

A produção do conhecimento nas Ciências Exatas e da Terra

6,0 Gt CO₂

1,5 Gt CO₂

Ingrid Aparecida Gomes
(Organizadora)



Atena
Editora

Ano 2019

Ingrid Aparecida Gomes

(Organizadora)

A produção do conhecimento nas Ciências Exatas e da Terra

**Atena Editora
2019**

2019 by Atena Editora

Copyright © da Atena Editora

Editora Chefe: Profª Drª Antonella Carvalho de Oliveira

Diagramação e Edição de Arte: Lorena Prestes e Geraldo Alves

Revisão: Os autores

Conselho Editorial

- Prof. Dr. Alan Mario Zuffo – Universidade Federal 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
Profª Drª Cristina Gaio – Universidade de Lisboa
Prof. Dr. Constantino Ribeiro de Oliveira Junior – Universidade Estadual de Ponta Grossa
Profª Drª Daiane Garabeli Trojan – Universidade Norte do Paraná
Prof. Dr. Darllan Collins da Cunha e Silva – Universidade Estadual Paulista
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
Profª Drª Juliane Sant’Ana Bento – Universidade Federal do Rio Grande do Sul
Prof. Dr. Julio Candido de Meirelles Junior – Universidade Federal Fluminense
Prof. Dr. Jorge González Aguilera – Universidade Federal de Mato Grosso do Sul
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
Profª Drª Vanessa Lima Gonçalves – Universidade Estadual de Ponta Grossa
Prof. Dr. Willian Douglas Guilherme – Universidade Federal do Tocantins

Dados Internacionais de Catalogação na Publicação (CIP) (eDOC BRASIL, Belo Horizonte/MG)

P964 A produção do conhecimento nas ciências exatas e da terra [recurso eletrônico] / Organizadora Ingrid Aparecida Gomes. – Ponta Grossa (PR): Atena Editora, 2019. – (A produção do Conhecimento nas Ciências Exatas e da Terra; v. 1)

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

Inclui bibliografia

ISBN 978-85-7247-238-8

DOI 10.22533/at.ed.388190304

1. Ciências exatas e da terra – Pesquisa – Brasil. I. Gomes, Ingrid Aparecida. II. Série.

CDD 507

Elaborado por Maurício Amormino Júnior – CRB6/2422

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

2019

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

APRESENTAÇÃO

A obra “*A produção do conhecimento nas Ciências Exatas e da Terra*” aborda uma série de livros de publicação da Atena Editora, em seu I volume, apresenta, em seus 21 capítulos, discussões de diversas abordagens acerca do ensino e educação.

As Ciências Exatas e da Terra englobam, atualmente, alguns dos campos mais promissores em termos de pesquisas atuais. Estas ciências estudam as diversas relações existentes da Astronomia/Física; Biodiversidade; Ciências Biológicas; Ciência da Computação; Engenharias; Geociências; Matemática/ Probabilidade e Estatística e Química.

O conhecimento das mais diversas áreas possibilita o desenvolvimento das habilidades capazes de induzir mudanças de atitudes, resultando na construção de uma nova visão das relações do ser humano com o seu meio, e, portanto, gerando uma crescente demanda por profissionais atuantes nessas áreas.

A ideia moderna das Ciências Exatas e da Terra refere-se a um processo de avanço tecnológico, formulada no sentido positivo e natural, temporalmente progressivo e acumulativo, segue certas regras, etapas específicas e contínuas, de suposto caráter universal. Como se tem visto, a ideia não é só o termo descritivo de um processo e sim um artefato mensurador e normalizador de pesquisas.

Neste sentido, este volume é dedicado aos trabalhos relacionados a ensino e aprendizagem. A importância dos estudos dessa vertente, é notada no cerne da produção do conhecimento, tendo em vista o volume de artigos publicados. Nota-se também uma preocupação dos profissionais de áreas afins em contribuir para o desenvolvimento e disseminação do conhecimento.

Os organizadores da Atena Editora, agradecem especialmente os autores dos diversos capítulos apresentados, parabenizam a dedicação e esforço de cada um, os quais viabilizaram a construção dessa obra no viés da temática apresentada.

Por fim, desejamos que esta obra, fruto do esforço de muitos, seja seminal para todos que vierem a utilizá-la.

Ingrid Aparecida Gomes

SUMÁRIO

CAPÍTULO 1	1
A CONTEXTUALIZAÇÃO DA CONSTRUÇÃO DE UM CURSO DE EXTENSÃO UNIVERSITÁRIA VOLTADO PARA O ENSINO DE ASTRONOMIA NA EDUCAÇÃO BÁSICA	
Rachel Zuchi Faria Daniel Rutkowski Soler Evonir Albrecht Marcos Rogerio Calil Marcos Pedroso Marília Rios	
DOI 10.22533/at.ed.3881903041	
CAPÍTULO 2	11
DETECÇÃO AUTOMÁTICA E DINÂMICA DE ESTILOS DE APRENDIZAGEM DE ESTUDANTES EM SISTEMAS DE GESTÃO DE APRENDIZAGEM UTILIZANDO MODELOS OCULTOS DE MARKOV E APRENDIZAGEM POR REFORÇO	
Arthur Machado França de Almeida Luciana Pereira de Assis Alessandro Vivas Andrade Cristiano Grijó Pitangui	
DOI 10.22533/at.ed.3881903042	
CAPÍTULO 3	29
USO DE SOFTWARE COMO FERRAMENTA DE ENSINO-APRENDIZAGEM	
Francisco de Assis Martins Ponce Maria Jorgiana Ferreira Dantas Irla Gonçalves Barbosa	
DOI 10.22533/at.ed.3881903043	
CAPÍTULO 4	36
ESPAÇO E MEMÓRIA NA CONSTITUIÇÃO DA CRIANÇA: APROXIMAÇÕES COM A CARTOGRAFIA ESCOLAR	
Thiago Luiz Calandro João Pedro Pezzato	
DOI 10.22533/at.ed.3881903044	
CAPÍTULO 5	58
FORMAÇÃO DE PROFESSORES DE CIÊNCIAS: UMA LEITURA PEIRCEANA DE NÍVEIS DE SIGNIFICADO DAS ESTAÇÕES DO ANO	
Daniel Trevisan Sanzovo Carlos Eduardo Laburú	
DOI 10.22533/at.ed.3881903045	
CAPÍTULO 6	72
MAPAS CONCEITUAIS E SEU USO COMO FERRAMENTA DE AVALIAÇÃO DE APRENDIZAGEM E ENSINO DE CONCEITOS DE ASTRONOMIA: UM ESTUDO DE CASO	
Marconi Frank Barros Sérgio Mascarello Bisch	

DOI 10.22533/at.ed.3881903046

CAPÍTULO 7 81

VERIFICAÇÃO DA LEI DE TITIUS-BODE EM SISTEMAS EXOPLANETÁRIOS E DETERMINAÇÃO DE FÓRMULAS QUE DESCREVEM AS DISTÂNCIAS PLANETAS-ESTRELA

Vinícius Lima dos Santos
Marcos Rogerio Calil
Manoel de Aquino Resende Neto

DOI 10.22533/at.ed.3881903047

CAPÍTULO 8 97

A RELEVÂNCIA DO APOIO DIDÁTICO NA GRADUAÇÃO DE METEOROLOGIA: ATIVIDADE DO PROGRAMA DE EDUCAÇÃO TUTORIAL

Leticia Prechesniuki Alves
Laíz Cristina Rodrigues Mello
André Becker Nunes

DOI 10.22533/at.ed.3881903048

CAPÍTULO 9 102

UM ESTUDO SOBRE A INFLUÊNCIA DAS DISTINTAS DEFINIÇÕES DE ANEL

Elisandra Cristina Souto
Marlon Soares

DOI 10.22533/at.ed.3881903049

CAPÍTULO 10 109

UMA INTRODUÇÃO AO ENSINO DA DINÂMICA DOS FLUIDOS COMPUTACIONAL (DFC) UTILIZANDO SCILAB®

Nicolly Coelho
Eduardo Vieira Vilas Boas
Paulo Vataavuk

DOI 10.22533/at.ed.38819030410

CAPÍTULO 11 125

METODOLOGIA PARA O ENSINO DE FÍSICA: ENTRE DEUSES MITOLÓGICOS E ASTROS

Bárbara de Almeida Silvério
Ricardo Yoshimitsu Miyahara

DOI 10.22533/at.ed.38819030411

CAPÍTULO 12 134

AVALIAÇÃO DAS METODOLOGIAS ATIVAS APLICADAS DURANTE O SEMESTRE 2018.1 - DISCIPLINA ECOLOGIA GERAL

Matheus Cordeiro Façanha
Márcia Thelma Rios Donato Marino
Leonardo Holanda Lima
Vanessa Oliveira Liberato
Suellen Galvão Moraes
Diego Oliveira Ferreira

DOI 10.22533/at.ed.38819030412

CAPÍTULO 13 140

**OS CAMINHOS QUE LEVAM ÀS CIDADES ACESSÍVEIS: O PANORAMA
BRASILEIRO E O PREMIO ACCESS. CITY PARA AS CIDADES DA EU**

Kaíto Loui Sousa do Amaral
Vlândia Barbosa Sobreira
Angélica de Castro Abreu

DOI 10.22533/at.ed.38819030413

CAPÍTULO 14 148

**A UTILIZAÇÃO DO DESENHO A MÃO LIVRE NO AUXÍLIO DO ENSINO DO
DESENHO TÉCNICO**

Giulia Queiroz Primo
Beatriz Maria Moreira Aires
Sarah Bastos de Macedo Carneiro

DOI 10.22533/at.ed.38819030414

CAPÍTULO 15 154

**PROJETO GAMA: UM EXEMPLO BEM-SUCEDIDO DO ENSINO COOPERATIVO
NA UFPEL**

João Inácio Moreira Bezerra
Rejane Pergher
Cícero Nachtigall

DOI 10.22533/at.ed.38819030415

CAPÍTULO 16 161

**CURSOS DE AGRONOMIA E ENGENHARIA FLORESTAL DA UNIVERSIDADE
ESTADUAL DE GOIÁS (UEG) SOB OLHAR DOS EGRESSOS**

Camila Lariane Amaro
Adalberto Antunes de Medeiros Neto
Fábio Santos Matos

DOI 10.22533/at.ed.38819030416

CAPÍTULO 17 169

**A EXPECTATIVA DOS ALUNOS PARA COM A DISCIPLINA PLANEJAMENTO DA
PAISAGEM NO CURSO DE ARQUITETURA E URBANISMO DA UNIVERSIDADE
DE FORTALEZA - UNIFOR**

Ravena Alcântara Holanda Rocha
Newton Célio Becker de Moura

DOI 10.22533/at.ed.38819030417

CAPÍTULO 18 175

**A INFLUÊNCIA DO PROJETO DE ARQUITETURA DE INTERIORES COMERCIAL
NO FORTALECIMENTO DA IDENTIDADE VISUAL**

Raíssa Gomes Bastos Capibaribe
Maria das Graças do Carmo Dias
Ana Caroline de Carvalho Lopes Dantas Dias

DOI 10.22533/at.ed.38819030418

CAPÍTULO 19	185
ARQUITETURA DE INTERIORES COMO SINALIZADOR DA APRENDIZAGEM	
Thaiany Veríssimo Andrade Batista de Moraes	
Ana Caroline de Carvalho Lopes Dantas Dias	
DOI 10.22533/at.ed.38819030419	
CAPÍTULO 20	192
IMPACTO CONSTRUTIVO NO ENTORNO DE BENS HISTÓRICOS. CASO DO CENTRO DE FORTALEZA-CE	
Naiana Madeira Barros Pontes Camilo	
Anderson Yago Sampaio Brito	
André Soares Lopes	
DOI 10.22533/at.ed.38819030420	
CAPÍTULO 21	205
O CONTRASTE DAS ABORDAGENS DE PLANEJAMENTO URBANO NO PROCESSO DE ENSIO-APRENDIZAGEM	
Mariana Saraiva de Melo Pinheiro	
Paulo Estênio da Silva Jales	
André Araújo Almeida	
DOI 10.22533/at.ed.38819030421	
SOBRE A ORGANIZADORA.....	220

DETECÇÃO AUTOMÁTICA E DINÂMICA DE ESTILOS DE APRENDIZAGEM DE ESTUDANTES EM SISTEMAS DE GESTÃO DE APRENDIZAGEM UTILIZANDO MODELOS OCULTOS DE MARKOV E APRENDIZAGEM POR REFORÇO

Arthur Machado França de Almeida

Instituto Federal do Norte de Minas Gerais
(IFNMG)

Araçuaí – Minas Gerais

Luciana Pereira de Assis

Universidade Federal dos Vales do Jequitinhonha
e Mucuri (UFVJM)

Diamantina – Minas Gerais

Alessandro Vivas Andrade

Universidade Federal dos Vales do Jequitinhonha
e Mucuri (UFVJM)

Diamantina – Minas Gerais

Cristiano Grijó Pitangui

Universidade Federal de São João del-Rei (UFSJ)

São João Del Rei – Minas Gerais

RESUMO: Os Sistemas de Gestão de Aprendizagem (*Learning Management Systems - LMS*) surgiram para auxiliar o processo ensino-aprendizagem na Educação à Distância (EaD). Os LMS são ferramentas essenciais no processo da EaD, mas eles não oferecem um suporte adequado ao usuário, já que o mesmo conteúdo é apresentado para todos os estudantes. Sendo assim, a adaptação desses sistemas ao estudante, de acordo com seu Estilo de Aprendizagem (EA), tem sido frequentemente discutida. Para realizar a adaptação, o sistema deve conhecer o EA do aluno. Dessa forma, diversas abordagens para detecção automática

de EA vêm sendo estudadas. A abordagem proposta neste trabalho utiliza Modelos Ocultos de Markov (HMM) e uma abordagem por reforço para detectar o EA do estudante. A inferência do EA é realizada pelo Algoritmo de Viterbi. Os resultados obtidos apresentam média de 91% de inferências corretas, demonstrando ser uma abordagem eficaz para a utilização em LMS.

PALAVRAS-CHAVE: Estilos de Aprendizagem. Modelos Ocultos de Markov. Aprendizagem por Reforço. Sistemas de Gestão de Aprendizagem.

ABSTRACT: Learning Management Systems (LMS) have emerged to support the teaching-learning process in Distance Education (EAD). LMS are essential tools in the EAD process, but they do not offer adequate support to the user, since the same content is presented to all students. Thus, the adaptation of these systems to the student, according to their Learning Style (EA), has been frequently discussed. To perform the adaptation, the system must know the student's EE. In this way, several approaches for automatic detection of AE have been studied. The approach proposed in this work uses Hidden Markov Models (HMM) and a reinforcement approach to detect student AE. The inference of EA is performed by the Viterbi Algorithm. The obtained results present a 91% average of correct inferences, proving to be an effective approach for the use in LMS.

KEYWORDS: Learning Styles. Hidden Markov Models. Reinforcement Learning. Learning Management Systems.

1 | INTRODUÇÃO

A Educação a Distância (EaD) tem crescido mundialmente nos últimos anos. No Brasil, a realidade não é diferente, visto que a EaD é incentivada pela Lei de Diretrizes e Bases da Educação (BRASIL, 1996). Segundo dados do Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP), o número de cursos de graduação a distância no Brasil cresceu 571%, entre 2003 e 2006. Entre 2011 e 2014, esse número cresceu 213% (BITTENCOURT & MERCADO, 2014).

Com a criação da World Wide Web por Tim Berners-Lee na década de 1990, a internet começou a se popularizar. A popularização dessa tecnologia é um marco para a EaD, já que a internet facilita o acesso aos cursos. Nesse contexto, o conceito de e-learning começa a ser difundido. O e-learning pode ser entendido como a utilização dos computadores e da internet como meio para proporcionar a EaD (ROSENBERG, 2001).

Nesse sentido, para a utilização da internet como um meio que permite facilitar e proporcionar a EaD e o e-learning, surgiram os Ambientes Virtuais de Aprendizagem (AVAs), que são implementações dos Sistemas de Gestão de Aprendizagem (*Learning Management Systems - LMS*). Os AVAs são sistemas de ensino-aprendizagem que proporcionam aos professores e estudantes a criação e a participação nas aulas (VAZ et al., 2010).

No entanto, por se tratar de um LMS, os AVAs tradicionais não oferecem um suporte adequado ao usuário, já que o mesmo conteúdo é apresentado para todos os estudantes. Considerar diferenças em relação a estilos de aprendizagem, conhecimento prévio, habilidades cognitivas, interesses, motivação, dentre outras, tem um efeito importante na melhoria do progresso dos estudantes e nos resultados de aprendizagem (BRUSILOVSKY & MILLAN, 2007; GRAF et al., 2010). Dessa forma, é importante que o LMS forneça ao estudante um conteúdo adaptado, de acordo com seus Estilos de Aprendizagem (EAs).

Porém, a imprecisão na correta identificação dos EAs do estudante é um problema. As abordagens tradicionais para detecção de EAs, baseadas em questionários, não são eficientes, pois além da imprecisão, tem-se ainda o grau de incerteza associado a questionários para auto-avaliação de EAs. Diante desse cenário, as abordagens automáticas para detecção de EAs tem sido frequentemente discutidas.

O presente trabalho propõe uma abordagem eficiente para detecção de EAs. A proposta utiliza Modelos Ocultos de Markov (HMM) para a modelagem do estudante e o FSLSM como modelo de descrição de EAs. Uma abordagem por reforço foi implementada para corrigir os EAs. A inferência do EA probabilístico do aluno é

realizada utilizando o Algoritmo de Viterbi.

2 | REFERENCIAL TEÓRICO

2.1 Estilos de Aprendizagem e o modelo FSLSM

O modelo educacional brasileiro, da forma como é concebido atualmente, é um processo homogêneo (CAVELLUCCI et al., 2003). Ou seja, em nenhum momento do processo considera-se que as pessoas possuem formas diferentes de aprender, que são moldadas por suas características psicológicas. As diferentes formas como os indivíduos aprendem derivam de suas características psicológicas, e são conhecidas como Estilos de Aprendizagem.

EAs podem ser entendidos como uma predisposição que o estudante tem em adotar uma estratégia particular de aprendizagem (SCHMECK, 1988). Felder & Brent (2005) definem EAs como características cognitivas que servem como um indicador de como o estudante percebe, interage e responde aos ambientes de aprendizagem.

Com o passar dos anos, vários modelos foram desenvolvidos para a estruturação e descrição de EAs. Os modelos de estilos de aprendizagem servem para categorizar e classificar as diferentes formas de aprender, receber e processar as informações (ROSÁRIO et al., 2006). Os modelos mais conhecidos e utilizados são o de Kolb, o Myers-Briggs Type Indicator (MBTI), o modelo de Pask, o modelo proposto por Honey e Mumford e o FSLSM.

O Felder-Silverman Learning Style Model (FSLSM) é um modelo baseado em 4 dimensões: entrada, percepção, processamento e organização; sendo que cada uma das dimensões é dividida em duas subdimensões (FELDER et al., 1988). As dimensões e subdimensões se caracterizam da seguinte forma (DORÇA, 2012; SILVA, 2012; FELDER et al., 1988; FELDER & BRENT, 2005; GRANITO, 2008):

- Entrada: refere-se ao tipo de informação que é mais efetivamente percebida. Divide-se em Visual, onde a preferência é por figuras, diagramas, gráficos; e Verbal, onde a preferência é por explicação escrita ou falada.
- Percepção: refere-se ao tipo de informação que o estudante prefere receber. Divide-se em Sensitivo, onde a preferência é por fatos, datas, dados experimentais, exemplos; e Intuitivo, onde a preferência é por teorias, definições, modelos matemáticos, símbolos e diagramas.
- Processamento: refere-se à preferência do estudante sobre o processamento da informação. Divide-se em Ativo, onde a preferência é por experimentação ativa, discussões, trabalho em grupo; e Reflexivo, onde a preferência é por trabalho individual, introspecção, reflexão, teoria.
- Organização: essa dimensão refere-se à preferência de progressão do estudante dentro do curso. Divide-se em Sequencial, onde a preferência é por uma progressão lógica e linear no conteúdo; e Global, onde a preferência é por uma visão geral do todo, aprendendo aleatoriamente.

Os estudantes apresentam tendências de preferências em cada uma das quatro dimensões (FELDER & SPURLIN, 2005). As dimensões definem as formas de receber, processar, perceber e organizar a informação (DORÇA, 2012). Uma importante característica do FSLSM é que suas dimensões não são estáticas, ou seja, um estudante pode tender de um EA para outro, dentro de uma mesma dimensão.

2.2 Modelos Ocultos de Markov

O formalismo do Modelo Oculto de Markov (*Hidden Markov Model - HMM*) foi descrito pela primeira vez no final dos anos 1960, por (BAUM & PETRIE, 1966) e (BAUM et al., 1967). Inicialmente, os modelos eram aplicados para reconhecimento de palavras. Com o tempo, eles passaram a ser utilizados também em outras áreas, mais recentemente na teoria dos jogos (WAGHABI & BENEVIDES, 2009) e simulação e modelagem do fluxo de rios intermitentes (BARBOSA, 2014).

Um Modelo Oculto de Markov (Hidden Markov Model - HMM) é um formalismo que representa uma variação das cadeias de Markov, pois além de apresentar as distribuições de probabilidades comuns às cadeias de Markov, ele possui também uma distribuição baseada em observação e comportamento do ambiente em que está inserido (RABINER, 1989).

Um HMM é um processo duplamente estocástico. Um dos processos é não visível e não observável, e este compõe os estados ocultos do modelo. O outro é um processo que produz uma sequência de observações e compõe os estados observáveis do modelo. Dessa forma, o primeiro processo, não visível, pode ser observado pelo segundo processo estocástico, que produz a sequência de observações (RABINER, 1989).

De forma genérica, um HMM pode ser descrito pelo conjunto de parâmetros do modelo $\lambda = (a, b, \pi)$, onde π representa o vetor de probabilidades inicial da cadeia oculta de Markov, A representa a matriz de transição entre os estados e B representa a matriz de probabilidade de emissão de estados observáveis (SENA et al., 2016).

2.3 Aprendizagem por Reforço

Quando considera-se a natureza da aprendizagem, a primeira ideia a ocorrer é a de que aprende-se interagindo com o ambiente (SUTTON & BARTO, 1998). Uma criança, por exemplo, ao agitar os braços e brincar, está realizando uma conexão sensorial e motora com o ambiente (SUTTON & BARTO, 1998). O exercício dessa conexão produz várias informações sobre causa e efeito, sobre as consequências de suas ações e sobre o que fazer para atingir os objetivos (SUTTON & BARTO, 1998). Dessa forma, a ideia de aprendizagem por meio da interação com o ambiente está relacionada a diversas teorias da aprendizagem.

A Aprendizagem por Reforço (AR) é uma técnica de Aprendizado de Máquina que busca aprender como mapear estados e ações de forma a maximizar um sinal de

recompensa (SUTTON & BARTO, 1998). AAR envolve um agente que percebe e atua em um ambiente, realizando ações que afetam o estado do ambiente e (ARMSTRONG et al., 2006). O agente recebe recompensas como forma de medida de sucesso de suas ações (ARMSTRONG et al., 2006). Dessa forma, na AR o agente deve aprender qual o melhor comportamento, por meio de “tentativa e erro”, interagindo com um ambiente dinâmico (KAELBLING et al., 1996).

Ao contrário da Aprendizagem Supervisionada, na AR o agente não tem conhecimento se uma ação é ótima (ARMSTRONG et al., 2006). Ele deve descobrir quais ações produzem melhores recompensas experimentando-as (SUTTON & BARTO, 1998). A ação tomada pode afetar não somente a recompensa imediata, mas também todas as recompensas subseqüentes (SUTTON & BARTO, 1998).

A AR é bastante utilizada quando o agente deve atuar em ambientes desconhecidos, onde não se tem conhecimento sobre qual o comportamento correto em determinadas situações (DORÇA, 2012). Dessa forma, ela se difere da Aprendizagem Supervisionada por não possuir uma representação de pares de entrada/saída (DORÇA, 2012). Ao realizar determinada ação, o agente é informado sobre o estado alcançado e adquire experiência sobre suas ações (DORÇA, 2012).

A construção de um agente para atuar na AR envolve a definição de suas percepções e ações, e o reforço do ambiente (DORÇA, 2012). Sendo assim, não é preciso definir como o agente deve agir ou qual objetivo deve alcançar, já que todo o aprendizado será conduzido de maneira constante e incremental por intermédio do reforço (DORÇA, 2012).

3 | ABORDAGEM PROPOSTA

Os LMS fornecem aos alunos diversos recursos de aprendizagem, como vídeos, fóruns, chat, imagens, dentre outros. Esses recursos são conhecidos como Objetos de Aprendizagem (OA). Os LMS armazenam as diversas interações do estudante com os OAs e com o sistema em geral. Dessa forma, essas interações estudante/sistema podem ser pensadas como observações que o LMS faz do estudante.

No FSLSM, cada dimensão possui duas subdimensões. As subdimensões, por sua vez, estão associadas a determinadas observações ou Objetos de Aprendizagem. Sendo assim, cada subdimensão de cada dimensão pode ser pensada como um estado que o LMS deseja identificar: um estado oculto.

Os HMMs, como visto anteriormente, são estruturas capazes de armazenar probabilidades de transições entre estados observáveis e estados ocultos. Esses estados podem ser modelados por meio de uma matriz de emissão de estados observáveis e uma matriz de transição de estados ocultos.

Pode-se então modelar um HMM para cada dimensão do FSLSM, com os seguintes elementos: os estados observáveis do modelo são representados pelas

interações do aluno com o sistema; os estados ocultos do modelo são representados pelas subdimensões da dimensão do FLSM. Para a modelagem, foi utilizada a base de dados disponível em Yannibelli, Godoy & Amandi (2006), que apresenta interações reais de estudantes com um sistema de aprendizagem em oito disciplinas. As interações presentes na base de dados são:

- Participação em fóruns: refere-se à participação do estudante no fórum da disciplina. O estudante pode não participar do fórum, pode apenas ler mensagens, ler e responder mensagens ou enviar mensagens para iniciar uma discussão.
- Participação em chats: refere-se à participação do estudante em chats. O estudante pode não participar de chats, apenas ler as mensagens, ou enviar mensagens e ler as mensagens de outros estudantes.
- Leitura de material: as disciplinas podem apresentar tanto materiais abstratos, como teorias, quanto materiais concretos, como exemplos e aplicações. O estudante pode: observar apenas o material abstrato; observar todo o material abstrato e parte do concreto; observar partes iguais de material abstrato e concreto; observar todo o material concreto e parte do abstrato; ou observar somente o material concreto.
- Acesso a exemplos: as disciplinas oferecem uma série de exemplos sobre o conteúdo abordado. O estudante pode não assistir aos exemplos, assistir todos os exemplos ou assistir parte deles. Sendo assim, foi considerado que o estudante: pode assistir entre 0 e 10% dos exemplos; entre 10% e 30%; entre 30% e 50%; entre 50% e 70%; ou mais que 70% dos exemplos.
- Exercícios feitos: as disciplinas oferecem exercícios aos estudantes para fixação do conteúdo. O estudante pode não fazer nenhum exercício, fazer todos os exercícios ou alguns deles. Sendo assim, foi considerado que o estudante pode: fazer entre 0% e 10% dos exercícios; entre 10% e 30%; entre 30% e 50%; entre 50% e 70%; ou mais que 70% dos exercícios.
- Tempo de Entrega do exame: as disciplinas oferecem exames, sendo que os estudantes consomem determinado tempo para realizar a entrega da avaliação. Sendo assim, o estudante pode: utilizar menos que 40% do tempo determinado para o exame; entre 40% e 50% do tempo; entre 50% e 60% do tempo; entre 60% e 70% do tempo; ou mais que 70% do tempo do exame.
- Revisão do exame: o exame pode ser revisado pelo aluno, como parte do tempo dado para realizar a avaliação. Sendo assim, o estudante pode: usar menos que 5% do tempo dado para revisão; usar entre 5% e 10% do tempo; usar entre 10% e 15% do tempo; usar entre 15% e 20% do tempo; ou usar mais que 20% do tempo dado.
- Mudança nas respostas: os estudantes podem alterar alguma resposta antes da entrega da avaliação. Sendo assim, os estudantes podem: alterar menos que 10% das respostas; alterar entre 10% e 30% das respostas; alterar entre 30% e 50% das respostas; alterar entre 50% e 70% das respostas; ou alterar mais que 70% das respostas.
- Acesso à informação: o acesso aos itens de determinada disciplina pode ser realizado de forma totalmente sequencial (da forma como foram propostos); de forma aleatória, fora da ordem em que foram propostos; ou o estudante pode utilizar de uma combinação das duas formas.

Cada uma dessas informações obtidas da base de dados do sistema pode ser categorizada em uma dimensão do FLSM. Elas irão compor os estados observáveis

do modelo, sendo que cada modelo irá representar uma dimensão do FSLSM. Sendo assim, cada dimensão do FSLSM será representada por estados ocultos (subdimensões da dimensão do FSLSM) e por estados observáveis (observações da interação entre o aluno e o sistema).

A dimensão Processamento possui as subdimensões ativo e reflexivo, que na modelagem aqui proposta vão compor os estados ocultos do HMM. Já para os estados observáveis, foram utilizadas duas informações: participação em fórum e participação em chat. Estudantes reflexivos tendem a não participar de chats e fóruns, enquanto os estudantes ativos tendem a participar dos dois (YANNIBELLI; GODOY; AMANDI, 2006).

A dimensão Percepção possui as subdimensões sensitivo e intuitivo, que compõem os estados ocultos do HMM. Como estados observáveis, foram utilizadas as seguintes informações: leitura de material, acesso a exemplos, exercícios feitos, tempo de entrega do exame, revisão do exame e mudança nas respostas. Os estudantes sensitivos preferem material concreto, tendem a acessar mais exemplos, fazem todos os exercícios e revisam cuidadosamente as avaliações. Os estudantes intuitivos preferem abstrações, tendem a não acessar muitos exemplos das disciplinas, não fazem todos os exercícios propostos e não realizam uma revisão cuidadosa das avaliações (YANNIBELLI; GODOY; AMANDI, 2006).

A dimensão Organização possui as subdimensões sequencial e global, que compõem os estados ocultos do HMM. Como estados observáveis, foi utilizada a informação referente à forma de acesso à informação. O estudante sequencial prefere acessar os itens de determinada disciplina de forma sequencial (como foram propostos), enquanto o estudante global prefere acessar o conteúdo de forma aleatória e não seguir uma organização linear do conteúdo (YANNIBELLI; GODOY; AMANDI, 2006).

A dimensão Entrada do FSLSM não será modelada nessa abordagem, pois a base de dados utilizada não possui informações sobre observações relativas à esta dimensão. No entanto, a modelagem da dimensão Entrada pode ser facilmente incorporada à esta abordagem, seguindo a mesma linha das outras dimensões.

Feitas as devidas observações, foram produzidos 3 HMMs, sendo um para a dimensão Processamento, outro para Percepção e outro para Organização. A Figura 1 representa o HMM para a dimensão processamento do FSLSM. As outras dimensões seguem o mesmo padrão.

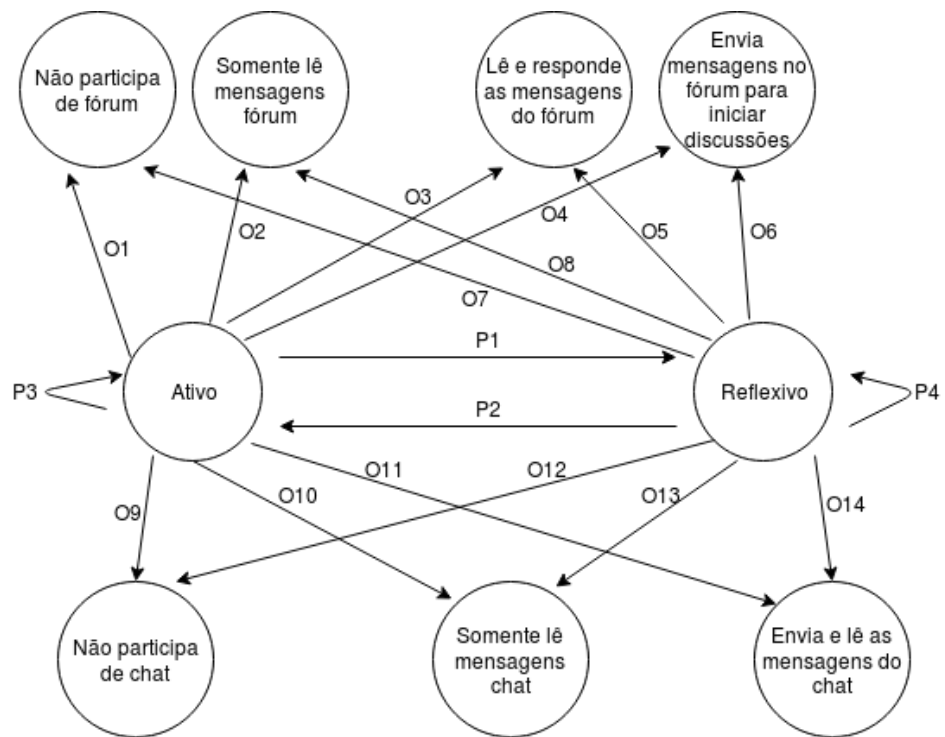


Figura 1 - Modelo Oculto de Markov para a Dimensão Processamento

Na Figura 1, os estados “Ativo” e “Reflexivo” compõem os estados ocultos do modelo. Os estados “Não participa de fórum”, “Somente lê mensagens fórum”, “Lê e responde as mensagens do fórum”, “Envia mensagens no fórum para iniciar discussões”, “Não participa de chat”, “Somente lê mensagens chat”, “Envia e lê as mensagens do chat” compõem os estados observáveis do modelo.

A transição entre os estados é representada por meio de probabilidades. Dessa forma, as probabilidades P1, P2, P3 e P4 representam a matriz de transição de estados ocultos do modelo. Já as probabilidades O1, O2, O3, O4, O5, O6, O7, O8, O9, O10, O11, O12, O13 e O14 representam a matriz de emissão dos estados observáveis do modelo.

Para cada uma das observações, foi associado um número inteiro para ser identificado pelo algoritmo. Dessa forma, para “Participação em Fórum”, por exemplo, a observação “Não participa de fórum” possui o valor 0; a observação “Somente lê as mensagens do fórum” possui o valor 1; a observação “Lê e responde as mensagens do fórum” possui o valor 2; e a observação “Envia mensagens no fórum para iniciar discussões” possui o valor 3. Para as outras observações, seguiu-se a mesma lógica.

O Algoritmo de Viterbi é utilizado nos HMMs para solucionar o Problema do Reconhecimento, que está relacionado a descobrir qual a melhor sequência de estados ocultos que influenciou na geração dos estados observáveis (ALAMINO, 2005). Ele é a solução mais viável computacionalmente para se resolver esse problema, dado uma grande quantidade de estados (NGUYEN, 2013). Na modelagem de EA por meio de HMM, o Algoritmo de Viterbi possui um papel fundamental, já que ele irá realizar a inferência do EA probabilístico do modelo.

O algoritmo proposto foi estruturado para funcionar por meio de disciplinas e alunos. Sendo assim, para cada aluno, em cada disciplina, o HMM é atualizado com as novas observações (atualiza-se a matriz de emissão de observáveis) e o Algoritmo de Viterbi é executado novamente para inferir o EA probabilístico. Caso a performance do aluno seja inferior a 60, o modelo recebe um reforço na matriz de transição de estados ocultos. Nas subseções seguintes, serão abordados alguns aspectos importantes da abordagem: a abordagem por reforço e o pseudocódigo do algoritmo proposto.

3.1 Abordagem por Reforço

Após cada disciplina e o cômputo das observações a ela relacionadas, a matriz de transição dos estados observáveis do HMM é atualizada com os novos valores e o Algoritmo de Viterbi é executado novamente para o cálculo do EA Probabilístico. Caso a performance do aluno seja inferior a 60, a matriz de transição de estados ocultos é atualizada mediante a Aprendizagem por Reforço. Dessa forma, a abordagem por reforço busca aproximar o EA Probabilístico do EA Real do estudante.

O algoritmo de reforço atualiza as probabilidades de transição entre os estados ocultos do HMM. Para o cálculo do reforço, foi implementada uma abordagem proposta em Dorça (2012). Na abordagem, o cálculo do reforço é baseado no algoritmo *Q-Learning* e é realizado basicamente por meio de duas variáveis: o desempenho simulado do estudante e a distância entre o EA Real e o EA Probabilístico.

Em sua abordagem, Dorça (2012) propôs o PESDE - Processo Estocástico para Simulação do Desempenho do Estudante. O PESDE é um modelo probabilístico que implementa o aspecto não determinístico existente no processo de aprendizagem e desempenho do estudante (DORÇA, 2012). O modelo permite simular a influência de EA na aprendizagem, sem desconsiderar os diversos outros fatores que podem influenciar no processo de aprendizagem (DORÇA, 2012).

O PESDE utiliza o EA Real para o cálculo do desempenho do estudante. Essa variável é necessária para descobrir a quantidade de preferências não satisfeitas ($Qpns$), que corresponde à quantidade de EA presentes no EA Real e que não são contemplados no EA Probabilístico. O cálculo da performance (PFM) do aluno realizado pelo PESDE é dado pela Equação 1.

$$PFM = 100 - (Qpns * K * \beta) \quad (1)$$

Como $0 \leq Qpns \leq 5$, a constante K foi definida pelo autor com o valor 20, pois dessa forma o valor de PFM estará no intervalo $0 \leq PFM \leq 100$. A variável β é um fator aleatório entre 0 e 1, que representa os diversos fatores, além do EA, que podem influenciar no desempenho do estudante (DORÇA, 2012).

Já a Distância Entre Estilos de Aprendizagem (DEA) é uma variável que armazena a diferença entre os EA de determinada dimensão do EA Probabilístico. Uma DEA baixa (próxima de zero) indica que o EA do estudante ainda é desconhecido. Uma DEA alta indica que o EA do estudante já foi descoberto e que ele possui forte preferência

por aquele EA.

Na fórmula da DEA, calcula-se a distância entre os estilos probabilísticos. A distância é obtida utilizando sempre o módulo, para a garantia de obtenção de valores positivos. Sendo assim, considerando que cada dimensão do FSLSM possui duas subdimensões, a fórmula para cálculo da DEA é dada pela Equação 2, onde di_A e di_B representam os valores (probabilidades) de preferência em cada uma das subdimensões.

$$DEA = |di_A - di_B| \quad (2)$$

Dadas as equações 1 e 2, o cálculo do reforço é dado pelas duas variáveis previamente explicadas, a saber, o desempenho simulado do estudante e a distância entre os estilos de aprendizagem. A Equação 3 foi utilizada para o cálculo do reforço. Ela retorna um valor entre 0 e 1, que é o valor que irá atualizar as probabilidades de transição entre os estados. Sendo assim, quando a performance do aluno for inferior a 60, o valor do reforço será acrescido de forma a maximizar a probabilidade de transição entre o EA Probabilístico do Modelo do Estudante e outro EA da dimensão. De forma análoga, esse valor será decrescido de forma a minimizar a probabilidade de transição entre outro EA da dimensão e o EA Probabilístico.

$$R = 1 / PFM * DEA \quad (3)$$

Assuma, como exemplo, a dimensão Processamento, um estudante com EA Probabilístico Reflexivo, um valor de PFM igual a 49 e a DEA igual a 0,25. Como a PFM é menor que 60, um reforço será aplicado no modelo. O valor do reforço, segundo a Equação 3, será 0,08. Sendo assim, o algoritmo irá acrescentar 0,08 na transição entre Reflexivo e Ativo e irá decrementar 0,08 na transição entre Reflexivo e Reflexivo. Dessa forma, levando-se em consideração a PFM baixa do aluno e que esta pode ter sido causada pelo Modelo do Estudante não corresponder à realidade, o reforço busca obter uma aproximação de outro EA, que pode ser o EA Real do estudante.

3.2 Algoritmo Proposto

O algoritmo proposto neste trabalho inclui a modelagem por meio dos HMMs e a abordagem por reforço. Para facilitar o entendimento, foi elaborado o pseudocódigo do algoritmo, conforme constante na Figura 2.

Algorithm 2 Algoritmo Proposto

```
1: para aluno ← 1 até N faça
2:   lerAlunoArquivo();
3:   criaHMMs();
4:   para disciplina ← 1 até 8 faça
5:     atualizaHMMs();
6:     infereEAProbabilistico();
7:     PFM = calculaPerformance();
8:     se PFM < 60 então
9:       calculaReforco();
10:      aplicaReforco();
11:    fim se
12:  fim para
13: fim para
```

Figura 2 - Algoritmo Proposto

O algoritmo inicia com a leitura dos alunos da base de dados. Foi criado um arquivo .txt para cada um dos alunos. Nos arquivos, constam as informações relacionadas às observações das disciplinas, sendo que cada linha corresponde a uma disciplina e cada coluna corresponde a uma observação. A base de dados será melhor descrita na seção dos resultados.

São então criados os HMMs, um para cada uma das dimensões Processamento, Percepção e Organização. A partir de então, em cada disciplina, os HMMs são atualizados com as observações constantes naquela disciplina (atualiza-se a matriz de emissão de estados observáveis). Os HMMs são atualizados com as observações da nova disciplina, mas sempre mantendo o histórico das observações das disciplinas anteriores.

Após a atualização dos modelos, o EA probabilístico é inferido novamente (por meio do Algoritmo de Viterbi) e a performance do estudante é calculada (por meio do PESDE). Caso a PFM do aluno seja inferior a 60, um reforço é calculado e aplicado na matriz de transição de estados ocultos do modelo (conforme seção 3.1).

4 | RESULTADOS EXPERIMENTAIS

4.1 Metodologia Experimental

Com o objetivo de comparar os resultados dessa abordagem com a proposta por Yannibelli, Godoy & Amandi (2006), foram implementados os dois algoritmos: o Algoritmo Genético e o algoritmo descrito neste trabalho. Para facilitar a programação dos algoritmos, foi utilizado o padrão de projetos Strategy e o paradigma de Orientação a Objetos. O Strategy é um *design pattern* que define uma família de algoritmos e encapsula cada uma delas, tornando-as intercambiáveis (GAMMA et al., 2000). Com

o uso do Strategy e do paradigma de Orientação a Objetos, a implementação dos algoritmos e a execução dos testes se torna mais fácil.

Os algoritmos foram implementados utilizando a linguagem de programação Java. O ambiente gráfico para desenvolvimento (*IDE - Integrated Development Environment*) utilizado foi o Netbeans, na sua versão 8.2. O sistema operacional utilizado tanto para o desenvolvimento quanto para os testes foi o Linux Ubuntu 16.04 LTS.

A execução do algoritmo proposto retorna o EA Probabilístico (EAp) do estudante, obtido por meio da inferência realizada pelo Algoritmo de Viterbi, aplicado aos HMMs. Caso o EA Probabilístico seja igual ao EA Real - obtido segundo regras constantes em Yannibelli, Godoy & Amandi (2006) - ao final da execução do algoritmo, considera-se que a abordagem proposta consegue inferir corretamente o EA do estudante. O algoritmo retorna ainda o tempo médio de execução, calculado pelo método `java System.currentTimeMillis()`, que retorna o tempo atual em milissegundos.

Para os experimentos e validação da proposta de pesquisa, foi utilizada a base de dados apresentada em Yannibelli, Godoy & Amandi (2006). A base de dados consiste nas observações que foram realizadas em um sistema de aprendizagem de determinado curso em oito disciplinas distintas. O curso teve um total de dez alunos.

São, no total, dez arquivos do tipo `.txt`, sendo um arquivo para cada estudante. Os arquivos são carregados pelo algoritmo para a inicialização do aluno e apresentam oito disciplinas - cada disciplina é uma linha do arquivo `.txt`. Cada linha (ou disciplina) contém nove observações, sendo que cada observação apresenta um valor numérico que a identifica unicamente.

Neste sentido, os arquivos são representados por meio de matrizes, com oito linhas (disciplinas) e nove colunas (observações). As duas primeiras colunas contém observações relacionadas à dimensão Processamento do FSLSM: participação em fórum e participação em *chat*. As colunas de 3 a 8 contém observações relacionadas à dimensão Percepção do FSLSM: leitura de material, acesso a exemplos, exercícios feitos, tempo de entrega de avaliações, revisão de exame e respostas alteradas. Por fim, a última coluna apresenta observações relacionadas à dimensão Organização do FSLSM: acesso à informação.

4.2 Resultados Obtidos

O algoritmo proposto infere, para cada disciplina, o EAp dos estudantes. Sendo assim, é possível verificar se o algoritmo consegue inferir corretamente o EA. As figuras 3 e 4 apresentam as inferências realizadas pelo algoritmo para os estudantes 9 e 10, após cada uma das 8 disciplinas. Pela análise dos gráficos é possível perceber, para cada disciplina, se o EA Probabilístico (inferido por meio do Algoritmo de Viterbi) é igual ao EA Real. Nos casos onde os EAs Probabilístico e Real não coincidem, é apresentado o valor 1; nos casos onde os EAs coincidem, é apresentado o valor 2. Dessa forma, podemos perceber o comportamento do algoritmo e a convergência do

mesmo ao longo de sua execução.

Para o estudante 9, por exemplo, percebe-se que todas as dimensões foram inferidas corretamente na primeira disciplina. As dimensões Percepção e Organização continuaram a ser inferidas corretamente ao longo das próximas disciplinas, até a oitava e última disciplina. Já a dimensão Processamento foi inferida corretamente apenas na primeira e quarta disciplina. Nas outras seis disciplinas, devido às novas observações realizadas e ao reforço aplicado no ME, a inferência do EA Probabilístico foi equivocada após a finalização das 8 disciplinas. Esse é um dos três casos onde o algoritmo não conseguiu inferir corretamente o EA do estudante ao final das 8 disciplinas, conforme será visto na Tabela 1.

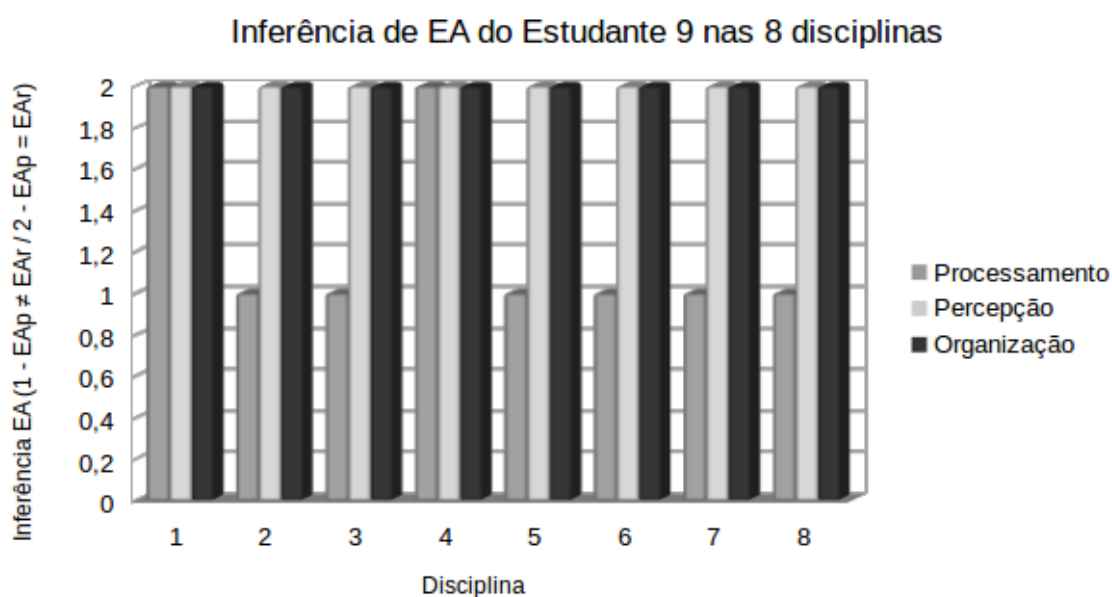


Figura 3 - Inferências de EA para o estudante 9, por disciplina

Para o estudante 10 (Figura 4), percebe-se que o algoritmo não alterou seu comportamento ao longo das disciplinas. As dimensões Processamento e Organização foram inferidas corretamente desde a primeira disciplina. Já o EAp da dimensão Percepção foi inferido incorretamente desde a primeira disciplina, mantendo o comportamento até o final das 8 disciplinas. Esse é outro dos três casos onde o algoritmo não conseguiu inferir corretamente o EA do estudante ao final das 8 disciplinas, conforme será visto na Tabela 1.

Inferência de EA do Estudante 10 nas 8 disciplinas

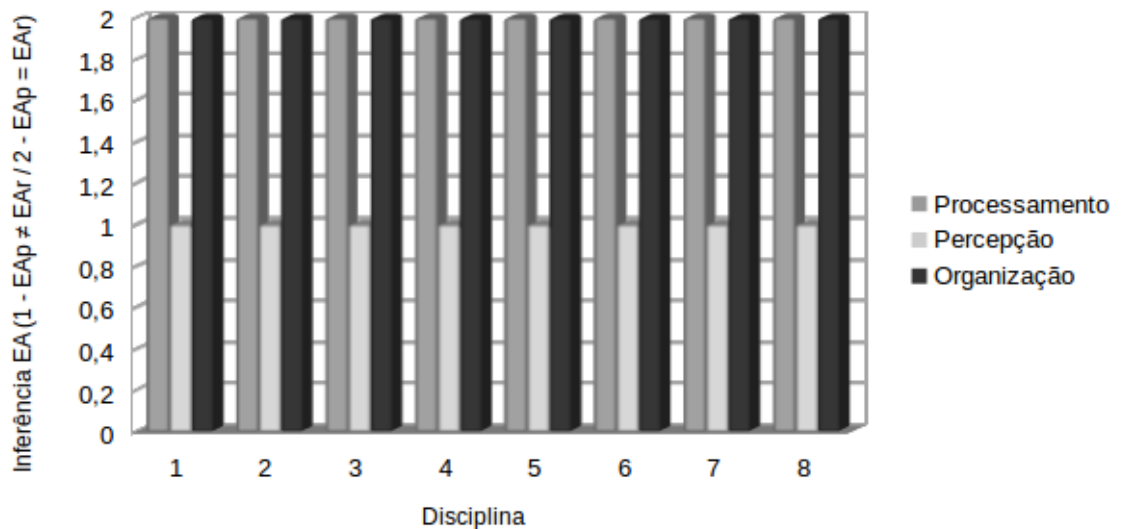


Figura 4 - Inferências de EA para o estudante 10, por disciplina

Os resultados obtidos pela execução do algoritmo para os dez estudantes constam na Tabela 1. Para simplificação, considera-se Ativo como ATV, Reflexivo como REF, Sensitivo como SEN, Intuitivo como INT, Sequencial como SEQ, Global como GLB e Neutro como NEU.

Estudante	EAr Proc.	EAp Proc.	EAr Percep.	EAp Percep.	EAr Org.	EAp Org.
1	REF	REF	INT	INT	SEQ	SEQ
2	ATV	ATV	SEN	SEN	SEQ	SEQ
3	REF	REF	INT	SEN	GLB	GLB
4	REF	REF	NEU	NEU	GLB	GLB
5	ATV	ATV	SEN	SEN	SEQ	SEQ
6	REF	REF	INT	INT	GLB	GLB
7	ATV	ATV	NEU	NEU	NEU	NEU
8	REF	REF	INT	INT	NEU	NEU
9	ATV	REF	SEN	SEN	SEQ	SEQ
10	ATV	ATV	NEU	SEN	SEQ	SEQ

Tabela 1 - EA Real e EA Probabilístico de cada estudante

Percebe-se, pela análise da Tabela 1, que a abordagem proposta consegue inferir os EA dos estudantes com um bom nível de acerto. Na dimensão Processamento, a abordagem conseguiu inferir 90% dos EA corretamente. Na dimensão Percepção, o algoritmo inferiu 80% dos EA corretamente. Na dimensão Organização, 100% dos EA foram inferidos corretamente.

A título de comparação, em seu trabalho, onde é utilizado um Algoritmo Genético para detectar os EA, Yannibelli, Godoy & Amandi (2006) obtiveram

resultados semelhantes: na dimensão Processamento, o algoritmo inferiu 80% dos EA corretamente; na dimensão Percepção, 100% dos EA foram inferidos corretamente; na dimensão Organização, 100% dos EA foram inferidos corretamente.

Entre a abordagem proposta por Yannibelli, Godoy & Amandi (2006) e a abordagem proposta neste trabalho, a diferença nos resultados se encontra nas dimensões Percepção e Processamento. Na dimensão Percepção, o Algoritmo Genético obteve 100% de acerto, enquanto o algoritmo aqui proposto obteve 80% de acerto. Em contrapartida, na dimensão Processamento, o Algoritmo Genético obteve 80% de acerto, enquanto a presente proposta obteve 90% de acerto.

Uma outra forma de analisar os dados obtidos é verificando a quantidade total de inferências, para os 10 estudantes, nas oito disciplinas. Quando analisam-se todas as inferências de EA após cada disciplina, é possível perceber que a abordagem proposta apresenta uma alta taxa de acerto nas inferências. São, no total, 24 inferências por aluno: uma inferência por disciplina para cada uma das 3 dimensões do FSLSM, sendo que no total existem 8 disciplinas. A base é composta por 10 estudantes, totalizando 240 inferências.

Levando-se em consideração os erros nas inferências (foram 6 erros de inferência para o aluno 3, na dimensão Percepção; 8 erros de inferência para o aluno 10, na dimensão Percepção; 6 erros de inferência para o aluno 9, na dimensão Processamento), o número total de erros é de 20 em 240 inferências. Isso representa uma taxa média de aproximadamente 8,33% das inferências. Portanto, verifica-se que o algoritmo é capaz de inferir o EA corretamente em 91,67% dos casos.

Em termos de tempo de execução, a diferença entre os dois algoritmos é significativa. O Algoritmo Genético proposto por Yannibelli, Godoy & Amandi (2006) apresenta um tempo médio entre 132000 e 134000 milissegundos para convergir para os melhores resultados, com uma população inicial de 10000 cromossomos. Já o algoritmo proposto neste trabalho apresenta um tempo médio de convergência muito menor: entre 80 e 150 milissegundos.

Existem alguns fatores que podem explicar essa diferença nos tempos de execução dos dois algoritmos. Para convergir, o Algoritmo Genético utiliza uma população inicial de cromossomos muito grande: 10000 cromossomos. Em seu trabalho, Yannibelli, Godoy & Amandi (2006) realiza também testes com uma população menor, de 5000 cromossomos. No entanto, os resultados obtidos na inferência do EA não foram tão satisfatórios como os obtidos com a população de 10000 cromossomos. O Algoritmo Genético utiliza ainda técnicas de seleção (roleta), recombinação de dois pontos e mutação simples, que elevam o tempo de execução do programa. O tamanho da população inicial do Algoritmo Genético, bem como a quantidade de métodos utilizados para garantir a convergência para bons resultados, certamente influenciam diretamente o tempo de execução do mesmo.

Em contrapartida, o algoritmo proposto neste trabalho utiliza HMMs, que são modelos matemáticos relativamente simples e de fácil representação computacional.

Além disso, a inferência do EA probabilístico, que poderia ser o problema dessa abordagem, não o é, visto que o Algoritmo de Viterbi otimiza a busca nos estados observáveis e o mapeamento nos estados ocultos.

5 | CONSIDERAÇÕES FINAIS

O modelo computacional proposto no presente trabalho utiliza HMMs para modelar EA. A inferência dos EA é realizada por meio do Algoritmo de Viterbi e a correção dos EA é feita por meio de um algoritmo de aprendizagem por reforço. A abordagem se mostrou eficiente e de fácil adaptação à estrutura do FSLSM. Além disso, pelo fato de EA serem considerados como tendências (KINSHUK & GRAF, 2009), a modelagem por meio de matrizes de probabilidades se adapta muito bem ao problema.

A base de dados utilizada para testes do modelo é composta por observações das interações de estudantes em um sistema de aprendizagem. Sendo assim, a modelagem por meio de HMMs é muito eficiente, visto que sua estrutura é capaz de armazenar os estados observáveis e suas probabilidades de transição.

A inferência dos EA por meio do Algoritmo de Viterbi é, além de simples, eficiente. A abordagem por reforço implementada no modelo torna-se importante para corrigir automaticamente eventuais distorções no EA inferido, além de aproximar o EA Probabilístico do EA Real. A abordagem apresenta, ainda, um baixo custo computacional.

Como trabalhos futuros, existem algumas possibilidades: a utilização de uma base de dados com mais estudantes, que contemple a dimensão Entrada do FSLSM, e a execução do modelo proposto nessa base; utilização dos HMMs como estrutura para recomendação de Objetos de Aprendizagem para estudantes; implementação e validação do modelo proposto em um Ambiente Virtual de Aprendizagem, com alunos reais.

REFERÊNCIAS

ALAMINO, R. C. **Aprendizado em modelos de Markov com variáveis de estado escondidas**. Tese (Doutorado) — Universidade de São Paulo, 2005.

ARMSTRONG, W.; CHRISTEN, P.; MCCREATH, E.; RENDELL, A. P. **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.

BARBOSA, B. D. L. **O uso de modelos ocultos de markov no estudo do fluxo de rios intermitentes**. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Norte, 2014.

BAUM, L. E.; EAGON, J. A. et al. **An inequality with applications to statistical estimation for probabilistic functions of markov processes and to a model for ecology**. Bull. Amer. Math. Soc, v. 73, n. 3, p. 360–363, 1967.

BAUM, L. E.; PETRIE, T. **Statistical inference for probabilistic functions of finite state markov**

chains. The annals of mathematical statistics, JSTOR, v. 37, n. 6, p. 1554–1563, 1966.

BITTENCOURT, I. M.; MERCADO, L. P. L. **Evasão nos cursos na modalidade de educação a distância: estudo de caso do curso piloto de administração da ufal/uab.** Revista Ensaio: Avaliação e Políticas Públicas em Educação, v. 22, n. 83, p. 465–504, 2014.

BRASIL. **Lei de Diretrizes e Bases da educação Nacional.** Diário Oficial da União, Brasília, Seção 1, p. 27839, 1996. Disponível em: <<http://www.planalto.gov.br/ccivil/03/leis/L9394.htm>>.

BRUSILOVSKY, P.; MILLÁN, E. **User models for adaptive hypermedia and adaptive educational systems.** In: SPRINGER-VERLAG. The adaptive web. [S.l.], 2007. p. 3–53.

CAVELLUCCI, L. C. B. et al. **Estudo de um ambiente de aprendizagem baseado em mídia digital: uma experiência na empresa.** Tese (Doutorado) — Universidade Estadual de Campinas, 2003.

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.** Tese (Doutorado) — Universidade Federal de Uberlândia, 2012.

FELDER, R. M.; BRENT, R. **Understanding student differences.** Journal of engineering education, Wiley Online Library, v. 94, n. 1, p. 57–72, 2005.

FELDER, R. M.; SILVERMAN, L. K. et al. **Learning and teaching styles in engineering education.** Engineering education, v. 78, n. 7, p. 674–681, 1988.

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.

GAMMA, E.; HELM, R.; JOHNSON, R. E.; VLISSIDES, J. **Design patterns: elements of reusable object-oriented software.** [S.l.]: Braille Jymico Incorporated, 2000.

GRAF, S.; IVES, C. et al. **A flexible mechanism for providing adaptivity based on learning styles in learning management systems.** In: IEEE. Advanced Learning Technologies (ICALT), 2010 IEEE 10th International Conference on. [S.l.], 2010. p. 30–34.

GRANITO, R. A. N. **Educação a distância e estilos de aprendizagem: elaboração de um protocolo de qualidade para ambientes virtuais de ensino.** Tese (Doutorado) — Universidade de São Paulo, 2008.

KAELBLING, L. P.; LITTMAN, M. L.; MOORE, A. W. **Reinforcement learning: A survey.** Journal of artificial intelligence research, v. 4, p. 237–285, 1996.

KINSHUK, L. T. C.; GRAF, S. **Coping with mismatched courses: students' behaviour and performance in courses mismatched to their learning styles.** Educational Technology Research and Development, v. 57, n. 6, p. 739–752, 2009.

NGUYEN, L. **A new approach for modeling and discovering learning styles by using hidden markov model.** Global Journal of Human-Social Science Research, v. 13, n. 4, 2013.

RABINER, L. R. **A tutorial on hidden markov models and selected applications in speech recognition.** Proceedings of the IEEE, IEEE, v. 77, n. 2, p. 257–286, 1989.

ROSÁRIO, J. d. A. d. et al. **Estilos de aprendizagem de alunos de engenharia química e engenharia de alimentos da ufsc: O caso da disciplina de análise e simulação de processos.** Tese (Doutorado) — Universidade Federal de Santa Catarina, 2006.

ROSENBERG, M. J. **E-learning: estratégias para a transmissão do conhecimento na era digital**. São Paulo: Makron Brooks, 2001.

SCHMECK, R. R. **An introduction to strategies and styles of learning**. In Learning strategies and learning styles, p. 3–19, Springer, 1988.

SENA, E.; VIVAS, A.; ASSIS, L.; PITANGUI, C. **Proposta de uma abordagem computacional para detecção automática de estilos de aprendizagem utilizando modelos ocultos de markov e fsm**. In: Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE). [S.l.: s.n.], 2016. v. 27, n. 1, p. 1126.

SILVA, L. L. V. **Estilos e estratégias de aprendizagem de estudantes universitários**. Tese (Doutorado) — Universidade de São Paulo, 2012.

SUTTON, R. S.; BARTO, A. G. **Reinforcement Learning: An Introduction**. [S.l.]: MIT Press, 1998.

WAGHABI, E. R.; BENEVIDES, M. R. **Aplicação de modelos ocultos de markov na teoria dos jogos**. In ENIA-VII Encontro Nacional de Inteligência Artificial, 29a Congresso da Sociedade Brasileira de Computação, volume 1, p. 1–10, 2009.

VAZ, D.; ZANELLA, R.; ANDRADE, S. **Ambientes virtuais: Uma nova ferramenta de ensino**. Revista iTEC, v. 1, n. 1, p. 8–12, 2010.

YANNIBELLI, V.; GODOY, D.; AMANDI, A. **A genetic algorithm approach to recognise students' learning styles**. Interactive Learning Environments, Informa UK Limited, v. 14, n. 1, p. 55–78, apr 2006. Disponível em: <<https://doi.org/10.1080/10494820600733565>>.

SOBRE A ORGANIZADORA

Ingrid Aparecida Gomes - Bacharel em Geografia pela Universidade Estadual de Ponta Grossa (2008), Mestre em Geografia pelo Programa de Pós-Graduação Mestrado em Gestão do Território da Universidade Estadual de Ponta Grossa (2011). Atualmente é Doutoranda em Geografia pelo Programa de Pós-Graduação da Universidade Federal do Paraná (UFPR). Foi professora colaborada na UEPG, lecionando para os cursos de Geografia, Engenharia Civil, Agronomia, Biologia e Química Tecnológica. Também atuou como docente no Centro de Ensino Superior dos Campos Gerais (CESCAGE), lecionando para os cursos de Engenharia Civil e Arquitetura e Urbanismo. Participou de projetos de pesquisas nestas duas instituições e orientou diversos trabalhos de conclusão de curso. Possui experiência na área de Geociências com ênfase em Geoprocessamento, Geotecnologia, Geologia, Topografia e Hidrologia.

