

Avanços na modelagem automática e dinâmica de estilos de aprendizagem de estudantes em sistemas adaptativos e inteligentes para educação: uma análise experimental

André Gonçalves¹, Alessandro Vivas¹, Luciana Assis¹,
Cristiano Pitangui², Fabiano Dorça³

¹PPGED - UFVJM
Diamantina, MG, Brasil

{avgandre, alessandrovivas, lupassis}@gmail.com

²DTECH - UFSJ
Ouro Branco, MG, Brasil

pitangui.cristiano@gmail.com

³Faculdade de Computação – Universidade Federal de Uberlândia (UFU)
Uberlândia, MG, Brasil

fabiano@ufu.br

Abstract. *This paper aims to make a comparative study of new approaches to automatic and dynamic modeling of learning styles in adaptive and intelligent educational systems. We proposes modifications to the Student and Pedagogical Models. We achieved on average an improvement 6.1 % in the performance evaluation of the student and an average reduction of 68.3 % in the learning problems, demonstrating the effectiveness of this approach.*

Resumo. *Este trabalho tem como objetivo fazer um estudo comparativo de novas abordagens para modelagem automática e dinâmica de estilos de aprendizagem em sistemas adaptativos e inteligentes para educação. Foram propostas modificações no Modelo do Estudante e o Modelo Pedagógico. As soluções propostas neste trabalho proporcionaram uma melhoria de 6,1% no desempenho avaliativo do estudante e uma redução média de 68,3% nos problemas de aprendizagem, demonstrando eficiência e eficácia da proposta.*

1. Introdução

Ambientes Virtuais de Aprendizagem (AVA) facilitam a organização de cursos on-line, mas a maioria destes sistemas têm limitação quanto a personalização automática do conteúdo proposto [Helic et al. 2005]. Considerar particularidades em relação a, por exemplo, estilos de aprendizagem, habilidades cognitivas, interesses, motivação, dentre outras, tem um efeito positivo no progresso dos estudantes e nos resultados de aprendizagem [Graf and Kinshuk 2010]. Estilo de Aprendizagem (EA) é a maneira pela qual a pessoa absorve, processa e retêm a informação.

A detecção dos EA pode ser feita através de testes psicométricos, mas alguns autores alertam sobre a imprecisão e o grau de incerteza do método [Graf and Lin 2007].

Devido a estes problemas, Dorça [Dorça et al. 2012, Dorça et al. 2011] desenvolveu uma abordagem automatizada capaz de modelar os EA dos estudantes. Este trabalho tem como objetivo estender a abordagem proposta por [Dorça et al. 2012] para aumentar a velocidade e precisão da detecção de estilos de aprendizagem.

2. Fundamentação Teórica

Existem muitos modelos de EA cada um descrevendo diferentes aspectos e concepções de como os estudantes devem aprender. Contudo, [Kinshuk et al. 2009] destaca as particularidades do modelo de EA proposto por Felder-Silverman (FLSM) por ser uma teoria que combina características de outros modelos, baseado em uma escala de quatro dimensões: ativo/reflexivo, sensitivo/intuitivo, visual/verbal e sequencial/global.

Neste trabalho será adotado um Sistema Adaptativo e Inteligente para Educação (SAIE) dividido em três componentes: Modelo Estudante (ME), Módulo Pedagógico (MP) e Componente de Modelagem do Estudante (CME) [Dorça et al. 2012]. O ME é o componente responsável por armazenar todas as características do estudante, sobretudo os EA que sustentam a estrutura central do sistema. O Módulo Pedagógico (MP) tem a missão de inferir o tipo de conteúdo mais adequado ao estudante em determinado momento através da seleção estocástica de uma combinação de estilos de aprendizagem (CEA) de acordo com as probabilidades de preferências armazenadas no ME. Ele estabelece uma estratégia de estudo ao aluno, apresentando os objetos de aprendizagem de acordo com o ME. Por fim, o CME tem a função de ajustar as preferências contidas no ME por meio de uma política baseada em técnicas de Aprendizagem por Reforço (AR).

3. Trabalhos Correlatos

Diversas abordagens foram propostas para Detecção de Estilos de Aprendizagem. Em 2005 foi publicado o primeiro trabalho de detecção de estilos de aprendizagem de forma dinâmica, onde [Kelly and Tangney 2005] aplicaram técnicas de aprendizado de Máquina para determinar o EA de um estudante. [Özpolat and Akar 2009] utilizou algoritmos de classificação por Relevância Binária, Árvores de Decisão e Naive Bayes. Em 2012, [Dorça et al. 2012] apresentou um modelo baseado na Combinação de Estilos de Aprendizagem (CEA) para corrigir inconsistências no Modelo do Estudante de forma dinâmica. Em 2013, [Ahmad et al. 2013] utilizaram métodos baseados em literatura para monitorar o comportamento de estudantes em AVA. [Pham and Florea 2013] identificou o EA do estudante baseando nos Objetos de Aprendizagem (OA) selecionados em um AVA. [Feldman et al. 2014] utilizou o Classificador Naive Bayes para detectar o EA de usuários de um jogo.

A Figura 1 apresenta o modelo probabilístico, levando-se em consideração as incertezas em relação ao processo de modelagem de EA dos estudantes [Dorça et al. 2012]. Desta forma, as probabilidades de preferências por um ou outro estilo pelo estudante são armazenadas na forma de distribuições de probabilidades.

Em síntese, o conteúdo programático é dividido em conceitos. O processo começa com a inicialização do ME. Então um conceito é selecionado e o MP seleciona estocasticamente uma CEA baseado nos EA armazenados no ME. Por conseguinte, é possível ao sistema personalizar o material didático seguindo a CEA e apresenta ao estudante.

Na próxima etapa ocorre o método avaliativo. Se o desempenho estiver abaixo do mínimo exigido, o sistema entende que precisa revisar suas informações e corrigir seus dados do ME, tornando-o cada vez mais bem adaptado ao estudante. O aluno por sua vez terá a oportunidade de rever o conceito de forma mais adequada às suas preferências.

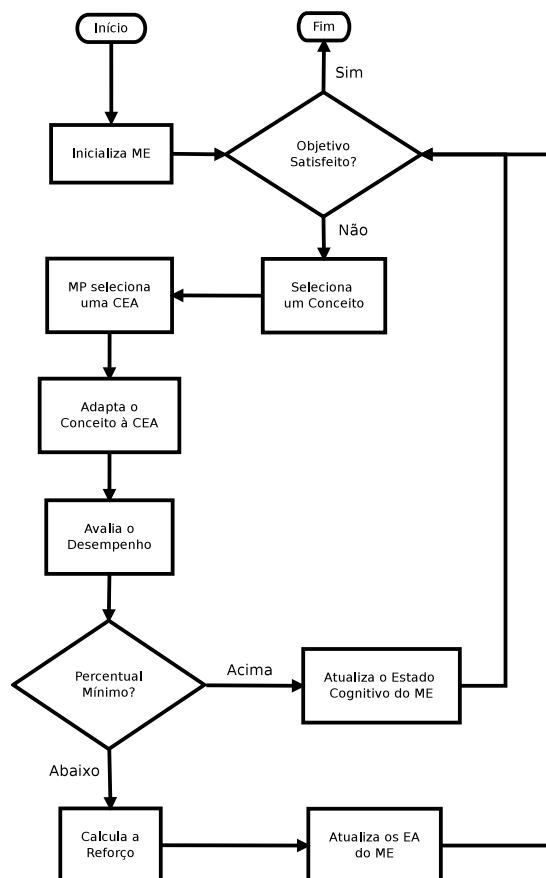


Figura 1. Visão Geral da abordagem proposta por [Dorça et al. 2012].

4. Abordagem Proposta

Segundo [Botelho et al. 2009] a representação explícita do ME retrata aquilo que se acredita saber sobre o estudante, como por exemplo, o conhecimento, o progresso no conteúdo, as preferências, os EA, os objetivos de aprendizagem, a motivação, as crenças e as características pessoais. O desempenho do estudante serve como indicador da preferência do estudante diante de uma CEA selecionada [Dorça et al. 2012], mas é difícil precisar o impacto de determinado EA na nota obtida.

Portanto, diante de um universo avaliativo, os estilos impróprios de um conteúdo provavelmente contribuem negativamente a sua performance. Desta forma, faz sentido armazenar no ME o conjunto de notas que represente todo o processo de aprendizagem. Assim, neste trabalho foi inserido o histórico das notas separando os valores por EA, conforme ilustra a Tabela 1. Este histórico fica estruturado no ME no formato de média aritmética.

Tal como ocorre no trabalho de [Dorça et al. 2012], o ME é constantemente atualizado pelo CME. Entretanto, o novo formato apresentado exigirá a manutenção da nova

| EA Probabilísticos | | | | | | | |
|--------------------------------|-----------|-----------|-----------|---------|--------|-------------|--------|
| Processamento | | Percepção | | Entrada | | Organização | |
| Ativo | Reflexivo | Sensitivo | Intuitivo | Visual | Verbal | Sequencial | Global |
| 0,7 | 0,3 | 0,44 | 0,66 | 0,28 | 0,72 | 0,85 | 0,15 |
| Média Aritmética do Desempenho | | | | | | | |
| Processamento | | Percepção | | Entrada | | Organização | |
| Ativo | Reflexivo | Sensitivo | Intuitivo | Visual | Verbal | Sequencial | Global |
| 0,82 | 0,41 | 0,67 | 0,81 | 0,74 | 0,56 | 0,89 | 0,32 |

Tabela 1. Modelo Estudante Estendido.

variável. Esta estrutura contribuirá na composição de informações sobre o comportamento do estudante, durante as interações com o sistema.

O MP tem a função de selecionar uma CEA pelo qual o conteúdo didático será adaptado. O sucesso do tratamento individualizado considerando o perfil do estudante está relacionado com qualidade das escolhas das CEA. Este trabalho também propõe uma modificação do MP baseado na nova estrutura do ME. O novo MP deixa de considerar apenas as preferências dos EA e acrescenta como parâmetro a média aritmética de desempenho em cada EA, obtida através das avaliações nas sessões de aprendizagem.

A formalização do cálculo está dividido em duas partes. O cálculo deve ser realizado separadamente para cada dimensão do ME. A primeira é a transformação das médias em pesos representados através de percentuais. Dado M_a a média do estilo A e a M_b a média do estilo B , calcula-se o peso PM da seguinte forma:

$$PM_a = \frac{M_a}{M_a + M_b} \quad (1)$$

A segunda parte consiste em usar os percentuais para reforçar positivamente ou negativamente as preferências dos EA. Considerando A e B os estilos de uma mesma dimensão, PR a probabilidade das preferências dos EA e PM o peso da média histórica, a nova probabilidade P de um estilo ser selecionado pelo MP durante uma seção de aprendizagem é dada por:

$$P = \frac{PR_a * PM_a}{PR_a * PM_a + PR_b * PM_b} \quad (2)$$

A probabilidade P de uma CEA ser selecionada pelo MP continua a mesma defendida por [Dorça et al. 2012], contudo, os EA são influenciados diretamente pelo valor da média histórica correspondente. A nova proposta continua considerando estocasticamente todas as CEA de acordo com os EA do estudante, mesmo que o ME esteja inconsistente se comparado com a preferência real do estudante. Este fato proporciona a seleção estocástica de toda e qualquer CEA, possibilitando o ajuste das preferências de acordo com o desempenho do estudante nos processos avaliativos.

Neste trabalho há uma diferença significativa desse componente comparado com a tese desenvolvida por [Dorça et al. 2012]. O desempenho do estudante continua sendo o parâmetro para o ajuste dos valores, entretanto, a política de ajuste dos valores do ME proposta por [Dorça et al. 2012], é estendida.

É proposto um novo parâmetro, chamado de percentual de excelência PFM_{exc} na qual houve êxito na aprendizagem. O parâmetro de excelência corresponde a um percentual da avaliação e pode ser configurado de acordo com indicação pedagógica, por exemplo, 90% ou 95% de aproveitamento.

Na nova estratégia, além de ajustar quando ocorre um desempenho abaixo do esperado, o ajuste dos EA_P acontece quando o desempenho é maior ou igual que o nível de excelência. Contudo, esta condição não garante por si só que os estilos escolhidos na sessão de aprendizagem correspondem aos estilos reais do estudante. Por isso, exige-se também que a média aritmética da CEA esteja na mesma condição, isto é, $PFM \geq PFM_{exc}$.

O parâmetro como os EA_P será atualizado levando-se em consideração a CEA escolhida na sessão de aprendizagem. O ME será atualizado quando ocorrer um desempenho de excelência (Algoritmo 1) e quando ocorrer um desempenho insatisfatório (Algoritmo 2)

Algorithm 1: Regra de ajuste dos EA armazenados no ME para desempenho de excelência.

```

1 início
2   para cada elemento de  $d$  faça
3     se  $(CEA[d_i] == A)$  então
4        $ME[d_i]_A = ME[d_i]_A + \alpha * R$ 
5        $ME[d_i]_B = ME[d_i]_B - \alpha * R$ 
6     fim
7     senão se  $(CEA[d_i] == B)$  então
8        $ME[d_i]_A = ME[d_i]_A - \alpha * R$ 
9        $ME[d_i]_B = ME[d_i]_B + \alpha * R$ 
10    fim
11  fim
12 fim
```

Onde $ME[d_i]_A$ representa um valor numérico armazenado no ME na dimensão i para o EA A , com $i = i...4$. $ME[d_i]_B$ representa um valor numérico armazenado no ME na dimensão i para o EA B , com $i = i...4$. $CEA[d_i]$ representa o EA que constitui a CEA considerando uma dimensão i , com $i = i...4$. R é o reforço, seja recompensa ou penalização, recebido pela realização da ação pedagógica e α corresponde a taxa de aprendizagem do agente.

Na abordagem proposta por [Dorça et al. 2012] os valores dos EA_P são atualizados pelo sistema sempre que o estudante apresenta dificuldade de aprendizagem, isto é, quando o desempenho fica abaixo do mínimo exigido durante uma seção de aprendizagem. O valor mínimo de performance M_{min} corresponde a um percentual da avaliação e pode ser configurado de acordo com normas pedagógica de cada instituição, por exemplo, 60% ou 70% de aproveitamento.

A Função Reforço exerce grande influência no processo de diagnóstico e detecção de EA. Ela está definida, na Equação 3, considerando-se duas variáveis: Performance do Estudante na Seção de Aprendizagem (PFM) e a Diferença Absoluta entre os Estilos de Aprendizagem (DEA).

Algorithm 2: Regras de ajuste dos EA armazenados no ME para desempenho insatisfatório.

```

1 início
2   para cada elemento de  $d$  faça
3     se  $(CEA[d_i] == A)$  então
4        $ME[d_i]_A = ME[d_i]_A - \alpha * R$ 
5        $ME[d_i]_B = ME[d_i]_B + \alpha * R$ 
6     fim
7     senão se  $(CEA[d_i] == B)$  então
8        $ME[d_i]_A = ME[d_i]_A + \alpha * R$ 
9        $ME[d_i]_B = ME[d_i]_B - \alpha * R$ 
10    fim
11  fim
12 fim

```

$$R = \frac{1}{PFM * DEA} \quad (3)$$

$$DEA = |ME[d_i]_A - ME[d_i]_B| \quad (4)$$

5. Testes Realizados

Este trabalho propõe duas melhorias no sistema proposto por [Dorça et al. 2012], denominado nos testes como Abordagem I. A Abordagem II modifica a Abordagem I atualizando o Modelo de Estudante tanto na ocorrência de um desempenho ruim (nota inferior a 60 pontos) quanto em um desempenho bom (notas acima de 90 pontos). A Abordagem III modifica a Abordagem II alterando o MP que agora atualiza as probabilidades do ME considerando o histórico das notas obtidas pelo estuante ao longo das atividades avaliativas.

As métricas escolhidas foram a de Problema de Aprendizagem e a de Desempenho. A primeira é a quantidade de ocorrências em que o desempenho esteve abaixo do mínimo exigido no processo avaliativo. A segunda está relacionada com nota média obtida ao longo de todas sessões de aprendizagem. Ambas variáveis estão relacionadas com a consistência do modelo, ou seja, relacionado à convergência efetiva do EA_p para os EA_r durante o processo de simulação. Este processo é apresentado em detalhes em [Dorça 2015].

Neste trabalho utilizou-se uma taxa de aprendizagem α de 0,5 que define o valor da intensidade do reforço. O parâmetro de limitação do impacto do reforço de $R_{max} : \alpha = 0,2$ [Dorça et al. 2013]. Foram realizados 100 repetições para cada teste e os valores apresentados correspondem a média de todos os testes realizados. O algoritmo reforça negativamente quando o desempenho do aluno for inferior a 60 pontos (desempenho mínimo) e na abordagem proposta define-se como reforço de desempenho de excelência quando o desempenho for superior a 90 pontos. O ME foi inicializado com os valores apresentados na Tabela 2.

Foram realizados 3 categorias de testes com cargas de trabalho diferentes (15, 30 e 60 conceitos). Para conceito, o estudante deve passar pelos 6 níveis cognitivos da

| Estilos de Aprendizagem | | | | | | | |
|-------------------------|-----------|-----------|-----------|---------|--------|-------------|--------|
| Processamento | | Percepção | | Entrada | | Organização | |
| Ativo | Reflexivo | Sensitivo | Intuitivo | Visual | Verbal | Sequencial | Global |
| 0,5 | 0,5 | 0,5 | 0,5 | 0,5 | 0,5 | 0,5 | 0,5 |

Tabela 2. ME Inicial

Taxonomia de Bloom, a fim de alcançar o Objetivo de Aprendizagem. Então haverá ao menos 90 sessões para 15 conceitos, 180 sessões para 30 conceitos e 360 sessões para 60 conceitos. Em cada carga de trabalho, os parâmetros permaneceram fixos e sem variação.

Os testes foram divididos em duas etapas variando os níveis de preferências dos EA do estudante. As amostras de dados foram obtidas através de execuções seguindo as técnicas das três abordagens comentadas anteriormente. Neste experimento a comparação utilizou-se o nível de confiança de 95%, que corresponde a um nível de significância de 0.05 (erro tipo I). Este teste consiste em determinar a média das diferenças entre duas amostras pareadas e através dela calcular intervalo de confiança. Se o número zero estiver compreendido dentro deste intervalo, o resultado é considerado indefinido por não existir uma diferença estatisticamente significativa entre as amostras (hipótese nula $\mu_d = D$). Caso contrário, a hipótese nula é rejeitada e a verificação procede da seguinte forma: se ambos limites do intervalo estiver abaixo de zero, a amostra I é menor (hipótese A: $\mu_d < D$), porém se ambos limites do intervalo estiver acima de zero, a amostra II é maior (hipótese B: $\mu_d > D$). Neste experimento a comparação utilizou-se o nível de confiança de 95%, que corresponde a um nível de significância de 0.05 (erro tipo I).

Na primeira etapa dos testes foram considerados os seguintes níveis de intensidade para os estilos de aprendizagem reais dos estudantes simulados utilizados no experimento. Estes níveis afetam o desempenho do estudante simulado no processo de aprendizagem, conforme apresentado em [Dorça 2015]: forte na dimensão Processamento, forte na dimensão Percepção, moderada na dimensão Entrada e leve na dimensão Organização. Na Tabela 3 é apresentado o resumo dos resultados, obtidos através das 100 execuções para cada estudante simulado considerado no experimento, utilizando as três abordagens citadas anteriormente. As 16 possíveis combinações de preferências de EA do estudante foram testadas nas mesmas condições, sendo que para cada uma delas apresenta-se a média com o desvio padrão e abaixo o intervalo de confiança.

A Tabela 4 são mostrados o resumo dos resultados, obtidos através das 100 execuções utilizando as três abordagens citadas anteriormente.

Na Tabela 5 são mostrados o resumo dos resultados, obtidos através das 100 execuções utilizando as três abordagens citadas anteriormente.

6. Análise dos Resultados

A Tabela 3 apresenta a comparação entre as amostras da Abordagem I, II e III, exibindo o cálculo do intervalo de confiança e a síntese do melhor desempenho, segundo o método estatístico supracitado. Ao analisar os dados da Tabela 3, é possível afirmar com 95% de confiança que em ambas métricas houve superioridade unânime da Abordagem III, reduzindo os problemas de aprendizagem e aumentando o desempenho do estudante.

Diante às adaptações propostas, foram realizados testes computacionais na qual houve uma comparação entre a abordagem original por [Dorça et al. 2012] e as extensões

| EA _r | | Abordagem I | | Abordagem II | | Abordagem III | |
|-----------------|---------------|-------------------------------|-------------------------------|----------------------------|-------------------------------|----------------------------|-------------------------------|
| | | P. Apend. | Desempenho | P. Apend. | Desempenho | P. Apend. | Desempenho |
| 1 | A, S, VI, SEQ | 12,310±2,813 11,843~13,655 | 81,381±1,372 81,153~82,037 | 7,730±2,947 7,241~9,139 | 85,312±2,219 84,943~86,373 | 4,440±2,672 3,997~5,717 | 88,099±2,585 87,670~89,335 |
| 2 | A, S, VI, G | 13,010±3,264 12,468~13,552 | 81,190±1,500 80,941~81,439 | 7,260±2,984 6,765~7,755 | 85,474±2,173 85,114~85,835 | 5,490±3,526 4,905~6,075 | 87,679±3,016 87,179~88,180 |
| 2 | A, S, VE, SEQ | 12,740±3,224 12,205~13,275 | 81,127±1,656 80,852~81,402 | 7,660±2,903 7,178~8,142 | 85,172±1,911 84,855~85,490 | 5,270±3,275 4,726~5,814 | 87,177±3,076 86,666~87,688 |
| 4 | A, S, VE, G | 12,800±3,447 12,228~13,372 | 81,411±1,493 81,163~81,658 | 7,030±2,410 6,630~7,43 | 85,509±2,093 85,161~85,856 | 5,000±3,091 4,487~5,513 | 87,706±2,942 87,217~88,194 |
| 5 | A, I, VI, SEQ | 12,940±3,293 12,393~13,487 | 81,331±1,387 81,101~81,562 | 6,370±2,163 6,011~6,72 | 85,849±1,778 85,553~86,144 | 5,270±3,458 4,696~5,844 | 87,566±2,795 87,102~88,030 |
| 6 | A, I, VI, G | 12,260±3,077 11,749~12,771 | 81,459±1,400 81,227~81,692 | 7,510±2,925 7,024~7,99 | 85,365±1,779 85,069~85,660 | 5,200±3,531 4,614~5,786 | 87,784±2,783 87,323~88,246 |
| 7 | A, I, VE, SEQ | 13,180±3,427 12,611~13,749 | 81,120±1,534 80,866~81,375 | 7,860±2,992 7,363~8,35 | 85,114±2,140 84,759~85,470 | 5,320±3,272 4,777~5,863 | 87,578±2,862 87,103~88,053 |
| 8 | A, I, VE, G | 12,590±2,775 12,129~13,051 | 81,470±1,279 81,257~81,682 | 8,300±3,323 7,748~8,85 | 84,885±2,156 84,527~85,243 | 5,050±3,192 4,520~5,580 | 87,815±2,665 87,373~88,258 |
| 9 | R, S, VI, SEQ | 12,490±3,189 11,961~13,019 | 81,294±1,466 81,051~81,538 | 10,520±3,332 7,443~8,43 | 82,685±1,870 84,519~85,227 | 5,470±3,689 4,858~6,082 | 87,397±2,995 86,899~87,894 |
| 10 | R, S, VI, G | 12,980±3,281 12,485~13,475 | 80,972±1,511 80,721~81,223 | 7,970±3,053 7,463~8,47 | 85,064±1,930 84,744~85,385 | 5,110±3,366 4,551~5,669 | 87,599±2,783 87,137~88,061 |
| 11 | R, S, VE, SEQ | 12,500±3,283 11,955~13,045 | 81,656±1,305 81,439~81,872 | 7,680±2,482 7,268~8,09 | 85,309±1,902 84,993~85,624 | 5,260±3,575 4,667~5,853 | 87,552±2,879 87,074~88,030 |
| 12 | R, S, VE, G | 12,570±3,382 12,009~13,131 | 81,511±1,556 81,253~81,770 | 7,670±3,150 7,147~8,19 | 85,187±2,179 84,825~85,549 | 5,390±3,287 4,844~5,936 | 87,420±2,890 86,940~87,900 |
| 13 | R, I, VI, SEQ | 12,440±3,233 11,903~12,977 | 81,260±1,515 81,008~81,511 | 7,800±3,065 7,291~8,30 | 85,273±2,044 84,934~85,612 | 5,100±3,466 4,525~5,675 | 87,528±2,776 87,067~87,988 |
| 14 | R, I, VI, G | 12,500±3,076 11,989~13,011 | 81,572±1,482 81,326~81,818 | 7,310±2,987 6,814~7,80 | 85,553±1,870 85,242~85,863 | 4,570±2,979 4,076~5,064 | 87,824±2,947 87,335~88,313 |
| 15 | R, I, VE, SEQ | 12,410±3,414 11,843~12,977 | 81,531±1,532 81,277~81,786 | 7,950±3,079 7,439~8,46 | 85,172±2,259 84,797~85,547 | 5,440±3,927 4,788~6,092 | 87,335±2,334 86,798~87,872 |
| 16 | R, I, VE, G | 13,080±3,284 12,535~13,625 | 81,100±1,688 80,820~81,380 | 7,740±2,901 7,258~8,22 | 85,384±1,964 85,058~85,710 | 4,960±3,091 4,447~5,473 | 87,649±2,864 87,173~88,124 |

Tabela 3. Valores Médios de 100 Execuções para Carga de Trabalho de 15 conceitos.

| EA _r | | Abordagem I | | Abordagem II | | Abordagem III | |
|-----------------|---------------|-------------------------------|-------------------------------|----------------------------|-------------------------------|----------------------------|-------------------------------|
| | | P. Apend. | Desempenho | P. Apend. | Desempenho | P. Apend. | Desempenho |
| 1 | A, S, VI, SEQ | 19,340±4,388 18,612~20,068 | 83,502±1,254 83,294~83,710 | 8,990±2,791 8,527~9,453 | 87,926±1,318 87,707~88,145 | 5,810±3,730 5,191~6,429 | 89,749±1,890 89,436~90,063 |
| 2 | A, S, VI, G | 19,190±4,244 18,485~19,895 | 83,410±1,147 83,219~83,600 | 8,960±3,162 8,435~9,485 | 88,001±1,217 87,799~88,203 | 5,270±3,114 4,753~5,787 | 90,095±1,775 89,800~90,389 |
| 3 | A, S, VE, SEQ | 18,860±3,838 18,223~19,497 | 83,347±1,201 83,148~83,547 | 9,220±3,237 8,683~9,757 | 88,084±1,196 87,886~88,283 | 5,510±3,762 4,886~6,134 | 90,187±1,809 89,887~90,487 |
| 4 | A, S, VE, G | 18,980±3,464 18,40~19,555 | 83,416±1,116 83,230~83,601 | 9,030±3,258 8,489~9,571 | 88,131±1,312 87,914~88,349 | 6,120±4,066 5,445~6,795 | 89,926±1,945 89,603~90,249 |
| 5 | A, I, VI, SEQ | 18,500±3,700 17,886~19,114 | 83,474±0,951 83,316~83,632 | 8,720±3,137 8,199~9,241 | 87,930±1,131 87,742~88,118 | 5,750±3,825 5,115~6,385 | 89,864±1,956 89,539~90,189 |
| 6 | A, I, VI, G | 18,920±4,646 18,149~19,691 | 83,282±1,333 83,061~83,503 | 8,870±3,287 8,324~9,416 | 88,024±1,358 87,798~88,249 | 5,970±3,463 5,395~6,545 | 89,561±1,891 89,247~89,875 |
| 7 | A, I, VE, SEQ | 19,060±3,915 18,410~19,710 | 83,549±1,089 83,369~83,730 | 8,710±3,006 8,211~9,209 | 88,074±1,166 87,880~88,268 | 5,860±3,232 5,324~6,396 | 89,885±1,629 89,615~90,156 |
| 8 | A, I, VE, G | 19,140±3,458 18,566~19,714 | 83,373±0,952 83,215~83,531 | 8,920±3,558 8,329~9,511 | 88,147±1,262 87,938~88,357 | 6,320±3,749 5,698~6,942 | 89,678±1,894 89,364~89,992 |
| 9 | R, S, VI, SEQ | 18,580±3,980 17,919~19,241 | 83,439±1,202 83,239~83,638 | 8,890±3,393 8,327~9,453 | 87,998±1,472 87,753~88,242 | 5,860±3,665 5,252~6,468 | 89,924±1,734 89,636~90,212 |
| 10 | R, S, VI, G | 19,540±4,205 18,842~20,238 | 83,397±1,039 83,225~83,570 | 9,180±3,036 8,676~9,684 | 87,950±1,329 87,730~88,171 | 5,880±3,699 5,266~6,494 | 89,983±1,857 89,675~90,291 |
| 11 | R, S, VE, SEQ | 20,000±3,835 19,363~20,637 | 83,310±1,140 83,120~83,499 | 8,680±3,493 8,100~9,260 | 88,284±1,146 88,094~88,474 | 6,240±3,995 5,577~6,903 | 89,737±2,084 89,391~90,083 |
| 12 | R, S, VE, G | 18,840±3,670 18,231~19,449 | 83,368±1,195 83,170~83,567 | 8,710±3,059 8,202~9,218 | 88,122±1,214 87,921~88,324 | 6,220±3,457 5,646~6,794 | 89,802±1,818 89,500~90,103 |
| 13 | R, I, VI, SEQ | 19,360±3,996 18,697~20,023 | 83,295±1,085 83,115~83,475 | 9,040±2,715 8,589~9,491 | 87,952±1,211 87,751~88,153 | 5,880±3,534 5,293~6,467 | 89,803±1,802 89,504~90,102 |
| 14 | R, I, VI, G | 18,280±3,391 17,717~18,843 | 83,598±1,012 83,430~83,766 | 9,240±3,525 8,655~9,825 | 87,995±1,376 87,766~88,223 | 5,940±3,632 5,337~6,543 | 89,888±1,759 89,596~90,180 |
| 15 | R, I, VE, SEQ | 19,490±3,460 18,916~20,064 | 83,278±0,981 83,115~83,441 | 9,120±3,160 8,595~9,645 | 87,867±1,304 87,650~88,083 | 5,910±3,758 5,286~6,534 | 89,756±1,984 89,426~90,085 |
| 16 | R, I, VE, G | 19,010±4,021 18,342~19,678 | 83,362±1,247 83,155~83,569 | 9,330±3,458 8,756~9,904 | 87,906±1,348 87,682~88,130 | 5,600±3,736 4,980~6,220 | 89,949±1,893 89,635~90,264 |

Tabela 4. Resumo dos resultados na execução da carga de trabalho de 30 conceitos.

propostas neste trabalho. A comparação utilizou-se o teste T-Pareado para analisar as amostras divididos em duas métricas: quantidade de problemas de aprendizagem e desempenho médio. Diante da comparação realizada pelo teste estatístico, constataram-se uma diminuição média de 68,268% na quantidade de problemas de aprendizagem e um aumento de 6,074% no desempenho, considerando as novas ideias defendidas neste tra-

| EA _v | Abordagem I | | Abordagem II | | Abordagem III | | |
|-----------------|---------------|-------------------------------|-------------------------------|-------------------------------|-------------------------------|----------------------------|-------------------------------|
| | P. Aprend. | Desempenho | P. Aprend. | Desempenho | P. Aprend. | Desempenho | |
| 1 | A, S, VI, SEQ | 28,680±5,743 27,727~29,633 | 85,182±0,966 85,021~85,342 | 11,320±3,618 10,719~11,921 | 89,682±0,742 89,558~89,805 | 7,010±4,580 6,250~7,770 | 91,199±1,399 90,966~91,431 |
| 2 | A, S, VI, G | 28,320±4,790 27,525~29,115 | 85,298±0,847 85,158~85,439 | 11,440±3,630 10,837~12,043 | 89,637±0,770 89,510~89,765 | 7,140±4,212 6,441~7,839 | 91,067±1,411 90,833~91,302 |
| 3 | A, S, VE, SEQ | 28,450±4,996 27,621~29,279 | 85,040±0,808 84,906~85,174 | 11,170±3,893 10,524~11,816 | 89,581±0,775 89,452~89,709 | 6,980±3,363 6,422~7,538 | 91,086±1,166 90,892~91,280 |
| 4 | A, S, VE, G | 27,810±5,894 26,832~28,788 | 85,281±0,997 85,116~85,447 | 11,440±3,639 10,836~12,044 | 89,497±0,904 89,347~89,647 | 7,140±4,245 6,435~7,845 | 91,093±1,278 90,881~91,305 |
| 5 | A, I, VI, SEQ | 27,270±5,013 26,438~28,102 | 85,336±0,954 85,177~85,494 | 10,850±3,614 10,250~11,450 | 89,697±0,645 89,590~89,804 | 6,400±3,665 5,792~7,008 | 91,331±1,178 91,135~91,526 |
| 6 | A, I, VI, G | 28,870±5,592 27,942~29,798 | 85,124±0,901 84,974~85,273 | 11,130±3,589 10,534~11,726 | 89,624±0,731 89,503~89,746 | 7,500±3,820 6,866~8,134 | 90,990±1,323 90,770~91,209 |
| 7 | A, I, VE, SEQ | 27,870±4,952 27,048~28,692 | 85,305±0,943 85,149~85,462 | 11,300±3,512 10,717~11,883 | 89,533±0,738 89,411~89,656 | 6,480±4,001 5,816~7,144 | 91,296±1,091 91,115~91,477 |
| 8 | A, I, VE, G | 27,920±4,748 27,132~28,708 | 85,282±0,814 85,147~85,417 | 11,150±3,919 10,499~11,801 | 89,633±0,836 89,494~89,772 | 6,250±3,839 5,613~6,887 | 91,292±1,310 91,074~91,509 |
| 9 | R, S, VI, SEQ | 28,300±5,229 27,432~29,168 | 85,192±0,934 85,037~85,347 | 11,760±3,397 11,196~12,324 | 89,580±0,651 89,472~89,688 | 6,900±4,021 6,232~7,568 | 90,978±1,295 90,763~91,192 |
| 10 | R, S, VI, G | 28,070±5,129 27,219~28,921 | 85,289±0,846 85,148~85,429 | 11,480±3,984 10,819~12,141 | 89,635±0,811 89,501~89,770 | 7,880±5,028 7,045~8,715 | 90,927±1,372 90,699~91,155 |
| 11 | R, S, VE, SEQ | 27,960±5,081 27,117~28,803 | 85,204±0,896 85,055~85,353 | 11,330±3,596 10,733~11,927 | 89,588±0,762 89,461~89,714 | 7,310±4,739 6,523~8,097 | 90,959±1,359 90,733~91,184 |
| 12 | R, S, VE, G | 28,070±4,963 27,246~28,894 | 85,181±0,856 85,039~85,323 | 11,470±3,818 10,836~12,104 | 89,503±0,831 89,365~89,641 | 7,450±4,349 6,728~8,172 | 90,863±1,423 90,627~91,099 |
| 13 | R, I, VI, SEQ | 28,550±4,556 27,794~29,306 | 85,138±0,838 84,998~85,277 | 11,870±3,730 11,251~12,489 | 89,476±0,764 89,349~89,603 | 6,700±4,487 5,955~7,445 | 91,198±1,407 90,965~91,432 |
| 14 | R, I, VI, G | 27,230±4,980 26,403~28,057 | 85,448±0,907 85,297~85,598 | 11,570±3,602 10,972~12,168 | 89,509±0,730 89,388~89,630 | 7,230±4,075 6,554~7,906 | 91,080±1,191 90,882~91,278 |
| 15 | R, I, VE, SEQ | 29,160±5,116 28,311~30,009 | 85,160±0,882 85,013~85,306 | 10,700±3,791 10,071~11,329 | 89,603±0,803 89,469~89,736 | 6,270±3,595 5,673~6,867 | 91,284±1,193 91,086~91,482 |
| 16 | R, I, VE, G | 28,380±5,272 27,505~29,255 | 85,127±1,014 84,959~85,295 | 11,130±3,768 10,505~11,755 | 89,694±0,759 89,568~89,820 | 6,200±3,926 5,548~6,852 | 91,295±1,136 91,106~91,483 |

Tabela 5. Resumo dos resultados na execução da carga de trabalho de 60 conceitos.

Tabela 6. Resumo dos resultados do Teste I.

| Carga de Trabalho | Abordagem I | | Abordagem II | | Abordagem III | |
|-------------------|---------------|--------------|--------------|--------------|---------------|--------------|
| | P. Aprend. | Desempenho | P. Aprend. | Desempenho | P. Aprend. | Desempenho |
| 15 Conceitos | 12,675±0,290 | 81,337±0,196 | 7,773±0,857 | 85,144±0,693 | 5,146±0,299 | 87,607±0,221 |
| 30 Conceitos | 19,068 ±0,429 | 83,400±0,094 | 8,976±0,207 | 88,024±0,109 | 5,884±0,273 | 89,862±0,155 |
| 60 Conceitos | 28,182±0,521 | 85,224±0,102 | 11,319±0,302 | 89,592±0,072 | 6,928±0,503 | 91,121±0,152 |

balho.

7. Conclusões

Este trabalho propõe uma extensão na abordagem proposta por [Dorça et al. 2012]. Com a inserção do histórico de notas para cada CEA selecionada possibilitou a modificação do método de seleção de CEA. Outra intervenção relevante foi no ajuste dos pesos quando houve também sucesso no processo.

A experimentação se deu através de simulação de estudantes [Dorça et al. 2013], facilitando muito a análise de variáveis fundamentais à verificação e validação: consistência e eficiência. Pôde-se observar nitidamente o comportamento das abordagens através de duas etapas de testes, cada uma com 16 diferentes testes, considerando situações adversas. Quando comparado com a abordagem proposta por [Dorça et al. 2012] constatou-se melhoria significativa.

Referências

Ahmad, N., Tasir, Z., Kasim, J., and Sahat, H. (2013). Automatic Detection of Learning Styles in Learning Management Systems by Using Literature-Based Method. *Procedia - Social and Behavioral Sciences*, 103:181–189.

- Botelho, C. A., Pimentel, E. P., Senger, H., and Stiubiener, I. (2009). Personalização em sistemas de gerenciamento da aprendizagem em conformidade com o padrão SCORM. In *XX Simpósio Brasileiro de Informática na Educação*.
- Dorça, F. (2015). Implementation and use of Simulated Students for Test and Validation of new Adaptive Educational Systems: a Practical Insight. *International Journal of Artificial Intelligence in Education*, 25(3):319–345.
- Dorça, F. A., Lima, L. V., Fernandes, M. A., and Lopes, C. R. (2011). 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., and Lopes, C. R. (2012). Consistent Evolution of Student Models by Automatic Detection of Learning Styles. *IEEE Latin America Transactions*, 10(5):2150–2161.
- Dorça, F. A., Lima, L. V., Fernandes, M. A., and Lopes, C. R. (2013). Comparing strategies for modeling students learning styles through reinforcement learning in adaptive and intelligent educational systems: An experimental analysis. *Expert Syst. Appl.*, 40(6):2092–2101.
- Dorça, F. A., Lima, L. V., Fernandes, M. A., and Lopes, C. R. (2013). 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. *VAEP-RITA*, 1(3).
- Feldman, J., Monteserin, A., and Amandi, A. (2014). Automatic detection of learning styles: state of the art. *Artificial Intelligence Review*.
- Graf, S. and 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.
- Graf, S. and Lin, T. (2007). Analysing the Relationship between Learning Styles and Cognitive Traits. In *Advanced Learning Technologies*, pages 235–239.
- Helic, D., Hrastnik, J., and Maurer, H. (2005). An Analysis of Application of Business Process Management Technology in E-Learning Systems. In *Proceedings of E-Learn*, pages 2937–2942.
- Kelly, D. and Tangney, B. (2005). ‘First aid for you’: Getting to know your Learning Style using Machine Learning. In *Proceedings of Fifth IEEE International Conference on Advanced Learning Technologies*, pages 1–3, Kaohsiung, Taiwan. IEEE.
- Kinshuk, Liu, T., and 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.
- Özpolat, E. and Akar, G. B. (2009). Automatic detection of learning styles for an e-learning system. *Computers & Education*, 53(2):355–367.
- Pham, Q. D. and Florea, A. M. (2013). A Method for Detection of Learning Styles in Learning Management Systems. *UPB Scientific Bulletin, Series C: Electrical Engineering*, 75(4):3–12.