

# Simulação de Aprendizagem em Estudantes como Ferramenta para Minimização de Custos na Avaliação de Novas Abordagens em Sistemas Adaptativos e Inteligentes para Educação a Distância: Uma Análise Experimental

Fabiano A. Dorça<sup>1,2</sup>, Luciano V. Lima<sup>2</sup>, Márcia A. Fernandes<sup>1</sup>, Carlos R. Lopes<sup>1</sup>

<sup>1</sup>Faculdade de Computação (FACOM) – Universidade Federal de Uberlândia (UFU)

<sup>2</sup>Faculdade de Engenharia Elétrica (FEELT) – Universidade Federal de Uberlândia (UFU)

{fabiano,marcia,crlopes}@facom.ufu.br, vieira@ufu.br

**Resumo.** *A modelagem automática de estilos de aprendizagem do estudante em sistemas adaptativos e inteligentes para educação é uma área de pesquisa em crescimento, e caracteriza um grande desafio em Informática na Educação. Uma dificuldade, neste caso, está em experimentar, avaliar e validar novas abordagens para modelagem automática do estudante antes destas serem efetivamente implantadas em sistemas adaptativos e inteligentes para educação. Desta forma, este trabalho apresenta uma abordagem para a avaliação desses sistemas, com foco na simulação da aprendizagem em estudantes com base em seus estilos de aprendizagem e de como o sistema educacional os atende ao longo do curso. Como resultado deste trabalho, obteve-se a experimentação e validação de uma nova abordagem para modelagem automática de estilos de aprendizagem num curto espaço de tempo e sem qualquer custo.*

**Abstract.** *The automatic detection of learning styles in adaptive and intelligent educational systems is a growing research area. One difficulty in this case is to experiment, evaluate and validate new approaches to automatic student modeling, before they are actually deployed in adaptive and intelligent educational systems. In this way, in this paper we present a novel approach for the evaluation of these systems, which relies on simulating the performance of real students based on their learning styles and on how the system attends to them. The result of the present research work has led to considerable enhancements to a component for automatic modeling of learning styles, which has been tested, corrected and improved in a short time and without any cost.*

**Palavras-chave** - simulação computacional, experimentação de modelos computacionais, sistemas adaptativos e inteligentes para educação, modelagem do estudante, estilos de aprendizagem.

*Este trabalho contou com o suporte da FAPEMIG, Fundação de Amparo à Pesquisa do Estado de Minas Gerais.*

## 1. Introdução

Um grande número de estudos atestam que o processo de aprendizagem é facilitado se as estratégias de ensino estiverem de acordo com os estilos de aprendizagem (EA)

dos estudantes. Isto torna o processo de aprendizagem mais efetivo, e melhorando consideravelmente as performances dos estudantes, como apontam [Haider et al. 2010, Graf et al. 2008, Kinshuk et al. 2009, Graf e Liu 2008, Bajraktarevic et al. 2003].

Desta forma, um desafio em pesquisas na área de Informática na Educação (IE) tem sido o de melhorar o processo de modelagem de EA em sistemas adaptativos e inteligentes para educação (SAIE). Então, abordagens automáticas para detecção de EA tem sido propostas. Tais abordagens possibilitam a eliminação do uso de questionários psicométricos de auto-avaliação de EA. O uso de tais questionários apresentam problemas, conforme apontam [Price 2004, Castillo et al. 2005]. Consequentemente, é imperativo que abordagens mais eficientes com este fim sejam propostas.

Neste contexto, outro grande desafio em pesquisas na área de IE é possibilitar que as novas abordagens propostas sejam testadas e avaliadas de forma consistente antes de serem efetivamente implantadas em um SAIE. Desta forma, pode-se garantir a eficiência e eficácia do processo de ensino e aprendizagem.

Diante disto, técnicas de simulação computacional são essenciais e podem contribuir muito na experimentação de novas abordagens no processo de ensino. Isto porque testar este tipo de sistema requer quantia considerável de recursos humanos (tutores e alunos), financeiros (infra-estrutura e produção de material) e tempo (um curso a distância tende a durar meses). Além disto, o teste e validação destes sistemas torna-se cada vez mais crítico, se considerarmos que a demanda por este tipo de sistemas cresce rapidamente, e o número de estudantes que dependem deles tem aumentado consideravelmente [Graf et al. 2009].

Alguns trabalhos, como [Abdullah e Cooley 2002, Vanlehn et al. 1994, Vizcaino e du Boulay 2002, Virvou et al. 2003, Bravo e Ortigosa 2006, Mertz 1997], propõem diferentes abordagens para simulação de estudantes na avaliação de SAIE. Porém, nenhum destes trabalhos levam em consideração os EA do estudante no processo de simulação.

Considerando este cenário, este trabalho apresenta um modelo cognitivo para simulação da aprendizagem em estudantes considerando EA e a forma como o sistema educacional os atende. Este modelo foi utilizado na experimentação e validação de uma nova abordagem para modelagem automática e dinâmica de EA, proposta em [Dorça et al. 2011, Dorça et al. 2013]. O modelo concebido é probabilístico, e leva em consideração resultados de estudos sobre como EA afetam a performance dos estudantes [Haider et al. 2010, Graf et al. 2008, Kinshuk et al. 2009, Graf e Liu 2008, Bajraktarevic et al. 2003].

O uso de simulação computacional neste processo foi de fundamental importância, pois possibilitou a correção de problemas e melhorias no sistema. Além disto, permitiu avaliações rápidas do sistema fossem feitas desde o início de sua concepção, resultando em ajustes e correções de problemas ao longo do seu desenvolvimento, enquanto um único teste com estudantes reais levaria meses. Desta forma, a simulação computacional é uma técnica largamente utilizada para testar sistemas educacionais, e pode trazer vantagens, conforme apontam [Abdullah e Cooley 2002, Vanlehn et al. 1994, Vizcaino e du Boulay 2002, Virvou et al. 2003, Bravo e Ortigosa 2006, Mertz 1997].

É importante destacar que este artigo tem por objetivo apresentar uma abor-

dagem para a avaliação desses sistemas, com foco principal na simulação da aprendizagem em estudantes com base em seus estilos de aprendizagem e de como o sistema educacional os atende ao longo do curso. Desta forma, não é foco deste trabalho apresentar a abordagem para modelagem de EA, já descrita detalhadamente em [Dorça et al. 2011, Dorça et al. 2013]. Alguns aspectos importantes sobre EA, e que dão embasamento teórico ao modelo computacional apresentado neste trabalho também compõem o escopo principal deste trabalho. A seção 2 apresenta detalhes de implementação do processo de simulação de aprendizagem em estudantes, considerando seus EA. A seção 3 apresenta e analisa alguns experimentos e seus resultados. A seção 4 apresenta conclusões e trabalhos futuros.

## **2. Modelo cognitivo para simulação da aprendizagem em estudantes baseado em estilos de aprendizagem**

Esta seção descreve inicialmente, de forma breve, um sistema para detecção automática de EA. Em seguida, detalha o modelo cognitivo para simulação da performance de estudantes que foi utilizado para testá-lo, que é o foco deste trabalho. O sistema para detecção automática de EA proposto por [Dorça et al. 2011] é baseado no *Felder and Silverman Learning Styles Model* (FSLSM) [Felder e Silverman 1988]. O FSLSM descreve EA em mais detalhes [Graf e Kinshuk 2009] [Graf e Kinshuk 2010], 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.

Neste sistema, a preferência por cada EA é armazenada no modelo do estudante (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 os EA são tratados pelo sistema como probabilidades, e não como certezas. Detalhes desta abordagem são apresentados no trabalho de [Dorça et al. 2011].

Com base neste modelo de probabilidades, a cada seção de aprendizagem do curso o sistema gera uma combinação de estilos de aprendizagem (CEA) cujos EA são combinados de acordo com as probabilidades de preferência de EA armazenados no ME. Considerando as 4 dimensões do FSLSM tem-se 16 possíveis CEAs. 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. Tais preferências podem estar inconsistentes ou variar ao longo do tempo em decorrência de algum aspecto, conforme discutido anteriormente. Por isto, ao longo do curso os  $EA_p$  são atualizados através de um sistema baseado em aprendizagem por reforço, conforme descrito por [Dorça et al. 2013].

O modelo cognitivo para simulação da aprendizagem em estudantes baseado em EA, apresentado adiante, considera importantes aspectos relacionados ao impacto de EA no processo de aprendizagem [Haider et al. 2010, Graf et al. 2008, Kinshuk et al. 2009, Graf e Kinshuk 2009, 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,

Vasilyeva et al. 2006].

O principal aspecto deste modelo é que quando os estilos de aprendizagem reais ( $EA_r$ ) de um estudante são atendidos pela CEA selecionada, o processo de aprendizagem tende a se tornar mais fácil, e a probabilidade de sucesso é maior. Desta forma, este modelo considera um aumento na dificuldade quando os  $EA_r$  do estudante não são atendidos pelo sistema. Então, o modelo infere o grau de dificuldade a ser enfrentado pelo estudante durante uma seção de aprendizagem elevando a probabilidade de falha. Considera-se ainda que o processo de aprendizagem é não-determinístico, e pode ser influenciado por muitos fatores além dos EA, de forma que um processo de ensino inadequado pode contribuir para a ocorrência de falha, mas não pode determiná-la. Alguns destes fatores são apontados por [Al-Dujaily e Ryu 2006, Lim et al. 2007, Santos e Boticario 2008, Mosakhani e Jamporzmay 2010]. Neste caso, os estilos de aprendizagem reais são aqueles que efetivamente guiam o comportamento do estudante, e não aqueles que estão no ME, que podem estar inconsistentes em relação aos  $EA_r$ .

Outro aspecto importante do modelo é que preferências fortes produzem efeitos negativos mais notórios no processo de aprendizagem quando não são satisfeitas, conforme atestam [Felder e Silverman 1988, Haider et al. 2010, Graf et al. 2008, Kinshuk et al. 2009]. Neste contexto, o modelo calcula a quantidade de divergências ( $d$ ) entre os  $EA_r$  do estudante e a CEA selecionada pelo sistema, e a utiliza no cálculo de um fator de dificuldade ( $D$ ) dado por (1).

$$D = d + \beta + \gamma \quad (1)$$

tal que:

- $d$  é a quantidade de divergências entre a CEA selecionada e os  $EA_r$  do estudante, estando no intervalo [0,4].
- $\beta$  é avaliado como um número aleatório entre [0,1] sempre que uma preferência forte do estudante não for satisfeita pelo sistema. Caso contrário, seu valor é 0.
- $\gamma$  é avaliado como um número aleatório entre [0,  $1 - \beta$ ] sempre que uma preferência moderada do estudante não for satisfeita pelo sistema. Caso contrário, seu valor é 0.

Preferências leves ou balanceadas não elevam o fator de dificuldade. Desta forma,  $\beta$  and  $\gamma$  permitem ao modelo considerar a força das preferências e sua influência no processo de aprendizagem [Felder e Silverman 1988, Haider et al. 2010, Graf et al. 2008, Kinshuk et al. 2009]. O fator de dificuldade  $D$  é utilizado no cálculo da performance  $PFM$  do estudante, conforme apresenta (2), estando seu valor no intervalo [0,100].

$$PFM = M - (D \times K \times \alpha) \quad (2)$$

tal que:

- $M$  é o valor máximo da performance, neste caso  $M = 100$ .
- $D$  é o fator de dificuldade dado por (1), cujo valor está no intervalo [0,5]
- $K$  é uma constante, e possibilita que o valor de PFM seja 0 se  $D$  e  $\alpha$  assumirem seus valores máximos. Desta forma,  $K = 20$

- $\alpha$  é um multiplicador, dado por um número aleatório no intervalo  $[0,1]$ , e representa um fator de dificuldade não determinístico, considerando-se que não apenas EA, mas outros fatores exercem influência na performance do estudante, conforme mencionado anteriormente.

Desta forma, este modelo permite inferir a performance de estudantes em um ambiente simulado, e conseqüentemente a evolução do nível cognitivo, de forma probabilística, em um processo de ensino-aprendizagem, criando o ambiente propício para experimentação de novos SAIE, no que tange à modelagem de EA do estudante e ao fornecimento de experiências de ensino personalizadas, considerando adaptatividade baseada em EA. É particularmente interessante conseguir conhecer o comportamento e funcionamento destes novos sistemas antes de testá-los com estudantes reais, o que torna o processo todo mais complexo.

Como resultado da utilização deste modelo, 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 na próxima seção. Desta forma, conseguiu-se analisar o comportamento do sistema para detecção automática de EA, demonstrando-se que os  $EA_p$  convergem eficientemente em direção aos  $EA_r$  ao interagir com estudantes simulados com diferentes características.

### 3. Experimentação

Esta seção apresenta um experimento, em que considerou-se o valor da performance mínima esperada  $m = 60,0\%$  (padrão adotado na maioria dos processos de ensino). Foi considerado um conjunto de 30 conceitos a serem aprendidos pelo estudante simulado, considerando que seu nível cognitivo inicial, em todos os conceitos, equivalente ao primeiro nível da Taxonomia de Bloom [Starr et al. 2008]. Como objetivos de aprendizagem em todos os conceitos considerou-se o último nível desta taxonomia. A execução de um experimento é finalizada quando o estudante atinge todos os objetivos de aprendizagem especificados. Desta forma, o nível cognitivo do estudante evolui por seis níveis, dispostos em uma hierarquia, do menos complexo para o mais complexo. Portanto, o processo de aprendizagem simulado nesses experimentos deve ter, pelo menos, 180 sessões de aprendizagem (ou iterações) a fim de alcançar todas as metas de aprendizagem (30 conceitos  $\times$  6 níveis cognitivos em cada conceito = 180).

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, ou seja, a consistência dos MEs obtidos em relação às preferências reais do estudante.

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.

Este experimento considerou um estudante com  $EA_p$  apresentados na Tabela 1.

**Tabela 1.**  $EA_p$

$LS_p$							
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

O  $EA_r$  do estudante considerado é:

$EA_r = \{Reflexivo(forte), Intuitivo(forte), Verbal(moderado), Global(leve)\}$ . Considerando este estudante, o  $EA_p$  inicial apresentado na Tabela 1 é inconsistente em suas 4 dimensões. A Figura 1 apresenta graficamente o processo de atualização do  $EA_p$  durante a primeira execução deste experimento. É importante notar que o  $EA_p$  se tornou consistente com o  $EA_r$  em todas as suas dimensões, satisfazendo os aspectos de consistência e eficiência.

A Figura 2 apresenta a performance média alcançada pelo estudante e a média de problemas de aprendizagem a cada 20 iterações do processo. Pode-se perceber que mesmo quando o  $EA_p$  é consistente com o  $EA_r$  (ou seja,  $d = 0$ ), problemas de aprendizagem podem ocorrer, já que outros fatores exercem influência na performance do estudante.



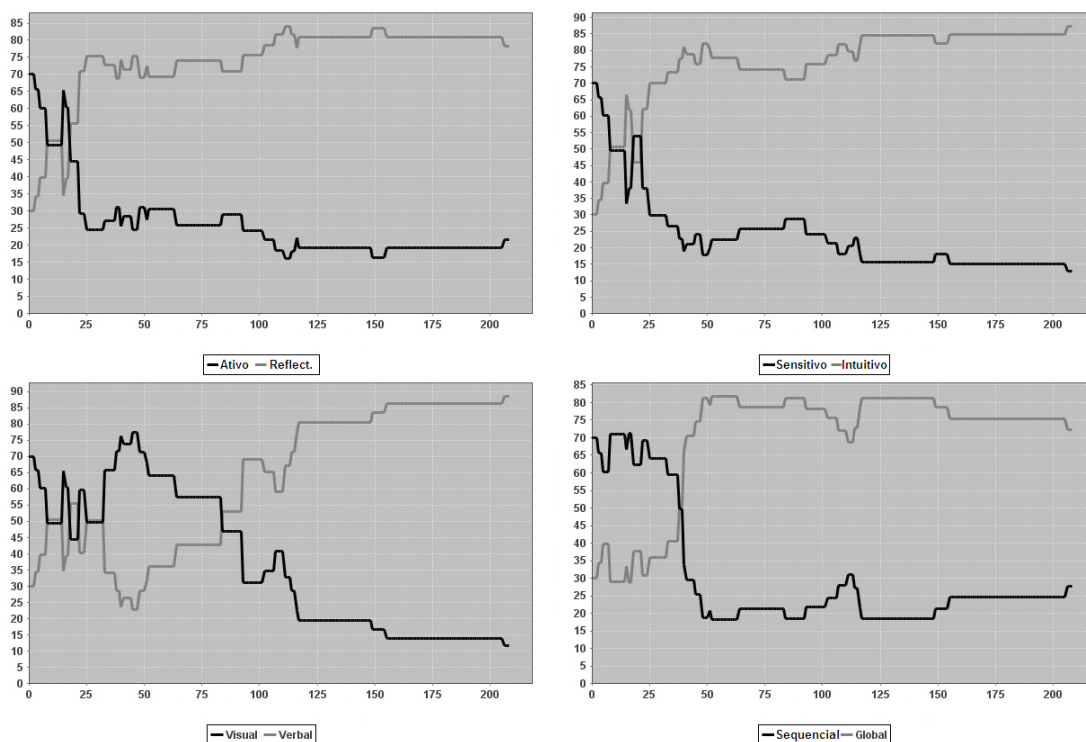


Figura 1. Atualização de  $EA_p$  durante o processo de aprendizagem




Figura 2. Médias de performance e problemas de aprendizagem

Acredita-se que os resultados obtidos a partir deste e de outros experimentos executados validam a abordagem proposta para modelagem de EA, que pode ser implementada em LMS existentes, como o Moodle [Moodle 2010], para que possa ser utilizada com estudantes reais. O processo de simulação foi muito importante para este trabalho, já que possibilitou testes, ajustes e melhorias desde o início do desenvolvimento. Desta forma, sem a utilização de simulação, seria impossível chegar a este resultado em tempo razoável, devido à grande quantidade de tempo necessário para se executar testes com estudantes reais. A próxima seção apresenta conclusões e trabalhos futuros.

#### 4. Conclusões e trabalhos futuros

A simulação de estudantes tem sido cada vez mais adotada no teste de sistemas adaptativos e inteligentes para educação, permitindo que se observe antecipadamente como

o sistema se comporta, e os resultados gerados. Portanto, a utilização de simulação permite entender o sistema e prever o seu comportamento, permitindo-nos corrigir e otimizar decisões de projeto e validar os modelos matemáticos implementados. Assim, um processo de simulação pode fornecer uma visão clara sobre o funcionamento de um sistema, para que se possa compreendê-lo e testá-lo antes de implantá-lo, o que pode exigir alto investimento e recursos.

Neste contexto, simular performances de estudantes para se testar novas abordagens no domínio de SAIE é fundamental, uma vez que a implementação desses sistemas requerem quantidades consideráveis de recursos financeiros, humanos e de tempo [Graf et al. 2009]. Assim, é importante avaliar o desempenho de uma nova abordagem de forma experimental antes de se implantá-la efetivamente em um sistema de ensino, devido à complexidade deste tipo de tarefa e dos esforços necessários.

Desta forma, este trabalho apresenta um processo probabilístico para simulação de desempenho de estudantes considerando seus estilos de aprendizagem. A inferência de desempenho dos alunos deve considerar a influência exercida por suas preferências no processo de aprendizagem, assim como ocorre em um processo tradicional de ensino, como apontam [Haider et al. 2010, Graf et al. 2008, Kinshuk et al. 2009, Graf e Kinshuk 2009, 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, Vasilyeva et al. 2006].

Conforme apresentado, técnicas de simulação computacional foram aplicadas com sucesso na experimentação de uma nova abordagem para a detecção automática de estilos de aprendizagem, que foi brevemente apresentada neste trabalho, e que é detalhadamente descrita em [Dorça et al. 2011] considerando seus diferentes aspectos e características. A experimentação desta abordagem a partir de simulação computacional do processo de aprendizagem nos permitiu observar claramente o comportamento do sistema em diferentes contextos e situações diferentes. Como resultado, esta abordagem foi validada e está sendo implantado no *Moodle* [Moodle 2010], para que seja utilizada com estudantes reais em um breve trabalho futuro.

## Referências

- 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.
- 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.
- 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.



- 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.
- 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.
- 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).
- Dorça, F. A., Lima, L. V., Fernandes, M. A., e Lopes, C. R. (2013). Comparing strategies for modeling students learning styles through reinforcement learning in adaptive and intelligent educational systems: An experimental analysis. *Expert Systems with Applications*. <http://dx.doi.org/10.1016/j.eswa.2012.10.014>.
- Dorça, F. A., Lima, L. V., Fernandes, M. A., e Lopes, C. R. (2011). A new approach to discover students learning styles in adaptive educational systems. In *XXII Simpósio Brasileiro de Informática na Educação*.
- Felder, R. e Silverman, L. (1988). Learning and teaching styles in engineering education. *Journal of Engineering education*, 78(7):674–681.
- Graf, S. e Kinshuk (2009). 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, C. (2010). 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., Lan, C., Liu, T., et al. (2009). 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 Internatio-*

- nal Conference on Cognition and Exploratory Learning in Digital Age (CELDA 2008)*, pages 223–230. IADIS International Conference.
- 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.
- 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.
- Lim, H., Lee, S., e Nam, K. (2007). Validating e-learning factors affecting training effectiveness. *International Journal of Information Management*, 27(1):22–35.
- Mertz, J. (1997). Using a simulated student for instructional design. *International Journal of Artificial Intelligence in Education (IJAIED)*, 8:116–141.
- Moodle (2010). <http://www.moodle.org/>.
- Mosakhani, M. e Jamporzam, 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.
- Price, L. (2004). Individual differences in learning: Cognitive control, cognitive style, and learning style. *Educational Psychology*, 24(5):681–698.
- 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*.
- Starr, C., Manaris, B., e Stalvey, R. (2008). Bloom's taxonomy revisited: specifying assessable learning objectives in computer science. *ACM SIGCSE Bulletin*, 40(1):261–265.
- 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.
- 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.
- 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.