

Informática Aplicada à Educação

Everson Mario Novak
(Organizador)



 **Editora**
Atena

Ano 2018

Everson Mario Novak
(Organizador)

Informática Aplicada à Educação

Atena Editora
2018

2018 by Atena Editora

Copyright © da Atena Editora

Editora Chefe: Profª Drª Antonella Carvalho de Oliveira

Edição de Arte e Capa: Geraldo Alves e Natalia Sandrini

Revisão: Os autores

Conselho Editorial

Prof. Dr. Alan Mario Zuffo – Universidade Estadual de Mato Grosso do Sul
Prof. Dr. Álvaro Augusto de Borba Barreto – Universidade Federal de Pelotas
Prof. Dr. Antonio Carlos Frasson – Universidade Tecnológica Federal do Paraná
Prof. Dr. Antonio Isidro-Filho – Universidade de Brasília
Prof. Dr. Constantino Ribeiro de Oliveira Junior – Universidade Estadual de Ponta Grossa
Profª Drª Daiane Garabeli Trojan – Universidade Norte do Paraná
Profª Drª Deusilene Souza Vieira Dall’Acqua – Universidade Federal de Rondônia
Prof. Dr. Eloi Rufato Junior – Universidade Tecnológica Federal do Paraná
Prof. Dr. Fábio Steiner – Universidade Estadual de Mato Grosso do Sul
Prof. Dr. Gianfábio Pimentel Franco – Universidade Federal de Santa Maria
Prof. Dr. Gilmei Fleck – Universidade Estadual do Oeste do Paraná
Profª Drª Girlene Santos de Souza – Universidade Federal do Recôncavo da Bahia
Profª Drª Ivone Goulart Lopes – Istituto Internazionele delle Figlie de Maria Ausiliatrice
Prof. Dr. Jorge González Aguilera – Universidade Federal de Mato Grosso do Sul
Prof. Dr. Julio Candido de Meirelles Junior – Universidade Federal Fluminense
Profª Drª Lina Maria Gonçalves – Universidade Federal do Tocantins
Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Profª Drª Paola Andressa Scortegagna – Universidade Estadual de Ponta Grossa
Profª Drª Raissa Rachel Salustriano da Silva Matos – Universidade Federal do Maranhão
Prof. Dr. Ronilson Freitas de Souza – Universidade do Estado do Pará
Prof. Dr. Takeshy Tachizawa – Faculdade de Campo Limpo Paulista
Prof. Dr. Urandi João Rodrigues Junior – Universidade Federal do Oeste do Pará
Prof. Dr. Valdemar Antonio Paffaro Junior – Universidade Federal de Alfenas
Profª Drª Vanessa Bordin Viera – Universidade Federal de Campina Grande
Prof. Dr. Willian Douglas Guilherme – Universidade Federal do Tocantins

Dados Internacionais de Catalogação na Publicação (CIP) (eDOC BRASIL, Belo Horizonte/MG)	
143	Informática aplicada à educação [recurso eletrônico] / Organizador Everson Mario Novak. – Ponta Grossa (PR): Atena Editora, 2018. 10.596 kbytes Formato: PDF Requisitos de sistema: Adobe Acrobat Reader Modo de acesso: World Wide Web Inclui bibliografia ISBN 978-85-85107-14-7 DOI 10.22533/at.ed.147181308 1. Educação. 2. Informática. 3. Tecnologia educacional. I. Novak, Everson Mario. CDD 371.334
Elaborado por Maurício Amormino Júnior – CRB6/2422	

O conteúdo do livro e seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva dos autores

2018

Permitido o download da obra e o compartilhamento desde que sejam atribuídos créditos aos autores, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

www.atenaeditora.com.br

E-mail: contato@atenaeditora.com.br

APRESENTAÇÃO

Este livro foi dividido em 3 eixos, fruto de pesquisa científica de ótima qualidade acadêmica sobretudo por equipes multidisciplinares e de diversas instituições. Os trabalhos realizados são para auxiliar na Educação a distância e presencial, utilizando recursos computacionais para o planejamento e desenvolvimento de aplicativos para apoiar o aprendizado de matemática e de atividades cotidianas para crianças autistas, desenvolvimento de jogos educacionais e ainda para avaliar os dados armazenados em LMS (Learning Management Software) da plataforma Moodle.

No primeiro eixo temos o desenvolvimento de softwares e aplicativos voltados para a EAD, iniciamos por uma aplicação m-learning Genius para o auxiliar no ensino de matemática na educação infantil, explorando formas geométricas, números e a adição e subtração através de figuras e sons. O ENEN foi tema de um aplicativo focado em preparar os alunos na disciplina de matemática. O relacionamento social, comunicação e alterações de comportamento do autista são o tema de estudo para o desenvolvimento de um aplicativo para auxiliar os autistas no aprendizado e no relacionamento social.

A Cloud Computing apoia a aprendizagem em ambientes U-learning para verificar os estilos de aprendizagem e aplicabilidade em ambientes educacionais. As métricas de software são utilizadas para fazer uma análise da aprendizagem em cursos de programação a distância. Uma base de conhecimento gerada das questões e códigos inseridos nas plataformas digitais de ensino, foi feita a classificação de códigos da linguagem C em medidas similares para fazer os agrupamentos para formação de uma base de questões com códigos e soluções associadas para correções de questões de forma automatizada.

O segundo eixo entra em jogos digitais e gamificação, auxiliam na aprendizagem de pessoas com deficiência visual, tenta garantir no processo pedagógico uma inclusão digital e social destas pessoas. O processo de aprendizado utilizou-se dos jogos construcionistas para propor quatro jogos educativos, simplificando a complexidade na sua criação. Problemas motivacionais dos alunos são tratados na gamificação para verificar o que ocorre em processos de aprendizagem em ambientes educacionais.

No terceiro e último eixo é abordada a aprendizagem de máquina (machine-learning), aplicada a educação e aprendizado. O conceito de Estilos de Aprendizagem (EA) da psicologia cognitiva e da pedagogia, são propostos em sistemas educacionais adaptativos, com algumas aplicações da Aprendizagem por Reforço, foi proposto uso de algoritmos relacionados a aprendizagem de máquina para obter os estilos de Aprendizagem. Aplicabilidade de modelos de Regressão Múltipla no contexto da EAD foi abordado para validar as variáveis de comportamento de autorregulação da aprendizagem na plataforma LMS – Moodle.

Ao escrever este prefácio contextualizei o alinhamento das análises e teorias desenvolvidas nos artigos contidos neste livro. Sugiro que o leitor faça este caminho para uma compreensão ampla destes trabalhos, agradeço a oportunidade de fazer parte de grupo e felicito a todos os integrantes.

Everson Mario Novak
Mestrando em Informática - PUCPR

SUMÁRIO

EIXO 1: SOFTWARES E APLICATIVOS VOLTADOS PARA A EAD

CAPÍTULO 1	1
GENIUS MATH: UMA APLICAÇÃO MOBILE PARA AUXILIAR A APRENDIZAGEM DA MATEMÁTICA NA PRÉ-ESCOLA	
<i>Stefane Vieira Menezes</i> <i>Jiani Cardoso da Roza</i>	
CAPÍTULO 2	13
APLICATIVO MÓVEL PARA PREPARAÇÃO DE ESTUDANTES PARA O ENEM NO CONTEXTO DA DISCIPLINA DE MATEMÁTICA	
<i>Hannderson Faria Arantes</i> <i>Rodrigo Duarte Seabra</i>	
CAPÍTULO 3	27
COTIDIANO: UM SOFTWARE PARA AUXILIAR CRIANÇAS AUTISTAS EM SUAS ATIVIDADES DIÁRIAS	
<i>Afranio Furtado de Oliveira Neto</i> <i>Hugo Leonardo Pereira Rufino</i> <i>Diovane de Godoi Beira</i> <i>Rodolfo Bocado Palis</i> <i>Paula Teixeira Nakamoto</i>	
CAPÍTULO 4	41
APRENDIZAGEM SIMULADA NA NUVEM	
<i>Rafaela R. Jardim</i> <i>Roseclea Duarte Medina</i> <i>Giliane Bernardi</i> <i>Fabricio Herpich</i> <i>Andressa Facalde</i> <i>Eduardo Lemos</i>	
CAPÍTULO 5	55
ANÁLISE DA APRENDIZAGEM DE PROGRAMAÇÃO POR MAPEAMENTO DE PERFIS EM MÉTRICAS DE SOFTWARE	
<i>Márcia Gonçalves de Oliveira</i> <i>Ádler Oliveira Silva Neves</i> <i>Helen França Medeiros</i> <i>Mônica Ferreira Silva Lopes</i> <i>Leonardo Leal Reblin</i> <i>Elias Silva de Oliveira</i>	
CAPÍTULO 6	68
CLASSIFICAÇÃO DE CÓDIGOS C USANDO MEDIDAS DE SIMILARIDADE PARA APOIO AO ENSINO DE PROGRAMAÇÃO	
<i>José Carlos Campana Filho</i> <i>Elias Silva de Oliveira</i> <i>Márcia Gonçalves de Oliveira</i>	

EIXO 2: JOGOS DIGITAIS E GAMIFICAÇÃO

CAPÍTULO 7 79

BEM EXPRESSÕES: JOGO DIGITAL VOLTADO PARA O ENSINO INCLUSIVO DA MATEMÁTICA

André Luis Bitencourt Fernandes
Claudia Pinto Pereira
Kayo Costa de Santana
Ana Jaize de Oliveira Silva Santos
Bruno Gonzaga de Mattos Vogel

CAPÍTULO 8 95

JINDIE: UMA LINHA DE PRODUTO DE SOFTWARE PARA JOGOS EDUCATIVOS COM FOCO NO CONSTRUCIONISMO

Carlos Alberto Correia Lessa Filho
Arturo Hernandez Dominguez

CAPÍTULO 9 107

METODOLOGIAS GAMIFICADAS PARA A EDUCAÇÃO: UMA REVISÃO SISTEMÁTICA
DETECÇÃO AUTOMÁTICA DE ESTILOS DE APRENDIZAGEM: UMA ANÁLISE COMPARATIVA DE
CLASSIFICADORES APLICADOS EM UM CENÁRIO REAL DE APRENDIZADO

André Luiz de Souza Brito
Charles Andryê Galvão Madeira

EIXO 3: APRENDIZAGEM DE MÁQUINA APLICADA A EDUCAÇÃO

CAPÍTULO 10 120

DETECÇÃO AUTOMÁTICA DE ESTILOS DE APRENDIZAGEM: UMA ANÁLISE COMPARATIVA DE
CLASSIFICADORES APLICADOS EM UM CENÁRIO REAL DE APRENDIZADO

Lucas Daniel Ferreira
José Fernando Rodrigues Jr

CAPÍTULO 11 140

DETECÇÃO AUTOMÁTICA E DINÂMICA DE ESTILOS DE APRENDIZAGEM EM SISTEMAS
ADAPTATIVOS E INTELIGENTES PARA A EDUCAÇÃO UTILIZANDO DYNAMIC SCRIPTING

Júlio César da Costa Silva
Cristiano Grijó Pitangui
Alessandro Vivas Andrade
Luciana Pereira de Assis
Cristiano Maciel da Silva

CAPÍTULO 12 156

UM PROCESSO DE VALIDAÇÃO DE VARIÁVEIS COMPORTAMENTAIS DE AUTORREGULAÇÃO
DA APRENDIZAGEM EM PLATAFORMAS DE LMS

Rodrigo Lins Rodrigues
João Carlos Sedraz Silva
Jorge Luis Cavalcanti Ramos
Fernando da Fonseca de Souza
Alex Sandro Gomes

SOBRE O ORGANIZADOR..... 166

EIXO 1 – SOFTWARES E APLICATIVOS VOLTADOS PARA A EAD

APRESENTAÇÃO

No primeiro eixo temos o desenvolvimento de softwares e aplicativos voltado para EAD, iniciamos por uma aplicação m-learning Genius para o auxiliar no ensino de matemática na educação infantil, explorando formas geométricas, números e a adição e subtração através de figuras e sons. Com atividades lúdicas viabilizando práticas contemporâneas ao cotidiano infantil.

Agora abordando outro tema pertinente o ENEN, um aplicativo focado em preparar os alunos para o Exame Nacional do Ensino Médio na disciplina de matemática.

As dificuldades apresentadas em relacionamento social, comunicação e alterações de comportamento por um autista são o tema de estudo para o desenvolvimento de um aplicativo para auxiliar os autistas no aprendizado e no relacionamento social.

A Cloud Computing está apoiando a aprendizagem em ambientes U-learning, criando um laboratório virtual U-Lab Cloud para verificar os estilos de aprendizagem para adotar a tecnologia em ambientes educacionais.

O software PCódigo II, utiliza métricas de software para fazer a análise da aprendizagem em cursos de programação a distância, para que sejam observadas dificuldades de aprendizagem, boas práticas de programação e perfis de aprendizagem de forma rápida, detalhada e holística.

Neste outro tema é gerado uma base de conhecimento de forma organizada das questões e códigos gerados nas plataformas digitais de ensino a distância. Abordando uma classificação de códigos da linguagem C baseada em medidas similares para fazer os agrupamentos para formação de uma base de questões com códigos e soluções associadas para correções de questões de forma automatizada.

Everson Mario Novak
Mestrando em Informática - PUCPR

DETECÇÃO AUTOMÁTICA E DINÂMICA DE ESTILOS DE APRENDIZAGEM EM SISTEMAS ADAPTATIVOS E INTELIGENTES PARA A EDUCAÇÃO UTILIZANDO DYNAMIC SCRIPTING

Júlio César da Costa Silva

Universidade de Uberaba (UNIUBE)
Guanhães - Minas Gerais

Cristiano Grijó Pitanguí

Universidade Federal de São João del-Rei
(UFSJ)
São João Del Rei – Minas Gerais

Alessandro Vivas Andrade

Universidade Federal dos Vales do
Jequitinhonha e Mucurí (UFVJM)
Diamantina – Minas Gerais

Luciana Pereira de Assis

Universidade Federal dos Vales do
Jequitinhonha e Mucurí (UFVJM)
Diamantina – Minas Gerais

Cristiano Maciel da Silva

Universidade Federal de São João del-Rei
(UFSJ)
São João Del Rei – Minas Gerais

RESUMO Sistemas Adaptativos e Inteligentes para a Educação(SAIE) buscam fornecer assistência personalizada ao aluno por meio da detecção de seu Estilo de Aprendizagem (EA). Uma das técnicas mais exploradas para esta detecção é o Aprendizado por Reforço (AR). Contudo, tal técnica, em alguns casos, é considerada de lenta convergência. Este trabalho propõe o aperfeiçoamento de um SAIE utilizando uma adaptação da técnica de *Dynamic*

Scripting, considerada mais rápida que o AR. Experimentos demonstraram que a proposta, comparada às soluções da literatura, reduziu o número de problemas de aprendizagem em $\approx 54\%$, e $\approx 35\%$, respectivamente, para EAs Estáticos e Dinâmicos, enquanto reduz o número de interações do sistema em $\approx 5,7\%$.

PALAVRAS-CHAVE Dynamic Scripting. SAIE. Estilos de Aprendizagem.

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

KEYWORDS Dynamic Scripting. Adaptive and Intelligent Educational Systems. Style.

1 | INTRODUÇÃO

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

Uma das formas de se gerar conteúdo adaptado aos alunos passa, primeiro, pela detecção dos Estilos de Aprendizagem (EA). A teoria dos EA presume que cada aluno tem características próprias que o distingue dos outros indivíduos (SILVA, 2012). Logo, cada aluno desenvolve uma maneira própria de processar as informações que recebe, sendo este processo denominado Estratégias de Aprendizagem (PRICE, 2004). Contudo, por mais pessoais que sejam essas estratégias, ainda é possível estabelecer padrões entre elas. Estes padrões são chamados de Estilos de Aprendizagem (FELDER, SILVERMAN, 1988; SILVA, 2012).

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

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

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

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

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

2 | REFERENCIAL TEÓRICO

2.1 Estilos de aprendizagem

Kolb (2005) define EA como a preferência de gerenciamento do aluno para trabalhar nas diferentes fases do ciclo da aprendizagem. Por sua vez, Felder e Silverman (1988) definiram EA como o método preferencial que as pessoas optam para receber e processar a informação.

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

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

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

Para Kirschner (2017), uma preferência por um determinado EA é sinal de

fraqueza em relação aos outros, logo, deve ser eliminada e não respeitada. Hood (2017) criticam ainda a existência de mais de 70 modelos de detecção e delimitação de EA que não são coerentes entre si e que comprometem toda a validade da teoria.

Apesar das críticas, pesquisas recentes (DORÇA, 2012; FALCI, 2017; GONCALVES, 2016; RODRIGUES, 2016; SENA, 2016; SILVA, 2017) assinalam uma tendência na aplicação de ferramentas automáticas de detecção dos EAs que não se amoldam aos parâmetros criticados. A exemplo, tem-se a detecção do EA fundamentada em dados coletados por sistemas durante o processo de ensino-aprendizagem, sendo o questionário opcional, útil apenas para fornecer uma direção inicial

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

2.2 O SAIE de dorça (2012) e suas adaptações

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

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

O ME contém o Estilo de Aprendizagem Probabilístico (EAp), o Estado cognitivo (EC), e os Objetivos de Aprendizagem (OAs). O EAp é armazenado por valores reais no intervalo $[0, 1]$, sendo estes valores a probabilidade da preferência de um ou outro EA de cada dimensão do FSLSM. O EC, baseado na Taxonomia de Bloom (BLOOM, 1956), versa sobre o nível de conhecimento do aluno em cada conceito a ser aprendido. Existem 6 Níveis Cognitivos (NC), sendo: Conhecimento, Compreensão, Aplicação, Análise, Síntese e Avaliação. 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 aprendidos (DORÇA, 2012).

O MP seleciona a estratégia pedagógica mais apropriada conforme o ME, com base em uma Combinação de Estilos de Aprendizagem (CEA) definida pelas 4 dimensões do FSLSM. A cada interação, o MP seleciona estocasticamente uma CEA.

Há 2 pólos para cada uma das 4 dimensões, assim, no total, 2^4 CEAs. Dessa forma, o aluno pode, com maior ou menor chance, se enquadrar em qualquer das 16 CEAs possíveis (DORÇA, 2012).

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

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

Algoritmo 1: AR aplicado à modelagem automática de EA (DORÇA, 2012)
1 Início
2 inicialize o ME;
3 Repita
4 Selecione um conceito C a ser apresentado ao estudante;
5 Selecione, através do MP, uma CEA a ;
6 Execute a , apresentando adequadamente o objetos de aprendizagem que ensinam C ao estudante;
7 Avalie, através do CME, a <i>performance</i> 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 com base a CEA. O passo 7 submete o aluno a uma avaliação. No passo 8, o EC do aluno no conceito selecionado é atualizado. O passo 9, com base na nota, calcula o valor do reforço. O passo 10 atualiza o EAp com base no reforço calculado no passo 9. O passo 11 incrementa o estado s para o próximo estado s' . Repete-se o processo descrito até que s seja estado final.

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

reforço.

Gonçalves (2016) preocupado com a incorreta aplicação de reforço, propôs uma abordagem que usa a série histórica das notas obtidas para cada CEA. A proposta 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 (2017), de posse das notas anteriores, categorizou o cálculo do reforço não apenas com base na nota da interação, mas em todas os resultados já coletados, permitindo ainda, que sejam aplicados reforços positivos, de acordo com a categoria em que a nota se enquadrou. Assim, diminuem-se as chances de aplicação indevida de reforço.

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

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

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

2.3 O dynamic scripting

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

AR é uma técnica de Aprendizado de Máquina que mapeia estados à ações (SUTTON, 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, 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, 1998).

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

Scripts de IA para jogos consistem em uma sequência de regras, onde cada regra consiste em duas partes: uma condicional, que identifica um ou mais estados do jogo; e uma de ação, que descreve a ação a ser tomada caso a condição seja satisfeita (SPRONCK, 2005). Contudo, estes *scripts* não apresentam características adaptativas. Seu funcionamento é baseado em uma série de regras, já conhecidas, que respondem aos estados do jogo. Já o DS adiciona a capacidade de explorar a representação do espaço de estados (que os *scripts* produzem) para uma aprendizagem rápida e eficiente, ao mesmo tempo em que confia no conteúdo baseado em *scripts* para garantir que todo o comportamento adaptativo seja plausível e eficaz (SPRONCK, 2005).

O mecanismo do DS pode ser definido em cinco etapas (THAWONMAS et al., 2006):

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

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

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

jogador.

3 | ABORDAGEM PROPOSTA

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

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

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

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

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




Figura 1- Demonstração da Atualização dos Pesos das Regras

Fonte: Elaborado pelo autor

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

4 | SESSÃO EXPERIMENTAL

4.1 Metodologia experimental

O ADS se propõe a ser eficaz tanto para casos de EAr Estáticos quanto para EAr Dinâmicos. Assim, para validar a proposta, foram realizados testes comparativos com as abordagens de (DORÇA, 2012) e (FALCI, 2017) para EAr Estáticos e, com a abordagem de (DORÇA, 2012) para EAr Dinâmicos. Não foram comparadas as abordagens de Falci (2017), Gonçalves (2016), e Rodrigues (2016) para EAr Dinâmicos, pois, como falado na seção 2.2, tais abordagens não são apropriadas para estes casos.

Objetiva-se demonstrar que o ADS, contribui para se elevar o desempenho do estudante a partir da personalização do ensino, sendo que os indicadores utilizados para demonstrar essa contribuição são a redução na quantidade de PA encontrados durante o processo de aprendizagem e o aumento da média das notas dos estudantes.

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

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

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.

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

4.2 Resultados experimentais

4.2.1 EAr Estáticos

A tabela 1 apresenta os resultados obtidos nos testes considerando EAr Estáticos. Cada experimento corresponde a uma CEA possível. As colunas que contém o símbolo %, correspondem à variação das outras abordagens em relação ao ADS.

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

Tabela 1. Comparativo para EAr Estático

Considerando os PAs, o ADS obteve uma redução de 54,1% em comparação a Dorça (2012) e de 69,1% em relação a Falci (2017). Destaca-se o Experimento 1 que apresentou uma redução nos PA de 73.6%, em relação a Dorça (2012). Nesse exemplo, o EAp inicial é igual ao EAr e, pode-se verificar o quanto o ADS contribuiu para acelerar a convergência, reduzindo os erros de reforço aplicados pelo AR.

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

No que tange à nota média obtida nos experimentos com EAr Estáticos com

carga de 60 conceitos, a Figura 2 apresenta dados comparativos contendo os 16 Experimentos para cada abordagem. Não foi possível comparar as notas com as outras abordagens pois não realizaram esses testes.




Figura 2: Comparação entre as abordagens no que tange à Média das Notas obtidas em cenários com EAr Estático

Fonte: Elaborado pelo autor

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

4.2.2 EAr Dinâmicos

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

	Dorça	ADS	%	Dorça	ADS	%
	Média Interações			Média PA		
Exp. 1	418.2	393	-6	58.2	33	-43.2
Exp. 2	426.6	404	-5.2	66.6	44	-33.8
Exp. 3	428.7	412.1	-3.8	68.7	52.1	-24.2
Exp. 4	424.8	406.9	-4.2	64.8	46.9	-27.6
Exp. 5	423.5	397.4	-6.1	63.5	37.4	-41
Exp. 6	433.8	404	-6.8	73.8	44	-40.4
Exp. 7	433.5	417.2	-3.7	73.5	57.2	-22.1
Exp. 8	428.1	396.5	-7.3	68.1	36.5	-46.3

Exp. 9	431.6	422.2	-2.1	71.6	62.2	-13
Exp. 10	431.0	397.7	-7.7	71	37.7	-46.8
Exp. 11	430.3	402.5	-6.4	70.3	42.5	-39.5
Exp. 12	440.5	421.8	-4.2	80.5	61.8	-23.2
Exp. 13	434.0	397.7	-8.3	74	37.7	-48.9
Exp. 14	435.3	406.1	-6.6	75.3	46.1	-38.6
Exp. 15	437.7	402.1	-8.1	77.7	42.1	-45.8
Exp. 16	443.6	411.6	-7.2	83.6	51.6	-38.2
Média	431.3	405.8	-5.9	71.3	45.8	-35.8

Tabela 2. Comparativo para EAr Dinâmico

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

A nota média obtida nos experimentos com EAr Dinâmico, é apresentada na Figura 3 com um gráfico comparativo entre os 16 Experimentos de cada abordagem. Novamente o ADS elevou a nota média dos estudantes em comparação à Dorça (2012), mesmo em cenário adverso com oscilação do EAr do estudante o ADS se manteve capaz de permitir a maximização do desempenho do estudante.




Figura 3: Comparação entre as abordagens no que tange à Média das Notas obtidas em cenários com EAr Dinâmico

Fonte: Elaborado pelo autor

5 | CONCLUSÃO E TRABALHOS FUTUROS

Este trabalho apresentou o ADS, uma adaptação da técnica de DS para aprimorar a convergência de um SAIE, com vistas a detectar e atualizar o EA do estudante para oferecer ao aluno um ensino personalizado. Levou-se em consideração que o EA do aluno muda ao longo do processo de ensino aprendizagem, necessitando de uma abordagem robusta que fosse apta a lidar com essa situação. Resultados experimentais apontaram redução na quantidade de interações bem como no número de PA em relação a trabalhos da literatura.

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

REFERÊNCIAS

- ARMSTRONG, Warren et al. **Dynamic algorithm selection using reinforcement learning**. In: Integrating AI and Data Mining, 2006. AIDM'06. International Workshop on. IEEE, 2006. p. 18-25.
- BLOOM, B. S. et al. **Taxonomy os educational objectives**. New York: David mckay co. Inc. 1956.
- CERQUEIRA, Teresa Cristina Siqueira et al. **Estilos de aprendizagem em universitários**. 2000.
- DAWSON, Chad; FORMATIONS, S. Rabin. **AI Game Programming Wisdom**. Charles River Media. Inc., Hingham, Massachusetts, USA, p. 272-281, 2002.
- DE SENA, Edson Batista et al. **Uma abordagem computacional para detecção automática de estilos de aprendizagem utilizando modelos ocultos de markov**. SIED: EnPED-Simpósio Internacional de Educação a Distância e Encontro de Pesquisadores em Educação a Distância, 2016.
- DORÇA, Fabiano Azevedo et al. **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**. 2012.
- DORÇA, Fabiano A. 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, v. 40, n. 6, p. 2092-2101, 2013.
- FALCI, Samuel Henrique et al. **Uma Nova Abordagem para Aplicação de Reforço em Sistemas Automáticos e Adaptativos de Detecção de Estilos de Aprendizagem**. Revista Eletrônica Argentina-Brasil de Tecnologias da Informação e da Comunicação, v. 1, n. 6, 2017.
- FELDER, Richard M. et al. **Learning and teaching styles in engineering education**. Engineering education, v. 78, n. 7, p. 674-681, 1988.
- GONÇALVES, André Vinícius. **Modelagem automática e dinâmica de estilos de aprendizagem em sistemas adaptativos e inteligentes para educação a distância: estudo comparativo entre duas abordagens**. 2016. Dissertação de Mestrado. UFVJM.
- HAIDER, M.; SINHA, A.; CHAUDHARY, B. **An Investigation of relationship between learning styles and performance of learners**. International Journal of Engineering Science and Technology, v. 2, n. 7, p. 2813-2819, 2010.
- HOOD, B. et al. **No evidence to back idea of learning styles**. The Guardian, March. 2017.

- KENSKI, Vani Moreira. **Tecnologias e ensino presencial e a distância**. Papirus Editora, 2003.
- KIRSCHNER, Paul A. **Stop propagating the learning styles myth**. *Computers & Education*, v. 106, p. 166-171, 2017.
- KIRSCHNER, Paul A.; VAN MERRIËNBOER, Jeroen JG. **Do learners really know best? Urban legends in education**. *Educational psychologist*, v. 48, n. 3, p. 169-183, 2013.
- KOLB, Alice Y. **The Kolb learning style inventory—version 3.1 2005 technical specifications**. Boston, MA: Hay Resource Direct, v. 200, p. 72, 2005.
- PASHLER, Harold et al. **Learning styles: Concepts and evidence**. *Psychological science in the public interest*, v. 9, n. 3, p. 105-119, 2008.
- PRICE, Linda. **Individual differences in learning: Cognitive control, cognitive style, and learning style**. *Educational Psychology*, v. 24, n. 5, p. 681-698, 2004.
- RAWSON, Kevin; STAHOVICH, Thomas F.; MAYER, Richard E. **Homework and achievement: Using smartpen technology to find the connection**. *Journal of Educational Psychology*, v. 109, n. 2, p. 208, 2017.
- RODRIGUES, Luiz Henrique Silva et al. **Análise comparativa de novas abordagens para modelagem automática e dinâmica de estilos de aprendizagem em sistemas adaptativos e inteligentes para educação**. In: Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE). 2016. p. 1076.
- SILVA, Júlio César da Costa et al. **Detecção Automática e Dinâmica de Estilos de Aprendizagem em Sistemas Adaptativos e Inteligentes utilizando Dynamic Scripting**. In: Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE). 2017. p. 1327.
- SILVA, Lisliê Lopes Vidal. **Estilos e estratégias de aprendizagem de estudantes universitários**. 2012. Tese de Doutorado. Universidade de São Paulo.
- SPRONCK, Pieter Hubert Marie. **Adaptive game AI**. Maastricht university, 2005.
- SPRONCK, Pieter et al. **Adaptive game AI with dynamic scripting**. *Machine Learning*, v. 63, n. 3, p. 217-248, 2006.
- SUTTON, Richard S.; BARTO, Andrew G. **Reinforcement learning: An introduction**. Cambridge: MIT press, 1998.
- THAWONMAS, Ruck; OSAKA, Syota. **A method for online adaptation of computer-game ai rulebase**. In: Proceedings of the 2006 ACM SIGCHI international conference on Advances in computer entertainment technology. ACM, 2006. p. 16.
- TRUONG, Huong May. **Integrating learning styles and adaptive e-learning system: Current developments, problems and opportunities**. *Computers in human behavior*, v. 55, p. 1185-1193, 2016.
- UBERABA, Universidade de. **Manual do Professor Tutor**. Uberaba, MG. 2016.
- VEENMAN, Marcel VJ; PRINS, Frans J.; VERHEIJ, Joke. **Learning styles: Self-reports versus thinking-aloud measures**. *British Journal of Educational Psychology*, v. 73, n. 3, p. 357-372, 2003.

SOBRE O ORGANIZADOR

Everson Mario Novak Possui graduação em Tecnologia em Sistemas para Internet, Especialização em Desenvolvimento Web e MBA em Gestão de TI pela Faculdade Educacional de Ponta Grossa (Faculdade UNIÃO). Atualmente está cursando Mestrado em Informática na PUCPR - Pontifícia Universidade Católica do Paraná é professor do curso de Sistemas de Informação na Faculdades Integradas de Itararé – FAFIT. Ainda como Professor pela PUCPR na TECPUC na unidade de Ponta Grossa. É Analista de Sistemas, programador e tem experiência na área de Ciência da Computação, com ênfase em Arquitetura de Sistemas de Computação, Agentes de Software e Inteligência artificial.

Agência Brasileira do ISBN

ISBN 978-85-85107-14-7



9 788585 107147