

Uma Nova Abordagem para 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

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

pitangui.cristiano@gmail.com

Abstract. *Adaptive and Intelligent Education Systems (SAIEs) seek to provide personalized student assistance by detecting their Learning Style (EA). One of the most exploited techniques for this detection is Reinforcement Learning (RA). However, such technique, in some cases, is considered of slow convergence. This work proposes the improvement of a SAIE using an adaptation of the technique of textit Dynamic Scripting, considered faster than the AR. Experiments using a student behavior simulator demonstrated that the approach, compared to the literature solutions, reduced the number of learning problems by $\approx 54\%$, and $\approx 35\%$, respectively, for Static and Dynamic EAs, while increasing the students' average score by $\approx 6.06\%$, which are very promising results.*

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 realizados utilizando-se um simulador de comportamento do estudante, demonstraram que a técnica utilizada neste trabalho, 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 aumentou a nota média dos estudantes em $\approx 6,06\%$, sendo estes, resultados muito promissores.*

1. Introdução

A Educação à Distância (EAD) pode ser conceituada como uma modalidade de ensino, viabilizada por Tecnologias da Informação e Comunicação (TIC), onde os atores envolvidos, professores e alunos, estão distantes espacial e/ou temporalmente [Moran 2000, Landim 1997]. As TICs conduzem a uma constante reestruturação dessa modalidade de ensino, permitindo a implementação de novos métodos, técnicas e procedimentos que otimizam o processo de ensino/aprendizagem [Kenski 2003, Barros 2009].

O pleno desenvolvimento da EAD que, em 2015, já possuía cerca 5.048.912 alunos matriculados [ABED 2016], demandou a criação dos Ambientes Virtuais de Aprendizagem (AVA). Estes, tratam-se de tecnologias integradoras e englobantes voltadas para organizar e orientar o ensino pela internet [Galafassi et al. 2013]. Um AVA reúne em um ambiente virtual, geralmente baseado na WEB, diversas ferramentas, como fóruns, wikis e diversas outras tecnologias colaborativas [Rosemann et al. 2014].

Contudo, um AVA não proporciona uma experiência de ensino orientada às características individuais do aluno. Para assegurar a qualidade do ensino na EAD é necessário observar que os alunos aprendem de formas distintas, assim, é necessário diversificar as estratégias e os materiais empregados, como forma de tornar o processo de ensino/aprendizagem mais otimizado e adequado a cada estudante [Netto et al. 2010]. Surgem então, Ambientes de Aprendizagem mais complexos, que se utilizam de técnicas de Inteligência Artificial (IA), para buscar a promoção de um aspecto mais adaptativo.

A estratégia utilizada para tornar um sistema adaptativo, passa primeiro por uma coleta de informações do usuário para assim adaptar-lhe algo. Entretanto, o que se questiona, são quais informações são essenciais para que o atendimento seja devidamente personalizado e de fato otimize o ensino.

Considerando-se que o indivíduo possui um processo mental, às vezes inconsciente, de como processar as informações, o professor, ao apresentar o conteúdo, pode usar de procedimentos que se encaixem a esse processo mental. Dessa forma, pouparia o aluno da necessidade de organizar a sequência em que processaria as informações para assimilá-la [Haider 2010]. Não obstante a isso, é possível ainda, que os conceitos a serem ensinadas ao aluno, estejam dispostos de acordo com sua preferência de interagir. Em outras palavras, temos pessoas que preferem ver os dados a serem estudados distribuídos em um gráfico, ao passo que outras preferem ler a descrição de como os dados foram distribuídos [Adán-Coello et al. 2008].

Naturalmente, oferecer a cada uma dessas pessoas o conteúdo da forma que elas mais apreciam, facilitará o seu aprendizado e tornará o processo de ensino/aprendizagem mais prazeroso. Essa preferência de interação denomina-se Estilos de Aprendizagem (EA). EA referem-se à maneira preferencial que as pessoas escolhem receber e processar a informação [Felder and Silverman 1988], ou descrevem as preferências dos estudantes quando recebem e processam informações [Crockett et al. 2013], ou ainda, como os estudantes percebem, interagem e respondem ao processo de ensino, sendo, portanto, uma medida de diferenças particulares [Dagez and Baba 2008, Silva 2012]. Embora tenha-se o conceito de Estratégias de Aprendizagem, isto é, conjunto de ações através das quais alcança-se os objetivos de aprendizagem, verifica-se que o estilo é mais amplo que a estratégia, uma vez que dentro de uma preferência de aprendizagem cabem diversas estratégias, podendo estas serem adequadas aos estilos do aprendiz [Gallego 2008].

A literatura apresenta que os EA desempenham um papel importante no processo de aprendizagem e que podem tornar o aprendizado mais fácil e eficiente [Ahmad and Tasir 2013, Dorça et al. 2011]. [Felder and Silverman 1988, Dorça 2012] salientam que, quando ocorre discrepância de estilos, os alunos podem ficar desatentos e desmotivados em relação ao conteúdo a ser aprendido. Há casos que essa incompatibilidade de EA pode vir a motivar a evasão e/ou mudança de curso, uma vez que o aluno

pode vir a associar a forma como o conteúdo é ensinado a um determinado curso.

Muito embora os EA apresentem vantagens, não é simples a sua aplicação na prática. Críticas apontam para a fragilidade da detecção por meio de questionários psicométricos, método este, largamente utilizado para esse fim. Surge, então, uma tendência na aplicação de ferramentas automáticas de detecção dos EAs. A exemplo os Sistemas de Hiperídia Adaptativa(SHA) e Sistemas Tutores Inteligentes (STI), que modelam o usuário através da coleta de seus dados de navegação para em seguida adaptar-lhe o conteúdo. A etapa de detecção do EA passa a fundamentar-se em informações obtidas pelo sistema durante o processo de ensino-aprendizagem, tornando o questionário como peça opcional[Dorça et al. 2013, Dorça 2012, Dorça et al. 2011].

Ferramentas automáticas de detecção dos EAs estão presentes em 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 interações, submete o aluno a avaliações. Caso as notas destas avaliações sejam insatisfatórias, o sistema realiza a atualização do modelo do estudante por meio de Aprendizado por Reforço(AR) [Dorça et al. 2013]. Para validação de sua abordagem, [Dorça 2012] utilizou-se de um simulador computacional para representar hipoteticamente o comportamento de um estudante na etapa de avaliação.

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 de técnicas computacionais que aprimorem a convergência do sistema [Silva et al. 2017].

Partindo-se desses pressupostos, propõe-se apresentar um método para uma nova abordagem para o SAIE apresentado por [Dorça 2012], visando otimizar o processo de detecção e correção do EA, considerando, para tal, cenários com EA do estudante oscilando durante as interações (Dinâmico) e com EA fixo (Estático). Busca-se reduzir os Problemas de Aprendizagem (PA) e aumentar a nota do aluno, apresentando uma solução que preencha os requisitos defendidos por Dorça, mas que ofereça um módulo de atualização do modelo do estudante mais eficiente. Para tal, pretende-se substituir a técnica de AR utilizada por Dorça, por uma técnica de aprendizagem de máquina *online*, isto é, aprendizado concomitante com a execução do sistema. A técnica escolhida para ser utilizada foi apresentada por [Spronck 2005] e chama-se *Dynamic Scripting* (DS).

A escolha por esta técnica se deu em função do seu aspecto dinâmico, isto é, a sua elevada capacidade de adaptação em cenários imprevistos. Várias técnicas já foram aplicadas a fim de solucionar o problema, desde Redes Bayesianas [Salazar et al. 2017], Média Móvel Exponencialmente Ponderada [Ribeiro et al. 2017],

Lógica Fuzzy [Rodrigues and da Costa 2017, Falci et al. 2017] e outras, contudo, todas essas abordagens trataram apenas cenários de EA estáticos. Como o objetivo deste trabalho é de se garantir um ensino adaptativo em cenários estáticos e dinâmicos, se amolda às características do DS que segue uma lógica de funcionamento semelhante ao da AR. Uma vez verificado que a AR já apresentou bons resultados, uma técnica semelhante, porém mais rápida, surgiu como uma alternativa a ser testada.

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

Muito se fala sobre os Estilos de Aprendizagem, há diversos trabalhos que buscam estudá-los e aplicá-los no ambiente educacional. Como fruto dessa grande quantidade de trabalhos e pesquisadores envolvidos, [Hood et al. 2017] relata a existência de mais de 70 Estilos de Aprendizagem encontrados na literatura.

[Kolb 1971], define Estilo de Aprendizagem como a preferência de gerenciamento do aluno para trabalhar nas diferentes fases do ciclo da aprendizagem [Kolb 2005]. [Dunn et al. 1981], por outro lado, conceituaram Estilo de Aprendizagem como o método pelo qual uma série de 18 elementos distintos, derivados de quatro estímulos primitivos, interferem na capacidade de um indivíduo absorver e reter um determinado conceito.

[Felder and Silverman 1988], uns dos autores mais citados que tratam os EA, definiram Estilos de Aprendizagem como o método preferencial que as pessoas optam para receber e processar a informação. [Alonso et al. 1997] definem os Estilos da Aprendizagem como sendo aspectos cognitivos, que servem de parâmetros, relativamente constantes, da maneira como o estudante interage ao processo de ensino/aprendizagem.

Por fim, [Berings et al. 2005] conceituam EA como uma tendência em buscar utilizar uma determinada estratégia de aprendizagem que lhe é preferencial. Verifica-se que o entendimento pacífico é que cada indivíduo se comporta ou interage de maneira particular diante de cada estímulo e, que essas particularidades influenciam o processo de ensino/aprendizagem [Silva 2012].

Destarte o exposto, há uma preocupação em se conhecer os EAs com o propósito de impedir que ocorra uma divergência entre o EA do estudante e a maneira como o conteúdo é exibido, dificultando-lhe o aprendizado. Busca-se a sintonia entre o EA e a forma como o conteúdo é ministrado com vistas a melhorar/aumentar a produtividade do aluno no processo de ensino/aprendizagem [Cerqueira 2000, Silva 2012].

Entretanto, não é pacífico na literatura o entendimento da validade dos EA. Há posicionamentos que enumeram e tratam de possíveis falhas e controvérsias inerentes a esse assunto.

[Veenman et al. 2003], por exemplo, contestam os métodos de detecção de EA partindo do princípio que, caso existam mesmo os EA, necessita-se conseguir conhecê-los ou detectá-los, para que possam ser usados como parâmetros de personalização do

ensino, contudo, os modelos de detecção dos EAs são em sua grande maioria, baseados em questionários psicométricos. Critica este ponto, alegando que o estudante não está apto a dizer verdadeiramente o que lhe é melhor. [Rawson et al. 2017] concordam com essa premissa e ainda ressaltam a baixa correlação entre o que é respondido em um formulário e a verdade, evidenciando a baixa credibilidade dessas respostas.

Outra crítica é a apresentada por [Kirschner et al. 2013] apontando que a maioria dos EAs tem como características um aspecto determinístico, isto é, presume-se que o EA é estático e, que um EA exclui outro, sendo portanto uma característica engessada acerca do indivíduo. Nesse tipo de abordagem, ao aluno, não é atribuído um EA baseado em um conjunto de pontuações em diferentes dimensões, mas é classificado em um grupo específico, as vezes exclusivo. Essa clusterização em determinados EAs leva à compreensão de um EA fixo. Corroborando com essa análise [Pashler et al. 2008] acrescenta que a ideia de um EA fixo, poderá gerar no aprendiz a sensação de que não é apto a aprender de determinadas formas, comprometendo assim sua motivação para se aplicar e se adaptar às circunstâncias diferentes que lhe serão impostas ao longo da vida.

Entretanto, apesar das críticas, pesquisas recentes [Dorça 2012, Falci et al. 2017, Gonçalves 2016, Rodrigues et al. 2016, Sena et al. 2016] reafirmam a tendência na aplicação dos EA. Inovam no que tange as ferramentas de detecção de EA que não se utilizam de questionários, as abordagens mais atuais tem focado na aplicação de ferramentas automáticas de detecção dos EAs.

Estas ferramentas, que não se amoldam aos parâmetros criticados, buscam a detecção do EA fundamentada em informações coletadas através dos sistemas de gestão de aprendizagem durante o processo de ensino/aprendizagem. Nessa perspectiva, o levantamento de informações por meio de questionário psicométricos se tornam em mecanismos de uso opcional, sendo útil sua utilização apenas para fornecer uma direção inicial ao sistema, mas totalmente dispensável de acordo com [Gonçalves 2016] e [Dorça 2012].

No que tange a característica determinística que foi atribuída a alguns modelos de EA, [Dorça 2012] enfatiza o aspecto dinâmico e probabilístico usado na seleção dos EAs baseando-se no *Felder-Silverman's Learning Styles Model* (FSLSM). O FSLSM, que será tratado adiante, em síntese, 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 and Silverman 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 estudante tem uma maior probabilidade de pertencer a determinado EA, mas possui, em probabilidade menor, afinidade com todos os estilos [Silva 2012, Dorça et al. 2013]. Dessa forma, afasta-se as críticas de [Kirschner et al. 2013] e [Pashler et al. 2008], onde, respectivamente, as abordagens que tratam EA não são todas determinísticas e que o aluno possui uma preferência maior com determinado estilos mas não possui uma limitação em aprender de outras formas.

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 FLSM. O Estado Cognitivo, baseado na Taxonomia de Bloom [Bloom et al. 1956], 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. Este modelo sofreu uma revisão, portanto é cabível considerar também, o novo entendimento dos 6 níveis cognitivos como sendo: Criar, Avaliar, Analisar, Aplicar, Compreender e Recordar [Wilson 2013, Sena et al. 2016]. O Estado Cognitivo indica qual o Nível Cognitivo atual do aluno em dado conceito. Por sua vez, os Objetivos de Aprendizagem indicam quais NCs o aluno deve atingir. A condição de parada do algoritmo é a igualdade do Estado Cognitivo e Objetivos de Aprendizagem 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 FLSM. A cada interação, o MP seleciona estocasticamente uma Combinação de Estilos de Aprendizagem. 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 Combinação de Estilos de Aprendizagem possíveis [Dorça 2012].

O CME realiza a atualização dos EAp no ME, utilizando 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 *FSLM*, 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

```
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  $a$ ;
6     Execute  $a$ , 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 próximo 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 Combinação de Estilos de Aprendizagem com base no EAp. O passo

6 apresenta ao aluno o conceito selecionado de acordo com a Combinação de Estilos de Aprendizagem. O passo 7 submete o aluno a uma avaliação. No passo 8, o Estado Cognitivo do aluno no conceito selecionado é atualizado. O passo 9, com base na nota da avaliação, 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 Combinação de Estilos de Aprendizagem. O método acrescenta 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. 2017], de posse das notas anteriores, categorizou o cálculo do reforço não apenas com base na nota da interação, mas em todas os resultados já coletados, permitindo, que sejam aplicados reforços positivos, de acordo com a categoria em que a nota se enquadrou. Dessa forma, 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 Combinação de Estilos de Aprendizagem. Objetiva-se, portanto, aumentar a velocidade de convergência do EAp para o EAr, bem como reduzir os riscos de aplicação de reforço indevido. Tal técnica visa ainda apresentar-se como uma alternativa robusta, sendo compatível e eficiente tanto para cenários de EAr Estáticos quanto Dinâmicos.

2.3. *Dynamic Scripting* (DS)

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

AR é uma técnica de Aprendizado de Máquina que mapeia estados à ações [Sutton and Barto 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 and Barto 1998].

De forma 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 sua vez, é capaz de aprender a partir de poucas tentativas através dos *scripts* tradicionais de IA, que limitam o tamanho do espaço de estados [Spronck 2005].

Os personagens controlados pela máquina, os chamados *Non-Player Characters* (NPC), são desenvolvidos como agentes inteligentes. Em geral, os NPCs, são controlados por *scripting* os quais estabelecem a lógica que determinará a tomada de decisão desses agentes [Farias 2014].

Esses *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 estados do jogo.

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 conforme apresenta [Osaka et al. 2006]:

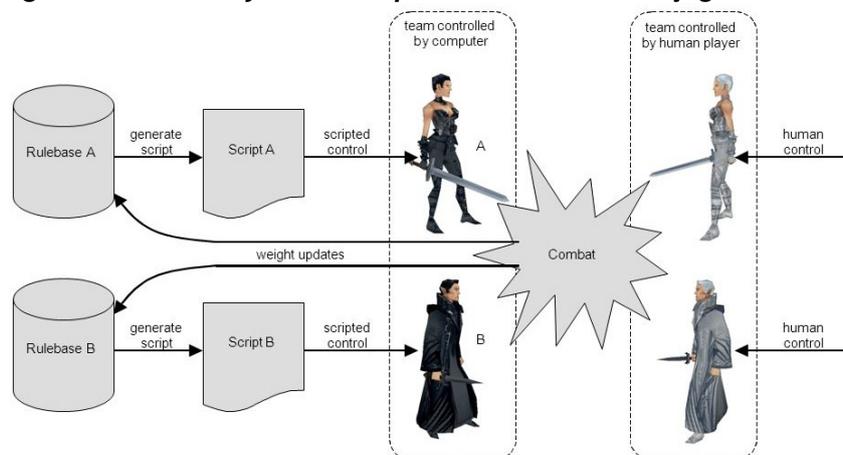
1. Uma base de dados, constituída por um conjunto de regras, é atribuída a um agente;
2. Regras são selecionadas da base, de acordo com os pesos, para a criação do *script*;
3. O agente de IA batalha contra o jogador usando o conteúdo de seu *script*;
4. O peso de cada regra no *script* é atualizado 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 Figura 1 apresenta o funcionamento básico do DS, onde têm-se dois NPC(A e B) os quais possuem uma base de regras cada(*Rulebase A* e *Rulebase B*). Executam-se os *generate script* de ambos os agentes criando-se os *Scripts A* e *B*. Os *Scripts* criados serão responsáveis pelo controle dos NPCs (*team controlled by computer*) A e B durante o *Combat*, ou durante a interação com jogadores humanos. Após o fim do *Combat*, com base nos resultados obtidos, os pesos das regras são atualizados pela função *weight updates*.

A função de atualização de peso(*weight updates* na Figura 1) altera o peso das regras nos *scripts*, de acordo com o valor de *fitness* obtido. O valor chamado *fitness*,

Figura 1. Técnica *Dynamic Script* no contexto de um jogo comercial



Fonte: [Spronck 2005]

corresponde a um coeficiente encontrado a partir dos resultados que determinado *script* obteve em uma partida. Esses valores podem ser, a título de exemplo, a duração da batalha, quantidade de energia restante do personagem, quão determinante foram as ações do agente no resultado da batalha e vários outros possíveis. 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.

Há na literatura muitos trabalhos que utilizam DS nos mais diversos estilos de jogos comerciais. Cita-se os jogos de luta [Majchrzak et al. 2015], jogos de estratégia [Dahlbom and Niklasson 2006], *First-person shooter* (FPS) ou tiro em 1ª pessoa [Policarpo et al. 2010], simuladores de voo [Toubman et al. 2014], *Role-Playing Game* (RPG) [Ladebeck 2008] e outros. Muitos destes trabalhos utilizaram o DS em sua forma original [Spronck 2005] e alguns outros implementaram adaptações à técnica.

[Kop et al. 2015], implementaram uma solução onde, propuseram superar uma limitação da técnica DS que é não ser capaz de gerar um comportamento completamente novo. A fim de eliminar esse inconveniente, integrou o DS a um sistema de programação genética. Um algoritmo genético é usado para alterar as regras existentes e gerar novas, que são integradas ao banco de regras e avaliados pelo DS. Sua abordagem de integração do DS e algoritmo genético, demonstrou ser capaz de sintetizar novas regras, e utilizá-las na composição dos *scripts* do DS. Através de testes em um simulador de combate aéreo, demonstrou ser capaz de melhorar as regras da base de regras existentes.

3. Abordagem Proposta: *Adapted Dynamic Scripting* - ADS

Neste seção será apresentada a adaptação da técnica de DS, chamada de *Adapted Dynamic Scripting* (ADS), para o SAIE proposto por [Dorça 2012].

O ADS é composto por um conjunto de regras constituídas por uma (ou mais) condições, uma ação, e um peso. As condições usam a nota obtida pelo estudante da etapa de avaliação e/ou a Distância do Estilo de Aprendizagem. As ações consistem na

aplicação de reforço positivo ou negativo no EAp contido no ME, podendo ser submetido através de um percentual sobre os valores existentes ou mesmo através de uma constante. Já o peso, por sua vez, determina a probabilidade de seleção de cada regra, sendo o valor que determina a qualidade da regra, quanto maior o peso, mais relevante é a regra. De forma geral, a estrutura das 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* > 95) então aplique reforço no EAp de 0.00456;
- Se (*nota* < 60) e (*DEA* < 0.1) então aplique reforço de -5% .

Para o ADS foram criadas 40 regras que constituem sua base de regras, sendo que 20 dessas 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 corresponde à seleção das regras que serão incorporadas ao *script* através de um sorteio, considerando seus pesos. Na ocasião da inicialização do sistema, todas as 40 regras são inicializadas com peso = 2,5, ou seja, com a probabilidade de 2,5% de serem selecionadas para o *script*. O passo 2 consiste na realização da verificação se as condições das regras do *script* são satisfeitas. Para cada regra que tem sua condição satisfeita, a ação correspondente a ela é executada. O passo 3, por fim, atualiza os pesos de todas as 40 regras de acordo com a nota obtida pelo aluno, sendo que a atualização dos pesos das regras do *script* e das que ficaram na base de regras é feita de forma diferente conforme será tratado a seguir. Tais atualizações são realizados pela fórmula de cálculo do valor de *fitness* dada pela Equação 1:

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

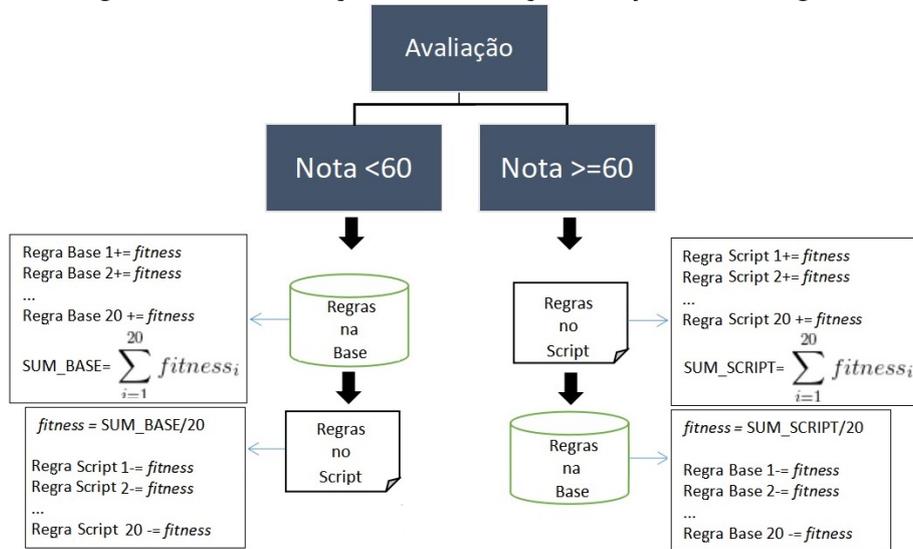
onde: *n* é a nota obtida pelo aluno; $i \in \{1, 2, \dots, 20\}$ é o número da regra, Sc_i é o número de vezes que a condição da regra *i* foi satisfeita; S_i é o número de vezes que a regra *i* foi sorteada.

A aplicação do valor de *fitness* dado pela equação 1 segue a seguinte lógica, representada pela Figura 2 e comentado na sequência:

Se *nota* >= 60, os pesos das regras do *script* serão atualizados positivamente de acordo com seus dados (Sc_i e S_i) submetidos à equação 1, enquanto os pesos das regras da base, que não foram selecionadas para o *script*, serão atualizados negativamente, reduzindo-se portanto, o valor dos seus pesos. Para isto, o somatório dos valores das atualizações positivas que foram realizadas em favor das regras que estavam no *script* é dividido por 20 (número de regras que não foram selecionadas). O valor obtido nessa divisão será subtraído dos pesos das regras que não estão no *script*. Esta medida garante que a soma das probabilidades de seleção das 40 regras criadas seja sempre igual a 1.

Se *nota* < 60, ocorre o oposto, sendo que os pesos das regras que ficaram na base, isto é, que não foram selecionadas para o *script* serão atualizados positivamente de acordo

Figura 2. Demonstração da atualização dos pesos das regras



Fonte: Elaborado pelo autor

com seus dados (S_{c_i} e S_i) submetidos à equação 1. Por outro lado os pesos das regras que estão no *script* serão atualizados negativamente de acordo com o somatório dos valores das atualizações que foram realizadas em favor das regras que estavam na base de regras dividido por 20 (número de regras no *script*). O valor obtido nessa divisão será subtraído dos pesos das regras que estão no *script*, penalizando-as pelo resultado insatisfatório.

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 2 apresenta a utilização do ADS considerando os componentes do SAIE. Em comparação ao Sistema do [Dorça 2012], acrescentou-se um passo inicial que é a seleção das regras para o *script*. Já o passo 9 do algoritmo 1, foi substituído por 2 novos passos, a saber, execução das regras do carregadas no *script* em função da nota obtida naquela interação e, em seguida a atualização dos pesos de todas as regras. Os demais passos permanecem idênticos.

Algoritmo 2: ADS aplicado à modelagem automática e dinâmica de EA

- 1 **início**
 - 2 inicialize o ME;
 - 3 **repita**
 - 4 Selecione regras da base para criar o *script*;
 - 5 Selecione um conceito C a ser apresentado ao estudante ;
 - 6 Selecione, através do MP, uma CEA a ;
 - 7 Execute a , apresentando adequadamente o objetos de aprendizagem que ensinam C ao estudante;
 - 8 Avalie, através do CME, a *performance* do aluno no conceito C ;
 - 9 Atualize o EC no conceito C ;
 - 10 Execute as regras do *script* de acordo com a nota, atualizando o EAp do ME;
 - 11 Atualize os pesos das regras do *script* de acordo com a *performance*;
 - 12 Faça de s o próximo estado, dado por s'
 - 13 **até** s seja o estado final;
 - 14 **fim**
-

A etapa de execução do *script* é a responsável pela atualização do EAp no ME,

sendo que essa atualização poderá ocorrer tanto para nota satisfatória (reforço positivo) quanto para nota insatisfatório (reforço negativo).

3.1. ADS vs AR

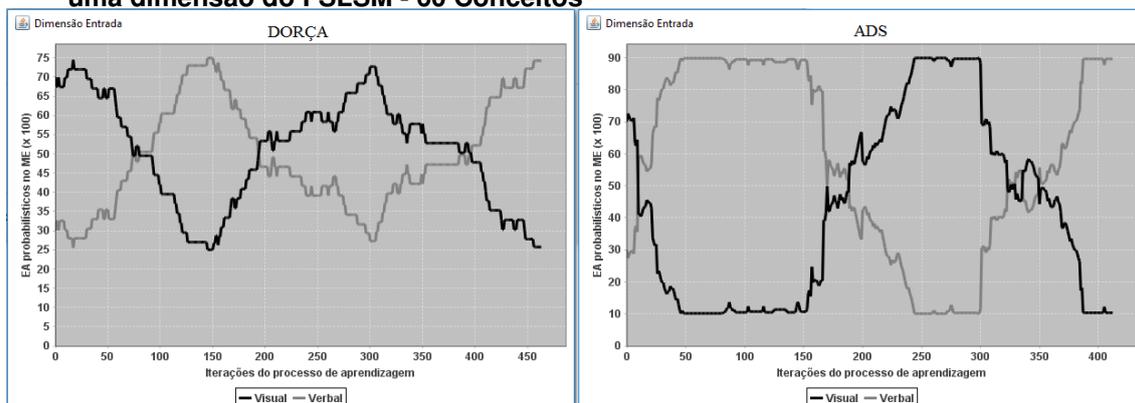
O ADS substitui a AR do CME de [Dorça 2012] e, por se basear em uma técnica de aprendizagem *online*, permite um aprendizado mais rápido. Essa rapidez torna o ADS apto também para situações em que o EAr muda ao longo do processo de ensino/aprendizagem.

Para demonstrar seu comportamento a cada interação, propôs-se 3 testes utilizando uma dimensão arbitrada do FLSM. Estes testes não refletem uma situação real provável, tem apenas a finalidade de demonstrar como as abordagens se comportam quando expostas a uma circunstância extrema, como descrito a seguir.

Os testes consistem em iniciar o sistema com um EAr inicial e, após algumas interações, realizar a mudança do EAr. Cada um dos 3 testes propostos foi com uma carga de conceitos diferentes, haja vista que, quanto menos conceitos forem colocados para o aluno aprender, menor será a quantidade de interações, ou seja, menos tempo para o sistema aprender e convergir para o EAr.

A Figura 3 apresenta o primeiro teste, realizado com uma carga de 60 conceitos. Considerando-se os 6 níveis cognitivos da Taxonomia de Bloom[Bloom et al. 1956], temos 6*60, o que corresponde a um quantitativo mínimo de 360 interações neste caso. Para forçar o sistema a uma carga maior, as mudanças simuladas são bruscas. Dessa forma, o sistema inicializa com um EAr oposto ao EAr inicial e, após 150 interações o EAr muda para o inverso e, após mais 150 interações volta ao anterior, fazendo um vai e vem nos extremos. Muito embora seja um teste simples, é possível verificar como o ADS apresenta uma conversão mais ágil se comparada a AR. Isso se deve ao mecanismo de atualização discretizado pelo mapeamento de estados, permitindo a aplicação de reforço positivo, com uma redução da possibilidade de aplicação de reforço incorreto.

Figura 3. Comparativo de conversão em interações entre as abordagens para uma dimensão do FLSM - 60 Conceitos



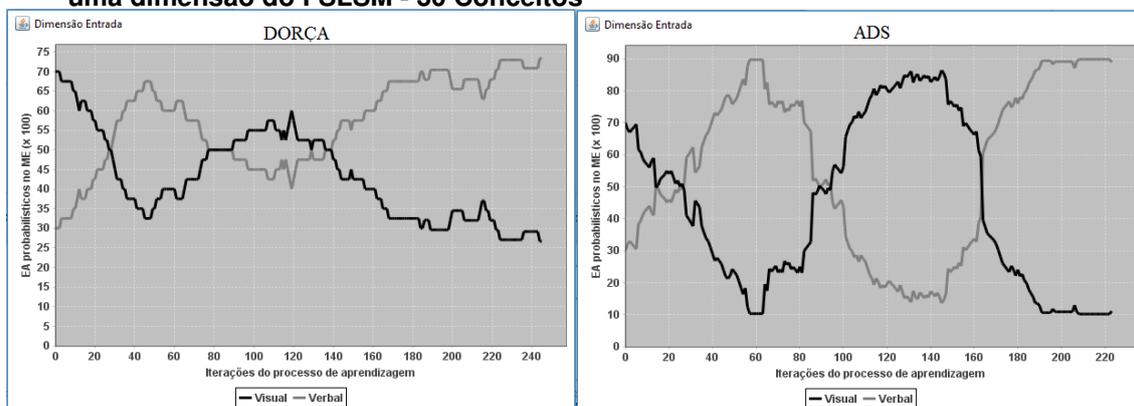
Fonte: Elaborado pelo autor

O ADS, com ≈ 50 interações já convergia para o EAr inicial ao passo que a AR, muito embora convergindo corretamente, demorou ≈ 100 interações para se aproximar do EAr inicial. [Dorça 2012] opta por não aplicar reforço positivo, pois como se trata de um processo estocástico, fatores aleatórios poderiam induzir o sistema a erro, entretanto,

trabalhos como [Gonçalves 2016, Falci et al. 2017, Rodrigues et al. 2016] já demonstraram que a aplicação de reforço positivo corrobora para um aumento na velocidade de conversão do sistema, acrescenta-se que a abordagem com ADS contribui para a redução do risco de se aplicar reforço incorreto, uma vez que, a parte condicional de cada regra, é responsável pela verificação do estado do sistema e portanto permite conhecer se é apropriado ou não a aplicação daquele reforço.

A Figura 4 apresenta o segundo teste, realizado com 30 conceitos. Considerando-se os 6 NC da Taxonomia de Bloom, temos 6×30 , o que corresponde a um quantitativo mínimo de 180 interações. Nesse caso, para forçar o sistema igual o teste da Figura 1, arbitrou-se que a cada 60 interações o EAr mudaria, variando 2x como no exemplo anterior. Neste caso, o tempo que o sistema tem para realizar a convergência para o EAr do aluno é bem menor que o caso anterior.

Figura 4. Comparativo de conversão em interações entre as abordagens para uma dimensão do FLSM - 30 Conceitos



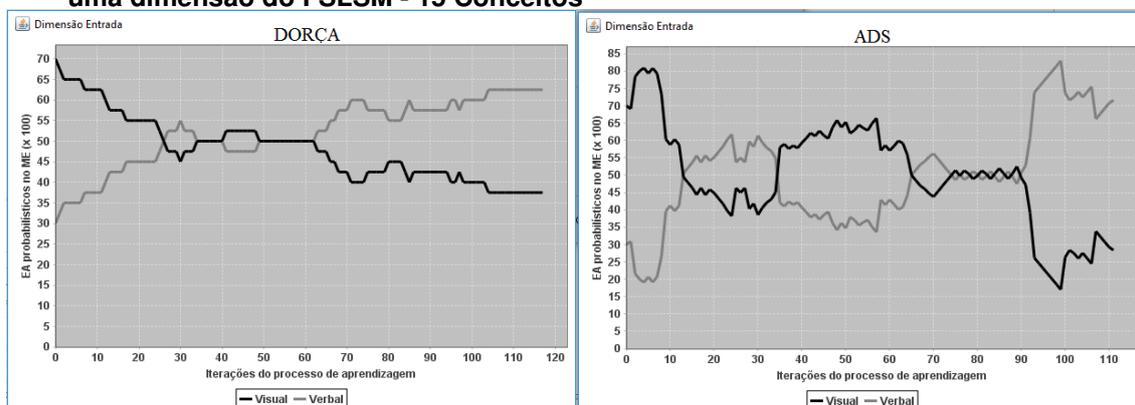
Fonte: Elaborado pelo autor

A abordagem da literatura, neste exemplo, chega a convergir rápido para o EAr inicial, mas quando ocorre a primeira mudança, o sistema oscila na área central do gráfico não convergindo para o novo EAr. Nesse exemplo, enquanto há essa demora na conversão, ocorre inconsistência no EA e é isso que gera o aumento no PAs, veja que em comparação às duas abordagens, a AR teve ≈ 20 interações a mais que com ADS, mais tempo que o estudante precisou se empenhar para aprender os conceitos.

O terceiro e último teste dessa natureza, representado pela Figura 5, simula uma situação ainda mais extrema que as anteriores, a mudança de EAr continua ocorrendo igual os testes anteriores, entretanto a quantidade de conceitos a serem aprendidos agora são 15. Considerando-se os 6 NC da Taxonomia de Bloom, temos 6×15 , o que corresponde a um quantitativo mínimo de 90 interações. Nesse exemplo o EAr mudará 2x a cada 30 interações. Metade do tempo do teste anterior.

O tempo disponível para conversão nesse teste é muito pouco, percebe-se que ambas as abordagens não apresentam um resultado muito bom. Contudo, ainda assim, o ADS se mostrou mais eficiente, mesmo não convergindo completamente para cada mudança de EAr, foram ≈ 10 interações a menos. Nota-se que a abordagem da literatura por ≈ 30 interações permaneceu ao centro da dimensão sem indicar o correto EA do aluno, gerando novamente mais PA.

Figura 5. Comparativo de conversão em interações entre as abordagens para uma dimensão do FLSM - 15 Conceitos



Fonte: Elaborado pelo autor

O propósito destes testes rápidos foi de apenas demonstrar como que o ADS é mais rápido que a AR e, aliado ao reforço positivo, poderá oferecer uma função de adaptabilidade mais eficiente e ágil, certo de que essa rapidez implica em diminuição dos PAs.

4. Sessão Experimental

Neste capítulo serão apresentados os experimentos realizados a fim de validar a viabilidade do ADS, apresentando-se a metodologia utilizada nos experimentos, bem como identificando os parâmetros utilizados nos testes. Em seguida são apresentados os resultados obtidos e, identificados alguns pontos importantes nos indicadores encontrados.

Importa ressaltar que, diante da complexidade do problema da adaptação do ensino, não é factível a realização de experimentos com estudantes reais, haja vista a grande quantidade de tempo que seria necessário. Dessa forma, para otimizar o uso do tempo e tornar factível os testes da abordagem, o comportamento do estudante foi simulado através da plataforma de simulação apresentada por [Dorça 2012] chamada de Processo Estocástico de Simulação de Desempenho do Estudante(PESDE).

O PESDE, em síntese, consiste na inferência do desempenho do estudante considerando que o EA influenciam nos seus resultados. A facilidade promovida pelo aspecto adaptativo do SAIE durante processo de ensino/aprendizagem e a melhoria de *performance* aferida, são reproduzidas pelo PESDE [Dorça 2012]. Assim, os resultados apresentados nesta seção correspondem aos coletados através do simulador de desempenho do estudante PESDE.

4.1. Metodologia Experimental

O ADS se propõe a ser eficaz tanto para casos de EA Estáticos quanto para EA Dinâmicos. Assim, para validar a técnica, foram realizados testes comparativos entre o ADS e a abordagem de [Dorça 2012] tanto para EA Estáticos como para EA Dinâmicos¹. Objetiva-se demonstrar que o ADS, contribui para se elevar o desempenho do estudante a partir da personalização do ensino, sendo que os indicadores utilizados para

¹Não foram comparadas as abordagens de [Falci et al. 2017, Gonçalves 2016, Rodrigues et al. 2016], uma vez que tais abordagens são se propuseram a tratar cenários de EA Dinâmicos

demonstrar essa contribuição são a redução na quantidade de PA encontrados durante o processo de aprendizagem e o aumento da média das notas dos estudantes.

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; EAr inicial carregado no ME: Ativo, Sensitivo, Visual e Sequencial. Salienta-se que [Dorça 2012] não realizou testes com quantidade de conceitos inferior a 60, contudo, neste trabalho são apresentados testes com 60, 30 e 15 conceitos, permanecendo inalterados os demais parâmetros.

Os testes para EAr Dinâmicos foram realizados modificando-se o EAr, que é inserido no sistema no início da execução, a cada 150 interações para testes com 60 conceitos, a cada 60 interações para testes com 30 conceitos, e a cada 30 interações para testes com 15 conceitos. Assim, o sistema é iniciado com um EAr, e após 150/60/30 interações, esse EAr é alterado invertendo-se os polos das 2 últimas dimensões. Em seguida, executam-se mais 150/60/30 interações e, alteram-se, novamente, os outros 2 polos do EAr que não haviam sido alterados. Assim, inicia-se com um EAr e após 300/120/60 interações o sistema buscará convergir para um EAr oposto ao buscado inicialmente.

Realizaram-se 30 testes para cada CEA possível em cada abordagem, sendo $2^4 \cdot 30$ testes para EAr Estáticos e $2^4 \cdot 30$ EAr Dinâmicos. Essa quantidade de testes é para cada carga de conceitos, 60, 30 e 15. Perfazendo, em números absolutos, 2880 testes.

As informações referentes às notas foram obtidas calculando-se a média de todas as notas em cada teste, depois a média das médias dos 30 testes de cada experimento, realizando essa rotina para todas as 16 CEAs.

Os experimentos estão organizados na sequencia elencada por [Dorça 2012], sendo as dimensões do FSLSM representadas da seguinte forma: Ativo(A), Reflexivo(R), Sensitivo(S), Intuitivo(I), Visual(Vi), Verbal(Ve), Sequencial(Sq), Global(G).

5. Resultados Experimentais

Nesta seção serão apresentados os resultados encontrados a partir dos experimentos propostos, divididos em EAr Estáticos e EAr Dinâmicos, contendo tabelas e gráficos comparativos entre a abordagem de [Dorça 2012] e o ADS.

5.1. EAr Estáticos

A tabela 1 apresenta os resultados obtidos nos testes considerando EAr Estáticos com carga de 60 conceitos. Cada experimento corresponde a uma CEA possível. As colunas que contém o símbolo %, correspondem à variação do ADS em relação à [Dorça 2012]. São apresentados a média de interações, média de PAs e o desvio padrão, estes dados correspondem aos resultados obtidos em 30 testes para cada uma das 16 CEAs.

Considerando os PAs, a abordagem utilizando o ADS obteve uma redução média de 54,23% em comparação a [Dorça 2012], valor que corresponderia em média, a cerca de 23 problemas de aprendizagem a menos, em se tratando de números absolutos. Destaca-se o Exp1-A-S-VI-S que apresentou uma redução nos PA de 73.6%, em relação a [Dorça 2012]. Nesse exemplo, o EAr inicial é igual ao EAr. Assim, é possível verificar o quanto o ADS contribuiu para acelerar a convergência, reduzindo os erros de reforço que foram aplicados pelo AR.

Tabela 1. Comparativo para EAr Estático - 60 Conceitos.

	Dorça	ADS	%	Dorça	ADS	%	Dorça	ADS	%
	Média Interações			P. Aprendizagem			Desvio Padrão		
Exp1-A-S-VI-S	383.83	366.28	-4.57	23.83	6.28	-73.65	3.38	2.33	-31.07
Exp2-R-S-Vi-S	396.06	378.28	-4.49	36.06	18.28	-49.31	4.34	7.08	63.13
Exp3-A-I-VI-S	394.81	371.38	-5.93	34.81	11.38	-67.31	5.23	3.31	-36.71
Exp4-A-S-VE-S	394.73	386.04	-2.2	34.73	26.04	-25.02	5.16	5.15	-0.19
Exp5-A-S-VI-G	395.2	376.46	-4.74	35.2	16.46	-53.24	4.83	6.22	28.78
Exp6-R-I-Vi-S	405.4	378.7	-6.59	45.4	18.7	-58.81	6.1	9.38	53.77
Exp7-A-I-VE-S	402.53	379.23	-5.79	42.53	19.23	-54.78	4.66	8.81	89.06
Exp8-A-S-VE-G	402.67	375.4	-6.77	42.67	15.4	-63.91	5.74	4.36	-24.04
Exp9-R-S-VE-S	405.53	380.35	-6.21	45.53	20.35	-55.3	4.79	4.18	-12.73
Exp10-R-S-Vi-G	401.93	385.78	-4.02	41.93	25.78	-38.52	5.85	8.47	44.79
Exp11-A-I-VI-G	403	377.73	-6.27	43	17.73	-58.77	4.74	4.53	-4.43
Exp12-R-I-VE-S	410.73	381.25	-7.18	50.73	21.25	-58.11	4.01	6.7	67.08
Exp13-A-I-VE-G	408.93	386.43	-5.5	48.93	26.43	-45.98	3.84	10.9	183.85
Exp14-R-I-Vi-G	411.13	390.04	-5.13	51.13	30.04	-41.25	7.42	14.52	95.69
Exp15-R-S-VE-G	413.33	380.92	-7.84	53.33	20.92	-60.77	6.11	6.91	13.09
Exp16-R-I-VE-G	419.8	382.17	-8.96	59.8	22.17	-62.93	4.74	8.99	89.66
Média	403.1	379.78	-5.76	43.1	19.78	-54.23	5.06	6.99	38.73

Considerando-se o número de interações, o ADS obteve uma redução de 5,7% em comparação a [Dorça 2012], ressalta-se que, no modelo em questão, o número mínimo de interações seria de 360, ou seja, se o sistema fosse 100% preciso na detecção do EA e nenhum fator aleatório influenciasse a interação, no caso ótimo, teríamos 360 interações (60 conceitos * 6 níveis cognitivos de [Bloom et al. 1956]).

É importante notar que, embora a redução do número de interações possa parecer pequena, em casos de aplicações reais, tais reduções são consideráveis. A exemplo, a UNIUBE, em seu modelo pedagógico EAD de graduação, cada seção de aprendizagem (interação) possui uma semana de duração [Uberaba 2016]. Logo, essa redução nas interações, do ponto de vista real, significa um ganho considerável de recursos e tempo.

O desvio padrão médio que o ADS apresentou, variou em relação a [Dorça 2012], em 38.73%, muito embora pareça ser um valor expressivo, em números absolutos corresponde a um desvio padrão no valor de 1.93 a mais que a abordagem da literatura.

No que tange à nota média obtida nos experimentos com EAr Estáticos com carga de 60 conceitos, a Figura 6 apresenta dados comparativos contendo os 16 Experimentos para cada abordagem.

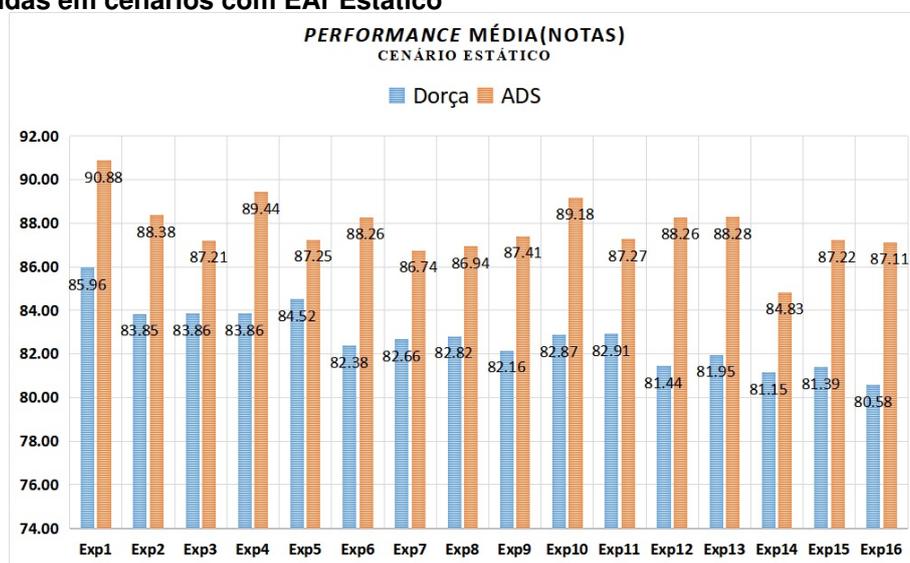
O ADS promoveu um aumento na nota média dos estudantes em 6.06% em comparação à abordagem da literatura, permitindo constatar que o ADS, além de reduzir os PAs se mostra apto a permitir um aumento na nota média dos estudantes.

A tabela 2 apresenta os resultados obtidos nos testes considerando EAr Estáticos com carga de 30 conceitos. Assim como a Tabela 1, a coluna que contém o símbolo %, corresponde à variação da abordagem ADS em relação a [Dorça 2012].

Considerando-se os PAs, o ADS foi apto a proporcionar uma redução média de 45,23% em comparação a abordagem de [Dorça 2012], esse valor corresponderia, em média, a cerca de 13 avaliações negativas a menos se fossem tratados números absolutos. A exemplo dos resultados apresentados na Tabela 1, o Exp1-A-S-VI-S, novamente apresentou uma maior redução nos PA, correspondendo a, em média, 78.33%, em relação a [Dorça 2012]. Neste experimento, o EAp inicial, é igual ao EAr.

Destaca-se ainda, o Exp13-A-I-VE-G, que apresentou uma redução média de

Figura 6. Comparação entre as abordagens no que tange à Média das Notas obtidas em cenários com EAr Estático



Fonte: Elaborado pelo autor

Tabela 2. Comparativo para EAr Estático - 30 Conceitos.

	Dorça	ADS	%	Dorça	ADS	%	Dorça	ADS	%
	Média Interações	Média PA		Desvio Padrão					
Exp1-A-S-VI-S	194.77	183.20	-5.94	14.77	3.20	-78.33	3.76	3.99	6.12
Exp2-R-S-VI-S	203.07	191.27	-5.81	23.07	11.27	-51.16	3.25	3.24	-0.33
Exp3-A-I-VI-S	201.30	193.73	-3.76	21.30	13.73	-35.52	3.70	3.23	-12.68
Exp4-A-S-VE-S	202.50	193.43	-4.48	22.50	13.43	-40.30	3.76	4.17	10.87
Exp5-A-S-VI-G	200.43	190.17	-5.12	20.43	10.17	-50.24	4.03	2.94	-27.15
Exp6-R-I-VI-S	208.67	194.57	-6.76	28.67	14.57	-49.19	3.58	5.00	39.89
Exp7-A-I-VE-S	209.50	192.77	-7.99	29.50	12.77	-56.72	4.26	4.78	12.35
Exp8-A-S-VE-G	209.03	194.87	-6.78	29.03	14.87	-48.79	3.78	4.51	19.19
Exp9-R-S-VE-S	211.57	191.47	-9.50	31.57	11.47	-63.67	5.08	3.62	-28.84
Exp10-R-S-VI-G	207.80	213.37	2.68	27.80	33.37	20.02	4.69	15.60	232.80
Exp11-A-I-VI-G	206.70	201.30	-2.61	26.70	21.30	-20.22	4.28	5.57	29.91
Exp12-R-I-VE-S	216.47	194.80	-10.01	36.47	14.80	-59.41	4.85	5.00	2.98
Exp13-A-I-VE-G	217.43	193.00	-11.24	37.43	13.00	-65.27	3.94	5.07	28.85
Exp14-R-I-VI-G	214.90	195.53	-9.01	34.90	15.53	-55.49	5.34	4.37	-18.18
Exp15-R-S-VE-G	215.03	207.47	-3.52	35.03	27.47	-21.60	4.41	11.57	162.11
Exp16-R-I-VE-G	221.50	201.67	-8.95	41.50	21.67	-47.79	4.22	10.87	157.75
Média	208.79	195.79	-6.17	28.79	15.79	-45.23	4.18	5.84	38.48

65.27% em relação a [Dorça 2012]. Diferentemente do Exp1, nesse caso, três dimensões do FSLSM foram alteradas, permanecendo apenas uma sem alteração. Novamente verificou-se que o ADS acelerou a convergência do sistema.

O Desvio Padrão médio ficou do ADS ficou em 5.84 ao passo que o a abordagem da literatura ficou em 4.18, ADS variando em 38.48%.

No que tange ao número de interações, a Tabela 2 evidencia que o ADS obteve uma redução média de 6,17% em comparação a [Dorça 2012], neste caso o quantitativo mínimo de interações possíveis é de 180 (30 conceitos * 6 níveis cognitivos). Uma redução menor, mas que se justifica pela proporção da quantidade de conceitos, onde a quantidade média de interações diminui muito em ambas as abordagens.

A tabela 3 apresenta os resultados obtidos nos testes considerando EAr Estáticos com carga de 15 conceitos. Assim como nos testes anteriores, a coluna que contém o

Tabela 3. Comparativo para EAr Estático - 15 Conceitos.

	Dorça	ADS	%	Dorça	ADS	%	Dorça	ADS	%
	Média Interações			Média PA			Desvio Padrão		
Exp1-A-S-VI-S	98.53	92.90	-5.72	8.53	2.90	-66.02	2.93	1.77	-39.70
Exp2-R-S-VI-S	103.43	96.40	-6.80	13.43	6.40	-52.36	3.21	2.76	-14.04
Exp3-A-I-VI-S	104.07	97.73	-6.09	14.07	7.73	-45.02	3.39	2.52	-25.79
Exp4-A-S-VE-S	103.83	97.43	-6.16	13.83	7.43	-46.27	3.23	2.97	-8.07
Exp5-A-S-VI-G	103.23	96.00	-7.01	13.23	6.00	-54.66	3.19	2.42	-24.13
Exp6-R-I-VI-S	109.63	103.33	-5.75	19.63	13.33	-32.09	3.99	3.10	-22.25
Exp7-A-I-VE-S	109.07	101.60	-6.85	19.07	11.60	-39.16	3.24	2.84	-12.40
Exp8-A-S-VE-G	107.90	103.93	-3.68	17.90	13.93	-22.16	3.25	4.09	25.86
Exp9-R-S-VE-S	109.77	104.23	-5.04	19.77	14.23	-27.99	3.53	5.46	54.57
Exp10-R-S-VI-G	107.93	98.80	-8.46	17.93	8.80	-50.93	3.75	2.57	-31.60
Exp11-A-I-VI-G	107.83	99.73	-7.51	17.83	9.73	-45.42	3.22	3.32	3.23
Exp12-R-I-VE-S	115.73	100.93	-12.79	25.73	10.93	-57.51	3.98	3.88	-2.64
Exp13-A-I-VE-G	114.33	120.63	5.51	24.33	30.63	25.89	4.48	10.78	140.53
Exp14-R-I-VI-G	111.40	105.80	-5.03	21.40	15.80	-26.17	3.47	5.19	49.53
Exp15-R-S-VE-G	112.77	106.70	-5.38	22.77	16.70	-26.65	3.98	5.50	38.27
Exp16-R-I-VE-G	119.33	110.40	-7.49	29.33	20.40	-30.45	3.67	7.30	99.01
Média	108.68	102.29	-5.89	18.68	12.29	-37.31	3.53	4.15	14.40

símbolo % , corresponde à variação da abordagem [Dorça 2012] em relação ao ADS.

Considerando-se os PAs, o ADS obteve uma redução média de 37,31% em comparação a [Dorça 2012]. Novamente, o Exp1-A-S-VI-S, apresentou uma maior redução nos PA correspondendo a, em média, 66,02%, em relação a [Dorça 2012]. Reitera-se essa observação por ela evidenciar o quanto o ADS, em cenários que a adaptação não se faz necessária, percebe o estado do sistema e realiza uma interferência mínima, garantindo essa redução significativa dos PAs.

O Exp12-R-I-VE-S apresentou uma redução média de 57,51% em relação a [Dorça 2012], onde, três dimensões do FLSM foram alteradas, permanecendo apenas uma sem alteração. Esse experimento corresponde à maior redução entre as 16 CEAs testadas para uma carga de 15 conceitos, salvo o Exp1-A-S-VI-S.

Em relação ao Desvio Padrão houve uma variação de 14,40% do ADS em relação à Dorça em experimentos com carga de 15 conceitos. Essa foi a menor diferença do desvio padrão entre as abordagens para EAr Estático.

A Tabela 3 apresenta o número de interações requerido pelos sistemas avaliados. O ADS obteve uma redução média de 5,89% em comparação a [Dorça 2012]. Uma menor redução em relação às outras cargas de trabalho, que se justifica pela proporção da quantidade de conceitos.

5.2. EAr Dinâmicos

A tabela 4 apresenta os resultados obtidos nos testes considerando EAr dinâmicos com carga de 60 conceitos. A coluna que contém o símbolo % , corresponde à variação da abordagem [Dorça 2012] em relação ao ADS.

Em relação os PAs, o ADS apresenta uma redução média de 35,8% em comparação a [Dorça 2012]. Destaca-se o Exp13-A-I-VE-G que apresentou uma redução de 48,9%, quase a metade dos PAs da outra abordagem.

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

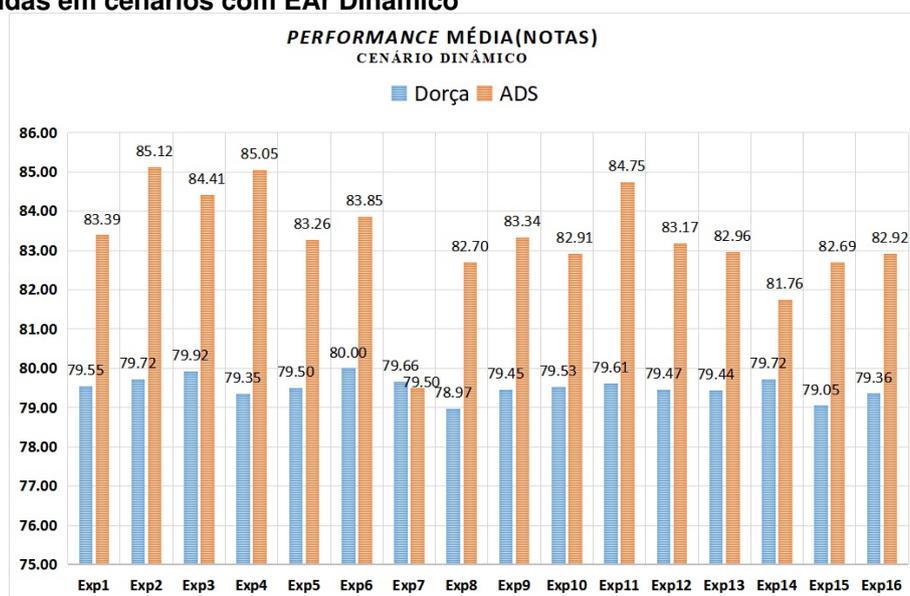
Tabela 4. Comparativo para EAr Dinâmico - 60 Conceitos.

	Dorça	ADS	%	Dorça	ADS	%	Dorça	ADS	%
	Média Interações			P. Aprendizagem			Desvio Padrão		
Exp1-A-S-VI-S	418.21	393.03	-6.02	58.21	33.03	-43.26	8.09	4.5	-44.38
Exp2-R-S-Vi-S	426.62	404.07	-5.29	66.62	44.07	-33.85	6.4	7.76	21.25
Exp3-A-I-VI-S	428.79	412.14	-3.88	68.79	52.14	-24.2	7.84	8.2	4.59
Exp4-A-S-VE-S	424.86	406.96	-4.21	64.86	46.96	-27.6	7.71	8.01	3.89
Exp5-A-S-VI-G	423.52	397.46	-6.15	63.52	37.46	-41.03	7.83	6.93	-11.49
Exp6-R-I-Vi-S	433.83	404	-6.88	73.83	44	-40.4	7.24	8.77	21.13
Exp7-A-I-VE-S	433.55	417.25	-3.76	73.55	57.25	-22.16	6.24	7.55	20.99
Exp8-A-S-VE-G	428.14	396.54	-7.38	68.14	36.54	-46.38	7.98	6.34	-20.55
Exp9-R-S-VE-S	431.64	422.29	-2.17	71.64	62.29	-13.05	8.16	8.23	0.86
Exp10-R-S-Vi-G	431.04	397.75	-7.72	71.04	37.75	-46.86	7.06	4.49	-36.4
Exp11-A-I-VI-G	430.35	402.5	-6.47	70.35	42.5	-39.59	6.6	8.17	23.79
Exp12-R-I-VE-S	440.58	421.86	-4.25	80.58	61.86	-23.23	4.57	9.78	114
Exp13-A-I-VE-G	434.04	397.78	-8.35	74.04	37.78	-48.97	7.49	7.34	-2
Exp14-R-I-Vi-G	435.3	406.19	-6.69	75.3	46.19	-38.66	6.3	7.69	22.06
Exp15-R-S-VE-G	437.77	402.11	-8.15	77.77	42.11	-45.85	6.36	6.91	8.65
Exp16-R-I-VE-G	443.65	411.62	-7.22	83.65	51.62	-38.29	6.82	5.93	-13.05
Média	431.37	405.85	-5.91	71.37	45.85	-35.84	7.04	7.29	7.08

O Desvio Padrão médio nesse experimento demonstrou uma variação pequena em comparação às duas abordagens, correspondendo a 7.04 para [Dorça 2012] e 7.29 para o ADS. ADS variou em 7.08% em relação a abordagem da literatura.

A nota média obtida nos experimentos com EAr Dinâmico com carga de 60 conceitos, é apresentada na Figura 7 com um gráfico comparativo entre os 16 Experimentos de cada abordagem. Novamente o ADS elevou a nota média dos estudantes em comparação à [Dorça 2012], mesmo em cenário adverso com oscilação do EAr do estudante o ADS se manteve capaz de permitir a maximização do desempenho do estudante.

Figura 7. Comparação entre as abordagens no que tange à Média das Notas obtidas em cenários com EAr Dinâmico



Fonte: Elaborado pelo autor

A tabela 5 traz os resultados obtidos nos testes com EAr dinâmicos e carga de trabalho de 30 conceitos. A coluna que contém o símbolo %, corresponde à variação da abordagem [Dorça 2012] em relação ao ADS.

Tabela 5. Comparativo para EAr Dinâmico - 30 Conceitos.

	Dorça	ADS	%	Dorça	ADS	%	Dorça	ADS	%
	Média Interações			Média PA			Desvio Padrão		
Exp1-A-S-VI-S	220.40	210.70	-4.40	40.40	30.70	-24.01	4.33	5.30	22.44
Exp2-R-S-VI-S	223.27	222.00	-0.57	43.27	42.00	-2.93	5.99	6.63	10.67
Exp3-A-I-VI-S	226.27	213.73	-5.54	46.27	33.73	-27.09	6.19	5.35	-13.53
Exp4-A-S-VE-S	218.23	213.43	-2.20	38.23	33.43	-12.55	5.23	6.03	15.23
Exp5-A-S-VI-G	218.73	212.37	-2.91	38.73	32.37	-16.44	7.21	6.68	-7.27
Exp6-R-I-VI-S	228.67	217.23	-5.00	48.67	37.23	-23.49	6.73	4.84	-28.11
Exp7-A-I-VE-S	226.07	217.07	-3.98	46.07	37.07	-19.54	6.31	6.24	-1.22
Exp8-A-S-VE-G	222.53	213.07	-4.25	42.53	33.07	-22.26	6.66	9.20	38.06
Exp9-R-S-VE-S	225.07	208.90	-7.18	45.07	28.90	-35.87	5.61	3.95	-29.54
Exp10-R-S-VI-G	225.07	204.50	-9.14	45.07	24.50	-45.64	6.94	5.15	-25.75
Exp11-A-I-VI-G	224.90	218.17	-2.99	44.90	38.17	-15.00	6.34	7.05	11.18
Exp12-R-I-VE-S	227.70	216.07	-5.11	47.70	36.07	-24.39	6.96	6.27	-9.83
Exp13-A-I-VE-G	224.03	221.07	-1.32	44.03	41.07	-6.74	6.57	12.17	85.27
Exp14-R-I-VI-G	229.13	215.60	-5.91	49.13	35.60	-27.54	4.98	5.44	9.28
Exp15-R-S-VE-G	223.77	215.77	-3.58	43.77	35.77	-18.28	5.70	7.89	38.26
Exp16-R-I-VE-G	229.10	225.37	-1.63	49.10	45.37	-7.60	7.42	7.35	-1.00
Media	224.56	215.31	-4.11	44.56	35.31	-20.59	6.20	6.60	7.133

Tabela 6. Comparativo para EAr Dinâmico - 15 Conceitos.

	Dorça	ADS	%	Dorça	ADS	%	Dorça	ADS	%
	Média Interações			Média PA			Desvio Padrão		
Exp1-A-S-VI-S	114.37	107.50	-6.00	24.37	17.50	-28.18	5.32	3.66	-31.30
Exp2-R-S-VI-S	115.77	113.60	-1.87	25.77	23.60	-8.41	4.91	4.50	-8.37
Exp3-A-I-VI-S	116.30	107.90	-7.22	26.30	17.90	-31.94	4.84	4.69	-3.26
Exp4-A-S-VE-S	112.10	102.00	-9.01	22.10	12.00	-45.70	6.02	4.57	-24.13
Exp5-A-S-VI-G	111.90	99.27	-11.29	21.90	9.27	-57.69	4.44	3.73	-15.88
Exp6-R-I-VI-S	111.83	114.60	2.47	21.83	24.60	12.67	4.30	5.75	33.75
Exp7-A-I-VE-S	116.80	107.47	-7.99	26.80	17.47	-34.83	5.60	5.35	-4.57
Exp8-A-S-VE-G	115.90	102.23	-11.79	25.90	12.23	-52.77	4.45	3.83	-13.97
Exp9-R-S-VE-S	113.93	102.00	-10.47	23.93	12.00	-49.86	5.43	4.53	-16.45
Exp10-R-S-VI-G	114.03	112.03	-1.75	24.03	22.03	-8.32	5.67	5.74	1.28
Exp11-A-I-VE-G	116.47	113.53	-2.52	26.47	23.53	-11.08	4.52	4.45	-1.36
Exp12-R-I-VE-S	114.90	119.33	3.86	24.90	29.33	17.80	4.04	6.06	50.22
Exp13-A-I-VE-G	113.20	108.60	-4.06	23.20	18.60	-19.83	4.54	5.78	27.44
Exp14-R-I-VI-G	116.80	113.73	-2.63	26.80	23.73	-11.44	4.57	6.19	35.36
Exp15-R-S-VE-G	114.03	108.33	-5.00	24.03	18.33	-23.72	4.11	5.58	35.87
Exp16-R-I-VE-G	116.07	112.97	-2.67	26.07	22.97	-11.89	6.25	5.10	-18.40
Media	114.65	109.07	-4.87	24.65	19.07	-22.82	4.94	4.97	2.89

Em relação os PAs, o ADS apresenta uma redução média de 20,59% em comparação a [Dorça 2012]. Destaca-se o Exp10-R-S-VI-G que apresentou uma redução de 45,64%, a maior redução para essa carga de trabalho em um cenário dinâmico.

Quanto ao número de interações, o ADS apresentou uma redução média de 4.11% em comparação a [Dorça 2012].

O Desvio Padrão médio ficou do ADS foi de 6.60 ao passo que o a abordagem da literatura situou-se na marca de 6.20, ADS variando em 7.13%.

Por fim, a tabela 6 contém os resultados obtidos nos testes com EAr dinâmicos e carga de trabalho de 15 conceitos, onde a coluna que contém o símbolo %, corresponde à variação da abordagem [Dorça 2012] em relação ao ADS.

Diante dos PAs, o ADS apresenta uma redução média de 22,82% em comparação a [Dorça 2012]. Destaca-se o Exp5-A-S-VI-G que apresenta uma redução média de 57,69%, a maior variação entre as abordagens em todos os testes EAr dinâmicos, independente da carga de conceitos.

O número médio de interações do ADS apresentou uma redução média de 4.87%

em comparação a [Dorça 2012].

O Desvio Padrão médio ficou do ADS foi de 4.97 ao passo que o a abordagem da literatura foi de 4.18, ADS variando em 2.89%, menor variação do desvio padrão encontrado em todos os resultados.

5.3. Considerações Acerca dos Resultados

Os testes comparativos das notas dos estudantes foram executados e avaliados comparando-se as notas médias obtidas a partir de 30 experimentos para cada CEA possível, sendo considerados cenários Estáticos e Dinâmicos. Para o indicador nota, a hipótese nula demonstra a ausência de diferença entre as duas abordagens. Com o propósito de afastar a hipótese que os resultados são de uma distribuição normal realizou-se os testes de *Wilcoxon* pareados [Montgomery and Runger 2010].

Selecionou-se um nível de confiança de 95% para o intervalo de confiança. Os resultados, como pode ser visto a seguir, demonstraram que o desempenho dos algoritmos são significativamente diferentes. Os testes comparativos de Notas em cenários estáticos demonstraram os seguintes resultados:

- Resultado 1 - O valor Z é -3,5162. O valor p é 0,00044. O resultado é significativo em $p \leq 0,05$.
- Resultado 2 - O valor W é 0. O valor crítico de W para N = 16 a $p \leq 0,05$ é 29. Portanto, o resultado é significativo a $p \leq 0,05$.

Os resultados obtidos demonstram a rejeição da hipótese nula através de um $p \leq 0,05$, demonstrando que as amostras originam-se de populações que possuem medianas diferentes para testes com EA Estáticos.

Em relação aos Testes comparativos de Notas em cenários Dinâmicos os testes *Wilcoxon* pareados demonstraram os seguintes resultados:

- Resultado 1 - O valor Z é -3,4645. O valor p é 0,00054. O resultado é significativo em $p \leq 0,05$.
- Resultado 2 - O valor W é 1. O valor crítico de W para N = 16 a $p \leq 0,05$ é 29. Portanto, o resultado é significativo a $p \leq 0,05$.

Em relação à amostra dos testes comparativos de Notas em cenários Dinâmicos, obteve-se valor de $p \leq 0,05$, afastando, portanto, a hipótese nula, demonstrando que as amostras originam-se de populações que possuem medianas diferentes para testes com EA Estáticos.

6. Conclusão e Trabalhos Futuros

A personalização do ensino em ambientes EAD, proposta que visa reduzir os números da evasão nessa modalidade de ensino, vem sendo alvo de diversas pesquisas e, os Sistemas Adaptativos e Inteligentes para a Educação têm se mostrado como uma solução promissora.

Dessa forma, para se personalizar o ensino se faz necessária a detecção automática e dinâmica dos EA dos usuários, de forma a assegurar um parâmetro para a adaptação do conteúdo a ser ensinado.

A etapa de detecção e, constante atualização do EA do estudante é determinante para o sucesso da abordagem de fornecimento de adaptatividade, portanto, pesquisou-se novas técnicas que pudessem oferecer um ganho nessa funcionalidade do sistema.

Assim foi proposto 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 ao aluno um ensino personalizado. Levou-se em consideração que o EA do aluno muda ao longo do processo de ensino aprendizagem, necessitando assim, de uma abordagem robusta que fosse apta a lidar com essa situação.

Os resultados experimentais encontrados apontaram para uma redução na quantidade de interações bem como no número de Problemas de Aprendizagem em comparação a literatura. A redução nas interações e Problemas de Aprendizagem foram possíveis nos dois cenários abordados, tanto com EA Estático como EA Dinâmico.

Nos experimentos foi possível verificar que o ADS contribuiu para elevar a nota média dos estudantes, através da correta adaptação do conteúdo ao estilo do aprendiz. Os resultados encontrados, apontam que o método apresentada se mostrou promissor para atender os objetivos que almeja.

Como trabalho futuro pretende-se que o ADS seja capaz de aprender automaticamente a estrutura das regras que serão utilizadas e, não somente seus pesos. Dessa forma, o próprio sistema seria capaz de verificar as condições que precisam ser verificadas antes de se realizar determinada correção no ME, além da correta atualização dos pesos.

Pretende-se ainda, realizar a implantação do modelo proposto em um ambiente virtual de aprendizagem real para testes, isto é, com estudantes reais e objetos de aprendizagem reais, de forma a determinar, do ponto de vista prático, a viabilidade da técnica.

Referências

- ABED, A. B. d. E. a. D. (2016). Censo ead.br: Relatório analítico da aprendizagem a distância no Brasil 2015/2016. *InterSaberes*.
- Adán-Coello, J. M., de Menezes, W. S., de Faria, E. S. J., and Tobar, C. M. (2008). Conflito sócio-cognitivo e estilos de aprendizagem na formação de grupos para o aprendizado colaborativo de programação de computadores. *Brazilian Journal of Computers in Education*, 16(03).
- Ahmad, N. and Tasir, Z. (2013). Threshold Value in Automatic Learning Style Detection. *Procedia - Social and Behavioral Sciences*, 97:346–352.
- Alonso, C. M., Gallego, D. J., and Honey, P. (1997). *Los estilos de aprendizaje: procedimientos de diagnósticos y mejora*. Mensajero.
- 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.
- Barros, D. M. V. (2009). Guia didático sobre tecnologias da comunicação e informação para o trabalho educativo na formação docente.
- Berings, M. G., Poell, R. F., and Simons, P. R.-J. (2005). Conceptualizing on-the-job learning styles. *Human Resource Development Review*, 4(4):373–400.

- Bloom, B. S. et al. (1956). Taxonomy of educational objectives. new york: David mckay co. Inc., 1956.
- Cerqueira, T. C. S. (2000). *Estilos de aprendizagem em universitários*. PhD thesis.
- Crockett, K., Latham, A., Mclean, D., and O'Shea, J. (2013). A fuzzy model for predicting learning styles using behavioral cues in an conversational intelligent tutoring system. *IEEE International Conference on Fuzzy Systems*.
- Dagez, H. E. and Baba, M. S. (2008). Applying neural network technology in qualitative research for extracting learning style to improve E-learning environment. *Proceedings - International Symposium on Information Technology 2008, ITSIm*, 1:4–9.
- Dahlbom, A. and Niklasson, L. (2006). Goal-directed hierarchical dynamic scripting for rts games. In *AIIDE*, pages 21–28.
- 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.
- 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*, 18:178–204.
- Dunn, R. S., Dunn, K. J., and Price, G. E. (1981). *Learning style inventory*. Price Systems New York, Lawrence, KS.
- Falci, S. H., Vivas, A., Assis, L., and Pitangui, C. (2017). Uma nova abordagem para aplicação de reforço em sistemas automáticos e adaptativos de detecção de estilos de aprendizagem. *Revista Eletrônica Argentina-Brasil de Tecnologias da Informação e da Comunicação*, 1(6).
- Farias, D. L. d. (2014). Avaliação de aprendizagem de agentes baseados em sistemas classificadores para jogos digitais.
- Felder, R. M. and Silverman, L. K. (1988). Learning and teaching styles in engineering education. *Engineering education*, 78(7):674–681.
- Galafassi, F. P., Gluz, J. C., and Galafassi, C. (2013). Análise crítica das pesquisas recentes sobre as tecnologias de objetos de aprendizagem e ambientes virtuais de aprendizagem. *Revista Brasileira de Informática na Educação*, 21(3):41–52.
- Gallego, D. J. (2008). Estilos de aprender en el siglo XXI. 1:23–34.
- 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. 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.
- Kolb, D. A. (1971). *Individual learning styles and the learning process*. MIT.
- Kop, R., Toubman, A., Hoogendoorn, M., and Roessingh, J. J. (2015). Evolutionary dynamic scripting: Adaptation of expert rule bases for serious games. In *International Conference on Industrial, Engineering and Other Applications of Applied Intelligent Systems*, pages 53–62. Springer.
- Ladebeck, M. (2008). Applying dynamic scripting to “jagged alliance 2”. *TU Darmstadt*.
- Landim, C. (1997). Educação a distância: algumas considerações. *Rio de Janeiro*.
- Majchrzak, K., Quadflieg, J., and Rudolph, G. (2015). Advanced dynamic scripting for fighting game ai. In *International Conference on Entertainment Computing*, pages 86–99. Springer.
- Montgomery, D. C. and Runger, G. C. (2010). *Applied statistics and probability for engineers*. John Wiley & Sons.
- Moran, J. M. (2000). *Novas tecnologias e mediação pedagógica*. Papirus Editora.
- Netto, C., Giraffa, L. M., and Faria, E. T. (2010). *Graduações a distância e o desafio da qualidade*. EDIPUCRS.
- 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.
- Policarpo, D., Urbano, P., and Loureiro, T. (2010). Dynamic scripting applied to a first-person shooter. In *Information Systems and Technologies (CISTI), 2010 5th Iberian Conference on*, pages 1–6. IEEE.
- 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*.
- Ribeiro, P., Assis, L., Vivas, A., and Pitanguí, C. (2017). Detecção de estilos de aprendizagem utilizando média móvel exponencialmente ponderada. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)*, volume 28, page 1247.
- Rodrigues, A. Z. and da Costa, J. B. A. (2017). As tecnologias de informação e comunicação na era da informação. *Anais do Seminário Nacional de Sociologia da UFS-ISSN 2526-3013*, 1.

- 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.
- Rosemann, D., Raabe, A. L., and Teive, R. C. G. (2014). Personalização de conteúdo e avaliação multicritério em ambiente virtual de aprendizagem de código aberto. In *Anais dos Workshops do Congresso Brasileiro de Informática na Educação*, volume 3, page 203.
- Salazar, L., Assis, L., Vivas, A., Pitangui, C., and Falci, S. (2017). Detecção de estilos de aprendizagem em ambientes virtuais de aprendizagem utilizando redes bayesianas. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)*, volume 28, page 1317.
- Sena, E. B. et al. (2016). Uma abordagem computacional para detecção automática de estilos de aprendizagem utilizando modelos ocultos de markov. *SIED: EnPED*.
- Silva, J. C., Pitangui, C., Assis, L., and Vivas, A. (2017). Detecção automática e dinâmica de estilos de aprendizagem em sistemas adaptativos e inteligentes utilizando dynamic scripting. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)*, volume 28, page 1327.
- Silva, L. L. V. (2012). Estilos e estratégias de aprendizagem de estudantes universitários.
- Spronck, P. (2005). *Adaptive Game AI*. PhD thesis, Universitaire Pers Maastricht.
- Sutton, R. S. and Barto, A. G. (1998). *Reinforcement learning: An introduction*, volume 1. MIT press Cambridge.
- Toubman, A., Roessingh, J., Spronck, P., Plaat, A., and van den Herik, H. (2014). Centralized versus decentralized team coordination using dynamic scripting.
- 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.
- Wilson, L. O. (2013). Anderson and krathwohl—understanding the new version of bloom’s taxonomy. *The second principle. The work of Leslie Owen Wilson. Ed. D.*