

Informática Aplicada à Educação

Everson Mario Novak
(Organizador)



 **Atena** Editora

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

Lucas Daniel Ferreira

Universidade de São Paulo
Instituto de Ciências Matemáticas e
Computação
São Carlos – SP

José Fernando Rodrigues Jr

Universidade de São Paulo
Instituto de Ciências Matemáticas e
Computação (ICMC-USP)
São Carlos – SP

RESUMO Diversos estudos nas áreas de psicologia cognitiva e pedagogia apontam que cada indivíduo possui diferentes maneiras de captar, processar, analisar e organizar informações durante o processo de aprendizado, o que fundamenta o conceito de Estilos de Aprendizagem (EA). Em vista disso, diversos sistemas educacionais adaptativos foram propostos com o intuito de proporcionar conteúdo personalizado em seus cursos. Porém, em boa parte dos casos, estes sistemas fazem uso de questionários para identificar os estilos de aprendizagem, e este método pode mostrar-se inviável em algumas situações. Deste modo, a proposta neste trabalho é investigar diferentes

algoritmos relacionados ao aprendizado de máquina (especialmente algoritmos de classificação) aplicados à detecção automática dos estilos de aprendizagem de estudantes, a partir de suas interações em um sistema educacional. Dentre os inúmeros modelos de EA propostos na literatura, optou-se por usar o modelo de Felder-Silverman como base para os experimentos. Para fins de experimentação, foram avaliadas as taxas de acertos e erros dos algoritmos em relação aos resultados apontados pelo questionário ILS, em cada uma das dimensões do modelo de Felder-Silverman. Os resultados apontaram para o uso de mais de um classificador - Naïve Bayes e aprendizagem baseada em instância - dependendo da dimensão do estilo de aprendizagem. A metodologia aplicada foi comparada com sete trabalhos correlatos da literatura; Os resultados demonstraram uma performance superior aos trabalhos anteriores em quase todas as dimensões.

1 | INTRODUÇÃO

Inúmeras instituições de ensino, tais

como colégios e universidades, fazem uso de métodos tecnológicos para fornecer e administrar seus cursos. Devido à popularização do acesso à internet esta prática está em constante crescimento, o que torna o conceito de ensino à distância uma tendência no contexto educacional. Em um ambiente de aprendizado online, são comumente utilizados Sistemas de Gerenciamento do Aprendizado - também conhecidos pela nomenclatura em inglês *Learning Management Systems* (LMS) - como ferramentas de apoio ao ensino; tais ferramentas proporcionam ao docente funcionalidades para criar, gerenciar e compartilhar conteúdo com os estudantes de maneira prática e efetiva. Porém, ao contrário do ensino tradicional (sala de aula) - onde o professor pode facilmente visualizar a maneira segundo a qual cada estudante se comporta - um problema apresentado por esses sistemas é a dificuldade que os professores encontram ao tratar as características individuais de cada aluno no decorrer do curso.

Com efeito, cada pessoa possui habilidades, necessidades, conhecimentos prévios e motivações próprias, e estas características são fundamentais para determinar se um indivíduo encontra mais dificuldades do que outros para aprender em certo modelo de ensino (GRAF, 2007). Além disso, diversos estudos nas áreas de psicologia cognitiva e pedagogia indicam que cada indivíduo possui diferentes maneiras de captar, processar e analisar informações durante o processo de aprendizado, o que fundamenta o conceito de Estilos de Aprendizagem (EA). De maneira geral, assume-se que os EA referem-se aos métodos que um indivíduo aplica com frequência para captar, organizar e interpretar novas informações em situações onde há aquisição de conhecimento. Estes comportamentos representam a maneira segundo a qual um aluno observa o ambiente, recebe informações, as processa, compreende seu significado e então as transforma em conhecimento (JONASSEN & GRABOWSKI, 2012).

A teoria dos Estilos de Aprendizagem tem motivado diversas pesquisas na área da computação aplicada à educação ao longo dos anos, pois, entende-se que a construção e atualização de um modelo de perfil dos estudantes pode melhorar os processos de ensino e aprendizagem de diversas maneiras. Por exemplo, durante a criação do conteúdo de um curso, os professores podem fazer uso dessa informação para compreender mais precisamente a preferência dos estudantes quanto ao material de estudos. Por outro lado, o aluno pode avaliar seu estilo de aprendizagem e identificar quais são seus pontos fortes e fracos durante o aprendizado, o que pode direcionar seus trabalhos a fim de reduzir suas deficiências. E, acima de tudo, a identificação dos EA possibilita a adaptabilidade de conteúdo em cursos oferecidos por meios tecnológicos, o que permite uma melhor experiência de aprendizagem para o aluno, que passa a interagir com recursos e atividades mais adequados às suas preferências em um modelo de ensino personalizado para cada indivíduo.

Usualmente, os estilos de aprendizagem são detectados de maneira colaborativa, ou seja, por meio de questionários respondidos pelos estudantes.

Tais ferramentas indicam os EA com precisão, porém esta abordagem possui

algumas limitações. De acordo com diversos autores (GARCÍA, 2007; GRAF, 2009; DUNG & FLOREA, 2012), este método pode mostrar-se impreciso ou inviável em alguns casos, pois depende diretamente da motivação e autoconhecimento dos estudantes ao preencher os questionários, além de demandar esforço adicional para a obtenção de um modelo, visto que alguns questionários possuem mais de 100 itens. Além disso, esta é uma classificação estática, pois o aluno constrói seu modelo apenas uma vez (geralmente no início do curso).

É hipótese deste trabalho, e de outros existentes (GARCÍA, 2007; GRAF, 2009; DORÇA et al., 2012; DUNG & FLOREA, 2012; LIYANAGE et al., 2014; SENA, 2016) que uma abordagem de detecção automática dos EA mostra-se mais precisa do que a detecção baseada em questionários, pois independe da motivação do aluno ao preencher os formulários, ou do nível de conhecimento do indivíduo a respeito de suas próprias preferências. Além disso, essa proposta isenta o aluno de qualquer esforço adicional para a construção de seu perfil, deixando-o focado apenas nas tarefas de aprendizado. Por fim, a construção do modelo do estudante é feita de maneira contínua, ou seja, enquanto o usuário interagir com o sistema, seu perfil será atualizado, mantendo a classificação válida em caso de mudanças nos Estilos de Aprendizagem.

Assim, o objetivo deste trabalho é explorar diferentes técnicas de aprendizado de máquina supervisionado, relacionadas especificamente à tarefa de classificação, aplicadas à identificação automática de EA. Para isso, será experimentado um conjunto de algoritmos de diferentes paradigmas (com diversas configurações dos dados) para classificar o Estilo de Aprendizagem no qual se enquadra cada aluno com base em seu comportamento durante o uso de um LMS. Para fins de avaliação da pesquisa, serão comparados sistematicamente os resultados dos classificadores quanto à predição dos EA dos alunos, por meio das medidas de acertos e erros obtidas. Ao fim do estudo, espera-se encontrar uma combinação de técnicas e configurações de dados que atinja resultados satisfatórios quando comparada aos trabalhos correlatos no que diz respeito à efetividade da classificação. Além disso, serão levantadas discussões a respeito dos resultados obtidos, a fim de apontar os êxitos e limitações do estudo e contribuir para o cenário atual da modelagem automática de estudantes.

2 | FUNDAMENTAÇÃO TEÓRICA

O termo “Estilos de Aprendizagem” não possui uma definição específica, porém pode ser entendido como uma descrição das ações e comportamentos que determinam as preferências de um estudante durante o processo de aprendizagem. A definição mais comumente aceita é a de Keefe (1979), que considera os EA como “uma composição de características cognitivas, afetivas e fatores fisiológicos que servem como indicadores relativamente estáveis de como um aluno percebe, interage

e responde ao ambiente de aprendizagem”. De maneira geral, os EA referem-se aos métodos que um estudante aplica com frequência para observar o ambiente, captar informações, as processar, compreender seu significado e então transformá-las em conhecimento.

Muitos teóricos educacionais e pesquisadores consideram o EA como um fator importante no processo de ensino e concordam que incorporá-los na educação tem potencial para tornar a aquisição de conhecimento mais fácil para os estudantes (GRAF, 2007). Felder (1988), por exemplo, argumenta que os alunos com uma forte preferência por um EA específico podem ter dificuldades nos estudos caso seu estilo de aprendizagem não seja suportado pelo ambiente de ensino. Por outro lado, pode-se assumir que incorporar os EA dos alunos nos métodos de ensino torna a aprendizagem mais fácil e eficiente.

Inúmeros autores propuseram modelos para definir e classificar Estilos de Aprendizagem capazes de mapear o comportamento de estudantes. Estes modelos são construídos de forma distinta por cada autor, que por sua vez, possui influências e embasamentos em diferentes teorias da psicologia educacional. Neste trabalho, é explorado o Modelo de Estilos de Aprendizagem de Felder e Silverman (FSLSM) (FELDER & SILVERMAN, 1988), que será detalhado a seguir. Uma vasta revisão acerca de modelos de estilos de aprendizagem está disponível em Coffield et al. (2004).

2.1 Modelo de estilos de aprendizagem de Felder e Silverman

O modelo de Felder e Silverman (1988) pode ser compreendido como um compilado de um conjunto de modelos propostos na literatura a fim de dar início a um modelo de maior amplitude e possibilidades. As dimensões dos EA propostos por Felder-Silverman estão relacionadas com as estratégias de captação, percepção, organização e processamento de informações adotadas pelos estudantes durante a aprendizagem. Portanto, Felder e Silverman sintetizaram descobertas de diversos estudos que resultaram em um modelo de estilos de aprendizagem composto por quatro dimensões distintas, que são detalhadas a seguir.

- **Processamento (ativos x reflexivos):** os estudantes ativos mais bem processam a informação enquanto executam alguma atividade, precisam experimentar para compreender, poderão iniciar as tarefas prematuramente e gostam de participar de trabalhos em grupo. Já os estudantes reflexivos precisam compreender para experimentar, demoram a iniciar as atividades e preferem trabalhos individuais.
- **Percepção (sensoriais x intuitivos):** indivíduos intuitivos possuem grande capacidade para distinguir e interpretar símbolos e textos quando comparados aos sensoriais. Além disso, estão propensos a tomar decisões com base na intuição, ou seja, com base em estímulos oriundos do inconsciente. Por outro

lado, os indivíduos sensoriais tomam decisões e percebem as informações baseando-se fortemente nos sentidos (visão, audição, tato, olfato), e tendem a ter maior atividade na região consciente do cérebro.

- **Captação (visuais x verbais):** indivíduos com maior tendência para o polo visual possuem melhor captação de informações que se apresentam de forma gráfica, tais como ilustrações, figuras, diagramas, fluxogramas, esquemas e mapas. Em contrapartida, aqueles mais inclinados ao polo verbal estão relacionados às propriedades de leitura e audição. Eles possuem facilidade para compreender conceitos traduzidos em palavras.
- **Organização (sequenciais x globais):** estudantes sequenciais organizam a informação a partir do detalhamento para compreender informações mais generalizadas. Ou seja, dão forte prioridade para as características específicas de um conteúdo, e não se atentam fortemente ao que é abstrato. Por outro lado, estudantes globais organizam a informação a partir de regras gerais, para que a partir destas cheguem ao nível de detalhe. Deste modo, estes indivíduos tendem a ter uma visão geral do todo, porém podem perder dados importantes que constituem este todo.

Este modelo foi escolhido para os experimentos conduzidos neste trabalho por diversas razões. Uma delas, é o fato de que Felder e Silverman agruparam em um único modelo importantes descobertas de outros autores já consolidados neste campo de investigação, tais como Kolb (1976), Pask (1975) e os Indicadores de Tipos de Myers-Briggs (1985). Outra característica importante deste modelo é a praticidade para se identificar o estilo de um estudante, visto que Felder e Soloman desenvolveram um questionário contendo 44 questões (11 questões para cada dimensão), denominado *Index of Learning Styles (ILS)* (FELDER & SOLOMAN, 2005), que aponta as preferências de cada indivíduo de acordo com o modelo proposto. Por fim, a escolha do modelo de Felder-Silverman justifica-se por este ser um dos modelos mais adotados em trabalhos de modelagem automática de estudantes (FELDMAN, 2015; TRUONG, 2016), além de já ser incorporado a diversos sistemas adaptativos, demonstrando bons resultados quanto à classificação de perfis e recomendação de conteúdo.

3 | TRABALHOS RELACIONADOS

Diversas abordagens foram propostas para identificação automática de Estilos de Aprendizagem em ambientes virtuais de ensino. O trabalho de García et al. (2007), por exemplo, foi um dos precursores no tema e representou a base para vários outros trabalhos que relacionam redes bayesianas e o modelo de estilos de Felder-Silverman

(FSLSM). Neste trabalho os autores aplicaram o Teorema de Bayes e observaram 11 padrões de comportamento em 10 estudantes matriculados em um curso de Inteligência Artificial, oferecido via Web. Como resultado é proposto o sistema SAVER (abreviação para *Software de Asistencia Virtual para Educación Remota*), que, por meio de técnicas de Redes Bayesianas, possibilita o cálculo da preferência dos alunos nas dimensões ativo/reflexivo, sensorial/intuitivo e sequencial/global do FSLSM.

Outro trabalho clássico na área e que influenciou diversas pesquisas, é o de Graf, Kinshuk e Liu (GRAF et al., 2009), o qual propõe uma abordagem de identificação automática de EA em sistemas de gestão do aprendizado a partir das interações dos estudantes nos cursos online. Neste trabalho, os autores exploram técnicas baseadas em regras para traçar a correlação de padrões de comportamento online com os estilos de Felder e Silverman. Para a avaliação, um estudo foi conduzido com 75 alunos, comparando os resultados da abordagem automática com os obtidos pelo questionário ILS, onde alcança-se precisão de 79,33%, 77,33%, 76,67% e 73,33% nas dimensões de processamento, percepção, captação e organização, respectivamente.

Dorça et al. apresentam inúmeras contribuições para o contexto da modelagem automática e dinâmica de estudantes por meio de EA. Em um de seus trabalhos (DORÇA et al., 2011), o foco é a investigação de como (além de construir) atualizar gradualmente e constantemente o modelo dos estudantes, visto que as preferências de cada indivíduo podem mudar de maneira inesperada com o decorrer do tempo. Para a avaliação da proposta, este trabalho considera o modelo FSLSM, e realiza uma simulação computacional do comportamento de estudantes em um sistema educacional. Em outro trabalho, Dorça et al. (2012) realizam uma abordagem semelhante, porém baseada em cadeias de Markov. Neste caso, os autores introduzem uma combinação de Estilos de Aprendizagem para detectar e corrigir o modelo dos estudantes, demonstrando bons resultados.

O trabalho de Dung e Florea (2012) apresenta outra proposta para modelagem automática de estudantes usando o modelo FSLSM, bastante influenciada no trabalho de Graf e Liu (2009). Com uma abordagem baseada em regras de mapeamento, são considerados o número de visitas e o tempo gasto pelos estudantes em cada objeto de aprendizagem (que possuem meta dados descritivos). Como resultado, o método proposto obteve precisão de acertos (em relação ao questionário ILS) de 72,73%, 70,15%, 79,54% e 65,91% nas dimensões de processamento, percepção, captação e organização, respectivamente.

Em um trabalho mais recente, Liyanage et al. (2014) propõem um arcabouço para sistemas adaptativos dividido em três módulos. O primeiro, aplica o já conhecido questionário ILS para indicar os EA dos estudantes segundo o modelo de Felder-Silverman. No segundo módulo ocorre a recomendação de objetos compatíveis com cada estilo de aprendizagem; e por fim, no terceiro módulo são disponibilizadas ferramentas para os docentes calibrarem os mecanismos de adaptabilidade. Os experimentos para detecção dos EA foram conduzidos em um grupo de 80 estudantes matriculados no

Moodle, e alcançaram precisões de 65%, 75%, 76,25% e 77,50% para as dimensões de processamento, percepção, captação e organização, respectivamente.

Dentre os trabalhos contemporâneos, Sena et al. (2016) propõem uma abordagem probabilística que combina o modelo FSLSM com as técnicas de inferência probabilística dos Modelos Ocultos de Markov (HMM) a fim de realizar o processo de inferência da preferência do aluno por um determinado estilo de aprendizagem. Para isso, matrizes de emissão e transição de estados do modelo de Markov foram criadas por meio do algoritmo de Viterbi. Para avaliar a proposta, os autores realizam uma simulação do comportamento de estudantes em sistemas educacionais, e alcançam bons resultados quanto à detecção de seus EA.

Conforme apontado por Truong (2016), - que apresenta uma revisão a respeito de desenvolvimentos, problemas e oportunidades na área de EA integrados a Sistemas Educacionais Adaptativos - apesar da variedade de trabalhos conduzidos na área, ainda existem questões em aberto e diversas lacunas a serem investigadas. Uma das questões discutidas é que embora muitos algoritmos de classificação tenham sido explorados, entre os quais Redes Bayesianas e Rules-based são os mais amplamente utilizados, apenas uma pequena proporção de trabalhos considera uma análise comparativa de métodos de classificação neste contexto. Portanto, o presente trabalho diferencia-se dos demais apresentados neste capítulo por atender à oportunidade de aplicar diferentes métodos de classificação ao mesmo problema, com o intuito de comparar desempenhos e levantar discussões a respeito dos resultados obtidos.

4 | MATERIAIS E MÉTODOS

4.1 Contexto, participantes e características do curso

Para a realização dos estudos propostos neste trabalho, foi avaliado um curso de pós-graduação em Reabilitação Auditiva, na área de Fonoaudiologia, oferecido pela Faculdade de Odontologia de Bauru em parceria com o Hospital Samaritano de São Paulo. O curso em questão possui duração de 18 meses, é ministrado integralmente com auxílio do sistema Moodle, e conta com 105 alunos matriculados, oriundos de diversas localidades do Brasil. Dada a separação geográfica, estes estudantes interagem entre si diariamente por meio dos fóruns de discussões e ferramentas de comunicação disponíveis no ambiente virtual. Como parte dos experimentos, os alunos foram solicitados a responder ao questionário ILS no início do curso com o intuito de registrar suas respectivas preferências nas dimensões de processamento, percepção, captação e organização do modelo de estilos de aprendizagem de Felder-Silverman (FSLSM). Os resultados do questionário são apresentados na Tabela 1, a qual indica o percentual de preferência dos estudantes para cada dimensão.

| Processamento | | Captação | | Organização | | Percepção | |
|---------------|------------|----------|---------|-------------|---------|------------|------------|
| Ativos | Reflexivos | Visuais | Verbais | Sequenciais | Globais | Sensoriais | Intuitivos |
| 79,38% | 20,62% | 53,61% | 46,39% | 69,07% | 30,93% | 87,63% | 12,37% |

Tabela 1 - Resultados do questionário ILS.

Os registros de uso do Moodle foram coletados entre setembro de 2015 e agosto de 2016. Ao todo, foram avaliadas as interações dos estudantes com 252 recursos educacionais disponibilizados neste período, o que corresponde ao material didático referente aos 16 primeiros capítulos do curso.

4.2 Recursos educacionais

O curso em questão oferece uma grande diversidade de recursos educacionais aos estudantes, que variam suas características de acordo com o propósito do objeto de aprendizagem e sua forma de apresentação. Na Figura 1, é possível observar a distribuição dos recursos educacionais disponíveis no curso avaliado de acordo com suas características. Conforme pode-se observar, objetos relacionados a materiais didáticos textuais e vídeo-aulas são predominantes (70 e 54 objetos respectivamente). Neste trabalho e em outros semelhantes, assume-se que a distinção dos materiais de acordo com o formato de apresentação (vídeo ou texto) é fundamental para o processo de classificação de estilos de aprendizagem segundo o modelo de Felder-Silverman. Isso se dá, principalmente, devido à dimensão de captação desse modelo, que diferencia os estudantes entre visuais ou verbais.

Além disso, destaca-se o alto número de fóruns de discussões disponíveis no curso (total de 44). Isso ocorre principalmente pela separação geográfica dos participantes, que usaram essa ferramenta como mecanismo central de comunicação. Conseqüentemente, uma alta massa de dados foi gerada decorrente das interações em fóruns de discussões, como por exemplo a criação de tópicos, visualizações, respostas e postagens. Tais interações foram registradas diariamente, o que caracteriza uma alta comunicação entre todos os participantes, que foram fortemente incentivados a usar a ferramenta.

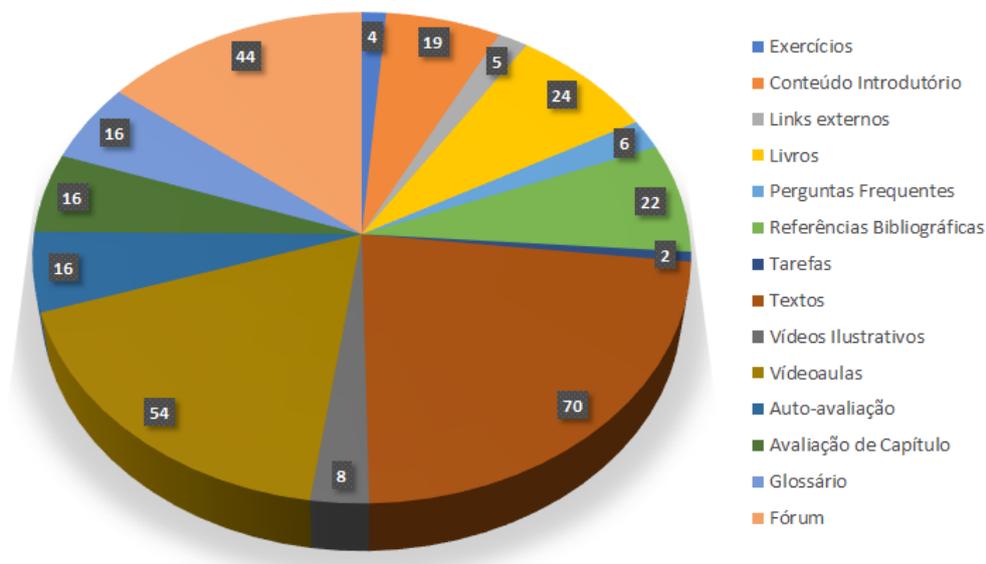


Figura 1 - Recursos educacionais disponíveis no curso avaliado

Adicionalmente, livros, materiais introdutórios e páginas de referências bibliográficas também são recursos recorrentes durante o curso. Os livros possuem objetivo semelhante aos materiais textuais citados anteriormente, porém divergem quanto à forma de apresentação. Neste caso, o estudante pode navegar pelo conteúdo de maneira ordenada e sequencial. Por hipótese, estudantes com predileção por este tipo de recurso podem estar mais inclinados ao estilo de aprendizagem sequencial do modelo de Felder-Silverman, enquanto aqueles com preferência por textos convencionais podem se identificar como globais.

Ademais, objetos relacionados a formulários de auto avaliação, avaliação dos capítulos e glossários acompanham a quantidade de capítulos observados. Em conclusão, objetos relacionados a vídeos ilustrativos, tarefas, exercícios, links externos e páginas de perguntas frequentes representam uma pequena fração dos recursos educacionais, mas ainda assim foram considerados.

4.3 Padrões de comportamento

O modelo de estilos de aprendizagem de Felder e Silverman, assim como os demais modelos propostos na literatura, foi construído com base em conceitos do ensino tradicional. Portanto, para que seja possível detectar esses estilos de maneira automática e dinâmica em um sistema educativo, é necessário mapear o comportamento dos estudantes em ambientes tradicionais para as ações realizadas no ambiente virtual de ensino. Em vista disso, nesta seção são apresentadas as ações desempenhadas pelos usuários no ambiente virtual que serviram como base para o processo de caracterização de perfis durante a execução do curso. Para isso, foi explorado um conjunto de interações e comportamentos capazes de descrever as preferências de cada estudante durante o processo de aprendizagem em um sistema educacional.

Estes padrões de comportamento foram bastante influenciados pelos trabalhos de Graf (2009), García et al. (2007) e Dung e Florea (2012), os quais trabalham com mapeamentos de padrões de utilização dos usuários no sistema Moodle para o modelo FSLSM. Mapeamentos que, por sua vez, foram fortemente baseados no trabalho de Felder e Soloman (2005), os quais apontam as preferências dos estudantes durante o aprendizado e como elas estão relacionadas a cada dimensão do modelo proposto.

| Categoria | Recursos | Dados Coletados |
|---------------------|----------------------------|--|
| Materiais Didáticos | Conteúdo Introdutório | Visitas; Tempo gasto. |
| | Livro | Visitas; Tempo gasto; Navegação. |
| | Conteúdo Textual | Visitas; Tempo gasto. |
| | Conteúdo em Vídeo | Visitas; Tempo gasto. |
| Atividades | Tarefas | Visitas; Tempo gasto. |
| | Exercícios | Visitas; Tempo gasto. |
| Materiais de Apoio | Perguntas Frequentes | Visitas; Tempo gasto. |
| | Referências Bibliográficas | Visitas; Tempo gasto. |
| | Links Externos | Visitas; Tempo gasto. |
| Interação | Fórum de Discussões | Visitas ao fórum; Visitas aos tópicos; Criação de tópicos; Pesquisas; Postagens; Média de palavras; Tempo gasto. |
| | Glossário | Visitas; Tempo gasto; Postagens. |

| | | |
|-----------|-----------------------|---|
| Avaliação | Auto Avaliação | Visitas; Tempo gasto; Questões respondidas. |
| | Avaliação do Capítulo | Visitas; Tempo gasto; Questões respondidas. |

Tabela 2 - Padrões de Comportamento Avaliados.

Um dos requisitos nesta tarefa é que os padrões de comportamento investigados sejam relevantes o suficiente para a predição automática de EA, ou seja, os dados observados devem ser representativos o bastante para que os algoritmos de classificação baseados em aprendizado de máquina sejam capazes de inferir modelos eficientes e precisos.

A partir das premissas citadas, foi selecionado um conjunto dos registros de interação a serem incorporados a esta experimentação, descritos na Tabela 2. Os objetos referentes ao material didático representam a apresentação do assunto em questão, o que pode ser realizada de diferentes formas (textos em *pdf*, apresentações de slides, vídeo-aulas, livros, etc.). Neste caso, os dados de interação dos usuários levados em conta foram a quantidade de visitas e o tempo médio gasto em acessos para esta categoria de recursos. Além disso, nos objetos apresentados no formato “livro”, foram quantificadas as alterações de navegação entre as páginas, ou seja, o número de trocas de páginas. As mesmas informações foram coletadas quanto aos acessos aos materiais introdutórios, exemplos, vídeos ilustrativos, vídeo aulas, páginas de perguntas frequentes, referências bibliográficas, e exercícios publicados pelos docentes.

Para os formulários de avaliação foram consideradas informações mais detalhadas: o número de questões respondidas, o desempenho do aluno em suas respostas e o tempo gasto durante o teste. Quanto às atividades do glossário, foram coletadas a quantidade de acessos às páginas de glossário, o tempo gasto e a quantidade de publicações de cada aluno. Por fim, para os recursos de comunicação foram considerados o número de visitas ao fórum de discussões, número de visitas aos tópicos do fórum, número de tópicos criados por cada usuário, quantidade de postagens publicadas pelo usuário, tempo médio gasto em recursos do fórum, número de pesquisas realizadas e quantidade média de palavras por publicação.

4.4 Classificação de dados

De maneira geral, o aprendizado de máquina é um processo que permite a descoberta de conhecimento a partir da experiência. Nos casos de aprendizado supervisionado, este processo consiste na atribuição de rótulos aos objetos que

serão usados para treinar o método de aprendizado computacional. O rótulo atribuído corresponde à resposta certa conhecida, a resposta com a qual o método deverá aprender e prever para outros objetos que não aqueles no conjunto de treino. No contexto das tarefas de aprendizado de máquina, o processo de classificação se dá por meio de um algoritmo cujo objetivo é prever o rótulo de novas entradas com base na experiência adquirida a partir de exemplos de entrada já rotulados. Neste caso, o primeiro passo para a classificação é mapear e modelar o conjunto de dados do domínio ao qual pretende-se aplicar o algoritmo, preparando os exemplos para o processamento.

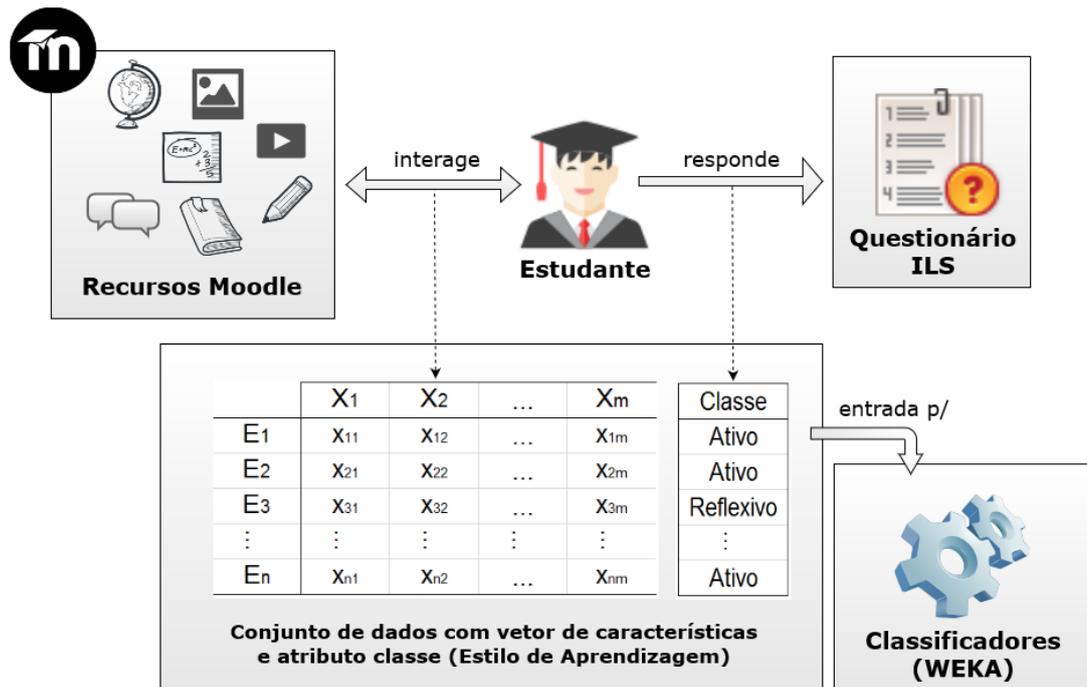


Figura 2 – Metodologia para classificação de Estilos de Aprendizagem

Sendo assim, idealmente o conjunto de dados de entrada, também denominado conjunto de treino, é composto por uma coleção de exemplos, sendo que cada exemplo é constituído por uma lista de atributos independentes, capazes de descrever as características deste exemplo. Portanto, é fundamental para o processo de classificação que essa lista de atributos seja composta por informações significativas e relevantes sobre o exemplo, de modo a representar um objeto do mundo real de maneira precisa. Há também um atributo classe, como já mencionado, o qual é o atributo alvo para os problemas de classificação e regressão.

A ideia na etapa de treinamento dos classificadores é utilizar meios computacionais combinados com modelos matemáticos, estatísticos, associativos ou lógicos para encontrar um modelo que correlacione as características de um exemplo com seu rótulo. De modo geral, o objetivo neste tipo de aplicação é encontrar modelos precisos o suficiente para realizar a predição do rótulo de novos exemplos, usando apenas seu conjunto de atributos, com um alto grau de confiabilidade. Por fim, é realizada a fase

de teste do classificador. Também definida como fase de validação, esta etapa do processo busca avaliar a eficácia do modelo gerado a partir da classificação de novos exemplos ainda não rotulados que compõem o conjunto de teste.

4.5 Metodologia para experimentação

Dadas as definições do processo de classificação de dados, uma das etapas fundamentais foi a construção do conjunto de dados para a execução dos experimentos, onde cada estudante matriculado no curso corresponde a um exemplo observável. Portanto, para cada aluno da amostra, foi coletado um conjunto de atributos que descrevem suas características e preferências durante a experiência com o sistema Moodle. Além disso, cada estudante deveria possuir um rótulo, fundamental para as fases de treinamento e teste das técnicas de aprendizado supervisionado investigadas. Conforme ilustrado na Figura 2, os atributos (ou características) que compõem o conjunto de entrada para os algoritmos são constituídos pelas medidas extraídas dos logs de utilização do sistema Moodle. Estas medidas correspondem às interações e padrões de comportamento descritos na Seção 4.3 (Tabela 2). O rótulo para cada instância corresponde ao estilo de aprendizagem identificado por meio do questionário ILS aplicado aos estudantes no início do curso.

Ao todo foram realizadas quatro classificações distintas durante os experimentos: uma para cada dimensão do modelo de Felder-Silverman. Ou seja, os mesmos conjuntos de atributos descritivos dos estudantes foram avaliados em quatro execuções: uma para cada dimensão. Por fim, o resultado dos algoritmos foi avaliado com validação cruzada de 10 execuções (*10-fold cross validation*) no software WEKA, a qual resultou na extração das medidas de precisão, revocação e F-measure de cada técnica investigada.

5 | EXPERIMENTOS E RESULTADOS

Na Tabela 3 são apresentados todos os algoritmos avaliados neste trabalho, provenientes dos diferentes paradigmas do aprendizado de máquina. Como pode-se observar, para o paradigma estatístico foram experimentados os classificadores correspondentes a *Redes Bayesianas*, *Naive Bayes* e *Support Vector Machine*; com relação a redes neurais, foram explorados o *MultiLayer Perceptron* e a implementação do Weka para *Deep Learning* (DL4J); quanto ao aprendizado baseado em Instâncias foram testados o classificador kNN (também denominado *IBk*) e o *K-Star*; por fim, para o paradigma simbólico foram avaliadas a árvore de decisão de Hoeffding, a árvore J48 (implementação do algoritmo *C4*), a *Random Forest* e *Random Tree*. Porém, dentre todos os experimentos realizados, serão apresentados nas próximas seções

somente aqueles que obtiveram os melhores resultados para cada paradigma, com o intuito de abstrair o processo de avaliação. Portanto, para o paradigma estatístico, foi selecionado o algoritmo *Naive Bayes*; quanto às redes neurais, foi selecionado o classificador *MultiLayer Perceptron*; para o paradigma baseado em instâncias, foi selecionado o *IBk*; e, por fim, para o paradigma simbólico, foi escolhido o algoritmo *J48*, que implementa árvores de decisões.

| Paradigma Estatístico | Redes Neurais | Baseado em Instâncias | Paradigma Simbólico |
|--|---|---------------------------------------|---|
| Redes Bayesianas; Naive Bayes ; Support Vector Machine. | M u l t i L a y e r Perceptron ; Deep Learning. | Classificador kNN ; K-Star. | Hoeffding Tree; J48 ; Random Forest; Random Tree. |

Tabela 3 - Algoritmos avaliados para a classificação de EA. Em negrito, os algoritmos com melhor desempenho.

5.1 Avaliação experimental

Para os experimentos conduzidos neste trabalho, o conjunto de entrada passou por um pré-processamento envolvendo filtros disponíveis no software WEKA. Primeiramente, foi realizado um filtro de instâncias para balanceamento de classes por meio do método *ClassBalancer*. Neste filtro, são atribuídos pesos às instâncias do conjunto de dados para que cada classe tenha o mesmo peso total, mas de maneira que a soma total de pesos em todas as instâncias seja mantida. Esta prática serve como uma solução para problemas de classificação em conjuntos de dados com classes desbalanceadas. Nos experimentos, este problema ocorreu principalmente durante a avaliação da dimensão de percepção do modelo de Felder-Silverman, visto que mais de 87% dos estudantes foram identificados como ‘*sensoriais*’ e apenas 12% foram identificados como ‘*intuitivos*’.

Em uma abordagem inicial, foram realizados experimentos com pré-processamento limitado apenas a balanceamento de classes. No entanto, esta proposta não alcançou resultados viáveis para um cenário real de modelagem de estudantes, visto que a classificação se deu com precisões máximas de 55,2%, 61,9%, 57,6% e 60,3% para as dimensões de processamento, captação, organização e percepção respectivamente. Tais medidas não são consideradas ideais para a adaptatividade de conteúdo em sistemas educacionais, pois se assemelham a um classificador aleatório, e portanto, não são capazes de prever o estilo de aprendizagem de um estudante com eficácia.

Como primeira alternativa para superar estes resultados, foram avaliadas execuções dos algoritmos acompanhadas de um pré-processamento adicional: o filtro de atributos. Sendo assim, nesta execução dos algoritmos, além do método

ClassBalancer foi avaliada a aplicação de uma seleção de características que, como o próprio nome sugere, tem por objetivo eleger um subconjunto de atributos de entrada, reduzindo a dimensão do conjunto de dados. Com essa redução de dimensão, reduz-se a quantidade de informação redundante e/ou espúria, aumentando assim a precisão dos classificadores; além disso, reduz-se a complexidade dos dados, bem como o tempo de processamento para extrair deles algum conhecimento. Ao todo foram avaliadas as técnicas: *CFS Subset Eval*, *Correlation Attribute Eval*, *Info Gain Attribute Eval*, *Principal Components*, e *Wrapper Subset Eval*, disponíveis na biblioteca. Dentre elas, optou-se pela aplicação do método *WrapperSubsetEval*, o qual demonstrou os melhores resultados quanto à precisão dos algoritmos em relação às demais opções.

Em conclusão, todos os resultados demonstrados a seguir foram obtidos a partir da seguinte configuração: 1) construção do conjunto de entrada a partir da base de dados do sistema Moodle (com rótulos identificados pelo questionário ILS); 2) filtro das instâncias com *ClassBalancer*; 3) seleção de atributos com *WrapperSubsetEval*; 4) execução do algoritmo em validação cruzada de 10 execuções (*10-fold cross validation*); e 5) extração das medidas de Precisão, Revocação (Recall) e F-measure de cada uma das técnicas de aprendizado de máquina avaliadas.

5.2 Resultados

Na Figura 3 são apresentados os índices de precisão dos algoritmos avaliados em conjunto com a técnica de seleção de atributos *WrapperSubsetEval*, aplicados à classificação dos estudantes em cada uma das dimensões do modelo de Felder-Silverman. Conforme pode-se observar, a seleção de atributos impactou significativamente o desempenho da predição, de maneira que este pré-processamento, combinado com o rebalanceamento de classes, mostra-se necessário quando da identificação automática de estilos de aprendizagem. A abordagem de refinamento alcançou precisões máximas de 79,4% (*Naive Bayes*), 76,2% (*IBk*), 76,3% (*Naive Bayes*) e 85,9% (*IBk*) para classificar os estudantes quanto às dimensões de processamento, captação, organização e percepção respectivamente. Tais valores superaram consideravelmente os experimentos iniciais, que alcançaram o máximo de 55,2%, 61,9%, 57,6% e 60,3% de precisão nas mesmas tarefas.

Ademais, os experimentos demonstraram que o aprendizado Bayesiano (*Naive Bayes*) obteve o melhor desempenho nas dimensões de processamento e de organização, ao passo que o aprendizado baseado em instâncias (*IBk*) teve o melhor desempenho nas dimensões de captação e percepção. Individualmente, a técnica *IBk* alcançou a melhor média de precisão somando-se os resultados nas quatro dimensões do modelo de Felder-Silverman, com 77,9%. Por outro lado, o algoritmo *J48* obteve a pior, com média de 67,6% de precisão. Portanto, em caso de escolha da melhor técnica de classificação de EA para este estudo de caso, seria selecionada a abordagem baseada em instâncias. Entretanto, nesta avaliação experimental assume-

se que o uso de um único classificador não é suficiente para todas as dimensões, de modo que o uso combinado dos aprendizados Bayesiano e baseado em instâncias provê uma classificação mais apurada para cenários com esta configuração de dados.

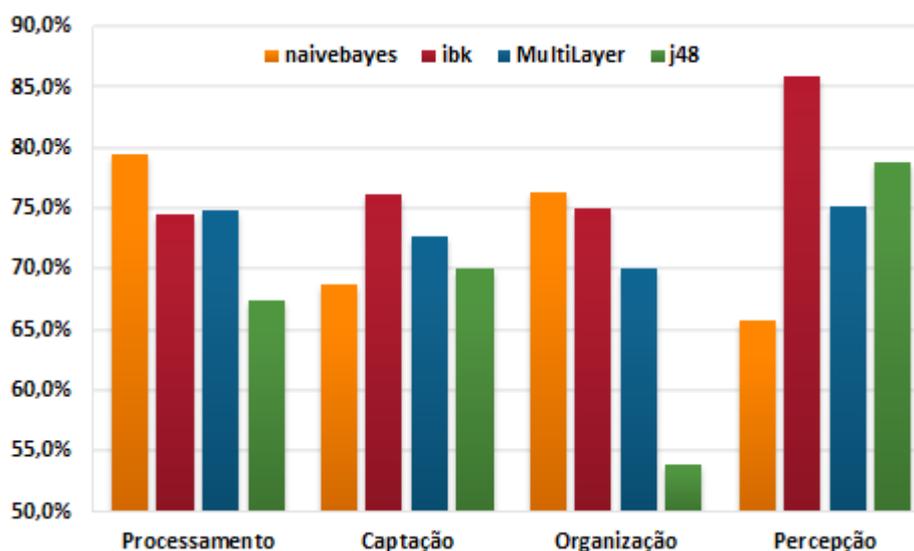


Figura 3 - Análise comparativa da precisão dos classificadores.

No mais, quanto à seleção de atributos, observa-se que os padrões de comportamento mais selecionados pelo algoritmo de poda foram aqueles relacionados à interação com o fórum de discussões, visto que os atributos correspondentes à criação de tópicos, visitas, buscas e publicações no fórum foram selecionados com frequência pelo filtro. Isso pode ser justificado devido ao alto grau de interação com estes recursos por parte dos estudantes que participaram do experimento, produzindo assim, informações mais precisas quanto às suas preferências e comportamento.

5.3 Discussão

Em geral, foram realizadas análises comparativas de diversos algoritmos executados com diferentes configurações, além de uma diversidade de pré-processamentos a fim de se estabelecer um protocolo de experimentação adequado. Como resultado, assume-se que a abordagem proposta alcançou medidas de desempenho viáveis para a aplicação de aprendizado de máquina para a modelagem automática de estudantes em um sistema educacional. Consequentemente, tais resultados validam os padrões de comportamento observados, o estudo de caso conduzido, bem como o processo de experimentação prática dos algoritmos. Quando comparados com trabalhos correlatos, os experimentos conduzidos neste estudo demonstram resultados satisfatórios quanto à precisão dos classificadores.

Conforme apontado na Tabela 4, os percentuais apresentados nesta proposta superam os trabalhos mais clássicos que exploram detecção automática de estilos de aprendizagem, como o de Cha et al. (2006), García et al. (2007), Graf et al. (2009),

e Dung e Florea (2012). Além disso, a precisão obtida encontra-se equiparada aos trabalhos mais recentes (LIYANAGE, 2014; ABDULLAH, 2015), o que sustenta a efetividade da avaliação experimental conduzida.

| Autor | Processamento | Captação | Organização | Percepção |
|------------------------|---------------|----------|-------------|-----------|
| Cha et al. (2006) | 66,7% | 85,7% | 71,4% | 77,8% |
| García et al. (2007) | 58,0% | --- | 63,0% | 77,0% |
| Graf et al. (2009) | 79,3% | 76,7% | 73,3% | 77,3% |
| Dung e Florea (2012) | 72,7% | 79,5% | 65,9% | 70,1% |
| Liyanage et al. (2014) | 65,0% | 76,2% | 77,5% | 75,0% |
| Abdullah et al. (2015) | 90,0% | 76,0% | 70,0% | 85,0% |
| Atual proposta | 79,4% | 76,2% | 76,3% | 85,9% |

Tabela 4 – Comparação da precisão com trabalhos correlatos

Ao comparar os resultados com os trabalhos relacionados, os experimentos demonstraram resultados semelhantes ou superiores em relação à precisão dos outros classificadores em todos os casos. Na dimensão de percepção, o método proposto apresentou o melhor resultado. Comparativamente, o pior desempenho foi na dimensão de processamento, em que o trabalho de Abdullah alcançou 90,0% de precisão contra 82,2%. No entanto, o trabalho de Abdullah considerou apenas 35 alunos, enquanto que o presente trabalho considerou 105 alunos.

Todavia, uma análise comparativa dos índices de precisão alcançados pelos demais trabalhos não reflete necessariamente uma superioridade ou inferioridade da atual proposta, visto que cada trabalho foi conduzido em estudos de caso diferentes, com estudantes, recursos e propriedades de curso diferentes. Portanto, a análise comparativa apresentada em relação aos trabalhos presentes na literatura tem por objetivo apenas situar os atuais percentuais de precisão em relação ao estado da arte, pois não há, nesse caso, como constatar uma absoluta superioridade da proposta.

Além disso, destaca-se a importância das tarefas de pré-processamento para a modelagem de estudantes, visto que o balanceamento de classes e seleção de atributos impactaram significativamente nos resultados. Portanto, entende-se que a metodologia proposta obteve êxito, e pode ser replicada em outros trabalhos. Ademais, assume-se que os padrões de comportamento avaliados foram suficientes para a predição de EA neste curso, visto que os algoritmos avaliados foram capazes de classificar os estudantes com alto grau de acurácia. Em destaque, os padrões de comportamento relacionados ao fórum de discussões mostraram-se relevantes para a construção de um modelo de classificação, de modo que foram selecionados por diversas vezes na tarefa de seleção de atributos.

Por fim, para o estudo de caso, conclui-se que o classificador kNN alcançou os melhores resultados de classificação em geral. Esta técnica apresentou eficácia para a modelagem de estudantes em todos os cenários investigados, e portanto,

proporcionaria um nível de precisão viável caso fosse aplicada individualmente para a predição de EA dos estudantes deste curso. No entanto, uma combinação com outros algoritmos mostra-se mais eficaz em alguns cenários. Além disso, no que se refere às dimensões do modelo Felder-Silverman, os resultados demonstraram que a dimensão de percepção foi a mais suscetível aos métodos de classificação, atingindo mais de 85% de precisão em sua predição. Como cada dimensão corresponde a uma tarefa de classificação distinta, tais informações podem ser relevantes para trabalhos futuros, de modo que abrem margem para a investigação de quais características do curso levaram ao sucesso (ou fracasso) da predição em determinada dimensão. Em caso de fracasso, pode-se, por exemplo, investigar componentes que faltem ao curso estudado e que poderiam influenciar mais significativamente para a predição quanto a esta dimensão.

6 | CONCLUSÕES

No que se refere à experimentação, este trabalho trouxe esclarecimento com relação ao uso de técnicas de aprendizado de máquina na tarefa de caracterização de perfis de aprendizado. Especificamente, foram comparados quatro métodos de aprendizado de máquina voltados à tarefa de classificação: aprendizado Bayesiano, aprendizado baseado em instâncias, redes neurais artificiais, e árvores de decisão. Os resultados demonstraram que o aprendizado Bayesiano tem o melhor desempenho nas dimensões de processamento e de organização, ao passo que o aprendizado baseado em instâncias teve o melhor desempenho nas dimensões de captação e percepção. Em comparação com outros trabalhos, pôde-se notar que estes dois métodos, aprimorados com pré-processamento, superaram alguns dos trabalhos mais recentes, e mostram-se viáveis para aplicação em um sistema educacional adaptativo. Nota-se, ainda, que o uso de um único classificador não é suficiente para todas as dimensões, de modo que o uso combinado do aprendizado Bayesiano e do aprendizado baseado em instâncias provê uma classificação mais apurada do que o que se observou até agora na literatura.

De maneira geral, este trabalho contribui para o estado da arte com resultados de diversos classificadores aplicados ao mesmo problema de predição de EA, visto que esta trata-se de uma lacuna em trabalhos da área. Além disso, são expostos novos resultados que podem guiar estudos futuros, obtidos por meio de uma metodologia bem definida para extração de características em um ambiente virtual de ensino, pré-processamento de dados e coleta de diferentes medidas de avaliação dos resultados. A metodologia proposta também é entendida como uma contribuição ao estado da arte, de modo que pode ser reproduzida em trabalhos futuros. Como proposta para trabalhos futuros, espera-se avaliar a mesma abordagem a partir de outros modelos

de estilos de aprendizagem propostos na literatura. Entende-se que outros estudos apresentam potencial para bons resultados em uma classificação de estudantes. Além disso, espera-se experimentar uma classificação considerando novas características a respeito de cada aluno, como por exemplo, opiniões emitidas nos fóruns de discussões e dados coletados de redes sociais. Outra lacuna aberta é a observação de quais padrões de comportamento avaliados são os mais preditivos, e quais destes estão diretamente relacionados a determinado estilo de aprendizagem. Por fim, como complemento da pesquisa, abre-se a possibilidade de uma avaliação dos modelos de classificação gerados quanto à recomendação de conteúdo aos estudantes, ou seja, uma análise experimental do quanto a detecção automática de EA influencia o desempenho dos alunos durante o aprendizado em um sistema educacional personalizado.

REFERÊNCIAS

ABDULLAH, Manal Abdulaziz. **Learning style classification based on student's behavior in moodle learning management system**. Transactions on Machine Learning and Artificial Intelligence, v. 3, n. 1, p. 28, 2015.

CHA, Hyun Jin et al. **Learning styles diagnosis based on user interface behaviors for the customization of learning interfaces in an intelligent tutoring system**. In: International Conference on Intelligent Tutoring Systems. Springer, Berlin, Heidelberg, 2006. p. 513-524.

COFFIELD, Frank et al. **Learning styles and pedagogy in post-16 learning: A systematic and critical review**. 2004.

DORÇA, Fabiano Azevedo et al. **Detecção e correção automática de estilos de aprendizagem em sistemas adaptativos para educação**. Revista de Informática Teórica e Aplicada, v. 18, n. 2, p. 178-204, 2011.

DORÇA, Fabiano Azevedo et al. **Consistent evolution of student models by automatic detection of learning styles**. IEEE Latin America Transactions, v. 10, n. 5, p. 2150-2161, 2012.

DUNG, Pham Quang; FLOREA, Adina Magda. **An approach for detecting learning styles in learning management systems based on learners' behaviours**. In: International Conference on Education and Management Innovation. 2012. p. 171-177.

FELDER, Richard M. et al. **Learning and teaching styles in engineering education**. Engineering education, v. 78, n. 7, p. 674-681, 1988.

FELDMAN, Juan; MONTESERIN, Ariel; AMANDI, Analía. **Automatic detection of learning styles: state of the art**. Artificial Intelligence Review, v. 44, n. 2, p. 157-186, 2015.

GARCÍA, Patricio et al. **Evaluating Bayesian networks' precision for detecting students' learning styles**. Computers & Education, v. 49, n. 3, p. 794-808, 2007.

GRAF, Sabine. **Adaptivity in learning management systems focussing on learning styles**. 2007.

GRAF, Sabine et al. **Supporting teachers in identifying students' learning styles in learning management systems: An automatic student modelling approach**. Journal of Educational Technology & Society, v. 12, n. 4, p. 3, 2009.

JONASSEN, David H.; GRABOWSKI, Barbara L. **Handbook of individual differences, learning, and instruction**. Routledge, 2012.

- KEEFE, J. W. **Learning style: An overview. In national association of their relationship.** British Journal of Educational Psychology, v. 67, p. 199-212, 1979.
- KOLB, David A. **Experiential learning: Experience as the source of learning and development.** FT press, 1976.
- LIYANAGE, M. Prabhani Pitigala; GUNAWARDENA, KS Lasith; HIRAKAWA, Masahito. **Using Learning Styles to Enhance Learning Management Systems.** ICTer, v. 7, n. 2, 2014.
- MYERS, Isabel Briggs. **The Myers-Briggs Type Indicator: Manual.** 1985.
- PASK, Gordon. **A fresh look at cognition and the individual.** International Journal of Man-Machine Studies, v. 4, n. 3, p. 211-216, 1972.
- 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.
- SOLOMAN, Barbara A.; FELDER, Richard M. **Index of learning styles questionnaire.** NC State University. Available online at: <http://www.engr.ncsu.edu/learningstyles/ilsweb.html> (last visited on 14.05.2010), v. 70, 2005.
- 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.

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