

Detecção Automática e Dinâmica de Estilos de Aprendizagem em Sistemas Adaptativos e Inteligentes utilizando *Dynamic Scripting*

Júlio César da Costa Silva¹, Cristiano Pitangui², Alessandro Vivas¹, Luciana Assis¹

¹ Universidade Federal dos Vales do Jequitinhonha e Mucuri
Diamantina/MG, Brasil

{analistacesar, alessandro.vivas, lupassis}@gmail.com

² Universidade Federal de São João Del-Rei
São João Del-Rei/MG, Brasil

pitangui.cristiano@gmail.com

Abstract. *Adaptive and Intelligent Educational Systems (AIES) aim to provide a personalized assistance to the student by detecting their Learning Style (LS). One of the most popular techniques used for this detection is Reinforcement Learning (RL). However, RL presents slow convergence rate in some cases. This work proposes the improvement of an AIES by using an adaptation of the Dynamic Scripting technique, considered faster than the RL. Experimental results showed that the proposed technique reduced the number of the learning problems by $\approx 54\%$, and $\approx 35\%$, respectively, to Static and Dynamic LS, while reduced the number of interactions by $\approx 5.7\%$ in relation to the literature.*

Resumo. *Sistemas Adaptativos e Inteligentes para a Educação (SAIE) buscam fornecer assistência personalizada ao aluno por meio da detecção de seu Estilo de Aprendizagem (EA). Uma das técnicas mais exploradas para esta detecção é o Aprendizado por Reforço (AR). Contudo, tal técnica, em alguns casos, é considerada de lenta convergência. Este trabalho propõe o aperfeiçoamento de um SAIE utilizando uma adaptação da técnica de Dynamic Scripting, considerada mais rápida que o AR. Experimentos demonstraram que a proposta, comparada às soluções da literatura, reduziu o número de problemas de aprendizagem em $\approx 54\%$, e $\approx 35\%$, respectivamente, para EAs Estáticos e Dinâmicos, enquanto reduz o número de interações do sistema em $\approx 5,7\%$.*

1. Introdução

A Educação à Distância (EAD) é um processo de ensino-aprendizagem mediado por Tecnologias da Informação e Comunicação (TICs) que se encontra em pleno desenvolvimento [Kenski 2003]. As TICs viabilizaram os Ambientes Virtuais de Aprendizagem (AVA) que reúnem na Web diversas ferramentas, como fóruns, wikis e outras tecnologias colaborativas. Apesar da diversidade de ferramentas, elas não são adaptadas individualmente aos alunos. Assim, sistemas utilizando-se de técnicas de Inteligência Artificial (IA) são construídos para garantir tratamento adaptado a cada aluno [Dorça et al. 2013].

Uma das formas de se gerar conteúdo adaptado aos alunos passa, primeiro, pela detecção dos Estilos de Aprendizagem (EA). A teoria dos EA presume que cada aluno tem

características próprias que o distingue dos outros indivíduos [Silva 2012]. Logo, cada aluno desenvolve uma maneira própria de processar as informações que recebe, sendo este processo denominado Estratégias de Aprendizagem [Price 2004]. Contudo, por mais pessoais que sejam essas estratégias, ainda é possível estabelecer padrões entre elas. Estes padrões são chamados de Estilos de Aprendizagem [Felder et al. 1988, Silva 2012].

Os EAs permitem a criação de ambientes adaptativos, como o Sistema Adaptativo e Inteligente para Educação (SAIE) elaborado por [Dorça 2012]. Seu trabalho objetiva apresentar uma solução estocástica para provimento de adaptatividade e customização de Sistemas Educacionais por meio da modelagem probabilística dos EAs. Em síntese, seu sistema visa modelar o estudante, coletando e atualizando seus dados, de forma a descobrir seu EA. Com esta finalidade, o sistema, durante suas iterações, submete o aluno a avaliações. Notas das avaliações insatisfatórias, geram atualização do modelo do estudante por meio de Aprendizado por Reforço (AR) [Dorça et al. 2013].

Apesar do AR ser uma técnica muito utilizada, [Spronck 2005] afirma que ela pode ser considerada uma técnica “lenta” de aprendizado já que, em geral, demanda mais tempo para ajustar o elemento a ser otimizado, pois não há direção para o aprendizado. Esta lentidão pode prejudicar o sistema em convergir para o EA do aluno, denominado de Estilo de Aprendizado real (EAR). Delongas na convergência implicam na geração de Problemas de Aprendizagem (PAs), isto é, resultados insatisfatórios na avaliação. Significa uma maior dificuldade do aluno em aprender os conceitos ensinados. Assim, faz-se necessário o uso técnicas computacionais que aprimorem a convergência do sistema.

[Spronck et al. 2006] propõem o *Dynamic Scripting* (DS), uma técnica de Aprendizagem de Máquina *online*, isto é, aprendizado concomitante à própria utilização do sistema, que tem como características rapidez, eficácia, robustez, eficiência, clareza, variedade, consistência e escalabilidade. [Spronck 2005] usou DS para tornar a IA de jogos adaptativa, obtendo notáveis resultados em seus experimentos.

O presente trabalho busca aprimorar o SAIE apresentado por Dorça, via substituição do componente de AR por uma adaptação do DS, visando aumentar a velocidade de convergência do sistema e reduzir os PAs frutos da demora dos ajustes realizados pelo AR. Resultados experimentais permitiram validar o uso da adaptação do DS em cenários de EAR Estáticos, em que o EAR não se modifica durante as iterações do sistema, e EAR Dinâmicos, em que o EAR é modificado durante as iterações do sistema. Em testes com EAR Estáticos, a média de redução dos PAs foi de 54.2% em relação à abordagem da literatura. Já em relação EAR Dinâmicos, obteve-se uma redução média de 35.8% dos PAs. Verificou-se, portanto, que a proposta alcança resultados promissores.

Este trabalho se organiza como segue. A seção 2 apresenta o referencial teórico e os principais trabalhos relacionados a esta pesquisa. A seção 3 apresenta de que forma o DS foi adaptado ao conceito de SAIE. Os resultados experimentais são apresentados na seção 4. Finalmente, a seção 5 conclui o trabalho e aponta alguns trabalhos futuros.

2. Referencial Teórico

2.1. Estilos de Aprendizagem

[Kolb 2005] define EA como a preferência de gerenciamento do aluno para trabalhar nas diferentes fases do ciclo da aprendizagem. Por sua vez, [Felder et al. 1988] definiram EA

como o método preferencial que as pessoas optam para receber e processar a informação.

A preocupação em se conhecer os EAs está em impedir que a divergência entre o EAr e a maneira como o conteúdo é exibido dificulte o aprendizado. Busca-se, portanto, uma sintonia entre o EAr e a forma como o conteúdo é exibido, com o objetivo de melhorar a produtividade do aluno no processo de ensino-aprendizagem.

Não é pacífico na literatura a validade da teoria dos EAs. Há trabalhos que enumeram possíveis falhas e controvérsias inerentes a esse assunto. [Veenman et al. 2003], por exemplo, criticam o modelo de detecção dos EAs baseado em questionários, alegando que o estudante não está apto a dizer verdadeiramente o que lhe é melhor. [Rawson et al. 2017] ressalta ainda a baixa correlação entre o que é respondido em um formulário e a verdade, evidenciando a baixa credibilidade dessas respostas.

[Kirschner et al. 2013] apontam que a muitos dos EAs são determinísticos, onde ao aluno não é atribuído um EA baseado em um conjunto de pontuações em diferentes dimensões, mas é classificado em um grupo específico. Essa clusterização em determinados EAs leva à compreensão de um EA fixo, o que pode comprometer a motivação para se aplicar e se adaptar à circunstâncias diferentes [Pashler et al. 2008].

Para [Kirschner 2017], uma preferência por um determinado EA é sinal de fraqueza em relação aos outros, logo, deve ser eliminada e não respeitada. [Hood et al. 2017] criticam ainda a existência de mais de 70 modelos de detecção e delimitação de EA que não são coerentes entre si e que comprometem toda a validade da teoria.

Apesar das críticas, pesquisas recentes [Dorça 2012, Falci et al. 2016, Gonçalves 2016, Rodrigues et al. 2016, Sena et al. 2016] assinalam uma tendência na aplicação de ferramentas automáticas de detecção dos EAs que não se amoldam aos parâmetros criticados. A exemplo, tem-se a detecção do EA fundamentada em dados coletados por sistemas durante o processo de ensino-aprendizagem, sendo o questionário opcional, útil apenas para fornecer uma direção inicial.

[Dorça 2012] ressalta o aspecto dinâmico e probabilístico da seleção dos EAs baseando-se no *Felder-Silverman's Learning Styles Model* (FSLSM). O FSLSM possui um caráter probabilístico e separa os EAs em quatro dimensões: a Percepção (Sensorial/Intuitivo), a Entrada de Informações (Imagem/Verbal), Processamento de Informação (Ativo/Reflexivo) e Compreensão (Sequencial/Global) [Felder et al. 1988]. As dimensões dividem-se em 2 polos que indicam o EA do estudante. O FSLSM analisa as dimensões no intervalo [-11,11] através da distância que se encontra de cada polo [Truong 2015]. Assim, cada aluno tem uma maior probabilidade de possuir um EA, mas tem, em probabilidade menor, afinidade com todos os estilos [Silva 2012, Dorça et al. 2013].

2.2. O SAIE de [Dorça 2012] e suas Adaptações

SAIEs são softwares de gestão de aprendizagem que coletam dados de interação do aluno e, através de técnicas de IA, inferem suas características. A partir de então, o sistema passa a adaptar o ensino com base nas inferências realizadas [Dorça 2012].

[Dorça 2012] propôs um SAIE composto pelos Modelo do Estudante (ME), o Módulo Pedagógico (MP), e o Componente de Modelagem do Estudante (CME).

O ME contém o Estilo de Aprendizagem Probabilístico (EAp), o Estado cognitivo

(EC), e os Objetivos de Aprendizagem (OAs). O EAp é armazenado por valores reais no intervalo $[0,1]$, sendo estes valores a probabilidade da preferência de um ou outro EA de cada dimensão do FSLSM. O EC, baseado na Taxonomia de Bloom [Diab et al. 2017], versa sobre o nível de conhecimento do aluno em cada conceito a ser aprendido. Existem 6 Níveis Cognitivos (NC), sendo: Conhecimento, Compreensão, Aplicação, Análise, Síntese e Avaliação. O EC indica qual o NC atual do aluno em dado conceito. Por sua vez, os OAs indicam quais NCs o aluno deve atingir. A condição de parada do algoritmo é a igualdade do ECs e OAs para todos os conceitos a serem aprendidos [Dorça 2012].

O MP seleciona a estratégia pedagógica mais apropriada conforme o ME, com base em uma Combinação de Estilos de Aprendizagem (CEA) definida pelas 4 dimensões do FSLSM. A cada interação, o MP seleciona estocasticamente uma CEA. Há 2 polos para cada uma das 4 dimensões, assim, no total, 2^4 CEAs. Dessa forma, o aluno pode, com maior ou menor chance, se enquadrar em qualquer das 16 CEAs possíveis [Dorça 2012].

O CME realiza a atualização dos EAp no ME, usando AR. Ocorrendo um PA, usa-se a nota e a distância do EA (DEA), isto é, a distância entre os polos de cada dimensão do FSLSM, para calcular o reforço. Então, aplica-se o reforço no EAp, atualizando-se as probabilidades de seleção das CEAs para a próxima interação [Dorça 2012].

O algoritmo 1 destaca a utilização do AR considerando os componentes do SAIE. Seus principais passos são discutidos em seguida.

Algoritmo 1: AR aplicado à modelagem automática de EA [Dorça 2012]

```

1  início
2  inicialize o ME;
3  repita
4      Selecione um conceito  $C$  a ser apresentado ao estudante;
5      Selecione, através do MP, uma CEA  $\alpha$ ;
6      Execute  $\alpha$ , apresentando adequadamente o objetos de aprendizagem que ensinam  $C$  ao estudante;
7      Avalie, através do CME, a performance do aluno no conceito  $C$ ;
8      Atualize o EC no conceito  $C$ ;
9      Calcule o reforço  $R$ ;
10     Atualize o EAp do ME;
11     Faça de  $s$  o proximo estado, dado por  $s'$ ;
12 até  $s$  seja o estado final;
13 fim

```

O passo 2 inicializa as variáveis contidas no ME no estado s , sendo s a descrição dos EAp armazenados pelo ME. O passo 4 seleciona o conceito a ser ensinado. O passo 5 realiza a seleção da CEA com base no EAp. O passo 6 apresenta ao aluno o conceito selecionado com base a CEA. O passo 7 submete o aluno a uma avaliação. No passo 8, o EC do aluno no conceito selecionado é atualizado. O passo 9, com base na nota, calcula o valor do reforço. O passo 10 atualiza o EAp com base no reforço calculado no passo 9. O passo 11 incrementa o estado s para o próximo estado s' . Repete-se o processo descrito até que s seja estado final.

[Haider 2010] julga que fatores aleatórios podem influenciar a avaliação do aluno. Isto quer dizer que o ME pode conter o EAp bem próximo do EAr, mas, mesmo assim, a nota do aluno ser insatisfatória. Caso este fato ocorra, o AR trabalhará no sentido de distanciar o EAp do EAr. Há, portanto, nesse caso, um erro na aplicação do reforço.

[Gonçalves 2016] preocupado com a incorreta aplicação de reforço, propôs uma abordagem que usa a série histórica das notas obtidas para cada CEA. A proposta acres-

centa a média das notas no ME, permitindo que o MP venha a se valer de mais uma variável para maximizar a chance de uma escolha correta da apresentação do conteúdo. Inova, ainda, na aplicação de reforço positivo caso a nota obtida seja 90% ou maior.

[Falci et al. 2016], de posse das notas anteriores, categorizou o cálculo do reforço não apenas com base na nota da interação, mas em todos os resultados já coletados, permitindo ainda, que sejam aplicados reforços positivos, de acordo com a categoria em que a nota se enquadrou. Assim, diminuem-se as chances de aplicação indevida de reforço.

[Rodrigues et al. 2016] substituiu a seleção de CEAs com uso de Cadeias de *Markov*, por Lógica *Fuzzy*. Inova na clusterização das notas em 5 conjuntos difusos em uma escala de Muito Ruim a Muito Boa. Usa o histórico armazenado das médias oriundas de cada conjunto difuso, obtendo resultados promissores em cenários com EAr Estáticos.

Apesar da obtenção de bons resultados, abordagens que usam histórico podem comprometer o aspecto probabilístico do sistema, além de se tornarem inapropriadas para cenários de EAr Dinâmicos, uma vez que, o histórico não irá contribuir caso o EAr mude durante as interações. [Cerqueira 2000, Dorça 2012, Silva 2012] ressaltam que os EAr sofrem alterações (graduais ou abruptas), influenciadas pelo conteúdo estudado, pelo fruto do processo de amadurecimento, e/ou por qualquer outra razão desconhecida.

Este trabalho propõe a substituição do AR por uma adaptação do DS para atualização das probabilidades das CEAs. Objetiva-se, portanto, aumentar a velocidade de convergência do EAp para o EAr, bem como reduzir os riscos de aplicação de reforço indevido. Tal proposta visa ainda apresentar-se como uma alternativa robusta, sendo compatível e eficiente tanto para cenários de EAr Estáticos quanto Dinâmicos.

2.3. Dynamic Scripting

Dynamic Scripting (DS) é uma técnica de AR *online*, isto é, aprendizado concomitante à própria utilização do sistema, para IA de jogos [Spronck 2005].

AR é uma técnica de Aprendizado de Máquina que mapeia estados à ações [Sutton et al. 1998]. As ações afetam o estado do ambiente e geram recompensas, que são encarregadas de medir o desempenho do agente em uma atividade. O objetivo do agente é maximizar os valores das recompensas recebidas [Armstrong et al. 2006]. No AR o aprendizado é por tentativa e erro. Assim, dado um estado do ambiente, o agente escolhe uma ação e a executa. Como resultado desta ação, o agente muda para outro estado (ou permanece no mesmo estado) e recebe uma gratificação. Repetindo este ciclo, o agente aprende quais ações deve tomar para receber as maiores recompensas [Sutton et al. 1998].

Em geral, técnicas de AR não são eficientes para a aprendizagem *online*, pois demandam grande quantidade de tentativas para convergência [Rabin 2002]. Portanto, são aptas para problemas em que as tentativas ocorrem num curto intervalo de tempo. O DS, por outro lado, é capaz de aprender a partir de poucas tentativas por meio do uso de *scripts* tradicionais de IA, que limitam o tamanho do espaço de estados [Spronck 2005].

Scripts de IA para jogos consistem em uma sequência de regras, onde cada regra consiste em duas partes: uma condicional, que identifica um ou mais estados do jogo; e uma de ação, que descreve a ação a ser tomada caso a condição seja satisfeita [Spronck 2005]. Contudo, estes *scripts* não apresentam características adaptativas. Seu funcionamento é baseado em uma série de regras, já conhecidas, que respondem aos es-

tados do jogo. Já o DS adiciona a capacidade de explorar a representação do espaço de estados (que os *scripts* produzem) para uma aprendizagem rápida e eficiente, ao mesmo tempo em que confia no conteúdo baseado em *scripts* para garantir que todo o comportamento adaptativo seja plausível e eficaz [Spronck 2005].

O mecanismo do DS pode ser definido em cinco etapas [Osaka et al. 2006]:

1. Uma base de dados, constituída por um conjunto de regras, é atribuída a um agente;
2. Regras são selecionadas da base, de acordo com os pesos, para a criação do *script*;
3. O agente de IA batalha contra o jogador usando o conteúdo de seu *script*;
4. O peso de cada regra no *script* é atualizado de acordo com o resultado da batalha;
5. Vá para 2.

O DS usa uma base de dados onde cada regra tem um peso que determina sua probabilidade de seleção para um *script*. Ao final de cada batalha, calcula-se um valor de *fitness*, que representa a eficácia do comportamento do agente. A *fitness*, mensura o desempenho do agente, e é usada para atualizar o peso das regras do *script* [Spronck 2005].

A função de atualização de peso altera o peso das regras nos *scripts*, de acordo com o valor de *fitness* obtido. Valores altos de *fitness* aumentam os pesos, e baixos valores de *fitness* os diminuem. Assim, regras que fazem os agentes funcionarem bem serão associadas aos pesos maiores, o que significa que essas regras serão selecionadas com maiores probabilidades [Spronck 2005]. Dessa forma, os agentes controlados pelo DS se adaptarão e se sairão melhor contra um determinado jogador.

3. Abordagem Proposta

Este trabalho apresenta uma adaptação da técnica de DS, chamada de *Adapted Dynamic Scripting* (ADS), para o SAIE proposto por [Dorça 2012].

O ADS possui um conjunto de regras constituídas por uma (ou mais) condições, uma ação, e um peso. As condições usam a nota e/ou a DEA. As ações consistem na aplicação de reforço positivo ou negativo no EAp. Já o peso determina a probabilidade de seleção da regra. De forma geral, as regras são bastante simples. Alguns exemplos são:

- Se (*nota* > 95) então aplique reforço no EAp de 5%;
- Se (*nota* < 10) e (*DEA* < 0.2) então inverta os polos do EAp;
- Se (*nota* < 60) e (*DEA* < 0.1) então aplique reforço de -5% .

Foram criadas 40 regras que constituem a base de regras, sendo que 20 regras são necessárias para se compor um *script*. O mecanismo do ADS pode ser definido como:

1. Gere um *script* selecionando probabilisticamente 20 regras da base de regras;
2. Avalie o aluno e execute o *script*;
3. Atualize os pesos de todas as regras.

O passo 1 realiza o sorteio das regras que serão incorporadas ao *script*, considerando seus pesos. Todas as 40 regras são inicializadas com peso = 2,5, ou seja, com a probabilidade de 2,5% de serem sorteadas. O passo 2 verifica se as condições das regras no *script* são satisfeitas. Para cada regra que tem sua condição satisfeita, sua ação é executada. O passo 3 atualiza os pesos de todas as 40 regras de acordo com a nota obtida pelo aluno. Tais ajustes são realizados pela Equação 1:

$$f(n, i) = \frac{1}{1000} * (n / \frac{Sc_i}{Si}), \quad (1)$$

onde: n é a nota obtida pelo aluno; $i \in \{1, 2, \dots, 20\}$ é o nº da regra, S_{c_i} é o nº de vezes que a condição da regra i foi satisfeita; S_i é o nº de vezes que a regra i foi sorteada.

A aplicação da equação 1 segue a seguinte lógica:

- Caso a nota > 60 , os pesos das regras do *script* serão atualizados positivamente (equação 1), enquanto os pesos das regras da base de regras, que não foram selecionadas para o *script*, serão atualizados negativamente. Para isto, o somatório dos valores das atualizações positivas é dividido por 20 (número de regras que não foram selecionadas para o *script*) e o resultado é subtraído dos pesos das regras que não estão no *script*. Esta medida garante que a soma das probabilidades das 40 regras criadas seja sempre igual a 1.
- Caso a nota < 60 , ocorre o oposto, os pesos das regras que não foram selecionadas para o *script* serão atualizados positivamente (equação 1), enquanto os pesos das regras do *script* serão atualizados negativamente de acordo com o somatório dos valores das atualizações feitas aos pesos das regras que não estão no *script*.

Dessa forma, regras associadas aos maiores pesos, obtidos através de boas notas, serão consideradas mais apropriadas e, portanto, terão maiores chances de serem selecionadas para a criação do *script*.

O algoritmo 1, para acomodar a utilização do ADS, foi alterado em dois de seus pontos, a saber: antes do passo 4, acrescentou-se o passo 1 aqui apresentado. O passo 9 foi substituído pelos passos 2 e 3 aqui apresentados.

4. Sessão Experimental

4.1. Metodologia Experimental

O ADS se propõe a ser eficaz tanto para casos de EAr Estáticos quanto para EAr Dinâmicos. Assim, para validar a proposta, foram realizados testes comparativos com as abordagens de [Dorça 2012] e [Falci et al. 2016] para EAr Estáticos e, com a abordagem de [Dorça 2012] para EAr Dinâmicos¹.

Os parâmetros utilizados nos testes são os definidos por [Dorça 2012], a saber: nota mínima para aprovação: 60%; quantidade de conceitos a serem aprendidos: 60; EAp inicial carregado no ME: Ativo, Sensitivo, Visual e Sequencial.

Os testes para EAr Dinâmicos foram realizados mudando o EAr, que é inserido no sistema no início da execução, a cada 150 interações. Assim, o sistema é iniciado com um EAr, e após 150 interações, esse EAr é alterado invertendo-se os polos das 2 últimas dimensões. Em seguida, executam-se mais 150 interações e, alteram-se, novamente, os outros 2 polos do EAr que não haviam sido alterados. Assim, inicia-se com um EAr e após 300 interações o sistema buscará convergir para um EAr oposto ao buscado inicialmente.

Realizaram-se 30 testes para cada CEA possível, sendo $2^4 \cdot 30$ testes para cada abordagem com EAr Estáticos e EAr Dinâmicos.

¹Não foram comparadas as abordagens de [Falci et al. 2016, Gonçalves 2016, Rodrigues et al. 2016] para EAr Dinâmicos, pois, como falado na seção 2.2, tais abordagens não são apropriadas para estes casos.

Tabela 1. Comparativo para EAr Estático.

	Dorça	Falci	ADS	Dorça	Falci	Dorça	Falci	ADS	Dorça	Falci
	Média Interações			%	%	Média PA			%	%
Experimento 1	383.8	361.2	366.2	-4.5	1.4	23.8	1.2	6.2	-73.6	423.3
Experimento 2	396	366.1	378.2	-4.4	3.3	36.0	6.1	18.2	-49.3	196.2
Experimento 3	394.8	368.3	371.3	-5.9	0.8	34.8	8.3	11.3	-67.3	37.1
Experimento 4	394.7	520.1	386.0	-2.2	-25.7	34.7	160.1	26.0	-25	-83.7
Experimento 5	395.2	365.7	376.4	-4.7	2.9	35.2	5.7	16.4	-53.2	185.2
Experimento 6	405.4	520.9	378.7	-6.5	-27.3	45.4	160.9	18.7	-58.8	-88.3
Experimento 7	402.5	515.1	379.2	-5.7	-26.3	42.5	155.1	19.2	-54.7	-87.6
Experimento 8	402.6	369.7	375.4	-6.7	1.5	42.6	9.7	15.4	-63.9	57.6
Experimento 9	405.5	364.5	380.3	-6.2	4.3	45.5	4.5	20.3	-55.3	352.2
Experimento 10	401.9	518.9	385.7	-4	-25.6	41.9	158.9	25.7	-38.5	-83.7
Experimento 11	403	521	377.7	-6.2	-27.5	43.0	161	17.7	-58.7	-88.9
Experimento 12	410.7	367.8	381.2	-7.1	3.6	50.7	7.8	21.2	-58.1	172.4
Experimento 13	408.9	524.5	386.4	-5.5	-26.3	48.9	164.5	26.4	-45.9	-83.9
Experimento 14	411.1	368	390	-5.1	5.9	51.1	8	30	-41.2	272.2
Experimento 15	413.3	368.2	380.9	-7.8	3.4	53.3	8.2	20.9	-60.7	152.9
Experimento 16	419.8	364.3	382.1	-8.9	4.8	59.8	4.3	22.1	-62.9	407.3
Média	403.1	424	379.7	-5.7	-7.9	43.1	64	19.7	-54.1	-69.1

4.2. Resultados Experimentais

4.2.1. EAr Estáticos

A tabela 1 apresenta os resultados obtidos nos testes considerando EAr Estáticos. Cada experimento corresponde a uma CEA possível. As colunas que contém o símbolo %, correspondem à variação das outras abordagens em relação ao ADS. Considerando os PAs, o ADS obteve uma redução de 54,1% em comparação a [Dorça 2012] e de 69,1% em relação a [Falci et al. 2016]. Destaca-se o Experimento 1 que apresentou uma redução nos PA de 73.6%, em relação a [Dorça 2012]. Nesse exemplo, o EAp inicial é igual ao EAr e, pode-se verificar o quanto o ADS contribuiu para acelerar a convergência, reduzindo os erros de reforço aplicados pelo AR.

Quanto ao número de interações, o ADS obteve uma redução de 5,7% comparado a [Dorça 2012] e de 7,9% a [Falci et al. 2016]. É importante notar que embora a redução do nº de interações possa parecer pequena, em casos de aplicações reais, tais reduções são consideráveis. A exemplo, a UNIUBE, em seu modelo pedagógico de EAD de graduação, cada seção de aprendizagem (interação) possui uma semana de duração [Uberaba 2016]. Logo, essa redução, do ponto de vista real, significa um ganho considerável.

4.2.2. EAr Dinâmicos

A tabela 2 apresenta os resultados obtidos nos testes com EAr Dinâmicos, onde, considerando-se os PAs, o ADS apresenta uma redução de 35,8% em comparação a [Dorça 2012]. Destaca-se o Experimento 13 que apresentou uma redução de 48,9%, quase a metade dos PAs.

Em relação ao número de interações, o ADS apresentou uma redução de 5,9% para alcançar os OAs. É satisfatório o desempenho do ADS em relação à [Dorça 2012], haja visto que, uma interação, em casos reais, demanda tempo considerável.

5. Conclusão e Trabalhos Futuros

Este trabalho apresentou o ADS, uma adaptação da técnica de DS para aprimorar a convergência de um SAIE, com vistas a detectar e atualizar o EA do estudante para oferecer

Tabela 2. Comparativo para EA Dinâmico.

	Dorça	ADS	%	Dorça	ADS	%
	Média Interações			Média PA		
Experimento 1	418.2	393	-6	58.2	33	-43.2
Experimento 2	426.6	404	-5.2	66.6	44	-33.8
Experimento 3	428.7	412.1	-3.8	68.7	52.1	-24.2
Experimento 4	424.8	406.9	-4.2	64.8	46.9	-27.6
Experimento 5	423.5	397.4	-6.1	63.5	37.4	-41
Experimento 6	433.8	404	-6.8	73.8	44	-40.4
Experimento 7	433.5	417.2	-3.7	73.5	57.2	-22.1
Experimento 8	428.1	396.5	-7.3	68.1	36.5	-46.3
Experimento 9	431.6	422.2	-2.1	71.6	62.2	-13
Experimento 10	431.0	397.7	-7.7	71	37.7	-46.8
Experimento 11	430.3	402.5	-6.4	70.3	42.5	-39.5
Experimento 12	440.5	421.8	-4.2	80.5	61.8	-23.2
Experimento 13	434.0	397.7	-8.3	74	37.7	-48.9
Experimento 14	435.3	406.1	-6.6	75.3	46.1	-38.6
Experimento 15	437.7	402.1	-8.1	77.7	42.1	-45.8
Experimento 16	443.6	411.6	-7.2	83.6	51.6	-38.2
Média	431.3	405.8	-5.9	71.3	45.8	-35.8

ao aluno um ensino personalizado. Levou-se em consideração que o EA do aluno muda ao longo do processo de ensino aprendizagem, necessitando de uma abordagem robusta que fosse apta a lidar com essa situação. Resultados experimentais apontaram redução na quantidade de interações bem como no número de PA em relação a trabalhos da literatura.

Como trabalho futuro pretende-se que o sistema aprenda automaticamente a estrutura das regras que são utilizadas pelo ADS, e não somente seus pesos.

Referências

- Armstrong, W., Christen, P., McCreath, E., and Rendell, A. P. (2006). Dynamic algorithm selection using reinforcement learning. In *Integrating AI and Data Mining, 2006. AIDM'06. International Workshop on*, pages 18–25. IEEE.
- Carqueira, T. C. S. (2000). *Estilos de aprendizagem em universitários*. PhD thesis.
- Diab, S. et al. (2017). Classification of questions and learning outcome statements (los) into blooms taxonomy (bt) by similarity measurements towards extracting of learning outcome from learning material. *arXiv preprint arXiv:1706.03191*.
- Dorça, F. A. (2012). *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*. PhD thesis.
- Dorça, F. A., Lima, et al. (2013). Comparing strategies for modeling students learning styles through reinforcement learning in adaptive and intelligent educational systems: An experimental analysis. *Expert Systems with Applications*, 40(6):2092–2101.
- Falci, S. H., Vivas, A., Assis, L., and Pitanguí, C. (2016). Uma Nova Abordagem para Aplicação de Reforço em Sistemas Automáticos e Adaptativos de Detecção de Estilos de Aprendizagem. *ReABTIC*, 1(6).
- Felder, R. et al. (1988). Learning and teaching styles in engineering education. *Engineering education*, 78(June):674–681.
- Gonçalves, A. V. (2016). Modelagem Automática e Dinâmica de Estilos de Aprendizagem em Sistemas Adaptativos e Inteligentes para Educação a Distância: Estudo Comparativo entre Duas Abordagens. (1):121.

- Haider (2010). An Investigation of relationship between learning styles and performance of learners. . *International Journal of Engineering Science and Technology*, 2(7).
- Hood, B. et al. (2017). No evidence to back idea of learning styles. *The Guardian*, (March).
- Kenski, V. M. (2003). *Tecnologias e ensino presencial e a distância*. Papirus Editora.
- Kirschner, P. A. (2017). Stop propagating the learning styles myth. *Computers and Education*, 106:166–171.
- Kirschner, P. A. et al. (2013). Do learners really know best? urban legends in education. *Educational psychologist*, 48(3):169–183.
- Kolb, A. Y. (2005). The kolb learning style inventory-version 3.1 2005 technical specifications. *Boston, MA: Hay Resource Direct*, 200:72.
- Osaka, S. et al. (2006). A method for online adaptation of computer-game ai rulebase. In *Proceedings of the 2006 ACM SIGCHI international conference on Advances in computer entertainment technology*, page 16. ACM.
- Pashler, H., McDaniel, M., Rohrer, D., and Bjork, R. (2008). Learning Styles: Concepts and Evidence. *Psychological Science in the Public Interest*, 9(3):105–119.
- Price, L. (2004). Individual differences in Learning: Cognitive control, cognitive style, and learning style. *Educational Psychology*, 24(5):681–698.
- Rabin, S. (2002). *AI Game Programming Wisdom*. Charles River Media; 1 edition (April 3, 2002), Boston, first edit edition.
- Rawson, K., Stahovich, T. F., and Mayer, R. E. (2017). Homework and achievement: Using smartpen technology to find the connection. *Journal of Educational Psychology*.
- Rodrigues, L. H. S., Assis, L., Vivas, A., Pitangui, C., and Falci, S. (2016). Análise comparativa de novas abordagens para modelagem automática e dinâmica de estilos de aprendizagem em sistemas adaptativos e inteligentes para educação. (Cbie):1076.
- Sena, E. B. et al. (2016). Uma abordagem computacional para detecção automática de estilos de aprendizagem utilizando modelos ocultos de markov. *SIED: EnPED*.
- Silva, L. L. V. (2012). Estilos e estratégias de aprendizagem de estudantes universitários.
- Spronck, P. (2005). *Adaptive Game AI*. PhD thesis, Universitaire Pers Maastricht.
- Spronck, P., Ponsen, M., Sprinkhuizen-Kuyper, I., and Postma, E. (2006). Adaptive game AI with dynamic scripting. *Machine Learning*, 63(3):217–248.
- Sutton, R. S. et al. (1998). *Reinforcement learning: An introduction*, volume 1. MIT press Cambridge.
- Truong, H. M. (2015). Integrating learning styles and adaptive e-learning system: Current developments, problems and opportunities. *Computers in Human Behavior*.
- Uberaba, U. d. (2016). *Manual do Professor Tutor*. Uberaba, MG.
- Veenman, M. V. J., Prins, F. J., and Verheij, J. (2003). Learning styles: Self-reports versus thinking-aloud measures. *British Journal of Educational Psychology*, 73:357–372.