

Júlio César da Costa Silva

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

Diamantina

2017

Júlio César da Costa Silva

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

Dissertação apresentada ao Programa de Pós  
Graduação em Educação da Universidade  
Federal dos Vales Jequitinhonha e Mucuri  
como requisito parcial para a obtenção de  
Título de Mestre em Educação.

Área de concentração: Educação e Tecnolo-  
gias aplicadas em Instituições Educacionais

Orientador: Prof. Dr. Cristiano Grijó Pitangui

Diamantina

2017

Ficha Catalográfica – Serviço de Bibliotecas/UFVJM  
Bibliotecário Anderson César de Oliveira Silva, CRB6 – 2618.

S586d

Silva, Júlio César da Costa

Detecção Automática e Dinâmica de Estilos de Aprendizagem em  
Sistemas Adaptativos e Inteligentes utilizando Dynamic Scripting /  
Júlio César da Costa Silva. – Diamantina, 2017.

81 p. : il.

Orientador: Cristiano Grijó Pitangui

Dissertação (Mestrado Profissional – Programa de Pós-Graduação  
em Educação) - Universidade Federal dos Vales do Jequitinhonha e  
Mucuri.

1. *Dynamic Scripting*. 2. Sistema Adaptativo e Inteligente para a  
Educação. 3. Estilos de Aprendizagem. I. Pitangui, Cristiano Grijó.  
II. Título. III. Universidade Federal dos Vales do Jequitinhonha e  
Mucuri.

**CDD 006.3**

Elaborado com os dados fornecidos pelo(a) autor(a).

JULIO CESAR DA COSTA SILVA

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

Dissertação apresentada ao  
PROGRAMA DE PÓS-GRADUAÇÃO  
EM EDUCAÇÃO - STRICTO SENSU,  
nível de MESTRADO como parte dos  
requisitos para obtenção do título de  
MAGISTER SCIENTIAE EM  
EDUCAÇÃO

Orientador : Prof. Dr. Cristiano Grijó  
Pitangui

Data da aprovação : 08/11/2017

  
Prof.ª Dr.ª JOSIANE MAGALHAES TEIXEIRA - UFVJM

  
Prof.ª Dr.ª LUCIANA PEREIRA DE ASSIS - UFVJM

  
Prof.Dr. CRISTIANO GRIJÓ PITANGUI - UFVJM

DIAMANTINA

*Dedico este trabalho a minha amada esposa Karine, que tanto me apoiou e suportou nessa jornada. Dedico aos meus pais Antonio Carlos e Angelina, que sempre me apoiaram e incentivaram a correr atrás dos meus objetivos, seja através de palavras ou mesmo pelo exemplo cotidiano de luta e trabalho. Dedico aos meus irmãos que sempre me deram aquele suporte importante.*

# Agradecimentos

Agradeço a Deus por todas as bênçãos que me foram proporcionadas, não há meios de delimitar aqui, minha gratidão por tanta coisa maravilhosa que tenho recebido por parte do Senhor, como costume dizer, Deus me abençoa com uma precisão incrível, me proporcionando vitórias no limite de todos os recursos. Essa precisão é que reforça, ano após ano, minha fé em Ti, fé esta que foi muito provada nos últimos meses, mas como todas as vezes, o Senhor me sustentou e me manteve de pé para que eu pudesse alcançar os objetivos propostos, muito obrigado Senhor.

Agradeço a minha amada, linda, carinhosa, cuidadosa, gentil, sábia e todos os outros adjetivos que lhe cabem, esposa Karine. Minha preciosa que desde o 1º dia, ainda no processo seletivo, me apoiou incondicionalmente nessa jornada, não poupando esforços para me ajudar de todas as formas, desde o preparo saboroso de vários cappuccinos ao longo das noites de trabalho, até mesmo à análise e sugestões de melhorias no meu algoritmo. Todo o tempo, estive ao meu lado me ajudando e apoiando, muito obrigado amor.

Agradeço aos meus pais Antonio Carlos e Angelina, aos meus irmãos João Carlos, Luiz Henrique e Adriana, melhor referencial de família que alguém poderia ter, sou grato a Deus todos os dias por tê-los, sendo exemplos contínuos para mim em todos os aspectos da vida. Agradeço todo o apoio que foi desprendido a meu favor, as orações feitas e todo esforço que fizeram pra me ajudar de diversas formas. Sou infinitamente grato a todos vocês, em especial ao meu Pai e minha Mãe pelo exemplo de vida, sabedoria, simplicidade, humildade e temor ao Senhor. Muito Obrigado!

Agradeço ao meu orientador Cristiano Pitangui, por todo o conhecimento compartilhado bem como toda a paciência investida nesse projeto. Agradeço o professor Vivas e a professora Luciana, que juntamente com meu orientador, em não poucas oportunidades, me ajudaram de várias formas a crescer dentro dessa pesquisa, ora mostrando o caminho, ora caminhando comigo. Muito obrigado aos senhores!

Agradeço ao Barney, por todos os dias, noites e madrugadas sem exceção, que ficou ao meu lado, enquanto escrevi cada uma das linhas do meu algoritmo, cada uma das linhas dos artigos publicados e cada uma das linhas dessa dissertação. Valeu garoto!

Agradecimentos especiais são direcionados a família do Sr. João Izabel Lopes (*in memoriam*) juntamente com sua querida esposa Maria Fernanda Cordeiro Lopes, mais conhecida com Flor e seus filhos Renatinha e Luiz Felipe. Família maravilhosa que me recebeu de maneira muito especial em sua casa durante todo o mestrado, me tratando como filho, com direito a pratos típicos feitos com muito amor. Muito obrigado a todos vocês!

*"Segui a paz com todos, e a santificação, sem a qual ninguém verá o Senhor"*  
*(Bíblia Sagrada, Hebreus 12, 14)*

# Resumo

Uma das formas de se gerar conteúdo adaptado ao estudante passa, primeiro, pela detecção dos Estilos de Aprendizagem (EA). A teoria dos EA presume que cada aluno tem características próprias que o distingue dos demais. A partir dos EA, o Sistema Adaptativo e Inteligente para Educação (SAIE) de Dorça foi idealizado. Seu trabalho objetiva apresentar uma solução estocástica para provimento de adaptatividade e customização de Sistemas Educacionais por meio da modelagem probabilística dos EA. Em síntese, seu SAIE visa modelar o estudante, coletando e atualizando seus dados, de forma a descobrir seu EA. Com este fim, o sistema, durante suas iterações, submete o aluno a avaliações e, caso as notas sejam insatisfatórias, o sistema realiza a atualização do modelo do estudante (ME) por meio do Aprendizado por Reforço (AR). Contudo, AR é considerada uma técnica lenta de aprendizado que demanda muito tempo para ajustar o elemento a ser otimizado. Por sua vez, a técnica Dynamic Scripting (DS), uma variação da técnica de AR, apresenta alta velocidade de convergência, mesmo em ambientes dinâmicos. DS é popularmente utilizada na IA de Jogos e consiste em um conjunto de Regras sobre um domínio, estruturadas por uma condição e uma ação. Sua forma de aprendizagem atrela um peso a cada regra, o qual determina a qualidade da regra, frente à sua condição, e uma probabilidade da mesma ser aplicada. A condição de uma regra é a representação de uma situação possível no sistema, e sua ação é a intervenção gerada no sistema durante a sua aplicação. Este trabalho propõe o aperfeiçoamento do SAIE citado, utilizando uma adaptação do DS, com os objetivos de acelerar a convergência do sistema, reduzir os Problemas de Aprendizagem (PA) e aumentar a nota do estudante. Adicionalmente, devido a característica dinâmica do DS, este trabalho realiza experimentos em situações em que o EA Real (EAR) dos alunos variam ao longo do processo de ensino/aprendizagem. A pesquisa parte da elaboração das regras e implementação da estrutura do DS, avançando para a substituição do módulo de AR pelo DS no SAIE de Dorça. Realizaram-se 30 testes para cada uma das 16 Combinações de EA (CEA), 16\*30 testes para cada uma das 4 abordagens: Dorça-Estático, Dorça-Dinâmico, DS-Estático e DS-Dinâmico. Nos testes dinâmicos, modificou-se o EAR a cada 150 interações, de forma que após 300 interações, o sistema deve convergir para uma CEA oposta à inicial. Resultados preliminares, em comparação à abordagem da literatura, apresentaram uma redução média nos PA de 35.8% para os testes dinâmicos e de 54.1% para os testes estáticos. Quando o EA Probabilístico (EAp) inicial é exatamente igual ao EAR, verificou-se que a abordagem proposta apresentou em média 6 erros na atualização do ME, enquanto a abordagem da literatura apresentou, em média, 23 erros. Verificou-se, portanto, que, preliminarmente, a proposta obteve resultados promissores.

**Palavras-chave:** Dynamic Scripting. Sistema Adaptativo e Inteligente para a Educação. Estilos de Aprendizagem.

# Abstract

One of the ways to generate the content adapted to the student passes, first, by the detection of Learning Styles (LS). The LS theory assumes that every time you have distances. From the LS, the Adaptive and Intelligent System for Education (AISE) of Dorça was idealized. His work aims to present a stochastic solution for the provision of adaptability and customization of Educational Systems through the probabilistic modeling of LS. In summary, your AISE visa model, offering and updating your data, in order to discover your LS. To this end, the system, during its iterations, submits the student to the evaluation and, in case of notes and dissatisfactions, the system performs an updating of the student model (ME) through Reinforcement Learning (RL). However, RL is a slow learning technique that requires a lot of time to adjust the element to be optimized. In turn, a Dynamic Scripting (DS) technique, a variation of the RL technique, presents a high speed of convergence, even in dynamic environments. DS is popularly used in Artificial Intelligence of Games and consists of a set of Rules on a domain, structured by a condition and an action. Its form of learning brings a weight to each rule, which determines a quality of the rule, in front of its condition, and a probability of the same company. The condition of a rule is a representation of a good situation, and its action is an intervention generated without system during its application. This work proposes the improvement of the SAIE mentioned, the use of an adaptation of the DS, with the objectives of accelerating the convergence of the system, reduce the Learning Problems (PA) and increase student grade. In addition, due to the dynamic nature of the DS, this work performs tasks in situations in which students' real LS (LSr) vary throughout the teaching / learning process. A research of elaboration of the rules and implementation of the structure of the DS, advancing to the substitution of the RL module by the DS without AISE of Dorça. A total of 30 tests were performed for each of the 16 AE combinations (CEA), 16 \* 30 testicles for each of the 4 approaches: Dorca-Static, Dynamic Doric, DS-Static and DS-Dynamic. In the dynamic tests, the LSr was modified every 150 interactions, so that after 300 interactions, the system must converge to a CEA opposite to the initial one. Preliminary results, in literature comparison, presented a mean reduction in BP of 35.8 % for dynamic tests and 54.1 % for static tests. When the initial Probabilistic LS (LSp) is exactly the same as the LSr, it was verified that the proposed approach presented on average 6 errors in the updating of the ME, while a literature approach presented, on average, 23 errors. It was therefore found that a proposal had obtained promising results in the first place.

**Keywords:** Dynamic Scripting. Adaptive and Intelligent System for Education. Learning Styles.

# Lista de ilustrações

Figura 1 – Comparação entre as WEB 1.0, 2.0 e 3.0 . . . . .	25
Figura 2 – Conjunto de TICs atualmente disponíveis e utilizadas na EAD . . . . .	27
Figura 3 – Interação dos elementos que compõem a EAD através de um SGA/AVA . . . . .	29
Figura 4 – O ciclo de aprendizagem proposto por Kolb . . . . .	33
Figura 5 – Intervalo de classificação dos EA apresentados pelo ILSQ . . . . .	36
Figura 6 – Demonstração de RNA composta por 2 camadas( <i>layers</i> ) de 4 entradas( <i>input</i> ) e 2 saídas( <i>output</i> ) . . . . .	37
Figura 7 – Disposição de como um agente AR interatua em seu ambiente . . . . .	39
Figura 8 – Técnica <i>Dynamic Script</i> no contexto de um jogo comercial . . . . .	41
Figura 9 – Estrutura básica de um Sistema Tutor Inteligente . . . . .	44
Figura 10 – Espaços de Adaptação em um SHA . . . . .	46
Figura 11 – Fluxo de adaptação do SHA em função do Modelo do Estudante . . . . .	47
Figura 12 – Modelo do Estudante . . . . .	48
Figura 13 – Classificação dos níveis cognitivos chamada Taxonomia de Bloom . . . . .	49
Figura 14 – Comparação dos níveis cognitivos da Taxonomia de Bloom versão original e revisada . . . . .	49
Figura 15 – Demonstração da atualização dos pesos das regras . . . . .	53
Figura 16 – Comparativo de conversão em interações entre as abordagens para uma dimensão do FLSM - 60 Conceitos . . . . .	56
Figura 17 – Comparativo de conversão em interações entre as abordagens para uma dimensão do FLSM - 30 Conceitos . . . . .	56
Figura 18 – Comparativo de conversão em interações entre as abordagens para uma dimensão do FLSM - 15 Conceitos . . . . .	57
Figura 19 – Comparação entre as abordagens no que tange à Média das Notas obtidas em cenários com EAr Estático . . . . .	61
Figura 20 – Comparação entre as abordagens no que tange à Média das Notas obtidas em cenários com EAr Dinâmico . . . . .	65

# Lista de tabelas

Tabela 1 – Comparativo para EAr Estático - 60 Conceitos. . . . .	60
Tabela 2 – Comparativo de Notas Médias para Experimentos Estáticos . . . . .	61
Tabela 3 – Comparativo para EAr Estático - 30 Conceitos. . . . .	62
Tabela 4 – Comparativo para EAr Estático - 15 Conceitos. . . . .	63
Tabela 5 – Comparativo para EAr Dinâmico - 60 Conceitos. . . . .	64
Tabela 6 – Comparativo de Notas Médias para Experimentos Dinâmicos . . . . .	64
Tabela 7 – Comparativo para EAr Dinâmico - 30 Conceitos. . . . .	65
Tabela 8 – Comparativo para EAr Dinâmico - 15 Conceitos. . . . .	66

# Lista de abreviaturas e siglas

A	Ativo.
AR	Aprendizagem por Reforço.
ABED	Associação Brasileira de Educação à Distância.
ADS	Adapted Dynamic Script.
AG	Algoritmos Genéticos.
AVA	Ambiente Virtual de Aprendizagem.
CEA	Combinação de Estilo de Aprendizagem.
CME	Componente de Modelagem do Estudante.
DEA	Diferença entre Estilos de Aprendizagem.
DS	Dynamic Scripting.
EA	Estilo de Aprendizagem.
EAp	Estilo de Aprendizagem Probabilístico.
EAr	Estilo de Aprendizagem Real.
EAD	Educação à Distância.
EBW	Ensino Baseado na Web.
EC	Estado Cognitivo.
FSLSM	Felder-Silverman's Learning Styles Model.
G	Global.
I	Intuitivo.
IA	Inteligência Artificial.
ILSQ	Index of Learning Styles Questionnaire.
LSI	Kolbs Learning Style Inventory.
LMS	Learning Management System.

MDP	Markov Decision Process.
MBTI	Mayers-Briggs Type Indicator.
ME	Modelo Estudante.
MP	Módulo Pedagógico.
NC	Nível Cognitivo.
NPC	Non-Player Characters
OA	Objetivo de Aprendizagem.
PA	Problema de Aprendizagem.
PESDE	Processo Estocástico de Simulação de Desempenho do Estudante.
R	Reflexivo.
S	Sensitivo.
SAIE	Sistema Adaptativo e Inteligente para Educação.
SGA	Sistemas de Gerenciamento de Aprendizagem.
SHA	Sistemas de Hiperídia Adaptativo.
Sq	Sequencial.
STI	Sistemas de Tutores Inteligentes.
TIC	Tecnologia de Informação e Comunicação.
UNIUBE	Universidade de Uberaba.
VE	Verbal.
VI	Visual.

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>15</b>
<b>1.1</b>	<b>Hipótese</b>	<b>18</b>
1.1.1	Fundamentação da Hipótese	18
1.1.2	Hipótese	19
<b>1.2</b>	<b>Objetivos</b>	<b>19</b>
<b>1.3</b>	<b>Justificativa</b>	<b>20</b>
<b>1.4</b>	<b>Metodologia</b>	<b>21</b>
<b>1.5</b>	<b>Estrutura da Dissertação</b>	<b>22</b>
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	<b>23</b>
<b>2.1</b>	<b>Educação à Distância</b>	<b>23</b>
2.1.1	Evolução da EAD	23
2.1.2	Tecnologias da Informação e Comunicação	26
2.1.3	Sistemas de Gestão de Aprendizagem(SGA) e Ambientes Virtuais de Aprendizagem(AVA)	27
<b>2.2</b>	<b>Estilos de Aprendizagem (EA)</b>	<b>29</b>
2.2.1	Inventário de Estilos de Aprendizagem de Kolb	32
2.2.2	Felder <i>and</i> Silverman <i>Learning Style Model</i> (FSLSM)	33
<b>2.3</b>	<b>Inteligência Artificial (IA)</b>	<b>35</b>
2.3.1	Redes Neurais Artificiais (RNA)	36
2.3.2	Aprendizagem por Reforço (AR)	38
2.3.3	<i>Dynamic Scripting</i> (DS)	40
<b>2.4</b>	<b>Sistemas Especialistas na EAD</b>	<b>43</b>
2.4.1	Sistemas de Tutores Inteligentes(STI)	43
2.4.2	Sistemas de Hiperídia Adaptativa(SHA)	45
2.4.3	Sistemas Adaptativos e Inteligentes para a Educação (SAIE)	47
2.4.3.1	O SAIE de (DORÇA, 2012) e suas Adaptações	48
<b>3</b>	<b>ABORDAGEM PROPOSTA</b>	<b>52</b>
<b>3.1</b>	<b><i>Adapted Dynamic Scripting - ADS</i></b>	<b>52</b>
<b>3.2</b>	<b>ADS vs AR</b>	<b>55</b>
<b>4</b>	<b>EXPERIMENTOS COMPUTACIONAIS</b>	<b>58</b>
<b>4.1</b>	<b>Metodologia Experimental</b>	<b>58</b>
<b>4.2</b>	<b>Resultados Experimentais</b>	<b>59</b>
4.2.1	EAr Estáticos	60

4.2.2	EAr Dinâmicos . . . . .	63
<b>5</b>	<b>CONCLUSÃO E TRABALHOS FUTUROS . . . . .</b>	<b>67</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>69</b>
	<b>APÊNDICE A – APÊNDICE . . . . .</b>	<b>79</b>

# 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; GLUZ; GALAFASSI, 2013). Um AVA reúne em um ambiente virtual, geralmente baseado na WEB, diversas ferramentas, como fóruns, *wikis* e diversas outras tecnologias colaborativas (ROSEMANN; RAABE; TEIVE, 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; GIRAFFA; FARIA, 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.

Na literatura, alguns desses sistemas são os Sistemas de Hipermídia Adaptativos (SHA) e Sistemas Tutores Inteligentes (STI) (BARBOSA, 2004). A adaptação em um SHA visa oferecer informação hipermídia e navegação ajustados ao perfil do usuário já modelado previamente (PALAZZO, 2000). Já os STI buscam, através da interação do usuário com o sistema, coletar e atualizar informações de uso e, a partir daí, passa a ser apto a aprender, adaptar e oferecer atendimento personalizado (BADIN; BORDIGNON; AGOSTI, 2017).

A estratégia utilizada pelas técnicas citadas 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.

Várias teorias influenciaram a maneira como se compreende a aprendizagem. Dentre elas, pode-se citar a Teoria do Processamento de Informação, em que a aprendizagem é vista

como um processo pelo qual o estudante percebe, escolhe, manuseia, denota e armazena o conteúdo ensinado. Este modelo é usado para explicar o processo de aprendizagem no mesmo estilo aplicado em computadores, sendo *Input-processamento-Output* (CASTAÑÓN, 2007). Trata-se da dinâmica de processos que os indivíduos aplicam para obter, guardar e fazer uso das informações. Não se trata apenas do comportamento, leva-se também em consideração os pensamentos desenvolvidos pelo aluno durante o processo de assimilar, memorizar e recuperar as informações recebidas (SILVA, 2012).

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 ensinados 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; 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; 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 mais eficiente (AHMAD; TASIR, 2013; DORÇA et al., 2011). Felder e 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 estilos de aprendizagem 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, o primeiro obstáculo trata da delimitação e detecção dos EA. Hood et al. (2017) afirmam que há cerca de 70 modelos de EA que não são coerentes entre si. Em muitos

destes modelos de EA a etapa de detecção é realizada por questionários respondidos pelo próprio aluno. Veenman, Prins e Verheij (2003) criticam esses modelos de detecção dos EAs baseado em questionários, alegando que o estudante não está apto a dizer verdadeiramente o que lhe é melhor. Rawson, Stahovich e Mayer (2017) ressaltam ainda, a baixa correlação entre o que é respondido em um formulário e a verdade, evidenciando a baixa credibilidade dessas respostas. Há ainda a crítica dos modelos que realizam uma clusterização dos alunos em determinados EAs, modelos determinísticos, levando 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).

Destoando de grande parte dos modelos de detecção de EA, e ressaltando o aspecto dinâmico e probabilístico da seleção dos EAs, tem-se o *Felder-Silverman's Learning Styles Model* (FSLSM)(FELDER; SILVERMAN, 1988). 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; SILVERMAN, 1988). As dimensões dividem-se em 2 polos que indicam o EA do estudante.

O FSLSM analisa as dimensões em um intervalo [-11,11], baseado no *Index of Learning Styles Questionnaire*(ILSQ), onde para cada dimensão há 11 questões, sendo que as respostas correspondem a um polo ou outro da dimensão (visual ou verbal por exemplo). De acordo com as respostas verifica-se o nível de aptidão com cada estilo, podendo ser forte, moderada ou leve (FELDER; SPURLIN, 2005; 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; LIMA et al., 2013). Ressalta-se, no entanto, que a detecção do EA nesse modelo ocorre através do ILSQ, que se trata de uma detecção por meio de questionário.

Diante das críticas encontradas na literatura acerca do uso de questionários, 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 os SHA e 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; LIMA 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 iterações, submete o aluno a avaliações. Caso as notas destas avaliações sejam insatisfatórias, o sistema realiza a atualização do modelo do estudante por meio de Aprendizagem por Reforço (AR) (DORÇA; LIMA 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.

Ademais, cabe ressaltar que os testes realizados e apresentados por Dorça (2012) limitaram-se a uma abordagem estática, onde o EA do aluno não se modifica durante o processo de ensino-aprendizagem. Na literatura já é pacífico o entendimento que os EA são passíveis de mudança ao longo do tempo. Dessa forma, os EA sofrem alterações (graduais ou abruptas), sejam influenciadas pelo conteúdo que o aluno está estudando, ou pelo fruto de seu processo de amadurecimento e/ou qualquer outra razão desconhecida (CASTILLO; GAMA; BREDÁ, 2005; CERQUEIRA, 2000; DORÇA, 2012; GRAF et al., 2009; KURI, 2004; SILVA, 2012).

Partindo-se desses pressupostos, propõe-se apresentar uma proposta para uma nova abordagem para o SAIE apresentado por Dorça (2012). Procura-se 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).

Resultados experimentais permitiram validar o uso da adaptação do DS em cenários de EA Estáticos, em que o EA do aluno não se modifica durante as iterações do sistema, e EA Dinâmicos, em que o EA do aluno se modifica durante as iterações do sistema.

## 1.1 Hipótese

### 1.1.1 Fundamentação da Hipótese

Dorça (2012) propôs um SAIE composto pelos Modelo do Estudante (ME), o Módulo Pedagógico (MP), e o Componente de Modelagem do Estudante (CME). Em síntese, no processo de aprendizagem, o sistema utiliza um Modelo do Estudante (ME), que contém informações preliminares acerca do aluno. Essas informações são usadas para a seleção inteligente do formato que os conteúdos são apresentados ao estudante. Esta seleção é realizada pelo Módulo Pedagógico (MP). Após a apresentação do conteúdo, o estudante é submetido a uma avaliação e, a nota reflete a compatibilidade entre estratégia pedagógica utilizada e o Estilo de Aprendizagem real (EAR) do estudante. A partir da nota, o Componente de Modelagem do Estudante (CME), realiza a atualização do ME usando Aprendizagem por Reforço, ajustando o Estilos de Aprendizagem probabilísticos (EAp) a cada interação até que sejam alcançados os Objetivos de Aprendizagem (OA)

estabelecidos.

Apesar da AR ser uma técnica bastante utilizada, Spronck (2005) afirma que ela pode ser considerada uma técnica “lenta” de aprendizado já que, em geral, demanda muito 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, EA<sub>r</sub>.

Delongas na convergência do sistema implicam na geração de Problemas de Aprendizagem (PAs), isto é, quanto mais tempo o algoritmo demorar para encontrar o EA do estudante, mais vezes ocorrerão resultados insatisfatórios na avaliação. Isto significa uma maior dificuldade do aluno em aprender os conceitos ensinados. Assim, faz-se necessário o uso de técnicas computacionais que aprimorem a velocidade de 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.

### 1.1.2 Hipótese

Substituir a Aprendizagem por Reforço que é uma técnica de aprendizagem de máquina considerada mais lenta, por *Dynamic Scripting*, uma técnica de aprendizagem de máquina *online*, considerada mais rápida, no SAIE proposto por Dorça (2012), aumentará a velocidade de conversão do sistema, bem como seu aspecto dinâmico, reduzindo a quantidade de interações necessárias e, conseqüentemente, os problemas de aprendizagem.

## 1.2 Objetivos

Realizar um estudo aprofundado no trabalho desenvolvido por Dorça (2012) com vistas a implementar uma solução que reduza os Problemas de Aprendizagem e aumente a nota do aluno ao longo da interação com o sistema, apresentando uma solução que preencha os requisitos defendidos pelo autor, mas que ofereça um módulo de atualização do ME mais eficiente.

Objetivos Específicos:

- Implementar uma variação do DS, para garantir ao sistema uma característica mais dinâmica e de maior velocidade de conversão;
- Substituir as instruções de AR pela proposta de variação DS para eliminar os Problemas de Aprendizagem decorrentes das delongas da conversão provocadas pela AR;

- Ajustar os parâmetros do algoritmo através de bateria de testes para obter uma solução otimizada;
- Comparar os resultados da proposta com abordagens encontradas na literatura para verificação da sua viabilidade e contribuição.

### 1.3 Justificativa

Segundo dados do Censo EAD.BR 2015, 5.048.912 alunos estão matriculados em Cursos à Distância, sendo dados que correspondem a 368 Instituições regulamentadas que participaram dessa pesquisa (ABED, 2016). O público de alunos de graduação EAD no Brasil em 2015 correspondia a 17,82% de todos os alunos do ensino superior (INEP, 2015). A Associação Brasileira de Educação à Distância (ABED) relata que a EAD exige inovação tecnológica e administrativa, infraestrutura tecnológica e de apoio ao aluno em níveis mais elevados quando em comparação à modalidade educacional presencial.

Outro dado pertinente é a evasão do aluno EAD, que em 2015 registrou uma marca de 26% a 50%. Ainda segundo dados da ABED (2016) havia uma previsão de aumento nos investimentos em EAD para o ano de 2016 de 24,91% e, que de todos investimentos 37,01% foram destinados a Tecnologia e Inovação.

A percepção apresentada nos resultados dos Censos da ABED (2016) e INEP (2015) evidenciaram a necessidade constante de inovação tecnológica e apoio ao aluno para manutenção do EAD. Trata-se, portanto de um ponto sensível para a continuidade do desenvolvimento desta modalidade de ensino, tendo em vista o incômodo e grave problema da evasão, que se infere, que seja proporcionada pelo pouco apoio ao aluno. A preocupação da sociedade acadêmica é ainda notada quando se analisa os investimentos destinados a implementação de tecnologias que permitem melhorar o ensino.

Cursos de curta duração se popularizam nos dias atuais. As vezes destinados a alunos recém-formados de diversas áreas que pretendam atualizar conhecimentos ou adquirirem competências em áreas práticas de forma objetiva (BRANDÃO, 2006). Buscam também atender às necessidades de capacitação voltados para o trabalho, mão de obra técnica da indústria brasileira (BOSCHETTI; OLIVEIRA, 2017). Empresas também utilizam desses cursos para nivelarem conhecimento entre seus empregados e para capacitação em geral (ALMEIDA; COSTA, 2006). O que há em comum nessa demanda é o fato de utilizarem largamente o EAD (MELLO, 2011). Dessa forma, uma abordagem adaptativa, para ser efetiva, necessita de um modelo de detecção e correção do modelo estudantil de rápida conversão.

Todos os elementos citados corroboram para justificar a presente pesquisa, que de forma objetiva busca atender os anseios existentes pelo público EAD.

A proposta aqui apresentada é de inovação tecnológica que visa apoiar o aluno, tratando-o de maneira individualizada, respeitando suas preferências, contribuindo para redução da evasão e elevando ainda mais a qualidade do EAD.

## 1.4 Metodologia

A elaboração deste trabalho consiste em uma proposta de otimização no modelo apresentado por Dorça (2012) em sua tese intitulada 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. Para tal buscou-se contribuir com a proposta citada, no aspecto que trata da AR.

AR, segundo Dorça (2012), foi escolhida por ser uma técnica da IA que permite a um agente aprender a partir da sua interação com o ambiente no qual ele está inserido. Contudo, para atender à demanda esperada, era necessário que fosse utilizada uma técnica de aprendizagem não supervisionada, uma vez que não se sabe qual é o EA real do aluno. Dessa forma, o AR funciona como um adestramento do ME, convergindo para o modelo desconhecido a partir de recompensas recebidas quando a avaliação é positiva.

Contudo, segundo Spronck (2005), técnicas como Redes Neurais, Algoritmos Evolutivos e Aprendizado por Reforço, são consideradas lentas, e seu uso corresponderiam a muito tempo necessário para ajustar o elemento a ser otimizado. Além disso, uma característica do AR é que não há direção para o treinamento do agente, isto é, a única forma que ele aprende é por tentativa e erro, sabendo apenas a ação a desempenhar em caso de resultado abaixo de 60%. Assim, não há conhecimento prévio das regras que relacionem ações a estados (FARIAS, 2014).

Neste sentido, busca-se contribuir implementando uma solução em substituição à AR, que visa eliminar os problemas ou deficiências inerentes à AR, e buscar oferecer um modelo mais robusto e que tenha condições de acelerar a convergência do sistema. O DS apresenta uma estrutura de aprendizagem que atrela a cada regra um peso, o qual determina a qualidade desta, frente a sua condição, e também à probabilidade dessa regra ser escolhida para ter sua ação executada (SPRONCK, 2005).

Dentre as vantagens do DS tem-se a possibilidade de inclusão de informação explícita pelo desenvolvedor, que pode aproveitar seu conhecimento prévio do problema, para interferir na inicialização das regras e dos pesos. Essa característica garante a qualidade esperada do conhecimento que o agente possui (DORÇA, 2012), além, ainda, que permitir um maior controle sobre os possíveis comportamentos adotados pelo agente, uma vez que o desenvolvedor conhece previamente as regras que ele implementou (FARIAS, 2014).

A Metodologia do presente trabalho segue os seguintes passos:

1. Elaboração das regras que estarão na base de regras. A princípio serão criadas 40 regras que se propõem a executar uma ação no sistema caso uma determinada condição seja satisfeita. Será implementado um sistema de sorteio onde as regras sorteadas serão carregadas em um *script* e executadas. Em seguida, após receber o resultado da avaliação (PFM), essas regras serão penalizadas ou recompensadas.
2. Substituição do módulo de AR pelo DS e realização da integração do mecanismo DS ao sistema para realizar a atualização do ME, e assegurar o aspecto adaptativo do sistema.
3. Realização dos mais variados testes a fim de comprovar a viabilidade da proposta.

## 1.5 Estrutura da Dissertação

O presente trabalho se estrutura como segue. O segundo capítulo contém conceitos acerca de Educação, Estilos de Aprendizagem, Tecnologias da Informação e Comunicação, Educação à Distância, Técnicas de Inteligência Artificial, o Sistema Adaptativo e Inteligente para Educação proposto por [Dorça \(2012\)](#) e revisão da literatura. O terceiro capítulo descreve a Abordagem Proposta denominada de *Adapted Dynamic Scripting*(ADS). O quarto capítulo demonstra a metodologia utilizada para realização dos experimentos e os resultados obtidos. Por fim, o quinto capítulo contém as considerações finais e trabalhos futuros.

## 2 Referencial Teórico

Neste capítulo tratar-se-ão conceitos, teorias, técnicas e abordagens que fundamentam esta pesquisa.

### 2.1 Educação à Distância

A Educação à Distância (EAD) não se trata de uma nova forma de aprender, consiste em uma modalidade de ensino que permite a democratização e o acesso ao ensino em números expressivos, sempre, ao longo dos anos, evoluindo e se adaptando ao contexto social e tecnológico (MORAN, 2000; POLAK; MUNHOZ; DUARTE, 2008). Para uma melhor abordagem desse conceito dividiu-se sua análise em 4 subseções, sendo: Evolução da EAD, Tecnologias da Informação e Comunicação e Sistemas de Gestão de Aprendizagem (SGA) / Ambientes Virtuais de Aprendizagem (AVA).

#### 2.1.1 Evolução da EAD

O surgimento da EAD se confunde com a evolução e popularização dos meios de transporte e de comunicação. Referências remontam à Europa do século XV quando do surgimento da imprensa ou a partir do século XIX com o advento das ferrovias nos Estados Unidos e Europa (BITTENCOURT, 2003). O que se sabe ao certo é que a EAD, ao longo de várias épocas e gerações, variou sua metodologia conforme as mídias e tecnologias disponíveis (VIEIRA; CUNHA; MARTINEZ, 2017).

Houve vários momentos, desde modelos por correspondência, rádio e televisão, até chegar a um modelo baseado na Web. O modelo EAD baseado na web pode ser dividido em pelo menos 3 momentos distintos, assim como a própria Web. Isso se deve à natural evolução da integração da Web às diversas práticas de EAD, se aperfeiçoando juntamente com a Web, percebendo novas funcionalidades e recursos ao longo do tempo (LIMA; MATTAR, 2017).

Diante dessa premissa se faz necessário pensar um pouco sobre a Web, para que se possa compreender sua ligação com a EAD. A história versa que a Web surgiu na década de 80, sua expansão e popularização ocorreu a partir de meados da década de 90 (BERNERS-LEE; FISCHETTI; BY-DERTOUZOS, 2000). A Web, é percebida hoje, como o resultado da evolução de 3 estágios chamados na literatura de Web 1.0, Web 2.0 e Web 3.0.

Para Naik e Shivalingaiah (2008) a chamada Web 1.0 tinha como propósito conectar informação e disponibilizá-la em rede. As páginas nesse período eram estáticas

e caracterizadas pela limitação ao conteúdo divulgado pelo desenvolvedor (CORMODE; KRISHNAMURTHY, 2008). Nesse contexto o modelo de EAD à época mantinha uma proposta de disponibilização de conteúdo em páginas com uma limitada interação com o usuário (SCHONS; RIBEIRO; BATTISTI, 2008).

A Web 2.0, por outro lado, almejava popularizar a conexão entre pessoas, democratizando a construção de conteúdo. Buscava aproveitar ao máximo a capacidade de interação dos usuários, incentivando as pessoas a usar, consumir e transformar dados de várias fontes, em especial de outros usuários, fornecendo seu próprio conteúdo, criando uma arquitetura de participação, indo além da ideia da página da Web 1.0 (O'REILLY, 2005). O ensino à distância nesse período recepcionou muitas das novidades trazidas pela Web 2.0, como as ferramentas colaborativas *wikis* e fóruns de discussão, almejando a construção coletiva do conhecimento no ciber espaço (ANJOS, 2009). Ressalta-se ainda a popularização de muitas redes sociais, as quais foram apropriadas e usadas pela EAD de diversas formas. Pode-se exemplificar com o *YouTube*, rede social largamente utilizada na EAD, onde a quantidade de video aulas nessa rede social por si só, já denota sua importância para a EAD, que não apenas é utilizada pelas instituições educacionais, mas por qualquer pessoa que quer ensinar ou aprender algo (MATTAR, 2009).

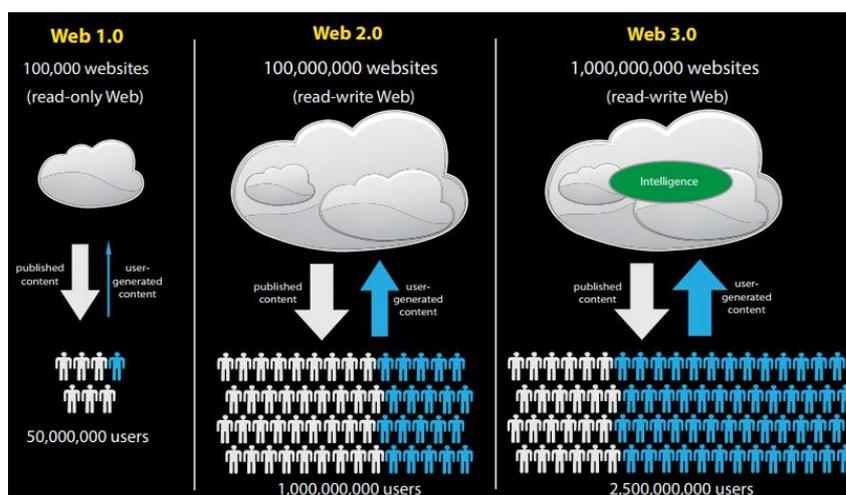
O próximo estágio, Web 3.0, também chamada de Web Semântica, trata da representação de significados, busca conectar conhecimento e, colocá-los para trabalhar de forma que façam a experiência na internet mais relevante e útil (PALETTA; MUCHERONI, 2017). O conceito de semântica é entender o significado das coisas e poder extrair informações deste significado, portanto o objetivo da Web Semântica pressupõe que ao invés da web ativar suas buscas por palavras-chaves será usado significação para dar uma direção para a busca. Segundo Stojanovic, Staab e Studer (2001) o termo Web Semântica significa criar conteúdo também apropriado e adequado para ser acessado por agentes inteligentes e não apenas voltado a seres humanos. Gomes (2008) salienta que a Web 3.0 permite aos computadores e humanos trabalharem juntos e utilizarem de Inteligencia Artificial para elevar a qualidade das tarefas a serem realizadas.

As várias funcionalidades e recursos disponibilizados pela Web 3.0 estão sendo explorados e incorporados no cotidiano dos usuários.

A Figura 1 demonstra, de forma geral, as diferenças mais marcantes entre os três momentos vividos pela *Web*. Tem-se a *Web* 1.0, marcada pela quantidade limitada de usuários geradores de conteúdo, a *Web* 2.0 caracterizada por um aumento considerável de usuários, um aumento nos usuários geradores de conteúdo e um aumento da nuvem. Por fim a *Web* 3.0, onde a maioria dos usuários já são produtores de conteúdo, a nuvem de dados permanece em contínua expansão, marcada ainda pela presença de mecanismos que permitem a interação de agentes inteligentes.

No que tange a EAD, as mais variadas pesquisas são feitas a fim de incorporar

Figura 1 – Comparação entre as WEB 1.0, 2.0 e 3.0



Fonte: [goo.gl/YUWkXw](http://goo.gl/YUWkXw)

técnicas de Inteligência Artificial nos ambientes de aprendizagem, buscando otimização de processos e personalização do ensino (ISOTANI et al., 2008). Alguns recursos da Web Semântica já permitem às plataformas de EAD que os alunos interajam melhor e mais diretamente com os sistemas de ensino, dispensando o intermédio de um professor ou tutor humano. Surge a possibilidade do sistema de gerenciamento de ensino, ao interagir com o aluno, aprender sobre ele, coletando seus dados de navegação e inferindo a forma que ele aprende melhor. Assim, passa a ser possível a personalização do processo de ensino/aprendizagem de acordo com o perfil de cada estudante (BITTENCOURT; COSTA, 2011).

Dessa geração da EAD que surgem os sistemas de educação adaptativa, divididos em dois grupos: os Sistemas Tutores Inteligentes (STI) e os Sistemas de Hipermissão Adaptativa (SHA) (BARBOSA, 2004). Em síntese os STI e SHA têm em comum a ideia de modelar o aluno a partir das suas interações com o sistema. Uma vez coletadas informações suficientes, cria-se um modelo de estudante, que reflete a maneira como o sistema vai lhe enxergar. Dessa forma os STI e SHA oferecem um tratamento customizado orientado ao modelo de estudante que perceberam durante as interações. Logo, quanto mais o aluno interagir com o sistema, mais robusto tende a ficar o modelo criado e dessa forma oferecerá um atendimento de maior qualidade (DAZZI; AZEVEDO; FERNANDES, ). Esses dois sistemas serão abordados com mais detalhes adiante.

É possível perceber que a evolução da EAD está vinculada diretamente com as tecnologias e meios de comunicação existentes, motivo pelo qual, trataremos delas a seguir.

### 2.1.2 Tecnologias da Informação e Comunicação

A evolução tecnológica tem promovido uma radical mudança na forma de viver em sociedade, em especial quando trata-se das relações interpessoais. A viabilidade dessas novas formas de relações interpessoais são frutos de uma constante evolução das chamadas Tecnologias da Informação e Comunicação (TICs).

Pinto et al. (2017) define TIC como sendo tecnologias que possuem um computador e a internet como itens básicos e que devem ser consideradas como ferramentas de otimização de processos, permitindo a ampliação do acesso à informação através da interligação de diversas fontes e recursos.

Vian (2016), por sua vez, diz que são as ferramentas de comunicação na atual tecnologia da informação. Consiste nos meios técnicos utilizados para tratamento da informação e auxílio na comunicação, seja via hardware ou software. TIC ou TI correspondem as tecnologias que interferem e mediam os processos informacionais e comunicativos dos seres. Já para MAYER (2016) TICs são uma área que se vale da informática como um mecanismo para produção, transmissão, armazenamento e uso das mais variadas informações.

Essa discussão a respeito das TIC é importante, uma vez que seu pleno desenvolvimento influencia e muda, de forma marcante, diversas áreas da vida social, como a economia, a política, a cultura e como já foi dito, as próprias relações sociais (RODRIGUES; COSTA, 2017).

Logo, com a educação não seria diferente, a tendência à incorporação e assimilação de diferentes TICs nas práticas pedagógicas é notável (SILVA, 2013). Essa evolução rápida e constante das TICs representam novos desafios pedagógicos, demandando um posicionamento das instituições de ensino, que deve formar pessoas ativas e aptas a viver no mundo da informação, capazes de construir e compartilhar seus conhecimentos (SILVA; SANTOS, 2017).

Toda mudança gera a necessidade de uma adaptação curricular e metodológica que considere o desenvolvimento de habilidades e competências nos alunos que convivem em um ambiente em constantes transformações (GOMES; UNGLAUB; COSTA, 2017). Mas não apenas isso, não há apenas novas demandas, há também novas oportunidades, uma vez que as TICs podem e são largamente utilizadas para incrementar e inovar o processo de ensino/aprendizagem, seja em ambientes presenciais ou à distância.

A EAD se apropriou das TICs de forma automática, haja vista sua integração natural aos meios de comunicação, a partir da Figura 2 pode-se ver um rol exemplificativo das inúmeras TICs que são largamente utilizadas hoje em dia na EAD. Existe agora, a necessidade de se utilizar as TICs com vistas a promover o desenvolvimento das habilidades e competências dos estudante utilizando todos os recursos que as TICs oportunizam. Esses

recursos, devido sua amplitude requer que a EAD opte por tecnologias que corroborem com as necessidade propostas em cada curso, respeitando o contexto necessário para proporcionar uma ação educacional satisfatória (SILVA, 2013).

Figura 2 – Conjunto de TICs atualmente disponíveis e utilizadas na EAD



Fonte: (TECNOLOGIA, 2012)

A contribuição mais significativa que as TICs proporcionaram à EAD, sem dúvida, foram os SGA ou AVA. Esses ambientes destinados à concentrar as atividades dos alunos EAD em um único lugar, integrando as mais diversas tecnologias colaborativas, corresponde a um marco de relevante importância que só se tornaram factíveis a partir das TICs. Acerca destes ambientes fala-se a seguir.

### 2.1.3 Sistemas de Gestão de Aprendizagem(SGA) e Ambientes Virtuais de Aprendizagem(AVA)

Os Sistemas de Gestão de Aprendizagem (SGA) e Ambientes Virtuais de Aprendizagem (AVA) são exemplos de ferramentas destinadas ao ensino à distância originadas a partir das TICs (MAURO et al., 2017).

Os SGAs ou *Learning Management Systems* (LMS), como também são conhecidos, são ferramentas de gerenciamento de ensino/aprendizagem que viabilizam o contato entre professores e estudantes, distantes temporal e geograficamente, permitindo que ambos usufruam de certa autonomia durante o processo de ensino/aprendizagem (PHILLIPO; KRONGARD, 2012). Em geral, são destinados ao gerenciamento dos recursos que o estudante necessita durante seu processo de ensino/aprendizagem. Foca, não apenas a disponibilização do conteúdo online ao estudante, mas na disponibilização de recursos que permitem aos alunos o aprendizado coletivo, mediado por ferramentas como fóruns, chats, enquetes, mensagens instantâneas, *wikis* e outras (MACEDO; FOLTRAN, 2007).

Os AVAs, de forma semelhante, são ferramentas de mediação do ensino à distância, consistindo em ambientes de interação entre os estudantes e os chamados Objetos de Aprendizagem (SANTOS, 2002). Os Objetos de Aprendizagem são quaisquer materiais digitais (textos, vídeos, imagens, aplicações e etc) que possam ser utilizados para melhorar o aprendizado, permitindo um estímulo ao raciocínio e pensamento crítico dos alunos, recorrendo aos recursos tecnológicos para inovar nas abordagens pedagógicas (AYUB; CARVALHO; TEIXEIRA, 2009).

Verifica-se que se confundem os conceitos de SGA e AVA (GONÇALVES, 2016), e que muito embora exista as duas nomenclaturas, para este trabalho, tratar-se-ão os dois como sendo um ambiente de construção de conhecimentos onde as tecnologias digitais são de fundamental importância para aumentar a produtividade dos alunos (MACEDO; FOLTRAN, 2007).

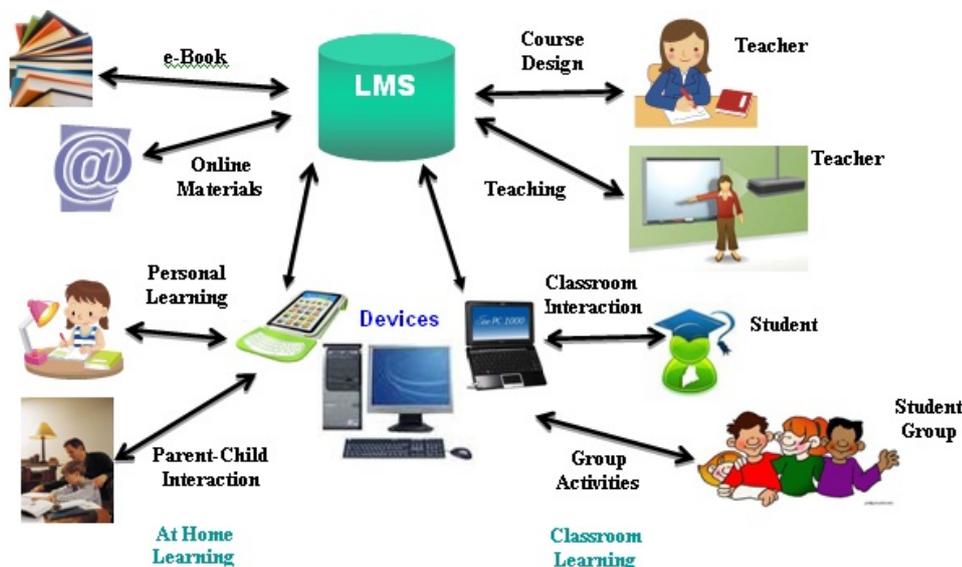
São muitos os ambientes de aprendizagem utilizados nos mais diversos cursos EAD, para fins de exemplo, cita-se o mais utilizados que é o sistema Moodle (GONÇALVES, 2016 apud RICE, 2006). O *Modular Object-Oriented Dynamic Learning Environment* ou Moodle, é um software livre de gestão da aprendizagem. Foi concebido com a finalidade de promover um ambiente colaborativo, onde os envolvidos seriam capazes de intercambiar conhecimento, vivenciando e criando novas formas de interação para um ambiente de uma comunidade. Permitindo aos atores envolvidos a customização do ambiente, com base em seus interesses e propósitos pedagógicos (ALVES; BARROS; OKADA, 2009). Tem como característica um alto grau de compatibilidade com outros sistemas, flexibilidade e de fácil *upgrade* e customização (DOUGIAMAS; TAYLOR, 2003).

O Moodle, assim como diversos outros SGA/AVA, buscam a promoção de um aprendizado ativo por parte dos estudantes, de forma que o aluno seja capaz de construir novas perspectivas a partir dos conhecimentos adquiridos, modificando as informações e criando hipóteses. É requerido do aluno EAD essa pró atividade, cabendo ao professor ou tutor, a tarefa de conduzi-los pelo aprendizado com base no conteúdo pré estabelecido (COMASSETTO et al., 2006).

A Figura 3 apresenta um exemplo de como os elementos de um ambiente de ensino EAD se relacionam através do SGA. É possível verificar o papel desenvolvido por cada participante do processo de ensino/aprendizagem e como a ferramenta de gestão proporciona de forma organizada e integração de todos os elementos.

Essas tecnologias utilizadas no processo de ensino/aprendizagem, proporcionam ao EAD um constante avanço na superação das dificuldades dessa modalidade de ensino. A barreira tempo e espaço se reduz diante do uso desses ambientes virtuais de aprendizagem de forma a permitir ao estudante escolher o melhor momento para se dedicar aos estudos, tendo à disposição informação de qualidade e de fácil acesso (GONÇALVES, 2016).

Figura 3 – Interação dos elementos que compõem a EAD através de um SGA/AVA



Fonte: (POMPTCLOUD, 2015)

Contudo, segundo [ABED \(2016\)](#) os sistemas de gestão de aprendizagem no EAD, demandam constante evolução e investimentos tecnológicos com vista a reduzir o elevado número da evasão nessa modalidade de ensino. Para tal busca-se oferecer ao estudante um ensino personalizado de acordo com suas preferências individuais. A etapa de adaptação do ensino passa primeiro pela detecção dos Estilos de Aprendizagem, tópico este, que será tratado a seguir.

## 2.2 Estilos de Aprendizagem (EA)

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.

Contudo, compreende-se essa quantidade exacerbada de EA, uma vez que há uma longa caminhada percorrida por pesquisadores desta área, que desde 1930 já discutiam a influência e importância dos EA na educação ([RIDING; CHEEMA, 1991](#)). Devido a importância dessa teoria para se garantir um aspecto adaptativo ao processo de ensino/aprendizagem, buscar-se-á uma melhor compreensão do assunto relacionando algumas definições de EA encontradas 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, Dunn e Price \(1981\)](#), 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 e 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, Gallego e Honey (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, Poell e Simons (2005) conceituam EA como uma tendência em buscar utilizar uma determinada estratégia de aprendizagem que lhe é preferencial.

Diante dessas definições, é possível verificar 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 diversos trabalhos que enumeram e tratam de possíveis falhas e controvérsias inerentes a esse assunto.

Veenman, Prins e Verheij (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, Stahovich e Mayer (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.

[Kirschner \(2017\)](#) ainda afirma que, uma preferência por um determinado EA é sinal de fraqueza em relação aos outros EA, dessa forma, essa preferência deve ser eliminada e não respeitada. De tal forma que, caso um determinado estudante tenha preferência por um aprendizado com mais conteúdo visual, a este deve ser submetido conteúdos de natureza verbal, para que ele busque se desenvolver e estar apto a todos os EA possíveis. Outra crítica, conforme falado anteriormente, a própria quantidade exagerada de EA informado por [Hood et al. \(2017\)](#) já é um sinal de incoerência acerca da teoria dos EA.

Entretanto, apesar das críticas, pesquisas recentes ([DORÇA, 2012](#); [FALCI et al., 2016](#); [GONÇALVES, 2016](#); [RODRIGUES et al., 2016](#); [SENA et al., 2016](#)) assinalam uma nova tendência na aplicação dos EA. No que tange às ferramentas de detecção de EA que se utilizam de questionários, atualmente 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; 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; LIMA 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.

Tratados os pontos polêmicos, passa-se a discutir a dificuldade que surge na preocupação de conhecer o método ou a maneira como se é possível detectar o EA que determinada pessoa possui. Diante deste problema, muitas soluções são encontradas na literatura. Algumas das mais conhecidas serão abordadas a seguir.

### 2.2.1 Inventário de Estilos de Aprendizagem de Kolb

Kolb (1971) apresenta o processo de ensino/aprendizagem como uma sequencia periódica orientada pela experiência. A experiência qualifica a pessoa e a torna capaz de buscar novas oportunidades e portanto, novas experiências (CERQUEIRA, 2000; SILVA, 2012; KOLB, 2005). Nessa perspectiva Kolb (2005) entende que os conflitos cognitivos do ser humano podem ser solucionados ao agirmos de forma concreta ou abstrata, ativa ou reflexiva. Logo, pode-se concluir sumariamente que seu modelo de EA se divide em apenas duas dimensões, sendo a Percepção e o Processamento (ALMEIDA, 2010)

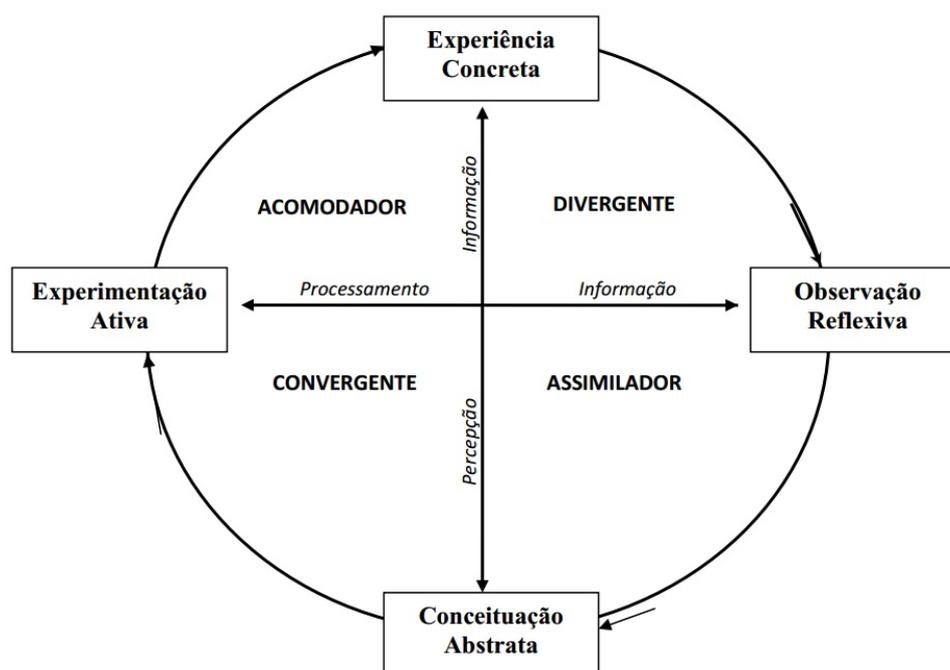
Para cada dimensão, portanto, há dois extremos diferentes que determinam os diferentes EA possíveis para cada aprendiz. Na dimensão de Percepção há duas maneiras de se receber as informações, sendo através da experiência concreta ou da observação reflexiva. De igual forma, a dimensão de Processamento também possui duas formas de se processar as informações, sendo a conceituação abstrata ou a experimentação ativa.

Para uma melhor representação do processo de ensino/aprendizagem tem-se a Figura 4, onde é possível compreender o ciclo proposto por Kolb (2005). Como se trata de um ciclo, presume-se uma sequencia entre as experiências, dessa forma, caso siga a partir das experiências concretas, através dos sentidos, permitirão observações e reflexões, por outro lado, o que foi assimilado através da observação reflexiva torna-se em conceitos abstratos, e implicarão em novas experiências (SILVA, 2012 apud KOLB et al., 2001).

As duas dimensões do modelo de Kolb et al. (2001), presentes no ciclo das experiências da Figura 4, geram quatro quadrantes que delimitam os estilos de aprendizagens possíveis. Os estilos de aprendizagem definidos por Kolb (2005) são:

1. Divergente (concreto e reflexivo): os divergente são caracterizados pela muita criatividade e capacidade de apresentarem soluções inéditas;
2. Assimilador (abstrato e reflexivo): os assimiladores fundamentam sua aprendizagem na observação reflexiva e na conceitualização abstrata. Optam por pensar e refletir sobre o conteúdo, contato direto com a prática não é importante para esse EA;

Figura 4 – O ciclo de aprendizagem proposto por Kolb



Fonte: Kolb (2005) adaptado por Silva (2012)

3. Convergente (abstrato e ativo): o aluno convergente opta, através da conceituação abstrata e da experimentação ativa aplicar as ideias em situações práticas;
4. Acomodador (concreto e ativo): este EA é caracterizado pela preferência em acessar a informação de forma concreta e processá-la ativamente;

Uma vez delimitados os Estilos de Aprendizagem definidos por Kolb (1971), passa-se a apresentar o modelo usado na detecção dos EA. Seu instrumento de detecção dos EA é conhecido como *Learning Style Inventory - LSI* ou Inventário de Estilos de Aprendizagem de Kolb.

Após sofrer diversas revisões desde sua criação a versão mais recente possui uma série de doze 12 questões que devem ser respondidas pelo estudante de acordo com suas preferências pessoais. Cada uma das questões possui 4 respostas possíveis, logo cada uma das opções corresponde a um dos EA que tratou-se anteriormente (KOLB et al., 2001), ao fim do questionário o maior percentual de respostas que se enquadra em determinado estilo corresponderá ao EA do aluno.

### 2.2.2 Felder and Silverman Learning Style Model(FSLSM)

Sob influência do modelo de EA de Kolb (2005) e outros teóricos, Felder e Silverman (1988) desenvolveram um modelo de EA orientado pela maneira como o indivíduo interage com a informação (SILVA, 2012).

O FSLSM foi proposto em 1988 e desde então passou por algumas revisões e atualizações, a mais expressiva delas diz respeito à quantidade de dimensões de EA, anteriormente eram 5 mas o modelo mais atual é composto por 4 dimensões. As dimensões dizem respeito ao à forma como estudante se relaciona com a informação, sendo que cada dimensão corresponde a uma etapa do processo de aprendizagem. [Felder e Silverman \(1988\)](#) elencaram as seguinte dimensões de EA, as quais seguem comentadas de acordo com [Dorça \(2012\)](#) e [Silva \(2012\)](#):

1. Percepção-> sensitivo ou intuitivo : essa dimensão diz respeito à qual o tipo de informação o estudante tem preferência em perceber.
  - a) Sensitivos: optam por informações fáticas, datas, resultados experimentais, exemplos, informação real, preferindo abstrair informações pelos seus sentidos (vendo, ouvindo, tocando). Intuitivos: preferem teorias, definições, informação simbólica, modelos matemáticos, abstrações, buscam a ser concretos, pragmáticos na resolução de problemas;
  - b) Intuitivos: preferem modelagens teóricas acerca dos conceitos que aprenderá. Inovadores e imaginam novas soluções para resolução de problemas;
2. Entrada-> visual ou verbal: essa dimensão determina quais os sentidos são os preferidos pelo estudante usar na ocasião do recebimento da informação;
  - a) Visuais: como o próprio nome já diz, são visuais, possuem uma preferência em usar a visão para receber a informação, gostam de figuras, gráficos, filmes e etc.
  - b) Verbais: apreciam receber a informação escrita, aptos a obter mais informações em um debate, possuem facilidade em lidar com a palavra.
3. Processamento-> ativo ou reflexivo: corresponde a como o estudante prefere processar a informação;
  - a) Ativos: gostam de lidar ativamente com a matéria estudada através de debates, trabalho em grupo. Assimilam melhor a informação na prática. Buscam cenários dinâmicos que tendem a proporcionar experimentações.
  - b) Reflexivos: introspectivos, preferem refletir sobre o que estão estudando, trabalhando sozinhos. A reflexão é sua maneira preferencial de processamento. Se desenvolvem melhor em circunstâncias que lhe ofereçam tempo e espaço para a abstração e construção de hipóteses.
4. Organização-> global ou sequencial: diz respeito a como o estudante organiza suas ideias diante das etapas até chegar à compreensão.

- a) Sequenciais: preferem seguir uma sequência lógica e linear de etapas. Optam por seguir uma sequência lógica acerca de uma tarefa. No passo a passo buscam produzir a visão geral sobre o todo.
- b) Globais: iniciam a análise buscando obter uma visão geral do todo. Preferem ter uma visão geral do conteúdo a ser estudado de forma a conseguir entendê-lo.

Pode-se verificar que cada dimensão possui dois extremos, isto é, polos opostos que são os responsáveis por determinar o EA do estudante (FELDER; SPURLIN, 2005).

Assim como Kolb et al. (2001) que apresentou seu modelo de detecção de EA, Soloman e Felder (1999) desenvolveram um instrumento para avaliar, as preferências de um aluno dentro das quatro dimensões do FLSM, trata-se do *Index of Learning Styles Questionnaire* (ILSQ).

O ILSQ<sup>1</sup>, assim como o ILS de Kolb et al. (2001), é composto por um questionário onde, de acordo com as respostas obtidas, infere-se o EA do aprendiz.

Contudo, o modelo de Felder, Soloman et al. (1991) inova em alguns aspectos, diferente do modelo de Kolb et al. (2001) que possui um aspecto mais determinístico acerca do EA do estudante, o ILSQ é fundamentado na premissa de que cada aluno possui um determinado grau de preferência por cada EA dentro das 4 dimensões (FELDER; SILVERMAN, 1988).

As preferências são mensuradas dentro do intervalo de [-11,11], conforme pode ser visto na Figura 5, cada uma das dimensões do FLSM possui dois lados opostos, as respostas do ILSQ indicarão para qual lado de cada dimensão o aluno está tendendo formando um intervalo. Logo, através desse intervalo é possível classificar a intensidade do EA em cada dimensão, permitindo diferenciá-los entre fortes, moderadas ou leves (DORÇA, 2012; SILVA, 2012).

O ILSQ é composto por 44 questões, de forma que cada uma das 4 dimensões possuem 11 perguntas. Cada questão possui duas alternativas de resposta, as quais o estudante deverá optar, de acordo com suas preferências. Ao final, a consolidação de todas as respostas determinarão o estilo de aprendizagem daquele aluno (FELDER; SPURLIN, 2005; DORÇA, 2012).

## 2.3 Inteligência Artificial (IA)

Os estudos na área IA não são tão recentes, Turing (1950) já propunha teorias acerca desse assunto iniciando sua obra questionando o leitor se é possível a uma máquina pensar.

---

<sup>1</sup> O ILSQ se encontra disponível em: [www.webtools.ncsu.edu/learningstyles](http://www.webtools.ncsu.edu/learningstyles)

Figura 5 – Intervalo de classificação dos EA apresentados pelo ILSQ

<b>Estilo</b>	<b>11</b>	<b>9</b>	<b>7</b>	<b>5</b>	<b>3</b>	<b>1</b>	<b>1</b>	<b>3</b>	<b>5</b>	<b>7</b>	<b>9</b>	<b>11</b>	<b>Estilo</b>
<b>Sensorial</b>	11	9	7	5	3	1	1	3	5	7	9	11	<b>Intuitivo</b>
<b>Visual</b>	11	9	7	5	3	1	1	3	5	7	9	11	<b>Verbal</b>
<b>Ativo</b>	11	9	7	5	3	1	1	3	5	7	9	11	<b>Reflexivo</b>
<b>Sequencial</b>	11	9	7	<b>5</b>	3	1	1	3	5	7	9	11	<b>Global</b>

Fonte: [www.webtools.ncsu.edu/learningstyles/](http://www.webtools.ncsu.edu/learningstyles/)

A Inteligência Artificial sempre esteve relacionada à evolução da computação, passando a ser reconhecida como ciência em 1956 na ocasião do *Workshop of Dartmouth College* (NAVEGA, 2000). Hoje procura estudar e compreender o fenômeno da inteligência, em busca de desenvolver ferramentas para melhorar e otimizar processos e, portanto, a qualidade de vida humana. O uso de técnicas de Inteligência Artificial no desenvolvimento de sistemas educacionais vem se tornando cada vez mais indispensável, proporcionando um nível de qualidade e robustez cada vez mais elevado (GUELPELI; RIBEIRO; OMAR, 2003).

As primeiras propostas para uso da IA enquanto ferramenta de aprendizagem, foram os Sistemas de Instrução Assistida por Computador. Com o passar do tempo, vários outros estudos nessa área passaram a constituir uma área que passou a ser chamada de Informática na Educação (POZZEBON; FRIGO; BITTENCOURT, 2004).

A IA na educação foca inicialmente na busca pela adaptação às características individuais dos aprendizes utilizando algumas técnicas abordadas a seguir.

### 2.3.1 Redes Neurais Artificiais (RNA)

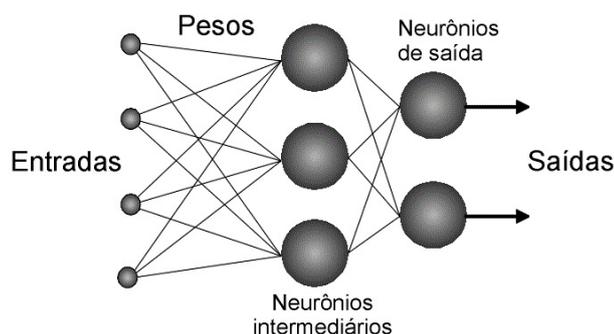
Uma Rede Neural pode ser definida como um modelo de raciocínio lógico inspirado no cérebro humano. Assim, o cérebro é constituído por um conjunto de células nervosas densamente interligadas, ou unidades de processamento de informações básicas, chamadas neurônios (NEGNEVITSKY, 2005; SCHMIDHUBER, 2015). São técnicas computacionais bioinspiradas firmadas em modelos matemáticos que aprendem através da experiência e são utilizadas para solução dos mais diversos tipos de problemas.

São caracterizadas por serem tolerantes a falhas, possuem uma alta capacidade de distribuição e realização de informações, são capazes de autoaprendizagem, são adaptáveis e hábeis em mapeamento não linear (QI, 2009). Quando o problema a ser resolvido é de

certa forma mal definido, onde falta o conhecimento claro e objetivo de como a tarefa deve ser realizada, são apropriados para as RNA (KANG; PALMER-BROWN, 2008). Para solucioná-los, a rede é treinada com exemplos bem sucedidos com saídas esperadas, e a partir desse conhecimento se torna capaz de encontrar ou aproximar a solução do problema. Assim, programa-se uma máquina que simula as células cerebrais (neurônios) e se espera um comportamento inteligente a partir de então, capaz de aprender com o treinamento, fazendo generalizações e identificando padrões (BARRETO, 2002; YEH; LO, 2005).

RNA são compostas de neurônios artificiais que são estruturas lógico-matemática que visam simular a forma, o comportamento e as funções de um neurônio orgânico. Sendo assim, a parte do neurônio biológico conhecida como dendritos foi substituído por entradas(inputs), cujas conexões com o corpo do neurônio artificial são feita através de elementos chamados de pesos. Os dados recebidos pelas entradas são processados, e o extremo oposto do neurônio artificial corresponde à função de saída (output) (TAFNER, 1998; YANG, 2010), conforme pode ser visto na 6.

Figura 6 – Demonstração de RNA composta por 2 camadas(layers) de 4 entradas(input) e 2 saídas(output)



Fonte: (TAFNER, 1998)

Assim, utilizando-se as RNA artificiais, tem-se condições de lidar com problemas que pela complexidade ou elevado número de possibilidades seria enfadonho ou polinomialmente não factível em função do tempo de serem solucionados por sistemas lineares de resolução de problemas. As RNA serão treinadas e passarão a estarem aptas a reconhecerem os padrões existentes em determinada população e assim, com custo computacional baixo, se aproximará da solução ótima. Vale ressaltar que as RNA não buscam alcançar a solução ótima, mas aproximar o resultado a pontos aceitáveis por um custo menor (BARRETO, 2002).

Na literatura, encontram-se vários trabalhos desenvolvidos que tratam da detecção automática dos Estilos de Aprendizagem utilizando-se das RNA.

Cabada et al. (2009) por exemplo, propõe um modelo adaptativo baseado nos EA que utiliza de uma RNA com lógica *Fuzzy*. Propôs um novo método de customização que

ao identificar o EA do aluno ele viria a adaptar o material de ensino em ambientes de aprendizagem colaborativos e dispositivos móveis. Em síntese, seu método consiste em uma rede *fuzzy* neural treinada com diferentes cursos e diferentes estilos de aprendizagem e, depois é exportada para um dispositivo móvel juntamente com um interprete e os objetos de aprendizagem. Para treinar a rede o autor submeteu diversos estudantes ao ILSQ e armazenou seu resultado. Em seguida, submeteu os mesmos estudantes a um exame desenvolvido pelo próprio autor que buscava avaliar qual o desempenho dos alunos nos cursos que ele mesmo selecionou e nos estilos de aprendizagem escolhidos por eles. Essa escolha do EA foi aleatória. Ao final do teste, esperava-se que a saída fosse a mesma obtida pelo ILS. Dessa forma inicia-se a aplicação atribuindo um EA ao estudante e dependendo dos resultados obtidos nas perguntas preparadas para os alunos dentro dos objetos de aprendizagem, o material de aprendizagem é adaptado ao EA encontrado. Nesse processo, a Rede *Fuzzy* Neural é consultada, a fim de encontrar o EA mais apropriado para o aluno.

Crockett et al. (2013) idealizou uma técnica para classificar ou criar perfis de alunos de acordo com os EA, utilizando dados coletados através de um STI de conversação de um ambiente *e-learning*. Para processar os dados coletados, utilizou uma Rede Neural Artificial multi camadas. Foi realizada a integração de uma RNA de forma a combinar um conjunto de dados de comportamento extraídos da conversa de tutoria para melhorar a precisão da previsão dos EA, utilizando-se ainda de uma forma de realimentação de informações, a fim de tornar o sistema cada vez mais inteligente. Resultados experimentais realizados com os alunos reais mostram que a RNA foi capaz de prever os EA com uma precisão de  $\approx 84\%$ .

### 2.3.2 Aprendizagem por Reforço (AR)

Aprendizagem por Reforço é uma técnica de aprendizagem de máquina não supervisionada, usada para treinar um agente a exibir comportamentos específicos ao recompensar e penalizar ações ligadas a determinados estados (SPRONCK, 2005). O agente age sobre o ambiente percebendo sinais de *feedback* emitidos depois da execução de suas ações (FARIAS, 2014; ANDRADE et al., 2005).

Consiste, em síntese, em um agente aprender a melhor rotina de ações que proporcionem a melhor satisfação dos seus propósitos, de forma que o agente consiga compreender o conjunto de ações para os estados do problema que geram as maiores recompensas (SUTTON; BARTO, 1998).

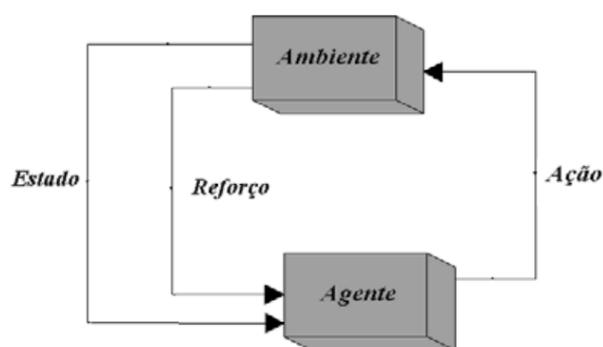
Funciona de maneira similar ao adestramento de um cão: para cada comportamento há uma resposta, aqueles comportamentos que se deseja estimular, é recompensada com respostas positivas ou agradáveis, ao passo que comportamentos indesejáveis são respondidos de forma negativa a fim de desestimular essa conduta (COSTA et al., 2016).

O agente AR a ser ajustado, age em determinado ambiente que é caracterizado por um conjunto de estados possíveis e para cada estado pode realizar uma ação que também pertence a um conjunto de ações possíveis, percebendo um valor chamado de reforço, decorrente de cada ação executada. O valor do reforço determina a qualidade dos pares estados-ações. O objetivo do agente passa a ser identificar os pares ordenados estado-ação que proporcionam o maior reforço possível (SUTTON; BARTO, 1998; RIBEIRO; KOERICH; ENEMBRECK, 2006).

Em outras palavras, pode-se dizer que a AR funciona como se existisse um avaliador externo ao ambiente, que analisa a ação tomada, mas sem demonstrar claramente a ação correta, deixando transparecer apenas uma tendência que pode ser percebida pelo agente através do reforço recebido (GUELPELI; RIBEIRO; OMAR, 2003).

Para maior clareza apresenta-se a Figura 7 a qual demonstra a estrutura do AR e os itens que o compõem, sendo os estados, ações e as recompensas.

Figura 7 – Disposição de como um agente AR interatua em seu ambiente



Fonte: Adaptado por Guelpeli, Ribeiro e Omar (2003)

O agente da AR adquire conhecimento, acerca de um ambiente, a partir da tentativa e erro. Uma vez selecionada a ação a ser executada, esta pode levar a outro estado e promover o recebimento de uma recompensa. A repetição desse processo gera o aprendizado, uma vez que as escolhas corretas, geram um reforço desejável e portanto o sistema buscará repeti-las. Ao longo das interações o agente de AR já começa a assimilar os estados, ações, e recompensas, de forma que possará a realizar somente as ações desejáveis (SUTTON; BARTO, 1998; OLIVEIRA, 2017).

Diversos trabalhos encontrados na literatura possuem implementado a técnica de AR para solução de problemas educacionais. Dorça (2012) por exemplo, aplica a AR para ajustar o modelo de estudante de forma a detectar seu estilo de aprendizagem e adaptar-lhe a forma de ministração dos conteúdos a serem estudados. Por outro lado, Guelpeli, Ribeiro e Omar (2003) propôs acrescentar um novo módulo de análise a ser inserido em uma arquitetura de Sistemas Tutores Inteligentes (STI) utilizando-se da técnica de AR a fim de modelar, de forma independente, o estudante.

Contudo, muito embora seja largamente utilizada na literatura, segundo [Spronck et al. \(2006\)](#) o AR é uma técnica de aprendizagem lenta, que necessita de muitas tentativas para conseguir modelar o agente a ser ajustado. Sendo, portanto, inapropriada para sistemas que demandem aprendizado *online*, isto é, em tempo de execução. Logo, para situações em que a demora em ajustar o agente acarrete problemas, o uso da AR não se mostra uma solução adequada, como por exemplo na IA de jogos comerciais. Para solucionar essa dificuldade, [Spronck \(2005\)](#) propôs o *Dynamic Scripting*, como será visto a seguir.

### 2.3.3 *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; 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; 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 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](#)).

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.

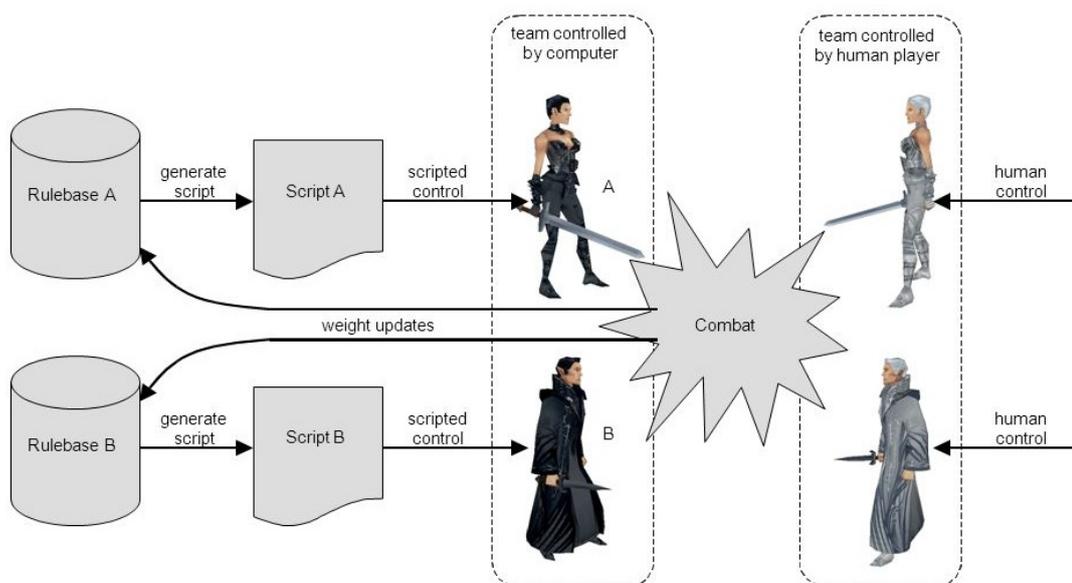
O DS adiciona a capacidade de explorar a representação do espaço de estados (que os *scripts* produzem) para uma aprendizagem rápida e eficiente, ao mesmo tempo em que confia no conteúdo baseado em *scripts* para garantir que todo o comportamento adaptativo seja plausível e eficaz (SPRONCK, 2005).

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).

Figura 8 – Técnica *Dynamic Script* no contexto de um jogo comercial



Fonte: (SPRONCK, 2005)

A Figura 8 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 de todas as regras são atualizados pela função *weight updates*.

A função de atualização de peso (*weight updates* na Figura 8) altera o peso das regras nos *scripts*, de acordo com o valor de *fitness* obtido. O valor chamado *fitness*, corresponde a um coeficiente encontrado a partir dos resultados que determinado *script* obteve em uma partida. Esses valores podem ser, a título de exemplo, quanto tempo demorou a 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. Citam-se os jogos de luta (MAJCHRZAK; QUADFLIEG; RUDOLPH, 2015), jogos de estratégia (DAHLBOM; NIKLASSON, 2006), *First-person shooter* (FPS) ou tiro em primeira pessoa (POLICARPO; URBANO; LOUREIRO, 2010), simuladores de voo (TOUBMAN et al., 2014), *Role-Playing Game* (RPG) (LADEBECK, 2008) e vários outros. Muitos destes trabalhos utilizaram o DS em sua forma original proposta por Spronck (2005) e alguns outros implementaram adaptações à técnica.

Toubman et al. (2014) por exemplo, propuseram uma abordagem destinada ao treinamento militar com a ideia de coordenação de equipe. Nesta proposta, um dos agentes seria o coordenador, aprendendo através do DS. A abordagem proposta foi de que esse agente principal coordene o comportamento dos outros agentes, através de mensagens. Os resultados obtidos com a coordenação centralizada da equipe e DS demonstraram um melhor comportamento e ajuste mais rápido do que a abordagem de ajuste de todos os agentes do time.

Kop et al. (2015), por sua vez, 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 proposta 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.

Ludwig e Farley (2009) estudaram o DS com a finalidade de desenvolver um

*framework* com condutas táticas de jogos, projetados para tornar mais fácil a escolha de comportamentos de agentes em jogos que incluam uma grande quantidade de incertezas. Realizou testes comparativos de desempenho entre sua versão intitulada, *Extended Dynamic Scripting* (EDS), e o DS original, proposto por Spronck (2005). Em seus resultados, demonstrou que sua abordagem obteve aumento na *performance* em comparação ao DS.

Soni e Hingston (2008) apresentaram em seu trabalho a premissa que *Bots*(NPC) preparados para se comportarem de maneira similar ao *player* humano proporcionam maior entretenimento. Aplica este pressuposto em jogos do estilo *First-Person Shooter*(FPS), entendendo que o *script* precisa controlar um agente de forma a torná-lo, não apenas mais competitivo, mas mais próximo do que seria um jogador humano. Descreveu alguns critérios para alcançar objetivo e declara der obtido resultados promissores.

## 2.4 Sistemas Especialistas na EAD

Serão tratados a seguir uma série de tipos de sistemas de gestão de aprendizagem que se utilizam de técnicas de IA para especializar a experiência de aprendizagem promovendo tratamento personalizado ao estudante.

### 2.4.1 Sistemas de Tutores Inteligentes(STI)

A aplicação de técnicas de IA na educação deram vida a diversos sistemas especialistas como por exemplo os Sistemas Tutores Inteligentes (STI). Tratam-se de sistemas aptos a modelar as características do estudante durante a interação permitindo a flexibilização do comportamento do sistema em função das características modeladas (POZZEBON; FRIGO; BITTENCOURT, 2004). É caracterizado por um esforço maior na busca por instrumentos que venham minimizar a falta de um professor direcionando o ensino (MELO et al., 2017), entretanto, não há pretensões de se substituir o papel de professor, uma vez que ainda é o professor o responsável pela criação de conteúdo e organização do ensino (GONÇALVES, 2016).

O foco de um STI é de fornecer uma flexibilização didática frente ao perfil de cada estudante, de forma a melhorar a comunicação com o aluno (GONÇALVES, 2016). Para tal se faz necessária a implementação de agentes inteligentes de forma a ampliar as possibilidades de assegurar ao estudante assistência personalizada (BOLZAN; GIRAFFA, 2002).

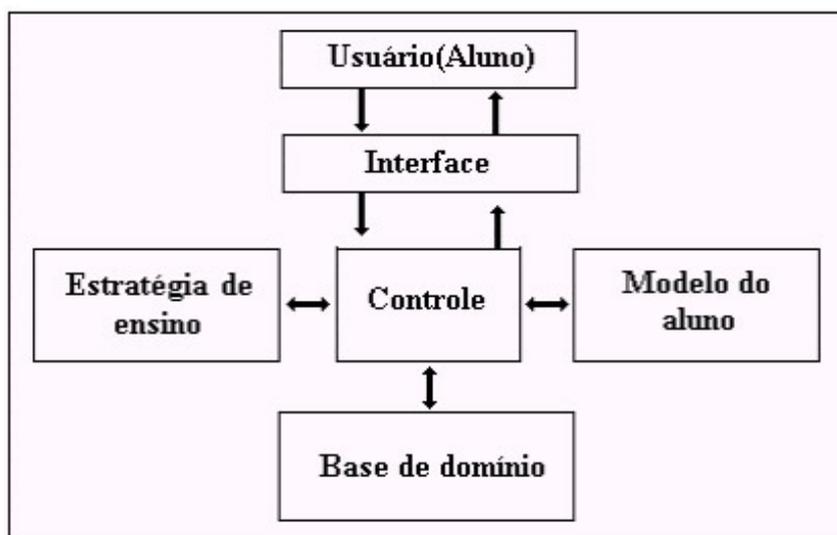
Agentes inteligentes são softwares aptos a assimilar informações e reagir diante delas, possuem comportamento autônomo sendo capazes de determinadas ações a fim de cumprir com seus objetivos (ZAMBONELLI et al., 2001). A forma como esses elementos se relacionam em um STI podem ser vista na Figura 9, onde, segundo COSTA (2002),

é possível conhecer os elementos que compõem um STI bem como a função de cada componente:

1. o Modelo Pedagógico: representado na Figura 9 como Estratégia de ensino, é responsável pela avaliação do conhecimento do aluno e escolha das estratégias de ensino que são mais apropriadas, determinando como a informação será exibida.
2. o Modelo do Especialista: ou Base de domínio, diz respeito à área de conhecimento daquele especialista, base esta, que servirá de apoio para construção do Modelo do Estudante.
3. o Modelo do Estudante(Modelo do aluno): ou Modelo do aluno refere-se a modelagem representativa dos conhecimentos inferidos acerca do estudante, a partir do mapeamento das informações assimiladas pelo sistema.
4. Interface

Os três módulos citados interagem de forma que, Modelo do Estudante em contato com Modelo do Especialista gera um diagnóstico de compatibilidade, estes resultados fornecem informações acerca da performance do aluno ao Modelo Pedagógico(COSTA, 2002).

Figura 9 – Estrutura básica de um Sistema Tutor Inteligente



Fonte: (COSTA, 2002)

Ainda acerca da Figura 9 o módulo de Interface é o responsável pela comunicação entre os atores envolvidos, é a partir da interface que o conteúdo adaptado é exibido ao

usuário. A interface é a suavização da complexidade do sistema aos olhos do usuário. O módulo de controle é o encarregado da coordenação geral do STI.

Destarte o exposto, importa ainda ressaltar algumas características que são consideradas desejáveis ou indispensáveis em um STI, as quais são enumeradas por [Viccari e Moussalle \(1990\)](#):

- oferecer elevados níveis de flexibilidade desde a arquitetura utilizada até à adaptação ao aluno;
- viabilizar a exploração de conteúdos instrucionais;
- possuir diversidade de metodologias de ensino;
- domínio do conteúdo;
- dispor de meios para detecção e correção de falhas;
- usar de simuladores para testes e verificações;
- possuir capacidade adaptativa em relação ao aluno;
- aptidão para reiniciar o procedimento se necessário.

Os Sistemas Tutoriais Inteligentes (STI) são sistemas especialistas para a Educação de essencial importância para a educação, em especial para a EAD, muitos de seus conceitos e premissas são recepcionados por outros sistemas especialistas que serão abordados adiante como os Sistemas Adaptativos e Inteligentes para a Educação(SAIE), mas antes disto serão tratados os Sistemas de Hiperídia Adaptativa (SHA), outro sistema especialista de fundamental importância para a EAD.

#### 2.4.2 Sistemas de Hiperídia Adaptativa(SHA)

Os Sistemas Hiperídia Adaptativos (SHA) visam oferecer a cada aluno uma interface de interação ajustada à suas características pessoais. Ocorre, portanto, uma seleção dinâmica de formas diversas de como o conteúdo poderá ser apresentado aos estudantes, sendo essa seleção pautada em função da modelagem do estudante ([PALAZZO, 2002](#))

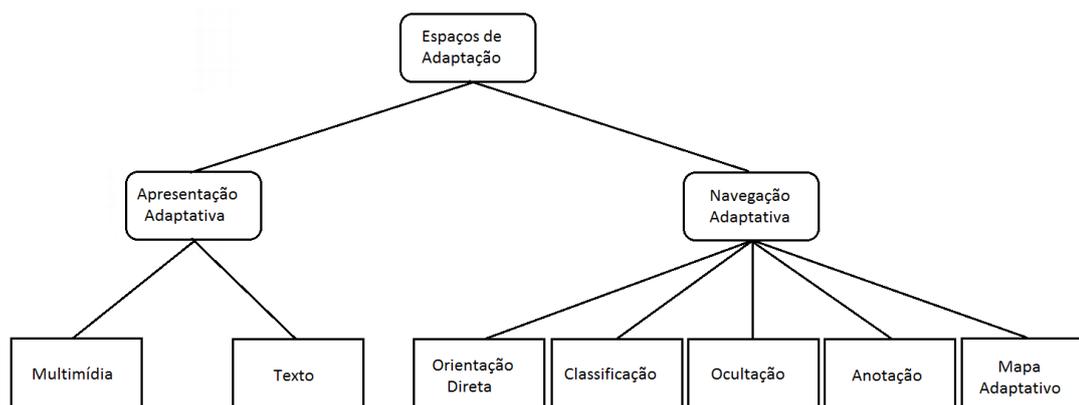
Muito embora possua essa característica adaptativa, o SHA não atua como um tutor, logo, não há nada a se esperar a respeito de estratégias pedagógicas ou mesmo algum tipo de auxílio didático ao aluno durante a interação ([COELHO,](#) ).

A finalidade a que se destina o SHA, reside na capacidade de disponibilização de conteúdo de maneira seletiva, permitindo a organização e exibição de informações orientadas

ao conhecimento, objetivo, *background*(experiência) e preferências do usuário (SILVEIRA et al., 2013 apud FALKEMBACH; TAROUCO, 2000). A partir dessas informações o sistema cria uma imagem residual do estudante modelando-o, passando a estar apto a lhe auxiliar durante a interação com o sistema.

A Figura 10 demonstra como o sistema pode auxiliar o estudante durante a interação, podendo ser uma adaptação da forma em como o conteúdo será exibido e/ou, através da adaptação da navegação, personalizando a usabilidade do sistema. Um exemplo de personalização da usabilidade pode ser verificada a partir da ocultação ou restrição ao ambiente de navegação, de forma a limitar a exibição de opções que podem ser consideradas inapropriadas naquele momento em função dos objetivos e níveis de conhecimento atuais (BRUSILOVSKY, 1998).

Figura 10 – Espaços de Adaptação em um SHA



Fonte: Adaptado a partir de Palazzo (2000)

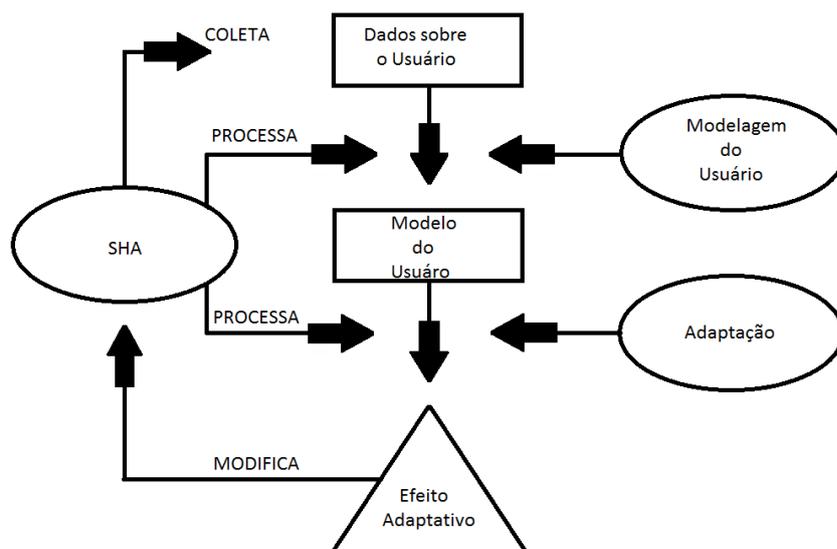
Os SHA buscam portanto, prever as necessidades dos estudantes a partir de modelos que lhe representam virtualmente, dessa forma, faz-se necessária a satisfação de 3 requisitos mínimos para o cumprimento desse propósito, estes são, segundo Zanchett e DALFOVO (2004), os requisitos que precisam ser satisfeitos:

1. ter como característica primordial ser um sistema hipertexto ou hipermissão;
2. ser apto a modelar o usuário;
3. ter capacidade de adaptatividade do conteúdo em função do usuário modelado.

O primeiro requisito diz respeito ao sistema ser, necessariamente, um sistema de hipertexto ou hipermissão. Hipermissão nesse contexto, pode ser definida como uma coleção de diversas mídias em um ambiente virtual suportada por TICs (LEÃO; HIPERMÍDIA,

1999). Já o Hipertexto consiste é um conjunto de elementos, chamados também de nós, interligados, esses elementos podem ser palavras, páginas, imagens, gráficos, documentos e outros. Não há uma ligação linear entre os elementos, muito pelo contrário, trata-se de uma estrutura de organização do conhecimento livre de qualquer formato fixo (LÉVY; COSTA, 1993).

Figura 11 – Fluxo de adaptação do SHA em função do Modelo do Estudante



Fonte: Adaptado a partir de Palazzo (2000)

O segundo e terceiro requisito possuem sua importância representada através da Figura 11, a qual demonstra o fluxo de interação entre os componentes de um SHA. Nota-se que o centro de um SHA é o modelo do estudante, o sucesso da adaptação reside na aptidão do SHA em conseguir modelar corretamente o estudante e na capacidade de de adaptar o sistema para atender aquele estudante modelado. Se um desses requisitos falhar todo o sistema estará comprometido.

### 2.4.3 Sistemas Adaptativos e Inteligentes para a Educação (SAIE)

Os sistemas Adaptativos e Inteligentes para a Educação (SAIE) são sistemas educacionais que buscam fornecer ao estudante atendimento personalizado, respeitando suas peculiaridades, derivando da integração de algumas ferramentas e tecnologias específicas dos STI e SHA (GONÇALVES, 2016).

A busca por customização no ensino, durante o processo de ensino/aprendizagem, passa pela adaptação das estratégias pedagógicas, escolhendo-se as que são mais apropriadas. Esta característica foi assimilada a partir dos STI. No que tange à gestão dos diversos objetos de aprendizagem, um SAIE busca oferecer uma navegação adaptativa, de forma a

auxiliar o usuário desde a usabilidade do sistema até ao formato adotado para apresentar o conteúdo, sendo esta, uma característica herdada dos SHA.

Assim como os STI e os SHA, os SAIE possuem requisitos que lhe são característicos, neste contexto Papanikolaou et al. (2002) elenca a característica dos SAIEs de trabalharem com um currículo sequencial de ensino, voltado para a resolução de problemas, assegurando ao usuário apresentação de conteúdo adaptada à suas necessidades e navegação assistida.

Neste trabalho será abordado o SAIE proposto por Dorça (2012), sendo a próxima seção destinada a tratar sua abordagem.

#### 2.4.3.1 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).

Assim como os STI e SHA, a etapa de modelagem do estudante é tarefa de fundamental importância para que sejam alcançados os objetivos propostos. Neste contexto, Dorça (2012) apresentou o seu ME, representado pela Figura 12.

Figura 12 – Modelo do Estudante

EA Probabilísticos							
Processamento		Percepção		Entrada		Organização	
Ativo	Reflexivo	Sensitivo	Intuitivo	Visual	Verbal	Sequencial	Global
0,7	0,3	0,34	0,66	0,28	0,72	0,85	0,15
Estado Cognitivo							
$EC = (C_0, 5) \dots (C_{n-1}, 5)$							
Objetivo de Aprendizagem							
$OA = (C_0, 5) \dots (C_{n-1}, 5)$							

Fonte: (DORÇA, 2012)

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 (BLOOM et al., 1956), versa sobre o nível de conhecimento do aluno em cada conceito a ser aprendido. Existem 6 Níveis Cognitivos (NC), representados pela Figura 13, 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, representados na Figura 14 como sendo: Criar, Avaliar, Analisar, Aplicar, Compreender e Recordar (WILSON, 2013

apud [SENA et al., 2016](#)). 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](#)).

Figura 13 – Classificação dos níveis cognitivos chamada Taxonomia de Bloom



Fonte: ([BLOOM et al., 1956](#) apud [FERRAZ; BELHOT et al., 2010](#))

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 EA<sub>p</sub> 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 *FSLSM*, para calcular o reforço. Então, aplica-se o reforço no EA<sub>p</sub>, atualizando-se as probabilidades de seleção das CEAs para a próxima interação ([DORÇA, 2012](#)).

Figura 14 – Comparação dos níveis cognitivos da Taxonomia de Bloom versão original e revisada



Fonte: ([WILSON, 2013](#) apud [SENA et al., 2016](#))

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 CEA com base no EAp. O passo 6 apresenta ao aluno o conceito selecionado de acordo com 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 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 CEA. A proposta 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. (2016), 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 ainda, 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 seções de aprendizagem. 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.

## 3 Abordagem Proposta

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

### 3.1 *Adapted Dynamic Scripting - ADS*

O ADS é composto por um conjunto de regras constituídas por uma (ou mais) condição, uma ação e um peso. As condições são construídas usando-se as variáveis nota obtida pelo estudante na etapa de avaliação e/ou a Distância do Estilo de Aprendizagem (DEA), podendo ser as duas variáveis ou apenas uma delas, dependendo do propósito de cada regra. As ações, consistem na aplicação de reforço positivo ou negativo no EAp contido no ME, podendo ser feito 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, onde são considerando seus pesos, de forma que, quanto maior o peso maior a chance da regra ser selecionada. Na ocasião da inicialização do sistemas, todas as 40 regras são inicializadas com peso = 2,5, ou seja, com a probabilidade de 2,5% de serem

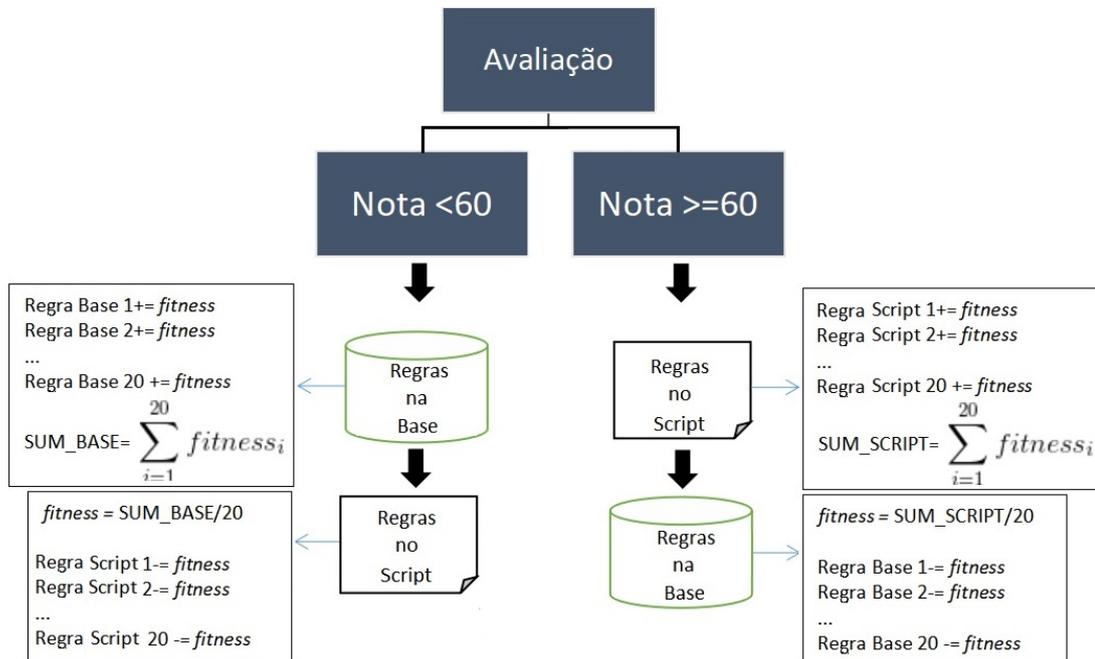
selecionadas para o *script*. O passo 2 consiste na realização da verificação se as condições das regras do *script* são satisfeitas. Para cada regra que tem sua condição satisfeita, a ação correspondente a ela é executada. O passo 3, por fim, atualiza os pesos de todas as 40 regras de acordo com a nota 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 3.1:

$$f(n, i) = \frac{1}{1000} * (n / \frac{Sc_i}{S_i}), \tag{3.1}$$

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 3.1 segue a seguinte lógica, representada pela Figura 15 e comentado na sequência:

Figura 15 – Demonstração da atualização dos pesos das regras



Fonte: Elaborado pelo autor

- Caso a nota obtida pelo estudante seja  $\geq 60$ , 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 de regras, 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 para o *script*). 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.

- Caso a nota obtida pelo estudante seja  $< 60$ , ocorre o contrário, sendo que os pesos das regras que ficaram na base de regras, isto é, que não foram selecionadas para o *script* serão atualizados positivamente de acordo com seus dados ( $Sc_i$  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 positivas 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).

## 3.2 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 FSLSM.

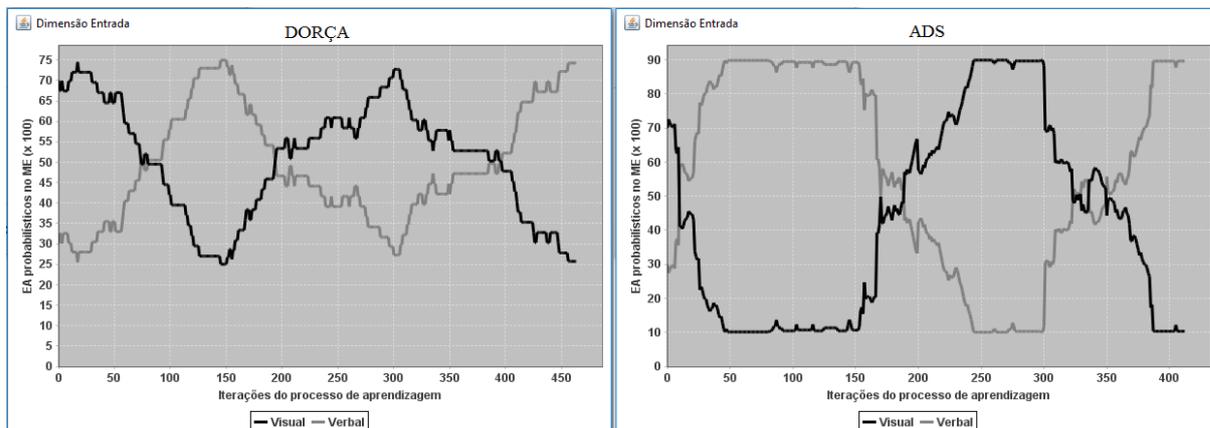
Os testes consistem em iniciar o sistema com um EAr inicial e, após algumas interações, realizar a mudança do EAr. Cada um dos 3 testes propostos foi com uma carga de conceitos diferentes, haja vista que, quanto menos conceitos forem colocados para o aluno aprender, menor será a quantidade de interações,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

A Figura 16 apresenta o primeiro teste, realizado com uma carga de 60 conceitos. Considerando-se os 6 níveis cognitivos da Taxonomia de Bloom, temos  $6 \times 60$ , 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 EAp 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.

O ADS, com  $\approx 50$  interações já convergia para o EAr inicial ao passo que a AR, muito embora convergindo corretamente, demorou  $\approx 100$  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. \(2016\)](#), [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 17 apresenta o segundo teste, realizado com 30 conceitos. Considerando-se

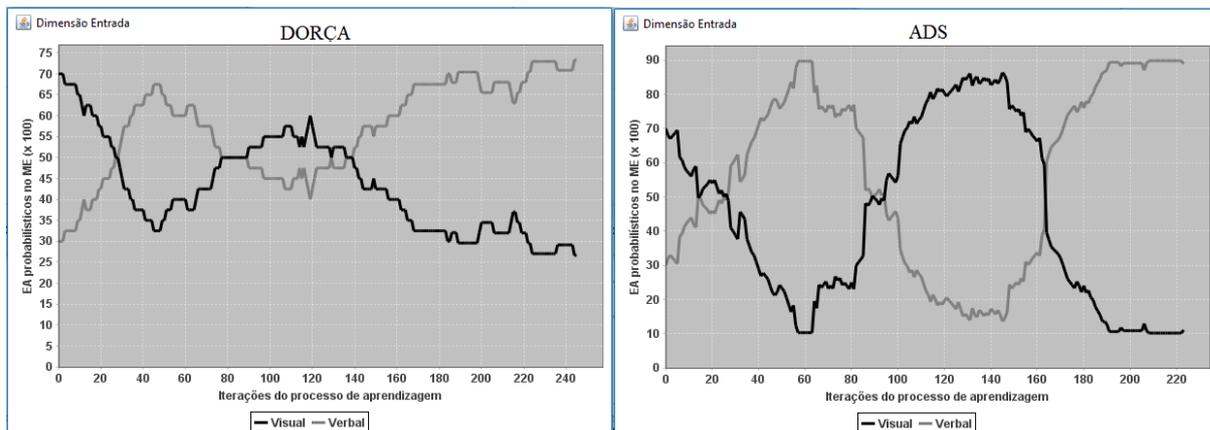
Figura 16 – Comparativo de conversão em interações entre as abordagens para uma dimensão do FLSM - 60 Conceitos



Fonte: Elaborado pelo autor

os 6 NC da Taxonomia de Bloom, temos  $6 \times 30$ , 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 17 – Comparativo de conversão em interações entre as abordagens para uma dimensão do FLSM - 30 Conceitos

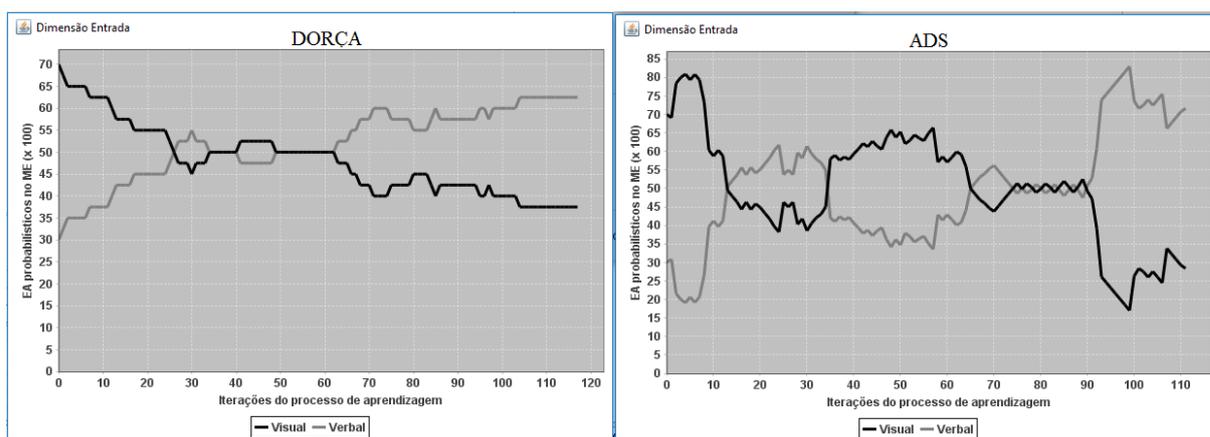


Fonte: Elaborado pelo autor

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  $\approx 20$  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 18, 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  $6 \times 15$ , 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.

Figura 18 – Comparativo de conversão em interações entre as abordagens para uma dimensão do FLSM - 15 Conceitos



Fonte: Elaborado pelo autor

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  $\approx 10$  interações a menos. Nota-se que a abordagem da literatura por  $\approx 30$  interações permaneceu ao centro da dimensão sem indicar o correto EA do aluno, gerando novamente mais PA.

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 Experimentos Computacionais

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 todos 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 proposta, 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 EAr Estáticos quanto para EAr Dinâmicos. Assim, para validar a proposta, foram realizados testes comparativos entre o ADS e a abordagem proposta por [Dorça \(2012\)](#) tanto para EAr Estáticos como para EAr Dinâmicos<sup>1</sup>. Objetiva-se demonstrar que o ADS, contribui para se elevar a produtividade do estudante a partir da personalização do ensino, sendo que os indicadores utilizados para demonstrar essa contribuição são a redução na quantidade de interações necessárias para se alcançar os objetivos de aprendizagem, redução na quantidade de PA encontrados durante o processo de ensino/aprendizagem e por fim 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

<sup>1</sup> Não foram comparadas as abordagens de [Falci et al. \(2016\)](#), [Gonçalves \(2016\)](#), [Rodrigues et al. \(2016\)](#), uma vez que tais abordagens são se propuseram a tratar cenários de EAr Dinâmicos

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.

São apresentados a média de interações, média de PAs e o desvio padrão, estes dados correspondem aos resultados obtidos em 30 testes para cada um dos 16 experimentos realizados.

A apresentação do desvio padrão tem a finalidade de demonstrar o quão estável é o sistema ao longo dos experimentos. Foram realizados 30 testes para cada CEA possível, sendo o sistema dinâmico, não era esperado que um teste repetido diversas vezes desse o mesmo resultado, contudo, uma variação muito grande entre os resultados demonstraria que o sistema não é estável. Dessa forma, comparou-se o Desvio Padrão obtido com a abordagem de [Dorça \(2012\)](#) com o ADS, para verificar se a oscilação dos resultados é aceitável.

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

## 4.2 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 proposta por [Dorça \(2012\)](#) e o ADS.

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

#### 4.2.1 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 contêm o símbolo %, correspondem à variação do ADS em relação à Dorça (2012).

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 EAp 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.

Considerando-se o número de interações, o ADS obteve uma redução de 5,76% 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 na quantidade de 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, demonstrando

Tabela 2 – Comparativo de Notas Médias para Experimentos Estáticos

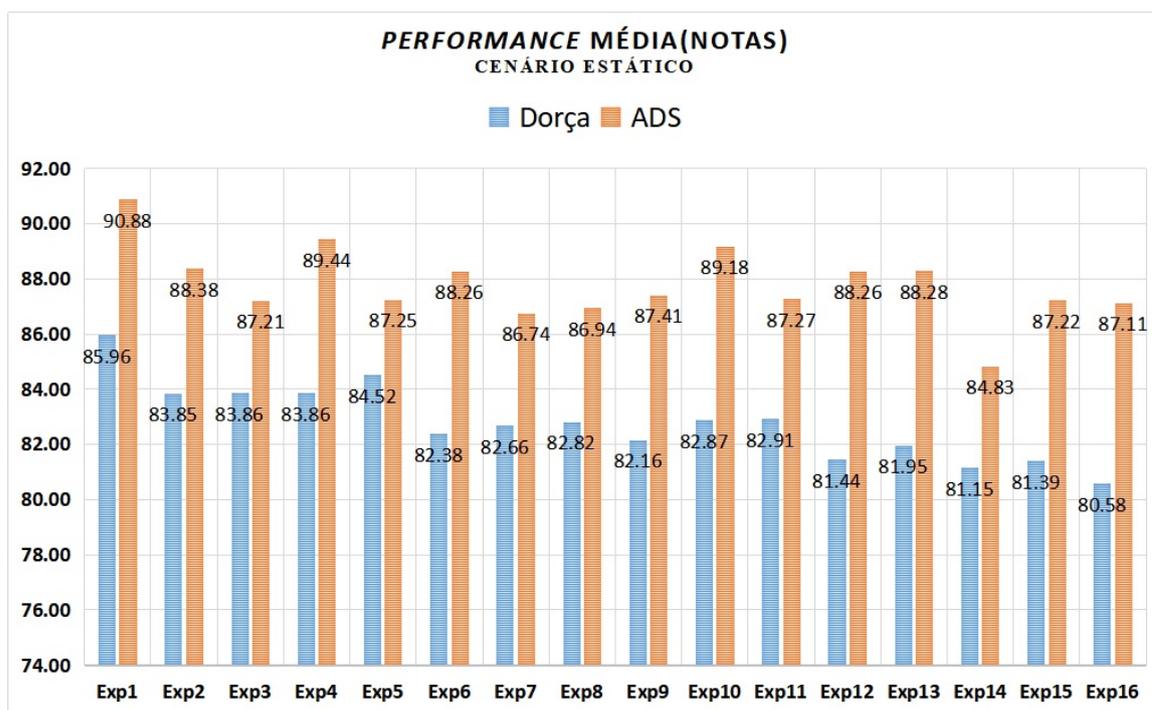
	Dorça	ADS	%
Exp1-A-S-VI-S	85.96	90.88	<b>5.72</b>
Exp2-R-S-VI-S	83.85	88.38	<b>5.40</b>
Exp3-A-I-VI-S	83.86	87.21	<b>3.99</b>
Exp4-A-S-VE-S	83.86	89.44	<b>6.66</b>
Exp5-A-S-VI-G	84.52	87.25	<b>3.24</b>
Exp6-R-I-VI-S	82.38	88.26	<b>7.14</b>
Exp7-A-I-VE-S	82.66	86.74	<b>4.94</b>
Exp8-A-S-VE-G	82.82	86.94	<b>4.98</b>
Exp9-R-S-VE-S	82.16	87.41	<b>6.39</b>
Exp10-R-S-VI-G	82.87	89.18	<b>7.62</b>
Exp11-A-I-VI-G	82.91	87.27	<b>5.26</b>
Exp12-R-I-VE-S	81.44	88.26	<b>8.38</b>
Exp13-A-I-VE-G	81.95	88.28	<b>7.73</b>
Exp14-R-I-VI-G	81.15	84.83	<b>4.53</b>
Exp15-R-S-VE-G	81.39	87.22	<b>7.16</b>
Exp16-R-I-VE-G	80.58	87.11	<b>8.10</b>
Média	<b>82.77</b>	<b>87.79</b>	<b>6.06</b>

portanto, uma baixa oscilação.

No que tange à nota média obtida nos experimentos com EAr Estáticos com carga de 60 conceitos, a Figura 19 e a Tabela 2 apresentam dados comparativos contendo os 16 Experimentos para cada abordagem.

Pode-se verificar que 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.

Figura 19 – Comparação entre as abordagens no que tange à Média das Notas obtidas em cenários com EAr Estático



Fonte: Elaborado pelo autor

Tabela 3 – 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	<b>-5.94</b>	14.77	3.20	<b>-78.33</b>	3.76	3.99	<b>6.12</b>
Exp2-R-S-VI-S	203.07	191.27	<b>-5.81</b>	23.07	11.27	<b>-51.16</b>	3.25	3.24	<b>-0.33</b>
Exp3-A-I-VI-S	201.30	193.73	<b>-3.76</b>	21.30	13.73	<b>-35.52</b>	3.70	3.23	<b>-12.68</b>
Exp4-A-S-VE-S	202.50	193.43	<b>-4.48</b>	22.50	13.43	<b>-40.30</b>	3.76	4.17	<b>10.87</b>
Exp5-A-S-VI-G	200.43	190.17	<b>-5.12</b>	20.43	10.17	<b>-50.24</b>	4.03	2.94	<b>-27.15</b>
Exp6-R-I-VI-S	208.67	194.57	<b>-6.76</b>	28.67	14.57	<b>-49.19</b>	3.58	5.00	<b>39.89</b>
Exp7-A-I-VE-S	209.50	192.77	<b>-7.99</b>	29.50	12.77	<b>-56.72</b>	4.26	4.78	<b>12.35</b>
Exp8-A-S-VE-G	209.03	194.87	<b>-6.78</b>	29.03	14.87	<b>-48.79</b>	3.78	4.51	<b>19.19</b>
Exp9-R-S-VE-S	211.57	191.47	<b>-9.50</b>	31.57	11.47	<b>-63.67</b>	5.08	3.62	<b>-28.84</b>
Exp10-R-S-VI-G	207.80	213.37	<b>2.68</b>	27.80	33.37	<b>20.02</b>	4.69	15.60	<b>232.80</b>
Exp11-A-I-VI-G	206.70	201.30	<b>-2.61</b>	26.70	21.30	<b>-20.22</b>	4.28	5.57	<b>29.91</b>
Exp12-R-I-VE-S	216.47	194.80	<b>-10.01</b>	36.47	14.80	<b>-59.41</b>	4.85	5.00	<b>2.98</b>
Exp13-A-I-VE-G	217.43	193.00	<b>-11.24</b>	37.43	13.00	<b>-65.27</b>	3.94	5.07	<b>28.85</b>
Exp14-R-I-VI-G	214.90	195.53	<b>-9.01</b>	34.90	15.53	<b>-55.49</b>	5.34	4.37	<b>-18.18</b>
Exp15-R-S-VE-G	215.03	207.47	<b>-3.52</b>	35.03	27.47	<b>-21.60</b>	4.41	11.57	<b>162.11</b>
Exp16-R-I-VE-G	221.50	201.67	<b>-8.95</b>	41.50	21.67	<b>-47.79</b>	4.22	10.87	<b>157.75</b>
Média	<b>208.79</b>	<b>195.79</b>	<b>-6.17</b>	<b>28.79</b>	<b>15.79</b>	<b>-45.23</b>	<b>4.18</b>	<b>5.84</b>	<b>38.48</b>

A tabela 3 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). Como citado nos experimentos anteriores, o EAp inicial neste teste, é igual ao EAr.

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

No que tange ao número de interações, a Tabela 3 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 (BLOOM et al., 1956)). 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 4 apresenta os resultados obtidos nos testes considerando EAr Estáticos com carga de 15 conceitos. Assim como nos testes anteriores, a coluna que contém o 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

Tabela 4 – 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	<b>-5.72</b>	8.53	2.90	<b>-66.02</b>	2.93	1.77	<b>-39.70</b>
Exp2-R-S-VI-S	103.43	96.40	<b>-6.80</b>	13.43	6.40	<b>-52.36</b>	3.21	2.76	<b>-14.04</b>
Exp3-A-I-VI-S	104.07	97.73	<b>-6.09</b>	14.07	7.73	<b>-45.02</b>	3.39	2.52	<b>-25.79</b>
Exp4-A-S-VE-S	103.83	97.43	<b>-6.16</b>	13.83	7.43	<b>-46.27</b>	3.23	2.97	<b>-8.07</b>
Exp5-A-S-VI-G	103.23	96.00	<b>-7.01</b>	13.23	6.00	<b>-54.66</b>	3.19	2.42	<b>-24.13</b>
Exp6-R-I-VI-S	109.63	103.33	<b>-5.75</b>	19.63	13.33	<b>-32.09</b>	3.99	3.10	<b>-22.25</b>
Exp7-A-I-VE-S	109.07	101.60	<b>-6.85</b>	19.07	11.60	<b>-39.16</b>	3.24	2.84	<b>-12.40</b>
Exp8-A-S-VE-G	107.90	103.93	<b>-3.68</b>	17.90	13.93	<b>-22.16</b>	3.25	4.09	<b>25.86</b>
Exp9-R-S-VE-S	109.77	104.23	<b>-5.04</b>	19.77	14.23	<b>-27.99</b>	3.53	5.46	<b>54.57</b>
Exp10-R-S-VI-G	107.93	98.80	<b>-8.46</b>	17.93	8.80	<b>-50.93</b>	3.75	2.57	<b>-31.60</b>
Exp11-A-I-VI-G	107.83	99.73	<b>-7.51</b>	17.83	9.73	<b>-45.42</b>	3.22	3.32	<b>3.23</b>
Exp12-R-I-VE-S	115.73	100.93	<b>-12.79</b>	25.73	10.93	<b>-57.51</b>	3.98	3.88	<b>-2.64</b>
Exp13-A-I-VE-G	114.33	120.63	<b>5.51</b>	24.33	30.63	<b>25.89</b>	4.48	10.78	<b>140.53</b>
Exp14-R-I-VI-G	111.40	105.80	<b>-5.03</b>	21.40	15.80	<b>-26.17</b>	3.47	5.19	<b>49.53</b>
Exp15-R-S-VE-G	112.77	106.70	<b>-5.38</b>	22.77	16.70	<b>-26.65</b>	3.98	5.50	<b>38.27</b>
Exp16-R-I-VE-G	119.33	110.40	<b>-7.49</b>	29.33	20.40	<b>-30.45</b>	3.67	7.30	<b>99.01</b>
Média	<b>108.68</b>	<b>102.29</b>	<b>-5.89</b>	<b>18.68</b>	<b>12.29</b>	<b>-37.31</b>	<b>3.53</b>	<b>4.15</b>	<b>14.40</b>

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 FSLSM 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.

A Tabela 4 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.

#### 4.2.2 EAr Dinâmicos

A tabela 5 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),

Tabela 5 – 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	<b>-6.02</b>	58.21	33.03	<b>-43.26</b>	8.09	4.5	<b>-44.38</b>
Exp2-R-S-VI-S	426.62	404.07	<b>-5.29</b>	66.62	44.07	<b>-33.85</b>	6.4	7.76	<b>21.25</b>
Exp3-A-I-VI-S	428.79	412.14	<b>-3.88</b>	68.79	52.14	<b>-24.2</b>	7.84	8.2	<b>4.59</b>
Exp4-A-S-VE-S	424.86	406.96	<b>-4.21</b>	64.86	46.96	<b>-27.6</b>	7.71	8.01	<b>3.89</b>
Exp5-A-S-VI-G	423.52	397.46	<b>-6.15</b>	63.52	37.46	<b>-41.03</b>	7.83	6.93	<b>-11.49</b>
Exp6-R-I-VI-S	433.83	404	<b>-6.88</b>	73.83	44	<b>-40.4</b>	7.24	8.77	<b>21.13</b>
Exp7-A-I-VE-S	433.55	417.25	<b>-3.76</b>	73.55	57.25	<b>-22.16</b>	6.24	7.55	<b>20.99</b>
Exp8-A-S-VE-G	428.14	396.54	<b>-7.38</b>	68.14	36.54	<b>-46.38</b>	7.98	6.34	<b>-20.55</b>
Exp9-R-S-VE-S	431.64	422.29	<b>-2.17</b>	71.64	62.29	<b>-13.05</b>	8.16	8.23	<b>0.86</b>
Exp10-R-S-VI-G	431.04	397.75	<b>-7.72</b>	71.04	37.75	<b>-46.86</b>	7.06	4.49	<b>-36.4</b>
Exp11-A-I-VI-G	430.35	402.5	<b>-6.47</b>	70.35	42.5	<b>-39.59</b>	6.6	8.17	<b>23.79</b>
Exp12-R-I-VE-S	440.58	421.86	<b>-4.25</b>	80.58	61.86	<b>-23.23</b>	4.57	9.78	<b>114</b>
Exp13-A-I-VE-G	434.04	397.78	<b>-8.35</b>	74.04	37.78	<b>-48.97</b>	7.49	7.34	<b>-2</b>
Exp14-R-I-VI-G	435.3	406.19	<b>-6.69</b>	75.3	46.19	<b>-38.66</b>	6.3	7.69	<b>22.06</b>
Exp15-R-S-VE-G	437.77	402.11	<b>-8.15</b>	77.77	42.11	<b>-45.85</b>	6.36	6.91	<b>8.65</b>
Exp16-R-I-VE-G	443.65	411.62	<b>-7.22</b>	83.65	51.62	<b>-38.29</b>	6.82	5.93	<b>-13.05</b>
Média	<b>431.37</b>	<b>405.85</b>	<b>-5.91</b>	<b>71.37</b>	<b>45.85</b>	<b>-35.84</b>	<b>7.04</b>	<b>7.29</b>	<b>7.08</b>

Tabela 6 – Comparativo de Notas Médias para Experimentos Dinâmicos

	Dorça	ADS	%
Exp1-A-S-VI-S	79.55	83.39	<b>4.82</b>
Exp2-R-S-VI-S	79.72	85.12	<b>6.78</b>
Exp3-A-I-VI-S	79.92	84.41	<b>5.62</b>
Exp4-A-S-VE-S	79.35	85.05	<b>7.18</b>
Exp5-A-S-VI-G	79.50	83.26	<b>4.74</b>
Exp6-R-I-VI-S	80.00	83.85	<b>4.82</b>
Exp7-A-I-VE-S	79.66	79.50	<b>-0.20</b>
Exp8-A-S-VE-G	78.97	82.70	<b>4.72</b>
Exp9-R-S-VE-S	79.45	83.34	<b>4.89</b>
Exp10-R-S-VI-G	79.53	82.91	<b>4.26</b>
Exp11-A-I-VI-G	79.61	84.75	<b>6.46</b>
Exp12-R-I-VE-S	79.47	83.17	<b>4.66</b>
Exp13-A-I-VE-G	79.44	82.96	<b>4.44</b>
Exp14-R-I-VI-G	79.72	81.76	<b>2.55</b>
Exp15-R-S-VE-G	79.05	82.69	<b>4.60</b>
Exp16-R-I-VE-G	79.36	82.92	<b>4.48</b>
Média	<b>79.52</b>	<b>83.24</b>	<b>4.68</b>

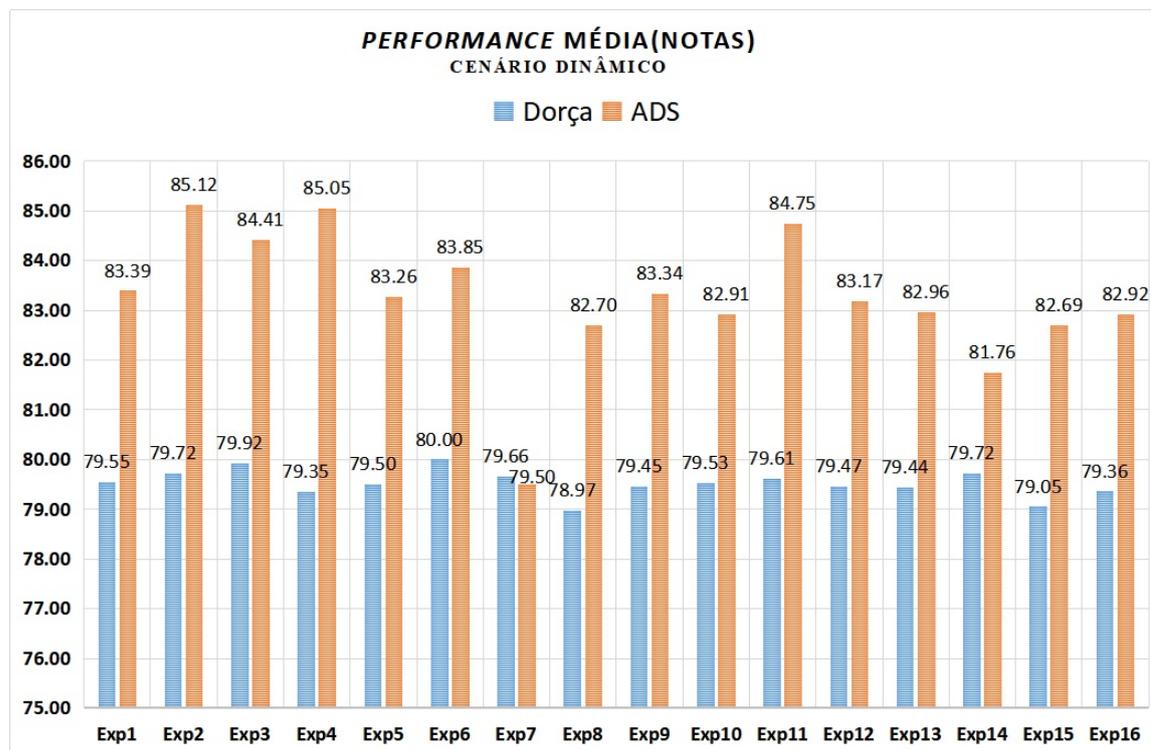
haja visto que, como apontado anteriormente, uma interação, em casos reais, demanda tempo considerável.

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, apresentada na Figura 20 com um gráfico comparativo entre os 16 Experimentos de cada abordagem. Novamente o ADS elevou a nota média dos estudantes em comparação à abordagem da literatura, mesmo em cenário adverso com oscilação do EAr do estudante a abordagem proposta se manteve capaz de permitir a maximização do desempenho do estudante.

A tabela 7 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.

Figura 20 – Comparação entre as abordagens no que tange à Média das Notas obtidas em cenários com EAr Dinâmico



Fonte: Elaborado pelo autor

Tabela 7 – 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

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

Tabela 8 – 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	<b>-6.00</b>	24.37	17.50	<b>-28.18</b>	5.32	3.66	<b>-31.30</b>
Exp2-R-S-VI-S	115.77	113.60	<b>-1.87</b>	25.77	23.60	<b>-8.41</b>	4.91	4.50	<b>-8.37</b>
Exp3-A-I-VI-S	116.30	107.90	<b>-7.22</b>	26.30	17.90	<b>-31.94</b>	4.84	4.69	<b>-3.26</b>
Exp4-A-S-VE-S	112.10	102.00	<b>-9.01</b>	22.10	12.00	<b>-45.70</b>	6.02	4.57	<b>-24.13</b>
Exp5-A-S-VI-G	111.90	99.27	<b>-11.29</b>	21.90	9.27	<b>-57.69</b>	4.44	3.73	<b>-15.88</b>
Exp6-R-I-VI-S	111.83	114.60	<b>2.47</b>	21.83	24.60	<b>12.67</b>	4.30	5.75	<b>33.75</b>
Exp7-A-I-VE-S	116.80	107.47	<b>-7.99</b>	26.80	17.47	<b>-34.83</b>	5.60	5.35	<b>-4.57</b>
Exp8-A-S-VE-G	115.90	102.23	<b>-11.79</b>	25.90	12.23	<b>-52.77</b>	4.45	3.83	<b>-13.97</b>
Exp9-R-S-VE-S	113.93	102.00	<b>-10.47</b>	23.93	12.00	<b>-49.86</b>	5.43	4.53	<b>-16.45</b>
Exp10-R-S-VI-G	114.03	112.03	<b>-1.75</b>	24.03	22.03	<b>-8.32</b>	5.67	5.74	<b>1.28</b>
Exp11-A-I-VI-G	116.47	113.53	<b>-2.52</b>	26.47	23.53	<b>-11.08</b>	4.52	4.45	<b>-1.36</b>
Exp12-R-I-VE-S	114.90	119.33	<b>3.86</b>	24.90	29.33	<b>17.80</b>	4.04	6.06	<b>50.22</b>
Exp13-A-I-VE-G	113.20	108.60	<b>-4.06</b>	23.20	18.60	<b>-19.83</b>	4.54	5.78	<b>27.44</b>
Exp14-R-I-VI-G	116.80	113.73	<b>-2.63</b>	26.80	23.73	<b>-11.44</b>	4.57	6.19	<b>35.36</b>
Exp15-R-S-VE-G	114.03	108.33	<b>-5.00</b>	24.03	18.33	<b>-23.72</b>	4.11	5.58	<b>35.87</b>
Exp16-R-I-VE-G	116.07	112.97	<b>-2.67</b>	26.07	22.97	<b>-11.89</b>	6.25	5.10	<b>-18.40</b>
Media	<b>114.65</b>	<b>109.07</b>	<b>-4.87</b>	<b>24.65</b>	<b>19.07</b>	<b>-22.82</b>	<b>4.94</b>	<b>4.97</b>	2.89

literatura situou-se na marca de 6.20, ADS variando em 7.13%.

Por fim, a tabela 8 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%.

## 5 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 proposta de fornecimento de adaptatividade, portanto, pesquisou-se novas técnicas que pudessem oferecer um ganho nessa funcionalidade do sistema.

Assim sendo, esta pesquisa propôs uma modificação no SAIE proposto por [Dorça \(2012\)](#) com o objetivo de aumentar a velocidade de convergência do sistema. Propôs-se, substituir a técnica de IA Aprendizagem por Reforço, por *Dynamic Scripting*, técnica popular na área de jogos digitais que se mostrou compatível com o problema.

Os resultados experimentais encontrados apontaram para uma redução na quantidade de interações bem como no número de Problemas de Aprendizagem em comparação a trabalhos da literatura. A redução nas interações e Problemas de Aprendizagem foram possíveis nos dois cenários abordados, tanto com EAr Estático como EAr Dinâmico. A redução nesses indicadores foi possível pela substituição da técnica de aprendizagem de máquina utilizada. O *Adapted Dynamic Scripting*, por utilizar uma técnica de aprendizado *online* proporcionou uma convergência mais otimizada do sistema, proporcionando uma redução nas interações e nos problemas de aprendizagem e, aumentando a *performance* dos alunos, medida através das notas.

Através dos resultados obtidos 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 a proposta apresentada se mostrou promissora 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 aprendi-

zagem reais, de forma a determinar, do ponto de vista prático, a viabilidade da proposta.

# Referências

- ABED, A. B. d. E. a. D. Censo ead.br: Relatório analítico da aprendizagem a distância no Brasil 2015/2016. *InterSaberes*, Curitiba, 2016. Citado 3 vezes nas páginas 15, 20 e 29.
- ADÁN-COELLO, J. M. et al. 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*, v. 16, n. 03, 2008. Citado na página 16.
- AHMAD, N.; TASIR, Z. Threshold Value in Automatic Learning Style Detection. *Procedia - Social and Behavioral Sciences*, Elsevier B.V., v. 97, p. 346–352, 2013. ISSN 18770428. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1877042813036896>>. Citado na página 16.
- ALMEIDA, K. R. d. Descrição e análise de diferentes estilos de aprendizagem. *Revista Interlocução*, v. 3, n. 3, 2010. Citado na página 32.
- ALMEIDA, M. G. d.; COSTA, G. M. T. da. Pedagogia empresarial. *Saberes, Práticas e Referências*. Rio de Janeiro. *Brásport*, v. 4, n. 1, 2006. Citado na página 20.
- ALONSO, C. M.; GALLEGO, D. J.; HONEY, P. *Los estilos de aprendizaje: procedimientos de diagnósticos y mejora*. [S.l.]: Mensajero, 1997. Citado na página 30.
- ALVES, L.; BARROS, D. M. V.; OKADA, A. *Moodle: estratégias pedagógicas e estudos de caso*. [S.l.]: Universidade do Estado da Bahia, 2009. Citado na página 28.
- ANDRADE, G. et al. Extending reinforcement learning to provide dynamic game balancing. In: *Proceedings of the Workshop on Reasoning, Representation, and Learning in Computer Games, 19th International Joint Conference on Artificial Intelligence (IJCAI)*. [S.l.: s.n.], 2005. p. 7–12. Citado na página 38.
- ANJOS, I. Ciberespaço: educação em um novo plano de realidade. In: *Congresso de la cibernsiedad-Crisis analógica, futuro digital*. [S.l.: s.n.], 2009. Citado na página 24.
- ARMSTRONG, W. et al. Dynamic algorithm selection using reinforcement learning. In: *IEEE. Integrating AI and Data Mining, 2006. AIDM'06. International Workshop on*. [S.l.], 2006. p. 18–25. Citado na página 40.
- AYUB, A. d. O. S.; CARVALHO, D. S.; TEIXEIRA, Í. H. Objetos de aprendizagem. 2009. Citado na página 28.
- BADIN, E.; BORDIGNON, M.; AGOSTI, C. Inteligência artificial aplicada ao ensino de expressões algébricas: sistema tutor inteligente pat2math. *Unoesc & Ciência-ACET*, v. 8, n. 1, p. 61–68, 2017. Citado na página 15.
- BARBOSA, A. T. R. Mecanismo de adaptação baseado em redes neurais artificiais para sistemas hipermedia adaptativos. p. 123, 2004. Citado 2 vezes nas páginas 15 e 25.
- BARRETO, J. M. Introdução ao as redes neurais artificiais. *V Escola Regional de Informática. Sociedade Brasileira de Computação, Regional Sul, Santa Maria, Florianópolis, Maringá*, p. 5–10, 2002. Citado na página 37.

- BARROS, D. M. V. *Guia didático sobre tecnologias da comunicação e informação para o trabalho educativo na formação docente*. [S.l.]: Vieira e Lent, 2009. Citado na página 15.
- BERINGS, M. G.; POELL, R. F.; SIMONS, P. R.-J. Conceptualizing on-the-job learning styles. *Human Resource Development Review*, Sage Publications Sage CA: Thousand Oaks, CA, v. 4, n. 4, p. 373–400, 2005. Citado na página 30.
- BERNERS-LEE, T.; FISCHETTI, M.; BY-DERTOUZOS, M. L. F. *Weaving the Web: The original design and ultimate destiny of the World Wide Web by its inventor*. [S.l.]: HarperInformation, 2000. Citado na página 23.
- BITTENCOURT, D. d. Estratégia e tomada de decisões para educação a distância. *Universidade Nacional Autónoma do México (UNAM). Trad. Unisul Virtual. Tubarão: Unisul*, 2003. Citado na página 23.
- BITTENCOURT, I. I.; COSTA, E. Modelos e ferramentas para a construção de sistemas educacionais adaptativos e semânticos. *Brazilian Journal of Computers in Education*, v. 19, n. 01, p. 85, 2011. Citado na página 25.
- BLOOM, B. S. et al. Taxonomy of educational objectives. new york: David mckay co. Inc., 1956, 1956. Citado 4 vezes nas páginas 48, 49, 60 e 62.
- BOLZAN, W.; GIRAFFA, L. M. Estudo comparativo sobre sistemas tutores inteligentes multiagentes web. *Porto Alegre: FACIN-PUCRS*, 2002. Citado na página 43.
- BOSCHETTI, V. R.; OLIVEIRA, L. C. de. O início do ensino de tecnologia no estado de são paulo. *South American Development Society Journal*, v. 1, n. 3, p. 01–13, 2017. Citado na página 20.
- BRANDÃO, M. Cursos superiores de tecnologia: democratização do acesso ao ensino superior. *Trabalho Necessário. Ano*, v. 5, p. 1–15, 2006. Citado na página 20.
- BRUSILOVSKY, P. Methods and techniques of adaptive hypermedia. In: *Adaptive hypertext and hypermedia*. [S.l.]: Springer, 1998. p. 1–43. Citado na página 46.
- CABADA, R. Z. et al. A fuzzy-neural network for classifying learning styles in a web 2.0 and mobile learning environment. *2009 Latin American Web Congress - Joint LA-WEB/CLIHC Conference*, p. 177–182, 2009. Citado na página 37.
- CASTAÑÓN, G. A. *O que é cognitivismo: fundamentos filosóficos*. [S.l.]: EPU, 2007. Citado na página 16.
- CASTILLO, G.; GAMA, J.; BRENDA, A. M. An adaptive predictive model for student modeling. *Advances in Web-based education: Personalized learning environments*, v. 7092, 2005. Citado na página 18.
- CERQUEIRA, T. C. S. *Estilos de aprendizagem em universitários*. 155 p. Tese (Doutorado), 2000. Citado 4 vezes nas páginas 18, 30, 32 e 51.
- COELHO, L. M. N.-F. Sistemas tutores inteligentes aplicados em sistemas hipermídia adaptativas. Citado na página 45.
- COMASSETTO, L. S. et al. Novos espaços virtuais para o ensino e a aprendizagem a distância: estudo da aplicabilidade dos desenhos pedagógicos. Florianópolis, SC, 2006. Citado na página 28.

CORMODE, G.; KRISHNAMURTHY, B. Key differences between web 1.0 and web 2.0. *First Monday*, v. 13, n. 6, 2008. Citado na página 24.

COSTA, E. V. G. d. et al. Adestramento e bem-estar de cães policiais: um estudo de caso. Universidade Federal da Paraíba, 2016. Citado na página 38.

COSTA, M. Sistemas tutores inteligentes. *Universidade Federal do Rio de Janeiro–Núcleo de Computação Eletrônica–Trabalho de Conclusão*, 2002. Citado 2 vezes nas páginas 43 e 44.

CROCKETT, K. et al. A fuzzy model for predicting learning styles using behavioral cues in an conversational intelligent tutoring system. *IEEE International Conference on Fuzzy Systems*, 2013. ISSN 10987584. Citado 2 vezes nas páginas 16 e 38.

DAGEZ, H. E.; BABA, M. S. Applying neural network technology in qualitative research for extracting learning style to improve E-learning environment. *Proceedings - International Symposium on Information Technology 2008, ITSIm*, v. 1, p. 4–9, 2008. Citado na página 16.

DAHLBOM, A.; NIKLASSON, L. Goal-directed hierarchical dynamic scripting for rts games. In: *AIIDE*. [S.l.: s.n.], 2006. p. 21–28. Citado na página 42.

DAZZI, R. L. S.; AZEVEDO, F. M. de; FERNANDES, A. P. S. Sti com adaptação de interface e estratégias pedagógicas. *RENOTE*, v. 6, n. 2. Citado na página 25.

DORÇA, F. A. *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*. 207 p. Tese (Doutorado), 2012. Citado 27 vezes nas páginas 13, 16, 17, 18, 19, 21, 22, 31, 34, 35, 39, 48, 49, 51, 52, 54, 55, 58, 59, 60, 62, 63, 64, 65, 66, 67 e 79.

DORÇA, F. A.; LIMA et al. Comparing strategies for modeling students learning styles through reinforcement learning in adaptive and intelligent educational systems: An experimental analysis. *Expert Systems with Applications*, Elsevier, v. 40, n. 6, p. 2092–2101, 2013. Citado 3 vezes nas páginas 17, 18 e 31.

DORÇA, F. A. et al. Detecção e Correção Automática de Estilos de Aprendizagem em Sistemas Adaptativos para Educação. *Revista de Informática Teórica e Aplicada*, v. 18, p. 178–204, 2011. ISSN 21752745. Citado 2 vezes nas páginas 16 e 17.

DOUGIAMAS, M.; TAYLOR, P. Moodle: Using learning communities to create an open source course management system. 2003. Citado na página 28.

DUNN, R. S.; DUNN, K. J.; PRICE, G. E. *Learning style inventory*. [S.l.]: Price Systems New York, Lawrence, KS, 1981. Citado na página 29.

FALCI, S. H. et al. Uma Nova Abordagem para Aplicação de Reforço em Sistemas Automáticos e Adaptativos de Detecção de Estilos de Aprendizagem. *ReABTIC*, v. 1, n. 6, 2016. ISSN 2446-7634. Disponível em: <<http://revistas.setrem.com.br/index.php/reabtic/article/view/200>>. Citado 5 vezes nas páginas 17, 31, 50, 55 e 58.

FALKEMBACH, G. A.; TAROUCO, L. M. Hipermídia adaptativa: um recurso para a adequação de ambientes e aprendizagem ao perfil do aprendiz. canoas: Ulbra, 2000. *Revista Acta Scientiae*, v. 2, n. 1/2, p. 67–75, 2000. Citado na página 46.

- FARIAS, D. L. d. Avaliação de aprendizagem de agentes baseados em sistemas classificadores para jogos digitais. Universidade Federal de Pernambuco, 2014. Citado 3 vezes nas páginas 21, 38 e 40.
- FELDER, R. M.; SILVERMAN, L. K. Learning and teaching styles in engineering education. *Engineering education*, v. 78, n. 7, p. 674–681, 1988. Citado 7 vezes nas páginas 16, 17, 30, 31, 33, 34 e 35.
- FELDER, R. M.; SOLOMAN, B. A. et al. *Index of learning styles*. 1991. Citado na página 35.
- FELDER, R. M.; SPURLIN, J. Applications, reliability and validity of the index of learning styles. *International journal of engineering education*, v. 21, n. 1, p. 103–112, 2005. Citado 2 vezes nas páginas 17 e 35.
- FERRAZ, A.; BELHOT, R. V. et al. Taxonomia de bloom: revisão teórica e apresentação das adequações do instrumento para definição de objetivos instrucionais. *Gest. Prod., São Carlos*, SciELO Brasil, v. 17, n. 2, p. 421–431, 2010. Citado na página 49.
- GALAFASSI, F. P.; GLUZ, J. C.; GALAFASSI, C. Análise crítica das pesquisas recentes sobre as tecnologias de objetos de aprendizagem e ambientes virtuais de aprendizagem. *Revista Brasileira de Informática na Educação*, v. 21, n. 3, p. 41–52, 2013. Citado na página 15.
- GALLEGO, D. J. Estilos de aprender en el siglo XXI. v. 1, p. 23–34, 2008. Citado na página 16.
- GOMES, M. J. Na senda da inovação tecnológica na educação a distância. Faculdade de Psicologia e Ciências da Educação da Universidade de Coimbra, 2008. Citado na página 24.
- GOMES, N. M. C.; UNGLAUB, E.; COSTA, F. P. da S. As tecnologias da informação e comunicação: desafios para o professor universitário. *Acta Científica. Ciências Humanas*, v. 25, n. 1, 2017. Citado na página 26.
- GONÇALVES, A. V. Modelagem Automática e Dinâmica de Estilos de Aprendizagem em Sistemas Adaptativos e Inteligentes para Educação a Distância: Estudo Comparativo entre Duas Abordagens. n. 1, p. 121, 2016. ISSN 0717-6163. Citado 8 vezes nas páginas 17, 28, 31, 43, 47, 50, 55 e 58.
- GRAF, S. et al. Advanced adaptivity in learning management systems by considering learning styles. In: IEEE COMPUTER SOCIETY. *Proceedings of the 2009 IEEE/WIC/ACM International Joint Conference on Web Intelligence and Intelligent Agent Technology-Volume 03*. [S.l.], 2009. p. 235–238. Citado na página 18.
- GUELPELI, M. V.; RIBEIRO, C. H.; OMAR, N. Utilização de aprendizagem por reforço para modelagem autônoma do aprendiz em um tutor inteligente. In: *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)*. [S.l.: s.n.], 2003. v. 1, n. 1, p. 465–474. Citado 2 vezes nas páginas 36 e 39.
- HAIDER. An Investigation of relationship between learning styles and performance of learners. *International Journal of Engineering Science and Technology*, v. 2, n. 7, 2010. Citado 2 vezes nas páginas 16 e 50.

- HOOD, B. et al. No evidence to back idea of learning styles. *The Guardian*, n. March, 2017. Disponível em: <<https://www.theguardian.com/education/2017/mar/12/no-evidence-to-back-idea-of-learning-styles>>. Citado 3 vezes nas páginas 16, 29 e 31.
- INEP, R. C. d. E. S. Instituto nacional de estudos e pesquisas educacionais anísio teixeira. *Acesso em 23 ago 2017*, v. 11, 2015. Disponível em: <[http://download.inep.gov.br/educacao\\_superior/censo\\_superior/documentos/2015/Notas\\_Estatisticas\\_Censo\\_Superior\\_2015.pdf](http://download.inep.gov.br/educacao_superior/censo_superior/documentos/2015/Notas_Estatisticas_Censo_Superior_2015.pdf)>. Citado na página 20.
- ISOTANI, S. et al. Web 3.0-os rumos da web semântica e da web 2.0 nos ambientes educacionais. In: *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)*. [S.l.: s.n.], 2008. v. 1, n. 1, p. 785–795. Citado na página 25.
- KANG, M.; PALMER-BROWN, D. A modal learning adaptive function neural network applied to handwritten digit recognition. *Information Sciences*, v. 178, n. 20, p. 3802–3812, 2008. ISSN 00200255. Citado na página 37.
- KENSKI, V. M. *Tecnologias e ensino presencial e a distância*. [S.l.]: Papyrus Editora, 2003. Citado na página 15.
- KIRSCHNER, P. A. Stop propagating the learning styles myth. *Computers and Education*, Elsevier Ltd, v. 106, p. 166–171, 2017. ISSN 03601315. Disponível em: <<http://dx.doi.org/10.1016/j.compedu.2016.12.006>>. Citado na página 31.
- KIRSCHNER, P. A. et al. Do learners really know best? urban legends in education. *Educational psychologist*, Taylor & Francis, v. 48, n. 3, p. 169–183, 2013. Citado 2 vezes nas páginas 30 e 31.
- KOLB, A. Y. The kolb learning style inventory-version 3.1 2005 technical specifications. *Boston, MA: Hay Resource Direct*, v. 200, p. 72, 2005. Citado 3 vezes nas páginas 29, 32 e 33.
- KOLB, D. A. *Individual learning styles and the learning process*. [S.l.]: MIT, 1971. Citado 3 vezes nas páginas 29, 32 e 33.
- KOLB, D. A. et al. Experiential learning theory: Previous research and new directions. *Perspectives on thinking, learning, and cognitive styles*, v. 1, n. 8, p. 227–247, 2001. Citado 3 vezes nas páginas 32, 33 e 35.
- KOP, R. et al. Evolutionary dynamic scripting: Adaptation of expert rule bases for serious games. In: SPRINGER. *International Conference on Industrial, Engineering and Other Applications of Applied Intelligent Systems*. [S.l.], 2015. p. 53–62. Citado na página 42.
- KURI, N. P. Tipos de personalidade e estilos de aprendizagem: proposições para o ensino de engenharia. Universidade Federal de São Carlos, 2004. Citado na página 18.
- LADEBECK, M. Applying dynamic scripting to “jagged alliance 2”. *TU Darmstadt*, 2008. Citado na página 42.
- LANDIM, C. Educação a distância: algumas considerações. *Rio de Janeiro*, 1997. Citado na página 15.

- LEÃO, L.; HIPERMÍDIA, O. L. da. Arquitetura e navegação no ciberespaço. *São Paulo, Edt. Iluminuras*, 1999. Citado na página 47.
- LÉVY, P.; COSTA, C. I. da. *tecnologias da inteligência*, As. [S.l.]: Editora 34, 1993. Citado na página 47.
- LIMA, C. C. de; MATTAR, J. Utilização do design educacional na concepção do projeto de ensino de programação de computadores na modalidade ead. *Research, Society and Development*, Grupo de Pesquisa Metodologias em Ensino e Aprendizagem em Ciências de Unifei-Itabira, v. 4, n. 3, p. 199–214, 2017. Citado na página 23.
- LUDWIG, J.; FARLEY, A. Examining extended dynamic scripting in a tactical game framework. In: *AIIDE*. [S.l.: s.n.], 2009. Citado na página 42.
- MACEDO, T. E.; FOLTRAN, E. *As tecnologias da informação e comunicação como ferramenta de enriquecimento para a educação*. [S.l.]: Acesso em: abril/2016. Disponível em: <http://www.diaadiaeducacao.pr.gov.br/portals/pde/arquivos/61-4.pdf>, 2007. Citado 2 vezes nas páginas 27 e 28.
- MAJCHRZAK, K.; QUADFLIEG, J.; RUDOLPH, G. Advanced dynamic scripting for fighting game ai. In: SPRINGER. *International Conference on Entertainment Computing*. [S.l.], 2015. p. 86–99. Citado na página 42.
- MATTAR, J. Youtube na educação: o uso de vídeos em ead. *São Paulo: Universidade Anhembi Morumbi*, 2009. Citado na página 24.
- MAURO, M. H. et al. Contribution of learning management system (lms) to the corporate knowledge management. In: *14th CONTECSI-International Conference on Information Systems and Technology Management*. [S.l.: s.n.], 2017. Citado na página 27.
- MAYER, O. J. Proposta do uso das ferramentas do marketing digital em uma empresa de segurança, higiene e medicina do trabalho. 2016. Citado na página 26.
- MELLO, F. Avaliação em ead: um estudo de caso corporativo. *Revista FGV Online*, v. 1, n. 2, p. 58–73, 2011. Citado na página 20.
- MELO, F. R. de et al. Estruturas de personalização em sistemas tutores inteligentes com redes neurais artificiais. *Anais do Simpósio Unificado de Sistemas de Informação da Universidade Estadual de Goiás*, v. 1, n. 1, 2017. Citado na página 43.
- MORAN, J. M. *Novas tecnologias e mediação pedagógica*. [S.l.]: Papyrus Editora, 2000. Citado 2 vezes nas páginas 15 e 23.
- NAIK, U.; SHIVALINGAIAH, D. Comparative study of web 1.0, web 2.0 and web 3.0. INFLIBNET Center3, 2008. Citado na página 23.
- NAVEGA, S. Inteligência artificial, educação de crianças e o cérebro humano. *Leopoldianum-Revista de Estudos de Comunicações da Universidade Católica de Santos*, p. 87–102, 2000. Citado na página 36.
- NEGNEVITSKY, M. *Artificial intelligence: a guide to intelligent systems*. [S.l.]: Pearson Education, 2005. Citado na página 36.

- NETTO, C.; GIRAFFA, L. M.; FARIA, E. T. *Graduações a distância e o desafio da qualidade*. [S.l.]: EDIPUCRS, 2010. Citado na página 15.
- OLIVEIRA, L. I. de. Aprimoramento da técnica de dynamic scripting para ia adaptativa de jogos com um algoritmo de substituição de táticas. *Trabalho de Conclusão de Curso Superior em Faculdade de Ciências Exatas*, Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina/MG, 2017. Citado na página 39.
- OSAKA, S. et al. A method for online adaptation of computer-game ai rulebase. In: ACM. *Proceedings of the 2006 ACM SIGCHI international conference on Advances in computer entertainment technology*. [S.l.], 2006. p. 16. Citado na página 41.
- O'REILLY, T. *What is web 2.0*. 2005. Citado na página 24.
- PALAZZO, L. A. M. Modelos proativos para hipermídia adaptativa. 2000. Citado 3 vezes nas páginas 15, 46 e 47.
- PALAZZO, L. A. M. Sistemas de hipermídia adaptativa. *XXI Jornada de Atualização em Informática-Livro Texto. Florianópolis*, v. 1, p. 287–325, 2002. Citado na página 45.
- PALETTA, F. C.; MUCHERONI, M. L. O desenvolvimento da web 3.0: Linked data e dbpedia. *Prisma. com*, n. 25, 2017. Citado na página 24.
- PAPANIKOLAOU, K. A. et al. Towards new forms of knowledge communication: the adaptive dimension of a web-based learning environment. *Computers & Education*, Elsevier, v. 39, n. 4, p. 333–360, 2002. Citado na página 48.
- PASHLER, H. et al. Learning Styles: Concepts and Evidence. *Psychological Science in the Public Interest*, v. 9, n. 3, p. 105–119, 2008. ISSN 15291006. Disponível em: <<http://psi.sagepub.com/content/9/3/105.abstract>>. Citado 2 vezes nas páginas 17 e 31.
- PHILLIPO, J.; KRONGARD, S. Learning management system (lms). *Massachusetts ASCD Perspectives*, 2012. Citado na página 27.
- PINTO, A. C. et al. Uso de tecnologias da informação e comunicação na educação em saúde de adolescentes: revisão integrativa. *Revista de enfermagem UFPE on line-ISSN: 1981-8963*, v. 11, n. 2, p. 634–644, 2017. Citado na página 26.
- POLAK, Y. Nascimento de S.; MUNHOZ, A. S.; DUARTE, E. V. G. Referenciais de qualidade para cursos em ead: dificuldades e desafios. *Revista Diálogo Educacional*, Pontifícia Universidade Católica do Paraná, v. 8, n. 24, 2008. Citado na página 23.
- POLICARPO, D.; URBANO, P.; LOUREIRO, T. Dynamic scripting applied to a first-person shooter. In: IEEE. *Information Systems and Technologies (CISTI), 2010 5th Iberian Conference on*. [S.l.], 2010. p. 1–6. Citado na página 42.
- POMPTCLOUD. Open source learning management system. Acesso em: outubro/2017. Disponível em: <https://www.promptcloud.com/open-source-learning-management-system/>, 2015. Citado na página 29.
- POZZEBON, E.; FRIGO, L. B.; BITTENCOURT, G. Inteligência artificial na educação universitária: Quais as contribuições? *Rev. CCEI*, v. 8, p. 33–40, 2004. Citado 2 vezes nas páginas 36 e 43.

- QI, Z. An evaluation of education informatization based on bp neural network. In: IEEE. *Information Science and Engineering (ICISE), 2009 1st International Conference on*. [S.l.], 2009. p. 3215–3218. Citado na página 36.
- RABIN, S. *AI Game Programming Wisdom*. [S.l.]: Charles River Media; 1 edition (April 3, 2002), Boston, first edit edition, 2002. Citado na página 40.
- RAWSON, K.; STAHOVICH, T. F.; MAYER, R. E. Homework and achievement: Using smartpen technology to find the connection. *Journal of Educational Psychology*, American Psychological Association, 2017. Citado 2 vezes nas páginas 17 e 30.
- RIBEIRO, R.; KOERICH, A. L.; ENEMBRECK, F. Uma nova metodologia para avaliação de desempenho de algoritmos baseados em aprendizagem por reforço. In: *XXXIII Seminário Integrado de Software e Hardware. Anais do XXVI Congresso da Sociedade Brasileira de Computação*. [S.l.: s.n.], 2006. Citado na página 39.
- RICE, W. Moodle e-learning course development. a complete guide to successful learning using moodleq3. *Packt Publ*, p. 13, 2006. Citado na página 28.
- RIDING, R.; CHEEMA, I. Cognitive styles—an overview and integration. *Educational psychology*, Taylor & Francis, v. 11, n. 3-4, p. 193–215, 1991. Citado na página 29.
- RODRIGUES, A. Z.; COSTA, J. B. A. da. As tecnologias de informação e comunicação na era da informação. *Anais do Seminário Nacional de Sociologia da UFS-ISSN 2526-3013*, v. 1, 2017. Citado na página 26.
- RODRIGUES, L. H. S. et al. Análise comparativa de novas abordagens para modelagem automática e dinâmica de estilos de aprendizagem em sistemas adaptativos e inteligentes para educação. n. Cbie, p. 1076, 2016. ISSN 2316-6533. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/6793>>. Citado 5 vezes nas páginas 17, 31, 51, 55 e 58.
- ROSEMANN, D.; RAABE, A. L.; TEIVE, R. C. G. 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*. [S.l.: s.n.], 2014. v. 3, n. 1, p. 203. Citado na página 15.
- SANTOS, E. O. dos. Ambientes virtuais de aprendizagem: por autorias livres, plurais e gratuitas. *Educação e Contemporaneidade*, v. 11, n. 18, p. 424, 2002. Citado na página 28.
- SCHMIDHUBER, J. Deep learning in neural networks: An overview. *Neural networks*, Elsevier, v. 61, p. 85–117, 2015. Citado na página 36.
- SCHONS, C. H.; RIBEIRO, A. C.; BATTISTI, P. Educação a distância: Web 2.0 na construção do conhecimento coletivo. INPEAU, 2008. Citado na página 24.
- SENA, E. B. et al. Uuma abordagem computacional para detecção automática de estilos de aprendizagem utilizando modelos ocultos de markov. *SIED: EnPED*, 2016. Citado 3 vezes nas páginas 17, 31 e 49.

- SILVA, L. Tecnologias da informação e comunicação (tics) na educação à distancia. Disponível em: [www.educacao-a-distancia.com/tecnologias-da-informacao-e-comunicacao-tics-na-educacao-a-distancia](http://www.educacao-a-distancia.com/tecnologias-da-informacao-e-comunicacao-tics-na-educacao-a-distancia), Acesso em: 23/10/2017, 2013. Citado na página 27.
- SILVA, L. L. V. Estilos e estratégias de aprendizagem de estudantes universitários. 2012. Citado 10 vezes nas páginas 16, 17, 18, 30, 31, 32, 33, 34, 35 e 51.
- SILVA, M. d. *Tecnologias de informação e comunicação: estruturando núcleos de conteúdos para disciplina específica no curso de Pedagogia*. 2011. Tese (Doutorado) — Dissertação de Mestrado. Universidade Federal do Paraná.(versão apresentada na defesa), 2013. Citado na página 26.
- SILVA, M. N. S. da; SANTOS, M. M. As tecnologias de informação e comunicação no ambiente escolar. *Revista Educação & Tecnologia*, v. 15, n. 15, 2017. Citado na página 26.
- SILVEIRA, S. R. et al. Aplicação de técnicas de hipermídia adaptativa em sistemas tutores inteligentes. *Colabor@-A Revista Digital da CVA-RICESU*, v. 7, n. 25, 2013. Citado na página 46.
- SOLOMAN, B. A.; FELDER, R. M. Index of learning styles questionnaire. *Retrieved March*, v. 26, p. 2003, 1999. Citado na página 35.
- SONI, B.; HINGSTON, P. Bots trained to play like a human are more fun. In: IEEE. *Neural Networks, 2008. IJCNN 2008.(IEEE World Congress on Computational Intelligence)*. *IEEE International Joint Conference on*. [S.l.], 2008. p. 363–369. Citado na página 43.
- SPRONCK, P. *Adaptive Game AI*. Tese (Doutorado) — Universitaire Pers Maastricht, 2005. Citado 7 vezes nas páginas 19, 21, 38, 40, 41, 42 e 43.
- SPRONCK, P. et al. Adaptive game AI with dynamic scripting. *Machine Learning*, v. 63, n. 3, p. 217–248, 2006. ISSN 08856125. Citado 2 vezes nas páginas 19 e 40.
- STOJANOVIC, L.; STAAB, S.; STUDER, R. elearning based on the semantic web. In: *WebNet2001-World Conference on the WWW and Internet*. [S.l.: s.n.], 2001. p. 23–27. Citado na página 24.
- SUTTON, R. S.; BARTO, A. G. *Reinforcement learning: An introduction*. [S.l.]: MIT press Cambridge, 1998. v. 1. Citado 3 vezes nas páginas 38, 39 e 40.
- TAFNER, M. A. Redes neurais artificiais: aprendizado e plasticidade. *Cérebro Mente, São Paulo*, v. 5, 1998. Citado na página 37.
- TECNOLOGÍA, B. y. The new classroom organization with ict. Disponível em: <http://www.bilinguismoytecnologia.com/en/la-nueva-organizacion-del-aula-con-las-tic/>, Acesso em: 23/10/2017, 2012. Citado na página 27.
- TOUBMAN, A. et al. Centralized versus decentralized team coordination using dynamic scripting. National Aerospace Laboratory NLR, 2014. Citado na página 42.
- TRUONG, H. M. Integrating learning styles and adaptive e-learning system: Current developments, problems and opportunities. *Computers in Human Behavior*, Elsevier Ltd, 2015. ISSN 07475632. Disponível em: <<http://dx.doi.org/10.1016/j.chb.2015.02.014>>. Citado 2 vezes nas páginas 17 e 31.

- TURING, A. M. Computing machinery and intelligence. *Mind*, JSTOR, v. 59, n. 236, p. 433–460, 1950. Citado na página 35.
- UBERABA, U. d. *Manual do Professor Tutor*. Uberaba, MG: [s.n.], 2016. Citado na página 60.
- VEENMAN, M. V. J.; PRINS, F. J.; VERHEIJ, J. Learning styles: Self-reports versus thinking-aloud measures. *British Journal of Educational Psychology*, v. 73, p. 357–372, 2003. ISSN 0007-0998. Citado 2 vezes nas páginas 17 e 30.
- VIAN, P. M. S. *Desenvolvimento de um quadro situacional para a cibersegurança em Portugal*. Tese (Doutorado), 2016. Citado na página 26.
- VICCARI, R.; MOUSSALLE, N. Tutores inteligentes para o ensino da linguagem prolog. *SEMINÁRIO NACIONAL DE INFORMÁTICA NA EDUCAÇÃO*, v. 1, 1990. Citado na página 45.
- VIEIRA, E. A. O.; CUNHA, D. M.; MARTINEZ, M. L. História da educação a distância no brasil, algumas provocações. *Revista Perspectivas em Políticas Públicas*, v. 9, n. 2, p. 121–148, 2017. Citado na página 23.
- WILSON, L. O. Anderson and krathwohl–understanding the new version of bloom’s taxonomy. *The second principle. The work of Leslie Owen Wilson. Ed. D*, 2013. Citado 2 vezes nas páginas 48 e 49.
- YANG, X.-S. *Nature-inspired metaheuristic algorithms*. [S.l.]: Luniver press, 2010. Citado na página 37.
- YEH, S.-W.; LO, J.-J. Assessing metacognitive knowledge in web-based call: a neural network approach. *Computers & Education*, Elsevier, v. 44, n. 2, p. 97–113, 2005. Citado na página 37.
- ZAMBONELLI, F. et al. Agent-oriented software engineering for internet applications. In: *Coordination of Internet Agents*. [S.l.]: Springer, 2001. p. 326–346. Citado na página 43.
- ZANCHETT, P. S.; DALFOVO, O. Hipermedia adaptativa no sistema de aprendizagem para a maior idade. In: *I Workshop de Computação da Região Sul*. [S.l.: s.n.], 2004. p. 1–11. Citado na página 46.

## APÊNDICE A – Apêndice

Neste apêndice são apresentadas as regras que compuseram a Base de Regras do ADS. Conforme dito, o ADS é composto por um conjunto de regras constituídas por uma (ou mais) condições, uma ação, e um peso. De forma que as condições usam a nota ou PFM obtida pelo estudante da etapa de avaliação e/ou a Distância do Estilo de Aprendizagem (DEA).

As ações consistem na aplicação de reforço positivo ou negativo no EAp contido no ME através de um valor percentual ou mesmo através do valor de uma constante. Os valores de constantes presentes nas regras, foram obtidos através da multiplicação do valor de reforço máximo ( $Rmax$ ) apresentando por Dorça (2012), pela fração das regras estratificadas em um intervalo de 5 em 5 pontos.

Em outras palavras, se a nota fosse ótima, por exemplo acima de 95, considera-se o reforço máximo através do cálculo:  $reforço = Rmax * 8/8$  e se a nota fosse a mais baixa, mas ainda assim satisfatória, como por exemplo 60, considera-se o reforço  $= Rmax * 1/8$ , onde 8 corresponde as frações de nota possível, em notas acima ou igual a 60 pontos, farão jus a um ajuste positivo. Dessa mesma forma, o reforço  $= Rmax * 12/12$ , corresponde as frações de notas possíveis que, de 5 em 5 pontos farão jus a um ajuste negativo por serem notas inferiores a 60. Por se tratarem de valores fixos, que não dependerão de outras variáveis, foram colocados nas regras como constantes.

Algumas regras, em especial que aplicam reforço positivo, tiveram seus valores divididos por 10, uma vez que a aplicação daquele ajuste, estava fazendo com que o sistema não estabilizasse, sendo necessário reduzir os valores.

Diversas regras foram criadas e usadas em testes, de acordo com a frequência com que eram usadas, algumas foram removidas, substituídas e ou alteradas. As regras utilizadas na versão final e que foram usadas nos experimentos dessa pesquisa são:

1. Se ( $nota > 95$ ) então aplique reforço no EAp de 0.00500;
2. Se ( $nota \geq 90 \ \&\& \ nota < 95$ ) então aplique reforço no EAp de 0.008375;
3. Se ( $nota \geq 85 \ \&\& \ nota < 90$ ) então aplique reforço no EAp de 0.007750;
4. Se ( $nota \geq 80 \ \&\& \ nota < 85$ ) então aplique reforço no EAp de 0.007375;
5. Se ( $nota \geq 75 \ \&\& \ nota < 80$ ) então aplique reforço no EAp de 0.007200;
6. Se ( $nota \geq 70 \ \&\& \ nota < 75$ ) então aplique reforço no EAp de 0.006875;

7. Se ( $nota \geq 65 \ \&\& \ nota < 70$ ) então aplique reforço no EAp de 0.004250;
8. Se ( $nota \geq 60 \ \&\& \ < 65$ ) então aplique reforço no EAp de 0.006250;
9. Se ( $nota \geq 55 \ \&\& \ nota < 60$ ) e ( $DEA \leq 0.1$ ) então Inverter Polos;
10. Se ( $nota \geq 50 \ \&\& \ nota < 55$ ) e ( $DEA \leq 0.1$ ) então Inverter Polos;
11. Se ( $nota \geq 45 \ \&\& \ nota < 50$ ) então aplique reforço no EAp de -0.01250;
12. Se ( $nota \geq 40 \ \&\& \ nota < 45$ ) então aplique reforço no EAp de -0.01667;
13. Se ( $nota \geq 35 \ \&\& \ nota < 40$ ) então aplique reforço no EAp de -0.02083;
14. Se ( $nota \geq 30 \ \&\& \ nota < 35$ ) então aplique reforço no EAp de -0.02500;
15. Se ( $nota \geq 25 \ \&\& \ nota < 30$ ) então aplique reforço no EAp de -0.02917;
16. Se ( $nota \geq 20 \ \&\& \ nota < 25$ ) então aplique reforço no EAp de -0.03333;
17. Se ( $nota \geq 15 \ \&\& \ nota < 20$ ) então aplique reforço no EAp de -0.03750;
18. Se ( $nota \geq 10 \ \&\& \ nota < 15$ ) então aplique reforço no EAp de -0.04167;
19. Se ( $nota \geq 05 \ \&\& \ nota < 10$ ) então aplique reforço no EAp de -0.04583;
20. Se ( $nota \geq 00 \ \&\& \ nota < 05$ ) então aplique reforço no EAp de -0.05000;
21. Se ( $nota \geq 90$ ) então aplique reforço no EAp de 4%;
22. Se ( $nota < 20$ ) e ( $DEA < 0.1$ ) então aplique reforço de -0.0600;
23. Se ( $nota < 5$ ) então aplique reforço no EAp de -15%;
24. Se ( $nota < 10$ ) e ( $DEA < 0.2$ ) então Inverter Polos;
25. Se ( $nota < 60$ ) e ( $DEA < 0.1$ ) então aplique reforço de -2% .
26. Se ( $nota < 50$ ) então aplique reforço no EAp de 0.01000
27. Se ( $nota < 40$ ) e ( $DEA < 0.2$ ) então aplique reforço de -10%;
28. Se ( $nota < 30$ ) e ( $DEA < 0.2$ ) então aplique reforço de -10%;
29. Se ( $nota < 60$ ) então aplique reforço no EAp de -0.01000;
30. Se ( $nota < 20$ ) então aplique reforço no EAp de -0.01000;
31. Se ( $nota < 10$ ) então aplique reforço de -5%;
32. Se ( $nota < 10$ ) e ( $DEA \leq 0.1$ )então Inverter Polos;

33. Se ( $nota < 15$ ) e ( $DEA \leq 0.3$ ) então Inverter Polos;
34. Se ( $nota > 90$ ) então aplique reforço de 0.01900;
35. Se ( $nota > 60$ ) então aplique reforço no EAp de 0.01400;
36. Se ( $nota > 80$ ) então aplique reforço de 3%;
37. Se ( $nota > 90$ ) então aplique reforço de 5%;
38. Se ( $nota > 80 \ \&\& \ nota < 90$ ) então aplique reforço no EAp de 0.00950;
39. Se ( $nota > 70 \ \&\& \ nota < 80$ ) então aplique reforço no EAp de 0.00400;
40. Se ( $nota \geq 90$ ) então aplique reforço no EAp de 0.05000;