

Artigo publicado nos Anais do 23º Simpósio Brasileiro de Informática na Educação (SBIE 2012),
ISSN 2316-6533. Rio de Janeiro, 26-30 de Novembro de 2012

13

Avaliação de Políticas de Aprendizagem por Reforço para Modelagem Automática e Dinâmica de Estilos de Aprendizagem: Uma Análise Experimental

Fabiano A. Dorça^{1;2}

Luciano V. Lima²

Márcia A. Fernandes¹

Carlos R. Lopes¹

Resumo

Um grande número de estudos atesta que a aprendizagem é facilitada se as estratégias de ensino estiverem de acordo com os estilos de aprendizagem do estudante, tornando o processo de aprendizagem mais eficaz, e melhorando o seu desempenho. Nesse contexto, este trabalho apresenta uma abordagem automática e dinâmica para modelagem de estilos de aprendizagem com base em aprendizagem por reforço. Três estratégias de aprendizagem diferentes são propostas e testadas por meio de experimentos. Os resultados obtidos são apresentados e discutidos, indicando a estratégia mais eficiente.

Abstract

A huge number of studies attest that learning is facilitated if teaching strategies are in accordance with students learning styles, making the learning process more effective and improving students performances. In this context, this paper presents an automatic, dynamic and probabilistic approach for modeling students learning styles based on reinforcement learning. Three different strategies for updating the student model are proposed and tested through experiments. The results obtained are analyzed, indicating the most effective strategy.

¹Faculdade de Computação (FACOM) – Universidade Federal de Uberlândia (UFU)

² Faculdade de Engenharia Elétrica (FEELT) – Universidade Federal de Uberlândia (UFU)

1 Introdução

Um grande número de estudos atesta que a aprendizagem é facilitada se as estratégias pedagógicas estiverem de acordo com os estilos de aprendizagem (EA) do estudante, tornando o processo de aprendizagem mais efetivo, e melhorando consideravelmente a performance do estudante, conforme apontam (Graf *et al.*, 2008; Kinshuk *et al.*, 2009; Graf *et al.*, 2009).

Mas as abordagens tradicionais para detecção de EA se mostram ineficientes (Graf e Lin, 2007; Price, 2004). Neste sentido, abordagens automáticas tendem a ser mais precisas e menos suscetíveis a erros, já que permitem analisar dados resultantes de um intervalo de tempo, em vez de dados colhidos em um momento específico (Graf *et al.*, 2009). De acordo com (Giraffa, 1999), um modelo realista do estudante implica em uma atualização dinâmica enquanto o sistema avalia o desempenho do estudante.

Um problema com abordagens automáticas é a obtenção de informação suficientemente confiável para se construir um modelo do estudante (ME) robusto (Graf e Lin, 2007). Então a construção desse tipo de abordagem, fundamentada em um modelo probabilístico, é um importante problema em pesquisas (Danine *et al.*, 2006).

Nesse contexto, este trabalho apresenta uma abordagem automática, dinâmica e probabilística para modelagem de EA do estudante, e também avalia e compara, por meio de experimentos, três diferentes políticas de aprendizagem por reforço (AR) (Sutton e Barto, 1998) para atualização do ME, apontando claramente a política mais eficiente.

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). O Fslsm se destaca dos demais por combinar os principais modelos de EA, conforme alerta Kinshuk *et al.* (2009). Além disto, o Fslsm é o mais frequentemente utilizado na construção de sistemas adaptativos e inteligentes para educação (Saie) (Graf e Kinshuk, 2009).

As demais seções deste trabalho são descritas a seguir. A seção 2 apresenta o estado da arte e analisa alguns dos principais trabalhos relacionados. A seção 3 apresenta em detalhes a abordagem proposta e as diferentes políticas de aprendizagem implementadas e experimentadas. A seção 4 apresenta e analisa os resultados obtidos por meio de experimentos. Finalmente a seção 5 apresenta as conclusões e discute trabalhos futuros.

2 Trabalhos Relacionados

Alguns trabalhos recentes têm apresentado propostas para detecção automática de EA (Graf e Viola, 2009; Limongelli *et al.*, 2009). Essas propostas utilizam sistemas de inferência determinísticos baseados em padrões de comportamento pré-definidos do estudante, de forma que, por seu comportamento e ações no sistema, possam infe-

rir seus EAs. Graf *et al.* (2009) e Graf e Viola (2009) discutem padrões de comportamento considerados relevantes para identificação de cada EA.

Sistemas de inferência determinísticos, com base em padrões de comportamento pré-definidos, ignoram importantes considerações, apresentadas por Marzano e Kendall (2007), Messick (1976), Felder e Spurlin (2005), Roberts e Erdos (1993), relacionadas aos aspectos dinâmicos e não-determinísticos de EA e do comportamento do estudante. Nesse contexto, a abordagem apresentada neste trabalho apresenta avanços ao considerar, de forma probabilística, os EAs dos estudantes.

Algumas abordagens, como García *et al.* (2007), Carmona e Castillo (2008), Zatarain-Cabada *et al.* (2009), e Villaverde *et al.* (2006), utilizam técnicas de aprendizagem supervisionada de máquina, tais como redes Bayesianas e redes neurais. Uma crítica a essas abordagens é sua alta complexidade de implementação e grande consumo de recursos computacionais, de modo que a presença simultânea de vários estudantes pode comprometer ou mesmo inviabilizar seu uso.

Além disso, destaca-se aqui a elevada dificuldade e o alto grau de subjetividade na tarefa de se relacionar EA e os aspectos de comportamento que o identificam, conforme observa García *et al.* (2007). Conseqüentemente, a obtenção de pares de treinamento é, além de complexa, duvidosa, pois gera uma massa de dados com alto nível de incerteza, podendo conter inconsistências, o que pode resultar em treinamento equivocado da rede, comprometendo seriamente o processo de fornecimento de adaptabilidade.

Acredita-se que, nesse contexto, uma abordagem que aprenda de maneira não supervisionada, devido à sua própria natureza, elimina diversas dificuldades e problemas encontrados no processo de diagnóstico automático de EA. O fato da abordagem proposta neste trabalho ser fundamentada em AR, que tem como características fundamentais o aprendizado incremental e a não utilização de conhecimento específico do domínio de aplicação, torna o método mais geral e, portanto, mais facilmente reutilizável.

3 Abordagem Proposta

Na abordagem proposta, os EA dos estudantes são armazenados por meio de distribuições de probabilidades no ME, indicando as probabilidades de preferência por cada EA dentro de cada uma das quatro dimensões do Fslsm, chamados aqui de EA probabilísticos (EA_p). Então, tem-se um ME probabilístico em que EA são tratados pelo sistema como probabilidades, e não como certezas. A Tabela 1 apresenta um exemplo de EA_p no ME, representando um estudante que provavelmente é Reflexivo, Intuitivo, Verbal e Sequencial.

Tabela 1. Exemplo de Inicialização dos EA_p

Tabela 1. Exemplo de Inicialização dos EA_p

EA Probabilísticos (EA_p)							
Processamento		Percepção		Entrada		Organização	
Ativo	Reflexivo	Sensitivo	Intuitivo	Visual	Verbal	Sequencial	Global
0,28	0,72	0,09	0,91	0,45	0,55	0,82	0,18

Caso seja utilizado um questionário inicial para auto-avaliação de EA compatível com o Fslsm, como o Index of Learning Styles Questionnaire (Ilsq) (Felder e Spurlin, 2005), 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, dividindo-se a quantidade de respostas favoráveis a um EA pelo total de respostas dentro da dimensão (11 para cada dimensão, totalizando 44 questões no Ilsq). Caso nenhum questionário para a identificação inicial de EAs dos estudantes seja utilizado, todos os EA_p no ME são inicializados em 0,50 (preferência indefinida).

Os processos de modelagem automática e dinâmica dos EA_p do estudante, e de seleção das estratégias de ensino, reforço e remediação, são fundamentados na seleção dinâmica de uma combinação de estilos de aprendizagem (CEA) que defina uma ação pedagógica apropriada, a ser tomada em determinado momento. Uma CEA é uma tupla formada por quatro estilos de aprendizagem, cada um pertencente a uma dimensão do Fslsm, conforme apresenta a Definição 3.1.

Definição 3.1 Combinação de estilos de aprendizagem (CEA)

$CEA = (a, b, c, d) \mid a \in D1; b \in D2; c \in D3; d \in D4$
considerando:

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

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

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

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

Desse modo, existem 16 (2^4) possíveis CEAs. A cada seção de aprendizagem do curso, seleciona-se estocasticamente uma CEA, de acordo com sua probabilidade de preferência pelo estudante, dada por P, de acordo com (1). Consequentemente, a probabilidade da CEA (A, S, Vi, Seq) ser selecionada é dada por $P(A, S, Vi, Seq) = 0,28 \times 0,09 \times 0,45 \times 0,82$. A CEA selecionada define a estratégia pedagógica a ser adotada na apresentação do conteúdo do curso durante uma seção de aprendizagem.

$$P(a, b, c, d) = P_{ra} \times P_{rb} \times P_{rc} \times P_{rd} \quad (1)$$

Considera-se, então, que o estudante pode, com maior ou menor probabilidade, pertencer a qualquer uma das 16 categorias pedagógicas dadas pelas 16 CEAs. Então pode-se dizer que temos uma classificação probabilística e dinâmica dos estudantes, que estocasticamente se enquadram nessas categorias pedagógicas, ao longo do processo de aprendizagem, com maior ou menor probabilidade. Com isto, espera-se produzir um melhor tratamento da incerteza inerente à inferência da categoria pedagógica à qual um estudante pertence.

Nesse contexto, apresenta-se, a seguir, os componentes relacionados à aplicação de AR na modelagem de EA:

- *Estados (S)*: Valores de EA_p e nível cognitivo armazenados no ME;
- *Ações (A)*: Ações que o sistema pode executar, com intuito de ensinar o conteúdo, maximizando a qualidade da performance do estudante, durante o processo de aprendizagem, ou seja, as CEAs dadas pela Definição 3.1;
- *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 ($R : S \times A \rightarrow <$)*: Essa função define os sinais de reforço a serem aplicados no aprendizado das melhores CEAs para um estudante, dada por (2);
- *Função valor-ação, ou ganho ($Q : S \times A \rightarrow <$)*: Esta função estima a utilidade de se adotar determinada CEA (ação), considerando determinado estado (EA_p), fornecendo um método de avaliação para as ações do sistema. Esta função é dada por (1), e associa uma ação a um número real, denominado ganho, e estima quão boa determinada CEA é em determinado estado.

O sinal de reforço é calculado em função da qualidade da performance (PFM) obtida pelo estudante na seção de aprendizagem, de acordo com (2). O reforço é inversamente proporcional à performance, já que, 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 contrapartida, deseja-se que, quanto maior a distância entre estilos de aprendizagem (DEA) em uma dimensão, menor o reforço, para que se possa evitar reforços abruptos em EA_p já consideravelmente fortes, e, ao mesmo tempo, possibilitar um reforço maior, quando a DEA se aproximar de 0 (preferência indefinida). O valor de PFM é considerado no intervalo real $[0,100]$ e o valor da DEA é considerado no intervalo real $[0,1]$. Um limite R_{max} é imposto ao valor do reforço, com intuito de impedir que reforços demasiadamente grandes sejam aplicados quando a DEA ou PFM tender a 0.

$$R = \frac{1}{PFM \times DEA} \quad (2)$$

Para decidir como os EA_p do estudante devem ser atualizados, leva-se em consideração a CEA aplicada durante uma seção de aprendizagem. Foram testadas três políticas:

- *política 01*: os EA_p presentes na CEA são reforçados sempre que o estudante obtiver uma performance considerada *satisfatória*.
- *política 02*: os EA_p presentes na CEA são reforçados sempre que o estudante obtiver uma performance sa-

tisfatória, e são decrementados (reforço negativo) sempre que o estudante obtiver uma performance considerada *insatisfatória*;

- *política 03*: os EA_p presentes na CEA são decrementados (reforço negativo) sempre que o estudante obtiver uma performance considerada *insatisfatória*.

O algoritmo 3.1 implementa o processo de AR com base no *Q-learning* (Sutton e Barto, 1998), e leva em consideração a definição dos componentes de AR no domínio de Saie, conforme apresentado anteriormente. O algoritmo 3.1 é executado a cada seção de aprendizagem, até que sejam atingidos todos os objetivos de aprendizagem do estudante.

Algoritmo 3.1 *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 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 (2);

 Atualize os EA_p ;

 Faça de s o próximo estado, dado pelo ME atualizado;

end while

A cada iteração do algoritmo, 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.

Sabe-se que uma diversidade de aspectos pode envolver a avaliação de aprendizagem e desempenho do estudante em Saie. Dessa maneira, com o intuito de se testar a abordagem proposta neste capítulo, isolando-se toda essa complexidade, foi desenvolvido um modelo probabilístico para simular o processo de aprendizagem e performance do estudante levando em consideração alguns aspectos relacionados ao impacto dos EAs no processo de aprendizagem (Graf *et al.*, 2008; Kinshuk *et al.*, 2009; Graf e Liu, 2008).

4 Verificação e Validação da Abordagem Proposta

A fim de analisar e comparar as três políticas para atualização do ME, apresentadas na seção anterior, foram

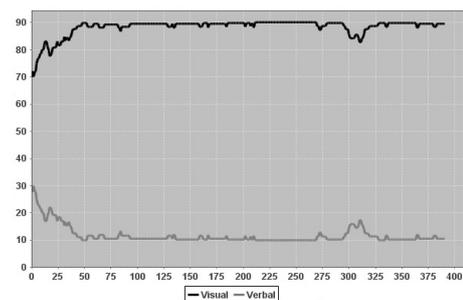
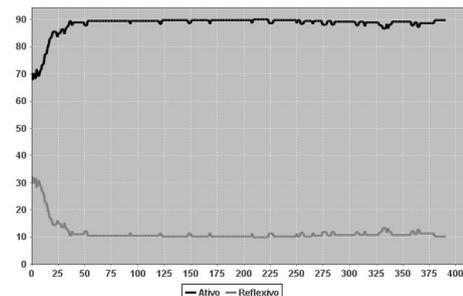
observadas e analisadas duas variáveis nos experimentos (considerando-se 10 execuções consecutivas de cada experimento):

- *consistência*: os EA_p efetivamente convergem para os EA_r (estilos de aprendizagem reais do estudante) 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?

Entende-se que 10 execuções consecutivas de cada experimento é suficiente para que se possa observar e analisar o comportamento, a consistência e eficiência de cada uma das políticas propostas, a fim de compará-las. Para cada experimento, apresenta-se graficamente o processo de atualização dos EA_p em sua primeira execução. 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.

Para a realização dos experimentos apresentados nesta seção, considera-se um estudante com $EA_r = \{\text{Reflexivo (Forte), Intuitivo (Forte), Verbal (Moderada), Global (Leve)}\}$. Os EA_p do estudante são inicializados de forma inconsistente com os EA_r , em todas as dimensões, com distribuições de probabilidades (0,70; 0,30). A Figura 1 apresenta graficamente a atualização dos EA_p no ME, durante a primeira execução do experimento, considerando a política 01 para atualização dos EA_p . Como se pode notar, as inconsistências foram reforçadas, em vez de serem corrigidas, demonstrando a ineficiência dessa política.



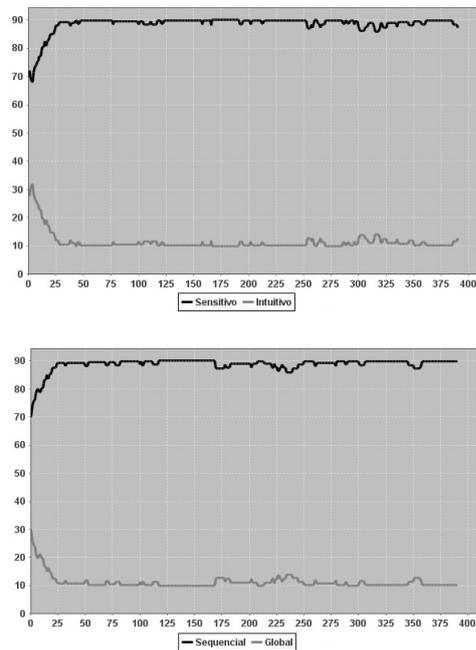


Figura 1. Atualização do ME utilizando a política 01

A Tabela 2 apresenta o número de iterações ocorridas em 10 execuções consecutivas desse experimento, utilizando-se a política 01 para atualização dos EA_p , além da quantidade de problemas de aprendizagem ocorridos (quando $PFM < 60$), e os EA_p armazenados no ME, ao final do processo de aprendizagem. Os EA_p destacados em vermelho não foram corrigidos durante o processo de aprendizagem, permanecendo inconsistentes no ME. Conclui-se, então, que essa política é extremamente ineficiente na modelagem de EA.

A Figura 2 apresenta graficamente a atualização dos EA_p no ME, durante a primeira execução desse experimento, considerando a política 02 para atualização dos EA_p . Como se pode perceber, apenas três preferências foram corretamente detectadas, permanecendo ainda a dimensão sensitivo-intuitivo inconsistente no ME.

A Tabela 3 apresenta os resultados obtidos em 10 execuções consecutivas desse experimento, utilizando a política 02. Os EA_p destacados em vermelho não foram corrigidos durante o processo de aprendizagem, permanecendo inconsistentes no ME. Pode-se notar um nível de consistência melhor nesses resultados, em relação aos resultados obtidos por meio da política 01. Nota-se uma redução acentuada no número de problemas de aprendizagem ocorridos, resultando na redução do número de iterações do processo de aprendizagem, o que denota um ganho de eficiência dessa política em relação à política 01.

Tabela 2. Atualização do ME utilizando a política 02

N.	Iterações	Prob. de Aprendizagem	EA_p
1	390	210	{(0,9;0,1); (0,9;0,1); (0,9;0,1); (0,9;0,1)}
2	298	118	{(0,9;0,1); (0,1;0,9); (0,9;0,1); (0,9;0,1)}
3	299	119	{(0,9;0,1); (0,9;0,1); (0,1;0,9); (0,9;0,1)}
4	322	142	{(0,1;0,9); (0,9;0,1); (0,9;0,1); (0,9;0,1)}
5	317	137	{(0,9;0,1); (0,9;0,1); (0,9;0,1); (0,1;0,9)}
6	381	201	{(0,9;0,1); (0,9;0,1); (0,9;0,1); (0,9;0,1)}
7	407	227	{(0,9;0,1); (0,9;0,1); (0,9;0,1); (0,9;0,1)}
8	404	224	{(0,9;0,1); (0,9;0,1); (0,9;0,1); (0,9;0,1)}
9	429	249	{(0,9;0,1); (0,9;0,1); (0,9;0,1); (0,9;0,1)}
10	374	194	{(0,9;0,1); (0,9;0,1); (0,9;0,1); (0,9;0,1)}
Média	377,5	197,5	-

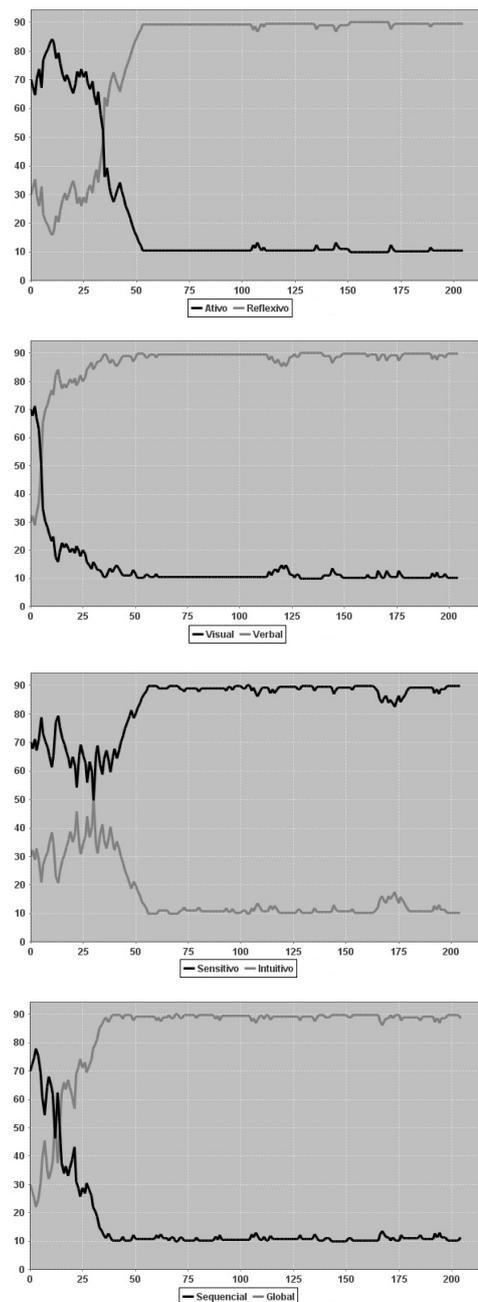


Figura 2. Atualização do ME utilizando a política 02

A Figura 3 apresenta graficamente a atualização dos EA_p no ME, durante a primeira execução desse experimento, considerando a política 03. Como se pode perceber, todas as inconsistências foram corrigidas nos EA_p do

estudante, demonstrando a eficácia dessa política em relação às demais.

A Tabela 4 apresenta os resultados obtidos nesse experimento, utilizando a política 03. Como se pode observar, todas as inconsistências nos EA_p foram eficientemente eliminadas. Nota-se uma redução no número de problemas de aprendizagem ocorridos, resultando na redução do número de iterações do processo de aprendizagem, o que denota um ganho de eficiência desta política em relação à política 02.

Tabela 3. Resultados obtidos utilizando a política 02

N.	Iterações	Prob. de Aprendizagem	EA_p
1	204	24	{(0,1;0,9); (0,9;0,1); (0,1;0,9); (0,1;0,9)}
2	206	26	{(0,1;0,9); (0,9;0,1); (0,1;0,9); (0,1;0,9)}
3	189	9	{(0,1;0,9); (0,1;0,9); (0,1;0,9); (0,1;0,9)}
4	215	35	{(0,1;0,9); (0,9;0,1); (0,1;0,9); (0,1;0,9)}
5	191	11	{(0,1;0,9); (0,1;0,9); (0,1;0,9); (0,1;0,9)}
6	211	31	{(0,9;0,1); (0,1;0,9); (0,1;0,9); (0,1;0,9)}
7	206	26	{(0,1;0,9); (0,1;0,9); (0,9;0,1); (0,1;0,9)}
8	210	30	{(0,9;0,1); (0,1;0,9); (0,1;0,9); (0,1;0,9)}
9	207	27	{(0,1;0,9); (0,1;0,9); (0,8;0,2); (0,1;0,9)}
10	205	25	{(0,1;0,9); (0,1;0,9); (0,1;0,9); (0,9;0,1)}
Média	206	26	-

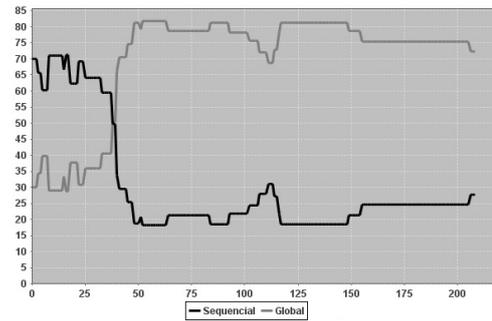


Figura 3. Atualização do ME utilizando a política 03

N.	Iterações	Prob. de Aprendizagem	EA_p
1	208	28	{(0,2;0,8); (0,1;0,9); (0,1;0,9); (0,3;0,7)}
2	204	24	{(0,2;0,8); (0,1;0,9); (0,2;0,8); (0,3;0,7)}
3	213	33	{(0,2;0,8); (0,2;0,8); (0,2;0,8); (0,1;0,9)}
4	206	26	{(0,1;0,9); (0,2;0,8); (0,2;0,8); (0,2;0,8)}
5	201	21	{(0,2;0,8); (0,2;0,8); (0,2;0,8); (0,2;0,8)}
6	204	24	{(0,2;0,8); (0,2;0,8); (0,2;0,8); (0,1;0,9)}
7	210	30	{(0,1;0,9); (0,2;0,8); (0,2;0,8); (0,3;0,7)}
8	196	16	{(0,1;0,9); (0,2;0,8); (0,2;0,8); (0,2;0,8)}
9	200	20	{(0,2;0,8); (0,1;0,9); (0,1;0,9); (0,2;0,8)}
10	198	18	{(0,2;0,8); (0,3;0,7); (0,1;0,9); (0,3;0,7)}
Média	204	24	-

Tabela 4. Resultados obtidos utilizando a política 03

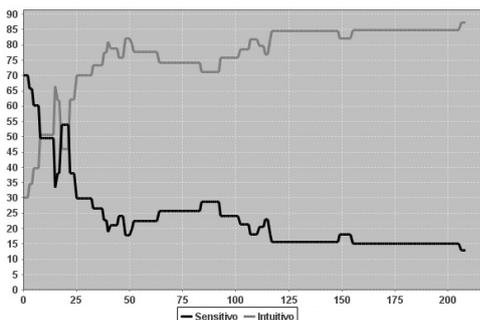
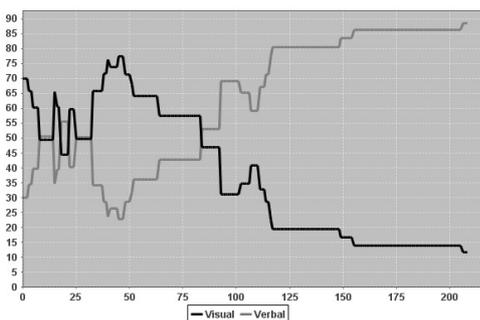
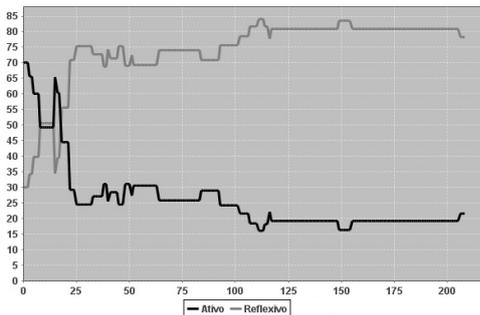
5 Conclusão

Acredita-se que os resultados dos experimentos apresentados mostram a eficiência e eficácia da abordagem proposta pela utilização da política 03 para atualização do ME, e permitem considerá-la promissora na implementação de novos Saie e na agregação de adaptatividade a sistemas 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 por meio de um modelo estocástico fundamentado em CEA, corrigindo-se automaticamente inconsistências entre o desempenho do estudante e suas preferências, que são dinâmicas e podem variar ao longo do tempo e em diferentes circunstâncias.

Encontra-se em andamento a integração da abordagem proposta ao Moodle (Moodle 2010), para que se possa realizar experimentos com estudantes reais em um ambiente capaz de fornecer adaptatividade com base em EA dos estudantes. Para isto, tem-se trabalhado na recuperação automática de objetos de aprendizagem na *web*, a partir de repositórios, levando-se em consideração características específicas de EA na análise de metadados dos objetos. Nesse contexto, a abordagem apresentada neste trabalho pode ser útil na seleção das estratégias de ensino, reforço e remediação. Desse modo, um trabalho já em execução é a discussão detalhada sobre a aplicabilidade e integração da abordagem apresentada em ambientes de aprendizagem.

Agradecimento

Agradecemos à Fapemig, Fundação de Amparo à Pesquisa do Estado de Minas Gerais, pelo apoio financeiro concedido a este trabalho.



Referências

- CARMONA, C.; CASTILLO, G. Designing a Dynamic Bayesian Network for Modeling Students Learning Styles. In *Eighth IEEE International Conference on Advanced Learning Technologies*, p. 346–350, 2008.
- DANINE, A.; LEFEBVRE, B.; MAYERS, A.. Tides-using bayesian networks for student modeling. In: *Proceedings of the Sixth International Conference on Advanced Learning Technologies (ICALT'06)*. IEEE Computer Society, 2006.
- FELDER, R.; SILVERMAN, L. Learning and teaching styles in engineering education. *Journal of Engineering education*, 78(7):674–681, 1988.
- FELDER, R.; SPURLIN, J. Applications, reliability and validity of the index of learning styles. *International Journal of Engineering Education*, 21(1):103–112, 2005.
- GARCÍA P. *et al.*. Evaluating Bayesian networks' precision for detecting students' learning styles. *Computers & Education*, 49(3):794–808, 2007.
- GIRAFFA, L. . *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, 1999.
- GRAF, S.; KINSHUK. 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*, p. 235–238, 2009. IEEE Computer Society.
- GRAF, S.; KINSHUK; LIU, T. . 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, 2009.
- GRAF, S.; LIN, T. Analysing the Relationship between Learning Styles and Cognitive Traits. In *Advanced Learning Technologies, 2007. ICALT 2007*. Seventh IEEE International Conference, p. 235–239. IEEE.
- GRAF, S.; LIU, T. Identifying Learning Styles in Learning Management Systems by Using Indications from Students' Behaviour. In: *Advanced Learning Technologies, 2008. ICALT'08. Eighth IEEE International Conference*, p. 482–486. IEEE, 2008.
- GRAF, S.; LIU, T. C.; KINSHUK. 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)*, p. 223–230. IADIS International Conference.
- GRAF, S.; VIOLA, S. Automatic student modelling for detecting learning style preferences in learning management systems. Citeseer, 2009.
- KINSHUK; LIU, T.; GRAF, S. Coping with Mismatched Courses: Students' behaviour and performance in courses mismatched to their learning styles. *Educational Technology Research and Development*, 57(6):739–752, 2009.
- LIMONGELLI, C.; *et al.* Adaptive learning with the LS-plan system: a field evaluation. *IEEE Transactions on Learning Technologies*, p. 203–215, 2009.
- MARZANO, R.; KENDALL, J. *The new taxonomy of educational objectives*. Corwin Pr, 2007.
- MESSICK, S. Personal styles and educational options. *Individuality in learning*, p. 327–368, 1976.
- Moodle (2010). <<http://www.moodle.org/>>.
- PRICE, L. Individual differences in learning: Cognitive control, cognitive style, and learning style. *Educational Psychology*, 24(5):681–698, 2004.
- ROBERTS, M.; ERDOS, G. Strategy selection and metacognition. *Educational Psychology*, 13(3):259–266, 1993.
- SUTTON, R.; BARTO, A. *Reinforcement learning: An introduction*, volume 116. Cambridge Univ Press, 1998.
- VILLAVERDE, J.; GODOY, D.; AMANDI, A. Learning Styles' Recognition in elearning Environments with Feed-Forward Neural Networks. *Journal of Computer Assisted Learning*, vl. 22(3):197–206, 2006.
- ZATARAIN-CABADA, R.; *et al.* A Kohonen Network for Modeling Students' Learning Styles in Web 2.0 Collaborative Learning Systems. *MICAI 2009: Advances in Artificial Intelligence*, p. 512–520, 2009.