estado cognitivo (EC)

e objetivos de aprendizagem (OA), medidos através de pares (conceito,valor), conforme exemplo apresentado pela Tabela 4.1. Um OA indica qual nível cognitivo (valor) o estudante deve atingir em um conceito do domínio a ser aprendido. Um EC indica qual o nível cognitivo atual do estudante em determinado conceito. A modelagem de EC e OA é particularmente importante neste trabalho para que o algoritmo de AR, implementado pelo CME, pare quando os OA forem atingidos, ou seja, quando $EC = OA$.

Tabela 4.1: Modelo Estudante

EA Probabilísticos							
Processamento		Percepção		Entrada		Organização	
Atv.	Ref.	Sen.	Int.	Vis.	Ver.	Seq.	Glb.
0,35	0,65	0,17	0,83	0,89	0,11	0,84	0,16
Objetivos de Aprendizagem e Estado Cognitivo							
$OA = \{\langle C_0, 5 \rangle \dots \langle C_{n-1}, 5 \rangle\}$ $EC = \{\langle C_0, -1 \rangle \dots \langle C_{n-1}, -1 \rangle\}$							

Como pode-se perceber na Tabela 4.1, a preferência por cada EA é armazenada no ME como um valor real no intervalo $[0,1]$. Este valor representa a probabilidade do estudante preferir um ou outro EA dentro de cada dimensão do FSLSM, chamado aqui de Estilos de Aprendizagem probabilísticos (EA_p). Ou seja, com isto, passamos a representar as preferências do estudante como distribuições de probabilidades que são armazenadas diretamente no ME. Desta forma, tem-se um ME probabilístico em que EA são tratados pelo sistema como probabilidades, e não como certezas.

Desta forma, considerando o aspecto probabilístico do ME, o exemplo fornecido pela Tabela 4.1 representa um estudante com 35% de probabilidade de preferência pelo estilo ativo e 65% de probabilidade de preferência pelo estilo reflexivo; 17% de probabilidade de preferência pelo estilo sensitivo e 83% de probabilidade de preferência pelo estilo intuitivo; 89% de probabilidade de preferência pelo estilo visual e 11% de probabilidade de preferência pelo estilo verbal; 84% de probabilidade de preferência pelo estilo sequencial e 16% de probabilidade de preferência pelo estilo global. Então, pode-se considerar que este estudante provavelmente é Reflexivo, Intuitivo, Visual e Sequencial.

Conforme observa-se na Tabela 4.1, além dos EAs do estudante, armazena-se o

seu nível cognitivo e objetivos de aprendizagem, ambos de acordo com a Taxonomia de Bloom. O nível cognitivo (NC), OA, e EC são apresentados pelas definições 4.1.1, 4.1.2, 4.1.3 respectivamente. Finalmente, o ME é apresentado pela Definição 4.1.4.

Definição 4.1.1 *Nível Cognitivo (NC)*

$NC = \{ \text{Conhecimento (0), Compreensão (1), Aplicação (2), Análise (3), Síntese (4), Avaliação (5)} \}$

Definição 4.1.2 *Objetivos de Aprendizagem (OA)*

Sub-conjunto de conceitos do modelo do domínio a serem aprendidos, dado por

$$OA = \{ \langle a, b \rangle | a \in C, b \in NC \},$$

onde

$C = \{C_0, \dots, C_{n-1}\}$, *são conceitos do curso a serem aprendidos pelo estudante.*

Definição 4.1.3 *Estado Cognitivo (EC)*

É o conjunto $EC = \{ \langle a, b \rangle | a \in C, b \in NC \uplus \{Indeterminado(-1)\} \}$ que determina o NC do estudante em cada conceito do curso em determinado momento.

Definição 4.1.4 *Modelo do Estudante (ME)*

O ME é uma 3-upla composta pelos estilos de aprendizagem, objetivos de aprendizagem e estado cognitivo do estudante, sendo

$$ME = \langle EA, OA, EC \rangle.$$

O EC inicial do estudante pode ser levantado através de um questionário que avalie o conhecimento prévio do estudante sobre o domínio. Caso isto não seja realizado, considera-se a inicialização do NC do estudante em um conceito como Indeterminado (-1).

Em relação a EA, caso seja utilizado um instrumento para a identificação de EA compatível com o FSLSM, como o ILSQ, o ME pode ser inicializado através dos dados obtidos pelo questionário, fazendo-se a conversão considerando-se a proporcionalidade das respostas pontuadas para cada EA. Esta conversão é dada por (4.1), que divide a quantidade de respostas favoráveis a um EA pelo total de respostas dentro da dimensão,

que é 11 em todas as dimensões (totalizando 44 questões no ILSQ). Conforme afirmam Felder e Spurlin (2005); Graf et al. (2008); Kinshuk et al. (2009), considerando-se os resultados obtidos através do ILSQ para cada dimensão do FSLSM, diferenças entre 1 e 3 correspondem a uma preferência leve (ou balanceada) por um estilo; entre 5 e 7 indica preferência moderada por um deles; e entre 9 e 11 indica forte preferência por um estilo.

$$Pr_i = \frac{Resp_i}{11} \quad (4.1)$$

Por exemplo, considerando-se o ILSQ, caso um estudante tenha respondido 3 questões favoráveis ao estilo Ativo e 8 questões favoráveis ao estilo Reflexivo, na dimensão Processamento, tem-se:

$$Pr_A = \frac{3}{11} = 0,28$$

$$Pr_R = \frac{8}{11} = 0,72$$

Desta forma, armazena-se no ME o valor 0,28 para Ativo e 0,72 para Reflexivo, que no escopo de nossa abordagem significa dizer que existe uma probabilidade de 28% do estudante preferir o EA Ativo, e 72% de probabilidade de preferir o EA Reflexivo. Continuando o exemplo, vamos considerar que as demais respostas do estudante ao questionário resultaram em:

$$Pr_S = \frac{1}{11} = 0,09$$

$$Pr_I = \frac{10}{11} = 0,91$$

$$Pr_{Vi} = \frac{5}{11} = 0,45$$

$$Pr_{Ve} = \frac{6}{11} = 0,55$$

$$Pr_{Seq} = \frac{9}{11} = 0,82$$

$$Pr_G = \frac{2}{11} = 0,18$$

Então, a Tabela 4.2 apresenta a configuração inicial de EA no ME.

Tabela 4.2: Exemplo de Inicialização do ME utilizando o ILSQ

EA Probabilísticos							
Processamento		Percepção		Entrada		Organização	
Atv.	Ref.	Sen.	Int.	Vis.	Ver.	Seq.	Glb.
0,28	0,72	0,09	0,91	0,45	0,55	0,82	0,18

Desta forma, considerando-se a Tabela 4.2, o estudante provavelmente é Reflexivo, Intuitivo, Verbal e Sequencial. Como pode-se notar pelos exemplos das Tabelas 4.1, 4.2, 4.3, os EA_p do estudante são considerados no ME conforme apresenta a Definição 4.1.5.

Definição 4.1.5 *Estilos de Aprendizagem Probabilísticos (EA_p)*

$EA = \{(Pr_A, Pr_R), (Pr_S, Pr_I), (Pr_{Vi}, Pr_{Ve}), (Pr_{Seq}, Pr_G) \mid Pr_A + Pr_R = 1, Pr_S + Pr_I = 1, Pr_{Vi} + Pr_{Ve} = 1, Pr_{Seq} + Pr_G = 1\}$ tal que: $A=Ativo$; $R=Reflexivo$; $S=Sensitivo$; $I=Intuitivo$; $Vi=Visual$; $Ve=Verbal$; $Seq=Sequencial$; $G=Global$

sendo:

Pr_A a probabilidade do estudante preferir o estilo Ativo;

Pr_R a probabilidade do estudante preferir o estilo Reflexivo;

Pr_S a probabilidade do estudante preferir o estilo Sensitivo;

Pr_I a probabilidade do estudante preferir o estilo Intuitivo;

Pr_{Vi} a probabilidade do estudante preferir o estilo Visual;

Pr_{Ve} a probabilidade do estudante preferir o estilo Verbal;

Pr_{Seq} a probabilidade do estudante preferir o estilo Sequencial;

Pr_G a probabilidade do estudante preferir o estilo Global.

Então, os EA_p dos estudantes são representados através de distribuições de probabilidades no ME, indicando as probabilidades de preferência por cada EA dentro de cada dimensão. Vale a pena ressaltar que a abordagem para diagnóstico automático e dinâmico de EA proposta neste trabalho permite, mas não requer, a utilização de qualquer instrumento para a identificação de EA, em decorrência de seu aspecto automático, conforme mencionado anteriormente.

Desta forma, esta abordagem, em consonância com Graf e Lin (2007); Price (2004);

Roberts e Erdos (1993) em relação à imprecisão em auto-concepções do estudante no processo de preenchimento de questionários psicométricos, como o ILSQ, e em harmonia com Graf e Liu (2008) em relação às vantagens da detecção automática de EA, elimina a necessidade de utilização do ILSQ. Desta forma, caso nenhum questionário para a identificação inicial de EAs dos estudantes seja utilizado, os seus EA_p no ME são inicializados conforme apresenta a Tabela 4.3. Ao deixar de armazenar concepções inconsistentes em relação aos EAs dos estudantes, a abordagem proposta consegue inferi-los de forma eficiente, conforme observou-se nos experimentos realizados.

Tabela 4.3: Exemplo de Inicialização do ME sem utilização do ILSQ

EA Probabilísticos							
Processamento		Percepção		Entrada		Organização	
Atv.	Ref.	Sen.	Int.	Vis.	Ver.	Seq.	Glb.
0,50	0,50	0,50	0,50	0,50	0,50	0,50	0,50

Neste ponto é importante mencionar que, apesar do ME ser exclusivamente baseado em EA, OA e NC, existem muitos outros fatores que são importantes e devem ser considerados na modelagem do estudante, tais como Martins et al. (2008): capacidades cognitivas, preferências, perfil acadêmico, idade, estilo cognitivo (afetivo, impulsivo, dentre outros), traços de personalidade (introvertido, extrovertido, dentre outros), deficiências (visual ou outras). Fatores importantes também são discutidos em (Dorça et al., 2009). Desta forma, o ME é geralmente mais complexo do que o apresentado neste trabalho. Mas, para atingir o objetivo proposto, foi fundamental focar a atenção em EA, excluindo-se outros aspectos da modelagem do estudante. Como consequência, isolou-se esta complexidade a fim de se chegar a uma abordagem eficiente para modelagem de EA. Mas, é importante mencionar que ao se utilizar esta abordagem em um SAIE, tais características do ME podem e devem ser consideradas para o fornecimento de adaptatividade.

4.2 Módulo Pedagógico

Esta seção apresenta em detalhes o funcionamento e a implementação do módulo pedagógico (MP). O MP é responsável por selecionar, dentre as estratégias pedagógicas possíveis, a estratégia pedagógica mais apropriada a um estudante, levando em consideração as informações armazenadas no ME. Com isto espera-se fornecer assistência personalizada e adaptatividade do processo de ensino. O MP proposto neste trabalho é baseado em CEA, levando em consideração os aspectos probabilísticos do ME e modelando-os adequadamente através de cadeias de Markov, dando origem a um processo estocástico para fornecimento de adaptatividade baseada em EA. A partir deste processo, o CME detecta automática e dinamicamente os EAs dos estudantes.

De acordo com (Franzoni e Assar, 2009; Franzoni et al., 2008), uma CEA é uma tupla formada por 4 estilos de aprendizagem, cada um pertencente a uma dimensão do FSLSM, conforme apresenta a Definição 4.2.1.

Definição 4.2.1 *Combinação de estilos de aprendizagem (CEA)*

$$CEA = (a, b, c, d | a \in D1, b \in D2, c \in D3, d \in D4)$$

considerando:

$$D1 = \{Ativo(A), Reflexivo(R)\};$$

$$D2 = \{Sensitivo(S), Intuitivo(I)\};$$

$$D3 = \{Visual(Vi), Verbal(Ve)\};$$

$$D4 = \{Sequencial(Seq), Global(G)\}.$$

Desta forma, existem 16 (2^4) possíveis CEAs, conforme apresentado pela Definição 4.2.2.

Definição 4.2.2 *Combinações de estilos de aprendizagens (CEAs)*

$$\begin{aligned} CEAs = \{ & (A, S, Vi, Seq), (A, S, Vi, G), (R, S, Vi, Seq), (R, S, Vi, G), (A, S, Ve, Seq), \\ & (A, S, Ve, G), (R, S, Ve, Seq), (R, S, Ve, G), (A, I, Vi, Seq), (A, I, Vi, G), (R, I, Vi, Seq), \\ & (R, I, Vi, G), (A, I, Ve, Seq), (A, I, Ve, G), (R, I, Ve, Seq), (R, I, Ve, G) \} \end{aligned}$$

No escopo deste trabalho, uma CEA é formada por 4 variáveis probabilísticas, definidas pelas 4 dimensões do FSLSM. Cada variável possui 2 valores possíveis, e cada valor representa um EA cujas possibilidades de assumir um valor ou outro é dado por sua probabilidade de preferência pelo estudante, conforme apresentado na seção 4.1. Desta forma, é proposta uma abordagem regida por um processo estocástico baseado nas 4 dimensões de estilos de aprendizagem do FSLSM.

A cada seção de aprendizagem do curso, o MP seleciona estocasticamente uma CEA cujos EA são combinados de acordo com as probabilidades de preferência de EA armazenados no ME. Neste contexto, uma grande vantagem desta abordagem é considerar estocasticamente, durante o processo de aprendizagem, todas as CEAs de acordo com as probabilidades de preferências do estudante armazenadas no ME, que podem estar inconsistentes ou variar ao longo do tempo em decorrência de algum aspecto, conforme discutido anteriormente.

Com isto, é possível proporcionar ações instrucionais voltadas às necessidade dos estudantes, e ao mesmo tempo, permitir o desenvolvimento de outras habilidades que não fazem parte dos seus EAs preferenciais, objetivando-se o desenvolvimento da destreza mental, além de estimular e fortalecer as habilidades menos desenvolvidas, conforme sugerem Lopes (2002); Messick (1976).

Desta forma, EA do estudante são vistos pelo MP como uma coleção de variáveis probabilísticas, ou aleatórias, que descrevem o processo de ensino e fornecimento de adaptatividade a ser executado pelo módulo pedagógico em um período de tempo, de acordo com um processo estocástico que leva em consideração as incertezas em relação ao desempenho (conhecimento e comportamento) do estudante e, também, as possíveis inconsistências dos EA_p no ME em determinado instante. É importante observar que esta é uma preocupação do MP, que deve ser capaz de decidir como o estudante prefere aprender (formato, sequência), conforme atestam Iglesias et al. (2009a).

Desta forma, considera-se que o estudante pode, com maior ou menor probabilidade, pertencer a qualquer uma das 16 categorias pedagógicas dadas pelas 16 CEAs da Definição

4.2.2. Desta forma, pode-se dizer que temos uma classificação probabilística e dinâmica dos estudantes, que estocasticamente se enquadram a estas categorias pedagógicas ao longo do processo de aprendizagem com maior ou menor probabilidade.

Então, considera-se que o estudante tem uma probabilidade de pertencer a qualquer uma destas categorias, ou seja, a pertinência de um estudante a uma categoria é probabilística, e não determinística (como ocorre nas abordagens tradicionais). Com isto, espera-se produzir um melhor tratamento da incerteza inerente à inferência da categoria pedagógica à qual um estudante pertence, levando-se em consideração seus EA. Caso o ME seja consistente, as necessidades pedagógicas do estudante serão atendidas com maior probabilidade através de estratégias pedagógicas que atendam aos seus EA, porém sem desconsiderar as demais CEAs, diante dos aspectos de incerteza apresentados no capítulo 2.

Desta forma, o MP considera a existência de 16 tipos possíveis de estudantes, considerando que um estudante pode, em determinado momento, de forma imprevisível e em decorrência de diversos fatores, por exemplo, o domínio do conhecimento ou nível cognitivo, tender de uma categoria a outra, conforme observado por Jones et al. (2003). À medida que o processo de aprendizagem evolui, os EA_p no ME são atualizadas pelo CME, tornando este processo cada vez mais bem adaptado ao estudante. Tal processo é modelado através de cadeias de Markov.

Neste processo, tem-se uma coleção de 4 variáveis probabilísticas independentes, representando cada uma das dimensões do FSLSM, podendo, então, este modelo ser representado por 4 máquinas de estados em que as transições são estocásticas. Este modelo é responsável pela seleção estocástica de uma CEA durante o processo de aprendizagem, de acordo com os EA_p no ME. As cadeias são variantes no tempo, em que as probabilidades de transição variam, devido aos ajustes que ocorrem nos EA_p , alterando o mecanismo de funcionamento das cadeias e consequentemente, afetando a seleção da CEA a cada seção de aprendizagem. Desta forma, tem-se um processo estocástico não estacionário, variante no tempo, pois as probabilidades variam ao longo do tempo.

No processo de diagnóstico automático e dinâmico dos EAs do estudante, em termos formais, a CEA representa o estado do sistema no tempo t , sendo irrelevantes as informações de estados passados e o tempo em que o processo se encontra no estado atual. Cabe ressaltar que tal processo é discreto em relação ao tempo e estado. Desta forma, este processo é um fenômeno que varia em algum grau de forma imprevisível à medida que o tempo passa.

Tal processo é modelado através de 4 cadeias de Markov concorrentes, em tempo discreto $t = 1..n$ dado pela sequência de seções de aprendizagem pelas quais o estudante passa ao longo do processo de aprendizagem. As cadeias e respectivas matrizes de transição de estados referentes ao processo, considerando-se o ME apresentado na Tabela 4.1, são apresentadas na Figura 4.1.

Cada estado de uma cadeia representa um EA dentro de uma dimensão do FSLSM. Na sub-figura 4.1a, o estado 0 representa o estilo Ativo e 1 representa o estilo Reflexivo. Na sub-figura 4.1b, o estado 0 representa o estilo Sensitivo e 1 representa o estilo Intuitivo. Na sub-figura 4.1c, o estado 0 representa o estilo Visual e 1 representa o estilo Verbal. Na sub-figura 4.1d, o estado 0 representa o estilo Sequencial e 1 representa o estilo Global. As transições entre os estados representam as probabilidades de ocorrência de um ou outro EA na composição estocástica da CEA. Nota-se que tais cadeias são irredutíveis, já que é possível transitar entre qualquer par de estados num número finito de passos com probabilidade não nula.

A cada EA corresponde a i -ésima linha (p_{i1}, p_{i2}) da matriz de transição de estados, que representa as probabilidades de ocorrência de x_j no instante n a partir do EA x_i no instante $n - 1$. Por exemplo, para a dimensão Processamento, se a CEA atual é composta pelo estado 0 (Ativo), então, tem-se 35% de probabilidade da próxima CEA continuar em Ativo no instante $t = n$, e 65% de probabilidade da nova CEA ser composta por Reflexivo (estado 1) no instante $t = n$. Se a CEA atual contém o EA Reflexivo, então tem-se 65% de probabilidade da nova CEA continuar composta pelo estilo Reflexivo no instante $t = n$ e 35% de probabilidade de conter o EA Ativo no instante $t = n$.

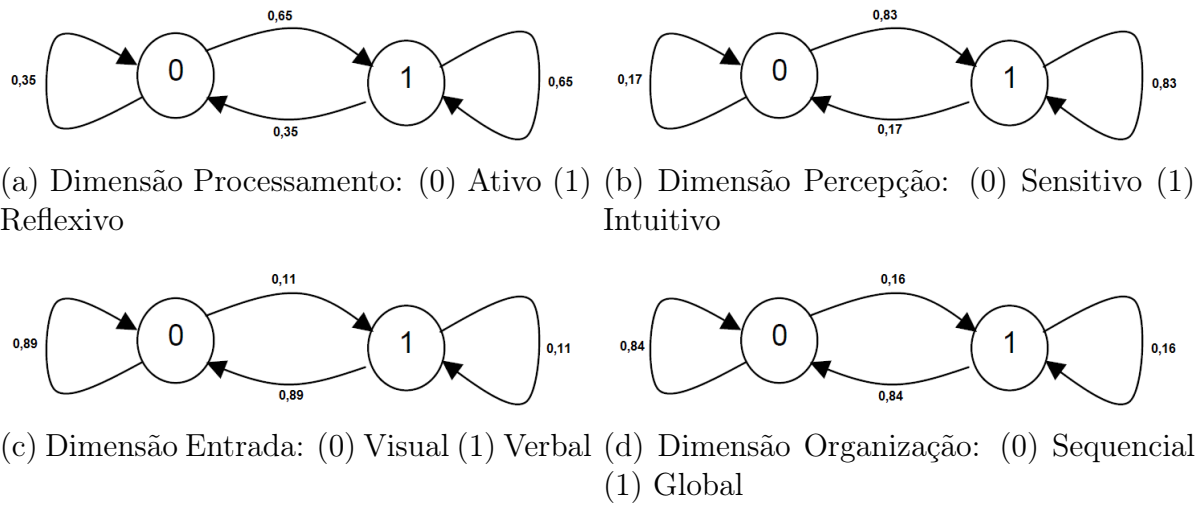


Figura 4.1: Modelo markoviano do processo estocástico de seleção de uma CEA

Portanto, uma preferência de cada dimensão é selecionada para compor uma CEA, que deverá ser considerada para fornecimento de adaptatividade na próxima sessão de aprendizagem do curso. Como resultado, o ME é constantemente atualizado, conforme explicado mais adiante nesta seção. As matrizes de transição $D1, D2, D3, D4$ descrevem as variáveis aleatórias modeladas pelas cadeias da Figura 4.1.

$$D1 = \begin{bmatrix} 0.35 & 0.65 \\ 0.35 & 0.65 \end{bmatrix} \quad D2 = \begin{bmatrix} 0.17 & 0.83 \\ 0.17 & 0.83 \end{bmatrix} \quad D3 = \begin{bmatrix} 0.89 & 0.11 \\ 0.89 & 0.11 \end{bmatrix} \quad D4 = \begin{bmatrix} 0.84 & 0.16 \\ 0.84 & 0.16 \end{bmatrix}$$

$D1$ representa a cadeia de Markov apresentada na Figura 4.1a, $D2$ representa a cadeia de Markov apresentada na Figura 4.1b, $D3$ representa a cadeia de Markov apresentada na Figura 4.1c e $D4$ representa a cadeia de Markov apresentada na Figura 4.1d.

Como estas preferências são atualizadas constantemente, é impossível prever a probabilidade de se observar sequências de estados específicos ao longo do processo, pois as probabilidades de ocorrência destes estados mudam constantemente. É importante notar que são irrelevantes as informações de estados passados e o tempo em que o processo se encontra no estado atual. Cabe ressaltar que tal processo é discreto em relação ao tempo e estado.

Desta forma, as matrizes de probabilidades são alteradas constantemente ao longo do processo de ensino-aprendizagem à medida que o ME é atualizado. Então, este processo é muito particular a cada estudante, já que cada um possui diferentes preferências armazenadas no ME, e depende de sua interação com o sistema. Ou seja, para cada estudante existem 4 matrizes de transição de estados distintas dadas pelos EA_p armazenados em seu ME, que permitem ao módulo pedagógico decidir a cada momento, dinamicamente, qual a melhor estratégia pedagógica para o estudante.

Considerando os EA_p , a probabilidade P de pertinência do estudante a uma categoria pedagógica é dada por (4.2), que é a mesma de uma CEA ser selecionada durante uma seção de aprendizagem, que é igual à probabilidade de preferência do estudante pela CEA. A probabilidade P é calculada através de (4.2), em que a, b, c, d é dado pela Definição 4.2.1.

$$P(a, b, c, d) = Pr_a \times Pr_b \times Pr_c \times Pr_d \quad (4.2)$$

Desta forma, de acordo com (4.2), a probabilidade de preferência do estudante pela CEA (A,S,Vi,Seq), considerando-se o ME dado pela Tabela 4.1, é dada por:

$$P(A, S, Vi, Seq) = Pr_A \times Pr_S \times Pr_{Vi} \times Pr_{Seq}$$

$$P(A, S, Vi, Seq) = 0,35 \times 0,17 \times 0,89 \times 0,84 = 0.045$$

Então, aplicando-se (4.2) às CEAs dadas pela Definição 4.2.2, tem-se a distribuição de probabilidades apresentadas na Tabela 4.4, considerando-se o ME dado pela Tabela 4.1.

Desta forma, uma vantagem desta abordagem é considerar estocasticamente todas as CEAs de acordo com os EA_p do estudante, que pode ser inconsistente, ou seja, pode não representar a preferência real do estudante, como apontado no capítulo 2. Conforme apresentado no capítulo 5, esta característica permite a descoberta eficiente e eficaz de EA do estudante. Então, esta abordagem é intrinsecamente capaz de lidar com a incerteza no

Tabela 4.4: Distribuição de Probabilidades das CEAs

CEA	Probabilidades
$P(A,S,Vi,Seq)$	$0,35 \times 0,17 \times 0,89 \times 0,84 = 0,045$
$P(A,S,Vi,G)$	$0,35 \times 0,17 \times 0,89 \times 0,16 = 0,008$
$P(R,S,Vi,Seq)$	$0,65 \times 0,17 \times 0,89 \times 0,84 = 0,083$
$P(R,S,Vi,G)$	$0,65 \times 0,17 \times 0,89 \times 0,16 = 0,016$
$P(A,S,Ve,Seq)$	$0,35 \times 0,17 \times 0,11 \times 0,84 = 0,005$
$P(A,S,Ve,G)$	$0,35 \times 0,17 \times 0,11 \times 0,16 = 0,002$
$P(R,S,Ve,Seq)$	$0,65 \times 0,17 \times 0,11 \times 0,84 = 0,010$
$P(R,S,Ve,G)$	$0,65 \times 0,17 \times 0,11 \times 0,16 = 0,003$
$P(A,I,Vi,Seq)$	$0,35 \times 0,83 \times 0,89 \times 0,84 = 0,217$
$P(A,I,Vi,G)$	$0,35 \times 0,83 \times 0,89 \times 0,16 = 0,043$
$P(R,I,Vi,Seq)$	$0,65 \times 0,83 \times 0,89 \times 0,84 = 0,403$
$P(R,I,Vi,G)$	$0,65 \times 0,83 \times 0,89 \times 0,16 = 0,076$
$P(A,I,Ve,Seq)$	$0,35 \times 0,83 \times 0,11 \times 0,84 = 0,026$
$P(A,I,Ve,G)$	$0,35 \times 0,83 \times 0,11 \times 0,16 = 0,005$
$P(R,I,Ve,Seq)$	$0,65 \times 0,83 \times 0,11 \times 0,84 = 0,049$
$P(R,I,Ve,G)$	$0,65 \times 0,83 \times 0,11 \times 0,16 = 0,009$
Soma das probabilidades	1,000

processo de modelagem de EA. A incerteza aparece devido à diversidade de fatores que exercem influência sobre o processo de aprendizagem e desempenho do estudante, como afirmam Haider et al. (2010); Graf et al. (2008); Kinshuk et al. (2009); Alfonseca et al. (2006); Graf et al. (2009b); Messick (1976).

4.3 Componente de Modelagem do Estudante

O Componente de Modelagem do Estudante (CME) é responsável pela atualização dos EA_p no ME, utilizando uma abordagem baseada em AR, implementando eficientemente a modelagem automática e dinâmica de EA. A seguir, são apresentados os componentes relacionados à utilização de AR em nossa abordagem, considerando o domínio de SAIE:

- Conjunto de estados (S): Um estado é definido como a descrição dos EA_p armazenados como distribuições de probabilidades pelo ME, cujos valores são definidos no intervalo $[0,1]$;

- Conjunto de ações (A): As ações que o sistema pode executar com intuito de ensinar o conteúdo maximizando a qualidade da performance do estudante no processo de aprendizagem, ou seja, estratégias pedagógicas a serem consideradas para mostrar os objetos de aprendizagem relacionados à uma seção de aprendizagem, de acordo com as categorias pedagógicas de estudantes, ou seja, as CEAs apresentadas;
- Percepção do ambiente ($I : S \rightarrow S$): Indica como o sistema percebe o estado do estudante. Por exemplo, um SAIE pode perceber o estado cognitivo do estudante através da avaliação de seu conhecimento por meio de testes ou exames;
- Reforço ($R : S \times A \rightarrow \mathfrak{R}$): Essa função define os sinais de reforço (recompensa) fornecidos pelo ambiente. Esta função de reforço fornece um valor máximo quando o estudante aprende a totalidade dos conteúdos em uma seção de aprendizagem, implicando em uma performance de alta qualidade. Esta função é apresentada à frente;
- Função valor-ação, ou ganho ($Q : S \times A \rightarrow \mathfrak{R}$): Esta função estima a utilidade de se adotar determinada estratégia pedagógica (definida por uma CEA) considerando determinado estado (dado pelo ME), fornecendo um método de avaliação para as ações sistema. A função ganho é dada por P , em (4.2), e associa uma ação a um número real, denominado ganho, e estima quão boa determinada CEA é. Tal associação é apresentada pela Tabela 4.4.

Portanto, na abordagem proposta neste trabalho, o valor de utilidade $Q(s, a)$ de um par (estado, ação) é dada por um valor que indique o quão preferida é uma CEA, ou o quão bem adaptada uma CEA é às necessidades do estudante, de acordo com as probabilidades de preferências descritas pelo ME. Desta forma, para cada estado diferente do sistema, tem-se uma tabela de valores $Q(s, a)$ diferente.

O sinal de reforço é dado em função da qualidade da performance (PFM) obtida pelo estudante na seção de aprendizagem, levando o agente a atualizar o ME, e consequentemente a estimar autonomamente o valor $Q(s, a)$ para cada possível ação a em cada

estado s em que o sistema se encontra. Desta forma, o principal objetivo do algoritmo *Q-learning* neste trabalho é estimar, autonomamente, em cada estado s em que o sistema se encontra, o valor $Q(s, a)$ para cada possível ação a , e a partir daí permitir a obtenção da melhor ação, ou seja, a ação com maior valor de utilidade.

Conforme dito anteriormente, em uma política de exploração pura (*greedy*) escolhem-se as ações que se julguem (talvez erroneamente, caso o algoritmo de AR ainda esteja longe da convergência) serem as melhores para resolver o problema (Guelpe et al., 2003). No contexto deste trabalho, isto ocorre quando o ME é inconsistente, ou seja, não retrata verdadeiramente as preferências do estudante. Neste caso, selecionar as ações (CEAs) que pareçam ser as melhores para o estudante gera efeito contrário ao esperado, interferindo negativamente no processo de aprendizagem. Desta forma, foi estabelecida uma política mista de exploração e exploração (política ϵ -*greedy*), que considera a escolha intencional (com probabilidade ϵ) de uma CEA que pode não ser considerada a melhor no estado atual do ME, visando maior eficiência na constante aquisição de conhecimento.

Na abordagem proposta neste trabalho, a técnica de AR tem como função modificar o ME baseado em quão boa ou ruim percebe-se uma determinada ação, que no contexto deste trabalho define a forma de apresentar o material instrucional ao estudante (estratégia pedagógica), forma esta descrita pela CEA que representa a ação. Um desafio, então, é escolher a melhor ação, ou seja, a melhor estratégia pedagógica, levando-se em consideração as incertezas relacionadas à modelagem de EA apresentadas anteriormente neste trabalho.

Os valores de EA armazenados no ME são atualizados sempre que o sistema detecta problemas ou dificuldades de aprendizagem, ou seja, quando o desempenho do estudante for considerado insatisfatório na avaliação em uma seção de aprendizagem. Isto ocorre quando o desempenho do estudante não atinge um valor mínimo de performance m correspondente a um percentual da avaliação, que pode ser particular a um LMS, a um curso, ou mesmo a uma seção de aprendizagem dentro de um curso, de acordo com uma estratégia pedagógica específica. Uma abordagem para detecção de dificuldades de aprendizagem é

apresentada em (Dorça et al., 2009).

Para decidir como os EA do estudante devem ser atualizados no ME, leva-se em consideração a CEA aplicada durante uma seção de aprendizagem. Ao longo do processo de diagnóstico automático e dinâmico de EA, o ME é atualizado da seguinte maneira: ao se detectar dificuldades de aprendizagem ou desempenho insatisfatório em uma seção de aprendizagem, os EA presentes na CEA são decrementados no ME, considerando-se uma possível inconsistência no ME. Em contrapartida, aqueles EA ausentes na CEA são incrementados no ME, reforçando-se sua preferência pelo estudante e, portanto, suas chances de estar presente em uma CEA em uma próxima seção de aprendizagem, considerando-se que, possivelmente, o não atendimento a estas preferências geraram dificuldades de aprendizagem. Esta política permite ao sistema aprender automaticamente qual a forma como o estudante aprende melhor, para que, então, passe a atender a esta forma com maior frequência.

O sinal de reforço é a base da atualização dos EA no ME, e pode ser aplicado ao longo ou apenas ao final de uma seção de aprendizagem, dependendo das políticas de avaliação consideradas, sempre que o estudante obtém um desempenho considerado, de alguma forma, insatisfatório ou um problema de aprendizagem é detectado. Então, o objetivo deste processo é encontrar os EA_p que maximizem o desempenho do estudante.

O reforço é sempre aplicado a todos os EA_p no ME, já que o sistema não sabe onde estão as inconsistências no ME que levaram ao problema de aprendizagem. Considerando-se que cada dimensão do FSLSM possui dois EA, representados por A e B nas regras $R1$ e $R2$, tem-se:

$$\begin{aligned}
 R1 : (CEA[d_i] = A) \rightarrow \\
 & ME[d_i]_A := ME[d_i]_A - \alpha \times R, \\
 & ME[d_i]_B := ME[d_i]_B + \alpha \times R. \\
 R2 : (CEA[d_i] = B) \rightarrow \\
 & ME[d_i]_A := ME[d_i]_A + \alpha \times R, \\
 & ME[d_i]_B := ME[d_i]_B - \alpha \times R.
 \end{aligned}$$

em que:

- $ME[d_i]_A$ representa o valor armazenado no ME na dimensão i para o EA A , para $i = 1 \dots 4$.
- $ME[d_i]_B$ representa o valor armazenado no ME na dimensão i para o EA B , para $i = 1 \dots 4$.
- $CEA[d_i]$ representa o EA que constitui a CEA considerando a dimensão i , com $i = 1 \dots 4$.
- R é o reforço recebido pela realização da ação pedagógica no estado corrente.
- α é a taxa de aprendizagem do agente.

No contexto da abordagem proposta, considerou-se $\gamma = 0$, resultando na estratégia de aprendizagem definida por 4.3. Desta forma, (4.3) não leva em consideração o melhor valor de $Q(s', a')$ a ser obtido no próximo estado s' , já que s' depende de futura avaliação da performance do estudante, que por sua vez não é determinística, já que muitos outros fatores além de EA podem influenciar em sua obtenção, conforme discutido anteriormente, além de depender da interação com o estudante.

$$Q(s, a) := Q(s, a) + \alpha R(s, a) \quad (4.3)$$

Então, a recompensa a ser aplicada não pode considerar este valor, até porque ele ainda não existe na prática, e só existirá depois que o estudante passar pela próxima avaliação de aprendizagem, no próximo estado a ser alcançado, que é probabilístico, levando em consideração uma política ϵ -greedy.

Além disto, sem ter certeza do estado real do estudante em relação aos EA, não há também certeza de como estas escolhas influenciarão em seu desempenho, configurando um ambiente com incerteza, tanto quanto ao resultado das ações executadas como quanto ao estado atual do ambiente, já que o ME pode estar inconsistente em relação às verda-

deiras preferências do estudante. Ou seja, o sistema não tem controle sobre a performance do estudante, este é um evento estocástico.

Nota-se que $R1$ e $R2$ podem diminuir ou aumentam a distância entre os EA_p (DEA), dependendo da composição da CEA, conforme ilustrado pela Figura 4.2. A cada problema de aprendizagem ou performance insatisfatória detectada, todos os EA_p são atualizados, mesmo aqueles já consistentes no ME, já que não se sabe quais estão consistentes e quais estão inconsistentes.

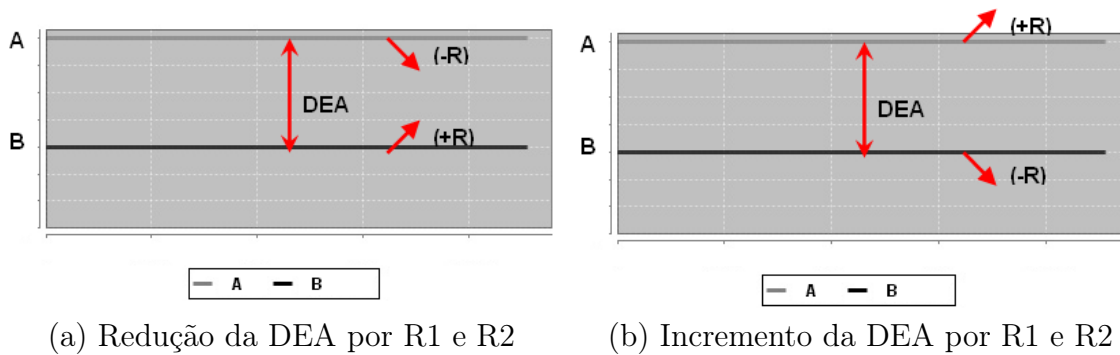


Figura 4.2: Atualização do ME durante o processo de aprendizagem

Enquanto essas atualizações são aplicadas nos EA_p , o ME torna-se mais consistente e, conseqüentemente, a CEA mais adequada ao estudante passa a ter maior probabilidade de ser selecionada. Portanto, o processo de adaptatividade torna-se mais preciso e, conseqüentemente, o desempenho do estudante melhora e os problemas de aprendizagem diminuem, conforme apresentado no capítulo 5. Neste ponto, ocorre, então, uma retroalimentação do processo markoviano que implementa o módulo pedagógico, em que a coleção de variáveis probabilísticas $D1, D2, D3, D4$, definidas pelas 4 dimensões do FSLSM, e que descrevem o processo em um período de tempo t , têm suas probabilidades alteradas, afetando o comportamento do processo no tempo $t + 1$.

É importante ainda ressaltar que a eficiência do processo de diagnóstico de EA é influenciada pela qualidade do reforço utilizado. O reforço R , dado por (4.4), é calculado considerando-se a distância entre os EA_p dentro de uma dimensão específica no ME, e a performance do estudante (PFM) obtida na seção de aprendizagem.

A DEA é calculada por (4.5). O reforço R é calculado para cada uma das quatro dimensões de EAs e aplicado sempre que $PFM < m$, considerando-se a DEA específica em cada uma, em que m é a performance mínima esperada, de forma que $PFM < m$ indica um problema de aprendizagem. O valor de PFM é considerado no intervalo real $[0,100]$ e o valor da DEA é considerado no intervalo real $[0,1]$.

$$R = \frac{1}{PFM \times DEA} \quad (4.4)$$

$$DEA = |ME[d_i]_A - ME[d_i]_B| \quad (4.5)$$

Em (4.4), deseja-se que quanto menor PFM, mais acentuado seja o reforço. Isto porque, provavelmente, quanto menor o desempenho, maior é a dificuldade de aprendizagem, que pode provavelmente estar sendo causada por forte inconsistência nos EA_p , que deve ser eliminada o quanto antes, necessitando-se de um reforço maior. Em contra-partida, deseja-se que quanto maior a DEA, menor o reforço, para que se possa evitar reforços abruptos em EA_p já consideravelmente fortes (DEA alta).

Observou-se que o ajuste do valor da taxa de aprendizagem α é de extrema importância. Se α possuir um valor muito alto, alterações abruptas no ME são produzidas. Isto não é desejável, devido aos aspectos de incerteza e não-determinismo envolvidos na modelagem automática de EAs. Além disto, não apenas EA, mas outros fatores influenciam no desempenho do estudante, o que torna difícil inferir EA de forma abrupta. Em contrapartida, se α possuir um valor muito pequeno, alterações muito reduzidas são produzidas no ME, o que resulta em uma aprendizagem lenta e consequentemente demandando muito tempo no diagnóstico dos EAs do estudante, resultando em um processo de fornecimento de adaptatividade ineficiente. Desta forma, ajustar apropriadamente o valor de α é de extrema importância para que se obtenha um processo de aprendizagem eficiente. Considerando estes aspectos, considerou-se $\alpha = 0,5$ nos experimentos realizados neste trabalho.

Quando os valores de PFM ou DEA se tornam muito pequenos, R tende a se tornar muito grande. Na prática, isto produziria uma mudança muito rápida nos valores de EAs no ME, sempre que a DEA se aproximar de 0. Isto é necessário porque quando a relação é de aproximadamente 50% a 50% nos EA_p do ME, a preferência do estudante ainda é desconhecida, e quanto mais rápido se descobrir tal preferência, mais rápido o sistema pode fornecer conteúdos adaptados às necessidades reais do aluno.

Isto pode ser observado nos gráficos resultantes dos experimentos expostos na próxima seção, e é uma característica desejável na nossa abordagem. O mesmo comportamento é percebido quando PFM se aproxima muito de zero. Quando isso acontece, o estudante pode estar enfrentando dificuldade elevada na aprendizagem, que pode ser proveniente da falta de personalização adequada do curso, que pode ser resultado de inconsistências nos EAs armazenados no ME. Neste caso, as mudanças rápidas no ME são desejáveis, de modo a corrigir o ME o quanto antes, e permitir ao sistema o provimento de conteúdo bem adaptado.

Mas, como dito antes, não só EA mas também muitos outros fatores exercem influência sobre performances dos estudantes, tornando-se muito arriscado inferir os EAs dos estudantes abruptamente. Desta forma, após a análise de resultados de diversos experimentos, decidiu-se por configurar o limite R_{max} de R em 0,05 (5%) como resultado de observações empíricas, em que diversos limites para R , maiores e menores do que 0,05 foram testados, recaindo em um problema de otimização, a ser considerado em um trabalho futuro.

A equação (4.4) para cálculo de R foi inferida após diversos experimentos que resultaram em vários ajustes neste cálculo. Isto se mostrou um ponto fundamental para a obtenção de uma abordagem eficiente. Provavelmente, melhorias neste cálculo ainda serão necessárias. Novas variáveis ainda não descobertas podem influenciar positivamente no cálculo de R . Assim, espera-se que o ME possa convergir gradativamente para as preferências do estudante da forma mais precisa possível, refletindo com exatidão a categoria pedagógica à qual pertence.

É importante mencionar que, mesmo que os valores dos EA_p em determinada dimensão estejam consistentes e precisos, eles sofrerão ajustes. Isto ocorre porque o sistema não sabe quando as preferências em determinada dimensão estão corretas, porque não se conhece as preferências reais do estudante, e conforme já mencionado, estas podem variar de alguma forma em função do tempo. Este é um dos principais motivos de ser necessário a aplicação de um valor relativamente suave de atualização dos EA_p no ME, já que preferências corretas não deveriam sofrer alterações bruscas, o que poderia prejudicar o fornecimento preciso de adaptatividade.

Em contrapartida, é necessário que este valor possibilite a correção das preferências inconsistentes o mais rápido possível, para que o processo de diagnóstico automático de EA seja eficaz. Os resultados obtidos através dos experimentos apresentados no capítulo 5 mostram que este objetivo foi alcançado. Pôde-se observar que o valor de preferências corretas é mantido ao longo do processo de aprendizagem, e que apenas preferências inconsistentes são efetivamente modificadas pelo processo estocástico de diagnóstico de EAs. Notou-se que a partir do momento em que uma preferência se torna consistente, seu valor se mantém relativamente estável, atingindo um estado de equilíbrio, e quando todos os EA_p no ME atingem este estado, o fornecimento de adaptatividade passa a ser mais preciso.

O algoritmo 4.1 implementa o processo de AR baseado no *Q-learning*, e leva em consideração a definição dos componentes de AR no domínio de SAIE, conforme apresentado anteriormente. O algoritmo 4.1 é executado a cada seção de aprendizagem, até que sejam atingidos todos os objetivos de aprendizagem presentes no ME.

O ME é inicializado com informações pré-existentes de EA, EC e OA a serem alcançados, configurando o estado inicial s . A execução do algoritmo termina quando todos os objetivos de aprendizagem estiverem satisfeitos. Cada iteração do algoritmo representa uma seção de aprendizagem.

As entradas da tabela de valores de ganho Q para cada par (s, a) , é dada pela distribuição de probabilidades da Tabela 4.4, e são atualizados automaticamente quando

Algoritmo 4.1 *Q-learning* aplicado à modelagem automática e dinâmica de EA

```

Inicialize o ME;
while  $s$  não seja o estado final do
  Selecione um conceito  $C$  a ser apresentado ao estudante;
  Selecione, através do MP, uma CEA  $a$ ;
  Execute  $a$ , apresentando adequadamente os objetos de aprendizagem que ensinam o
  conceito  $C$  ao estudante;
  Avalie a performance do estudante no conceito  $C$ ;
  Atualize o estado cognitivo do estudante no ME em relação a  $C$ ;
  Receba a recompensa  $r$ , dada por  $PFM$ ;
  Calcule o reforço  $R$  de acordo com 4.4;
  Atualize os  $EA_p$  através de R1 e R2;
  Faça de  $s$  o próximo estado, dado por  $s'$ ;
end while
  
```

os EA do estudante no ME são atualizados. Nesta tabela, cada valor $Q(s, a)$ estima a utilidade de se executar uma estratégia pedagógica a considerando o estado atual s do estudante, dado pelo ME.

A cada iteração, os valores de Q (dados pela função P) convergem para os seus valores ótimos automaticamente, possibilitando ao sistema selecionar a melhor estratégia pedagógica com a maior frequência possível para cada estudante.

4.4 Arquitetura resultante da integração de um SAIE com a abordagem proposta

A integração de um SAIE com a abordagem proposta neste trabalho, considerando-se seus 3 componentes principais (apresentados anteriormente neste capítulo), é apresentada na Figura 4.3.

Conforme observa-se na arquitetura apresentada na Figura 4.3, um SAIE deve utilizar os serviços fornecidos pela interface do CME, ICME, e pela interface do Módulo Pedagógico, IModuloPedagogico. Como as interfaces estão bem definidas, o SAIE que utiliza estes componentes não dependem de sua implementação (do componente em si), mas apenas da interface. Consequentemente, tem-se um baixo nível de acoplamento entre

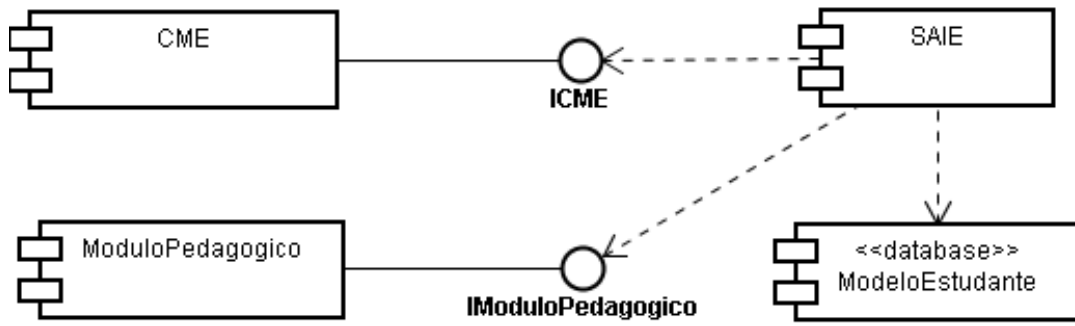


Figura 4.3: Arquitetura resultante da integração de um SAIE com a abordagem proposta.

o SAIE e os componentes CME e ModuloPedagogico.

A assinatura do serviço *atualizaEA_p*, fornecido pela interface ICME, é apresentada a seguir:

```

ICME::atualizaEAp(in EAp: double[],
                  in PFM: double,
                  in m: double,
                  in α: double,
                  in Rmax: double,
                  in CEA: byte[]):double[]

```

O serviço *atualizaEA_p*, fornecido pela interface ICME, recebe como parâmetros de entrada os *EA_p* armazenados no ME no momento, o valor da performance obtida pelo estudante (*PFM*), a performance mínima esperada (*m*) na seção de aprendizagem, a taxa de aprendizagem (*α*), o reforço máximo a ser aplicado (*R_{max}*), e a CEA aplicada durante a seção de aprendizagem. Como saída, *atualizaEA_p* retorna os novos valores de *EA_p* a serem armazenados no ME pelo SAIE. É importante observar que os *EA_p* são armazenados como um vetor de números reais.

Como o tamanho do vetor *EA_p* não é pré-determinado pelo serviço, um SAIE pode fornecer qualquer quantidade de dimensões de EA, dependendo de sua necessidade, desde que sejam fornecidas distribuições de probabilidades contendo dois valores cada. Como

este serviço não faz menção à quantidade de dimensões possíveis, novas dimensões de EA podem ser consideradas na modelagem do estudante, inclusive considerando-se outras teorias de EA, já que o método baseado em AR tem como benefício a não utilização de conhecimento específico do domínio de aplicação, o que o torna genérico e independente da teoria de EA subjacente, já que está relacionado a grandezas numéricas, e não simbólicas.

A assinatura do serviço *gerarCEA*, fornecido pela interface *IModuloPedagogico*, é apresentada a seguir:

IModuloPedagogico::gerarCEA(in EA_p: double[]):byte[]

O serviço *gerarCEA* recebe como parâmetro de entrada os *EA_p* armazenados no ME, e infere a CEA a ser aplicada no momento. O vetor que armazena a CEA retornada pelo serviço também não tem tamanho pré-definido. Desta forma, seu tamanho dependerá da quantidade de *EA_p* fornecidos. A CEA é armazenada na forma de um vetor de 0's e 1's, desta forma ficando sua representação também independente de uma teoria de EA específica.

Para a experimentação desta proposta, neste trabalho, as preferências A, S, Vi e Seq, dadas pela Definição 4.2.1, são representadas na CEA por 0, e as preferências R, I, Ve e G, dadas pela Definição 4.2.1, são representadas por 1. Desta forma, considerando-se as CEAs apresentadas na Definição 4.2.2, tem-se a seguinte representação equivalente: $CEAs = \{(0,0,0,0), (0,0,0,1), (1,0,0,0), (1,0,0,1), (0,1,0,0), (0,1,0,1), (1,1,0,0), (1,1,0,1), (0,0,1,0), (0,0,1,1), (1,0,1,0), (1,0,1,1), (0,1,1,0), (0,1,1,1), (1,1,1,0), (1,1,1,1)\}$.

É importante observar que a CEA gerada pelo serviço *gerarCEA* leva em consideração a ordem em que os *EA_p* são fornecidos no parâmetro de entrada. Desta forma, a constituição das CEAs consideradas neste trabalho são baseadas na configuração de *EA_p* fornecidos pela Definição 4.1.5, resultando no conjunto de CEAs dado pela Definição 4.2.2. Mas a ordem em que as distribuições de probabilidades indicando os *EA_p* são fornecidas não importa, ficando a cargo do SAIE esta decisão, já que nem quais e nem quantas as preferências a serem consideradas pelo SAIE estão sendo pré-definidas pela abordagem proposta neste trabalho.

Todas estas características tornam a abordagem proposta independente de um sistema específico e de teorias de EA subjacentes, podendo ser facilmente utilizada por diferentes sistemas, considerando diferentes teorias de EA.

A interação dos componentes da arquitetura apresentada na Figura 4.3 ocorre da seguinte forma:

- 1: o estudante interage com o SAIE.
- 2: o SAIE avalia a performance do estudante.
- 3: o SAIE solicita ao CME que atualize os EA_p do estudante.
- 4: o SAIE armazena os EA_p atualizados no ME.
- 5: o SAIE solicita ao Módulo Pedagógico que gere uma nova CEA a partir dos EA_p atualizados.
- 6: o SAIE fornece adaptatividade de acordo com a CEA gerada, o conceito a ser aprendido e o EC do estudante.

Sabe-se que uma diversidade de aspectos pode envolver a avaliação de aprendizagem e desempenho do estudante, tais como quantidade de acertos, tempo de resposta, tempo despendido em uma página, número de retrocessos no conteúdo, quantidade de acessos a ferramentas de comunicação e trabalho em grupo, quantidade de pedidos de ajuda ao tutor, dentre outros. A construção de um módulo de avaliação que leve em consideração todos estes aspectos e que permita ao sistema fazer inferências, com segurança, sobre a performance do estudante, assim como sobre os problemas de aprendizagem, é uma questão complexa, foco de atenção em pesquisas na área de SAIE, e diversas abordagens têm sido desenvolvidas com este intuito (Lopes et al., 2008b,a; Dorça et al., 2009; Dorça, 2004).

Além disto, há que se considerar o elevado custo e o tempo necessários à criação de uma base de objetos de aprendizagem suficientemente ampla a fim de dar suporte à toda a diversidade pedagógica inerente ao processo de fornecimento de adaptatividade baseada em EA em um curso real. Esta diversidade vem da necessidade de se executar diferentes ações instrucionais, dependendo da necessidade específica de EA de cada estudante na

aprendizagem de um conceito específico.

As ações instrucionais, que devem ser executadas pelo sistema, através da utilização de uma variedade de objetos de aprendizagem, podem assumir uma diversidade grande de atividades pedagógicas específicas, como: definir, exercitar, simular, descrever, distinguir, exemplificar, rotular, listar, memorizar, identificar, ordenar, reconhecer, reproduzir, dentre outras.

Por exemplo, a Figura 4.4 mostra o conceito de Servlet, contido no mapa conceitual da Figura 4.5, e os objetos de aprendizagem associados a ele, ou seja, os objetos de aprendizagem que podem ser utilizados para ensinar este conceito aos diferentes tipos de estudantes através de diferentes ações instrucionais.

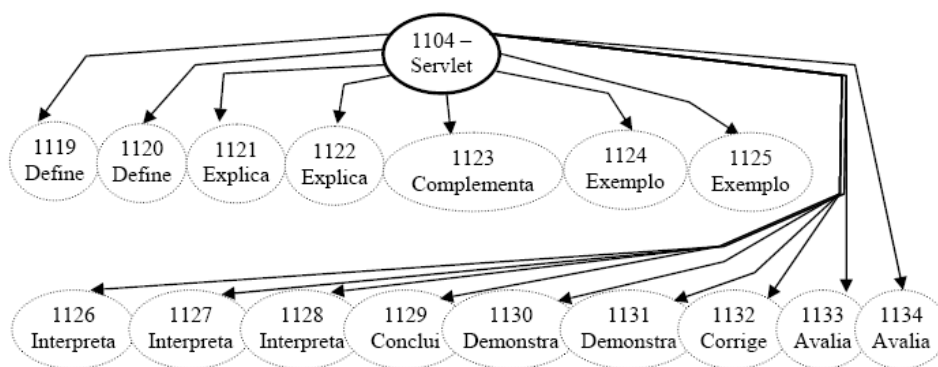


Figura 4.4: O conceito Servlet e respectivos objetos de aprendizagem associados

Cada objeto de aprendizagem associado a um conceito pode implementar uma ação instrucional diferente, considerando diferentes níveis cognitivos e CEAs. A Figura 4.5 mostra parte de um mapa conceitual simplificado que modela o domínio de um curso de Programação Orientada a Objetos. Na Figura 4.5 tem-se a representação dos relacionamentos entre alguns conceitos do curso.

Desta forma, faz-se necessária a associação automática e dinâmica de objetos de aprendizagem aos conceitos a serem ensinados, permitindo que se leve em consideração o nível cognitivo e os EA dos estudantes no fornecimento de adaptatividade, conforme abordam Zaina et al. (2012).

Alguns estudos realizam análises sobre quais tipos de objetos de aprendizagem são

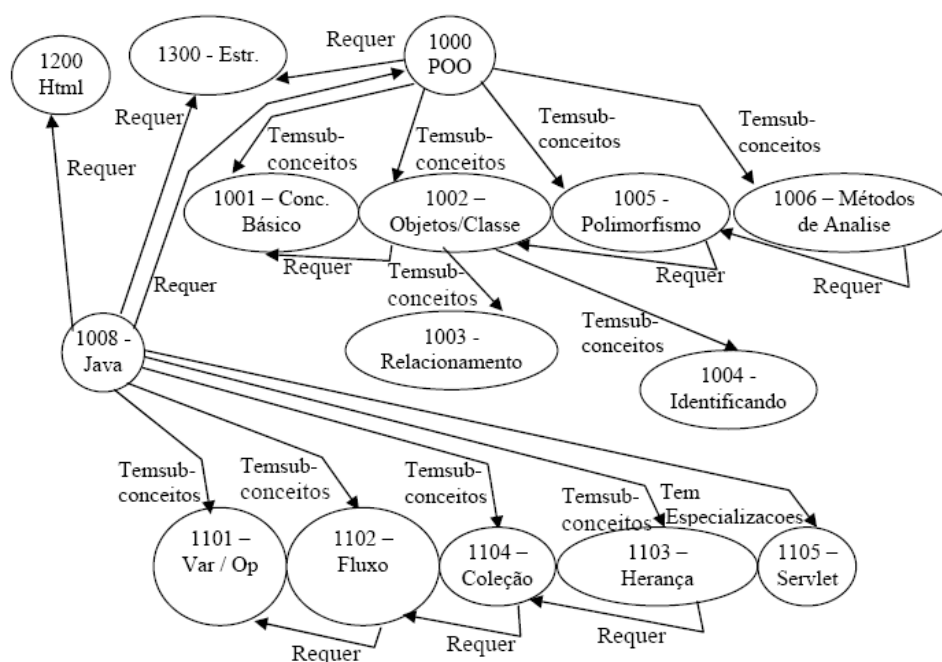


Figura 4.5: Parte do mapa conceitual de um curso de Programação Orientada a Objetos

mais propícios a um determinado EA. Terry et al. (1995) observou que algumas ações instrucionais são mais apropriadas a um EA do que outras. Terry et al. (1995) atribui valores no intervalo $[0,1]$ a cada ação instrucional, indicando o quanto tal ação satisfaz um EA. Lopes e Fernandes (2009) apresentam um exemplo de aplicação desta política de associação entre ações instrucionais e EA. Sangineto et al. (2008) classificam os diferentes tipos de objetos de aprendizagem de acordo com o valor do atributo "Learning Resource Type" do IMS Metadata Standard. Logicamente tal associação não é trivial, e deve contar com especialistas em educação, pedagogia e psicologia cognitiva.

Também, o desenvolvimento de um módulo de interface com o usuário que forneça, eficientemente, a adaptatividade baseada em EA e em técnicas de HA para adaptação de conteúdo e de navegação não é uma tarefa trivial, devido à necessidade de se relacioná-las às particularidades dos EA de forma eficiente. Algumas questões envolvidas no uso de EA em SHA são tratadas por Stash et al. (2004); Bajraktarevic et al. (2003); Paredes e Rodriguez (2006); Brown (2007).

Ainda, há que se considerar questões relacionadas ao sequenciamento do conteúdo, levando-se em consideração as relações pedagógicas existentes entre os conceitos a serem

ensinados, que devem estar devidamente organizados, por exemplo, em uma ontologia (Davies, 2006), conforme sugere Sangineto et al. (2008), permitindo que se gere automaticamente um curso, considerando-se conhecimento pedagógico do domínio, EC e EA do estudante.

Neste processo, a ontologia deve ser uma descrição abstrata do domínio do conhecimento do curso, sem nenhuma referência a objetos de aprendizagem específicos para explicar os conceitos, considerando que estes objetos devem ser sugeridos dinamicamente, de acordo com a CEA inferida pelo MP.

Ignorar estes aspetos logicamente prejudica ou impede a utilização da abordagem proposta neste trabalho, já que o MP ficaria limitado em seu funcionamento, o que seguramente prejudicaria os resultados gerados pelo CME.

Desta forma, com o intuito de se testar a abordagem proposta neste capítulo isolando toda esta complexidade, foi desenvolvido um modelo probabilístico para simular o processo de aprendizagem e performance do estudante. Para isto, um modelo de inferência estocástico simula o desempenho dos alunos levando em consideração alguns aspectos relacionados ao impacto dos EAs no processo de aprendizagem, conforme discute uma diversidade de estudos, apresentados em diversos trabalhos¹.

Também, foi construída uma interface gráfica para testes, permitindo a execução do Algoritmo 4.1 e a análise dos resultados gerados pela abordagem proposta através da integração dos componentes apresentados neste capítulo. A interface é apresentada na Figura 4.6.

A interface permite o ajuste de parâmetros relativos à execução do algoritmo, tais como a taxa de aprendizagem α , a performance mínima esperada m , o limite para o valor de reforço R_{max} , e a quantidade de conceitos a serem aprendidos pelo estudante (objetivos de aprendizagem), conforme discutido no próximo capítulo. Além disto, a interface permite definir os estilos de aprendizagem reais do estudante e a força da preferência por cada

¹Haider et al. (2010); Graf et al. (2008); Kinshuk et al. (2009); Graf e Kinshuk (2009a); Graf e Liu (2008); Coffield et al. (2009); Alfonseca et al. (2006); Graf e Lin (2007); Graf e Kinshuk (2007); Bajraktarevic et al. (2003); Sangineto et al. (2008); Terry et al. (1995); Friedel e Rudd (2006); Vasilyeva et al. (2006)

Modelagem Automática e Dinâmica de Estilos de Aprendizagem - Por Fabiano A. Dorça

Parâmetros:
 Taxa de Aprendizagem:
 PFM (mínimo):
 Rmax:
 Quant. Conceitos:

Estilos de Aprendizagem Reais do Estudante:

Ativo-Reflexivo ...	Sensitivo-Intuiti...	Visual-Verbal	Sequencial-Global
<input type="radio"/> Ativo	<input type="radio"/> Sensitivo	<input type="radio"/> Visual	<input type="radio"/> Sequencial
<input type="radio"/> Reflexi...	<input type="radio"/> Intuitivo	<input type="radio"/> Verbal	<input type="radio"/> Global
<input type="text" value="Forte"/> ▼	<input type="text" value="Forte"/> ▼	<input type="text" value="Forte"/> ▼	<input type="text" value="Forte"/> ▼

Modelo do Estudante:

Ativo: <input type="text" value="0.70"/>	Sensitivo: <input type="text" value="0.70"/>	Visual: <input type="text" value="0.70"/>	Sequencial: <input type="text" value="0.70"/>
Reflexivo: <input type="text" value="0.30"/>	Intuitivo: <input type="text" value="0.30"/>	Verbal: <input type="text" value="0.30"/>	Global: <input type="text" value="0.30"/>

Figura 4.6: Interface gráfica para testes

um. Estas definições são utilizadas para simulação da performance obtida pelo estudante ao longo do processo de aprendizagem, conforme apresentado no próximo capítulo.

Como resultado da execução do Algoritmo 4.1, tem-se gráficos que apresentam a variação dos valores dos EA_p durante o processo de aprendizagem, os valores de performances obtidas pelo estudante e a ocorrência de problemas de aprendizagem. Estes resultados são apresentados e analisados no próximo capítulo.

Desta forma, conseguiu-se analisar o comportamento da abordagem proposta, demonstrando-se que os EA_p convergem eficientemente em direção dos EA reais ao interagir com estudantes simulados com diferentes características. O próximo capítulo apresenta a verificação e validação da abordagem proposta a partir de uma diversidade de experimentos.

Capítulo 5

Verificação e Validação da Abordagem Proposta

A verificação e validação da abordagem proposta se deu através da metodologia descrita na seção 5.1. Para experimentação da abordagem proposta sem a necessidade de se ter um processo de aprendizagem real, com estudantes reais e toda a complexidade inerente a este processo, desenvolveu-se um modelo estocástico para simulação da aprendizagem em estudantes que permitisse simular a avaliação de performance do estudante de forma probabilística.

Tal modelo leva em consideração que, não apenas EA mas uma diversidade de fatores podem exercer influência no desempenho dos estudantes, conforme discutido no capítulo 2, e também considera aspectos relacionados ao impacto de EA no processo de aprendizagem, como descrito por Haider et al. (2010); Graf et al. (2008); Kinshuk et al. (2009); Alfonseca et al. (2006); Graf et al. (2009b). Este modelo é apresentado na seção 5.2. Os resultados dos experimentos são apresentados e analisados na seção 5.3.

5.1 Metodologia Utilizada

A verificação do modelo proposto consistiu em repetir 20 vezes cada um de uma série de experimentos, considerando-se uma situação diferente em cada um deles. A repetição

de um experimento por um certo número de vezes foi importante para que se pudesse observar o comportamento do processo em diversas ocasiões diferentes, mas sob condições idênticas.

Com isto, foi possível notar que as sequências resultantes em um mesmo teste foram diferentes. Desta forma, observou-se o não-determinismo inerente ao processo de aprendizagem, sendo este um fenômeno que varia em algum grau, de forma imprevisível, caracterizado por uma sequência ou série de valores, e não apenas um único valor final. Mas, a similaridade dos valores finais obtidos (ME consistente) em cada repetição do processo atesta a convergência do processo, e permite comprovar a eficiência e eficácia do modelo, e consequentemente validar a abordagem proposta. Ou seja, este processo possibilitou observar como diferentes estudantes podem reagir de forma diferente ao mesmo tratamento e como o processo converge em direção à solução desejada: o ME coerente com a realidade.

Ao se comparar os resultados alcançados em cada repetição de um experimento buscou-se analisar as diferenças entre as preferências EA_p obtidas ao final ao processo. Observou-se que os resultados finais gerados são equivalentes, possibilitando notar a convergência do processo estocástico, dada por $EA_p \rightarrow EA_r$, em que EA_r representa os estilos de aprendizagem reais, ou verdadeiros, do estudante. A análise desta convergência é indispensável para a validação do modelo proposto.

Para a realização dos experimentos apresentados neste capítulo, considerou-se o valor da performance mínima esperada $m = 60,0\%$ (padrão adotado na maioria dos processos de ensino) e a taxa de aprendizagem $\alpha = 0,5$, pelos motivos apresentados no capítulo 4. São apresentados 16 experimentos considerando-se as 16 categorias pedagógicas de EA apresentadas no capítulo 4. Desta forma, procurou-se cobrir todas as possíveis situações em um ambiente real.

Em todos os experimentos foi considerado um conjunto de 60 conceitos a serem aprendidos pelo estudante. Considerou-se o estado cognitivo inicial do estudante igual a -1 em todos os conceitos. Considerou-se como objetivos de aprendizagem o nível máximo

(5) de conhecimento em todos os conceitos. A execução de um experimento é finalizada quando o estudante atinge todos os objetivos de aprendizagem especificados no ME para todos os conceitos.

Portanto, o processo de aprendizagem simulado nesses experimentos deve ter, pelo menos, 360 sessões de aprendizagem (ou iterações) a fim de alcançar todas as metas de aprendizagem ($60 \text{ conceitos} \times 6 \text{ níveis cognitivos em cada conceito} = 360$). Cada uma das 16 categorias pedagógicas de estudantes apresentadas anteriormente foram consideradas na experimentação da abordagem proposta. Resultados e análises destes experimentos são apresentados na seção 5.3.

A fim de validar a abordagem proposta, foram observadas duas variáveis nos experimentos:

- consistência: os EA_p efetivamente convergem para os EA_r durante o processo de aprendizagem?
- eficiência: os EA_p convergem para os EA_r em tempo razoável, isto é, EA_p torna-se consistente no início do processo de aprendizagem?

Neste momento, é mister observar que sem a utilização de simulação seria difícil a validação da abordagem proposta. Isto porque ao se testar a abordagem proposta em processos de aprendizagem reais, com estudantes reais, seria impossível conhecer com exatidão seus EA_r , em decorrência dos motivos apontados anteriormente sobre a utilização de auto-concepções do estudante e sobre a utilização de processos e técnicas determinísticas na inferência de seus EA.

Desta forma, seria impossível medir o nível de consistência do ME obtido durante o processo de aprendizagem, impossibilitando-nos medir duas variáveis muito importantes na validação da abordagem proposta: a eficiência em relação ao tempo despendido na detecção de EA, assim como na correção de inconsistências existentes no ME; a consistência dos MEs obtidos em relação às preferências reais do estudante.

Este é o motivo principal pelo qual este trabalho foca na análise da viabilidade da

abordagem proposta sob uma ótica simulada antes de nos propor a utilizá-la em situações reais, que é um trabalho futuro. Estas variáveis são analisadas e discutidas através de experimentos que comprovam a eficiência e eficácia da abordagem proposta e sua importância no apoio à construção de SAIE.

Os resultados obtidos através de experimentos mostram que, considerando essas variáveis, a abordagem proposta neste trabalho é válida e cumpre eficientemente os objetivos inicialmente propostos. Pôde-se observar diferentes níveis de consistência e eficácia quando se comparam os experimentos, mas em todos eles os níveis atingidos são plenamente satisfatórios, conforme apresenta-se na seção 5.3.

Para a realização destes experimentos, a abordagem proposta foi implementada em Java. A geração de números aleatórios, necessários ao processo estocástico executado pelo MP e à simulação de aprendizagem em estudantes, foi realizada através do método *random()* da classe *Math*, que toma como semente um inteiro longo gerado por *System.currentTimeMillis()*, que devolve o número de milissegundos desde 1970. Desta forma, a cada momento que passa, uma semente diferente é utilizada, garantindo o aspecto verdadeiramente randômico necessário à execução destes experimentos (Biermann e Ramm, 2001).

5.2 Simulação de Aprendizagem em Estudantes

É de amplo conhecimento que uma variedade de fatores devem ser levados em conta na avaliação de aprendizagem, desempenho de estudantes e detecção de problemas de aprendizagem, e diversas abordagens tem sido propostas com este fim (Virvou et al., 2003; Chiu et al., 2007; Lopes et al., 2008b; Dorça et al., 2009; Lopes et al., 2008a; Zhang et al., 2010).

Em todo caso, existem desafios no processo de avaliação do estudante. Um deles é determinar se um erro ocorreu por um deslize ou por falta de conhecimento. Em contrapartida, ao demonstrar o conhecimento correto, existe a possibilidade de que ele

tenha apenas feito uma suposição, havendo certo grau de incerteza com relação à medição do conhecimento do estudante (Giotopoulos et al., 2005). Desta forma, a avaliação do estudante em sistemas para EAD é um problema complexo, e uma série de abordagens têm sido propostas para resolvê-lo.

Neste contexto, é proposto neste trabalho um modelo probabilístico que leva em consideração alguns estudos disponíveis na literatura sobre o impacto dos EA no desempenho do estudante, conforme discutido em uma diversidade de trabalhos¹. Então, a inferência do desempenho do estudante considera que EA influenciam no desempenho do estudante, pois ao se conhecer corretamente os EA específicos de um estudante, um SAIE pode prover uma experiência bem adaptada, compondo cursos que melhor atendam à forma como o estudante percebe e processa a informação e tornando mais fácil o processo de aprendizagem dos estudantes e melhorando sua performance.

Desta forma, se o ambiente de aprendizagem, suas características, seu conteúdo, forma de navegação e seus recursos se adaptam aos EA do estudante, sua probabilidade de ter um bom desempenho aumenta. Esta facilitação do processo de aprendizagem e melhoria de performance é reproduzida pelo Processo Estocástico de Simulação de Desempenho do Estudante (PESDE) , cujos principais aspectos são apresentados a seguir. Considerações importantes sobre simulação e modelagem estocástica são feitas por Geiss (2009).

O principal aspecto deste processo é que, quando um EA_r do estudante é contemplado na CEA inferida pelo MP, o aprendizado se torna mais fácil, e conseqüentemente a probabilidade de sucesso é maior, conforme apresentado a seguir, de acordo com 5.1, e conforme comprovado pela análise gráfica apresentada nos experimentos. Como apontado por Haider et al. (2010); Graf et al. (2008); Kinshuk et al. (2009), preferências fortes produzem efeitos negativos mais notórios sobre o desempenho dos estudantes quando elas não são satisfeitas pelo processo de ensino, e este fato é considerado pelo PESDE. Os re-

¹Haider et al. (2010); Graf et al. (2008); Kinshuk et al. (2009); Graf e Kinshuk (2009a); Graf e Liu (2008); Coffield et al. (2009); Alfonseca et al. (2006); Graf e Lin (2007); Graf e Kinshuk (2007); Bajraktarevic et al. (2003); Sangineto et al. (2008); Terry et al. (1995); Friedel e Rudd (2006); Vasilyeva et al. (2006)

sultados mostram que os alunos com fortes tendências por um EA têm mais dificuldades na aprendizagem do que os alunos com preferências moderadas, ou leves/balanceadas, quando elas não são atendidas. Esta descoberta mostra que os alunos com preferências fortes se beneficiam de forma mais acentuada da adaptatividade fornecida pelos SAIE em relação aos seus EA. Tais estudantes obtiveram pontuação significativamente menor no exame final do que os estudantes que não apresentaram preferências tão acentuadas em alguma dimensão. Este resultado confirma a argumentação de Felder (Felder e Silverman, 1988) sobre a importância da adaptatividade em relação a EA, especialmente para estudantes que apresentam forte preferência por determinados EA.

Estas considerações são levadas em conta pelo PESDE, um modelo probabilístico concebido para implementar o aspecto não-determinístico envolvido no processo de aprendizagem e no desempenho dos estudantes, permitindo a simulação da influência de EA no processo de aprendizagem, mas levando em consideração a grande quantidade de fatores que podem exercer alguma influência sobre este processo, além de EA. Para que possa cumprir sua tarefa, o PESDE precisa conhecer os EA_r do estudante e a força de cada preferência (forte; moderada; fraca ou balanceada). Estes pesos influenciam no resultado do desempenho do estudante, de modo que contrariar uma preferência forte tende a causar um impacto negativo maior do que contrariar uma preferência moderada, conforme alertam Kinshuk et al. (2009). Por sua vez, contrariar uma preferência moderada tende a causar um impacto maior do que contrariar uma preferência leve ou balanceada, já que neste tipo de preferência o estudante tende a apresentar destreza em ambos os estilos.

Basicamente, o PESDE considera um aumento de dificuldade quando um EA_r do estudante não aparece na CEA considerada para fornecimento de adaptatividade durante uma sessão de aprendizagem. Portanto, o PESDE conhece os EA_r dos estudantes, mas não conhece os seus EA_p , armazenados no ME. Logicamente, o ME não é levado em consideração para cálculo da probabilidade de falha do estudante, porque, na realidade, apenas os EA_r do estudante exercem influência sobre o seu desempenho.

O aumento da probabilidade de falha reflete naturalmente um aumento do nível de

dificuldade. Portanto, considerando-se o processo de aprendizagem como um processo não-determinístico, que é influenciado por muitos fatores além da adaptatividade por EA, o PESDE considera que a ocorrência de conteúdo inadequadamente adaptado pode contribuir para o fracasso dos estudantes, mas, não pode determiná-lo.

Neste contexto, o PESDE calcula a quantidade de preferências não satisfeitas (Q_{PNS}) do estudante pela CEA selecionada. Desta forma, Q_{PNS} representa a quantidade de EA presentes na CEA selecionada e que não contemplam os EA_r do estudante. Caso uma das preferências não satisfeitas seja uma preferência forte, então o PESDE incrementa Q_{PNS} em 1. Caso não existam preferências fortes não satisfeitas, mas exista pelo menos uma preferência moderada não satisfeita, então o PESDE incrementa Q_{PNS} em 0,5. Então, o cálculo da performance PFM do estudante é dado por (5.1), em que β é um número aleatório tal que $0 \leq \beta \leq 1$.

$$PFM = 100 - (Q_{PNS} \times K \times \beta); \quad (5.1)$$

Desta forma, como $0 \leq Q_{PNS} \leq 5$, considerando $K = 20$, tem-se, então, $0 \leq PFM \leq 100$. É importante observar que β representa um fator aleatório importante nesta simulação, já que não apenas EA mas diversos outros fatores exercem influência na performance do estudante, o que torna seu desempenho não-determinístico, ou seja, a partir do ME não é possível inferir com certeza o desempenho que será obtido em determinada situação.

Também por isto, caso $Q_{PNS} = 0$, o PESDE considera $Q_{PNS} = 1$, já que o fato de Q_{PNS} ser 0 não pode determinar $PFM = 100$, já que o caráter não determinístico relativo à performance do estudante precisa ser mantido, e também outros fatores podem exercer alguma influência no desempenho dos estudantes, tais como personalidade (Al-Dujaily e Ryu, 2006), motivação (Lim et al., 2007), interação homem-máquina (Zhang et al., 2010), adequação do curso ao ambiente, fatores humanos, suporte institucional, qualidade do serviço, suficiência de conteúdo, habilidades computacionais do estudante, dentre outros, conforme analisado por Santos e Boticario (2008); Mosakhani e Jamporazmey (2010).

Observa-se em 5.1 que quanto maior Q_{PNS} , maior o possível desconto da performance do estudante. Desta forma, é importante observar que os EA_r efetivamente afetam o desempenho do estudante no processo de simulação da aprendizagem. Tem-se consciência de que os valores das probabilidades de inferências utilizados pelo PESDE podem ser específicos para cada estudante. Mas, considerando-se as observações de autores tais como Haider et al. (2010); Graf et al. (2008); Kinshuk et al. (2009); Alfonseca et al. (2006); Graf et al. (2009b), acredita-se que esses valores são razoáveis para uma experimentação confiável da abordagem proposta neste trabalho.

Desta forma, o modelo é capaz de inferir o desempenho e evolução de nível cognitivo do estudante de forma probabilística. Isto permitiu a execução do algoritmo apresentado no capítulo 4, cujo comportamento deseja-se verificar, principalmente no que tange ao funcionamento e eficiência da abordagem proposta no diagnóstico automático de EA, considerando-se um ME probabilístico, conforme apresentado.

Este modelo não leva em consideração a diferenciação entre categorias de estudantes, sendo considerado para todas as possíveis 16 combinações de estilos de aprendizagem, ou seja, para as 16 possíveis categorias de estudantes. Esta abordagem é justificada, já que estudos mostram que a performance de estudantes de diferentes categorias, em diferentes domínios, não são afetadas pelas diferenças entre estilos de aprendizagem, ou seja, a variação de performance dos estudantes baseadas em estilos de aprendizagem não foi significativa (Haider et al., 2010).

É importante enfatizar neste ponto que o MP e o CME, apresentados no capítulo 4, tal como ocorre em uma situação real, logicamente não conhecem os EA_r do estudante, apenas tendo acesso aos EA_p armazenados no ME. Neste contexto, é fundamental observar que os EA_r são necessários apenas para que o PESDE possa inferir adequadamente o desempenho do estudante no processo de avaliação. A próxima seção apresenta e discute os resultados obtidos em experimentos realizados com esta abordagem e avalia tais resultados, mostrando que os objetivos inicialmente propostos foram alcançado através do modelo estocástico proposto neste trabalho.

5.3 Experimentos e Análise dos Resultados Obtidos

Esta seção apresenta uma sequência de experimentos que estende a experimentação realizada em (Dorça et al., 2011a; Dorça et al., 2012b) ao cobrir todas as categorias pedagógicas de estudantes, apresentadas no capítulo 4. O objetivo é atribuir um estado inicial ao modelo do estudante e analisar o comportamento do sistema ao longo do tempo e os resultados por ele gerados ao final do processo de aprendizagem com intuito de se verificar a eficiência e eficácia da abordagem proposta no que diz respeito à convergência do ME e ao tempo gasto no processo de aprendizagem, medido em número de seções de aprendizagem necessárias para completar o processo.

O processo de aprendizagem é iterativo, e o EC do estudante é atualizado de acordo com os resultados de seu desempenho a cada iteração do processo. Como consequência, o EC pode avançar, caso o estudante obtenha $PFM \geq m$, ou não avançar, caso o estudante obtenha $PFM < m$. Portanto, quanto mais fácil o processo de aprendizagem, menos iterações são necessárias para que se atinja a todos os objetivos de aprendizagem. E, quanto melhor adaptado o conteúdo é, mais fácil o processo de aprendizagem, conforme discutido anteriormente. Desta forma, quanto maior a dificuldade do estudante em progredir no nível cognitivo, maior a quantidade de iterações necessárias para que o processo seja finalizado, comportamento este que pode ser observado nos experimentos apresentados a seguir.

Para cada experimento define-se os EA_r e a força de cada preferência (forte, moderada, fraca ou balanceada). Para cada experimento, apresenta-se graficamente o processo de atualização dos EA_p durante o processo de aprendizagem. Em cada gráfico, o eixo x mostra o número de iterações do processo de aprendizagem, e o eixo y mostra os valores que os EA_p assumem ao longo do processo de aprendizagem em cada dimensão. O objetivo principal foi observar como o ME é gradualmente atualizado ao longo de cada seção (ou iteração) do processo de aprendizagem. Desta forma, foi possível visualizar claramente o processo de detecção e correção automática de EA em cada uma das dimensões do FSLSM.

Além disto, para cada experimento é apresentado um gráfico que mostra o valor da performance obtida pelo estudante a cada 5 seções de aprendizagem, o que permite observar a variação em relação à obtenção de $PFM \geq m$ e $PFM < m$ entre os diferentes experimentos. E, também, apresenta-se graficamente a variação da média da performance e da quantidade de problemas de aprendizagem ocorridos, em intervalos de 20 iterações. Isto permite verificar como a performance média aumenta e a quantidade de problemas de aprendizagem diminui à medida que o ME é corrigido e se torna consistente em relação aos EA_r do estudante.

Cada experimento considerou estudantes de uma categoria pedagógica específica, considerando as 16 possíveis CEAs. Desta forma, os EA_r do estudante são definidos em cada experimento. Pôde-se observar que quanto maior o nível de inconsistência do ME inicial em relação aos EA_r do estudante, mais sensível é a redução de problemas de aprendizagem em consequência da melhora da performance PFM do estudante, à medida que o ME é corrigido e se torna consistente.

Desta forma, foi possível verificar o comportamento apresentado em diversos estudos², que atestam que atender aos EA_r do estudante causa um impacto notoriamente positivo em seu desempenho. Esta é uma contribuição importante deste trabalho: garantir que os EA_p armazenados no ME sejam o mais consistente possível em relação aos EA_r do estudante, contribuindo assim para a maximização de seu desempenho. A seguir, os experimentos são apresentados considerando-se o ME inicial apresentado na Tabela 5.1.

Tabela 5.1: ME inicial

Estilos de Aprendizagem							
Processamento		Percepção		Entrada		Organização	
Ativo	Reflexivo	Sensitivo	Intuitivo	Visual	Verbal	Sequencial	Global
0,70	0,30	0,70	0,30	0,70	0,30	0,70	0,30
Estado Cognitivo e Objetivos de Aprendizagem							
$EC = \{\langle C0, -1 \rangle \dots \langle C59, -1 \rangle\}$							
$OA = \{\langle C0, 5 \rangle \dots \langle C59, 5 \rangle\}$							

²Haider et al. (2010); Graf et al. (2008); Kinshuk et al. (2009); Graf e Kinshuk (2009a); Graf e Liu (2008); Coffield et al. (2009); Alfonseca et al. (2006); Graf e Lin (2007); Graf e Kinshuk (2007); Bajraktarevic et al. (2003); Sangineto et al. (2008); Terry et al. (1995); Friedel e Rudd (2006); Vasilyeva et al. (2006)

Nos experimentos apresentados, pôde-se verificar o comportamento da abordagem considerando-se níveis de inconsistência de 0 a 4 do ME inicial, considerando-se as 4 dimensões de EA do FSLSM. Observa-se que a medida que o nível de inconsistência aumenta, a quantidade de iterações necessárias ao processo tende a crescer, o que é um resultado natural e esperado, já que falhas no processo de adaptatividade causam dificuldades de aprendizagem em decorrência de EA não satisfeitos.

5.3.1 Experimento 1

Neste experimento, considera-se um estudante com as seguintes preferências:

$$EA_r = \{Ativo(Forte), Sensitivo(Forte), Visual(Moderada), Sequencial(Leve)\}$$

Considerando-se este perfil de estudante, o ME apresentado na Tabela 5.1 é inicialmente consistente em todas as dimensões de EA. A Figura 5.1 apresenta graficamente a atualização de EA_p no ME durante o processo de aprendizagem.

A Tabela 5.2 apresenta o número de iterações deste experimento, a quantidade de problemas de aprendizagem ocorridos, e os EA_p armazenados no ME ao final do processo de aprendizagem, conforme Definição 4.1.5. Como pode ser observado, os EA_p se conservaram consistentes ao final do processo de aprendizagem.

Tabela 5.2: Resultados do Experimento 1

Iterações	Prob. de Aprendizagem	EA_p
393	33	$\{(0,89; 0,11) (0,86; 0,14) (0,81; 0,19) (0,80; 0,20)\}$

A Figura 5.2 apresenta o valor da performance PFM do estudante em intervalos de 5 seções de aprendizagem, obtidas neste experimento. O intuito é observar a variação na obtenção de $PFM \geq m$ e $PFM < m$, entre este e os demais experimentos. Nota-se que à medida em que LS_p inconsistentes persistem no ME, existe uma tendência maior em se obter $PFM < m$. Para tornar a percepção visual deste fato mais clara, uma linha dada por $f(x) = m$, com $m = 60$, separa visualmente os pontos indicando $PFM \geq m$ daqueles

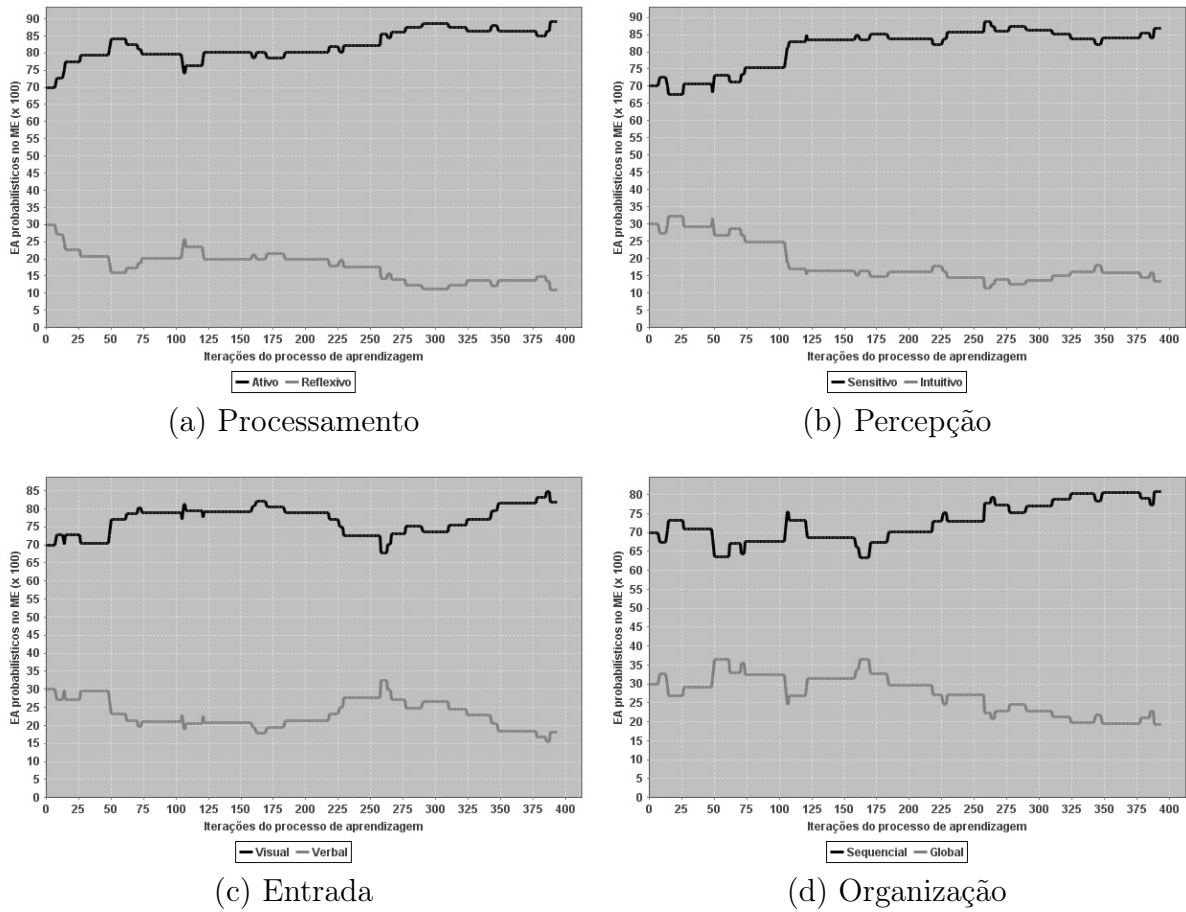


Figura 5.1: Atualização do ME no Experimento 1

que indicam $PFM < m$. Como não existem inconsistências no ME inicial, e os EA_p se conservam consistentes ao longo do processo, não é possível notar incremento qualitativo na performance do estudante.

A Figura 5.3 apresenta a performance média obtida pelo estudante (Figura 5.3a) e a média de problemas de aprendizagem ocorridos (Figura 5.3b) a cada 20 seções de aprendizagem, relativos a este experimento. Pelos mesmos motivos, a média de problemas de aprendizagem e performance se mantém ao longo do processo de aprendizagem.

Nos próximos experimentos, de 1 a 4 inconsistências são gradativamente introduzidas no ME inicial para que se possa perceber o comportamento da abordagem proposta frente a todos os tipos de inconsistências em todas as dimensões, considerando-se todos os níveis de força, e o impacto destas inconsistências na performance do estudante.

Neste experimento, quando comparado aos próximos, pôde-se notar que o processo

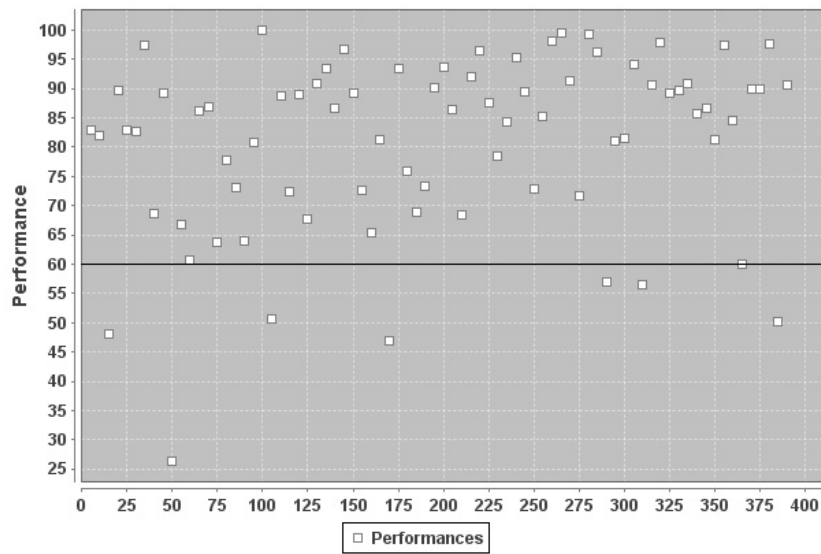
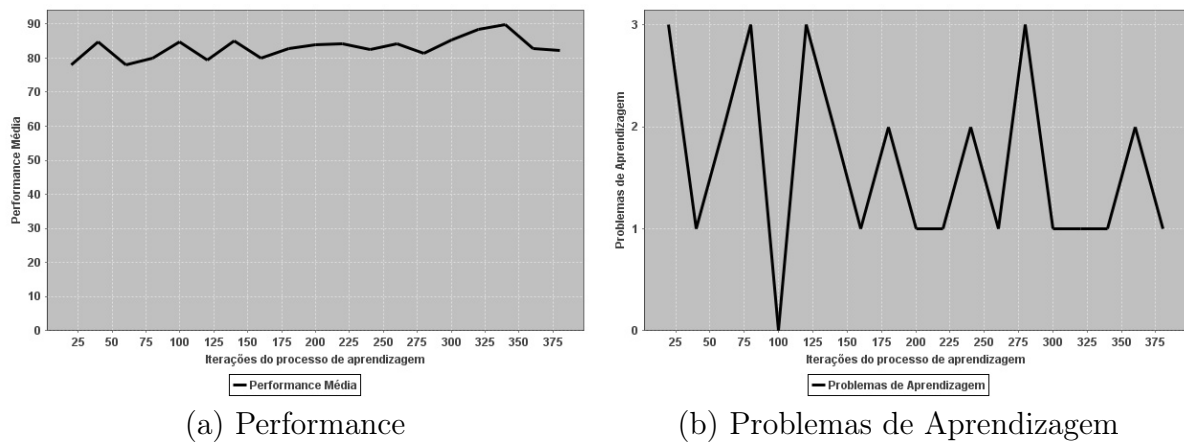


Figura 5.2: Performances do estudante no Experimento 1



(a) Performance

(b) Problemas de Aprendizagem

Figura 5.3: Médias de performances e problemas de aprendizagem no Experimento 1

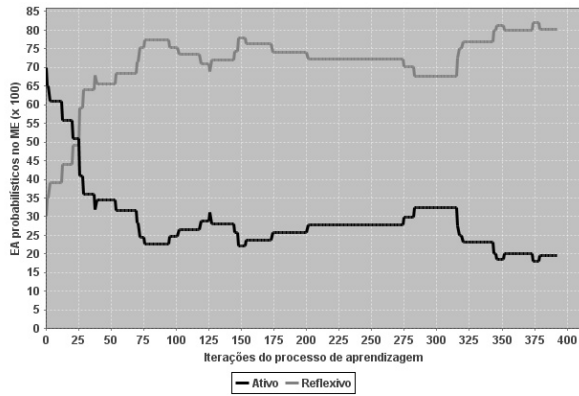
de adaptatividade atendeu mais eficientemente às necessidades do estudante, o que resultou em menor probabilidade de dificuldade no processo de aprendizagem, gerando um número menor de ocorrências de problemas de aprendizagem. Isto automaticamente resultou em uma quantidade menor de iterações, que foi na maioria das vezes maior nos demais experimentos. É importante lembrar que este acréscimo no número de iterações é probabilístico, e não determinístico. Desta forma, nem sempre ocorre, mas tende a ocorrer à medida que inconsistências aparecem no ME.

5.3.2 Experimento 2

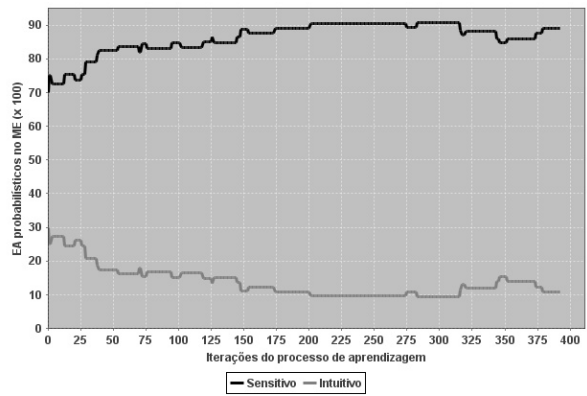
Neste experimento, considera-se um estudante com as seguintes preferências:

$$EA_r = \{Reflexivo(Forte), Sensitivo(Forte), Visual(Moderada), Sequencial(Leve)\}$$

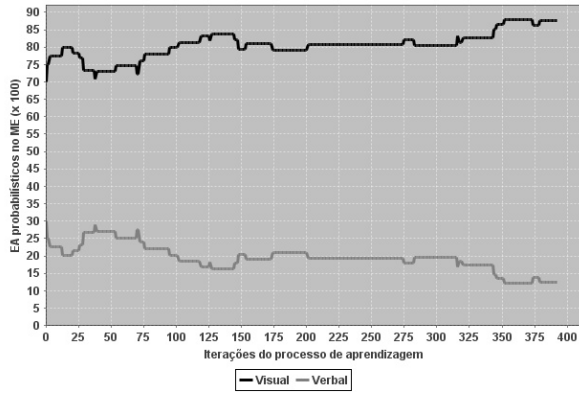
Considerando-se este perfil de estudante, o ME apresentado na Tabela 5.1 é inicialmente inconsistente na dimensão Processamento, em que o estudante apresenta forte preferência pelo estilo Reflexivo.



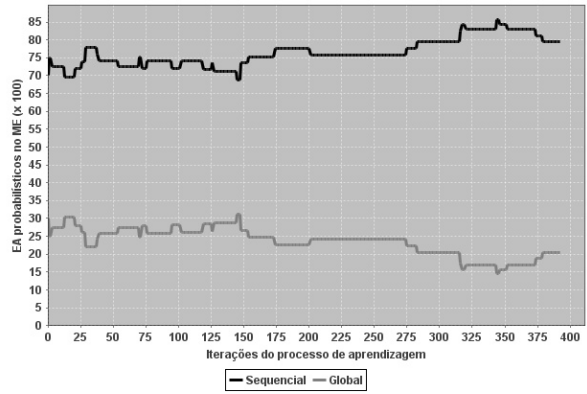
(a) Processamento



(b) Percepção



(c) Entrada



(d) Organização

Figura 5.4: Atualização do ME durante Experimento 2

A Tabela 5.3 apresenta o número de iterações deste experimento, a quantidade de problemas de aprendizagem ocorridos e os EA_p armazenados no ME ao final do processo de aprendizagem. Como pode ser observado, a inconsistência inicialmente presente no ME foi eficientemente eliminada no início do processo de aprendizagem. Apesar desta inconsistência inicial no ME, a quantidade de iterações do processo não foi maior, quando

comparada ao experimento anterior. Isto se explica em razão da inconsistência ter sido eliminada no início do processo, sendo impedida de impactar prejudicialmente no processo de aprendizagem. Além disto, conforme explicado anteriormente, como vários outros fatores influenciam na aprendizagem, o fato dos EA_p no experimento 1 estarem consistentes em todo o processo não elimina a possibilidade de ocorrência de problemas de aprendizagem, conforme modelado pelo PESDE.

Tabela 5.3: Resultados do Experimento 2

Iterações	Prob. de Aprendizagem	EA_p			
392	32	(0,19; 0,81)	(0,89; 0,11)	(0,87; 0,13)	(0,79; 0,21)

A Figura 5.5 apresenta o valor da performance PFM do estudante em intervalos de 5 seções de aprendizagem, obtidas neste experimento. O intuito é observar a variação na obtenção de $PFM \geq m$ e $PFM < m$, entre este e os demais experimentos. Nota-se que à medida em que LS_p inconsistentes persistem no ME, existe uma tendência maior em se obter $PFM < m$.

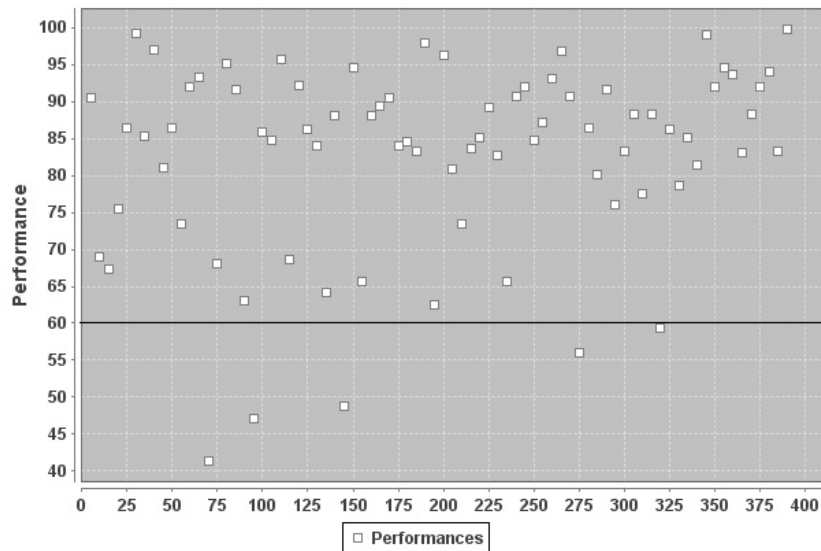


Figura 5.5: Performances do estudante no Experimento 2

A Figura 5.6 apresenta a performance média obtida pelo estudante (Figura 5.6a) e a média de problemas de aprendizagem ocorridos (Figura 5.6b) neste experimento. Ana-

lisando os gráficos, é possível notar que houve uma visível melhora inicial na performance do estudante e diminuição na média de problemas de aprendizagem, em decorrência da eliminação da inconsistência existente no início do processo.

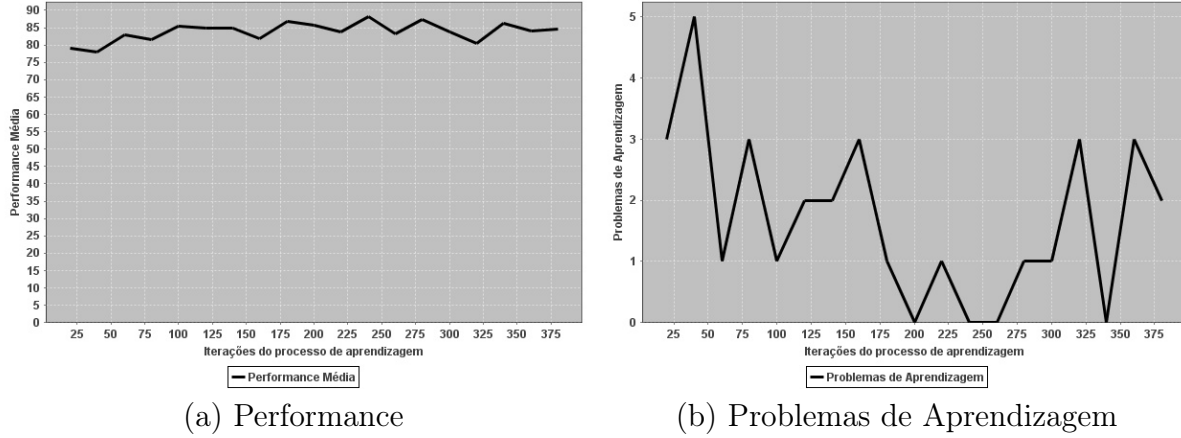


Figura 5.6: Médias de performances e problemas de aprendizagem no Experimento 2

Observou-se também que a quantidade de iterações foi maior do que aquele observado no experimento anterior, o que já era esperado, já que com uma preferência inicialmente inconsistente no ME, houve no início do processo de aprendizagem um aumento da probabilidade de ocorrência de problemas de aprendizagem.

5.3.3 Experimento 3

Neste experimento, considera-se um estudante com as seguintes preferências:

$$EA_r = \{Ativo(Forte), Intuitivo(Forte), Visual(Moderada), Sequencial(Leve)\}$$

Considerando-se este perfil de estudante, o ME apresentado na Tabela 5.1 é inicialmente inconsistente na dimensão Percepção, em que o estudante apresenta forte preferência pelo estilo Intuitivo.

A Tabela 5.4 apresenta o número de iterações deste experimento, a quantidade de problemas de aprendizagem ocorridos e os EA_p armazenados no ME ao final do processo de aprendizagem. Como pode ser observado, a inconsistência inicialmente presente no ME foi eficientemente eliminada no início do processo de aprendizagem.

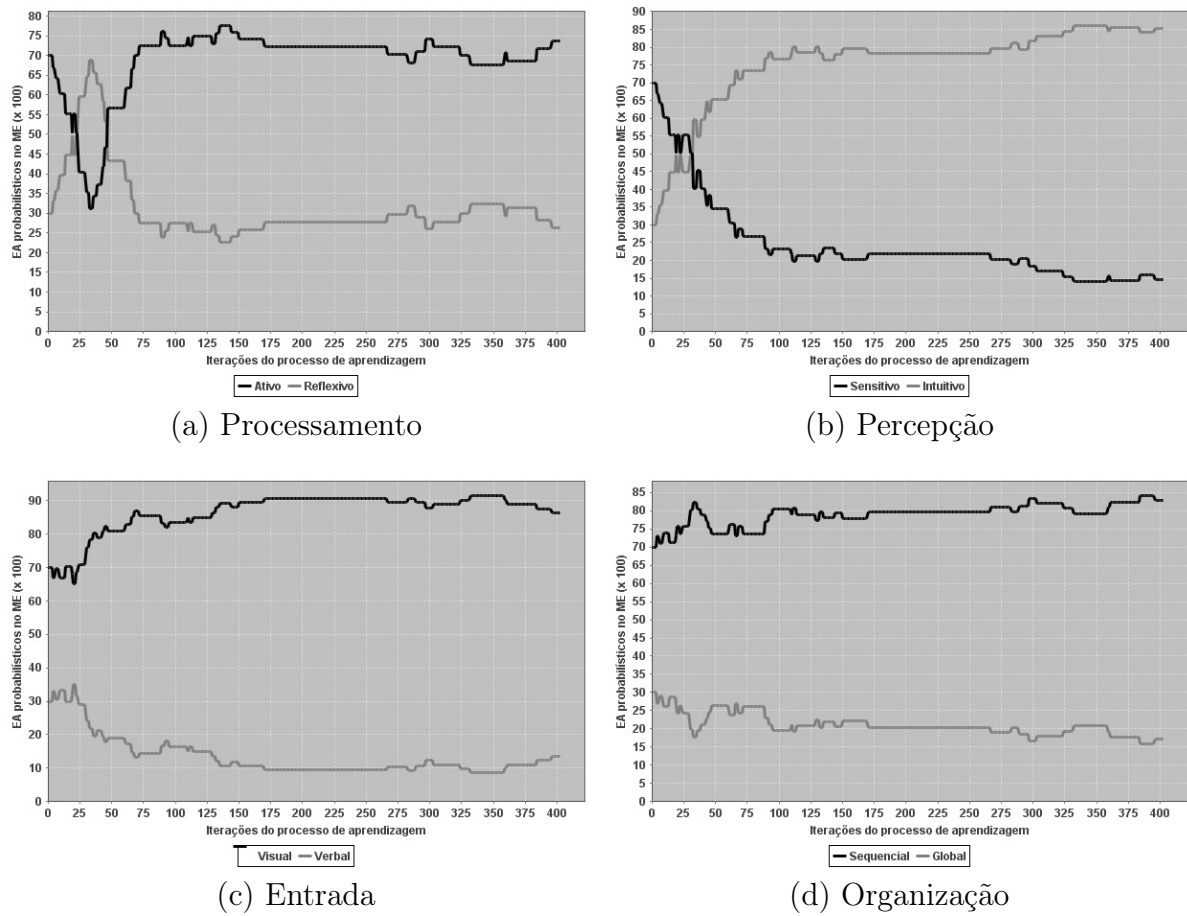


Figura 5.7: Atualização do ME durante Experimento 3

Tabela 5.4: Resultados do Experimento 3

Iterações	Prob. de Aprendizagem	EA_p			
402	42	(0,73; 0,27)	(0,14; 0,86)	(0,86; 0,14)	(0,82; 0,18)

Pode-se perceber que apesar da dimensão Processamento estar inicialmente consistente no ME, ela foi alterada no início do processo de aprendizagem, permanecendo inconsistente por um breve período.

Este é um efeito imediato do não-determinismo inerente ao processo de detecção de EA baseado em AR considerando uma política mista de exploração e exploração (política ϵ -greedy), que considera a escolha intencional (com probabilidade ϵ) de uma CEA que pode não ser considerada a melhor no estado atual do ME, visando maior eficiência na

constante aquisição de conhecimento, conforme mencionado anteriormente.

Comparando-se os resultados apresentados na Tabela 5.4 com aqueles apresentados nos experimentos anteriores, percebe-se um aumento na quantidade de iterações necessárias ao processo. Pode-se atribuir este aumento ao fato de que houveram duas preferências fortes inconsistentes no início do processo, o que pode ter causado dificuldades de aprendizagem.

A Figura 5.8 apresenta o valor da performance PFM do estudante em intervalos de 5 seções de aprendizagem, obtidas neste experimento. O intuito é observar a variação na obtenção de $PFM \geq m$ e $PFM < m$, entre este e os demais experimentos. Nota-se que à medida em que LS_p inconsistentes persistem no ME, existe uma tendência maior em se obter $PFM < m$.

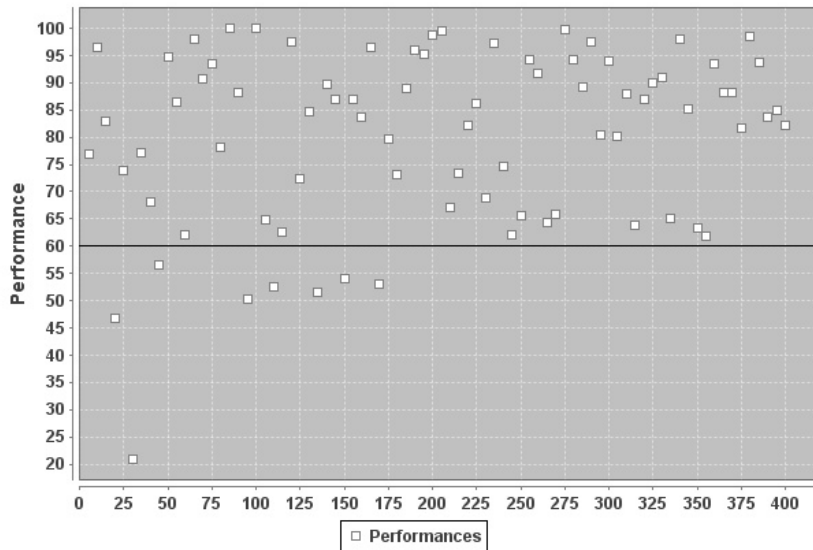


Figura 5.8: Performances do estudante no Experimento 3

A Figura 5.9 apresenta a performance média obtida pelo estudante (Figura 5.9a) e a média de problemas de aprendizagem ocorridos (Figura 5.9b) neste experimento.

Analisando-se os gráficos é possível notar significativo aumento na performance média do estudante e queda brusca na média de problemas de aprendizagem, logo no início do processo, à medida que as duas inconsistências existentes no ME são eliminadas. Depois, com o ME consistente, a média de problemas de aprendizagem permanece bem baixa.

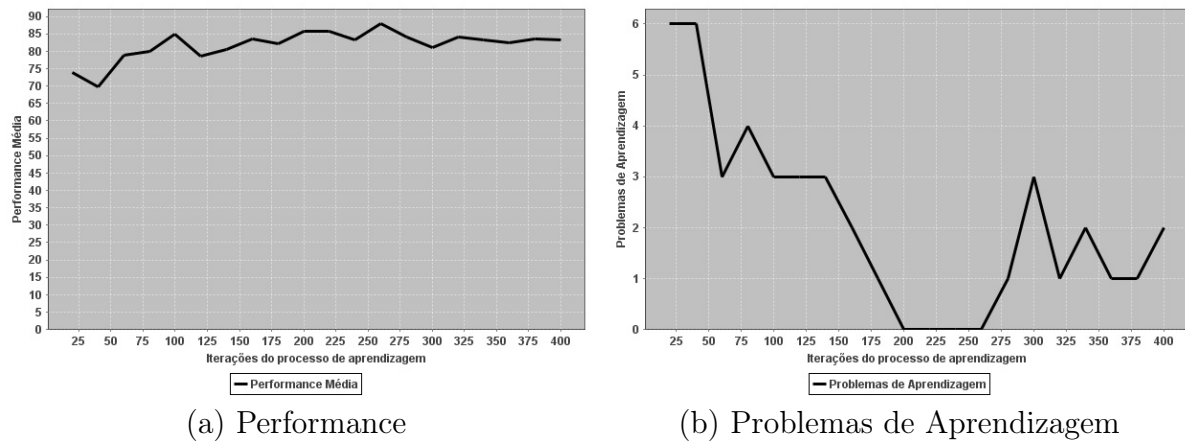


Figura 5.9: Médias de performances e problemas de aprendizagem no Experimento 3

5.3.4 Experimento 4

Neste experimento, considera-se um estudante com as seguintes preferências:

$$EA_r = \{Ativo(Forte), Sensitivo(Forte), Verbal(Moderada), Sequencial(Leve)\}$$

Considerando-se este perfil de estudante, o ME apresentado na Tabela 5.1 é inicialmente inconsistente na dimensão Entrada. Analisando-se o ME inicial e os EA_r do estudante, verifica-se uma inconsistência, em que o ME apresenta preferência pelo estilo Visual, tendo o estudante a preferência pelo estilo Verbal. Ou seja, tem-se neste experimento, inicialmente, uma preferência moderada inconsistente no ME.

A Tabela 5.5 apresenta o número de iterações deste experimento, a quantidade de problemas de aprendizagem ocorridos e os EA_p armazenados no ME ao final do processo de aprendizagem. Como pode ser observado, a inconsistência inicialmente presente no ME foi eficientemente eliminada ao longo do processo de aprendizagem.

Tabela 5.5: Resultados do Experimento 4

Iterações	Prob. de Aprendizagem	EA_p			
396	36	(0,78; 0,22)	(0,79; 0,21)	(0,22; 0,78)	(0,80; 0,20)

Comparando-se estes resultados àqueles apresentados no experimento anterior, percebe-se que uma quantidade menor de iterações foi necessária, provavelmente em decorrência

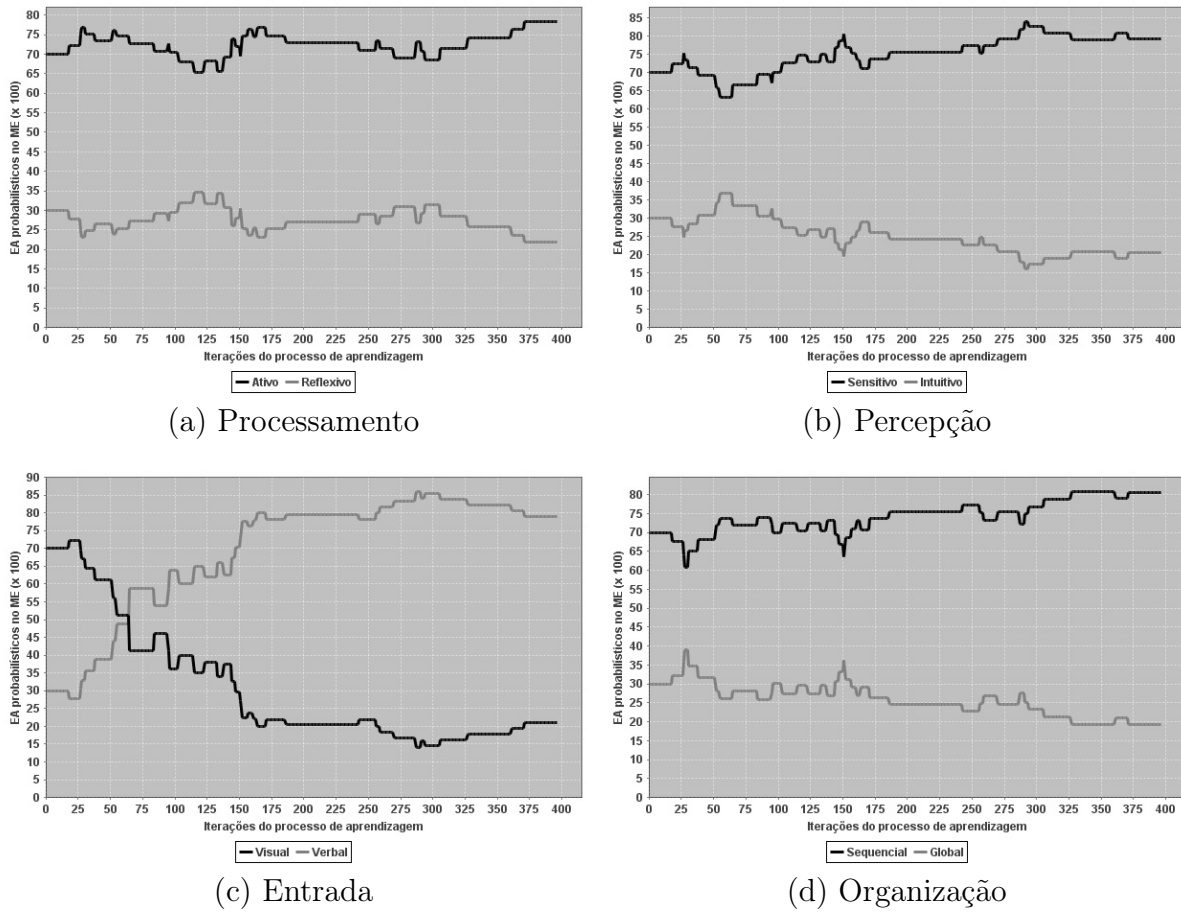


Figura 5.10: Atualização do ME durante Experimento 4

do fato de que preferências moderadas exercem influência menor do que fortes. Mas, ao comparar este experimento com o experimento 2. Atribui-se este resultado ao fato de que a inconsistência em uma preferência forte inicialmente existente no experimento 2 foi mais rapidamente eliminada (por volta da iteração 25), mitigando-se antecipadamente seu impacto negativo.

A Figura 5.11 apresenta o valor da performance PFM do estudante em intervalos de 5 seções de aprendizagem, obtidas neste experimento. O intuito é observar a variação na obtenção de $PFM \geq m$ e $PFM < m$, entre este e os demais experimentos. Nota-se que à medida em que LS_p inconsistentes persistem no ME, existe uma tendência maior em se obter $PFM < m$.

A Figura 5.12 apresenta a performance média obtida pelo estudante (Figura 5.12a) e a média de problemas de aprendizagem ocorridos (Figura 5.12b), obtidas neste experi-

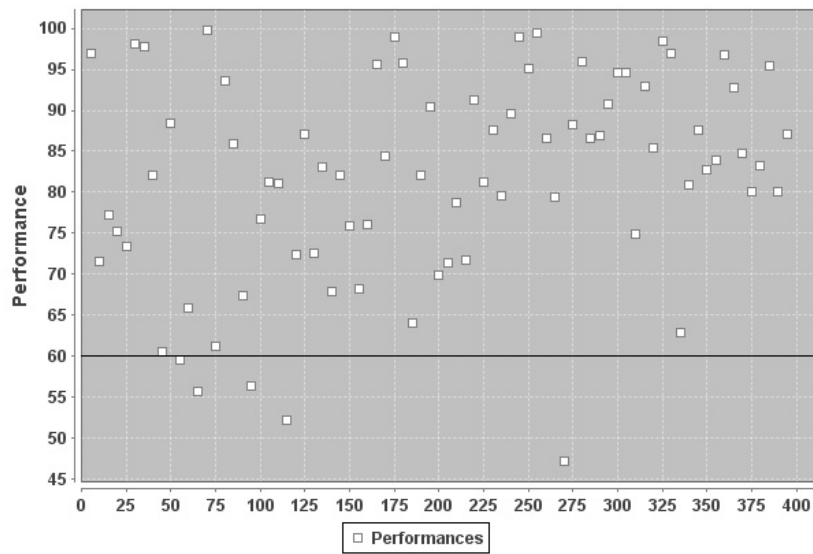
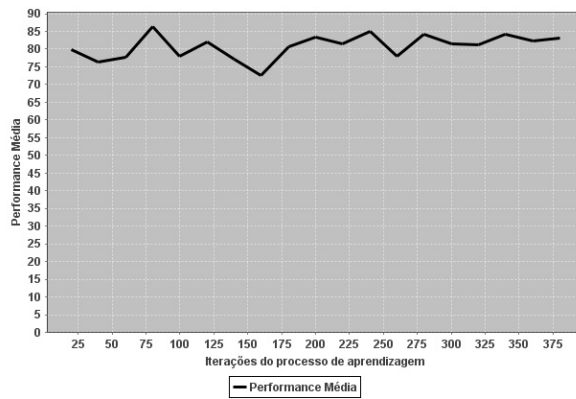
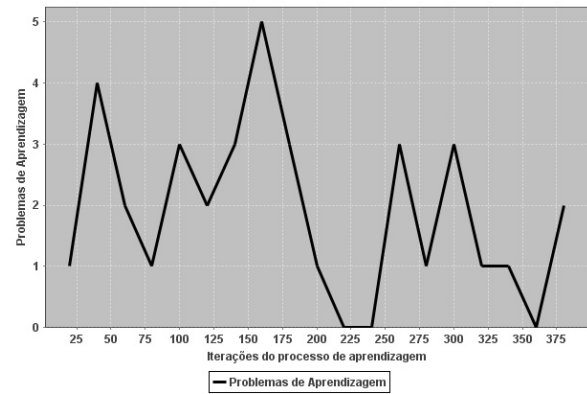


Figura 5.11: Performances do estudante no Experimento 4

mento.



(a) Performance



(b) Problemas de Aprendizagem

Figura 5.12: Médias de performances e problemas de aprendizagem no Experimento 4

Analisando-se os gráficos é possível notar aumento na performance média do estudante e queda na média de problemas de aprendizagem à medida que o ME se torna consistente.

5.3.5 Experimento 5

Neste experimento, considera-se um estudante com as seguintes preferências:

$$EA_r = \{Ativo(Forte), Sensitivo(Forte), Visual(Moderada), Global(Leve)\}$$

Considerando-se este perfil de estudante, o ME apresentado na Tabela 5.1 é inicialmente inconsistente na dimensão Organização, em que o estudante apresenta leve preferência pelo estilo Global.

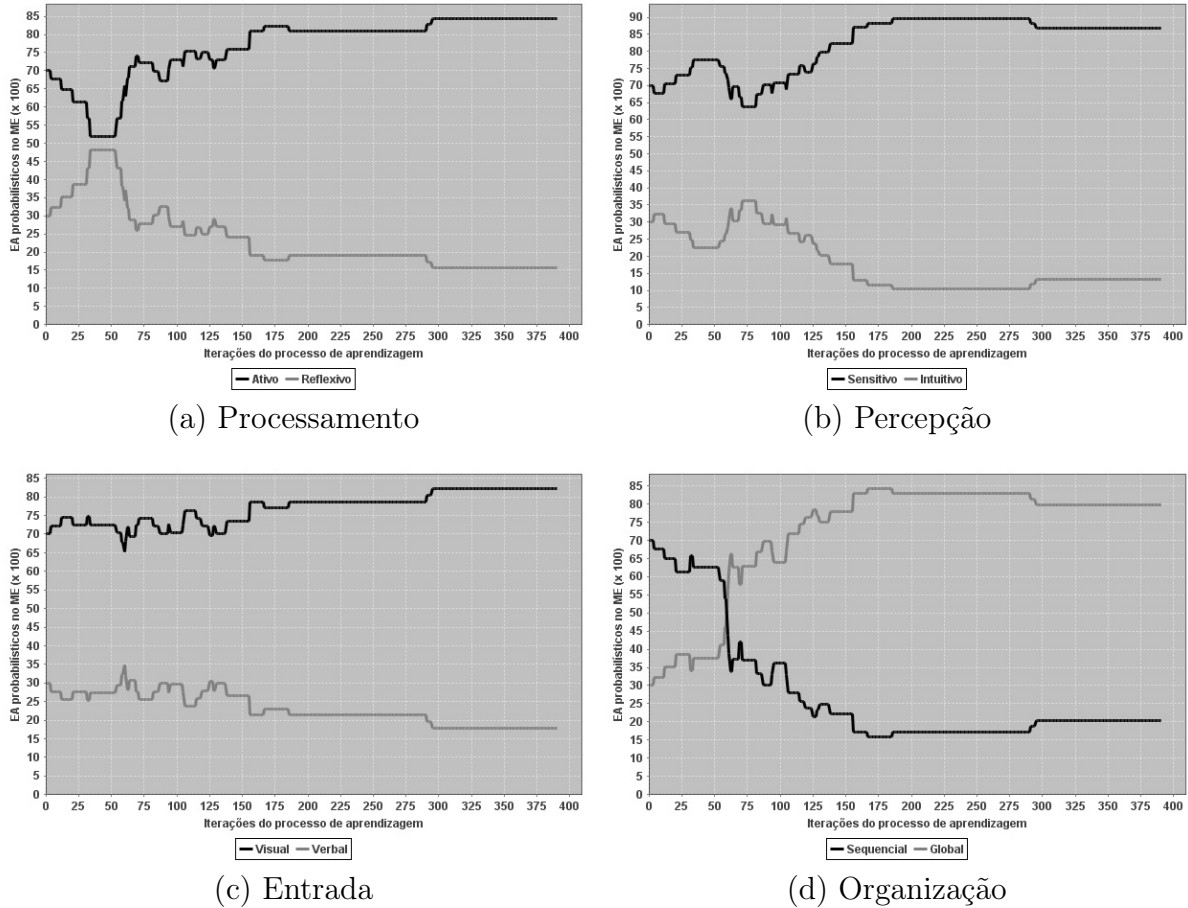


Figura 5.13: Atualização do ME durante Experimento 5

É possível observar no gráfico que a dimensão Processamento, que é inicialmente consistente, quase se tornou inconsistente, o que não ocorreu. Mais uma vez, reforça-se o não-determinismo da política de aprendizagem empregada, e sua importância. As preferências consistentes foram mantidas, e a inconsistência foi devidamente eliminada.

A Tabela 5.6 apresenta o número de iterações deste experimento, a quantidade de problemas de aprendizagem ocorridos e os EA_p armazenados no ME ao final do processo de aprendizagem. Como pode ser observado, a inconsistência inicialmente presente no ME foi eficientemente eliminada no início do processo de aprendizagem.

Nota-se que um número menor de iterações foram necessárias quando se compara

Tabela 5.6: Resultados do Experimento 5

Iterações	Prob. de Aprendizagem	EA_p			
390	30	(0,84; 0,16)	(0,86; 0,14)	(0,82; 0,18)	(0,20; 0,80)

este experimento com os anteriores, o que é compreensível, já que preferências leves ou balanceadas exercem influência reduzida na performance do estudante.

A Figura 5.14 apresenta o valor da performance PFM do estudante em intervalos de 5 seções de aprendizagem, obtidas neste experimento. O intuito é observar a variação na obtenção de $PFM \geq m$ e $PFM < m$, entre este e os demais experimentos. Nota-se que à medida em que LS_p inconsistentes persistem no ME, existe uma tendência maior em se obter $PFM < m$.

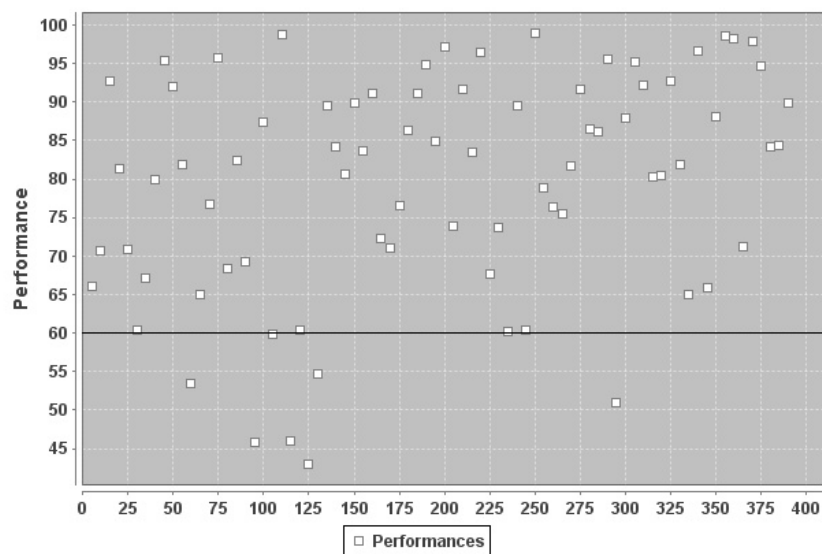


Figura 5.14: Performances do estudante no Experimento 5

A Figura 5.15 apresenta a performance média obtida pelo estudante (Figura 5.15a) e a média de problemas de aprendizagem ocorridos (Figura 5.15b) neste experimento.

Analisando-se os gráficos é possível notar aumento na performance média do estudante e queda na média de problemas de aprendizagem à medida que o ME se torna consistente.

É importante observar neste ponto que inconsistências em preferências leves ou

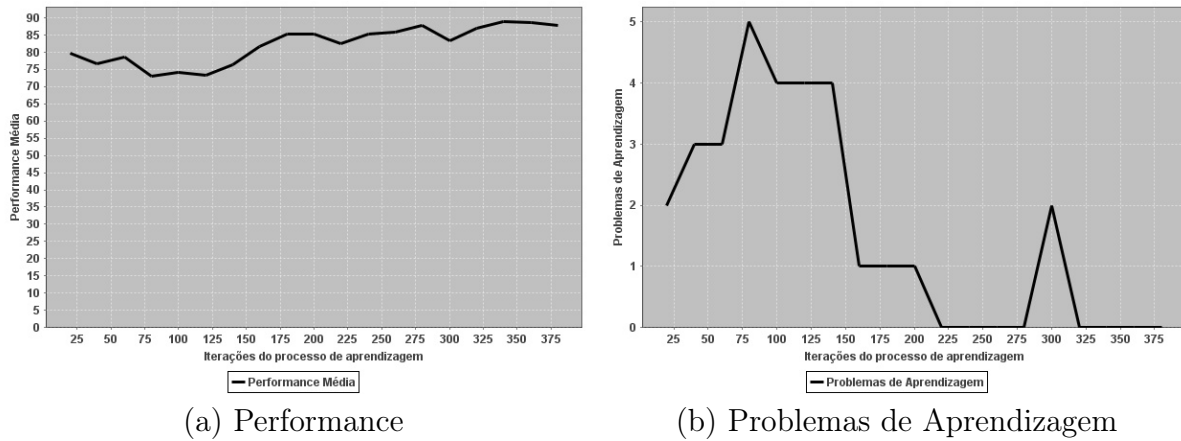


Figura 5.15: Médias de performances e problemas de aprendizagem no Experimento 5

moderadas demoram mais para serem completamente corrigidas do que aquelas em preferências fortes. Este comportamento provavelmente ocorre porque inconsistências em preferências fortes contribuem para que ocorram problemas de aprendizagem com maior frequência, tornando-as mais suscetíveis aos reforços aplicados pela política de AR.

5.3.6 Experimento 6

Neste experimento, considera-se um estudante com as seguintes preferências:

$$EA_r = \{Reflexivo(Forte), Intuitivo(Forte), Visual(Moderada), Sequencial(Leve)\}$$

Considerando-se este perfil de estudante, o ME apresentado na Tabela 5.1 é inicialmente inconsistente nas dimensões Processamento e Percepção, ambas apresentando preferências fortes pelo estudante aos estilos Reflexivo e Intuitivo.

A Tabela 5.7 apresenta o número de iterações deste experimento, a quantidade de problemas de aprendizagem ocorridos e os EA_p armazenados no ME ao final do processo de aprendizagem. Como pode ser observado, a inconsistência inicialmente presente no ME foi eficientemente eliminada no início do processo de aprendizagem.

Nota-se que mesmo havendo duas preferências fortes inicialmente inconsistentes no ME, o número de iterações necessárias ao processo de aprendizagem é menor do que nos experimentos 1 a 4. Atribui-se isto ao fato de que ambas as inconsistências foram rapidamente eliminadas, mitigando-se seu prejuízo ao processo de aprendizagem. Além

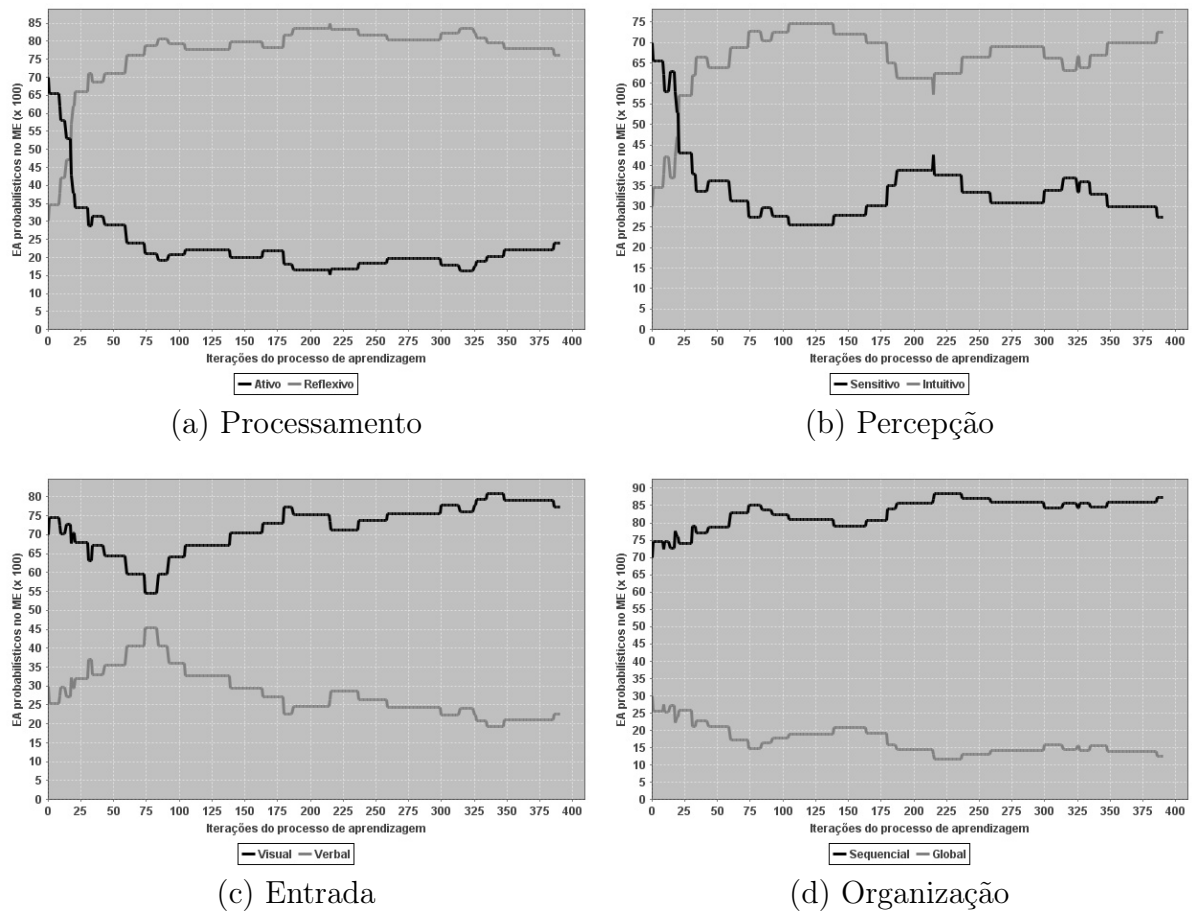


Figura 5.16: Atualização do ME durante Experimento 6

Tabela 5.7: Resultados do Experimento 6

Iterações	Prob. de Aprendizagem	EA_p			
390	30	(0,23; 0,77)	(0,27; 0,73)	(0,77; 0,23)	(0,87; 0,13)

disto, não apenas EA_p consistentes determinam a performance do estudante.

A Figura 5.17 apresenta o valor da performance PFM do estudante em intervalos de 5 seções de aprendizagem, obtidas neste experimento. O intuito é observar a variação na obtenção de $PFM \geq m$ e $PFM < m$, entre este e os demais experimentos. Nota-se que à medida em que LS_p inconsistentes persistem no ME, existe uma tendência maior em se obter $PFM < m$.

A Figura 5.18 apresenta a performance média obtida pelo estudante (Figura 5.18a)

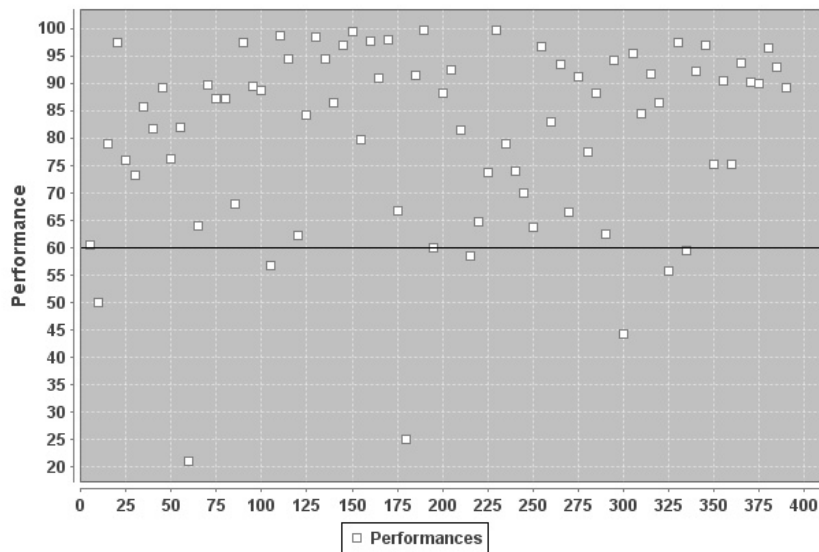
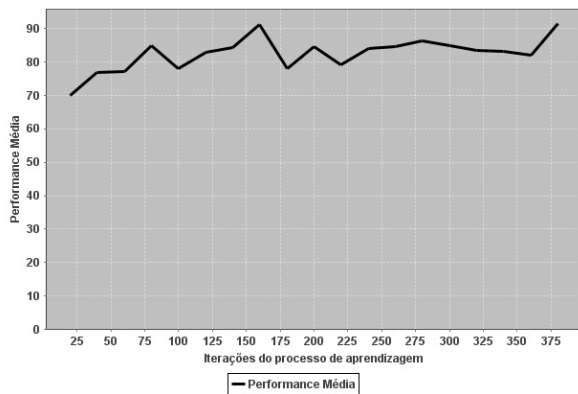
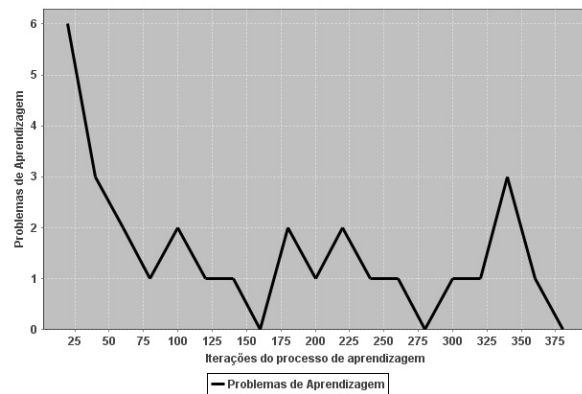


Figura 5.17: Performances do estudante no Experimento 6

e a média de problemas de aprendizagem ocorridos (Figura 5.18b), obtidas neste experimento.



(a) Performance



(b) Problemas de Aprendizagem

Figura 5.18: Médias de performances e problemas de aprendizagem no Experimento 6

Analisando-se os gráficos é possível notar significativo aumento na performance média do estudante e queda brusca na média de problemas de aprendizagem, logo no início do processo, à medida que as duas inconsistências existentes no ME são eliminadas. Depois, com o ME consistente, a média de problemas de aprendizagem permanece bem baixa, chegando diversas vezes a 0.

5.3.7 Experimento 7

Neste experimento, considera-se um estudante com as seguintes preferências:

$$EA_r = \{Ativo(Forte), Intuitivo(Forte), Verbal(Moderada), Sequencial(Leve)\}$$

Considerando-se este perfil de estudante, o ME apresentado na Tabela 5.1 é inicialmente inconsistente nas dimensões Percepção e Entrada, representando uma preferência forte e uma moderada respectivamente.

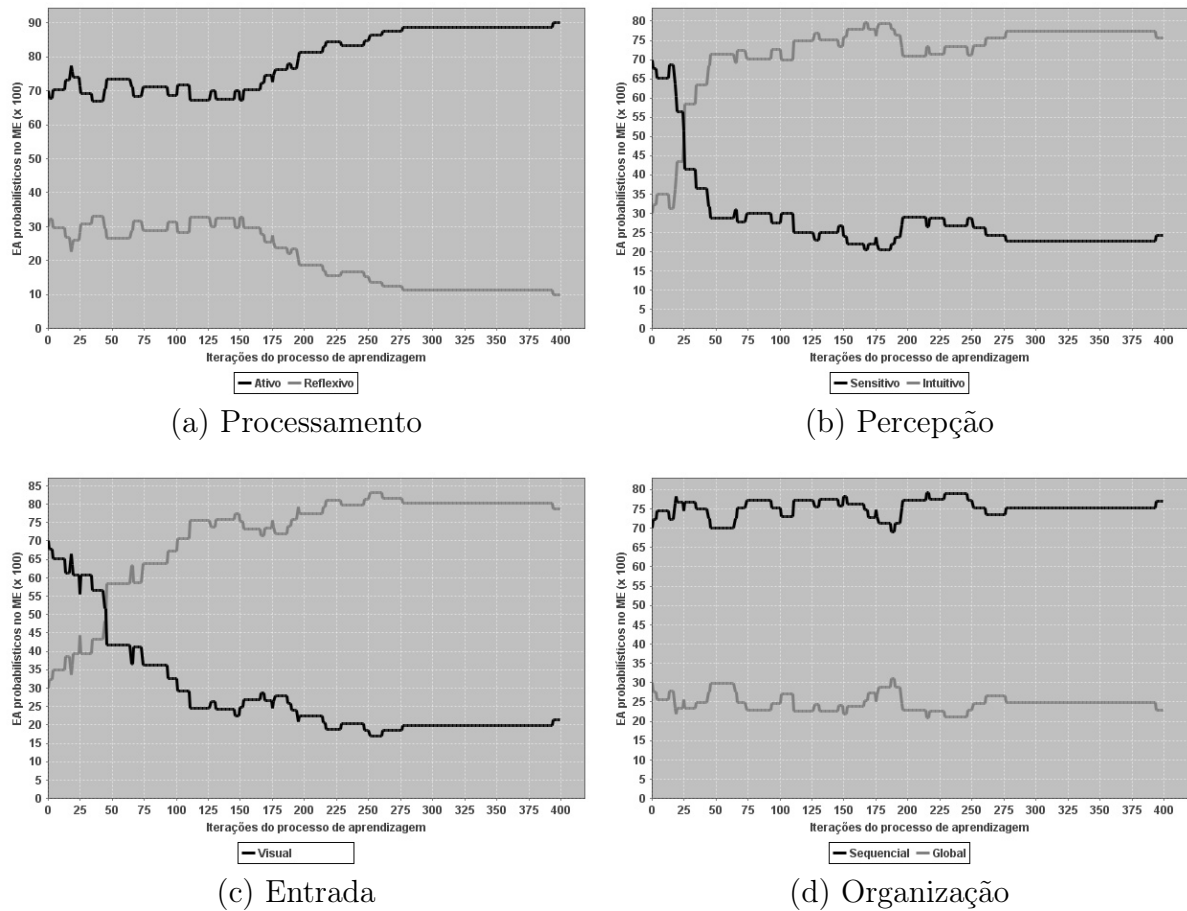


Figura 5.19: Atualização do ME durante Experimento 7

A Tabela 5.8 apresenta o número de iterações deste experimento, a quantidade de problemas de aprendizagem ocorridos e os EA_p armazenados no ME ao final do processo de aprendizagem. Como pode ser observado, as inconsistências inicialmente presentes no ME foram eficientemente eliminadas ao longo do processo de aprendizagem. É possível notar claramente como a inconsistência na preferência forte é eliminada mais rapidamente

do que na moderada.

Tabela 5.8: Resultados do Experimento 7

Iterações	Prob. de Aprendizagem	EA_p			
399	39	(0,89; 0,11)	(0,24; 0,76)	(0,22; 0,78)	(0,77; 0,23)

A Figura 5.20 apresenta o valor da performance PFM do estudante em intervalos de 5 seções de aprendizagem, obtidas neste experimento. O intuito é observar a variação na obtenção de $PFM \geq m$ e $PFM < m$, entre este e os demais experimentos. Nota-se que à medida em que LS_p inconsistentes persistem no ME, existe uma tendência maior em se obter $PFM < m$.

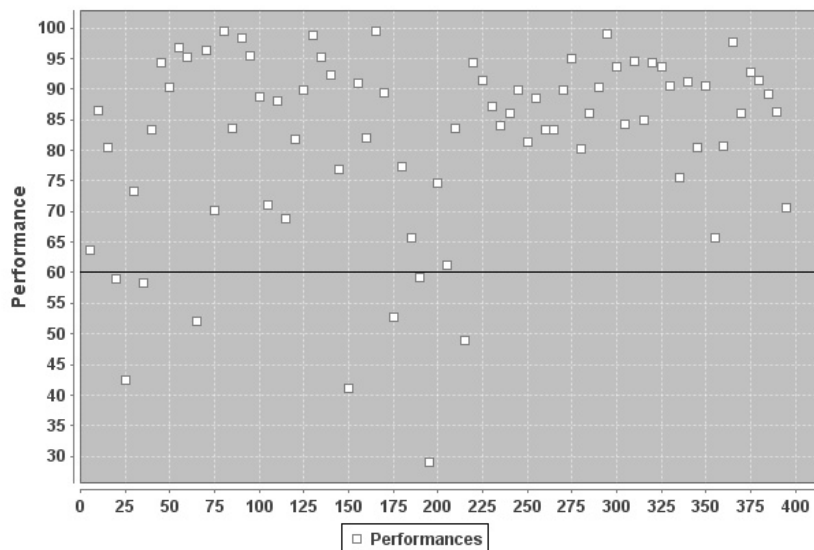


Figura 5.20: Performances do estudante no Experimento 7

A Figura 5.21 apresenta a performance média obtida pelo estudante (Figura 5.21a) e a média de problemas de aprendizagem ocorridos (Figura 5.21b) neste experimento.

Analisando-se os gráficos é possível notar significativo aumento na performance média do estudante e queda acentuada na média de problemas de aprendizagem à medida que as duas inconsistências existentes no ME são eliminadas.

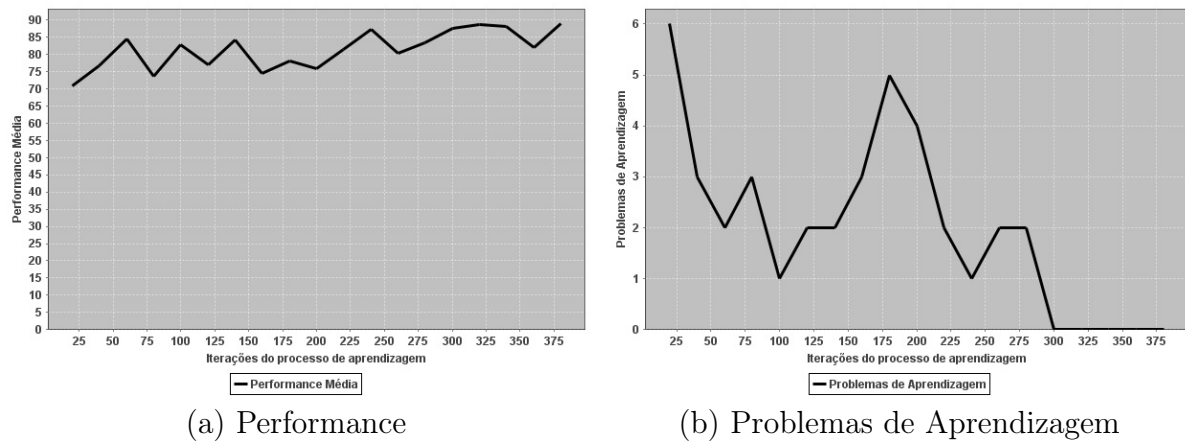


Figura 5.21: Médias de performances e problemas de aprendizagem no Experimento 7

5.3.8 Experimento 8

Neste experimento, considera-se um estudante com as seguintes preferências:

$$EA_r = \{Ativo(Forte), Sensitivo(Forte), Verbal(Moderada), Global(Leve)\}$$

Considerando-se este perfil de estudante, o ME apresentado na Tabela 5.1 é inicialmente inconsistente nas dimensões Entrada e Organização, configurando inconsistências em preferências moderada e leve.

A Tabela 5.9 apresenta o número de iterações deste experimento, a quantidade de problemas de aprendizagem ocorridos e os EA_p armazenados no ME ao final do processo de aprendizagem. Como pode ser observado, a inconsistência inicialmente presente no ME foi eficientemente eliminada no início do processo de aprendizagem.

Nota-se claramente uma lentidão maior na detecção e correção das inconsistências, principalmente na dimensão Organização, que apresenta inconsistência em uma preferência leve, que só é corrigida por volta da iteração 100. Isto mostra a dificuldade em se detectar inconsistências em preferências leves, por causarem baixo impacto no processo de aprendizagem, cujo efeito é difícil de se perceber. Como a abordagem proposta se baseia no retorno de uma ação no ambiente para aplicar o reforço, este comportamento é esperado, já que o retorno, neste caso, é de difícil percepção.

A Figura 5.23 apresenta o valor da performance PFM do estudante em intervalos de 5 seções de aprendizagem, obtidas neste experimento. O intuito é observar a variação

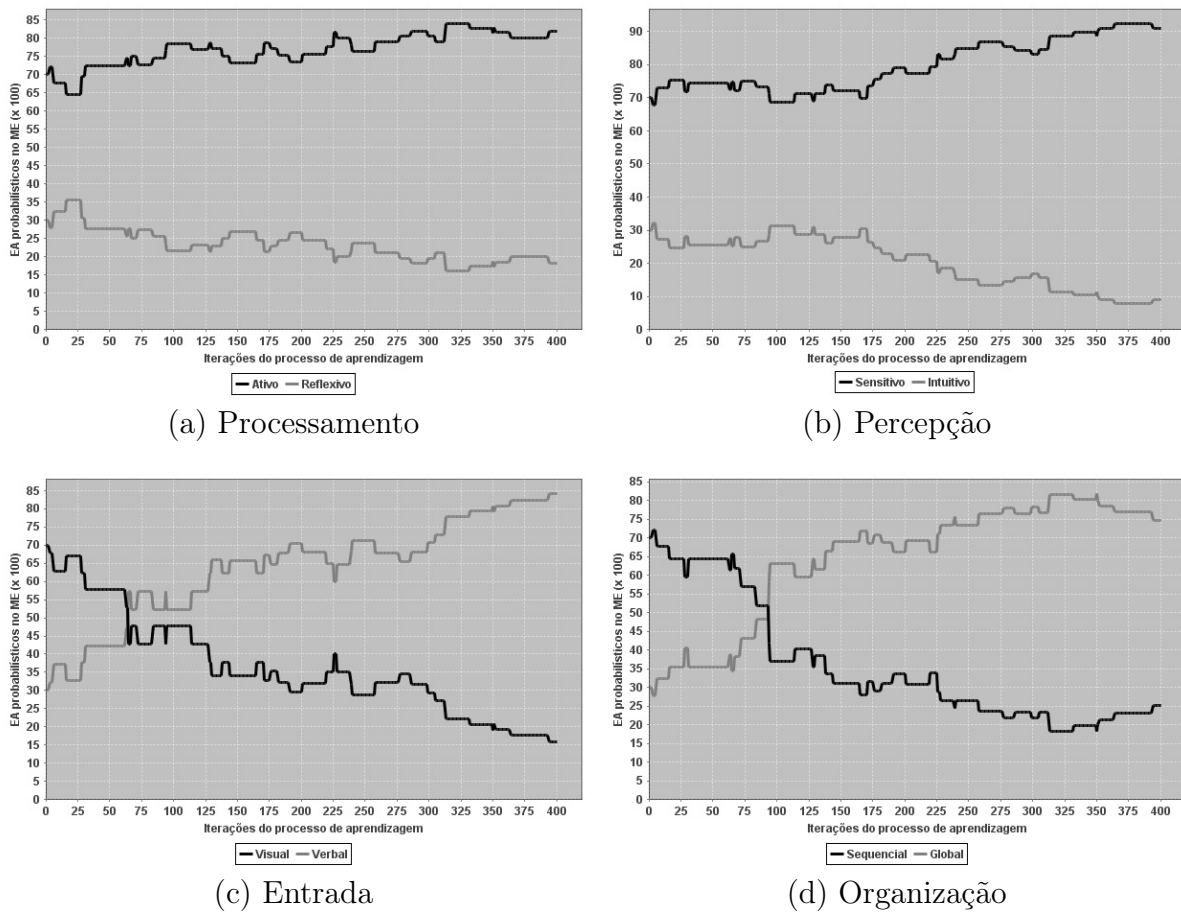


Figura 5.22: Atualização do ME durante Experimento 8

Tabela 5.9: Resultados do Experimento 8

Iterações	Prob. de Aprendizagem	EA_p			
400	40	(0,82; 0,18)	(0,90; 0,10)	(0,16; 0,84)	(0,26; 0,74)

na obtenção de $PFM \geq m$ e $PFM < m$, entre este e os demais experimentos. Nota-se que à medida em que LS_p inconsistentes persistem no ME, existe uma tendência maior em se obter $PFM < m$.

A Figura 5.24 apresenta a performance média obtida pelo estudante (Figura 5.24a) e a média de problemas de aprendizagem ocorridos (Figura 5.24b) neste experimento.

Observando-se os gráficos é possível notar que há um aumento sutil na média de performance, mas problemas de aprendizagem continuam a ocorrer ao longo de todo o

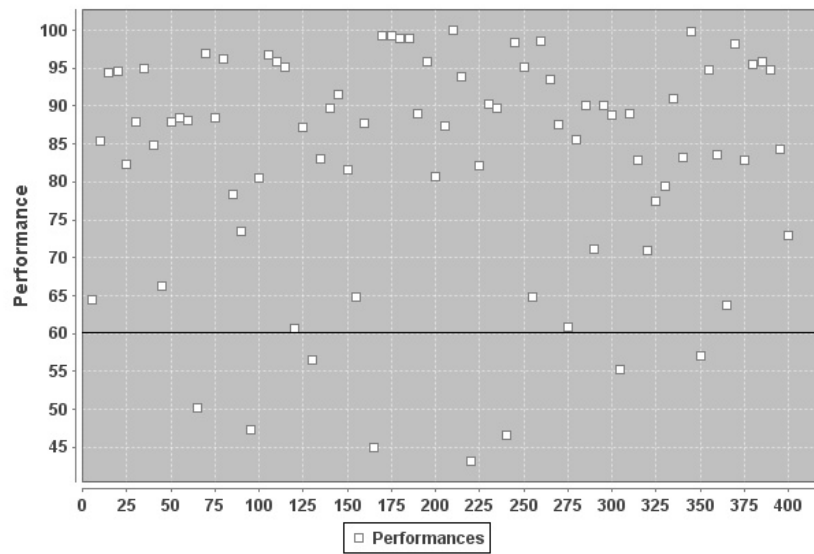


Figura 5.23: Performances do estudante no Experimento 8

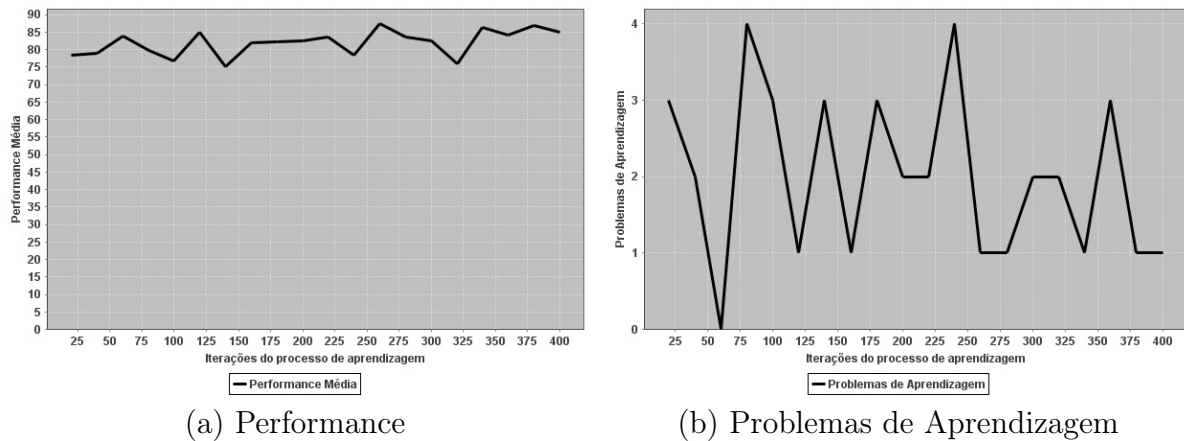


Figura 5.24: Médias de performances e problemas de aprendizagem no Experimento 8

processo de aprendizagem, apesar de atingir uma média baixa na maior parte do processo.

5.3.9 Experimento 9

Neste experimento, considera-se um estudante com as seguintes preferências:

$$EA_r = \{Reflexivo(Forte), Sensitivo(Forte), Verbal(Moderada), Sequencial(Leve)\}$$

Considerando-se este perfil de estudante, o ME apresentado na Tabela 5.1 é inicialmente inconsistente nas dimensões Processamento e Entrada, devido à forte preferência do estudante pelo estilo Reflexivo e à preferência moderada pelo estilo Verbal.

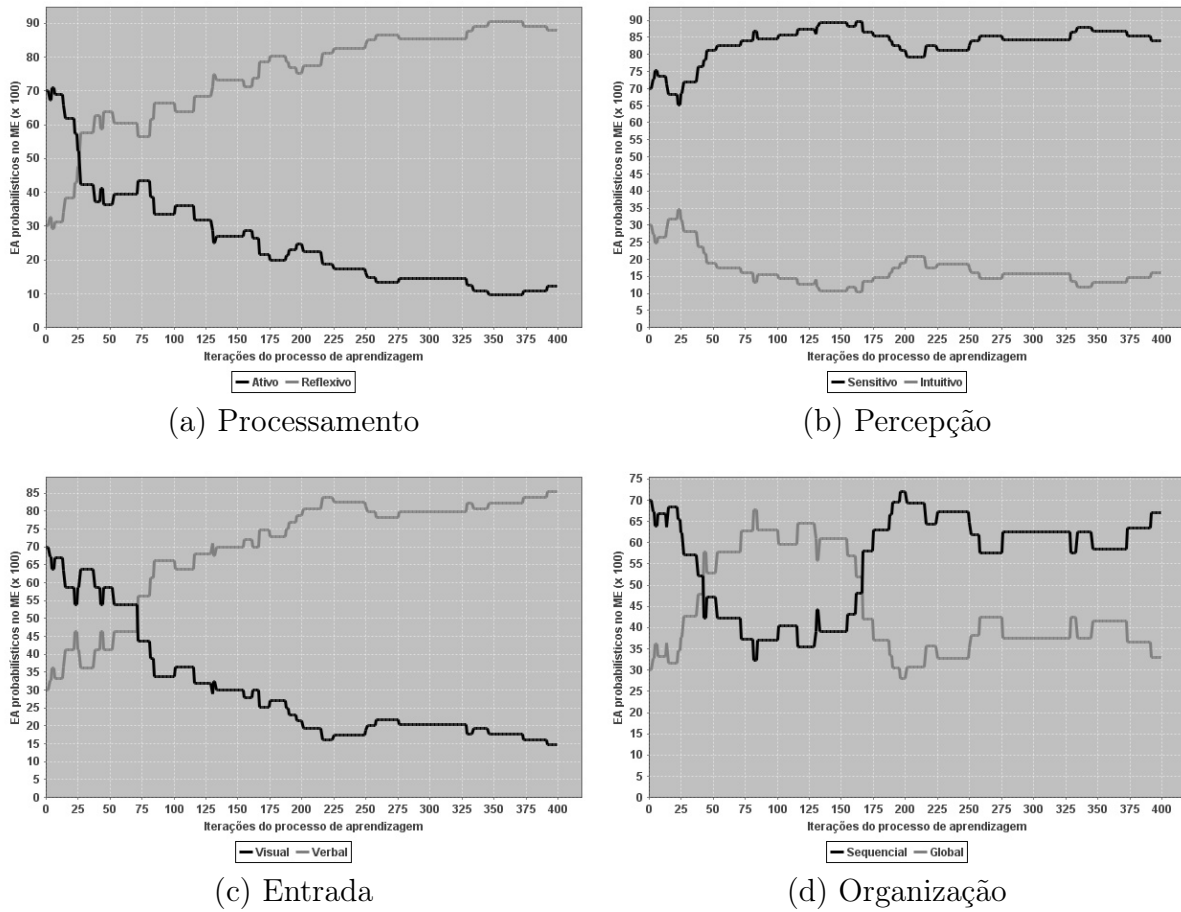


Figura 5.25: Atualização do ME durante Experimento 9

É possível observar, na Figura 5.25 que mesmo sendo inicialmente consistente a dimensão Organização, com preferência leve do estudante pelo estilo Sequencial, esta foi incorretamente inferida durante o processo de aprendizagem. Foi novamente retomada a consistência nesta dimensão após cerca de 100 iterações do processo, apresentando estabilidade até o final. Atribui-se a relativa demora em se retomar a consistência nesta dimensão ao fato da preferência leve ser mais dificilmente detectada, em decorrência do sutil impacto que causa no processo de aprendizagem.

A Tabela 5.10 apresenta o número de iterações deste experimento, a quantidade de problemas de aprendizagem ocorridos e os EA_p armazenados no ME ao final do processo de aprendizagem. Como pode ser observado, a inconsistência inicialmente presente no ME foi eficientemente eliminada no início do processo de aprendizagem.

A Figura 5.26 apresenta o valor da performance PFM do estudante em intervalos

Tabela 5.10: Resultados do Experimento 9

Iterações	Prob. de Aprendizagem	EA_p			
399	39	(0,12; 0,88)	(0,83; 0,17)	(0,15; 0,85)	(0,67; 0,33)

de 5 seções de aprendizagem, obtidas neste experimento. O intuito é observar a variação na obtenção de $PFM \geq m$ e $PFM < m$, entre este e os demais experimentos. Nota-se que à medida em que LS_p inconsistentes persistem no ME, existe uma tendência maior em se obter $PFM < m$.

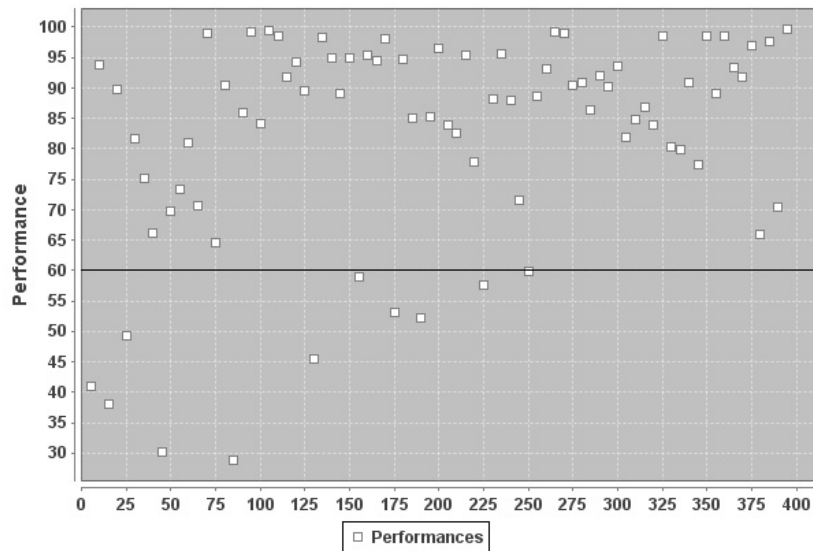


Figura 5.26: Performances do estudante no Experimento 9

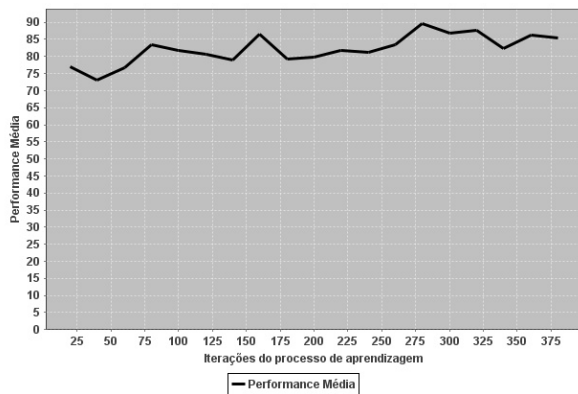
A Figura 5.27 apresenta a performance média obtida pelo estudante (Figura 5.27a) e a média de problemas de aprendizagem ocorridos (Figura 5.27b) neste experimento.

Analisando-se os gráficos é possível notar significativo aumento na performance média do estudante e queda acentuada na média de problemas de aprendizagem à medida que as inconsistências existentes no ME são eliminadas.

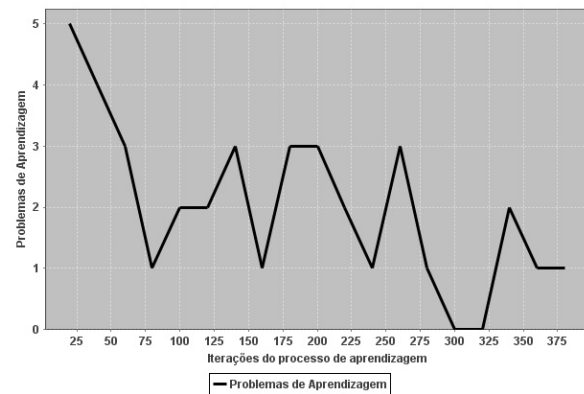
5.3.10 Experimento 10

Neste experimento, considera-se um estudante com as seguintes preferências:

$$EA_r = \{Reflexivo(Forte), Sensitivo(Forte), Visual(Moderada), Global(Leve)\}$$



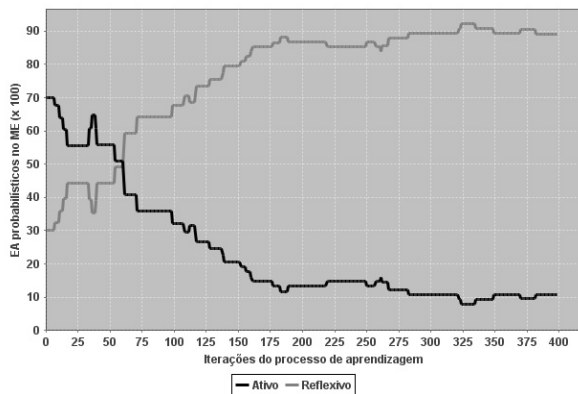
(a) Performance



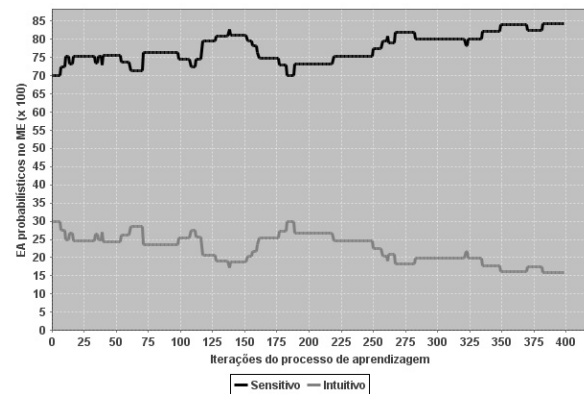
(b) Problemas de Aprendizagem

Figura 5.27: Médias de performances e problemas de aprendizagem no Experimento 9

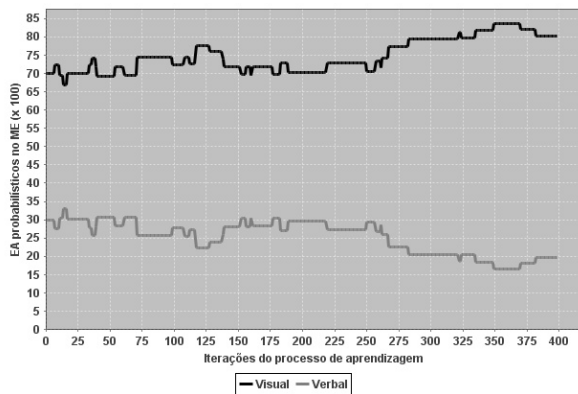
Considerando-se este perfil de estudante, o ME apresentado na Tabela 5.1 é inicialmente inconsistente nas dimensões Processamento e Organização, em que uma preferência forte e uma leve não atendem aos EA_r do estudante.



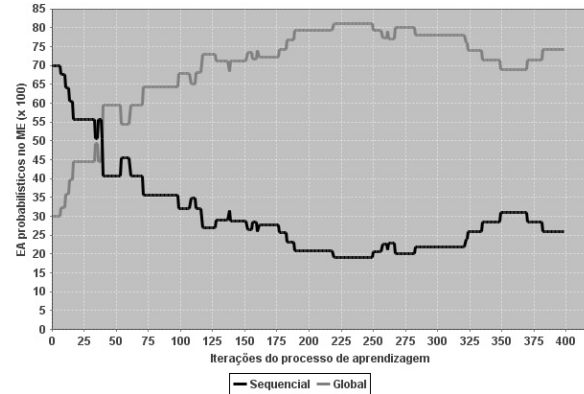
(a) Processamento



(b) Percepção



(c) Entrada



(d) Organização

Figura 5.28: Atualização do ME durante Experimento 10

A Tabela 5.11 apresenta o número de iterações deste experimento, a quantidade de problemas de aprendizagem ocorridos e os EA_p armazenados no ME ao final do processo de aprendizagem. Como pode ser observado, a inconsistência inicialmente presente no ME foi eficientemente eliminada no início do processo de aprendizagem.

Tabela 5.11: Resultados do Experimento 10

Iterações	Prob. de Aprendizagem	EA_p			
398	38	(0,11; 0,89)	(0,84; 0,16)	(0,80; 0,20)	(0,26; 0,74)

A Figura 5.29 apresenta o valor da performance PFM do estudante em intervalos de 5 seções de aprendizagem neste experimento. O intuito é observar a variação na obtenção de $PFM \geq m$ e $PFM < m$, entre este e os demais experimentos. Nota-se que à medida em que LS_p inconsistentes persistem no ME, existe uma tendência maior em se obter $PFM < m$.

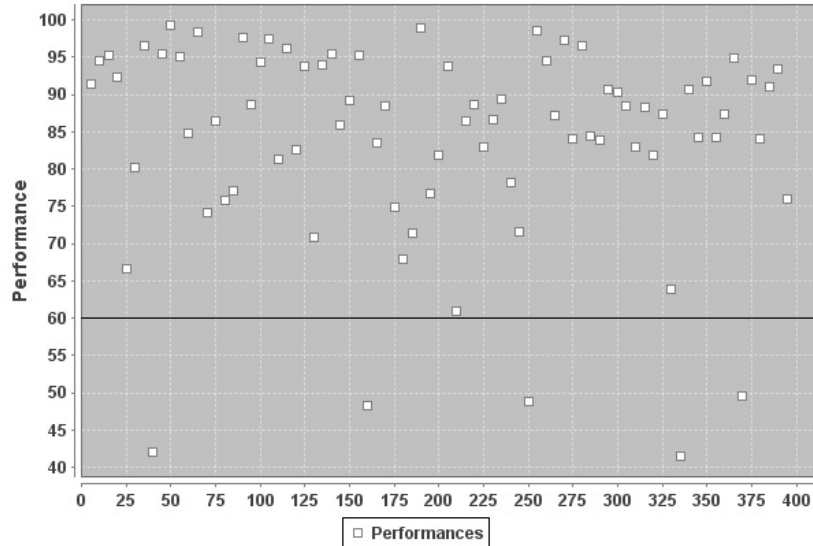


Figura 5.29: Performances do estudante no Experimento 10

A Figura 5.30 apresenta a performance média obtida pelo estudante (Figura 5.30a) e a média de problemas de aprendizagem ocorridos (Figura 5.30b) neste experimento.

Analisando-se os gráficos percebe-se melhoria na performance média do estudante. Mas, nota-se que problemas de aprendizagem continuaram a ocorrer ao longo de todo o

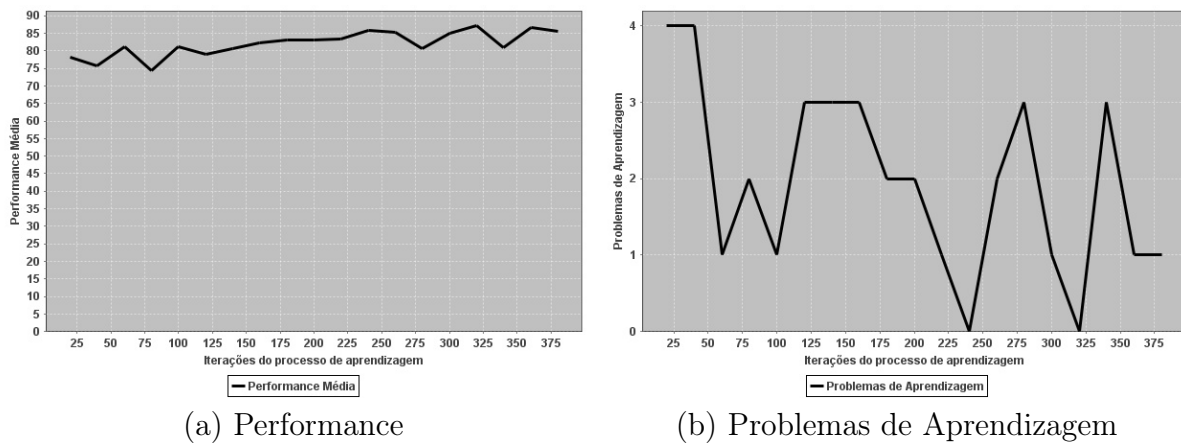


Figura 5.30: Médias de performances e problemas de aprendizagem no Experimento 10

processo de aprendizagem, em que pode-se notar uma redução na média à medida que o ME se tornou consistente.

5.3.11 Experimento 11

Neste experimento, considera-se um estudante com as seguintes preferências:

$$EA_r = \{Ativo(Forte), Intuitivo(Forte), Visual(Moderada), Global(Leve)\}$$

Considerando-se este perfil de estudante, o ME apresentado na Tabela 5.1 é inicialmente inconsistente nas dimensões Percepção e Organização, contendo respectivamente preferência forte pelo estilo Intuitivo, e leve pelo estilo Global.

A Tabela 5.12 apresenta o número de iterações deste experimento, a quantidade de problemas de aprendizagem ocorridos e os EA_p armazenados no ME ao final do processo de aprendizagem. Como pode ser observado, a inconsistência inicialmente presente no ME foi eficientemente eliminada no início do processo de aprendizagem.

Tabela 5.12: Resultados do Experimento 11

Iterações	Prob. de Aprendizagem	EA_p
400	40	(0,91; 0,09) (0,25; 0,75) (0,81; 0,19) (0,11; 0,89)

A Figura 5.32 apresenta o valor da performance PFM do estudante em intervalos

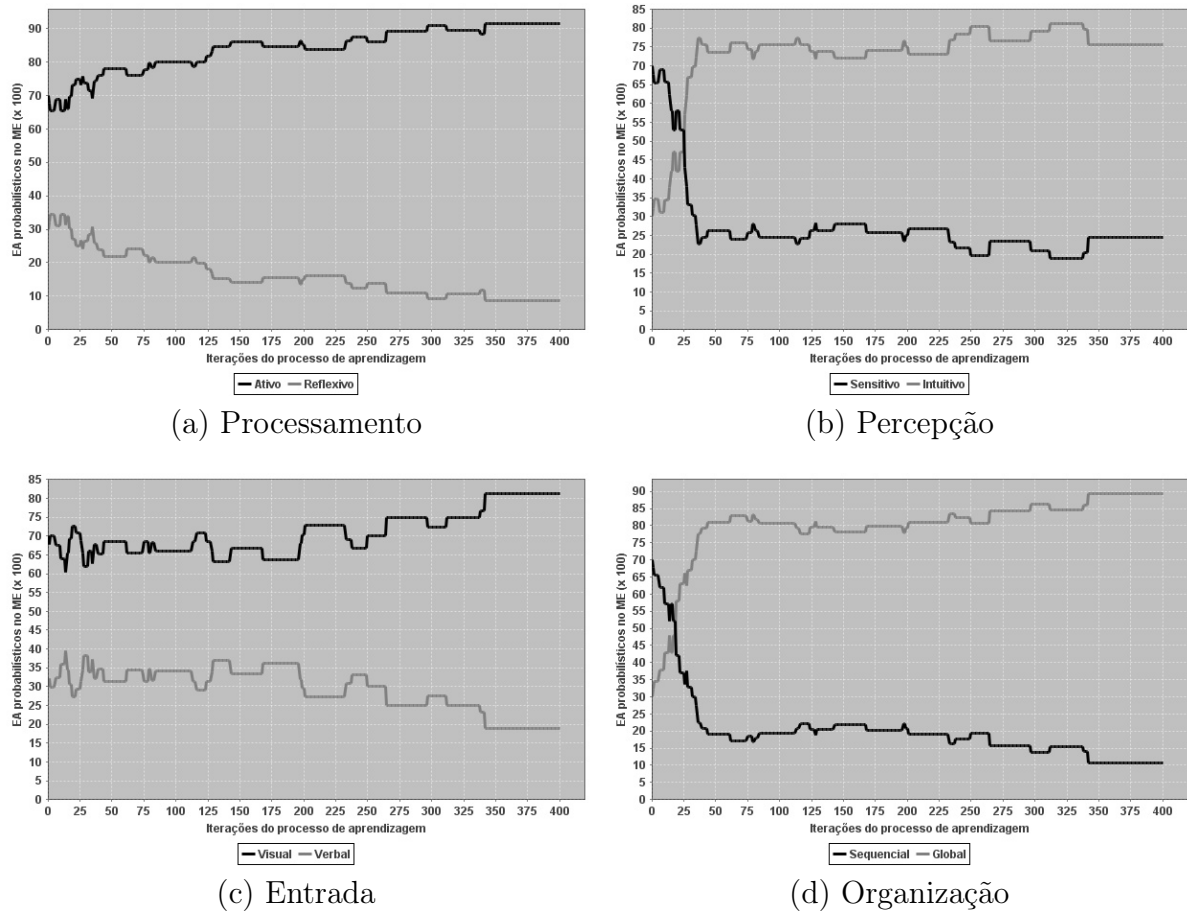


Figura 5.31: Atualização do ME durante Experimento 11

de 5 seções de aprendizagem, obtidas neste experimento. O intuito é observar a variação na obtenção de $PFM \geq m$ e $PFM < m$, entre este e os demais experimentos. Nota-se que à medida em que LS_p inconsistentes persistem no ME, existe uma tendência maior em se obter $PFM < m$.

A Figura 5.33 apresenta a performance média obtida pelo estudante (Figura 5.33a) e a média de problemas de aprendizagem ocorridos (Figura 5.33b) neste experimento.

Analisando-se os gráficos é possível notar aumento na performance média do estudante, e queda acentuada na média de problemas de aprendizagem, à medida que as inconsistências existentes no ME são eliminadas. A queda brusca na média de problemas de aprendizagem ocorre no tempo em que o ME se torna consistente, revelando o impacto na performance que tem um EA forte ao não ser satisfeito pelo processo de ensino.

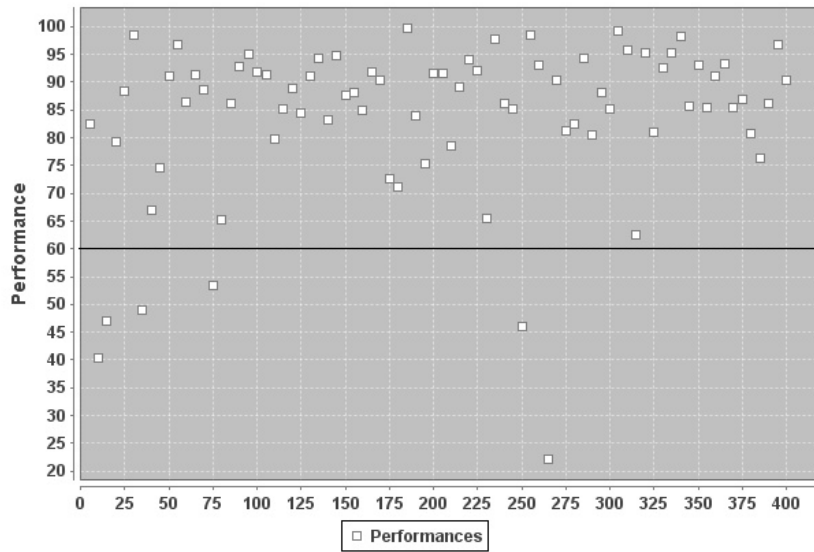


Figura 5.32: Performances do estudante no Experimento 11

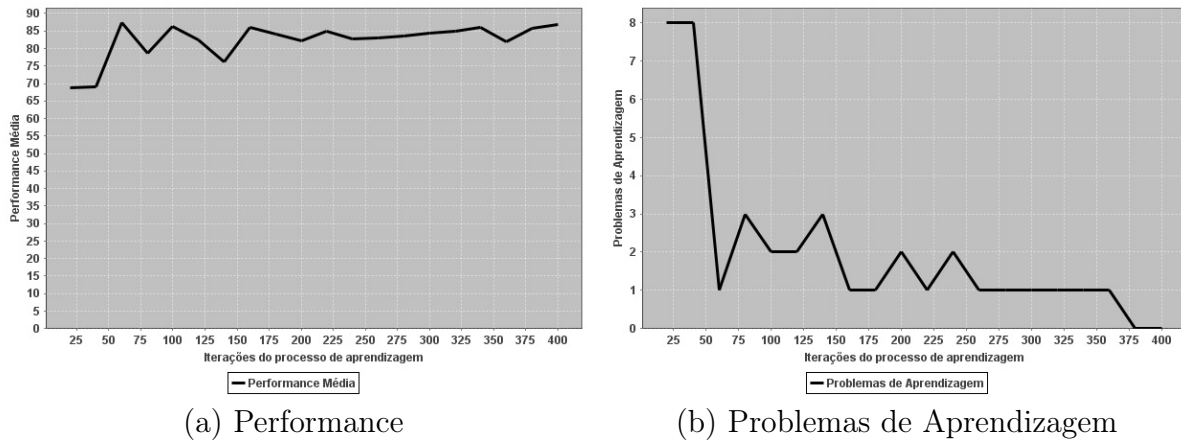


Figura 5.33: Médias de performances e problemas de aprendizagem no Experimento 11

5.3.12 Experimento 12

Neste experimento, considera-se um estudante com as seguintes preferências:

$$EA_r = \{Reflexivo(Forte), Intuitivo(Forte), Verbal(Moderada), Sequencial(Leve)\}$$

Considerando-se este perfil de estudante, o ME apresentado na Tabela 5.1 é inicialmente inconsistente nas dimensões Processamento, Percepção e Entrada. Neste ponto, este experimento possibilita a observação do funcionamento do sistema frente a 3 inconsistências no ME inicial.

Observando-se a Figura 5.34, nota-se a eficiência com que a inconsistência na dimen-

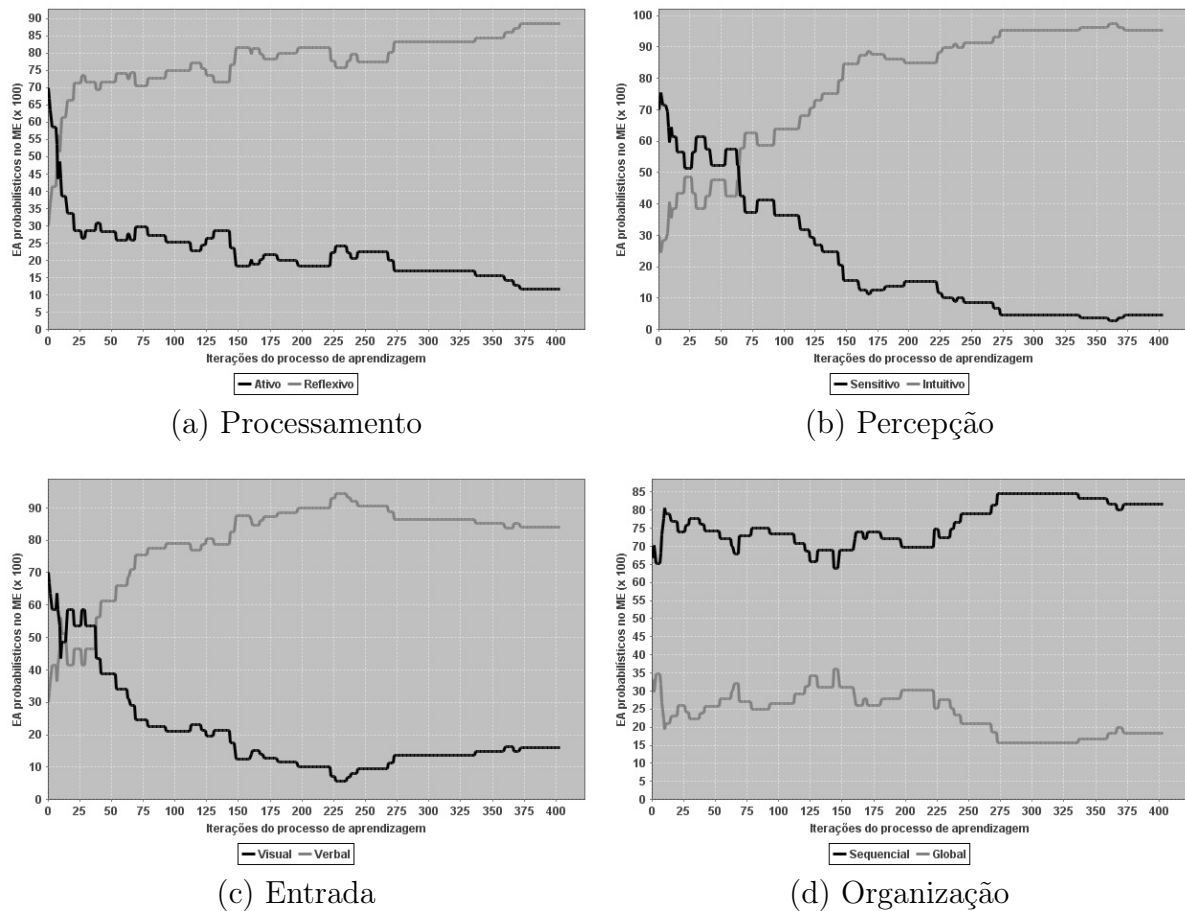


Figura 5.34: Atualização do ME durante Experimento 12

são Processamento foi eliminada, permanecendo estabilizada ao longo de todo o processo. Nas demais dimensões, apesar da necessidade de um número maior de iterações, as inconsistências foram eliminadas com eficácia.

Como resultado, é possível observar que apesar de haverem 3 inconsistências no ME, o aumento de iterações no processo de aprendizagem foi mínimo, devido a eliminação de tais inconsistências no início do processo. Esta é uma característica fundamental às abordagens para modelagem do estudante em seus diversos aspectos, e deve ser sempre avaliada com cuidado antes de sua utilização.

A Tabela 5.13 apresenta o número de iterações deste experimento, a quantidade de problemas de aprendizagem ocorridos e os EA_p armazenados no ME ao final do processo de aprendizagem. Como pode ser observado, a inconsistência inicialmente presente no ME foi eficientemente eliminada no início do processo de aprendizagem.

Tabela 5.13: Resultados do Experimento 12

Iterações	Prob. de Aprendizagem	EA_p			
403	43	(0,12; 0,88)	(0,05; 0,95)	(0,16; 0,84)	(0,81; 0,19)

A Figura 5.35 apresenta o valor da performance PFM do estudante em intervalos de 5 seções de aprendizagem, obtidas neste experimento. O intuito é observar a variação na obtenção de $PFM \geq m$ e $PFM < m$, entre este e os demais experimentos. Nota-se que à medida em que LS_p inconsistentes persistem no ME, existe uma tendência maior em se obter $PFM < m$.

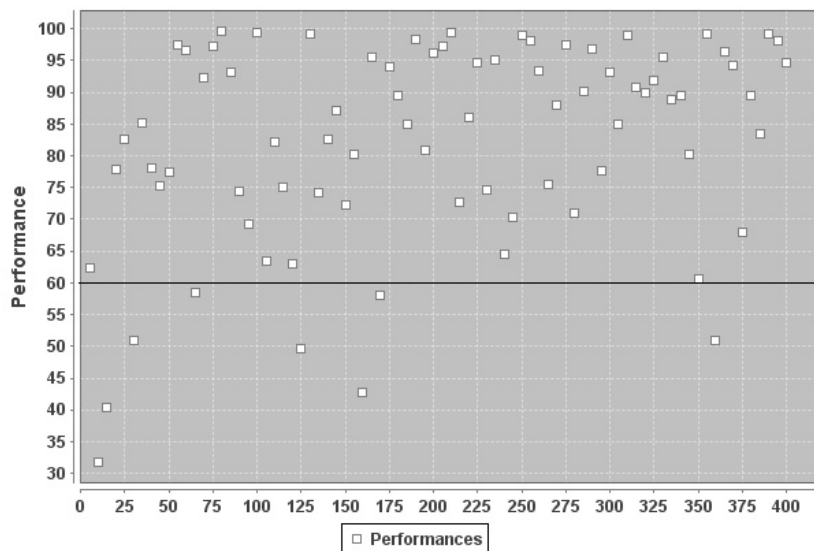


Figura 5.35: Performances do estudante no Experimento 12

A Figura 5.36 apresenta a performance média obtida pelo estudante (Figura 5.36a) e a média de problemas de aprendizagem ocorridos (Figura 5.36b) neste experimento.

Devido à existência de 3 inconsistências no ME, é possível notar aumento ainda maior na performance média do estudante quando comparado aos demais experimentos, e queda acentuada na média de problemas de aprendizagem, à medida que as inconsistências existentes no ME são eliminadas.

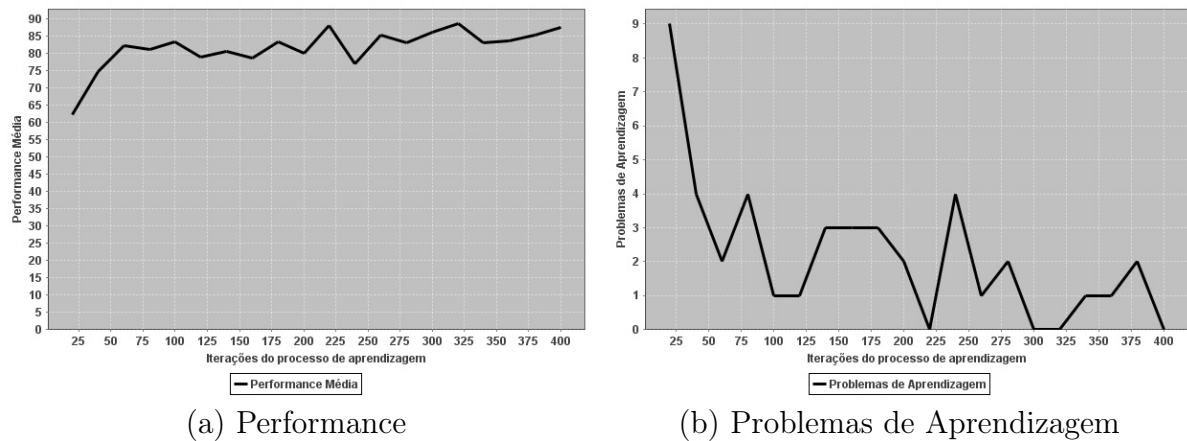


Figura 5.36: Médias de performances e problemas de aprendizagem no Experimento 12

5.3.13 Experimento 13

Neste experimento, considera-se um estudante com as seguintes preferências:

$$EA_r = \{Ativo(Forte), Intuitivo(Forte), Verbal(Moderada), Global(Leve)\}$$

Considerando-se este perfil de estudante, o ME apresentado na Tabela 5.1 é inicialmente inconsistente nas dimensões Percepção, Entrada e Organização.

Observando-se a Figura 5.37, nota-se que as inconsistências nas dimensões Percepção e Entrada foram rapidamente eliminadas. A atualização dos EA_p na dimensão Organização, foi inicialmente equivocada, em que a inconsistência foi reforçada no início. Em seguida, a os EA_p nesta dimensão foram devidamente ajustados. Mais uma vez, atribui-se este comportamento ao não-determinismo inerente ao processo de detecção de EA baseado em AR considerando uma política mista de exploração e exploração (política ϵ -greedy), que considera a escolha intencional (com probabilidade ϵ) de uma CEA que pode não ser considerada a melhor no estado atual do ME, visando maior eficiência na constante aquisição de conhecimento, conforme mencionado anteriormente.

A Tabela 5.14 apresenta o número de iterações deste experimento, a quantidade de problemas de aprendizagem ocorridos e os EA_p armazenados no ME ao final do processo de aprendizagem. Como pode ser observado, a inconsistência inicialmente presente no ME foi eficientemente eliminada no início do processo de aprendizagem.

A Figura 5.38 apresenta o valor da performance PFM do estudante em intervalos

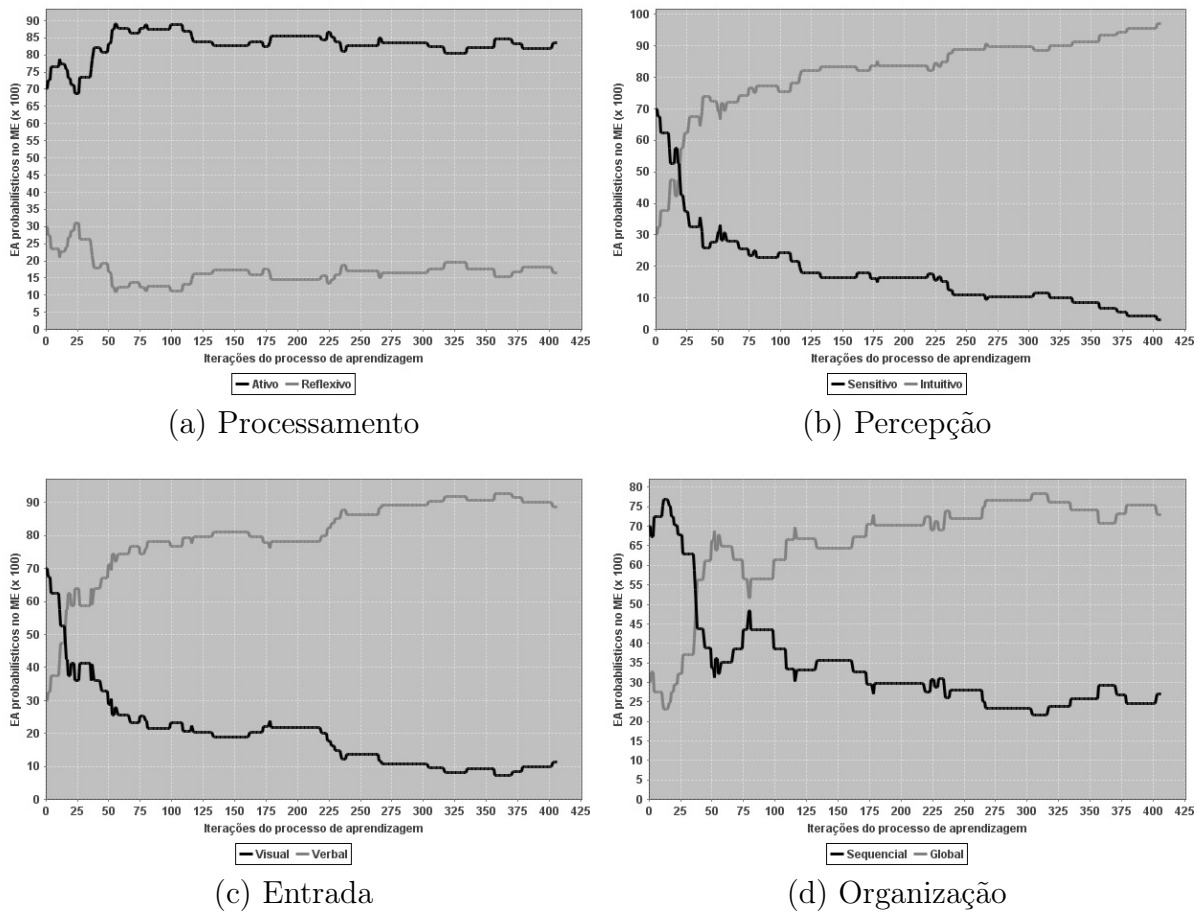


Figura 5.37: Atualização do ME durante Experimento 13

Tabela 5.14: Resultados do Experimento 13

Iterações	Prob. de Aprendizagem	EA_p			
406	46	(0,83; 0,17)	(0,04; 0,96)	(0,12; 0,88)	(0,26; 0,74)

de 5 seções de aprendizagem, obtidas neste experimento. O intuito é observar a variação na obtenção de $PFM \geq m$ e $PFM < m$, entre este e os demais experimentos. Nota-se que à medida em que LS_p inconsistentes persistem no ME, existe uma tendência maior em se obter $PFM < m$.

A Figura 5.39 apresenta a performance média obtida pelo estudante (Figura 5.39a) e a média de problemas de aprendizagem ocorridos (Figura 5.39b) neste experimento.

Um número maior de iterações foram gastos, devido à ocorrência de 46 problemas

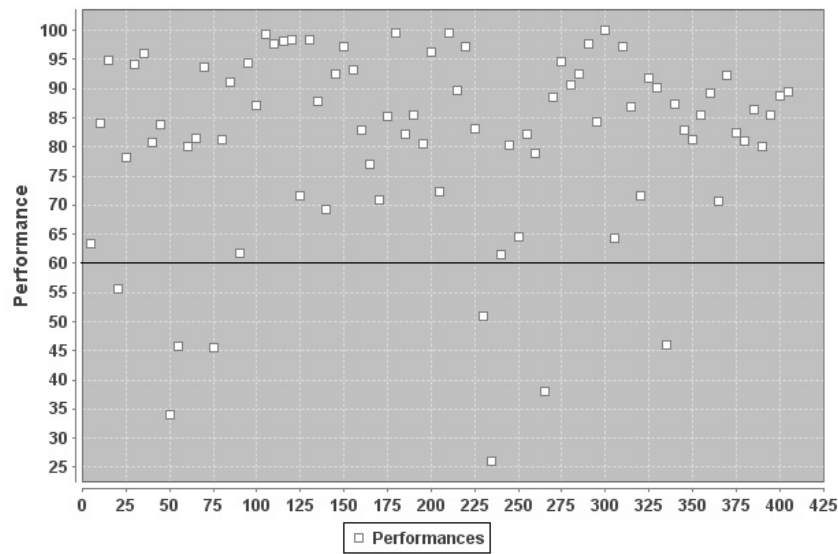
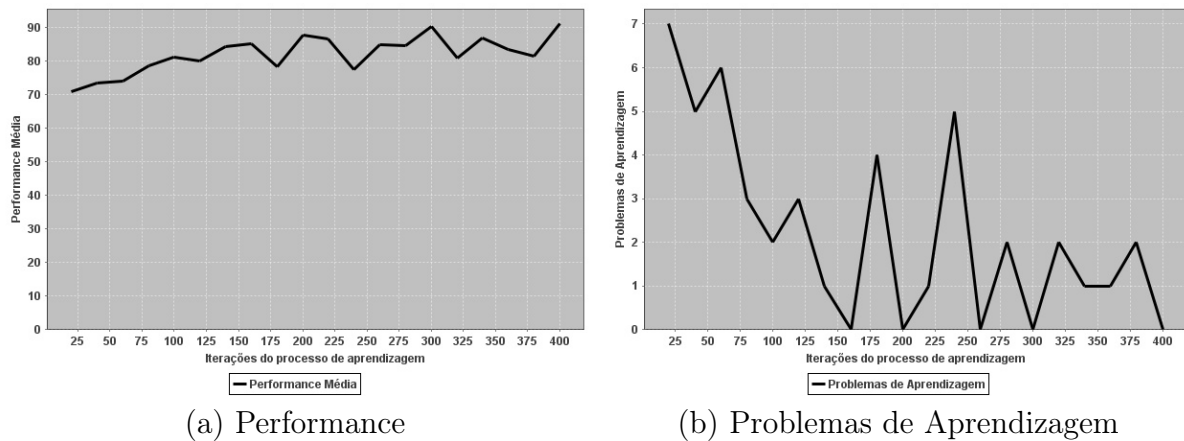


Figura 5.38: Performances do estudante no Experimento 13



(a) Performance

(b) Problemas de Aprendizagem

Figura 5.39: Médias de performances e problemas de aprendizagem no Experimento 13

de aprendizagem. Não obstante, é possível notar aumento na performance média do estudante, e queda acentuada na média de problemas de aprendizagem, à medida que as inconsistências existentes no ME são eliminadas.

5.3.14 Experimento 14

Neste experimento, considera-se um estudante com as seguintes preferências:

$$EA_r = \{Reflexivo(Forte), Intuitivo(Forte), Visual(Moderada), Global(Leve)\}$$

Considerando-se este perfil de estudante, o ME apresentado na Tabela 5.1 é inici-

almente inconsistente nas dimensões Processamento, Percepção e Organização, em que duas preferências fortes e uma leve não estão sendo satisfeitas.

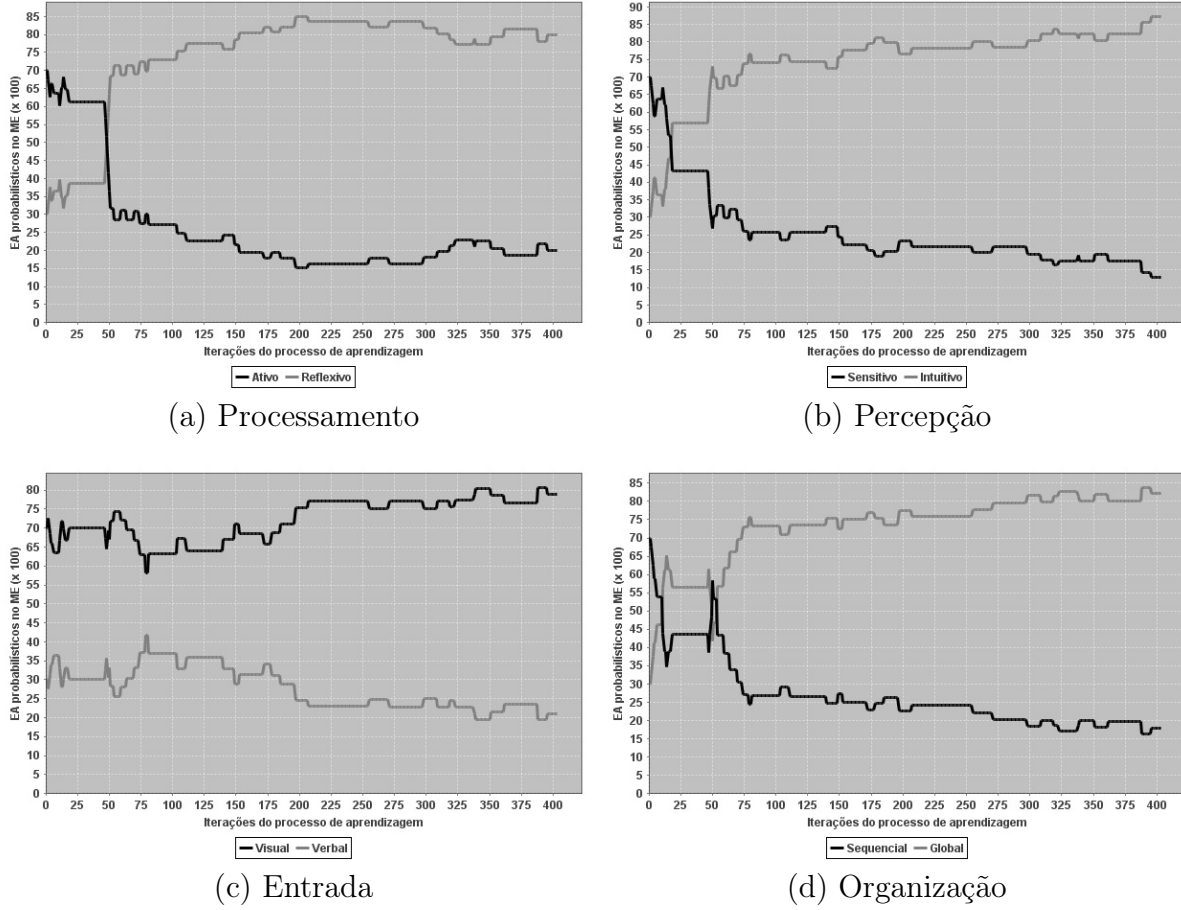


Figura 5.40: Atualização do ME durante Experimento 14

Como pode ser observado na Figura 5.40, as inconsistências inicialmente presentes no ME foram eficientemente eliminadas no início do processo de aprendizagem.

A Tabela 5.15 apresenta o número de iterações deste experimento, a quantidade de problemas de aprendizagem ocorridos e os EA_p armazenados no ME ao final do processo de aprendizagem. Apesar de duas preferências fortes estarem inicialmente inconsistentes, a quantidade de problemas de aprendizagem foi menor em relação ao experimento anterior.

A Figura 5.41 apresenta o valor da performance PFM do estudante em intervalos de 5 seções de aprendizagem, obtidas neste experimento. O intuito é observar a variação na obtenção de $PFM \geq m$ e $PFM < m$, entre este e os demais experimentos. Nota-se que à medida em que LS_p inconsistentes persistem no ME, existe uma tendência maior

Tabela 5.15: Resultados do Experimento 14

Iterações	Prob. de Aprendizagem	EA_p			
403	43	(0,20; 0,80)	(0,12; 0,88)	(0,78; 0,22)	(0,18; 0,82)

em se obter $PFM < m$.

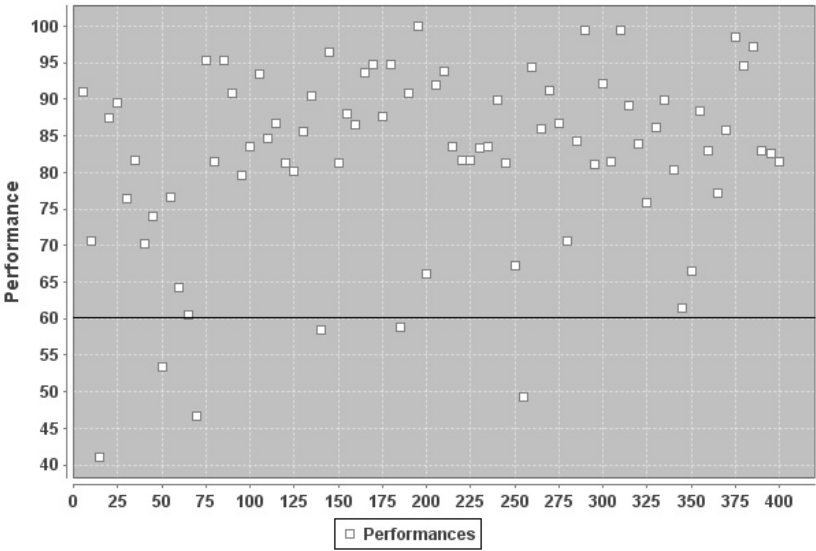
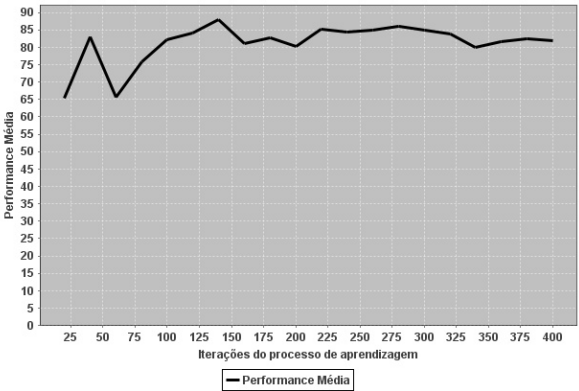
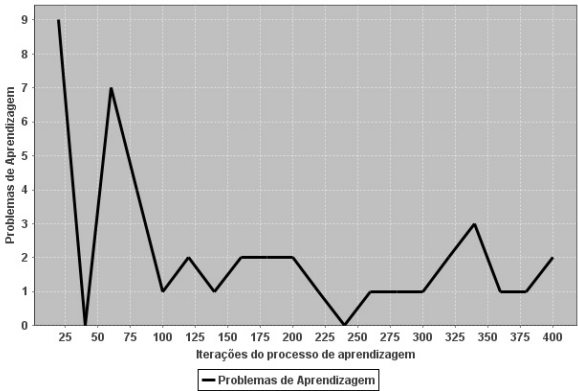


Figura 5.41: Performances do estudante no Experimento 14

A Figura 5.42 apresenta a performance média obtida pelo estudante (Figura 5.42a) e a média de problemas de aprendizagem ocorridos (Figura 5.42b) neste experimento.



(a) Performance



(b) Problemas de Aprendizagem

Figura 5.42: Médias de performances e problemas de aprendizagem no Experimento 14

Conforme esperado, é possível notar aumento na performance média do estudante, e

queda na média de problemas de aprendizagem, à medida que as inconsistências existentes no ME são eliminadas.

5.3.15 Experimento 15

Neste experimento, considera-se um estudante com as seguintes preferências:

$$EA_r = \{Reflexivo(Forte), Sensitivo(Forte), Verbal(Moderada), Global(Leve)\}$$

Considerando-se este perfil de estudante, o ME apresentado na Tabela 5.1 é inicialmente inconsistente nas dimensões Processamento, Entrada e Organização.

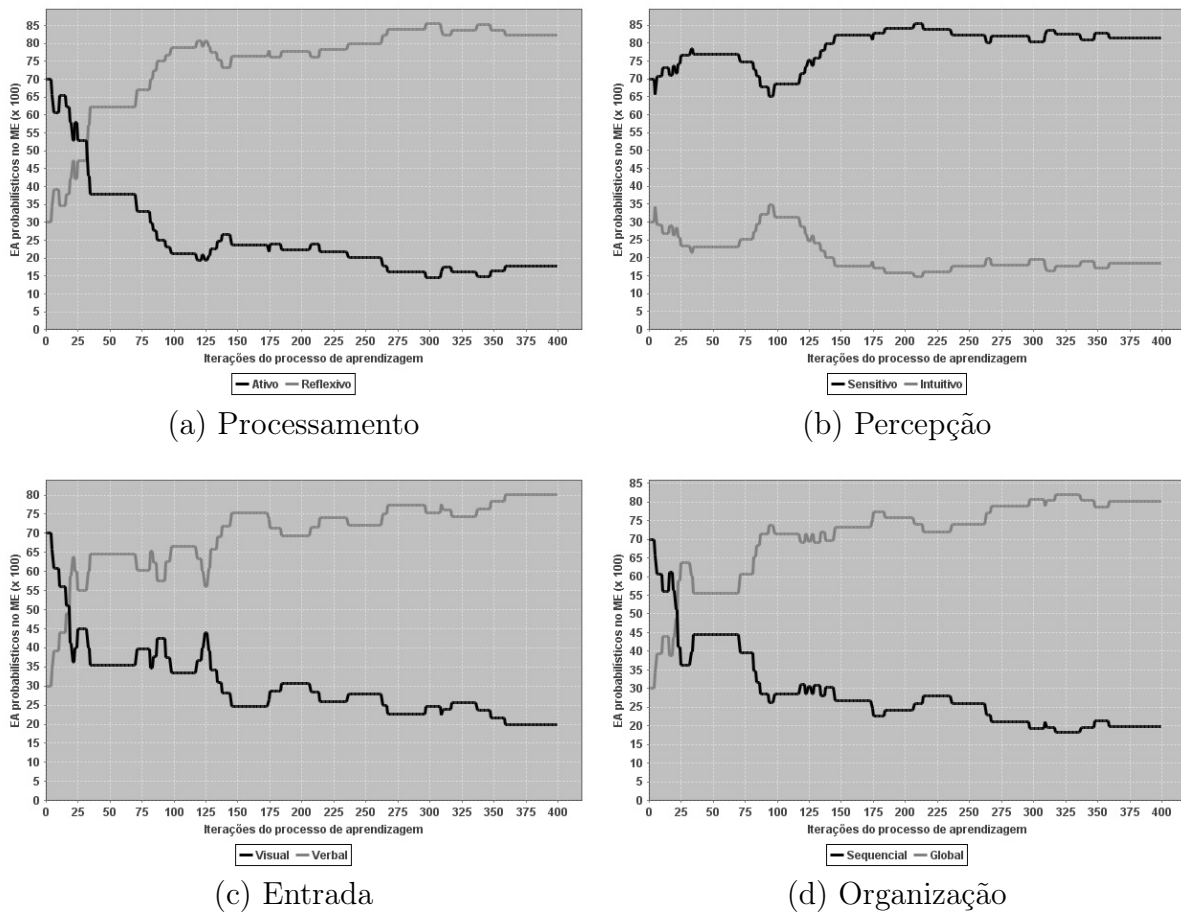


Figura 5.43: Atualização do ME durante Experimento 15

Como pode ser observado na Figura 5.43, as inconsistências inicialmente presentes no ME foram eficientemente eliminadas no início do processo de aprendizagem.

A Tabela 5.16 apresenta o número de iterações deste experimento, a quantidade de

problemas de aprendizagem ocorridos e os EA_p armazenados no ME ao final do processo de aprendizagem. Nota-se uma quantidade um pouco menor de problemas de aprendizagem em relação ao experimento anterior, podendo-se atribuir isto ao fato de apenas 1 preferência forte ser inicialmente contrariada neste experimento.

Tabela 5.16: Resultados do Experimento 15

Iterações	Prob. de Aprendizagem	EA_p			
399	39	(0,17; 0,83)	(0,81; 0,19)	(0,19; 0,81)	(0,20; 0,80)

A Figura 5.44 apresenta o valor da performance PFM do estudante em intervalos de 5 seções de aprendizagem, obtidas neste experimento. O intuito é observar a variação na obtenção de $PFM \geq m$ e $PFM < m$, entre este e os demais experimentos. Nota-se que à medida em que LS_p inconsistentes persistem no ME, existe uma tendência maior em se obter $PFM < m$.

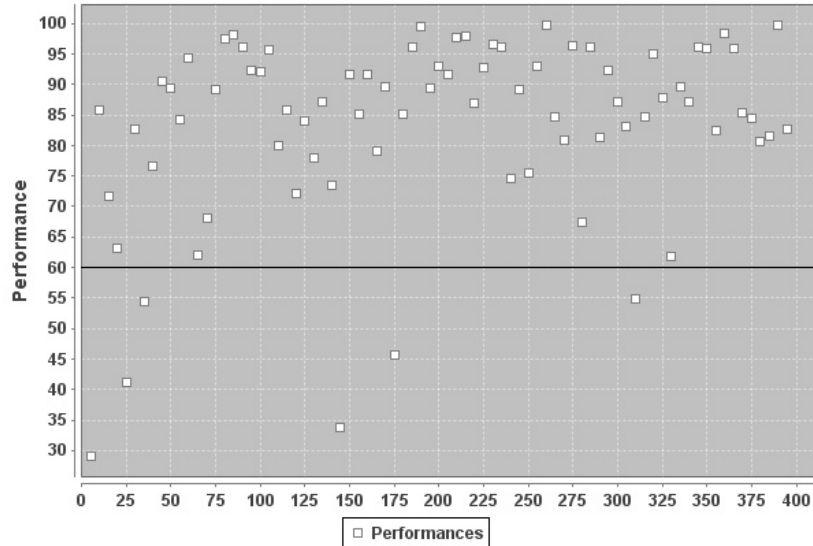


Figura 5.44: Performances do estudante no Experimento 15

A Figura 5.45 apresenta a performance média obtida pelo estudante (Figura 5.45a) e a média de problemas de aprendizagem ocorridos (Figura 5.45b) neste experimento, em que é possível observar melhoria da performance e redução dos problemas de aprendizagem.

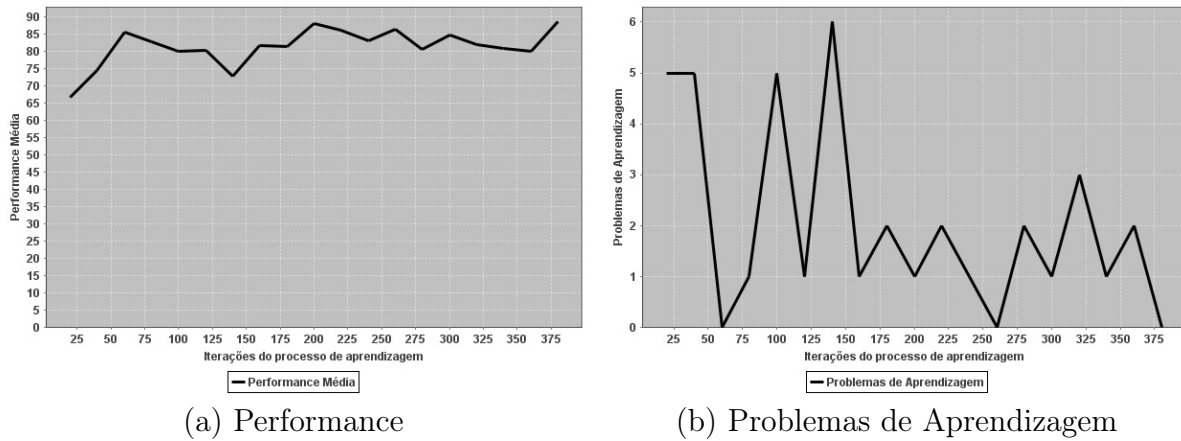


Figura 5.45: Médias de performances e problemas de aprendizagem no Experimento 15

É importante notar na Figura 5.45b elevações bruscas na média de problemas de aprendizagem, ocorridas mesmo após o ME estar totalmente consistente com os EA_r do estudante, em que é possível notar a elevação do valor da média de 1 para 6. Assim como em um processo de aprendizagem real, outros fatores podem exercer influência na performance do estudante. Alguns destes fatores são delineados por Brusilovsky et al. (1998); Zakaria e Brailsford (2002); Wu et al. (2001); Graf e Kinshuk (2009a); Clifford (2004); De Bra e Calvi (1998); Brusilovsky et al. (1996a); Hook et al. (1997); Chen e Macredie (2002). Além disto, diante da política de AR implementada, pode ocorrer a escolha intencional de uma CEA que pode não ser considerada a melhor no estado atual, considerando que EA podem variar, devido aos seus aspectos não-estacionário e não-determinístico, o que leva à necessidade de se considerar ações que não sejam consideradas as melhores no estado atual, visando a aquisição de conhecimento pela exploração, sendo este um ponto fundamental desta abordagem.

5.3.16 Experimento 16

Neste experimento, considera-se um estudante com as seguintes preferências:

$$EA_r = \{Reflexivo(Forte), Intuitivo(Forte), Verbal(Moderada), Global(Leve)\}$$

Considerando-se este perfil de estudante, o ME apresentado na Tabela 5.1 é inicialmente inconsistente em todas as dimensões. Como pode ser observado na Figura 5.46,

as inconsistências inicialmente presentes no ME foram eficientemente eliminadas no início do processo de aprendizagem.

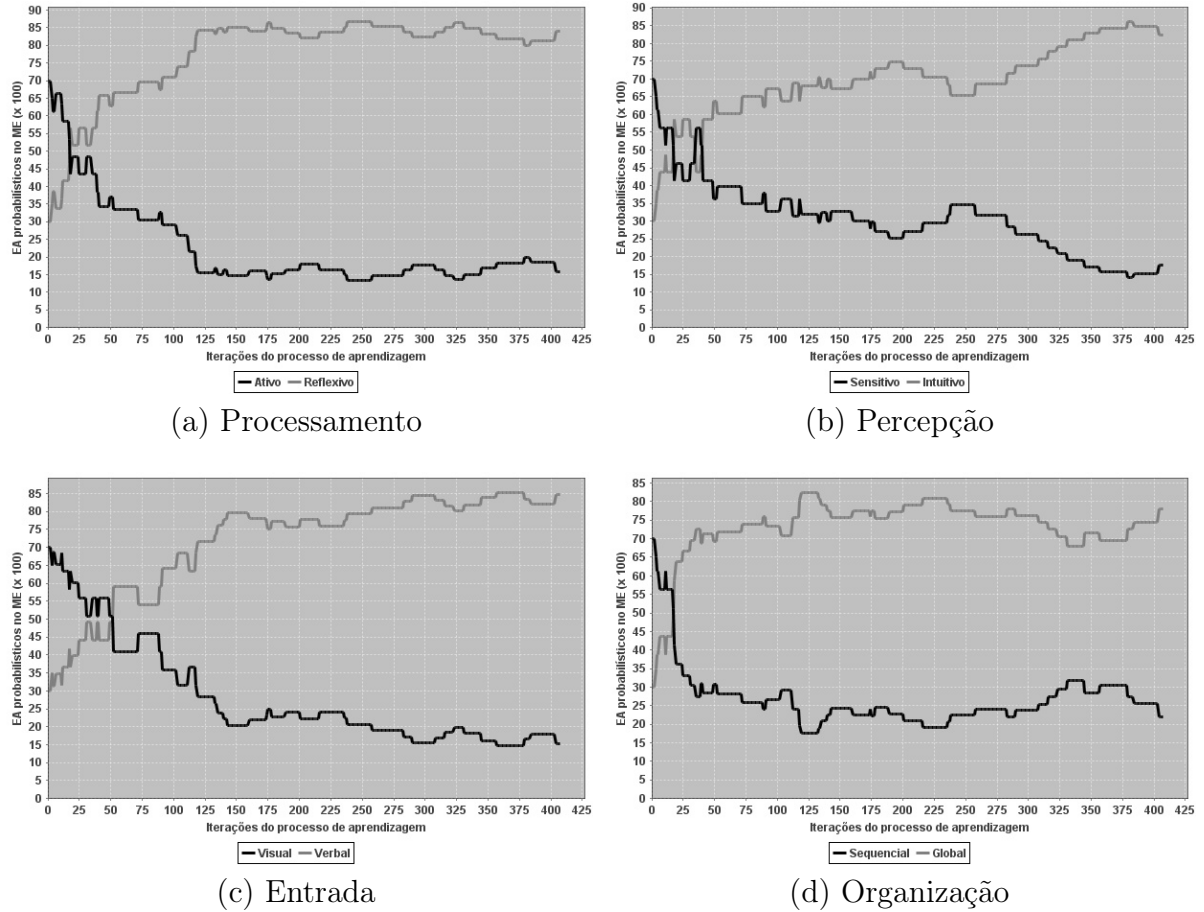


Figura 5.46: Atualização do ME durante Experimento 16

A Tabela 5.17 apresenta o número de iterações deste experimento, a quantidade de problemas de aprendizagem ocorridos e os EA_p armazenados no ME ao final do processo de aprendizagem. Apesar das quatro dimensões de EA estarem inicialmente inconsistentes no ME, o aumento na quantidade de problemas de aprendizagem foi muito pequeno, apenas 1 a mais do que no experimento 13, por exemplo. Atribui-se isto ao fato da eficiência e eficácia com que foram corrigidas as inconsistências no ME, conforme observa-se na Figura 5.46.

A Figura 5.47 apresenta o valor da performance PFM do estudante em intervalos de 5 seções de aprendizagem, obtidas neste experimento. O intuito é observar a variação na obtenção de $PFM \geq m$ e $PFM < m$, entre este e os demais experimentos. Nota-se

Tabela 5.17: Resultados do Experimento 16

Iterações	Prob. de Aprendizagem	EA_p			
407	47	(0,15; 0,85)	(0,17; 0,83)	(0,16; 0,84)	(0,22; 0,78)

que à medida em que LS_p inconsistentes persistem no ME, existe uma tendência maior em se obter $PFM < m$.

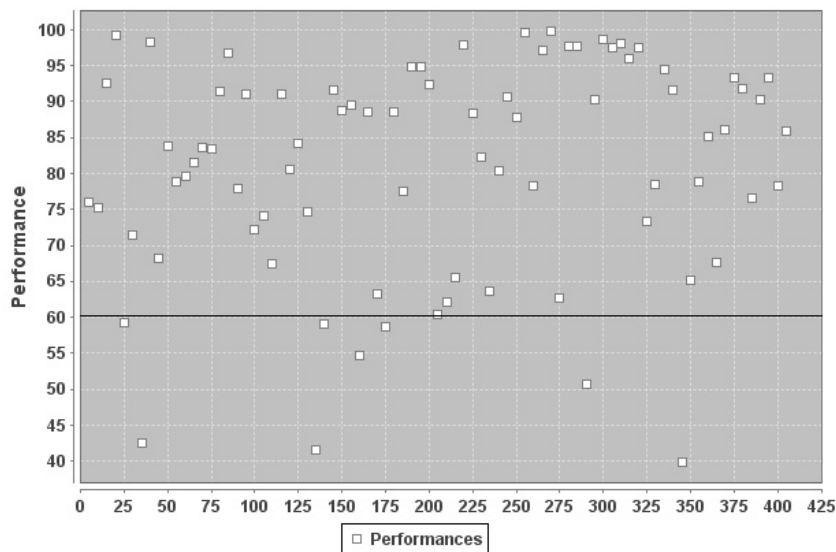
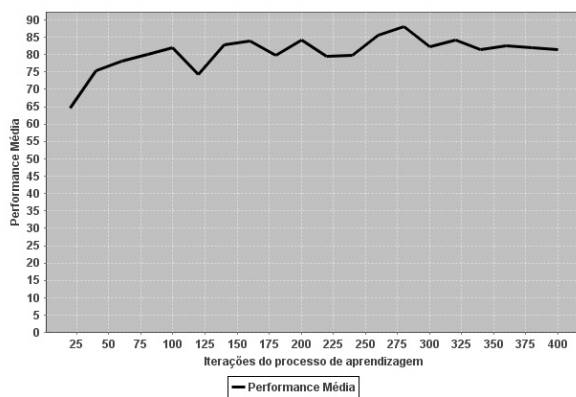
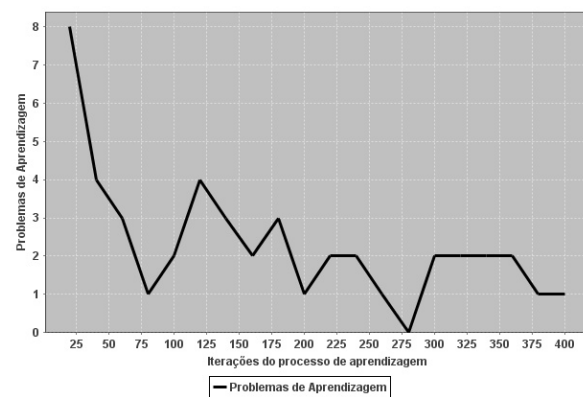


Figura 5.47: Performances do estudante no Experimento 16

A Figura 5.48 apresenta a performance média obtida pelo estudante (Figura 5.48a) e a média de problemas de aprendizagem ocorridos (Figura 5.48b) neste experimento.



(a) Performance



(b) Problemas de Aprendizagem

Figura 5.48: Médias de performances e problemas de aprendizagem no Experimento 16

Em todos os experimentos, os EA_p no ME foram corrigidos eficientemente. Em uma última análise, apresenta-se os resultados obtidos ao se executar este experimento considerando-se a taxa de aprendizagem $\alpha = 0$. Ou seja, não haverá aprendizagem, e consequentemente o ME não será modificado. A Figura 5.49 mostra este resultado.

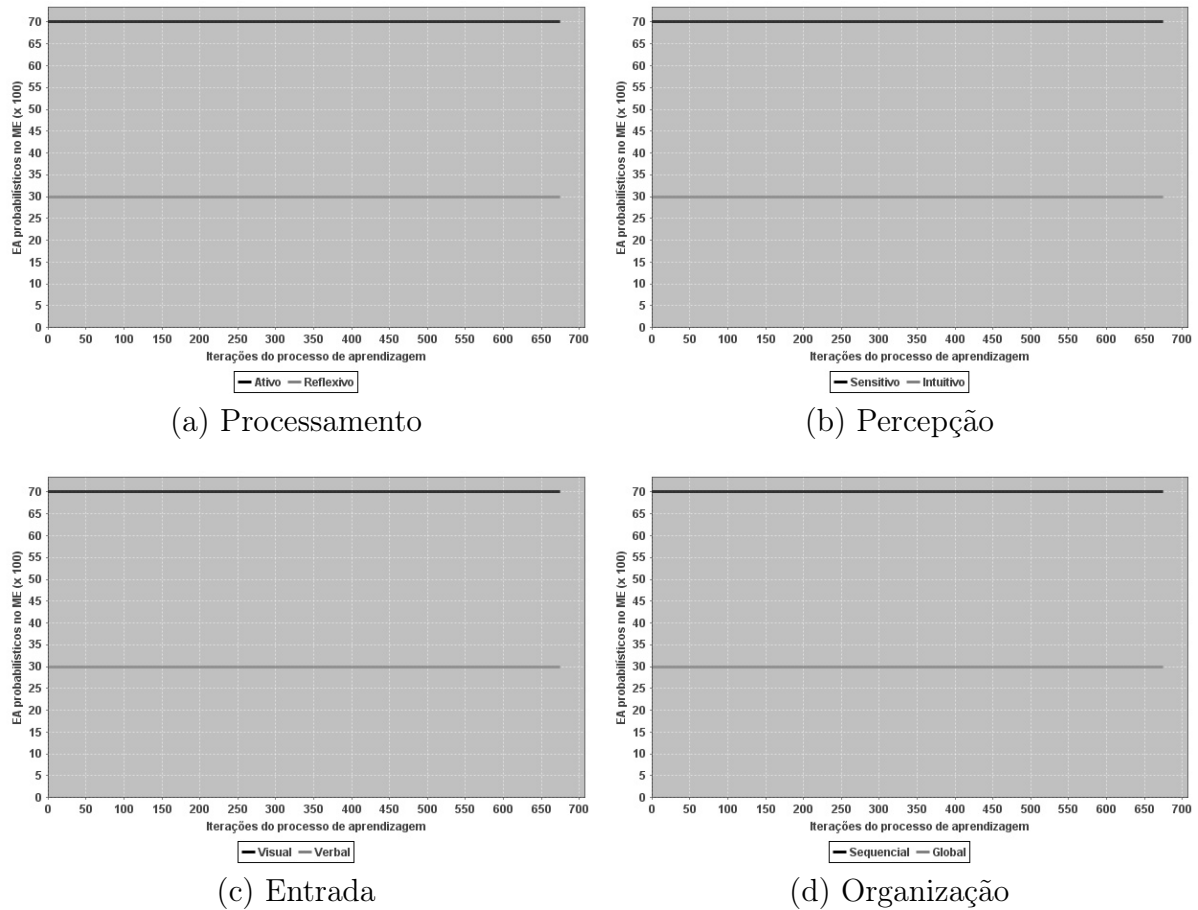


Figura 5.49: Atualização do ME durante Experimento 16 com $\alpha = 0$

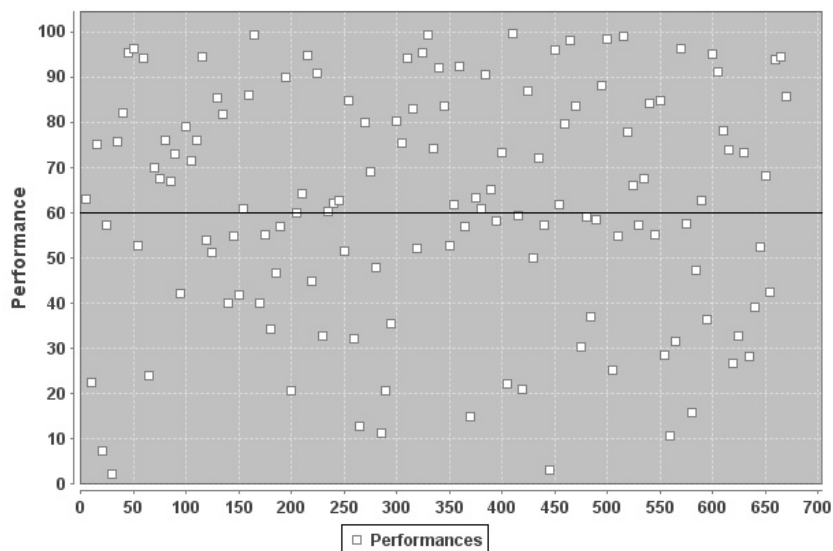
A Tabela 5.18 apresenta o número de iterações deste experimento, a quantidade de problemas de aprendizagem ocorridos e os EA_p armazenados no ME ao final do processo de aprendizagem. Conforme esperado, um crescimento considerável na quantidade de problemas de aprendizagem foi observado, em que registrou-se 314 problemas de aprendizagem.

A Figura 5.50 apresenta o valor da performance PFM do estudante em intervalos de 5 seções de aprendizagem, obtidas neste experimento. É possível observar que apesar das inconsistências não serem eliminadas do ME, perdurando durante todo o

Tabela 5.18: Resultados do Experimento 16 com $\alpha = 0$

Iterações	Prob. de Aprendizagem	EA_p			
674	314	(0,70; 0,30)	(0,70; 0,30)	(0,70; 0,30)	(0,70; 0,30)

processo de aprendizagem, performances satisfatórias ($PFM \geq 60$), inclusive máximas ($PFM = 100$), continuaram a ocorrer, já que deixar de fornecer suporte a EA não determina o fracasso do estudante, mas dificulta a aprendizagem. Percebe-se claramente uma quantidade muito maior de performances insatisfatórias ($PFM < 60$) neste experimento em relação aos experimentos anteriores.

Figura 5.50: Performances do estudante no Experimento 16 com $\alpha = 0$

A Figura 5.51 apresenta a performance média obtida pelo estudante (Figura 5.51a) e a média de problemas de aprendizagem ocorridos (Figura 5.51b).

Observando-se os gráficos, nota-se que a eficiência do processo de aprendizagem foi reduzida drasticamente, já que, em relação ao resultado obtido com $\alpha = 0,5$, a performance média ficou muito abaixo, com pico em torno de 70, e a média de problemas de aprendizagem aumentou muito, mantendo-se alta ao longo de todo o processo, chegando a 14.

Acredita-se que os resultados obtidos e apresentados neste capítulo validam a abor-

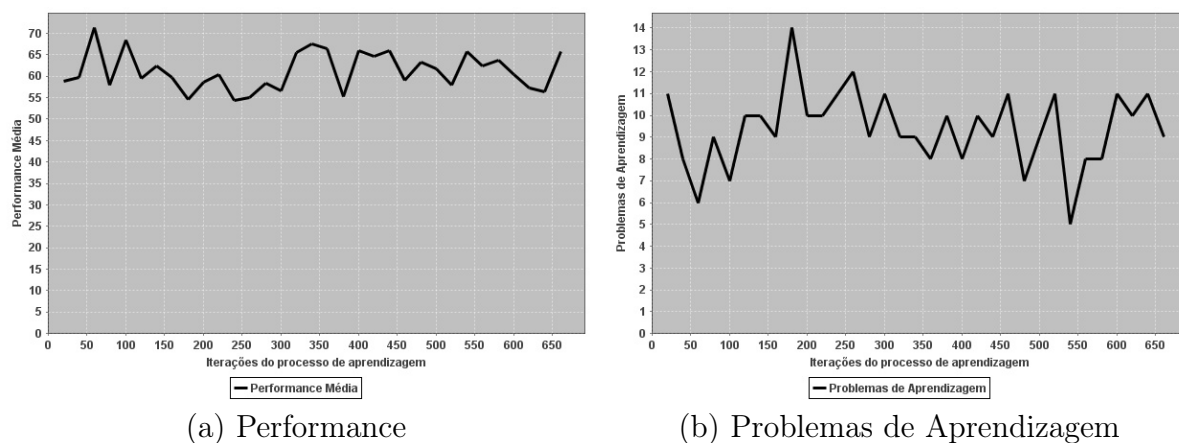


Figura 5.51: Médias de performances e problemas de aprendizagem no Experimento 16 com $\alpha = 0$

dagem proposta neste trabalho, sendo esta passível de ser implementada e experimentada em processos de aprendizagem reais. Sem o recurso de simulação de estudantes estes resultados ainda estariam longe de serem obtidos, devido ao longo tempo e ao alto custo necessário à realização de testes com estudantes reais.

A análise dos resultados permitem verificar que quando os EA_r do estudante são satisfeitos, sua chance de sucesso aumenta, conforme pontuado em diversos trabalhos³.

Isto permite afirmar que o ambiente de simulação reproduz a realidade, o que é indispensável para validação dos resultados gerados pela abordagem proposta. Desta forma, os resultados obtidos ilustram exatamente o que deve ocorrer em um processo de aprendizagem real, considerando-se que as teorias e estudos sobre estilos de aprendizagem analisados neste trabalho estejam corretos, desde a proposta original de Felder e Silverman (1988) até investigações recentes sobre EA, tal como aquelas apresentadas por Haider et al. (2010), em que se baseia o presente trabalho.

No Apêndice A, são apresentados experimentos considerando-se um ME inicial em que a $DEA = 0$ em todas as dimensões, ou seja, nenhuma informação inicial foi obtida a respeito das preferências do estudante. Ao se comparar os resultados obtidos nos experi-

³Graf e Kinshuk (2009a); Graf e Liu (2008); Coffield et al. (2009); Cristea e Stash (2006); Alfonseca et al. (2006); Franzoni e Assar (2009); Stash et al. (2004); Graf e Lin (2007); Velazquez e Assar (2007); Franzoni et al. (2008); Carver Jr et al. (2002); Graf e Kinshuk (2007); Bajraktarevic et al. (2003); Sangineto et al. (2008); Terry et al. (1995); Friedel e Rudd (2006); Cristea (2005); Vasilyeva et al. (2006)

mentos apresentados neste capítulo com aqueles apresentados no Apêndice A, percebe-se que as inconsistências iniciais no ME, obtidas através de questionários psicométricos como o ILSQ, podem trazer prejuízos maiores do que a não aplicação deste tipo de instrumento, sendo, então, necessário alto nível de seriedade, comprometimento e veracidade por parte dos estudantes no preenchimento destes questionários.

Ao se comparar os resultados, percebe-se que sendo o ME inicialmente inconsistente, há um aumento na quantidade de iterações do processo de aprendizagem, devido ao aumento da dificuldade do processo de aprendizagem. Através da análise gráfica é possível notar que é mais rápido inferir corretamente um EA quando se tem $DEA = 0$ do que corrigir uma inconsistência pré-existente no ME.

Pode-se concluir então que é melhor utilizar questionários psicométricos como um recurso opcional do que obrigar o estudante a respondê-lo, que pode vir a fazê-lo de forma inconsistente, considerando-se que é necessário certo esforço nesta tarefa e que ela demanda tempo e concentração do estudante. De acordo com (García et al., 2007), um problema com testes psicométricos baseados em *web* é que são muito longos, ou os estudantes não estão cientes das consequências ou usos futuros de suas repostas, tendendo a escolher repostas arbitrariamente ao invés de pensar cuidadosamente sobre elas. Então, os resultados obtidos podem ser inconsistentes em relação aos seus reais aspectos cognitivos e preferências de EA.

Porém, quando um questionário psicométrico é aplicado e detecta corretamente uma ou mais preferências, estas são conservadas ao longo do processo de aprendizagem, e apenas aquelas preferências inconsistentes são efetivamente corrigidas. Isto é um fato interessante de se observar, já que todas as preferências, em todas as dimensões, mesmo aquelas que já estão corretas, são atualizadas sempre que se identifica um problema de aprendizagem, já que o sistema não sabe quais são as preferências corretas e quais são as incorretas, por não conhecer os EA_r do estudante. Porém, apenas aquelas que estão incorretas são efetivamente alteradas, convergindo em direção aos EA_r .

Acredita-se que os resultados dos experimentos apresentados mostram a eficiência e

eficácia da abordagem proposta, e permitem considerá-la promissora na implementação de novos SAIE e na agregação de adaptatividade a LMS já existentes. Conclui-se, então, após a análise apresentada, que mesmo desconhecendo as preferências verdadeiras do estudante e o peso de cada uma delas, é possível inferi-las eficientemente através de um modelo estocástico baseado em CEA, corrigindo-se automaticamente inconsistências entre seu desempenho e suas preferências, que são dinâmicas e podem variar ao longo do tempo e em diferentes circunstâncias.

Desta forma, considera-se aqui a validade dos resultados obtidos, mesmo que inicialmente em um ambiente de simulação, já que traduzem os resultados obtidos baseados em um modelo probabilístico desenvolvido com base em estudos que analisaram a variação de desempenho de estudantes reais em cursos que não atendem seus estilos de aprendizagem, conforme apresentado por Haider et al. (2010); Graf et al. (2008); Kinshuk et al. (2009).

Fica evidente a necessidade de se contar com uma ferramenta automatizada para corrigir informações inconsistentes sobre EA, caso existam, pois o prejuízo ao processo de ensino-aprendizagem é notório, ficando evidente ao se observar o aumento de problemas de aprendizagem que podem ocorrer devido a tais inconsistências. Desta forma, pôde-se observar uma elevação real da quantidade de iterações necessárias ao processo de aprendizagem devido ao aumento na dificuldade de aprendizagem à medida que inconsistências relacionadas a EA ocorrem no ME.

Finalmente, não se afirma aqui que um estudante real necessitará do mesmo número de iterações necessários ao estudante simulado para conclusão de um curso, mas que as proporções relativas à diferença no número de iterações entre os diversos experimentos realizados são compatíveis com a realidade. O próximo capítulo expõe algumas observações, tece conclusões finais sobre o trabalho e aponta alguns trabalhos futuros.

Capítulo 6

Conclusões e Trabalhos Futuros

SAIE são uma nova abordagem em educação. Um fator indispensável neste tipo de sistema é a identificação precisa de EAs dos estudantes, de modo a fornecer conteúdo o mais apropriado possível às necessidades individuais. Um desafio na construção de sistemas capazes de fornecer adaptatividade baseada em EA é a construção de MEs fieis à realidade.

Existem diversas propostas para modelagem de características do estudante em SAIE. Em (Martins et al., 2008), uma visão geral destas propostas é apresentada, e pontos específicos de cada uma são discutidos. Também, em (García et al., 2007), o problema da modelagem do estudante é discutido em suas várias vertentes, e categoriza uma diversidade de propostas de acordo com diferentes fatores, por exemplo, o conteúdo do ME, o tipo de estudante a ser modelado, como o modelo é atualizado, com que finalidade o modelo é usado, dentre outros. Em relação à modelagem do estudante, um aspecto inovador é a modelagem probabilística de EA do estudante. Uma vantagem desta abordagem é que permite representar e tratar adequadamente os aspectos de incerteza discutidos.

Neste contexto, este trabalho apresenta uma abordagem probabilística para modelagem automática e dinâmica de EA baseada em CEA e AR, em que uma CEA corresponde a uma categoria pedagógica bem definida de estudantes, e indica ações instrucionais a serem executadas pelo agente pedagógico, que gradativamente aprende sobre qual ação

instrucional é mais apropriada a um estudante. Em relação à modelagem do estudante, um aspecto inovador é a modelagem probabilística de EA do estudante. Uma vantagem desta abordagem é que permite representar e tratar adequadamente os aspectos de incerteza discutidos, o que possibilitou a obtenção de resultados promissores nos experimentos realizados.

Um outro aspecto importante deste trabalho em relação às abordagens analisadas é a utilização de Aprendizagem por Reforço para modelagem automática e dinâmica do estudante considerando EA, o que elimina a necessidade de aprendizagem supervisionada. A abordagem proposta neste trabalho tem o foco principal no fornecimento de uma experiência de aprendizagem que atenda aos EA dos estudantes no cumprimento de objetivos de aprendizagem bem definidos.

Mas, também vai além, e incorpora pontos importantes introduzidos por teóricos da educação, tais como Messick (1976) e Felder e Spurlin (2005), que apontam que estudantes devem também aprender como lidar com cursos e materiais instrucionais que não atendam aos seus estilos de aprendizagem preferidos, devendo os estudantes ser também treinados a utilizar e desenvolver outras habilidades, já que nem sempre cursos adaptados às suas preferências estarão disponíveis. Desta forma, possibilitar o desenvolvimento da habilidade em lidar com diferentes estilos instrucionais é de suma importância em SAIE, sendo tal possibilidade inerente à abordagem automática e dinâmica proposta neste trabalho, em decorrência de sua forte natureza estocástica.

A eficiência e eficácia obtidas por esta abordagem, e comprovadas através de experimentos apresentados neste trabalho, se devem em grande parte ao fato desta natureza estocástica, que se caracteriza principalmente pela representação da variabilidade e das incertezas inerentes ao processo de aprendizagem de cada estudante e das possíveis inconsistências presentes no ME e nas informações obtidas a seu respeito. Desta forma, utilizando esta abordagem, um SAIE é, portanto, capaz de constantemente rever as informações armazenadas no ME, e assim fornecer suporte, material de aprendizagem e atividades que o estudante precisa em determinado momento.

Considerando este aspecto, este trabalho apresenta resultados promissores, com alto nível de precisão e baixo custo computacional, principalmente se comparada a outras abordagens analisadas que utilizam sistemas determinísticos, baseados em regras complexas e de difícil concepção, ou em técnicas de aprendizagem supervisionada, em que dificuldades relacionadas à implementação, obtenção de conjuntos de treinamento e alto custo computacional são notórias. Tais abordagens geram problemas e dificuldades, conforme analisado no capítulo 2, em que se discute a inadequação de tais abordagens ao problema tratado neste trabalho.

Neste contexto, este trabalho aborda e trata questões importantes na modelagem de EA, ignorados pelas abordagens desenvolvidas até o momento, apresentando grande potencial na construção de SAIE que levem em consideração EA para fornecimento da adaptatividade. Modelar EA de estudantes é uma tarefa complexa, pois estes não atuam isoladamente no desempenho do estudante, estando acompanhado de uma série de outros fatores.

Além disto, EA podem sofrer variações ao longo do tempo ou em diferentes contextos (Messick, 1976) (Kelly e Tangney, 2005) (Castillo et al., 2005), ou seja, nota-se claramente que este processo é, por natureza, não-determinístico. Provavelmente, por esta razão, as cadeias de Markov se mostraram ferramentas tão aderentes e eficazes na construção de um modelo eficiente para tratamento adequado deste problema.

Observou-se que ao passo que os EA do estudante são efetivamente diagnosticados, o processo de adaptatividade torna-se mais efetivo, à medida que o agente pedagógico passa a oferecer conteúdo cada vez adaptado às preferências do estudante, impactando nitidamente na melhora de sua performance. Desta forma, pode-se concluir que a abordagem proposta neste trabalho tem grande potencial no apoio à construção de SAIE.

A experimentação desta abordagem se deu através de simulação de estudantes, facilitando muito a análise de variáveis fundamentais à verificação e validação da abordagem: consistência e eficiência. Pôde-se observar nitidamente o comportamento do modelo em diferentes contextos e situações adversas em todas as 16 categorias pedagógicas, de acordo

com o conjunto de CEAs.

Em todos os experimentos ministrados obteve-se resultados que demonstram que o objetivo proposto foi alcançado, e que nos inspiram a implementar e utilizar esta abordagem em processos de aprendizagem reais. Através desta análise, pôde-se perceber que o estudante, ao longo do processo de ensino-aprendizagem, interage probabilisticamente com conteúdos fornecidos segundo uma diversidade de CEAs, e como resultado de seu desempenho, é realizada a modelagem automática e dinâmica de seus EA, eliminando-se eficientemente as inconsistências no ME.

A validação do modelo proposto através de técnicas de simulação computacional foi fundamental, já que a implantação de projetos de *e-learning* requerem quantias consideráveis de recursos financeiros, humanos e de tempo (Graf et al., 2009b). Desta forma, é de fundamental importância que se possa avaliar a performance de um modelo antes de implantá-lo efetivamente em um LMS, devido à complexidade desta tarefa e da quantidade de recursos exigidos. Esta questão é ainda mais crítica quando se considera que a demanda por sistemas de *e-learning* é cada vez maior, e o número de estudantes que dependem destes sistemas cresce rapidamente (Graf et al., 2009b).

Além disto, sem o uso de simulação, seria impossível chegar a esta proposta num prazo razoável, devido à grande quantidade de tempo necessário para realização de testes e experimentos com os estudantes reais e processos de aprendizagem verdadeiros. Conforme alertam Gogvadze et al. (2011) e Shein e Chiou (2011), a realização de testes com os estudantes reais exige grandes quantidades de dados de longo prazo.

Desta forma, a utilização de simulação de estudantes permitiu testar, ajustar e melhorar esta abordagem desde o início de seu desenvolvimento, o que otimizou sua concepção. Inúmeros ajustes e melhorias estiveram relacionados, principalmente, à criação das regras de atualização do ME e no cálculo do reforço a ser aplicado por essas regras. Ambos são pontos cruciais deste trabalho. Portanto, sem o uso de simulação, provavelmente seria impossível chegar a este resultado num prazo razoável, devido à grande quantidade de tempo necessário para se realizar experimentos com estudantes reais.

É importante ressaltar que ao se testar a abordagem proposta em um processo de aprendizagem real, seria impossível conhecer com exatidão os EA_r do estudante em decorrência dos motivos apontados anteriormente sobre a utilização de questionários, como o ILSQ, e técnicas determinísticas para inferência de EA.

Então, seria impossível medir o nível de consistência do ME obtido durante o processo de aprendizagem, devido à impossibilidade de se fazer a comparação dos EA_r com os EA_p obtidos, fundamental à validação da proposta, impossibilitando-nos, então, medir duas variáveis muito importantes na validação da presente proposta: a eficiência em relação ao tempo despendido na detecção de EA (assim como na correção de inconsistências existentes no ME) e a eficácia em relação à consistência dos EA_p obtidos em relação aos EA_r do estudante.

A simulação computacional com base em modelos matemáticos está hoje presente em todas as ciências e a sua importância tende a aumentar. É um meio de confrontar teorias com experimentação, de antecipar resultados experimentais ou realizar experiências de outro modo inacessíveis ou de elevada dificuldade.

O próximo passo deste trabalho é realizar a integração da abordagem apresentada a um LMS existente, a exemplo do Moodle (Moodle, 2010), para que se possa realizar experimentos com estudantes reais em um AVA capaz de fornecer adaptatividade baseada em EA dos estudantes. Com intuito de facilitar a integração desta abordagem com AVA existentes, uma possibilidade é o seu fornecimento através de um modelo de SaaS (*software as a service*) - software como serviço. Desta forma, através de um *webservice* poder-se-ia fornecer o serviço de modelagem automática e dinâmica de EA para AVA existentes de forma mais simples e transparente, com alto desacoplamento entre as diferentes soluções, permitindo a modularização, reaproveitamento e integração de processos de sistemas heterogêneos.

Um trabalho já em andamento remete à recuperação automática de objetos de aprendizagem na *web* através de seus metadados, levando-se em consideração características específicas de EA. Para isto, o sistema deve fazer uma comparação das características e

preferências do estudante com as características pedagógicas de cada objeto. A reutilização em larga escala de repositórios de objetos de aprendizagem e a interoperabilidade em ambientes virtuais de aprendizagem tem sido possibilitadas por tecnologias da *web* semântica (Davies, 2006), que tem sua base na *eXtensible Markup Language* (XML) (W3C, 2010a) e em padrões para representação de conhecimento tais como o *Resource Description Framework* RDF (W3C, 2010b) e a *Web Ontology Language* (OWL) (W3C, 2010c). A busca e manipulação deste conhecimento intercambiável é facilitada por linguagens de consulta, tal como a *XQuery* (W3C, 2010d).

Neste contexto, padrões de metadados para indexação de objetos de aprendizagem tais como o *Learning Object Metadata* (LOM) (IEEE, 2010b) e o *Sharable Content Object Reference Model* (SCORM) (Power et al., 2005), são de extrema importância na reutilização deste conteúdo e, também, facilitam a definição de regras de navegação condicionais e adaptativas levando-se em consideração as características presentes no ME (Giotopoulos et al., 2005).

O uso de todos estes padrões culminando em reutilização em larga escala tende a reduzir muito o custo da autoria em SAIE, tornando viável elevado grau de adaptatividade, como o proposto neste trabalho. Algumas considerações sobre o uso de XML e seus padrões na construção de SAIE são discutidos por Benadi et al. (2004) e Meccawy et al. (2006). Dificuldades relacionadas ao fornecimento de adaptatividade baseada em EA são discutidas por Vasilyeva et al. (2006).

Algumas aplicações que usam o SCORM como base para personalização do ensino são apresentadas por Power et al. (2005) e Bhatt e Rao (2006). Neste âmbito, ressalta-se o trabalho de Bhatt e Rao (2006), que apresenta um conjunto de objetos de aprendizagem desenvolvidos para dar suporte aos objetivos de aprendizagem da Taxonomia de Bloom, demonstrando como os metadados para estes objetos de aprendizagem podem ser criados com SCORM e LOM.

Também, encontra-se atualmente em desenvolvimento um módulo de interface com o usuário para apresentação de conteúdo através da utilização de técnicas de HA para

adaptação de conteúdo e navegação, considerando-se os EA do estudante. Para isto, tem-se trabalhado no relacionamento das particularidades de cada EA do FSLSM às técnicas fornecidas pela HA, o que é um ponto crucial deste módulo. Para isto, tem-se levado em consideração importantes trabalhos relacionados à aplicação da HA na construção de SAIE¹.

Como expansão da abordagem apresentada neste trabalho, tem sido desenvolvida uma abordagem híbrida para o tratamento da incerteza na modelagem do estudante, unindo a Teoria dos Conjuntos Fuzzy (Pedrycz e Gomide, 2007) com a Teoria das Probabilidades (Papoulis et al., 2002) afim de se produzir um melhor tratamento da incerteza inerente à inferência da categoria pedagógica (representadas pelas CEAs) à qual um estudante pertence, levando-se em consideração seus EA.

Desta forma, a classificação probabilística dos estudantes a partir da descrição probabilística dos EA_p no ME representando variáveis aleatórias *fuzzy* (Shapiro, 2009) dão margem a Distribuições de Probabilidade *Fuzzy* (Boswell e Taylor, 1987) e, consequentemente, à representação de conjuntos *fuzzy* probabilísticos (Hirota, 1981).

Considerando as categorias pedagógicas definidas pelas CEAs como conjuntos *fuzzy* probabilísticos, esta abordagem não considera que o estudante pertença a uma categoria pedagógica específica, mas sim que o estudante possui um grau de pertinência probabilístico a todas as 16 categorias pedagógicas definidas. Desta forma, tem-se nesta abordagem um ME baseado em Lógica *Fuzzy* Probabilística, em que o processo de desfuzificação deve ocorrer não por meio de regras determinísticas, mas através de modelos de inferência estocásticos.

Além disto, está sob investigação a evolução desta abordagem para uma abordagem

¹Brusilovsky et al. (1998); Zakaria e Brailsford (2002); Clifford (2004); De Bra e Calvi (1998); Brusilovsky et al. (1996a); Brusilovsky (2001a); Cristea e Stash (2006); Stash et al. (2004); Specht e Oppermann (1998); Graf e Kinshuk (2007); Bajraktarevic et al. (2003); Sangineto et al. (2008); Limongelli et al. (2009); De Bra et al. (2006); Weber e Brusilovsky (2001); Cristea e de Mooij (2003); Paredes e Rodriguez (2006); Stern e Woolf (2000); Grigoriadou et al. (2001); Iglesias et al. (2009b,a); Martins et al. (2008); Brusilovsky e Millan (2007); Cristea (2007, 2005); Meccawy et al. (2006); Brown (2007); Trif et al. (2010); Karagiannidis e Sampson (2004); Botsios, S. and Georgiou, D. and Safouris, N. (2008); Paredes e Rodriguez (2004); Brusilovsky e Peylo (2003); Palazzo et al. (1999); Candotti et al. (2006); Oliveira e Fernandes (2002); Zanchett et al. (2004); Cristea e Calvi (2003)

baseada em Algoritmos Genéticos (AG) (Eiben e Smith, 2003; Chipperfield et al., 1994; Goldberg, 1989; Linden, 2006). Considerando-se que AG também modelam um processo estocástico, devido à sua natureza probabilística, mantem-se a natureza estocástica do processo de detecção e correção automática dos EAs, mas abrindo uma infinidade de novas possibilidades através da aplicação de operadores genéticos existentes ou de novos operadores que venham a ser propostos considerando-se especificamente o domínio de modelagem de EA.

Um esboço inicial desta abordagem foi inicialmente apresentado em (Dorça et al., 2011b), na qual uma CEA é estocasticamente selecionada a partir de uma população através de um método de seleção estocástica Goldberg (1989) durante uma seção de aprendizagem. Nesta abordagem, a aptidão de um indivíduo é calculada pela função P , apresentada no capítulo 4. A probabilidade de seleção de um indivíduo i é dada pela razão entre seu *fitness* e o somatório do *fitness* de todos os indivíduos.

Em (Dorça et al., 2012a) é realizada uma comparação entre a abordagem apresentada neste trabalho e aquela baseada em AG. Experimentos mostraram a eficiência e eficácia de ambas. Pôde-se concluir que apesar da abordagem baseada em AG aparentemente apresentar convergência mais rápida em direção aos EA_r do estudante, por vezes novas inconsistências surgem no ME ao longo do processo de aprendizagem, o que não ocorre com a abordagem apresentada neste trabalho.

Além disto, a abordagem baseada em AG gera um custo computacional consideravelmente maior, devido à necessidade de avaliação dos indivíduos na população e aos processos de cruzamento e mutação a cada seção de aprendizagem, ou seja, a cada iteração do algoritmo apresentado no capítulo 4, o que pode gerar problemas de escalabilidade à medida que a quantidade de estudantes que utilizam o sistema cresce. Além disto, cria-se necessidade de se armazenar e manter uma população de CEAs para cada estudante. Então, uma vantagem importante da abordagem apresentada neste trabalho é o baixo custo computacional quando comparada a outras abordagens, já que não demanda nenhum processamento adicional além do cálculo e aplicação do reforço aos EA_p armazenados no

ME.

Neste trabalho, uma dificuldade encontrada foi a modelagem do processo de simulação da aprendizagem, especificamente no que tange à inferência de um valor para a performance do estudante frente ao processo de avaliação. Tal modelagem foi fundamental neste trabalho, já que a atualização das preferências de estilos de aprendizagem do estudante é baseada na avaliação de seu desempenho ao longo do curso. Outra dificuldade está relacionada ao cálculo do reforço R . A priori foi utilizado um valor constante, que não se mostrou eficiente na atualização dos EA. Desta forma, o cálculo de R com base em DEA e PFM surgiu após a realização de diversos testes. Percebeu-se através de experimentos que considerar o valor de R inversamente proporcional à DEA e PFM seria uma abordagem interessante.

Um ponto importante na fase experimental foi a necessidade de se estabelecer um limite R_{max} para R e a configuração do valor de α . Desta forma, como trabalho futuro tem-se também a otimização do valor de R_{max} e α através de um método de inteligência computacional (Konar, 2005) apropriado, tal como algoritmos genéticos (Goldberg, 1989). Neste contexto, encontrar os valores ótimos de R_{max} e α significa otimizar ainda mais os resultados apresentados neste trabalho, tornando esta abordagem ainda mais eficiente.

Finalmente, pôde-se verificar que, com o objetivo de se adaptar o conteúdo, o ambiente e a sequência de atividades às características dos estudantes em SAIE, vários trabalhos apresentam propostas de utilização de EA na modelagem do estudante e no fornecimento de adaptatividade. Porém, como apresentado, nenhum deles levam em consideração a necessidade de se implementar este processo de forma probabilística, observando-se a natureza fortemente estocástica do processo de ensino-aprendizagem e de modelagem automática e dinâmica de EA, conforme apresentou-se neste trabalho.

Referências Bibliográficas

- Abdullah, S. e Cooley, R. (2002). Using simulated students to evaluate an adaptive testing system. In *Computers in Education, 2002. Proceedings. International Conference on*, pages 614–618. IEEE.
- Abramson, M. e Wechsler, H. (2001). Competitive reinforcement learning for combinatorial problems. In *Neural Networks, 2001. Proceedings. IJCNN'01. International Joint Conference on*, volume 4, pages 2333–2338. IEEE.
- Al-Dujaily, A. e Ryu, H. (2006). A relationship between e-learning performance and personality. In *Advanced Learning Technologies, 2006. Sixth International Conference on*, pages 84–86. IEEE.
- Albuquerque, J., Fortes, J., e Finamore, W. (2008). *Probabilidade, Variáveis Aleatórias e Processos Estocásticos*. Rio de Janeiro: Editora Interciência.
- Alfonseca, E., Carro, R., Martín, E., Ortigosa, A., e Paredes, P. (2006). The impact of learning styles on student grouping for collaborative learning: a case study. *User Modeling and User-Adapted Interaction*, 16(3):377–401.
- Bajraktarevic, N., Hall, W., e Fullick, P. (2003). Incorporating learning styles in hypermedia environment: Empirical evaluation. In *Proceedings of the workshop on adaptive hypermedia and adaptive web-based systems*, pages 41–52.
- Baldiris, S., Santos, O., Huerva, D., Fabregat, R., e Boticario, J. (2009). Multidimensional Adaptations for Open Learning Management Systems. In *Web Intelligence and Intelli-*

- gent Agent Technology, 2008. WI-IAT'08. IEEE/WIC/ACM International Conference on*, volume 3, pages 352–356. IEEE.
- Benadi, S., Ramel, J., e Prevot, P. (2004). AHXEL: adaptive hyperdocument using XML for e-learning. In *Information Technology Based Higher Education and Training, 2004. ITHET 2004. Proceedings of the Fifth International Conference on*, pages 138–144. IEEE.
- Bhatt, C. e Rao, N. (2006). Scorm metadata in the context of bloom-vincenti taxonomy and intelligent tutoring system. In *Proceedings of the 6th International Conference on Web Engineering, ICWE 2006, Palo Alto, California, USA, July 11-14, 2006*, pages 87–88. ACM.
- Biermann, A. e Ramm, D. (2001). *Great ideas in computer science with Java*. The MIT Press.
- Blackboard (2010). <http://www.blackboard.com/>.
- Bostrom, L. (2011). Students' Learning Styles Compared with their Teachers' Learning Styles in Secondary Schools . *Institute for Learning Styles Journal*, 1.
- Boswell, S. e Taylor, M. (1987). A central limit theorem for fuzzy random variables. *Fuzzy Sets and Systems*, 24(3):331–344.
- Botelho, C., Pimentel, E., Senger, H., e Stiubiener, I. (2009). Personalização em sistemas de gerenciamento da aprendizagem em conformidade com o padrão scorm. In *Anais do Simpósio Brasileiro de Informática na Educação*, volume 1.
- Botsios, S. e Georgiou, D. (2008). Learning style diagnosis as an adaptivity parameter in a unified e-learning system architecture. In *AH '08 Proceedings of the 5th international conference on Adaptive Hypermedia and Adaptive Web-Based Systems*, pages 384–388. Springer-Verlag Berlin.

- Botsios, S. and Georgiou, D. and Safouris, N. (2008). Contributions to adaptive educational hypermedia systems via on-line learning style estimation. *Educational Technology & Society*, 12(4):322–339.
- Bravo, J. e Ortigosa, A. (2006). Validating the evaluation of adaptive systems by user profile simulation. In *Proceedings of Workshop held at the Fourth International Conference on Adaptive Hypermedia and Adaptive Web-Based Systems (AH2006)*, pages 479–483.
- Brown, E. (2007). *The use of learning styles in adaptive hypermedia*. PhD thesis, University of Nottingham.
- Brown, E., Brailsford, T., Fisher, T., Moore, A., e Ashman, H. (2006). Reappraising cognitive styles in adaptive web applications. In *Proceedings of the 15th international conference on World Wide Web*, pages 327–335. ACM.
- Brusilovsky, P. (1996). Methods and techniques of adaptive hypermedia. *User modeling and user-adapted interaction*, 6(2):87–129.
- Brusilovsky, P. (2001a). Adaptive educational hypermedia. In *International PEG Conference*, pages 8–12. Citeseer.
- Brusilovsky, P. (2001b). Adaptive hypermedia. *User modeling and user-adapted interaction*, 11(1):87–110.
- Brusilovsky, P., Eklund, J., e Schwarz, E. (1998). Web-based education for all: A tool for developing adaptive courseware. In *Seventh International WWW Conference*, pages 291–300.
- Brusilovsky, P., Karagiannidis, C., e Sampson, D. (2004). Layered evaluation of adaptive learning systems. *International Journal of Continuing Engineering Education and Life Long Learning*, 14(4):402–421.
- Brusilovsky, P. e Millan, E. (2007). User models for adaptive hypermedia and adaptive educational systems. *The adaptive web*, pages 3–53.

- Brusilovsky, P. e Peylo, C. (2003). Adaptive and intelligent Web-based educational systems. *International Journal of Artificial Intelligence in Education*, 13(2):159–172.
- Brusilovsky, P., Schwarz, E., e Weber, G. (1996a). A tool for developing adaptive electronic textbooks on WWW. In *Proceedings of WebNet*, volume 96, pages 64–69.
- Brusilovsky, P., Schwarz, E., e Weber, G. (1996b). Elm-art: An intelligent tutoring system on world wide web. In *Intelligent Tutoring Systems*, pages 261–269. Springer.
- Brusilovsky, P. e Vassileva, J. (2003). Course sequencing techniques for large-scale web-based education. *International Journal of Continuing Engineering Education and Life Long Learning*, 13(1):75–94.
- Cabada, R., Estrada, M., e Garcia, C. (2009). A Fuzzy-Neural Network for Classifying Learning Styles in a Web 2.0 and Mobile Learning Environment. In *Web Congress, 2009. LE-WEB'09. Latin American*, pages 177–182. IEEE.
- Candotti, C. T., Geller, M., Silveira, S. R., Marques, E. M., e Santana, M. B. (2006). Sistema hipermídia adaptativo baseado em estilos cognitivos. *RENOTE - Revista Novas Tecnologias na Educação ISSN 1679-1916*, 4(2).
- Carmona, C. e Castillo, G. (2008). Designing a Dynamic Bayesian Network for Modeling Students Learning Styles. In *Eighth IEEE International Conference on Advanced Learning Technologies*, pages 346–350. IEEE.
- Carmona, C., Castillo, G., e Millán, E. (2007a). Discovering student preferences in e-learning. In *Proceedings of the International Workshop on Applying Data Mining in e-Learning*. Citeseer.
- Carmona, C., Castillo, G., e Millán, E. (2007b). Discovering Student Preferences in E-Learning. In *Proceedings of the International Workshop on Applying Data Mining in e-Learning*.

- Carver, C., Howard, R., e Lane, W. (1999). Addressing different learning styles through course hypermedia. *IEEE Transactions on Education*, 42(1):33–38.
- Carver Jr, C., Howard, R., e Lane, W. (2002). Enhancing student learning through hypermedia courseware and incorporation of student learning styles. *Education, IEEE Transactions on*, 42(1):33–38.
- Castillo, G., Gama, J., e Breda, A. (2005). An Adaptive Predictive Model for Student Modeling. *Advances in Web-based education: Personalized learning environments*, pages 70–92.
- Cha, H., Kim, Y., Lee, J., e Yoon, T. (2006a). An adaptive learning system with learning style diagnosis based on interface behaviors. In *Workshop Proceedings of International Conference on E-Learning and Games, Hangzhou, China*, pages 513–524.
- Cha, H., Kim, Y., Park, S., Yoon, T., Jung, Y., e Lee, J. (2006b). Learning styles diagnosis based on user interface behaviors for the customization of learning interfaces in an intelligent tutoring system. In *Intelligent Tutoring Systems*, pages 513–524. Springer.
- Chen, S. Y. e Macredie, R. D. (2002). Cognitive styles and hypermedia navigation: Development of a learning model. *Journal of the American Society for Information Science and Technology*, 53(1):3–15.
- Chipperfield, A., Fleming, P., Pohlheim, H., e Fonseca, C. (1994). Genetic algorithm toolbox for use with matlab. *Citeseer*.
- Chiu, H., Sheng, C., e Chen, A. (2007). Designing a Dynamic E-learning Project Performance Evaluation Framework. In *Advanced Learning Technologies, 2007. ICALT 2007. Seventh IEEE International Conference on*, pages 381–385. IEEE.
- Chwif, L. e Medina, A. (2007). *Modelagem e simulação de eventos discretos*. Editora Medina. 2a. ed.
- Clarke, A. e Disney, R. (1979). *Probabilidade e processos Estocásticos*. LTC.

- Clifford, R. (2004). Adaptive hypermedia for music instruction. *7th International Technological Directions in Music Learning Conference, TDML ejournal*.
- Coelho, L. (2011). Processo de decisão markoviano e aprendizagem por reforço. Technical report, Laboratório de Técnicas Inteligentes, <http://www.lti.pcs.usp.br/>, USP.
- Coffield, F., Moseley, D., Hall, E., e Ecclestone, K. (2009). *Learning styles and pedagogy in post-16 learning: A systematic and critical review*. National Centre for Vocational Education Research (NCVER).
- Costa, M. (1999). *Uma arquitetura baseada em agentes para suporte ao ensino à distância*. 1999. PhD thesis, Departamento de Engenharia de Produção e Sistemas, Universidade Federal de Santa Catarina, Florianópolis, SC.
- Cristea, A. (2005). Adaptive course creation for all. In *Information Technology: Coding and Computing, 2004. Proceedings. ITCC 2004. International Conference on*, volume 1, pages 718–722. IEEE.
- Cristea, A. (2007). Authoring of Adaptive Educational Hypermedia. In *Advanced Learning Technologies, 2007. ICALT 2007. Seventh IEEE International Conference on*, pages 943–944. IEEE.
- Cristea, A. e Calvi, L. (2003). The three Layers of Adaptation Granularity. In *UM'03, Pittsburgh*.
- Cristea, A. e de Mooij, A. (2003). Adaptive Course Authoring: My Online Teacher. In *Telecommunications, 2003. ICT 2003. 10th International Conference on*, volume 2, pages 1762–1769. IEEE.
- Cristea, A. e Stash, N. (2006). AWELS: adaptive Web-based education and learning styles. In *Sixth IEEE International Conference on Advanced Learning Technologies (ICALT'06)*. IEEE Computer Society, IEEE Computer Society.

- Danine, A., Lefebvre, B., e Mayers, A. (2006). Tides-using bayesian networks for student modeling. In *Proceedings of the Sixth International Conference on Advanced Learning Technologies (ICALT'06)*. IEEE Computer Society, IEEE Computer Society.
- Davies, J. (2006). *Semantic Web technologies : trends and research in ontology-based systems*. John Wiley & Sons Ltd.
- De Bra, P. e Calvi, L. (1998). AHA! An open adaptive hypermedia architecture. *New Review of Hypermedia and Multimedia*, 4(1):115–139.
- De Bra, P., Houben, G., e Wu, H. (1999). Aham: a dexter-based reference model for adaptive hypermedia. In *Proceedings of the tenth ACM Conference on Hypertext and hypermedia: returning to our diverse roots: returning to our diverse roots*, pages 147–156. ACM.
- De Bra, P., Smits, D., e Stash, N. (2006). Creating and delivering adaptive courses with AHA! *Innovative Approaches for Learning and Knowledge Sharing*, pages 21–33.
- Desire2Learn (2012). *Desire2Learn*. URL: <https://learn.colorado.edu/>. University of Colorado.
- Devore, J. e da Silva, J. (2006). *Probabilidade e estatística: para engenharia e ciências*. Pioneira Thomson Learning.
- Do Rosário, J. (2006). *Estilos de aprendizagem de alunos de engenharia química e engenharia de alimentos da ufsc: O caso da disciplina de análise e simulação de processos*. PhD thesis, Universidade Federal de Santa Catarina.
- Dorça, F. A., Lima, L. V., Fernandes, M. A., e Lopes, C. R. (2012a). Automatic student modeling in adaptive educational systems through probabilistic learning style combinations: A qualitative comparison between two innovative stochastic approaches. doi: 10.1007/s13173-012-0078-2. *Journal of The Brazilian Computer Society*. ISSN: 0104-6500., 18(3).

- Dorça, F. A., Lima, L. V., Fernandes, M. A., e Lopes, C. R. (2012b). A stochastic approach for automatic and dynamic student modeling in adaptive educational systems. *Informatics in Education. Vilnius University Institute of Mathematics and Informatics, Lithuanian Academy of Sciences, Lithuania. ISSN: 1648-5831.*, 11(2).
- Dorça, F., Lopes, C., e Fernandes, M. (2003). A multiagent architecture for distance education systems. In *Advanced Learning Technologies, 2003. Proceedings. The 3rd IEEE International Conference on*, pages 368–369. IEEE.
- Dorça, F., Lopes, C., e Fernandes, M. (2004). A web-based multiagent educational system. In *International Conference on Education and Information Systems, Technologies and Applications (EISTA 2004) and the International Conference on Cybernetics and Information Technologies, Systems and Applications (CITSA 2004)*.
- Dorça, F. A. (2004). Um sistema inteligente multiagente para educação a distância apoiado em web. Master's thesis, Programa de Pós Graduação em Ciência da Computação. Faculdade de Computação. Universidade Federal de Uberlândia.
- Dorça, F. A., Fernandes, M. A., Lopes, C. R., e Queiroz, B. (2002). Um sistema inteligente multiagente para educação a distância. In *Anais do XXII Congresso da Sociedade Brasileira de Computação*. Sociedade Brasileira de Computação (SBC).
- Dorça, F. A., Lima, L. V., Fernandes, M. A., e Lopes, C. R. (2011a). Detecção e correção automática de estilos de aprendizagem em sistemas adaptativos para educação. *Revista de Informática Teórica e Aplicada*, 18(2).
- Dorça, F. A., Lima, L. V., Fernandes, M. A., e Lopes, C. R. (2011b). A new approach to discover students learning styles in adaptive educational systems. In *XXII Simpósio Brasileiro de Informática na Educação*.
- Dorça, F. A., Lopes, C. R., Fernandes, M. A., e Lopes, R. S. (2009). Adaptativity Supported by Neural Networks in Web-based Educational Systems. *Journal of Education, Informatics and Cybernetics (JEIC)*, 1.

- Dutra, R. e Tarouco, L. (2006). Objetos de aprendizagem: uma comparação entre scorm e ims learning design. *RENOTE: revista novas tecnologias na educação [recurso eletrônico]*. Porto Alegre, RS.
- Eiben, A. e Smith, J. (2003). *Introduction to evolutionary computing*. Springer Verlag.
- Entwistle, N. (1981). *Styles of learning and teaching*. Wiley Chichester.
- Felder, R. e Brent, R. (2005). Understanding student differences. *Journal of Engineering Education*, 94(1):57–72.
- Felder, R. e Silverman, L. (1988). Learning and teaching styles in engineering education. *Journal of Engineering education*, 78(7):674–681.
- Felder, R., Silverman, L., Solomon, B., e University, N. C. S. (1999). *Index of learning styles (ILS)*. North Carolina State University.
- Felder, R. e Spurlin, J. (2005). Applications, reliability and validity of the index of learning styles. *International Journal of Engineering Education*, 21(1):103–112.
- Franzoni, A., Assar, S., Defude, B., e Rojas, J. (2008). Student Learning Styles Adaptation Method Based on Teaching Strategies and Electronic Media. In *Advanced Learning Technologies, 2008. ICALT'08. Eighth IEEE International Conference on*, pages 778–782. IEEE.
- Franzoni, A. L. e Assar, S. (2009). Student learning styles adaptation method based on teaching strategies and electronic media. *Educational Technology & Society*, 12(4):15–29.
- Friedel, C. e Rudd, R. (2006). Creative thinking and learning styles in undergraduate agriculture students. *Journal of Agricultural Education*, 47(4):102.
- García, P., Amandi, A., Schiaffino, S., e Campo, M. (2007). Evaluating Bayesian networks' precision for detecting students' learning styles. *Computers & Education*, 49(3):794–808.

- Gardiner, C. W. (1983). *Handbook of stochastic methods for physics, chemistry and the natural sciences*. Springer-Verlag.
- Geiss, C. (2009). Stochastic Modeling. users.jyu.fi/~geiss/scripts/stochastic-models.pdf, 1.
- Gilbert, J. e Han, C. (1999). Adapting instruction in search of a significant difference. *Journal of Network and Computer applications*, 22(3):149–160.
- Giotopoulos, K., Alexakos, C., Beligiannis, G., e Likothanassis, S. (2005). Integrating Agents and Computational Intelligence Techniques in E-learning Environments. In *International Enformatika Conference (IEC '05)*, pages 231–238. World Academy of Science, Engineering and Technology.
- Giraffa, L. (1999). *Uma arquitetura de tutor utilizando estados mentais*. PhD thesis, Universidade Federal do Rio Grande do Sul. Instituto de Informática. Programa de Pós-Graduação em Computação.
- Gogvadze, G., Sosnovsky, S., Isotani, S., e McLaren, B. (2011). Evaluating a bayesian student model of decimal misconceptions. In *Proceedings of the 4th International Conference on Educational Data Mining*.
- Goldberg, D. (1989). *Genetic algorithms in search, optimization, and machine learning*. Addison-wesley.
- Gomes, S., Gadelha, B., Mendonça, A., e Amoretti, M. (2005). Objetos de aprendizagem funcionais e as limitações dos metadados atuais. In *Anais do Simpósio Brasileiro de Informática na Educação*, volume 1, pages 201–210.
- Gomez, R., Hadfield, O., e Housner, L. (1996). Conceptual maps and simulated teaching episodes as indicators of competence in teaching elementary mathematics. *Journal of Educational Psychology*, 88(3):572.

- Graf, S. (2006). An approach for detecting learning styles in learning management systems. In *Advanced Learning Technologies, 2006. Sixth International Conference on*, pages 161–163. IEEE, IEEE.
- Graf, S. e Kinshuk (2009a). Advanced Adaptivity in Learning Management Systems by Considering Learning Styles. In *Proceedings of the 2009 IEEE/WIC/ACM International Joint Conference on Web Intelligence and Intelligent Agent Technology-Volume 03*, pages 235–238. IEEE Computer Society.
- Graf, S. e Kinshuk (2009b). An Approach for Dynamic Student Modelling of Learning Styles. In *Proceeding of IADIS International Conference on Cognition and Exploratory Learning in Digital Age (CELDA 2009)*, pages 462–465.
- Graf, S., Kinshuk, e Liu, T. (2009a). Supporting teachers in identifying students' learning styles in learning management systems: An automatic student modelling approach. *Journal of Educational Technology & Society*, 12(4):3–14.
- Graf, S., Kinshuk, Zhang, Q., Maguire, P., e Shtern, V. (2010). An Architecture for Dynamic Student Modelling of Learning Styles in Learning Systems and its Application for Adaptivity. In *IADIS International Conference on Cognition and Exploratory Learning in Digital Age (CELDA 2010)*, pages 103–110.
- Graf, S. e Kinshuk, C. (2010a). A Flexible Mechanism for Providing Adaptivity Based on Learning Styles in Learning Management Systems. In *10th IEEE International Conference on Advanced Learning Technologies*, pages 30–34. IEEE.
- Graf, S. e Kinshuk, K. (2007). Providing Adaptive Courses in Learning Management Systems with Respect to Learning Styles. In *Proceedings of World Conference on E-Learning in Corporate, Government, Healthcare, and Higher Education 2007*, pages 2576–2583.
- Graf, S. e Kinshuk, K. (2010b). Using Cognitive Traits for Improving the Detection of

- Learning Styles. In *Database and Expert Systems Applications (DEXA), 2010 Workshop on*, pages 74–78. IEEE.
- Graf, S., Lan, C., Liu, T., et al. (2009b). Investigations about the Effects and Effectiveness of Adaptivity for Students with Different Learning Styles. In *2009 Ninth IEEE International Conference on Advanced Learning Technologies*, pages 415–419. IEEE.
- Graf, S. e Lin, T. (2007). Analysing the Relationship between Learning Styles and Cognitive Traits. In *Advanced Learning Technologies, 2007. ICALT 2007. Seventh IEEE International Conference on*, pages 235–239. IEEE.
- Graf, S. e Liu, T. (2008). Identifying Learning Styles in Learning Management Systems by Using Indications from Students' Behaviour. In *Advanced Learning Technologies, 2008. ICALT'08. Eighth IEEE International Conference on*, pages 482–486. IEEE.
- Graf, S., Liu, T.-C., e Kinshuk (2008). Interactions Between Students Learning Styles, Achievement and Behaviour in Mismatched Courses. In *Proceedings of the International Conference on Cognition and Exploratory Learning in Digital Age (CELDA 2008)*, pages 223–230. IADIS International Conference.
- Graf, S. e Viola, S. (2009). Automatic student modelling for detecting learning style preferences in learning management systems. *Citeseer*.
- Graf, S., Viola, S., e Leo, T. (2006). Representative characteristics of Felder-Silverman learning styles: An empirical model. In *Proceedings of the IADIS International Conference on Cognition and Exploratory Learning in Digital Age (CELDA 2006)*, pages 8–10. IADIS.
- Grigoriadou, M. e Papanikolaou, K. (2006). Authoring personalised interactive content. In *Semantic Media Adaptation and Personalization, 2006. SMAP'06. First International Workshop on*, pages 80–85. IEEE.

- Grigoriadou, M., Papanikolaou, K., Kornilakis, H., e Magoulas, G. (2001). INSPIRE: an intelligent system for personalized instruction in a remote environment. In *Proceedings of Third workshop on Adaptive Hypertext and Hypermedia, July*, volume 14, pages 13–24. Citeseer.
- Guelpele, M., Ribeiro, C., e Omar, N. (2003). Utilização de aprendizagem por reforço para modelagem autônoma do aprendiz em um tutor inteligente. In *Anais do Simpósio Brasileiro de Informática na Educação*, volume 1, pages 465–474.
- Haider, M., Sinha, A., e Chaudhary, B. (2010). An Investigation of relationship between learning styles and performance of learners. *International Journal of Engineering Science and Technology*, 2(7):2813–2819.
- Hirota, K. (1981). Concepts of probabilistic sets. *Fuzzy Sets and Systems*, 5(1):31–46.
- Hodgins, W. (2002). Draft standard for learning object metadata. Technical report, Institute of Electrical and Electronics Engineers. [Acesso: 10-09-2010].
- Honey, P. e Mumford, A. (1992). *The manual of learning styles*. Peter Honey Publications; 3Rev Ed edition (31 Jan 1992).
- Hook, K., Rudstrom, A., e Waern, A. (1997). Edited adaptive hypermedia: Combining human and machine intelligence to achieve filtered information. In *8th ACM International Hypertext Conference (Hypertext'97), Flexible Hypertext Workshop*. ACM.
- IEEE (2010a). *Learner Model*. *IEEE Learning Technology Standards Committee (LTSC)*, <http://ltsc.ieee.org/wg2/index.html>.
- IEEE (2010b). *LOM (Learning Object Metadata)*. *IEEE Learning Technology Standards Committee*, <http://ltsc.ieee.org/wg12/index.html>.
- Iglesias, A., Martinez, P., Aler, R., e Fernandez, F. (2009a). Learning teaching strategies in an adaptive and intelligent educational system through reinforcement learning. *Applied Intelligence*, 31(1):89–106.

- Iglesias, A., Martinez, P., Aler, R., e Fernandez, F. (2009b). Reinforcement learning of pedagogical policies in adaptive and intelligent educational systems. *Knowledge-Based Systems*, 22(4):266–270.
- Jones, C., Reichard, C., e Mokhtari, K. (2003). Are Students Learning Styles Discipline Specific? *Community College Journal of Research and Practice*, 27(5):363–375.
- Kaelbling, L., Littman, M., e Moore, A. (1996). Reinforcement learning: A survey. *Arxiv preprint cs/9605103*.
- Karagiannidis, C. e Sampson, D. (2004). Adaptation rules relating learning styles research and learning objects meta-data. In *Workshop on Individual Differences in Adaptive Hypermedia. 3rd International Conference on Adaptive Hypermedia and Adaptive Web-based Systems (AH2004), Eindhoven, Netherlands*, pages 136–145.
- Kelly, D. e Tangney, B. (2005). 'First Aid for You': getting to know your learning style using machine learning. In *Advanced Learning Technologies, 2005. ICALT 2005. Fifth IEEE International Conference on*, pages 1–3. IEEE.
- Kinshuk, Liu, T., e Graf, S. (2009). Coping with Mismatched Courses: Students' behaviour and performance in courses mismatched to their learning styles. *Educational Technology Research and Development*, 57(6):739–752.
- Kolb, D. et al. (1984). *Experiential learning: Experience as the source of learning and development*. Prentice-Hall Englewood Cliffs, NJ.
- Konar, A. (2005). *Computational intellingence [ie intelligence]: principles, techniques, and applications*. Springer Verlag.
- Krathwohl, D. (2002). A revision of Bloom's taxonomy: An overview. *Theory into practice*, 41(4):212–218.
- Lim, H., Lee, S., e Nam, K. (2007). Validating e-learning factors affecting training effectiveness. *International Journal of Information Management*, 27(1):22–35.

- Limongelli, C., Sciarrone, F., Temperini, M., e Vaste, G. (2009). Adaptive learning with the LS-plan system: a field evaluation. *IEEE Transactions on Learning Technologies*, pages 203–215.
- Linden, R. (2006). *Algoritmos genéticos*. Brasport.
- Lopes, R. S. (2009). Planejamento instrucional adaptativo usando workflow e planejamento genético. Master's thesis, Programa de Pós-Graduação em Ciência da Computação. Faculdade de Computação. Universidade Federal de Uberlândia. Uberlândia - Minas Gerais.
- Lopes, R. S., Dorça, F. A., Fernandes, M. A., e Lopes, C. R. (2008a). Um sistema de avaliação em EAD baseado em lógica Fuzzy. In *Simpósio Brasileiro de Informática na Educação*, pages 30–34. SBC.
- Lopes, R. S., Dorça, F. A., Fernandes, M. A., e Lopes, C. R. (2008b). Um sistema de avaliação em ead baseado em lógica fuzzy. In *Proceedings of XIX Simpósio Brasileiro de Informática na Educação, Fortaleza, CE*.
- Lopes, R. S. e Fernandes, M. A. (2009). Adaptative Instructional Planning Using Workflow and Genetic Algorithms. In *Computer and Information Science, 2009. ICIS 2009. Eighth IEEE/ACIS International Conference on*, pages 87–92. IEEE.
- Lopes, W. (2002). Ils inventário de estilos de aprendizagem de felder-soloman: Investigação de sua validade em estudantes universitários de belo horizonte. *Dissertação: Florianópolis, UFSC, Programa de Pós-Graduação em Engenharia de produção*.
- Magalhães, M. (2006). *Probabilidade e variáveis aleatórias*. Edusp.
- Martins, A. C., Faria, L., Vaz de Carvalho, C., e Carrapatoso, E. (2008). User Modeling in Adaptive Hypermedia Educational Systems. *Educational Technology & Society*, 11(1):194–207.

- Marzano, R. e Kendall, J. (2007). *The new taxonomy of educational objectives*. Corwin Pr.
- McGreal, R. (2004). Learning objects: A practical definition. *Instructional Technology e Distance Learning*.
- Meccawy, M., Celik, I., Cristea, A., Stewart, C., e Ashman, H. (2006). Interoperable Adaptive Educational Hypermedia: A Web Service Definition. In *Sixth International Conference on Advanced Learning Technologies, ICALT*. IEEE.
- Mertz, J. (1997). Using a simulated student for instructional design. *International Journal of Artificial Intelligence in Education (IJAIED)*, 8:116–141.
- Messick, S. (1976). Personal styles and educational options. *Individuality in learning*, pages 327–368.
- Meyn, S., Tweedie, R., e Glynn, P. (2009). *Markov chains and stochastic stability*, volume 2. Cambridge University Press Cambridge.
- Moodle (2010). <http://www.moodle.org/>.
- Mosakhani, M. e Jamporazmey, M. (2010). Introduce critical success factors (CSFs) of elearning for evaluating e-learning implementation success. In *Educational and Information Technology (ICEIT), 2010 International Conference on*, volume 1, pages V1–224. IEEE.
- Murray, R., VanLehn, K., e Mostow, J. (2001). A decision-theoretic approach for selecting tutorial discourse actions. In *Proceedings of the NAACL Workshop on Adaptation in Dialogue Systems, Pittsburgh, PA*, pages 41–48.
- Myers, I. e McCaulley, M. (1985). *Manual: A guide to the development and use of the Myers-Briggs Type Indicator*. Consulting Psychologists Press, Palo Alto, CA.
- Myers, I., McCaulley, M., e Most, R. (1985). *Manual: A guide to the development and use of the Myers-Briggs Type Indicator*. Consulting Psychologists Press Palo Alto, CA.

- Oliveira, J. e Fernandes, C. (2002). Arquitetura de adaptação em sistemas hipermídia adaptativos educacionais. In *Anais do Simpósio Brasileiro de Informática na Educação*, volume 1, pages 68–79.
- Palazzo, L. (2000). *Modelos proativos para hipermídia adaptativa*. PhD thesis, Universidade Federal do Rio Grande do Sul. Instituto de Informática. Programa de Pós-Graduação em Computação.
- Palazzo, L. (2002). Sistemas de hipermídia adaptativa. In *Anais do XXII Congresso da Sociedade Brasileira de Computação (SBC)*, Florianópolis. SBC.
- Palazzo, L. A. M., Costa, A. C. R., Brisolara, L. B., e Gonçalves, R. R. O. (1999). Hipermídia adaptativa na educação online: um modelo proativo e sua implementação na web. *Revista da UCPel*, 8(2):73–82.
- Papanikolaou, K., Grigoriadou, M., Magoulas, G., e Kornilakis, H. (2002). Towards new forms of knowledge communication: the adaptive dimension of a web-based learning environment. *Computers & Education*, 39(4):333–360.
- Papoulis, A., Pillai, S., e Unnikrishna, S. (2002). *Probability, random variables, and stochastic processes*, volume 73660116. McGraw-Hill New York.
- Paredes, P. e Rodriguez, P. (2004). A mixed approach to modelling learning styles in adaptive educational hypermedia. *Advanced Technology for Learning*, 1(4):210–215.
- Paredes, P. e Rodriguez, P. (2006). Considering sensing-intuitive dimension to exposition-exemplification in adaptive sequencing. In *Adaptive hypermedia and adaptive web-based systems*, pages 556–559. Springer.
- Pask, G. (1976). Styles and strategies of learning. *British journal of educational psychology*.
- Pedrycz, W. e Gomide, F. (2007). *Fuzzy systems engineering: toward human-centric computing*. Wiley-IEEE Press.

- Pollard, D. (1984). *Convergence of stochastic processes*. Springer.
- Power, G., Davis, H., Cristea, A., Stewart, C., e Ashman, H. (2005). Goal oriented personalisation with SCORM. In *Advanced Learning Technologies, 2005. ICAALT 2005. Fifth IEEE International Conference on*, pages 467–471. IEEE.
- Price, L. (2004). Individual differences in learning: Cognitive control, cognitive style, and learning style. *Educational Psychology*, 24(5):681–698.
- Prodan, A. e Prodan, R. (2001). Stochastic simulation and modelling. *ACM Journal of Education Resources in Computing*, 1:461–466.
- Queiroz, B. and Lopes, C. R. and Fernandes M. A. (2002). Automatic curriculum generation for a web-based educational system. *International Conference on Computers in Education (ICCE 2002)*.
- Reid, J. (1998). *Understanding learning styles in the second language classroom*. Prentice Hall Regents.
- Roberts, M. e Erdos, G. (1993). Strategy selection and metacognition. *Educational Psychology*, 13(3):259–266.
- Ross, S. (2010). *Probabilidade: um curso moderno com aplicações*. Bookman.
- Russel, S. e Norvig, P. (2004). *Inteligência Artificial: Um enfoque moderno*. 2ª edição. Editora Campus.
- Safouris, N., Botsios, N., e Georgiou, D. (2007). Some approaches in learning style diagnosis. *Proceedings ICICTE*.
- Sampaio, F. (1997). Modelagem dinâmica computacional e o processo de ensino-aprendizagem: algumas questões para reflexão. In *Conferência Internacional de Informática e Educação do Chile-TISE*, volume 98.

- Sangineto, E., Capuano, N., Gaeta, M., e Micarelli, A. (2008). Adaptive course generation through learning styles representation. *Universal Access in the Information Society*, 7(1):1–23.
- Santos, O. e Boticario, J. (2008). Recommendation strategies for promoting eLearning performance factors for all. In *6th Workshop on Intelligent Techniques for Web Personalization & Recommender Systems in conjunction with The 23rd AAAI Conference on Artificial Intelligence-2008*.
- Shapiro, A. (2009). Fuzzy random variables. *Insurance: Mathematics and Economics*, 44(2):307–314.
- Shein, P. e Chiou, W. (2011). Teachers as role models for students' learning styles . *Social Behavior and Personality*, 39(8):1097–1104.
- Silva, R., Silveira, J., e Balbinot, R. (2003). Plataforma deskead para aplicações de educação à distância. *Rede Nacional de Ensino e Pesquisa*.
- SOLAR (2012). <http://www.solar.virtual.ufc.br/>. Universidade Federal do Ceará.
- Souza, J. (2002). Teoria da revisao de primeira ordem para a modelagem do estudante. Master's thesis, Universidade Federal do Ceará, Fortaleza.
- Specht, M. e Oppermann, R. (1998). ACE-adaptive courseware environment. *New Review of Hypermedia and Multimedia*, 4(1):141–161.
- Stash, N., Cristea, A., e De Bra, P. (2004). Authoring of learning styles in adaptive hypermedia: Problems and solutions. In *Proceedings of the 13th international World Wide Web conference on Alternate track papers & posters*, pages 114–123. ACM.
- Stern, M. e Woolf, B. (2000). Adaptive content in an online lecture system. In *Adaptive hypermedia and adaptive Web-based systems*, pages 227–238. Springer.
- Sutton, R. e Barto, A. (1998). *Reinforcement learning: An introduction*, volume 116. Cambridge Univ Press.

- TelEduc (2012). *TelEduc*. www.teleduc.org.br. Núcleo de Informática Aplicada à Educação (NIED) da Universidade Estadual de Campinas (Unicamp).
- Terry, R. E., Harb, J. N., Hurt, P., e Williamson, K. (1995). *Teaching through the cycle: application of learning style theory to engineering education at Brigham Young University*. Brigham Young University Press.
- Tesauro, G. (1995). Temporal difference learning and td-gammon. *Communications of the ACM*, 38(3):58–68.
- Thompson, J. (1996). *Student modeling in an intelligent tutoring system*. PhD thesis, Faculty of the Graduate School of Engineering of the Air Force Institute of Technology.
- Trif, F., Lemnaru, C., e Potolea, R. (2010). Identifying the user typology for adaptive e-learning systems. In *Automation Quality and Testing Robotics (AQTR), 2010 IEEE International Conference on*, volume 3, pages 1–6. IEEE.
- Tsiriga, V. e Virvou, M. (2004). A framework for the initialization of student models in web-based intelligent tutoring systems. *User Modeling and User-Adapted Interaction*, 14(4):289–316.
- Valleperas, E. M. (2000). *Sistema bayesiano para modelado del alumno*. PhD thesis, Departamento de Lenguajes Y Ciencias De La Computación. Universidade de Málaga.
- Van Zwanenberg, N., Wilkinson, L., e Anderson, A. (2000). Felder and silverman’s index of learning styles and honey and mumford’s learning styles questionnaire: how do they compare and do they predict academic performance? *Educational Psychology*, 20(3):365–380.
- Vanlehn, K., Ohlsson, S., e Nason, R. (1994). Applications of simulated students: An exploration. *Journal of artificial intelligence in education*, 5:135–135.

- Vasilyeva, E., Pechenizkiy, M., e Puuronen, S. (2006). The Challenge of Feedback Personalization to Learning Styles in a Web-Based Learning System. In *Advanced Learning Technologies, 2006. Sixth International Conference on*, pages 1143–1144. IEEE.
- Velazquez, A. e Assar, S. (2007). Using Learning Styles to Enhance an E-Learning System. In *Proceedings of the 6th European Conference on e-Learning*, pages 235–244. Academic Conferences Limited.
- Villaverde, J., Godoy, D., e Amandi, A. (2006). Learning Styles' Recognition in e-learning Environments with Feed-Forward Neural Networks. *Journal of Computer Assisted Learning*, Vol. 22(3):197–206.
- Virvou, M., Manos, K., e Katsionis, G. (2003). An evaluation agent that simulates students' behaviour in intelligent tutoring systems. In *IEEE International Conference on Systems, Man and Cybernetics, 2003*, volume 5, pages 4872–4877. IEEE, IEEE.
- Virvou, M. e Troussas, C. (2011). Web-based student modeling for learning multiple languages. In *Information Society (i-Society), 2011 International Conference on*. Dept. of Inf., Univ. of Piraeus, Athens, Greece.
- Vizcaino, A. e du Boulay, B. (2002). Using a simulated student to repair difficulties in collaborative learning. In *ICCE '02 Proceedings of the International Conference on Computers in Education*. ACM, IEEE Computer Society Washington, DC, USA.
- W3C (2010a). *Extensible Markup Language (XML)*, <http://www.w3.org/XML/>.
- W3C (2010b). *Resource Description Framework (RDF)*, <http://www.w3.org/RDF/>.
- W3C (2010c). *Web Ontology Language (OWL)*, <http://www.w3.org/2004/OWL/>.
- W3C (2010d). *XQuery 1.0: An XML Query Language*, <http://www.w3.org/TR/xquery/>.
- Walpole, R., Myers, R., Myers, S., e Ye, K. (2009). *Probabilidade e estatística para engenharia e ciências*. Oitava edição. Prentice Hall.

WebCT (2010). <http://www.webct.com/>.

Weber, G. e Brusilovsky, P. (2001). ELM-ART: An adaptive versatile system for Web-based instruction. *International Journal of Artificial Intelligence in Education*, 12(4):351–384.

Wu, H. (2002). *A Reference Architecture for Adaptive Hypermedia Applications*. PhD thesis, Eindhoven University of Technology.

Wu, H., De Kort, E., e De Bra, P. (2001). Design issues for general-purpose adaptive hypermedia systems. In *Proceedings of the 12th ACM Conference on Hypertext and Hypermedia*, pages 141–150. ACM.

Yannibelli, V., Godoy, D., e Amandi, A. (2006). A Genetic Algorithm Approach to Recognize Students' Learning Styles. *Interactive Learning Environments*, DOI: 10.1080/10494820600733565, 14(1):55–78.

Zaina, L., Bressan, G., Cardieri, M., e Rodrigues, J. (2012). e-lors: Uma abordagem para recomendação de objetos de aprendizagem. doi: 10.5753/rbie.2012.20.01.04. *Revista Brasileira de Informática na Educação*, 20(1).

Zakaria, M. R. e Brailsford, T. J. (2002). User Modeling and Adaptive Educational Hypermedia Frameworks for Education. *New Review of Hypermedia and Multimedia*, 1(8):83–97.

Zanchett, P., Dalfovo, O., e Crescêncio, T. (2004). Hipermídia adaptativa no sistema de aprendizagem para a maior idade. In *I Workshop de Computação da Região Sul*, pages 1–11.

Zatarain, R., Barrón-Estrada, L., Reyes-García, C., e Reyes-Galaviz, O. (2010). Applying Intelligent Systems for Modeling Students' Learning Styles Used for Mobile and Web-Based Systems. *Soft Computing for Intelligent Control and Mobile Robotics*, pages 3–22.

- Zatarain-Cabada, R., Barrón-Estrada, M., Zepeda-Sánchez, L., Sandoval, G., Osorio-Velazquez, J., e Urias-Barrientos, J. (2009). A Kohonen Network for Modeling Students' Learning Styles in Web 2.0 Collaborative Learning Systems. *MICAI 2009: Advances in Artificial Intelligence*, pages 512–520.
- Zhang, L., Zhang, X., Duan, Y., Fu, Z., e Wang, Y. (2010). Evaluation of Learning Performance of E-Learning in China: A Methodology Based on Change of Internal Mental Model of Learners. *Turkish Online Journal of Educational Technology-TOJET*, 9(1):13.

Apêndice A

Experimentos considerando $DEA=0$ no ME inicial

Os experimentos apresentados neste apêndice foram realizados considerando-se o ME inicial apresentado na Tabela A.1.

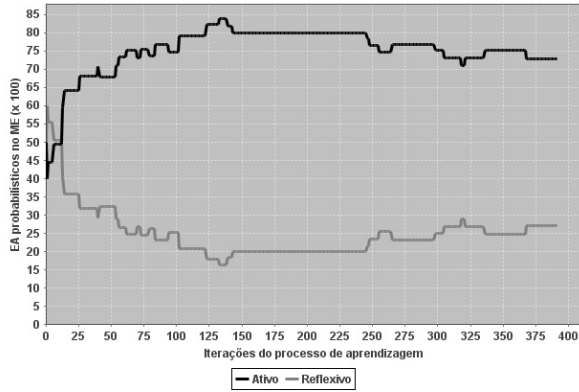
Tabela A.1: ME inicial

Estilos de Aprendizagem							
Processamento		Percepção		Entrada		Organização	
Ativo	Reflexivo	Sensitivo	Intuitivo	Visual	Verbal	Sequencial	Global
0,50	0,50	0,50	0,50	0,50	0,50	0,50	0,50
Estado Cognitivo e Objetivos de Aprendizagem							
$EC = \{\langle C0, -1 \rangle \dots \langle C59, -1 \rangle\}$							
$OA = \{\langle C0, 5 \rangle \dots \langle C59, 5 \rangle\}$							

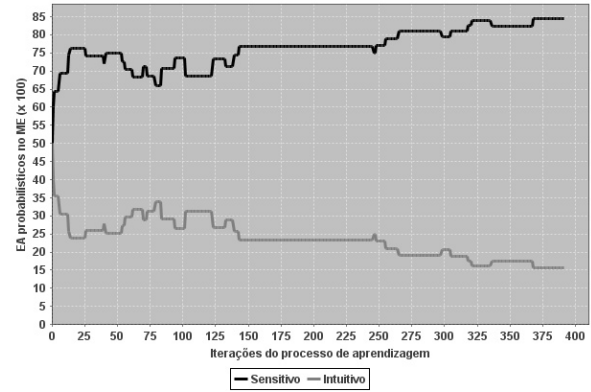
Para a realização destes experimentos, considerou-se o valor da performance mínima esperada $m = 60,0\%$ e a taxa de aprendizagem $\alpha = 0,5$. Pôde-se concluir através da análise gráfica que é mais rápido inferir corretamente um EA quando se tem $DEA = 0$ do que corrigir uma inconsistência pré-existente no ME. Ao se comparar os resultados obtidos nestes experimentos com aqueles apresentados no capítulo 5, percebe-se que sendo o ME inicialmente inconsistente, há um aumento na quantidade de iterações do processo de aprendizagem, devido ao aumento da dificuldade inicial do processo de aprendizagem.

A.1 Experimento 1

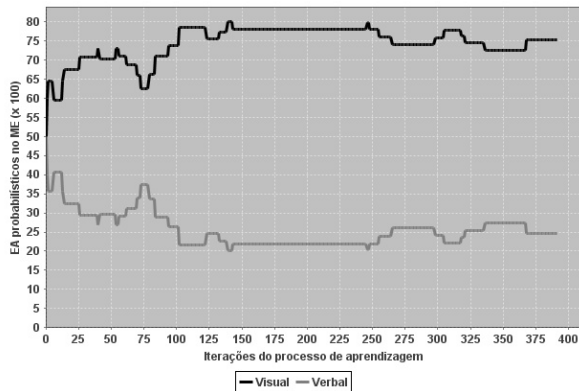
$$EA_r = \{Ativo(Forte), Sensitivo(Forte), Visual(Moderada), Sequencial(Leve)\}$$



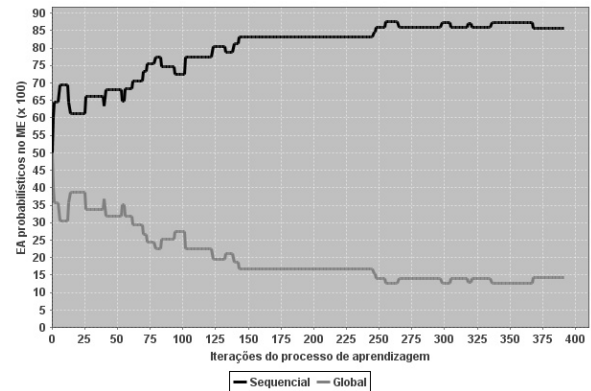
(a) Processamento



(b) Percepção



(c) Entrada



(d) Organização

Figura A.1: Atualização do ME no Experimento 1

Tabela A.2: Resultados do Experimento 1

Iterações	Prob. de Aprendizagem	EA _p			
399	39	(0,72; 0,28)	(0,84; 0,16)	(0,75; 0,25)	(0,85; 0,15)

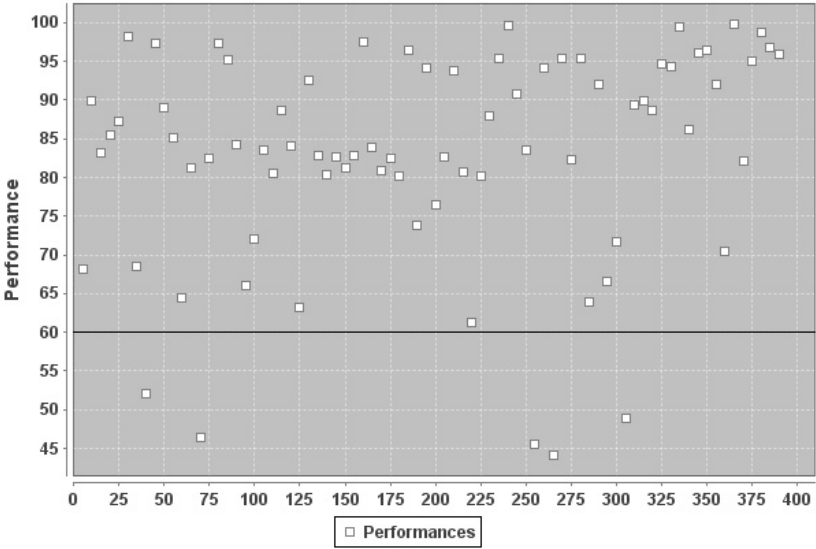


Figura A.2: Performances do estudante no Experimento 1

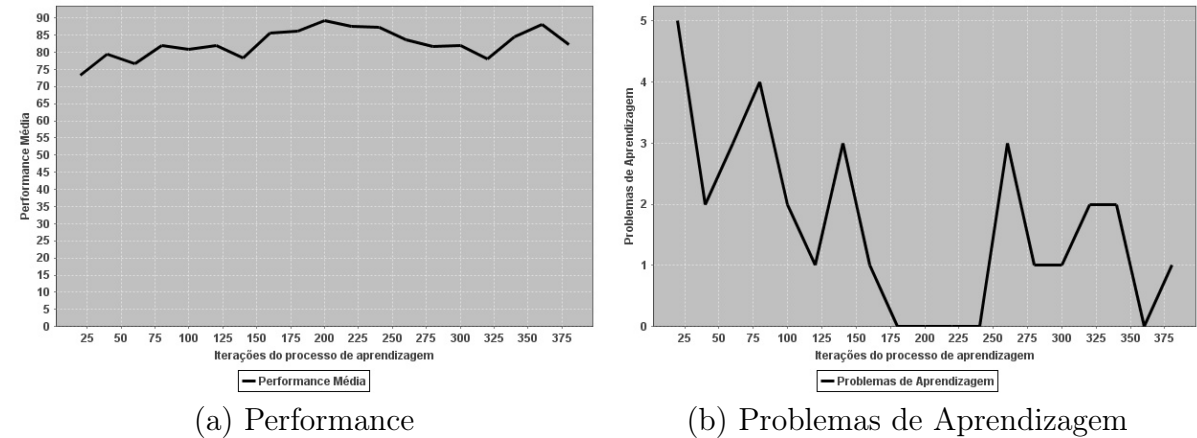
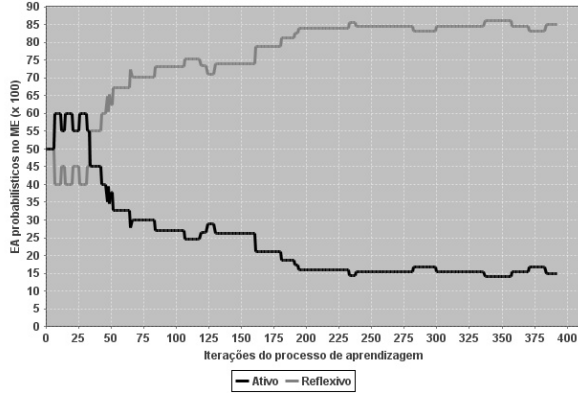


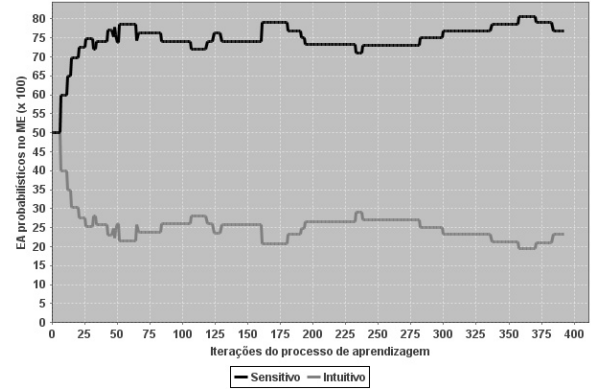
Figura A.3: Médias de performances e problemas de aprendizagem no Experimento 1

A.2 Experimento 2

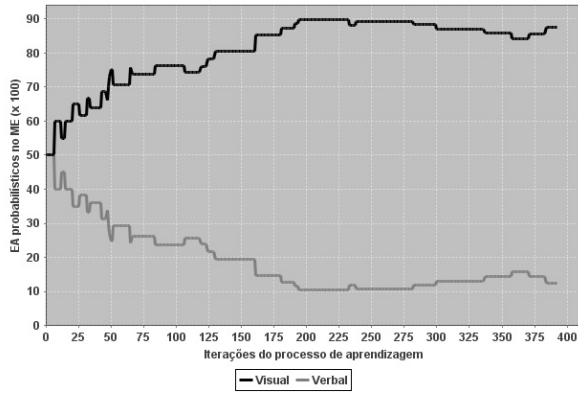
$$EA_r = \{Reflexivo(Forte), Sensitivo(Forte), Visual(Moderada), Sequencial(Leve)\}$$



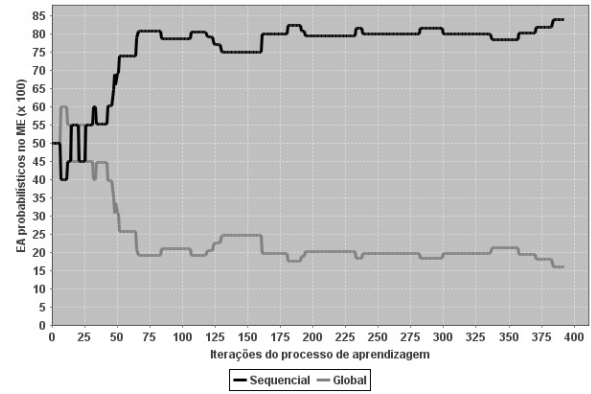
(a) Processamento



(b) Percepção



(c) Entrada



(d) Organização

Figura A.4: Atualização do ME durante Experimento 2

Tabela A.3: Resultados do Experimento 2

Iterações	Prob. de Aprendizagem	EA _p			
392	32	(0,14; 0,86)	(0,76; 0,24)	(0,87; 0,13)	(0,83; 0,17)

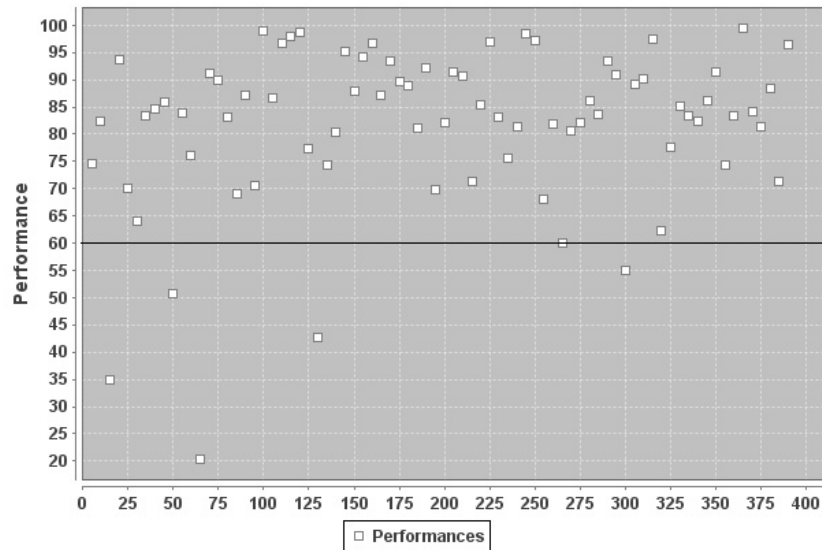


Figura A.5: Performances do estudante no Experimento 2

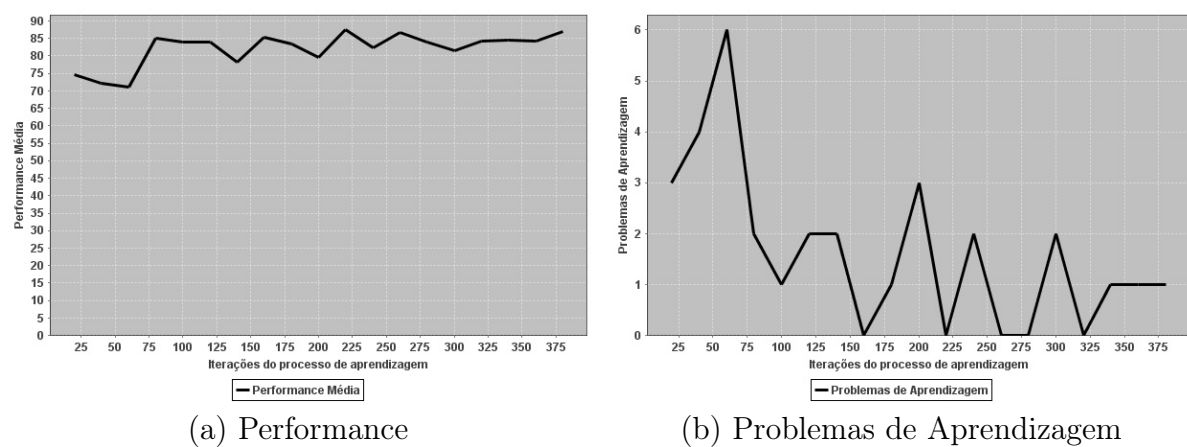


Figura A.6: Médias de performances e problemas de aprendizagem no Experimento 2