UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

Técnicas de aprendizado de máquina aplicadas à classificação de estudantes a partir de estilos de aprendizagem

Lucas Daniel Ferreira

Dissertação de Mestrado do Programa de Pós-Graduação em Ciências
de Computação e Matemática Computacional (PPG-CMC)

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Lucas Daniel Ferreira

Técnicas de aprendizado de máquina aplicadas à classificação de estudantes a partir de estilos de aprendizagem

Dissertação apresentada ao Instituto de Ciências
Matemáticas e de Computação – ICMC-USP,
como parte dos requisitos para obtenção do título
de Mestre em Ciências – Ciências de Computação e
Matemática Computacional. *VERSÃO REVISADA*

Área de Concentração: Ciências de Computação e
Matemática Computacional

Orientador: Prof. Dr. José Fernando Rodrigues Junior

USP – São Carlos
Junho de 2018

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

D184t Daniel Ferreira, Lucas
Técnicas de aprendizado de máquina aplicadas à
classificação de estudantes a partir de estilos de
aprendizagem / Lucas Daniel Ferreira; orientador
José Fernando Rodrigues Junior. -- São Carlos, 2018.
121 p.

Dissertação (Mestrado - Programa de Pós-Graduação
em Ciências de Computação e Matemática
Computacional) -- Instituto de Ciências Matemáticas
e de Computação, Universidade de São Paulo, 2018.

1. Estilos de Aprendizagem. 2. Aprendizado de
Máquina. 3. Sistemas Educacionais Adaptativos. 4.
Felder-Silverman. 5. Classificação de Estudantes. I.
Rodrigues Junior, José Fernando, orient. II. Título.

Bibliotecários responsáveis pela estrutura de catalogação da publicação de acordo com a AACR2:
Gláucia Maria Saia Cristianini - CRB - 8/4938
Juliana de Souza Moraes - CRB - 8/6176

Lucas Daniel Ferreira

**Machine Learning techniques applied to automatic detection
of Learning Styles in educational systems**

Master dissertation submitted to the Institute of
Mathematics and Computer Sciences – ICMC-USP,
in partial fulfillment of the requirements for the
degree of the Master Program in Computer Science
and Computational Mathematics. *FINAL VERSION*

Concentration Area: Computer Science and
Computational Mathematics

Advisor: Prof. Dr. José Fernando Rodrigues Junior

USP – São Carlos
June 2018

Este trabalho é dedicado às pessoas que estiveram ao meu lado ao longo de toda vida: meus pais Sandra e Daniel, e meu irmão Danilo. Aos amigos e colegas, que me incentivaram todos os dias e ofereceram apoio nos momentos críticos.

AGRADECIMENTOS

Aos meus pais, pelo amor, incentivo e apoio incondicional. Obrigado ao meu irmão e demais familiares, que sempre compreenderam os motivos de ausência dedicados ao estudo. À Universidade de São Paulo, ICMC, seu corpo docente, direção e administração pela oportunidade e estrutura concedidas. Sou inteiramente grato ao meu orientador Prof. Dr. José Fernando Rodrigues Jr, pelo total suporte e disponibilidade, além das correções e incentivos. A todos os professores do ICMC, que direta ou indiretamente contribuíram com meu crescimento pessoal e profissional. Agradeço também ao Prof. Dr. José Fernando Mantovani Micali, pela sugestão do tema. Aos colegas de pesquisa pela experiência compartilhada, em especial: Misael Costa Júnior, Joelson Santos, Jonathan Ramos, Felipe Maciel e Naylor Garcia Bachiega. Às meninas do curso de Fonoaudiologia da Faculdade de Odontologia de Bauru, que colaboraram imensamente com a pesquisa durante as etapas de coleta de dados, em especial à Prof. Dra. Deborah Ferrari, Paula Paiva e Marina Morettin. E aos amigos, que me ouviram falar sobre cada etapa do mestrado durante os últimos 3 anos. Por fim, a todos que direta ou indiretamente fizeram parte da minha formação, o meu muito obrigado.

*“O verdadeiro homem mede a sua força
quando se defronta com o obstáculo.”
(Antoine de Saint-Exupéry)*

RESUMO

FERREIRA, L. D. **Técnicas de aprendizado de máquina aplicadas à classificação de estudantes a partir de estilos de aprendizagem.** 2018. 121 p. Dissertação (Mestrado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2018.

Com efeito, 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. Isso ocorre pois o preenchimento dos questionários demanda um esforço adicional por parte do aluno, além fazer uma avaliação estática dos EA, desconsiderando possíveis variações em suas preferências ao longo do tempo. Supõe-se que uma estratégia de detecção automática e dinâmica dos EA baseada no comportamento dos estudantes pode ser mais proveitosa neste sentido, pois é isenta destas limitações. Deste modo, a proposta neste trabalho é investigar diferentes técnicas relacionadas ao aprendizado de máquina (especialmente algoritmos de classificação) aplicadas à predição automática dos estilos de aprendizagem de estudantes, a partir de suas interações em um ambiente virtual de ensino. Dentre os inúmeros modelos de EA propostos na literatura, optou-se por usar o modelo de Felder-Silverman como base para os experimentos. Como estudo de caso, foram rastreadas as interações de 105 estudantes de um curso de pós-graduação em fonoaudiologia ministrado integralmente pelo sistema Moodle. Além disso, estes alunos foram solicitados a responder ao questionário ILS, o qual indica a preferência de cada indivíduo de acordo com o modelo de Felder-Silverman. Para a construção dos conjuntos de dados, foram coletadas informações como a quantidade de visitas, tempo gasto e interação dos usuários em cada tipo de recurso (recursos de vídeo, formulários de avaliação, fórum, etc.). Estes conjuntos de dados no formato atributo-valor serviram de entrada para quatro algoritmos de classificação: Naïve Bayes, aprendizado baseado em instâncias (kNN), Redes Neurais Artificiais (MultiLayer Perceptron) e Árvores de Decisão (J48), combinados com métodos de seleção de atributos e executados em validação cruzada. 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. Portanto, o presente trabalho contribui para o contexto da informática aplicada à educação,

especificamente no que diz respeito à implementação de sistemas educacionais adaptativos, com base em uma análise comparativa entre diferentes técnicas aplicadas ao mesmo problema. Sendo assim, as conclusões obtidas devem colaborar para o aprimoramento do processo de modelagem de estudantes. Além disso, são levantadas discussões a respeito dos resultados, que podem auxiliar na direção de futuros trabalhos da área.

Palavras-chave: Estilos de Aprendizagem, Aprendizado de Máquina, Sistemas Educacionais Adaptativos, Felder-Silverman, Aprendizagem Adaptativa.

ABSTRACT

FERREIRA, L. D. **Machine Learning techniques applied to automatic detection of Learning Styles in educational systems**. 2018. 121 p. Dissertação (Mestrado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2018.

In fact, several studies in the areas of cognitive psychology and pedagogy point out that each individual has different ways of capturing, processing, analyzing and organizing information during the learning process, which supports the concept of Learning Styles (LS). Therefore, several adaptive educational systems were proposed with the aim of providing personalized content in their courses. However, in most cases, these systems use questionnaires to identify learning styles, and this method may prove unfeasible in some situations. This is because filling in the questionnaires requires an additional effort on the part of the student, besides, this approach makes a static evaluation of the LS, disregarding possible variations in their preferences over time. It is assumed that an automatic and dynamic detection of LS based on student behavior may be more useful in this sense, since it is exempt from these limitations. In this way, the proposal in this work is to investigate different techniques related to machine learning (especially classification algorithms) applied to the automatic prediction of student learning styles, based on their interactions in a virtual teaching environment. Among the many LS models proposed in the literature, we chose to use the Felder-Silverman model (FSLSM). As a case study, the interactions of 105 students from a post-graduate course in speech therapy were studied. In addition, these students were asked to respond to the ILS questionnaire, which indicates the preference of each individual according to FSLSM. In order to construct the data sets, information was collected such as the number of visits, time spent and user interaction in each type of resource (video resources, evaluation forms, forum, etc.). These data sets in the attribute-value format served as input to four classification algorithms: Naïve Bayes, instance-based learning (kNN), MultiLayer Perceptron and Decision Trees (J48), combined with attribute selection methods and executed in cross-validation. For the experimentation, the accuracy and error rates of the algorithms were evaluated in relation to the results indicated by the ILS questionnaire, in each one of FSLSM dimensions. Our results pointed out to the use of more than one classifier, Naïve Bayes and Instance-based Learning, depending on the learning style dimension. We compared our methodology to seven works of the literature; the results demonstrated a performance superior to the previous works in almost every dimension. The present work contributes to the context of informatics applied to education, specifically with regard to the implementation of adaptive educational systems, based on a comparative analysis of different methods applied to the same problem. Therefore, the conclusions obtained should contribute to the improvement of the student modeling process. In addition, discussions are held regarding the results, which may assist in the direction of future work in this area.

Keywords: Learning Styles, Machine Learning, Adaptive Educational Systems, Felder-Silverman, Adaptative Learning.

LISTA DE ILUSTRAÇÕES

Figura 1 – Recursos básicos de um LMS de acordo com Clark e Mayer (CLARK; MAYER, 2016)).	30
Figura 2 – Arquitetura de um Sistema Educacional Adaptativo (adaptado de Henze e Nejdí (HENZE; NEJDÍ, 2004)).	32
Figura 3 – A divisão do cérebro de acordo com Herrmann.	44
Figura 4 – Modelo de estilos de aprendizagem de Kolb.	46
Figura 5 – Modelo de estilos de aprendizagem de Felder-Silverman.	48
Figura 6 – Hierarquia do aprendizado de acordo com o grau de supervisão (Monard e Baranauskas, 2003).	56
Figura 7 – Hierarquia do Aprendizado (Monard e Baranauskas, 2003).	58
Figura 8 – Conjunto de exemplos no formato atributo-valor.	59
Figura 9 – Exemplo de Árvore de Decisão (Mitchell, 1997).	61
Figura 10 – Exemplo de K-Nearest Neighbours.	63
Figura 11 – Recursos educacionais disponíveis no curso avaliado.	85
Figura 12 – Recursos educacionais agrupados por seções.	86
Figura 13 – Metodologia para a classificação de estilos de aprendizagem.	89
Figura 14 – Metodologia experimental.	96
Figura 15 – Resultados da classificação com balanceamento de classes e seleção de atributos.	97
Figura 16 – Análise comparativa da precisão dos classificadores.	99
Figura 17 – Metodologia para extração dos resultados com seleção de exemplos.	101
Figura 18 – Resultados da classificação com filtro de exemplos.	102
Figura 19 – Análise comparativa da precisão dos classificadores com refinamento de exemplos.	104

LISTA DE TABELAS

Tabela 1 – Definição dos Tipos de Personalidade de acordo com o modelo Myers-Briggs.	41
Tabela 2 – Definição dos comportamentos dos estudantes segundo Grasha-Riechmann.	42
Tabela 3 – Resultados do questionário ILS.	83
Tabela 4 – Padrões de Comportamento Avaliados.	88
Tabela 5 – Algoritmos avaliados para a classificação de EA. Em negrito, os algoritmos com melhor desempenho.	94
Tabela 6 – Comparação da precisão com trabalhos correlatos.	106

LISTA DE ABREVIATURAS E SIGLAS

AD	Árvore de Decisão
AM	Aprendizado de Máquina
CEA	Combinação de Estilos de Aprendizagem
DeLes	<i>Detecting Learning Styles</i>
DTW	<i>Dynamic Time Warping</i>
e-LORS	<i>e-Learning Object Recommendation System</i>
FSLSM	Modelo de Estilos de Aprendizagem de Felder e Silverman
HBDI	Instrumento da Dominância Cerebral de Herrmann
HMM	Modelos Ocultos de Markov
IA	Inteligência Artificial
IA	Inteligência Artificial
ILS	Index of Learning Styles
KLSI	<i>Kolb's Learning Style Inventory</i>
kNN	K-Nearest-Neighbours
LMS	<i>Learning Management Systems</i>
LOM	<i>Learning Object Metadata</i>
LSI	Inventário de Estilos de Aprendizagem
LSQ	Questionário de Estilos de Aprendizagem
MBTI	Indicadores de Tipos de Myers-Briggs
ME	Modelo de Estudante
ME	Modelo do Estudante
OA	Objetos de Aprendizagem
RNA	Redes Neurais Artificiais
SAVER	<i>Software de Assistencia Virtual para Educación Remota</i>
SHR	Sistema Híbrido de Recomendações
SLSS	Student Learning Styles Scale
SVM	<i>Support Vector Machine</i>
TCAM	Teoria Cognitiva da Aprendizagem Multimídia de Mayer

SUMÁRIO

1	INTRODUÇÃO	23
2	ADAPTATIVIDADE EM SISTEMAS EDUCACIONAIS	29
2.1	Considerações iniciais	29
2.2	Sistemas de gerenciamento do aprendizado	30
2.3	Metodologia para personalização de conteúdo	31
2.4	Modelagem de estudantes	34
2.5	Considerações finais	36
3	ESTILOS DE APRENDIZAGEM	39
3.1	Considerações iniciais	39
3.2	Modelos propostos	40
3.2.1	<i>Os indicadores de Myers-Briggs</i>	40
3.2.2	<i>O modelo de Grasha-Riechmann</i>	41
3.2.3	<i>O modelo de Pask</i>	43
3.2.4	<i>O modelo de Herrmann</i>	44
3.2.5	<i>O modelo de Kolb</i>	45
3.2.6	<i>O modelo de Honey-Mumford</i>	47
3.2.7	<i>O modelo de Felder-Silvermann</i>	48
3.3	Considerações finais	50
4	APRENDIZADO DE MÁQUINA	53
4.1	Considerações Iniciais	53
4.2	Características gerais	54
4.2.1	<i>Inferência lógica</i>	55
4.2.2	<i>Modos de aprendizado</i>	56
4.2.3	<i>Tarefas de aprendizado</i>	57
4.3	Classificação de dados	58
4.3.1	<i>Paradigma simbólico</i>	60
4.3.2	<i>Paradigma estatístico</i>	61
4.3.3	<i>Paradigma baseado em exemplos (Instance-Based)</i>	62
4.3.4	<i>Paradigma conexionista</i>	64
4.4	Considerações finais	64

5	LITERATURA RELACIONADA	67
5.1	Considerações iniciais	67
5.2	Identificação automática de EA	68
5.3	Técnicas para recomendação de recursos educacionais	74
5.4	Considerações finais	79
6	MATERIAIS E MÉTODOS	83
6.1	Contexto, participantes e características do curso	83
6.2	Recursos educacionais disponíveis	84
6.3	Padrões de comportamento avaliados	87
6.4	Classificação de estilos de aprendizagem	89
6.4.1	<i>Validação cruzada</i>	90
6.4.2	<i>Software Weka</i>	91
6.4.3	<i>Protocolo de experimentação</i>	91
7	EXPERIMENTOS E RESULTADOS	93
7.1	Considerações iniciais	93
7.2	Avaliação experimental	94
7.2.1	<i>Resultados</i>	96
7.2.2	<i>Discussão</i>	98
7.3	Refinamento dos resultados com filtro de exemplos	100
7.3.1	<i>Resultados</i>	101
7.3.2	<i>Discussão</i>	103
7.4	Discussões finais	105
8	CONCLUSÕES	109
	REFERÊNCIAS	113

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 distancia 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. São exemplos de LMS já consolidados o Moodle ([MOODLE, 2017](#)), o Blackboard ([BLACKBOARD, 2017](#)) e o Sakai ([SAKAI, 2017](#)), dentre outros sistemas que atendem com sucesso à demanda para o oferecimento de cursos por meio da internet. 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. Em outras palavras, é mais difícil para o professor considerar as diferenças intelectuais de cada indivíduo durante um curso online, o que resulta em uma abordagem de ensino igual para todos, desconsiderando suas necessidades e especificidades ([AKBULUT; CARDAK, 2012](#)).

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 (([KEEFE, 1979](#)), ([GOMES et al., 2009](#)), ([FELDER, 1996](#)), ([JONASSEN; GRABOWSKI, 2012](#))) 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). Os estilos de aprendizagem podem ser entendidos como uma descrição das ações e comportamentos que determinam as preferências de um estudante durante o processo de aprendizado. Por exemplo,

enquanto alguns estudantes preferem aprender por meio de gráficos, figuras e apresentações, outros possuem maior facilidade para aprender por meio de textos ou palavras faladas.

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).

Motivação

A teoria dos Estilos de Aprendizagem tem motivado diversas pesquisas ((GARCÍA *et al.*, 2007), (GRAF; LIU *et al.*, 2009), (DUNG; FLOREA, 2012), (LIYANAGE *et al.*, 2014), entre outros) 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 para modelagem de perfis 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. Com efeito, esta abordagem personalizada de ensino, onde cada indivíduo recebe objetos de aprendizagem que se encaixam em suas preferências, pode tornar a aquisição de conhecimento mais proveitosa, além de melhorar o desempenho dos estudantes.

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 *et al.*, 2007) (GRAF; LIU *et al.*, 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). Entretanto, de acordo com (DORCA *et al.*, 2012), os Estilos de Aprendizagem podem variar ao longo do tempo, invalidando o resultado apontado inicialmente.

Uma vez que o processo de construção do perfil de um usuário se dá por meio da

análise e processamento de seus dados pessoais e interação com um sistema de gerenciamento do aprendizado, supõe-se que a 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, a determinação dos EA por meios computacionais baseada no comportamento dos estudantes em um ambiente virtual de estudos 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.

Proposta do trabalho

É premissa deste trabalho, e de outros existentes ((GARCÍA *et al.*, 2007), (GRAF; LIU *et al.*, 2009), (DORÇA *et al.*, 2011), (DORÇA *et al.*, 2012), (CARVALHO *et al.*, 2014), (DUNG; FLOREA, 2012), (LIYANAGE *et al.*, 2014), (SILVA; FERREIRA; PIMENTEL, 2016), (GONÇALVES *et al.*, 2016) e (SENA *et al.*, 2016)) que uma abordagem de detecção automática dos estilos de aprendizagem abre caminho para um vasto campo de investigação para a obtenção de melhores resultados no que se refere ao aproveitamento intelectual dos alunos. Assim, o objetivo deste trabalho é explorar diferentes técnicas de aprendizado de máquina supervisionado, relacionadas especificamente à tarefa de classificação, cujo objetivo é prever o rótulo de novos exemplos com base nos exemplos de entrada já rotulados. 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.

Visão geral da metodologia de trabalho

No desenvolvimento do trabalho, foi utilizado como estudo de caso um curso de especialização na área de Fonoaudiologia (Reabilitação Auditiva), onde os recursos educacionais são oferecidos integralmente pelo sistema Moodle. Além disso, toda a comunicação entre os participantes do curso, que conta com 105 estudantes oriundos de diversas localidades do Brasil, é realizada por meio do fórum de discussões, o que implica em uma interação diária dos

usuários com o sistema, e consequentemente, produz uma alta quantidade de dados que podem ser avaliados no processo de modelagem de perfil. Ademais, o curso em questão oferece uma alta gama de recursos, com diversidade de meios de apresentação. Ou seja, são disponibilizados aos alunos materiais baseados em vídeos, gráficos, textos, diagramas, animações, questionários de auto-avaliação, questionários de avaliação de cada seção, enquetes, tarefas, dentre outros recursos.

Este ambiente real de ensino proporcionou a esta pesquisa uma base sólida para experimentação, visto que a construção dos conjuntos de dados para classificação de perfis se deu por meio do rastreamento das ações que representam o comportamento dos usuários no ambiente Moodle. Portanto, uma das etapas fundamentais deste trabalho foi o processo de extração de características para os experimentos, que consistiu da coleta dos *logs* de navegação dos estudantes matriculados a fim de representar a interação dos usuários (quantidade de visitas, tempo gasto, quantidade de publicações, padrões de navegação, etc.) em relação a cada tipo de recurso disponível no curso. Porém, foram considerados somente dados de *logs* que também são disponibilizados para extração em outros LMSs, a fim de que as conclusões obtidas neste estudo sejam genéricas e aplicáveis a diversos sistemas. Além disso, como base para os experimentos foi necessário conhecer com quais EA os alunos participantes do estudo de caso se identificavam no início do curso. Diversos modelos de estilos de aprendizagem foram propostos na literatura, e dentre estes, optou-se por utilizar o Modelo de Estilos de Aprendizagem de Felder-Silverman (FELDER; SILVERMAN, 1988), o qual sintetiza descobertas de diversos estudos para formular um modelo padronizado que classifica o estudante em quatro diferentes dimensões: visual/verbal, ativo/reflexivo, sensorial/intuitivo, sequencial/global.

Organização do trabalho

Este trabalho está organizado da seguinte maneira: No Capítulo 2 são apresentados os principais conceitos que envolvem sistemas educacionais e as possibilidades para a adaptatividade de conteúdo em tais aplicações. Em seguida, no Capítulo 3, são explorados os conceitos fundamentais referentes à teoria dos Estilos de Aprendizagem, com enfoque nas características dos principais modelos presentes na literatura e a justificativa da escolha pelo Modelo de Felder-Silverman. No Capítulo 4 são exploradas as definições a respeito da área de estudos que envolve Aprendizado de Máquina, especialmente quanto à tarefa de classificação. Para isso, é realizada uma breve explicação a respeito dos principais paradigmas de aprendizado. Em sequência, o Capítulo 5 apresenta um compilado de trabalhos relacionados, passando por trabalhos mais clássicos até os mais contemporâneos da área. Além disso, são apontadas as diferenças entre este trabalho e os demais. No Capítulo 6, é descrita a metodologia implementada, detalhando o processo de extração de características, contexto, fonte de dados, padrões de comportamento e métodos para avaliar diferentes técnicas de aprendizado de máquina. Por fim, no Capítulo 7 é apresentada a avaliação experimental, com a comparação sistemática do desem-

penho dos diversos algoritmos aplicados à classificação de EA. Além disso, são demonstrados os pré-processamentos aplicados, acompanhados dos resultados obtidos. Considerações finais, conclusões e direcionamentos futuros são discutidos no Capítulo 8.

ADAPTATIVIDADE EM SISTEMAS EDUCACIONAIS

2.1 Considerações iniciais

Sistemas de gerenciamento do aprendizado - termo derivado do inglês *Learning Management Systems* - são ferramentas cujo intuito é de dar suporte a professores e coordenadores para a criação e administração de cursos online. São exemplos de LMS o Moodle ([MOODLE, 2017](#)), o Blackboard ([BLACKBOARD, 2017](#)) e o Sakai ([SAKAI, 2017](#)). Essas aplicações oferecem uma grande variedade de funcionalidades que podem ser incluídas em seus cursos, como materiais didáticos, questionários, fóruns, chats, exercícios, tarefas, wikis, entre outros. Por este motivo, essas ferramentas se tornaram bastante populares no contexto educacional no que se refere à aprendizagem suportada por tecnologia e são comumente usadas por instituições de ensino no oferecimento de suas disciplinas. No entanto, por si só, esses sistemas fornecem muito pouco ou, na maioria dos casos, nenhuma personalização do conteúdo apresentado aos usuários, com uma abordagem de ensino igual para todos, que desconsidera as preferências e particularidades de cada indivíduo.

O objetivo neste trabalho é experimentar técnicas para a modelagem automática de estudantes em um LMS, incorporando estilos de aprendizagem. Portanto, neste capítulo é apresentada uma visão geral destes sistemas, explorando suas características, limitações e contribuições para o contexto educacional. Além disso, serão explorados os métodos para adaptatividade em sistemas de ensino, a fim de detalhar o processo para a recomendação de conteúdo personalizado a partir das características e comportamento dos usuários. Por fim, é discutida especificamente a tarefa de modelagem de estudantes, que é uma das etapas que compõem o processo de adaptatividade em cursos online. O objetivo neste capítulo é compreender as possibilidades para a adaptabilidade em sistemas educacionais, bem como aprofundar a modelagem automática de estudantes, que é o tema de interesse neste trabalho.

2.2 Sistemas de gerenciamento do aprendizado

Também denominados sistemas de gerenciamento de cursos, ou plataformas de *e-learning*, os *Learning Management Systems* podem ser definidos como uma aplicação de software, ou tecnologia Web usada para planejar, implementar e avaliar um processo específico de aprendizagem (ALIAS; ZAINUDDIN, 2005). Outra definição proposta por Clark e Mayer (CLARK; MAYER, 2016) expõe que uma plataforma de *e-learning* é um software servidor que auxilia o ensino de qualquer material didático por meio da internet, além de fornecer suporte à organização dos processos relacionados. Além disso, Clark e Mayer definem cinco funcionalidades fundamentais (Figura 1) que devem ser abrangidas por estes sistemas: o suporte à apresentação de recursos educacionais; o suporte a ferramentas de comunicação, tais como fórum, chat e vídeo conferência; o suporte à criação de questionários, exercícios e tarefas; o suporte à avaliação da performance dos alunos por parte dos docentes; e por fim, o suporte à administração dos cursos no que diz respeito aos materiais, cursos e alunos.

Figura 1 – Recursos básicos de um LMS de acordo com Clark e Mayer (CLARK; MAYER, 2016)).

Na literatura, também é possível encontrar o termo “Sistema de Gerenciamento de Conteúdo de Aprendizagem”, onde o principal diferencial para os LMS convencionais é a proposta de objetos de aprendizagem reusáveis. Sendo assim, o foco nessas ferramentas é oferecer suporte para que os docentes organizem cursos a partir de repositórios de recursos já existentes. Neste contexto, os ambientes de aprendizado podem ser considerados como espaços vazios que são preenchidos com recursos educacionais pelos professores. De qualquer maneira, os desenvolvedores destes sistemas decidem como o aprendizado será realizado, e para

tanto, organizam a construção do modelo desses sistemas a partir de estratégias pedagógicas. Tais estratégias podem ser, por exemplo, baseadas em teorias educacionais, como cognição, construtivismo e construcionismo (GRAF, 2007).

A evolução das tecnologias web viabilizou processos de colaboração em tempo real, possibilitando que o aprendiz construa seu conhecimento por meio da interação com o professor e com outros participantes. Isto pode ser praticado, por exemplo, por meio de uma sala de aula virtual, modificando assim as relações de tempo e espaço, bem como a relação entre aluno e professor, que deixa de ser restrita à sala de aula (GOMES *et al.*, 2009). No entanto, existem limitações nas atuais plataformas de gestão de aprendizado, como por exemplo, para mediar a interação entre tutores e aprendizes, os sistemas atuais utilizam apenas a troca de artefatos (mídias contínuas ou estáticas) e mensagens instantâneas ou assíncronas (fóruns, chats, e-mail). Além disso, diversos estudos identificam problemas relacionados com: limites da percepção provida pelos LMS, falhas de usabilidade, dificuldades de navegação, falta de interatividade síncrona integrada, e pouca flexibilidade na manipulação de objetos de aprendizagem (CONDE *et al.*, 2014).

Dentre os principais componentes de um LMS estão os Objetos de Aprendizagem (OA), que podem ser compreendidos como qualquer recurso, digital ou não, que possa ser utilizado e reutilizado para o suporte ao ensino. Para Audino e Nascimento (AUDINO; NASCIMENTO, 2012), objetos de aprendizagem “são recursos digitais dinâmicos, interativos e reutilizáveis em diferentes ambientes de aprendizagem elaborados a partir de uma base tecnológica”.

Um objeto de aprendizagem pode ser usado em diferentes contextos e em diferentes plataformas de gerenciamento do aprendizado. A principal característica de um OA é sua reusabilidade, que se dá por meio de repositórios que armazenam os objetos logicamente, permitindo sua localização a partir da buscas por assunto, por nível de dificuldade, por autor ou por relação com outros objetos. São exemplos de OA: páginas web, figuras, recursos de áudio, animações, apresentações em *slides*, jogos, textos em PDF, avaliações eletrônicas, entre outros.

2.3 Metodologia para personalização de conteúdo

Os “Sistemas de Recomendação” são grandes aliados da personalização de sistemas computacionais, principalmente na web, pois são capazes de identificar preferências e sugerir itens relevantes para cada usuário, de acordo com a análise de seu comportamento (navegação, acessos e/ou ações), preferências, entre outros aspectos (CAZELLA; NUNES; REATEGUI, 2010). No caso de Sistemas Educacionais Adaptativos, o objetivo é proporcionar aos alunos um ambiente que se adapta de forma inteligente às suas necessidades, apresentando informações adequadas, material de aprendizagem, retorno e recomendações com base em suas características pessoais, e por este fato, de maneira geral, proporcionam melhor aproveitamento durante o processo de aprendizado (OLIVEIRA, 2013). Neste contexto, Graf (GRAF *et al.*, 2012) define que o termo

“adaptativo” refere-se à funcionalidade que um sistema tem para fornecer automaticamente diferentes experiências de aprendizagem para os alunos de acordo com suas características e necessidades. Portanto, a adoção de uma abordagem de aprendizagem adaptativa permite que o docente organize um curso com conteúdo flexível, de forma que os objetos de aprendizagem apresentados estejam em conformidade com o nível de conhecimento e preferências de cada estudante. Existem diversas abordagens que buscam usar métodos computacionais para aprimorar o aprendizado por meio da personalização do ensino, no entanto, na maioria dos casos segue-se uma arquitetura/metodologia comum. Na figura 2, é ilustrada uma metodologia adaptada do trabalho conduzido por Henze e Nejdl ([HENZE; NEJDL, 2004](#)), que propõem uma arquitetura lógica para o funcionamento de sistemas educacionais adaptativos em geral. Na proposta, os autores investigam como uma descrição lógica pode ser empregada para caracterizar os sistemas educacionais adaptativos. Além disso é apresentada uma definição de aplicações baseada na lógica de primeira ordem, e discutida a aplicabilidade desta abordagem em propostas de sistemas já existentes.

Figura 2 – Arquitetura de um Sistema Educacional Adaptativo (adaptado de Henze e Nejdl ([HENZE; NEJDL, 2004](#))).

Conforme observado na figura, existem diversas etapas que compõem a metodologia de um sistema educacional adaptativo. De maneira geral, este ciclo é iniciado a partir da interação do estudante com o sistema e finalizado com o retorno de conteúdo personalizado, e assim sucessivamente durante um processo contínuo. Dentro deste processo, são definidos quatro diferentes módulos que possuem funções específicas na arquitetura do sistema:

- **Espaço do Conhecimento:** composto pelos recursos educacionais e informações des-

critivas associadas, além do modelo de domínio, que contém a descrição da estrutura de conhecimento do contexto e os objetivos de aprendizagem associados. No geral, corresponde ao material didático e outros recursos disponibilizados pelo docente para o acesso dos alunos (usualmente, estes recursos possuem atributos que descrevem suas características).

- **Modelo de Usuário:** descreve o perfil do estudante, com informações que incluem estilos de aprendizagem, estilos cognitivos, indicadores de personalidade, nível de conhecimento ou indicadores híbridos, entre outros (dependendo da abordagem de cada sistema). Este módulo atua como um repositório de informações que possam servir de parâmetro para diferenciar os usuários em diferentes aspectos, e possibilitar a personalização do conteúdo.
- **Observações:** contém os resultados de interações entre o aluno e o sistema em tempo de execução. São exemplos de observações os acessos do aluno a determinado recurso, a quantidade de tempo gasto durante a interação, a sequência de ações tomadas durante a experiência com o sistema, entre outros padrões de comportamento que podem ser rastreados. Este mapeamento do comportamento do estudante atualiza continuamente o Modelo de Usuário, o que proporciona uma construção e manutenção dinâmica do perfil dos usuários.
- **Modelo Adaptativo:** por fim, o módulo que possui as regras que descrevem a maneira segundo a qual o sistema educacional adaptativo deverá se comportar em tempo de execução. Estas regras serão responsáveis por definir os métodos para seleção de objetos de aprendizagem, e além disso, propor a trilha de aprendizagem (sequência de objetos de aprendizagem) personalizada para os usuários. Portanto, neste módulo são definidas as métricas para avaliar quais recursos presentes no Espaço do Conhecimento correspondem a quais perfis presentes no Modelo de Usuário, para enfim recomendar conteúdo personalizado para o estudante.

Neste trabalho, é explorada especificamente a tarefa de modelagem dos usuários para um sistema educacional adaptativo. Além desta tarefa se demonstrar fundamental para o processo, entende-se que há um vasto campo para investigação neste sentido, onde busca-se alcançar precisão e confiabilidade ao apontar a qual perfil pertence cada estudante. Conforme mencionado anteriormente, diversas abordagens foram propostas para se construir o modelo de usuário, passando por Estilos de Aprendizagem, até a classificação de níveis de conhecimento de cada aluno. No entanto, o foco deste trabalho está relacionado diretamente à identificação de estilos de aprendizagem dos estudantes de maneira automática para a construção e atualização de seus respectivos modelos de usuários.

2.4 Modelagem de estudantes

A modelagem dos usuários - também denominada *Modelagem de Estudantes* em aplicações educacionais - pode ser entendida como o processo de construção e atualização do perfil dos usuários em sistemas de recomendação, e portanto, também é parte fundamental no funcionamento dos Sistemas Educacionais Adaptativos. Em geral, essa tarefa consiste na extração de todas as informações relevantes que um sistema é capaz de coletar quanto às características do usuário, a fim de se estabelecer um modelo que mapeie suas preferências a individualidades. Este modelo, denominado Modelo de Estudante (ME), servirá como base para os mecanismos adaptativos durante o fornecimento dos recursos educacionais personalizados. Neste contexto, o problema de modelagem do estudante é uma questão delicada no desenvolvimento deste tipo de sistema, exigindo assim uma atenção especial durante a implementação de um Sistema Educacional Adaptativo (DORÇA *et al.*, 2012). Um ME ideal deve ser capaz de registrar toda informação sobre o estudante, inclusive aquela aparentemente irrelevante. No entanto, um modelo absolutamente completo é impossível e impraticável, conforme afirma Valdeperas (VALDEPERAS, 2000). Polson *et al.* (POLSON; RICHARDSON, 2013) reiteram que o ME é uma representação explícita do que se acredita saber sobre o estudante a respeito do conhecimento, do progresso no conteúdo, preferências, EA, objetivos de aprendizagem, motivação, crenças e características pessoais.

Existem na literatura diversas estratégias para se realizar a modelagem de estudantes em sistemas de ensino e aprendizagem. Uma delas, é a avaliação do nível de conhecimento do aluno, onde serão oferecidos somente objetos de aprendizagem compatíveis com o grau de domínio do estudante em relação ao assunto em questão. Deste modo, o aprendizado do usuário no ambiente será gradual, num cenário em que o conteúdo do curso será apresentado em ordem crescente quanto ao nível de dificuldade, desde que o estudante esteja pronto para conhecer o próximo nível. Outra abordagem para construção e atualização do ME é por meio da análise das avaliações feitas pelo estudante a cada OA. Nessa proposta, serão recomendados aqueles recursos com características similares aos recursos avaliados de maneira positiva pelo usuário. Sendo assim, é construído um perfil de estudante por meio dos dados descritivos dos objetos de aprendizagem, e espera-se oferecer conteúdo condizente com a preferência do aluno de acordo com sua própria avaliação. Além disso, em outra abordagem semelhante, é realizado um agrupamento dos usuários que avaliaram os recursos de maneira similar e então recomendados objetos acessados por usuários do mesmo grupo. Nesta estratégia, a ideia é encontrar um modelo em comum para diversos indivíduos, e usar acessos dos membros deste grupo para sugerir objetos de aprendizagem que podem ser do interesse dos demais usuários. Por fim, há a estratégia de detecção do estilo de aprendizagem do estudante de acordo com modelos propostos na literatura. Nessa abordagem, a ideia é mapear conceitos da pedagogia e psicologia educacional da sala de aula e ambientes de aprendizagem tradicionais, para o ambiente virtual de ensino. Neste caso, espera-se oferecer ao usuário uma experiência de aprendizagem compatível às suas preferências

seguindo aspectos de sua personalidade voltados às tarefas do aprendizado.

Conforme apontado por Chrysafiadi ([CHRYSAFIADI; VIRVOU, 2013](#)), existem dois caminhos diferentes para realizar a modelagem de estudantes: a modelagem colaborativa e a modelagem automática. Na abordagem colaborativa os estudantes são responsáveis por fornecer as informações necessárias para a construção e atualização de seus modelos, de modo que, cabe ao próprio indivíduo a tarefa de informar suas preferências. Por exemplo, o aluno pode fornecer dados para o mecanismo de modelagem, declarando explicitamente o grau de relevância que considera para determinado recurso, ou quais os objetos de aprendizagem que mais lhe agradaram. Outra alternativa é o próprio aluno definir características do aprendizado, tais como a ordem dos recursos que serão apresentados. Por fim, o usuário pode ainda atualizar diretamente suas configurações de modelagem, selecionando o perfil de sua preferência. No entanto, uma das técnicas mais adotadas na modelagem colaborativa é a aplicação de questionários psicométricos. Nesses casos, os estudantes respondem a um conjunto de questões detalhadas sobre sua personalidade a fim de obter uma classificação de seus estilos de aprendizagem.

Por outro lado, na abordagem de modelagem automática o processo de construção e atualização do ME pode ser realizado sem esforço por parte do estudante, por meio de métodos computacionais que processem o comportamento e ações do usuário durante a interação com o sistema educacional. Deste modo, o aluno concentra-se inteiramente no processo de aprendizagem, sem precisar se preocupar com a construção de seu perfil. Basta que o estudante use o sistema frequentemente durante o aprendizado para que as informações relevantes sobre suas características sejam extraídas. Sendo assim, vários problemas encontrados na aplicação de questionários de estilos de aprendizagem podem ser superados, uma vez que a abordagem colaborativa pode ser imprecisa em determinados casos. Isso ocorre por diversas razões, como por exemplo a falta de motivação de estudante ao preencher adequadamente o questionário, a influência das expectativas dos colegas e a falta de auto-conhecimento sobre as próprias preferências de aprendizado. No entanto, um problema frequentemente encontrado em aplicações de modelagem automática é a falta de informações significativas o suficiente para se construir um modelo confiável e robusto, e portanto, diversos trabalhos concentram-se nesta tarefa.

Ademais, a modelagem de estudantes também pode ser classificada quanto à sua ordinalidade, que pode ser estática ou dinâmica. A modelagem estática considera que o perfil do aluno é determinado apenas uma vez, idealmente no início do curso durante o registro do estudante. Em contrapartida, na modelagem dinâmica o ME é atualizado frequentemente ao passo em que são coletadas novas informações durante a interação usuário-sistema. Neste contexto, diversos autores (([GARCÍA et al., 2007](#)), ([GRAF; LIU et al., 2009](#)), ([DUNG; FLOREA, 2012](#)), entre outros) defendem que a abordagem dinâmica mostra-se mais precisa em um ambiente real, visto que as preferências e estilos de aprendizagem dos alunos podem variar com o decorrer do tempo. Neste caso, a modelagem estática mantém o estudante com um perfil incorreto. Se os alunos, por exemplo, aprimoram suas deficiências de aprendizagem identificadas no início

do curso, seus estilos de aprendizagem possivelmente serão alterados. No entanto, devido à possibilidade de frequentemente reunir e analisar o comportamento e as ações dos alunos, a abordagem automática de modelagem de estudantes pode detectar esta alteração e atualizar a informação no ME.

Diferentes aplicações já foram desenvolvidas com o intuito de incorporar estilos de aprendizagem em sistemas educacionais. Em alguns casos são propostos sistemas educacionais adaptativos independentes, e em outros são propostas adaptações a sistemas já existentes, afim de prover adaptabilidade de conteúdo em LMS convencionais. No entanto, em grande parte dos casos estes sistemas fazem uso de questionários para identificar os estilos de aprendizagem dos estudantes. Com base nas premissas supracitadas, neste trabalho assume-se que uma proposta de modelagem automática e dinâmica dos estudantes pode ser mais proveitosa para adaptatividade de conteúdo em sistemas educacionais, visto que dessa maneira o modelo mostra-se confiável, adaptável a eventuais mudanças de personalidade, e independente do esforço e auto-conhecimento do estudante.

2.5 Considerações finais

Neste capítulo foram explorados os principais conceitos relacionados à adaptatividade de conteúdo em sistemas educacionais, com o intuito de compreender as possibilidades e atuais desenvolvimentos nesta área de interesse do trabalho. Inicialmente, foram investigadas as principais características referentes aos sistemas de gerenciamento do aprendizado, que são ferramentas constantemente adotadas para o oferecimento de cursos online. Apesar de fornecerem grande auxílio aos docentes, essas ferramentas, ainda que implementadas de maneira parcial (como complemento às aulas presenciais), oferecem poucos recursos para uma personalização do ensino. Desta maneira, o docente possivelmente encontra dificuldades para detectar eventuais necessidades de seus alunos, além de não conduzir o conteúdo que melhor se adequa às preferências de cada um.

Como alternativa a esses sistemas, nesse capítulo também são explorados os métodos para a adaptatividade em sistemas educacionais, que possuem o intuito de suprir essa necessidade. Portanto, são investigados todos os mecanismos que compõem o processo de personalização do ensino, passando pela interação do usuário com o sistema até o retorno de objetos de aprendizagem condizentes com suas preferências. A intenção original de projetar e desenvolver tais sistemas deve-se à ideia de que métodos computacionais (como por exemplo Inteligência Artificial (IA)) podem produzir uma solução promissora para as limitações que os profissionais da educação normalmente enfrentam: como efetivamente ensinar e ajudar os alunos a aprender em ambientes virtuais de ensino. Um dos conceitos que sustentam essa abordagem, é o de que a eficácia do ensino melhora quando professores lecionam para pequenas proporções de alunos. Em 1984, Bloom ([BLOOM, 1984](#)) realizou experimentos comparando a aprendizagem de alunos

em diferentes condições: em um grupo o professor lecionou para 30 alunos e no outro grupo, os alunos receberam aulas individuais. Ao fim do experimento, conclui-se que a tutoria individual é consideravelmente mais eficaz em relação ao ensino em grupo.

Por fim, foi detalhada especificamente a etapa de modelagem dos estudantes em sistemas educacionais adaptativos, visto que essa é a tarefa de interesse neste trabalho. Dentre as diversas abordagens propostas para se construir e atualizar o modelo de estudantes, este trabalho concentra-se na abordagem de incorporação de Estilos de Aprendizagem em sistemas educacionais, devido principalmente ao fato de ainda haver um amplo campo de investigação quanto à aplicação de técnicas computacionais neste contexto. Observou-se ainda que existem diferentes meios para se identificar os estilos de aprendizagem dos alunos. Uma das maneiras trata da detecção colaborativa de estilos, onde cabe ao estudante informar quais são suas preferências e dificuldades. Deste modo, o próprio aluno é responsável por classificar seu perfil, indiretamente por meio de questionários e interação, levando o sistema a adaptar o conteúdo educacional do modo que preferir. Alternativamente, há a proposta de detecção automática dos estilos, que considera que o processo de construção e atualização do perfil de um estudante pode ser realizado sem esforço por parte do aluno, baseando-se em suas ações durante o uso do ambiente virtual. Nesta abordagem os alunos ficam responsáveis apenas pelo processo de aprendizagem e não precisam tomar decisões quanto à personalização do conteúdo. Portanto, assume-se que métodos computacionais podem extrair informações implícitas nos registros de interação dos estudantes, e tais informações podem indicar uma classificação para o aluno em determinado estilo de aprendizagem.

Portanto, em resumo, neste capítulo foram esclarecidas considerações gerais quanto ao uso de sistemas computacionais em benefício do ensino e aprendizagem. Dada a revisão realizada, o foco do presente trabalho está em explorar métodos para a modelagem de estudantes a partir da teoria dos estilos de aprendizagem. Além disso, assume-se que uma abordagem automática e dinâmica de identificação destes perfis é a melhor estratégia para este tipo de aplicação. Ademais, eventuais resultados e descobertas obtidas neste estudo podem ser aplicáveis tanto para o aprimoramento da modelagem de estudantes em sistemas educacionais adaptativos, quanto para a adaptação de LMSs convencionais a partir da detecção de estilos de aprendizagem. Ou seja, o trabalho não concentra-se em um sistema específico, e sim na tarefa de detecção de EA de modo geral, independentemente da finalidade.

ESTILOS DE APRENDIZAGEM

3.1 Considerações iniciais

De acordo com Jonassen e Grabowski ([JONASSEN; GRABOWSKI, 2012](#)), cada aluno possui características únicas que definem seu perfil, dentre as quais, são exemplos: conhecimentos prévios em determinados contextos, habilidades cognitivas, motivações, referências sociais e estilos de aprendizagem. 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 ([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”. Já, Felder ([FELDER, 1996](#)) define EA como “características e preferências na forma como estudantes coletam e processam a informação”. 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 ([FELDER; SILVERMAN, 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. Por hipótese, quanto mais se conhece o estudante, melhores são as condições de oferecer-lhes recursos não só adequados ao seu nível de conhecimento ou interesses pessoais, como também, ao seu estilo pessoal de aprendizagem.

3.2 Modelos propostos

Como mencionado anteriormente, existe uma grande quantidade de modelos de estilos de aprendizagem propostos na literatura. Coffield *et al.* (COFFIELD *et al.*, 2004b) realizaram uma vasta revisão acerca dos modelos de estilos existentes, e classificaram estes estudos em diversas categorias que se baseiam em idéias abrangentes quanto à construção dos modelos, tentando refletir as visões dos principais teóricos dos estilos de aprendizagem. Nesta seção, é descrito um conjunto de modelos de estilo de aprendizagem comumente utilizados em ambientes educacionais. A seleção desses modelos baseia-se na revisão elaborada por Coffield *et al.* (COFFIELD *et al.*, 2004a), considerando-se a importância teórica, a relevância nas áreas da pedagogia e psicologia educacional, bem como os resultados obtidos em outras propostas para modelagem de estudantes em sistemas de ensino/aprendizado. Além disso, a aplicabilidade de cada modelo na recomendação de conteúdo em cursos online foi considerada como um critério importante, incluindo sua utilização em sistemas já existentes e seu potencial para ser adotado nesta proposta.

3.2.1 Os indicadores de Myers-Briggs

O modelo proposto por Myers e Briggs (MYERS, 1962) baseia-se na teoria dos tipos psicológicos de Jung (JUNG, 1923) para definir estilos de aprendizagem. De acordo com Jung, existem seis tipos psicológicos com os quais um indivíduo pode ser classificado: i) pensativo, ii) sentimental, iii) intuitivo, iv) perceptivo, v) extrovertido e vi) introvertido. Os tipos psicológicos determinados por Jung não são especificamente relacionados com perfis de aprendizagem, e sim como métodos para modelar personalidades. Entretanto, as autoras dos Indicadores de Tipos de Myers-Briggs (MBTI) fazem uso desta teoria pois consideram que as características da personalidade de um indivíduo são as principais influências no processo de aprendizagem.

Na Tabela 1 são apresentados os tipos de personalidade descritos pelo modelo de estilos de aprendizagem de Myers-Briggs. A partir dos tipos psicológicos determinados nos estudos conduzidos por Jung, Myers e Briggs definiram quatro dimensões, as quais são caracterizadas por dois pólos opostos: extrovertidos/introvertidos, sensoriais/intuitivos, racionais/sentimentais e julgadores/perceptivos. As combinações possíveis entre todos os pólos das quatro dimensões resultam em um conjunto de 16 tipos distintos. Por exemplo, um indivíduo pode ser identificado com os rótulos Introvertido-Sensorial-Racional-Perceptivo.

Os estudantes extrovertidos são mais propensos ao mundo externo, e por este motivo têm mais facilidade para trabalhar em grupo, enquanto os introvertidos focam no mundo interno e preferem trabalhar sozinhos. Estudantes sensoriais costumam compreender novas informações com base nos sentidos de audição, visão, olfato, tato e paladar, enquanto os intuitivos fazem uso do inconsciente para entender dados em um cenário educacional. Além disso, indivíduos sensoriais adaptam-se mais facilmente a rotinas, em relação aos intuitivos. A assimilação das

Tabela 1 – Definição dos Tipos de Personalidade de acordo com o modelo Myers-Briggs.

Dimensão	Comportamento dos Estudantes
Introvertido/Extrovertido	Introvertidos interagem menos com o ambiente e baseiam-se nas próprias ideias. Extrovertidos trabalham melhor em grupos, e possuem maior capacidade de comunicação.
Sensorial/Intuitivo	Sensoriais preferem compreender fatos, a partir dos sentidos de visão, audição, olfato, paladar e tato. Intuitivos tendem a dar prioridade às informações ocultas captadas pelo inconsciente.
Racional/Sentimental	Racionais utilizam o raciocínio lógico para julgar as informações que adquire. Sentimentais tomam decisões com base nos valores humanos.
Perceptivos/Julgadores	Perceptivos estão mais aptos a utilizar as habilidades de compreensão das informações (Sensoriais ou Intuitivas). Julgadores estão mais inclinados a usar as características de julgamento (Racionais ou Sentimentais).

informações compreendidas é distinguida pelos rótulos antagônicos: racional e sentimental. Indivíduos racionais tendem a tomar decisões com base em raciocínio lógico e regras como a lógica “verdadeiro ou falso”, e estruturas de decisão (se-então-senão). Por outro lado, o indivíduo sentimental prefere tomar suas decisões baseando-se em considerações pessoais e humanísticas. Por fim, a última dimensão indica se indivíduo possui maior aptidão em suas funções de percepção (Sensoriais ou Intuitivas) ou nas funções de julgamento (Racionais ou Sentimentais). Esta dimensão é polarizada pelos rótulos: Julgador e Perceptivo.

Por fim, é proposto o indicador de tipos de Myers-Briggs, que funciona como um instrumento para determinar os índices dos estudantes em cada uma das dimensões. Essa ferramenta permite mensurar os tipos de personalidades a partir de um questionário que pode ser encontrado *online*. O questionário possui 72 perguntas com duas opções de resposta: sim e não. A soma das respostas indica as preferências de aprendizagem de um aluno de acordo com o modelo proposto, de forma que este seja classificado em um dos 16 estilos possíveis.

3.2.2 O modelo de Grasha-Riechmann

O modelo de estilos de aprendizagem de Grasha e Riechmann (GRASHA, 1984) evidencia a interação entre o grupo dos alunos e os professores em um ambiente de estudos. Ou seja, a abordagem trata dos relacionamentos interpessoais de cada indivíduo. Para compreender o comportamento dos estudantes, Grasha e Riechmann definem três dimensões representadas por classificações antagônicas: participativo/inibido, colaborativo/competitivo e dependente/independente. Estas classificações dizem respeito às características de interação social do indivíduo, e

são resumidas na Tabela 2.

Tabela 2 – Definição dos comportamentos dos estudantes segundo Grasha-Riechmann.

Dimensão	Comportamento dos Estudantes
Participativo/Inibido	Participativos empenham-se nas atividades e buscam conhecimento de forma proativa. Inibidos demonstram menor interesse e não participam ativamente das atividades.
Colaborativo/Competitivo	Colaborativos trabalham em equipe, são comunicativos e tendem a participar de forma cooperativa. Competitivos buscam conhecimento como forma de disputa para superar seus colegas de classe.
Dependentes/Independentes	Dependentes necessitam de um controle por parte do docente, e não investiga o que não é solicitado. Independentes usam da curiosidade para buscar novos conhecimentos e não dependem do professor para aprender.

A dimensão participativo/inibido indica o grau de envolvimento de um estudante no ambiente escolar. Alunos com perfil participativo estão mais inclinados a se envolver nas atividades educacionais, de modo que estes buscam o conhecimento de forma proativa. Por outro lado, estudantes com estilo inibido não possuem grande interesse pelo aprendizado, o que causa uma menor participação nas aulas e atividades escolares. Além disso, estes alunos não se empenham para adquirir novos conhecimentos, e portanto, encontram dificuldades no aprendizado.

A dimensão colaborativo/competitivo determina o grau de motivação de um estudante ao interagir com seus colegas de classe e professores. Alunos com estilo colaborativo apreciam o trabalho em grupo, tendem a ser comunicativos e cooperativos em situações que envolvem o aprendizado. Entretanto, alunos competitivos encaram o ambiente de ensino como uma competição, e se empenham no processo de obtenção de conhecimento para superar os demais estudantes.

A dimensão dependente/independente mensura o grau de liberdade que mais agrada o estudante em um ambiente educacional. Alunos dependentes estão fortemente vinculados ao controle do docente, pois o enxergam como fonte de conhecimento. Estes alunos dependem diretamente do estímulo oriundo da autoridade do professor, e comumente buscam aprender somente o que lhes é solicitado. Por outro lado, os alunos independentes são identificados por meio da curiosidade, e do desejo de investigar informações. Eles estão mais inclinados a tirar conclusões pensando por si próprios, e buscar novos aprendizados sem a necessidade de um professor.

Para detectar os coeficiente dos estudantes em cada uma das dimensões é proposto um formulário de auto-avaliação contendo 90 itens, denominado Student Learning Styles Scale

(SLSS) (GRASHA; RIECHMANN, 1975). O questionário é dividido em seis categorias (uma para cada estilo possível), cada uma contendo 15 questões. Os estudantes devem avaliar cada item em uma escala de 5 níveis, a fim de expressar suas preferências no contexto de aprendizagem. A somatória das avaliações dos alunos em cada dimensão indica o estilo de aprendizagem ao qual o aluno se enquadra.

3.2.3 O modelo de Pask

Durante os anos 1970, um grupo de pesquisas em técnicas de aprendizagem explorou as abordagens e estratégias que impulsionam os estudantes em suas experiências. De acordo com esse ponto de vista, a forma de organização de uma disciplina influencia fortemente o desempenho dos alunos que a cursam.

Pask foi um dos mais influentes pesquisadores deste grupo de pesquisa, e argumenta que existem maneiras de categorizar as estratégias que os estudantes adotam no processo de aprendizagem. Portanto, Pask descreveu um estilo denominado serialista/holístico/versátil, que determina as preferências de um aluno ao se relacionar com um recurso educacional (PASK, 1972).

Estudantes serialistas preferem adquirir conhecimento por meio de um conteúdo sequencial, portanto, se concentram especificamente no nível mais detalhado do assunto, para que ao fim possam construir o conhecimento com base em um passo-a-passo. Para Pask, uma das limitações deste grupo de alunos é a dificuldade em relacionar tópicos distintos que podem ter significado relevante quando interligados.

Por outro lado, os estudantes holísticos adotam uma conduta de aprendizado baseada no raciocínio hierárquico, de forma que estes atentam-se primeiramente ao conteúdo como um todo, e depois examinam os detalhamentos e especificidades. Os alunos que se enquadram neste grupo possuem facilidade para observar conexões entre diferentes tópicos de um mesmo assunto, e relacionam as aplicações teóricas, práticas e pessoais de um conhecimento. Porém, um defeito desta categoria é a menor atenção aos detalhes, em relação aos serialistas.

Os indivíduos que apresentam uma conduta versátil, adotam estratégias mistas entre as determinadas serialistas e holísticas. Eles exploram dados tanto do plano global quanto do plano detalhado em um assunto, e estão mais propensos a absorver o conteúdo completamente.

Para mensurar os índices dos alunos em cada uma das categorias (serialista/holística/versátil), Pask desenvolveu um conjunto de testes, dos quais destacam-se o *Spy Ring History Test* (PASK; SCOTT, 1973) e o *Clobbits Test* (PASK, 1975). Além disso, Entwistle (ENTWISTLE, 1998) e Ford (FORD, 1985), desenvolveram listas para identificação de estilos de aprendizagem baseadas nos estudos conduzidos por Pask. O questionário de Ford, denominado “Questionário de Preferências no Estudo”, consiste de pares de itens, que são avaliados de acordo com a opinião dos alunos a partir de uma escala de 5 níveis.

3.2.4 O modelo de Herrmann

Herrmann categoriza os diferentes caminhos por meio dos quais os indivíduos captam e assimilam informações, tomam decisões e solucionam problemas. Porém, diferentemente dos modelos apresentados anteriormente, esta abordagem considera essas características como estilos de pensamento, e não estilos de aprendizagem. De qualquer maneira, o modelo de dominância cerebral proposto por Herrmann com base em estilos de pensamento é viável no contexto educacional (ALMEIDA, 2010).

O modelo de Herrmann baseia-se nas pesquisas conduzidas por Roger Sperry (SPERRY, 1964), que supõem que o cérebro humano é dividido em hemisférios esquerdo e direito, que são responsáveis por diferentes funções de pensamento. Além disso, de acordo com MacLean (MACLEAN, 1952), o pensamento pode ser realizado por diferentes sistemas do cérebro, que podem ser divididos entre sistema cerebral e sistema límbico. Sendo assim, o modelo de dominância cerebral de Herrmann sustenta-se na mente física do ser humano, portanto considera que as partes do cérebro com maior atividade têm influência no processo de aprendizagem. Conforme ilustrado na Figura 3, Herrmann define que o comportamento cerebral é dividido em quatro quadrantes.

Figura 3 – A divisão do cérebro de acordo com Herrmann.

Indivíduos com maior atividade cerebral no quadrante A (hemisfério esquerdo/sistema cerebral) tendem a ser racionais, tomando decisões a partir de raciocínio lógico, além de apresentarem comportamentos críticos, analíticos e matemáticos. Indivíduos com maior atividade no quadrante B (hemisfério esquerdo/sistema límbico) são serialistas, atentos a detalhes e possuem maior aptidão para a organização e planejamento (HERRMANN, 1991).

Se a atividade cerebral for mais intensa no quadrante C (hemisfério direito/sistema límbico), o indivíduo tende a ser emotivo, interpessoal, sensível e com aptidão para a música. Por fim, aqueles com maior atividade no quadrante D (hemisfério direito/sistema cerebral) possuem melhores habilidades visuais e estão inclinados a desenvolver habilidades de inovação e criatividade.

Para determinar os estilos de pensamento de um indivíduo, Herrmann propõe um questionário composto por 120 itens. O Instrumento da Dominância Cerebral de Herrmann (HBDI) foi desenvolvido para identificar o quadrante em que a pessoa sujeita ao teste mais se enquadra. O HBDI apresenta como resultado o perfil dominante do pensamento, que indica as preferências primárias, secundárias e terciárias do indivíduo.

3.2.5 O modelo de Kolb

O estilo de aprendizagem de Kolb (KOLB, 1976) concentra-se na importância da experiência adquirida pelo aluno durante o processo de aprendizagem. De acordo com este modelo, existem duas dimensões fundamentais que caracterizam as escolhas de um aluno no ambiente educacional: a percepção e o processamento de informações.

Para Kolb, os métodos de percepção do conhecimento podem ser divididos entre experiências concretas ou abstratas. Experiências concretas são a base para observações e reflexões, e são adquiridas por meio da visão, audição e fala. Por outro lado, as experiências abstratas estão relacionadas aos conceitos mentais, que remetem à generalização de conceitos em novas situações. A etapa posterior à percepção é o processamento da informação, que pode ser dividido em duas vertentes: experimentação ativa e observação reflexiva. A experimentação ativa ocorre quando o indivíduo executa o processamento a partir de alguma ação, enquanto a experimentação reflexiva ocorre quando este pensa em algo.

Em outras palavras, o modelo de Kolb considera duas dimensões que são caracterizadas por pólos opostos: concreto/abstrato e ativo/reflexivo. Por consequência, estas dimensões combinadas originam quatro estilos de aprendizagem distintos, conforme ilustrado na Figura 4.

O estudante identificado como concreto e reflexivo é denominado divergente. Indivíduos classificados como divergentes aprendem experimentando, desenvolvem ideias, a partir da observação audiovisual. Este estilo de aprendizagem está diretamente relacionado com a vivência do aluno, que é aplicada ao analisar e processar o conteúdo do curso. Portanto, estudantes enquadrados no estilo divergente tendem a ser criativos.

Estudantes convergentes são os que se identificam com a percepção abstrata e a experimentação ativa. Deste modo, os alunos que se enquadram neste estilo têm forte aptidão para a aplicação prática de ideias, são hábeis para resolver problemas e também na tomada de decisões. Estes estudantes utilizam constantemente o raciocínio dedutivo, e constroem o conhecimento utilizando técnicas de tentativa e erro.

O estilo de aprendizagem denominado assimilador, está relacionado com a percepção abstrata e experimentação reflexiva. Estudantes inclinados a este estilo tendem a aprender por meio da reflexão, audição, observação e criação de ideias, além de utilizarem raciocínio indutivo. Por possuírem facilidade para a criação de modelos teóricos, estes alunos são hábeis em assimilar diferentes observações para a construção de um conhecimento integrado.

Figura 4 – Modelo de estilos de aprendizagem de Kolb.

Os acomodadores são a combinação entre a percepção concreta e a experimentação ativa, e portanto, são apostos aos assimiladores. Estes estudantes aprendem por meio da experimentação e aplicação do conhecimento ao receberem uma nova informação. Portanto, eles realizam ações de forma ativa, e têm maior facilidade ao lidar com novas experiências, além de possuírem aptidão para situações que necessitam de uma tomada de decisão imediata.

De acordo com Kolb, a maneira mais eficaz de adquirir conhecimentos é um movimento cíclico passando pelos quatro estilos de aprendizagem descritos. Entretanto, cada indivíduo apresenta maior compatibilidade em apenas um dos estilos.

Para identificar o estilo de aprendizagem preferencial de cada estudante, Kolb desenvolveu o Inventário de Estilos de Aprendizagem (LSI) (KOLB, 2014), que foi revisado diversas vezes com o passar do tempo. A atual versão do questionário contém doze itens, compostos por quatro questões cada. Cada questão é correspondente a uma dimensão: percepção concreta, percepção abstrata, experimentação ativa e experimentação reflexiva. É solicitado que os alunos avaliem cada questão de acordo com suas preferências, atribuindo um grau de um a quatro para mensurar o quanto aquela questão descreve seu estilo de aprendizagem. A partir de uma ordem crescente na avaliação, receberão o valor um os itens que o aluno considerar menos afins,

e o valor quatro aquelas que apresentarem maior afinidade. Os resultados do LSI indicam a preferência do indivíduo em cada um dos quatro estilos a partir da somatória das avaliações.

3.2.6 O modelo de Honey-Mumford

Peter Honey e Alan Mumford desenvolveram a aprendizagem Teoria dos Estilos (HONEY; MUMFORD *et al.*, 1992) - uma continuação do trabalho de David Kolb e sua Teoria da Aprendizagem Experiencial. Honey e Mumford identificaram quatro estilos diferentes de aprendizagem: “ativista”, “teórico”, “reflexivo” e “pragmático”. Segundo a teoria, diferentes pessoas naturalmente gravitam em direção a um estilo de aprendizagem particular. Portanto, para alcançar a aprendizagem ideal, Honey e Mumford argumentam que é preciso identificar o estilo natural de aprendizagem, compreendê-lo e encontrar maneiras de aprender que complementam essa característica.

Segundo este modelo, indivíduos ativistas são fortemente relacionados a ações, são proativos e tomam iniciativa para alcançar resultados. Eles precisam agir, se envolver e totalmente mergulhar em uma situação de aprendizagem. Ativistas têm a mente aberta quando se trata de aprendizagem. Estão dispostos a experimentar situações novas, sem pré-julgamento. Estudantes deste estilo lidam com novas tarefas com entusiasmo e se destacam em situações de alta pressão. Atividades mais adequadas para ativistas são o trabalho em equipe, dinâmicas e competições.

Estudantes teóricos tendem a pensar cuidadosamente e logicamente sobre as situações, preferindo trabalhar dentro de um determinado sistema ou modelo. Eles não permitem que suas emoções afetem nas conclusões durante o aprendizado e, em vez disso levantam questionamentos. Indivíduos compatíveis com este estilo tendem a não fazer suposições sem realizar pesquisa e análise minuciosa, e portanto, coíbem de criatividade e preferem trabalhar em termos lógicos e práticos, baseando a sua aprendizagem em conceitos estabelecidos. Os teóricos respondem bem a atividades que lhes permitam usar as estatísticas, analisar evidências e fazer perguntas.

Indivíduos reflexivos usam a observação da situação para adquirir conhecimento, em vez de saltar para a ação e fazer decisões rápidas. Estes estudantes tendem a sentar, ouvir, olhar para os conceitos a partir de perspectivas diferentes e, em seguida, refletir sobre o assunto antes de chegar a uma conclusão. Reflexivos aprendem melhor por meio de questionários, entrevistas, comentários e atividades que requerem observação. Eles preferem participar em atividades que lhes permitam pensar antes de agir, realizar pesquisas e observar os resultados.

Pragmáticos preferem aplicar o conhecimento e teorias em um sentido prático e literal no ambiente educacional. Eles aprendem por meio de tentativa e teste, e experimentam ideias para resolver problemas. Estes estudantes não são hábeis para trabalhar com teorias, entretanto, possuem maior disposição em atividades práticas e que requerem ação. Pragmáticos respondem bem à aprendizagem de ciências aplicadas e têm preferência por experimentar e aplicar o que aprenderam de uma forma prática.

O Questionário de Estilos de Aprendizagem (LSQ) é um inventário de auto avaliação desenvolvido para identificar estilos de aprendizagem de acordo com o modelo proposto por Honey e Mumford. O questionário foi revisado diversas vezes pelos autores, e a última versão, datada de 2006 (HONEY; MUMFORD, 2000) está disponível em duas versões: uma contendo 80 questões e a outra com 40.

3.2.7 O modelo de Felder-Silvermann

O Modelo de Estilos de Aprendizagem de Felder e Silverman (FSLSM) (FELDER; SILVERMAN, 1988) pode ser compreendido como uma combinação de um conjunto de estudos propostos na literatura a fim de dar início a um modelo de maior amplitude possibilidades. As dimensões dos estilos de aprendizagem 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: processamento, captação, percepção e organização. Estas dimensões são resumidamente ilustradas na Figura 5. A abordagem foi desenvolvida e avaliada pelos autores com um grupo de estudantes de engenharia, e tornou-se um dos principais modelos de estilos de aprendizagem adotados em trabalhos que envolvem personalização do ensino.

Figura 5 – Modelo de estilos de aprendizagem de Felder-Silverman.

- **Processamento (ativos x reflexivos):** a dimensão de processamento das informações é dividida em dois pólos: ativos e 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.
- **Captação (visuais x verbais):** as dimensões visual e verbal são estilos relacionados com o tipo de captação da informação. Indivíduos com maior tendência para o pólo visual possuem melhor captação de informações que se apresentam de maneira gráfica, tais como: ilustrações, figuras, diagramas, fluxogramas, esquemas e mapas. Em outras palavras, estes indivíduos possuem melhor aproveitamento das características visuais do conteúdo apresentado pelas informações. Em contrapartida, aqueles mais inclinados ao pólo verbal estão relacionados às propriedades de leitura e audição. Ou seja, possuem facilidade para compreender conceitos traduzidos em palavras.
- **Percepção (sensoriais x intuitivos):** a dimensão da percepção contempla os pólos sensorial e intuitivo. 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 do inconsciente. Por outro lado, os indivíduos sensoriais tomam decisões e percebem informações baseando-se fortemente nos sentidos (visão, audição, tato, olfato), e tendem a ter maior atividade na região consciente do cérebro.
- **Organização (sequenciais x globais):** quanto à organização das informações, o modelo de Felder-Silverman define dois estilos opostos: sequenciais e 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 detalhes importantes que constituem este todo.

De acordo com Felder e Silverman, os estilos não são convergentes, e sim pólos opostos que constituem uma dimensão. A adequação de um estudante em determinado pólo não é extrema, de modo que este pode transitar entre os dois pólos por meio de uma escala de índices. Sendo assim, um indivíduo pode estar parcialmente identificado em determinado estilo, ou ainda possuir uma posição nula em certa dimensão (quando o número de características relacionadas a cada pólo é igual). Por exemplo, um estudante poderá ser fortemente visual se captar maior número de informações visuais, mas poderá ser levemente visual se for capaz de captar informações verbais com facilidade.

No modelo FSLSM, estas medidas são definidas por meio de escalas de -11 a 11 para cada dimensão, incluindo apenas os valores ímpares. As escalas permitem a detecção da característica segundo a qual o aluno está mais próximo, indicando que o estudante tem preferência para um dos dois pólos de cada dimensão. Por exemplo: Um aluno identificado com escala 9 na dimensão de captação tem uma tendência a aprender mais facilmente de maneira verbal, enquanto um aluno com índice -9 nessa mesma dimensão, prefere aprender de maneira visual. Para detectar os índices das dimensões de cada indivíduo, Felder e Soloman desenvolveram um questionário contendo 44 questões (11 questões para cada dimensão), chamado Index of Learning Styles (ILS) (SOLOMAN; FELDER, 1999). Este questionário é detalhado no Apêndice ??.

3.3 Considerações finais

Neste capítulo foram apresentados os conceitos e definições a respeito da área de estudos intitulada *Estilos de Aprendizagem*, onde diversos pesquisadores do campo da pedagogia e da psicologia educacional propõem estratégias para compreender as maneiras que um indivíduo utiliza para conseguir aprender o que lhe é proposto. O objetivo neste capítulo é, além de compreender a teoria dos estilos de aprendizagem, revisar os principais modelos que compõem essa área de estudos. Portanto, foram detalhados alguns dos estudos propostos já adotados em trabalhos envolvendo modelagem de estudantes em sistemas educacionais, a fim de se identificar suas principais características e também selecionar a abordagem a ser aplicada neste trabalho.

Acerca da teoria dos estilos de aprendizagem, embora trabalhos recentes apresentem críticas a este conceito (KIRSCHNER, 2017), neste trabalho acredita-se que esta seja uma ferramenta efetiva para classificar aprendizes *online*, visto que em cada modelo de EA são propostos comportamentos rastreáveis relacionados a cada perfil de estudante. Além disso, defende-se que efetivamente cada indivíduo possui suas particularidades e preferências durante o processo de aquisição de conhecimento, e que a teoria dos estilos de aprendizagem abrange essa questão, captando essas características dos estudantes para oferecer uma melhor experiência durante os estudos. Por fim, outro fator que sustenta o emprego de estilos de aprendizagem neste trabalho é o conjunto de resultados satisfatórios obtidos em propostas semelhantes. Diversas abordagens de personalização do ensino por meio de EA (discutidas no Capítulo 5) demonstraram maior satisfação dos estudantes em relação aos recursos oferecidos e também melhora no desempenho dos alunos durante o curso.

Quanto aos modelos apresentados, como mencionado anteriormente, foram propostas na literatura diferentes abordagens para mapear as características de cada indivíduo durante o aprendizado. Dentre elas, o modelo de estilos de aprendizagem de Felder e Silverman (FELDER; SILVERMAN, 1988) foi escolhido para os experimentos conduzidos neste trabalho por um conjunto de 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 (KOLB, 1976), Pask (PASK, 1975) e os Indicadores de Tipos de Myers-Briggs (MYERS, 1962). Outra característica importante deste modelo é a praticidade para se identificar o estilo de um estudante, devido ao questionário ILS. Além disso, destaca-se a classificação de um aluno a determinado estilo por meio de escalas mensuradas em valores entre -11 e +11. Isso possibilita uma avaliação mais detalhada do quanto um estudante está inclinado para certo estilo, visto que a maioria dos demais modelos apenas indica a qual estilo o aluno pertence. Deste modo, um sistema de recomendação pode diferenciar seu comportamento de acordo com o quão fortemente o estudante está alinhado a um estilo. Assume-se que esta diferenciação pode trazer resultados mais precisos em um cenário de personalização do ensino. 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; MONTESERIN; AMANDI, 2015) (TRUONG, 2016), além de já ser incorporado a diversos sistemas educacionais adaptativos, demonstrando bons resultados quanto à classificação de perfis e recomendação de conteúdo.

APRENDIZADO DE MÁQUINA

De acordo com Michalski *et al.* (MICHALSKI; CARBONELL; MITCHELL, 2013), o campo de pesquisa relacionado ao Aprendizado de Máquina (AM) concentra-se no desenvolvimento de técnicas computacionais que alterem aspectos de seu comportamento à medida em que é adquirida experiência. Neste trabalho são exploradas técnicas de aprendizado de máquina relacionadas especificamente à tarefa de classificação, a fim de investigar estratégias para a detecção automática e dinâmica de estilos de aprendizado dos estudantes em um sistema educacional. De maneira geral, a proposta visa rotular estudantes a partir de um conjunto de exemplos, utilizando-se de um algoritmo de aprendizado supervisionado que observe suas interações em um sistema de gerenciamento do aprendizado.

Neste capítulo são apresentados conceitos gerais a respeito de AM, fundamentados em definições científicas, além de exemplificadas algumas aplicações práticas para estas técnicas. Em seguida, são enunciadas características gerais a respeito desta área de estudos, além das diversas maneiras em que se pode classificar as técnicas relacionadas. Na seção seguinte, são apresentados especificamente os conceitos gerais quanto à tarefa de classificação, bem como as técnicas de classificação presentes na literatura. Ao fim, são apresentadas as considerações finais a respeito dos métodos apresentados.

4.1 Considerações Iniciais

O aprendizado de máquina pode ser definido como uma sub-área da Inteligência Artificial (IA), cujo objetivo é desenvolver métodos computacionais capazes de tomar decisões com base em conhecimentos já existentes (MICHALSKI; CARBONELL; MITCHELL, 2013). Em outras palavras, AM trata da construção de técnicas automatizadas que possibilitem que um computador, a partir da aquisição de novos conhecimentos, melhore seu desempenho e habilidades automaticamente de acordo com a experiência prévia. Portanto, assumindo-se que no contexto atual do desenvolvimento de software o desenvolvedor é o encarregado de implementar

as soluções computacionais necessárias para a solução de um problema, por outro lado, métodos de aprendizagem de máquina e inteligência computacional artificial oferecem aos desenvolvedores recursos para a implementação de um sistema que alcance as soluções para os problemas de forma automatizada, a partir de exemplos do domínio do problema.

Os sistemas que utilizam de aprendizado de máquina possuem diversas aplicações. De modo geral, estas técnicas são empreendidas em problemas que não podem ser resolvidos por meio de métodos tradicionais de programação, tais como os algoritmos imperativos, funcionais ou orientados a objetos (PISTORI, 2003). Deste modo, é fundamental que existam soluções computacionais capazes de adquirir conhecimento com base na experiência de forma eficiente e eficaz, uma vez que existem problemas que não possibilitam uma modelagem por meio de matemática ou algoritmos convencionais. Um exemplo destes problemas é um programa de computador que reconheça e traduza caracteres escritos à mão. Este problema requer uma solução que, dado um conjunto de caracteres escritos à mão e suas respectivas representações, obtenha um conhecimento baseado na experiência, ou seja, aprenda a interpretar novos caracteres escritos à mão a partir de um grande conjunto de exemplos (PRATI, 2006).

A mesma abordagem pode ser realizada em outros casos que demandem um sistema computacional que observe um conjunto de fatos ou valores, e faça a distinção de características de interesse nesses fatos (STANGE, 2011). Dentre tais casos, são exemplos a detecção de genes em uma sequência de DNA, a filtragem de e-mails, a identificação de objetos em imagens e vídeos, entre outros (PRATI, 2006). A resolução destes problemas de forma computacional possibilita avanços em cada domínio de contexto, porém necessita de um profundo embasamento teórico para que as soluções possam aprender por meio da experiência. A seguir são apresentadas características gerais das técnicas de aprendizado de máquina, além de considerações sobre os aspectos relacionados à descoberta de conhecimento.

4.2 Características gerais

Para se obter um sistema de aprendizado capaz de representar computacionalmente um problema e apresentar a este uma solução, é necessário descrever objetos, processos e situações que fazem parte de seu domínio (MONARD; BARANAUSKAS, 2000). Existem na literatura diversas maneiras para descrever as características que diferenciam cada aplicação no contexto de aprendizado de máquina, e deste modo, algumas dessas características permitem a segregação de cada técnica, método ou paradigma em grupos distintos. Nas seções a seguir, são apresentados diferentes meios para se classificar técnicas de AM: quanto à inferência lógica, modos e tarefas de aprendizado.

4.2.1 Inferência lógica

Técnicas de aprendizado de máquina estão relacionadas ao processamento e organização do conhecimento a fim de realizar observações que resultem em novos conhecimentos. A maneira com a qual essa manipulação de experiências é realizada é denominada pelos métodos de inferência lógica. Os métodos de inferência lógica podem ser agrupados em três alternativas: indução, dedução ou abdução.

Indução é uma estratégia de inferência lógica que permite que conclusões gerais sejam obtidas a partir de exemplos particulares. Portanto, pode ser compreendida como um raciocínio que parte do detalhado para o global, de parte para o todo, ou seja, de conceitos específicos para a generalização. Inferências indutivas não preservam necessariamente a verdade, mesmo que o conjunto de premissas que suportam a inferência seja verdadeiro, portanto, o resultado das induções é denominado hipótese (PRATI, 2006). Assim, hipóteses levam a conclusões que excedem às premissas. Ainda que não seja possível garantir a validade de uma hipótese, pode-se avaliar uma indução de acordo com um grau de confiança, baseado na qualidade das premissas, ou seja, é possível estimar a probabilidade de uma hipótese ser verdadeira a partir da quantidade de premissas verdadeiras.

Um aspecto fundamental da inferência lógica indutiva aplicada ao contexto de aprendizado de máquina refere-se à inferência amostra-para-população. Este método, também denominado como generalização indutiva, considera que se todos os objetos de uma amostra satisfazem uma propriedade, todos os objetos da população total também a satisfarão. Porém, esta hipótese construída pode sofrer alterações em seu grau de confiança ao passo em que são acrescentadas novas premissas ao conjunto. Em alguns casos, novas premissas podem até mesmo invalidar a hipótese induzida (PRATI, 2006).

Por outro lado, a inferência lógica de dedução apresenta conclusões obtidas a partir de um conjunto de premissas iniciais verdadeiras, o que conseqüentemente incide em um resultado verdadeiro (BATISTA *et al.*, 2003). Entretanto, esta abordagem não coleta novas informações a respeito das premissas, de forma que esta inferência trata da identificação de informações implícitas presentes no conjunto de dados. Portanto, nesta proposta, o conhecimento adquirido é uma abstração das transformações que resultaram no conhecimento já existente. De forma geral, a aprendizagem por dedução realiza uma sequência de conclusões por meio de cálculos que indiquem determinado conhecimento oculto, porém já existente nas premissas.

Por fim, as estratégias de abdução estão focadas em inferir conhecimento baseado na observação de outras informações conhecidas. De certa maneira, as hipóteses abduativas são construídas a fim de identificar um conhecimento incompleto, com o intuito de encontrar predicados específicos ainda não observados que completem este conhecimento. De acordo com Prati (PRATI, 2006), em uma inferência abduativa típica, assume-se que a descrição do domínio do problema é suficiente, desde que seja possível aplicar inferências sobre as informações de

acordo com a quantidade de informação disponível. O que resulta em um cenário onde a parte incompleta do conhecimento pode ser isolada em predicados não observados, denominados predicados abdutíveis.

De modo geral, indução, dedução e abdução são meios para se criar novos conhecimentos, prever situações e classificar exemplos futuros, construindo hipóteses a partir de premissas que se manifestam como propriedades no conjunto de dados avaliado. Desde modo, esses processos são indispensáveis para a obtenção de novos conhecimentos baseando-se na experiência de forma computacional, cada um com suas particularidades. Em vista disso, métodos de dedução são comumente utilizados em aplicações que buscam encontrar informações implícitas em conjuntos completos, ao passo que inferências indutivas são ideais para a descoberta de novas informações.

4.2.2 Modos de aprendizado

Conforme ilustrado na Figura 6, o aprendizado indutivo pode ser dividido em três categorias: aprendizado supervisionado, aprendizado não supervisionado e aprendizado semissupervisionado (MONARD; BARANAUSKAS, 2003). Esta classificação está relacionada com os métodos que podem ser adotados no processo de generalização do conhecimento.

Figura 6 – Hierarquia do aprendizado de acordo com o grau de supervisão (Monard e Baranauskas, 2003).

No aprendizado supervisionado são aplicadas técnicas onde algoritmos indutores realizam inferências a partir de exemplos rotulados, ou seja, cada exemplo observado é descrito por um conjunto de atributos e pelo valor da classe (também denominada atributo meta) à qual o exemplo pertence (RUSSELL; NORVIG, 2003). Neste caso, o objetivo do algoritmo é determinar um modelo capaz de classificar exemplos não rotulados recebidos como entrada. Em outras palavras, o processo de aprendizado supervisionado pode ser comparado com o processo de aprendizagem de um aluno em um ambiente onde há um professor. Ao resolver determinada tarefa, o professor avalia a resposta informando qual a resposta correta. Após a repetição contí-

nua deste processo, o aluno saberá responder às novas questões corretamente sem o auxílio do professor.

Formalmente, pode-se dizer que, dado um conjunto de exemplos $E = \{E_1, E_2, E_3, \dots, E_n\}$, cada exemplo $E_i \in E$ possui uma classe associada. Deste modo, cada exemplo $E_i \in E$ pode ser definido como um par $(\vec{x}_i, y_i)$, onde $\vec{x}_i$ representa um vetor de atributos do exemplo E_i , e y_i corresponde ao valor da classe desse exemplo. De certa forma, o objetivo do aprendizado supervisionado é induzir um mapeamento dos vetores $\vec{x}$ para os valores y , a fim de construir uma hipótese que permita prever valores de y para exemplos não rotulados (BATISTA *et al.*, 2003).

Por outro lado, na aprendizagem não supervisionada considera-se o conjunto de exemplos não rotulados, e portanto, estão disponíveis somente os exemplos de entradas. Neste caso, o algoritmo indutor não possui a informação sobre a classe à qual pertence cada exemplo. O objetivo na aprendizagem não supervisionada é encontrar similaridades ou diferenças no conjunto de valores dos atributos dos exemplos que permitam a criação de agrupamentos ou clusters. Sendo assim, exemplos agrupados podem ser atribuídos a uma mesma classe, enquanto exemplos dispersos estão mais propensos a pertencer a classes distintas (RUSSELL; NORVIG, 2003). O algoritmo k-médias e o algoritmo de agrupamento hierárquico são exemplos de técnicas de aprendizado não supervisionado.

Por fim, o aprendizado semissupervisionado combina ambos os métodos supervisionado e não supervisionado. Esta abordagem utiliza um pequeno conjunto de exemplos rotulados, e um conjunto maior de exemplos não rotulados. O objetivo neste caso é observar ambos os conjuntos de exemplos para encontrar uma hipótese capaz de classificar novas observações entre as classes já existentes.

4.2.3 Tarefas de aprendizado

Conforme visto na seção anterior, em problemas de aprendizado supervisionado, cada exemplo é descrito por um vetor de valores e por um atributo especial, denominado atributo meta. A função deste atributo é descrever uma característica de interesse, que representa um rótulo ou classe à qual pertence o exemplo. Desta forma, conforme visto na Figura 7, em uma técnica de aprendizagem supervisionada a tarefa de aprendizado pode ser descrita como classificação ou regressão, de acordo com a característica do atributo classe.

Quando o atributo classe assume um valor discreto, como por exemplo, *classe A*, *classe B*, ou *classe C*, o problema é conhecido como problema de classificação, e neste caso o objetivo é classificar futuros casos em cada uma das classes pré-estabelecidas. Por outro lado, quando o atributo assume valores contínuos, como por exemplo, o preço esperado de um produto de acordo com suas características, o problema é geralmente conhecido como problema de regressão, cujo objetivo é prever o valor deste atributo com base nas características dos demais exemplos (PRATI, 2006).

Figura 7 – Hierarquia do Aprendizado (Monard e Baranauskas, 2003).

4.3 Classificação de dados

A classificação de dados pode ser entendida como um processo que permite a descoberta de conhecimento a partir de um conjunto de dados, por meio da categorização de suas características. Em geral, este processo consiste na atribuição de rótulos a determinados objetos não rotulados a partir da observação de suas similaridades com outros objetos já classificados, ou seja, uma classificação baseada na experiência. Este conceito pode ser observado não somente na área da computação, porém em situações do cotidiano. Por exemplo, quando uma pessoa observa um indivíduo do outro lado da rua e, a partir de processos cerebrais, realiza inferências baseadas nas características do indivíduo. Dadas as características físicas do indivíduo em questão, a pessoa pode rotulá-lo como um homem ou uma mulher, um adulto ou uma criança, um conhecido ou um desconhecido, entre outros. Inferências como esta podem ser compreendidas como classificações.

No contexto das tarefas de aprendizado de máquina, o processo de classificação se dá por meio de um algoritmo indutor, cujo objetivo é prever o rótulo de novas entradas com base nos 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. Desta forma, o conjunto de entrada é composto por uma coleção de exemplos, sendo que cada exemplo é constituído por uma lista de atributos independentes, bem como um atributo classe. Em vista disso, o atributo classe representa o alvo no processo de classificação. A representação do conjunto de exemplos no formato atributo-valor é apresentada na Figura 8.

A partir do processamento dos dados, é construído um conjunto de treinamento que servirá de entrada para o algoritmo de aprendizagem indutiva. O objetivo do processo de treinamento

é obter uma função que mapeie as características preditoras do exemplo, a sua característica de interesse. Em outras palavras, deseja-se encontrar um modelo que relacione os atributos de um dado exemplo com seu atributo classe. Portanto, é necessário que o conjunto de treinamento seja representativo quanto à distribuição da amostragem geral dos dados no domínio. Na literatura, esse conjunto também é denominado como *seen cases*, pois refere-se aos dados já “vistos” pelo algoritmo durante a construção do modelo.

	X_1	X_2	$\dots$	X_M	Y
E_1	x_{11}	x_{12}	$\dots$	x_{1M}	y_1
E_2	x_{21}	x_{22}	$\dots$	x_{2M}	y_2
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
E_N	x_{N1}	x_{N2}	$\dots$	x_{NM}	y_N

Figura 8 – Conjunto de exemplos no formato atributo-valor.

O processo de treinamento do modelo de classificação idealmente deve resultar em um modelo classificador, capaz de prever a classe à qual pertence um novo exemplo de entrada ainda não rotulado. Porém, em determinados casos, o classificador pode estar sub-ajustado ou super-ajustado, o que não é desejável no contexto da indução. O sub-ajustamento, também denominado como *underfitting*, ocorre quando a hipótese resultante ajusta-se muito pouco aos casos de treinamento. Esta situação é consequência de uma amostra de exemplos de treino pouco representativa, o que prejudica o grau de precisão das classificações. Por outro lado, o super-ajustamento, também citado como *overfitting*, ocorre quando a hipótese apresenta resultados muito específicos. Neste caso, o modelo ajusta-se de forma elevada aos exemplos de treinamento e não é eficaz para novos exemplos. Portanto, a construção de um classificador confiável demanda uma seleção precisa dos conjuntos de treinamento, além de um ajuste correto dos modelos resultantes.

Por fim, é realizada a fase de teste do classificador. Também definida como fase de validação, esta fase do processo busca avaliar o desempenho do modelo gerado a partir da classificação de novos exemplos ainda não rotulados. Para isso faz-se o uso de um conjunto de teste, também denominado como *unseen cases*. Idealmente, o conjunto de teste não deve possuir exemplos em comum com o conjunto de treinamento.

Considerando as técnicas de aprendizado supervisionado, define-se que um conceito a ser aprendido deve relacionado com os casos observados, ou seja, todo exemplo deve ser classificado de acordo com o conhecimento prévio do algoritmo. Diversos paradigmas foram propostos na área de aprendizado de máquina como abordagens para o processo de indução. Nas próximas

seções, são apresentados paradigmas de aprendizado considerados relevantes nesta pesquisa, que descrevem o comportamento dos algoritmos explorados durante o processo de experimentação e coleta de resultados quanto à classificação de EA dos estudantes.

4.3.1 Paradigma simbólico

O paradigma de aprendizado simbólico fundamenta-se na construção de representações simbólicas de um conceito por meio da análise de exemplos e contraexemplos deste conceito. Em um problema de classificação, tais representações são induzidas de acordo com o estabelecimento de relacionamentos lógicos entre as características que descrevem o conjunto de dados e os rótulos (classes) envolvidos no problema. Sendo assim, este paradigma utiliza estruturas gráficas ou lógicas para representar a aprendizagem, e tais representações estão tipicamente na forma de uma expressão lógica, árvores de decisão, regras de produção ou redes semânticas (MONARD; BARANAUSKAS, 2003).

Morgan e Messenger (MORGAN; MESSENGER, 1973) desenvolveram o estudo inicial a respeito de técnicas para a indução de árvores de decisão. Estes métodos de indução de árvores de decisão a partir de dados empíricos, conhecidos como particionamento recursivo, tiveram importante contribuição para pesquisas nas áreas de estatística e IA, por meio de sistemas como o ID3 (QUINLAN, 1986) e o C4 (QUINLAN, 1987). O sistema de classificação de árvores de regressão CART (BREIMAN *et al.*, 1984) foi desenvolvido por estatísticos, durante praticamente o mesmo período que o ID3, no final dos anos 70. Os trabalhos com indução de regras de decisão surgiram com a família de algoritmos AQ (MICHALSKI, 1969), e precederam algoritmos como o CN2 (CLARK; NIBLETT, 1989) (CLARK; BOSWELL, 1991). Uma outra abordagem surgiu da tradução das árvores de decisão para regras, com um posterior refinamento (QUINLAN, 1986), resultando no algoritmo C4.5 (QUINLAN, 1987).

Uma Árvore de Decisão (AD) pode ser compreendida como uma estrutura de dados definida recursivamente a partir de: um nó folha que corresponde a uma classe ou um nó de decisão que contém um teste sobre algum atributo. Para cada resultado do teste existe uma aresta para uma sub-árvore e cada sub-árvore tem a mesma estrutura que a árvore (MONARD; BARANAUSKAS, 2003). Na Figura 9 é ilustrado um exemplo de uma AD que utiliza informações climáticas para prever se será possível jogar tênis em um determinado dia.

A partir dessa AD, regras podem ser obtidas. Por exemplo, se o tempo estiver ensolarado e o índice de umidade estiver normal, as condições estarão propícias para se jogar tênis. Portanto, essa regra é representada da seguinte forma:

$$\text{Tempo} = \text{Ensolarado} \wedge \text{Umidade} = \text{Normal} \longrightarrow \text{JOGAR TÊNIS}$$

A classificação de dados em uma AD se dá a partir da raiz em direção a alguma folha, que é responsável pela classificação. Neste processo, ao testar um atributo em determinado

Figura 9 – Exemplo de Árvore de Decisão (Mitchell, 1997).

nó, serão investigados os ramos abaixo da árvore correspondente ao valor do atributo presente no dado de teste. Em sequência, o processo é repetido para a sub-árvore enraizada no novo nó. Informações detalhadas a respeito de sistemas indutores de regras de decisão podem ser encontradas em (FÜRNKRANZ, 1999).

4.3.2 Paradigma estatístico

Diversos métodos de classificação têm sido criados por pesquisadores da área da estatística, de modo que muitos destes métodos são semelhantes a métodos empregados no contexto do aprendizado de máquina. Entre estes métodos por exemplo, pode-se citar o método CART (BREIMAN *et al.*, 1984), mencionado anteriormente. No entanto, esta técnica é empregada na construção de árvores de decisão. Como regra geral, técnicas estatísticas são aplicadas em tarefas nas quais todos os atributos têm valores contínuos ou ordinais, de modo que grande parte destes métodos são paramétricos, assumindo algum modelo pré-estabelecido, e então ajustando valores apropriados para os parâmetros do modelo a partir do conjunto de dados.

Deste modo, um classificador linear assume que as classes podem ser expressas como uma combinação linear dos valores dos atributos, e então busca uma combinação linear em particular que forneça a melhor aproximação sobre o conjunto de dados. Modelos estatísticos comumente assumem que os valores dos atributos estão normalmente distribuídos, e a partir destes dados são calculadas a média, variância, covariância e distribuição. Na literatura, alguns autores consideram Redes Neurais Artificiais (RNA) como um método estatístico paramétrico, uma vez que o processo de treino de uma rede neural consiste na procura por valores apropriados a partir de pesos pré-determinados.

Em outras palavras, o paradigma estatístico tem como fundamento a exploração das dependências funcionais de um conjunto de dados por meio de modelos estatísticos. Portanto, o

objetivo nesta tarefa do aprendizado é encontrar uma função ou modelo capaz de categorizar os dados em suas respectivas classes. Para tanto, assume-se que os dados são gerados de forma independente e identicamente distribuída de acordo com o modelo de distribuição de probabilidade assumido para o problema. No contexto de aprendizado estatístico, pode-se destacar as técnicas de *Support Vector Machine* (SVM) (VAPNIK, 2013), além do método de aprendizado Bayesiano, que manipula diretamente probabilidades para realizar o processo de indução. Exemplos deste método são as técnicas Naive Bayes (MITCHELL *et al.*, 1997) e Redes Bayesianas (FRIEDMAN; GEIGER; GOLDSZMIDT, 1997), que estão fundamentadas na manipulação de probabilidades explícitas para hipóteses. O cálculo das probabilidades é feito com base no Teorema de Bayes, representado na equação a seguir:

$$P(A/B) = \frac{P(B/A) * P(A)}{P(B)}$$

Essa equação envolve dois tipos de probabilidades: probabilidades a priori e probabilidades a posteriori. Portanto, $P(A)$ e $P(B)$ são probabilidades a priori de A e B , respectivamente. O termo “probabilidade a priori” indica que a probabilidade $P(A)$ não leva em consideração nenhuma informação a respeito de B e vice-versa. $P(B/A)$ e $P(A/B)$ são denominadas de probabilidades a posteriori de B condicional a A e de A condicional a B , respectivamente. A abordagem adotada no classificador Naive Bayes consiste em classificar um novo exemplo T com o valor mais provável, Y_s , dados os valores de atributos de entrada $\langle x_1, x_2, \dots, x_m \rangle$ que o descrevem e um conjunto de possíveis valores Y . A fórmula para o cálculo de Y_s é dada pela equação:

$$Y_s = \arg \max_{y_j \in Y} P(y_j) \prod_i P(x_i | y_j)$$

Como pode ser observado, o classificador Naive Bayes é baseado na simplificação de que os valores dos atributos são condicionalmente independentes. Em outras palavras, a probabilidade de observar a conjunção de atributos $\langle x_1, x_2, \dots, x_m \rangle$ é igual ao produto de suas probabilidades individuais. Porém, em alguns casos essa suposição feita pelo Naive Bayes pode ser considerada rígida, pois existem situações em que os atributos não são condicionalmente independentes.

4.3.3 Paradigma baseado em exemplos (Instance-Based)

No paradigma baseado em exemplos considera-se que se dois exemplos do conjunto de dados são similares, eles então pertencem à mesma classe. Portanto, quando um novo exemplo de entrada apresenta características similares a um exemplo já conhecido, a classe deste é atribuída ao novo exemplo. Essa filosofia exemplifica os sistemas *instance-based*, os quais classificam casos nunca vistos utilizando casos similares conhecidos (AHA; KIBLER; ALBERT, 1991). Para tanto, um algoritmo *instance-based* deve manter em memória os exemplos pertencentes ao conjunto de treinamento, entretanto algumas técnicas realizam uma filtragem dos dados de

exemplo a fim de considerar somente os exemplos mais significativos. Trabalhos na literatura descrevem algumas estratégias para decidir quando um novo caso deve ser memorizado. Uma segunda solução para o problema consiste em construir estruturas de indexação para os exemplos e responder consultas sobre os exemplos mais semelhantes de forma eficiente. Dentre essas estruturas estão as M-trees (CIACCIA; PATELLA; ZEZULA, 1997) e as Slim-trees (TRAINA *et al.*, 2000).

Figura 10 – Exemplo de K-Nearest Neighbours.

Diferentemente de outros paradigmas, algoritmos baseados em exemplos não geram modelos explícitos de classificação a partir do conjunto de treinamento, e por este motivo são também denominados com algoritmos *lazy*. Uma das vantagens destes métodos, é a construção de uma diferente aproximação da função objetivo para cada exemplo do conjunto de dados. De forma geral, a classificação nestas técnicas ocorre a partir da maior quantidade de exemplos vizinhos de uma dada classe, em uma proposta que é conhecida como K-Nearest-Neighbours (kNN), conforme representa a Figura 10. A mensuração do grau de semelhança entre casos nos quais todos os atributos são contínuos pode ser determinada por meio de uma função de avaliação, que de acordo com certos critérios calcula a distância entre os valores destes atributos (STANFILL; WALTZ, 1986). Um exemplo de método para o cálculo da similaridade entre duas instâncias é a função de distância euclidiana. Neste caso, considerando $\langle x_1, x_2, \dots, x_m \rangle$ como o vetor de atributos, a distância entre os dois exemplos T_1 e T_2 é dada pela seguinte equação:

$$d(T_1, T_2) = \sqrt{\sum_{r=1}^m x_r(T_1) - x_r(T_2)}$$

Quando o valor de k é igual a 1, então a classe do novo exemplo será igual à classe do exemplo com a menor distância em relação a ele. Ou seja, uma nova instância será classificada

com o rótulo de seu exemplo mais similar presente no conjunto de dados. No caso de k ser maior que 1, é formada uma lista com os k vizinhos mais próximos do exemplo de consulta. Desta maneira, a seguinte equação é adotada para calcular o rótulo de um novo exemplo:

$$Y^* = \arg \max_v \sum_{(T_i, Y_i) \in D_z} f(v = Y_i)$$

Nessa equação, v representa um rótulo, (T_i, Y_i) representa os exemplos pertencentes à lista dos k vizinhos mais próximos (D_z), e $f()$ é uma função que retorna 1 quando $v = Y_i$ e 0 caso contrário. De maneira geral, a equação encontra o rótulo que estiver mais presente na lista dos vizinhos mais próximos, realizando assim uma votação pela maioria. Uma variação dessa abordagem consiste em atribuir pesos à votação dos vizinhos mais próximos, denominada *Weighted kNN*.

Outro conceito que se enquadra neste paradigma de aprendizado é a família de algoritmos de Raciocínio Baseado em Casos, onde os casos protótipos são construídos e exemplos são classificados com base na similaridade com esses casos protótipos.

4.3.4 Paradigma conexcionista

Redes neurais são construções matemáticas inspiradas em padrões biológicos do sistema nervoso. A representação de uma rede neural envolve elementos altamente interconectados, e portanto, este paradigma é denominado conexcionista. A abstração do comportamento biológico relativo às conexões neurais do sistema nervoso motivou os estudos de diversos pesquisadores, incidindo em diversas discussões a respeito das qualidades e limitações destes métodos de aprendizagem. No entanto, acredita-se que tais abordagens apresentem bons resultados na resolução de problemas com características que requerem um processamento similar ao comportamento humano. Pesquisas nesta área de estudos foram iniciadas com o trabalho de McCulloch e Pitts ([MCCULLOCH; PITTS, 1943](#)), ambos pesquisadores do campo da psiquiatria que buscavam mapear eventos no sistema nervoso. A partir disso, Hopfield ([HOPFIELD, 1987](#)) idealizou uma função de energia para formular uma nova forma de compreender os cálculos realizados em redes recorrentes com conexões sinápticas simétricas. Hopfield ([HOPFIELD, 1987](#)) e Rumelhart e McClelland ([RUMELHART et al., 1986](#)) são grandes influências no que diz respeito ao interesse sobre redes neurais. De acordo com Braga et al. ([BRAGA; FERREIRA; LUDERMIR, 2007](#)), as redes neurais tiveram um longo caminho desde McCulloch e Pitts, e continuam a crescer em teoria, projetos e aplicações.

4.4 Considerações finais

O aprendizado de máquina é uma das áreas de pesquisa mais ativas no campo da Inteligência Artificial, o que tem motivado diversas pesquisas e aplicações práticas em diferentes

contextos nos últimos anos. A aplicação desses métodos é fundamental em processos de descoberta de conhecimento em grandes bases de dados, e por este motivo esta área de estudos tem grande interesse da comunidade de pesquisa científica como um todo. Neste capítulo, foram apresentados os principais conceitos que envolvem o AM, tais como as características de inferência lógica, os modos de aprendizado (que definem o grau de supervisão do aprendizado) e as principais tarefas de aprendizado. A descrição possui um foco maior na tarefa de classificação, que será abordada na metodologia deste trabalho. Portanto, neste trabalho serão exploradas técnicas de aprendizado de máquina, relacionadas especificamente à tarefa de classificação, cujo objetivo é prever o rótulo de novas entradas com base nos exemplos de entrada já rotulados. De maneira geral, algoritmos de diferentes paradigmas apresentados (simbólico, estatístico, *instance-based* e conexionista) serão avaliados em um conjunto de dados contendo a representação das interações de estudantes em um ambiente virtual de aprendizagem.

O objetivo neste trabalho é aprimorar o estado da arte quanto à detecção automática e dinâmica de estilos de aprendizagem para a personalização de conteúdo em sistemas educacionais. Portanto, é atividade central deste trabalho a experimentação e comparação de resultados de diversas técnicas de classificação aplicadas ao mesmo problema, a fim de apresentar métodos que possam melhorar a eficácia quanto à caracterização de perfis de alunos de acordo com suas preferências. Assume-se que dadas as particularidades e diferenças entre os diversos algoritmos existentes na literatura, cada técnica pode se comportar de maneira distinta neste tipo de aplicação, o que abre caminho para uma avaliação de quais técnicas são mais apropriadas para este contexto. Além disso, uma comparação sistemática neste sentido pode ser proveitosa para a obtenção de conclusões a respeito de quais propriedades dos dados disponíveis em ambientes acadêmicos podem potencializar o funcionamento de determinado algoritmo. Outro exemplo de conclusão que pode ser obtida é a identificação de técnicas que alcancem melhor resultado em determinado cenário, e a posterior investigação de quais fatores influenciaram para estes resultados. Entende-se que tal experimentação pode render evidências relevantes não só para a área de computação aplicada à educação, como também para estudos relacionados à aplicabilidade de Aprendizado de Máquina.

LITERATURA RELACIONADA

Nas próximas seções, são apresentados alguns dos trabalhos desenvolvidos no tema do presente trabalho, detalhando os processos de modelagem dos estudantes para recomendação personalizada de conteúdo educacional. O capítulo é dividido em quatro seções: inicialmente, são expostas considerações iniciais do autor a respeito dos trabalhos relacionados e a metodologia aplicada para a realização da revisão, em seguida, são apontados trabalhos clássicos e contemporâneos especificamente na área de estudos da detecção automática de estilos de aprendizado. Nesses casos, são exploradas as técnicas investigadas por cada autor para realizar as predições, bem como analisados os respectivos resultados. Na seção seguinte, são enunciados trabalhos que exploram a recomendação personalizada de conteúdo em ambientes educacionais como um todo. Muitos deles fazem uso de modelagem de estudantes, porém não de maneira automática. Outros trabalhos detalhados nesta seção exploram outras abordagens, tais como filtragem colaborativa e recomendação baseada em metadados dos recursos educacionais. Além disso, são apresentados outros trabalhos que envolvem EA, porém não especificamente para modelagem de perfis em sistemas educacionais. Por fim, na seção de considerações finais, são discutidos os trabalhos citados, e também investigadas lacunas a serem exploradas no presente trabalho.

5.1 Considerações iniciais

As seções a seguir apresentam trabalhos clássicos e contemporâneos relacionados ao estudo de técnicas para modelagem de indivíduos em ambientes virtuais em geral. Em sua maioria, os trabalhos citados são voltados para a recomendação de recursos em ambientes educacionais, mais precisamente para a construção de um modelo de perfil dos estudantes de acordo com a teoria dos estilos de aprendizagem. Porém, outros métodos de modelagem para recomendação também são explorados. O levantamento desta revisão tem como objetivo compreender de que maneira é realizado o processo de modelagem de usuários em ambientes online, além de revisar quais os métodos comumente aplicados para se recomendar objetos

de aprendizagem personalizados para estudantes em cursos oferecidos por meio de sistemas educacionais. Além disso, busca-se recolher informações de trabalhos realizados pelos demais autores para a detecção automática de estilos de aprendizagem, em vista de avaliar quais técnicas foram aplicadas, e quais os resultados obtidos. Esta tarefa foi fundamental para a condução do presente trabalho, visto que permitiu a observação de lacunas que podem ser exploradas quanto ao tema, e também a aquisição de conhecimento de metodologias similares que guiaram o desenvolvimento do estudo proposto. Ademais, os resultados obtidos por trabalhos correlatos servem como linha de base para a avaliação dos resultados obtidos nesta pesquisa. Para isso, foram levantados artigos publicados em conferências e periódicos nacionais e internacionais, da área de tecnologia aplicada à educação. Foram priorizados eventos classificados com conceitos altos para a área de Ciência da Computação, de acordo com a plataforma Qualis-CAPES (QUALIS, 2017). No entanto também foram consideradas publicações em *journals* e congressos não avaliados pelo Qualis-CAPES. As palavras-chave pesquisadas em mecanismos de busca foram: “Estilos de Aprendizagem”, “Sistemas Educacionais Adaptativos”, “Recomendação de recursos educacionais”, “Modelagem de estudantes”, “Detecção Automática de Estilos de Aprendizagem”, “Modelo de Felder-Silverman”, “Classificação de perfis de estudantes”, “Mineração de dados educacionais”, “Aprendizado de Máquina em Estilos de Aprendizagem”, entre outras. Além disso, foram observados trabalhos clássicos da área de modelagem de estudantes em ambientes online. Muitos destes trabalhos representam uma base para trabalhos contemporâneos, e apresentam conclusões relevantes para a área como um todo.

5.2 Identificação automática de EA

O trabalho de García *et al.* (GARCÍA *et al.*, 2005) (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. A avaliação da proposta se dá por meio da comparação sistemática entre os resultados obtidos pelo algoritmo com os resultados apontados pelo questionário ILS preenchido pelos estudantes no início do curso. Como resultado é proposto o *Software de Asistencia Virtual para Educación Remota* (SAVER), 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. A dimensão visual/verbal não foi considerada pois o curso investigado no experimento não possuía material relevante que diferenciasses estas características.

No trabalho de Cha *et al.* (CHA *et al.*, 2006), o objetivo é desenvolver um sistema de tutoria inteligente capaz de diagnosticar os estilos de aprendizagem por meio dos padrões de comportamento do aluno em relação à interface gráfica de um ambiente virtual de ensino. A ideia central é personalizar sua interface de usuário para se adequar às preferências e estilos específicos

de cada estudante, de acordo com o modelo de Felder-Silverman. No estudo conduzido com 600 estudantes foram investigadas duas técnicas de aprendizado de máquina, sendo que árvores de decisão foram usadas com foco nos contadores de cliques em botões disponíveis, e Modelos Ocultos de Markov foram usados para analisar informações sequenciais de acessos. Na dimensão de “organização”, o modelo de Markov obteve melhores resultados em relação à árvore de decisão. No entanto, para a dimensão de “captação”, a técnica de árvore de decisão apresentou 0% de taxa de erro, enquanto o modelo de Markov atingiu 14.28%. Este resultado ilustra que as interfaces hipotetizadas são bem projetadas para classificar os estudantes para ambas as dimensões. Conclui-se que atributos como o número de cliques de botão, o tempo gasto em estudos e as taxas de respostas corretas em questionários são mais úteis do que a informação de sequência de acessos para classificar a captação. Por outro lado, a navegação de usuários pela interface mostrou-se mais relevante para a classificação quanto à organização. As demais dimensões do modelo de Felder-Silverman não apresentaram bons resultados neste experimento.

Outro trabalho clássico na área e que influenciou diversas pesquisas, é o de Graf, Kinshuk e Liu ([GRAF; LIU et al., 2009](#)), o qual propõe uma abordagem de identificação automática de EA 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. Além de usar um conceito diferente para calcular estilos de aprendizagem a partir dos dados de comportamento dos alunos, essa abordagem diferencia-se dos demais de outra maneira importante. Enquanto trabalhos relacionados visam a identificação de estilos de aprendizagem em um sistema de educativo específico, a solução proposta é desenvolvida para sistemas de gestão do aprendizado em geral. No entanto, segundo os autores, tornar a abordagem aplicável para sistemas em geral é mais desafiador do que desenvolvê-la apenas para um sistema específico. Portanto, as características avaliadas pelos algoritmos deste estudo foram selecionadas em consideração se elas são comumente disponíveis em outros sistemas e comumente usadas por estudantes em cursos online. Além disso, o procedimento para calcular os estilos de aprendizagem é desenvolvido de forma a permitir dados vazios, caso a informação de um padrão não possa ser recuperada do curso. Entretanto, quanto mais dados estiverem disponíveis, mais precisa é a classificação. Neste contexto, a proposta de *Graf et al.* inclui um número relativamente alto de padrões de comportamento avaliados para cada dimensão do FSLSM, em comparação com os trabalhos relacionados, como o modelo apresentado por *García et al.* ([GARCÍA et al., 2007](#)). 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. Como resultado da proposta, é apresentado o sistema *Detecting Learning Styles* (DeLes), que atua como uma ferramenta de suporte aos docentes para identificar EA em cursos Web.

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), por exemplo, os autores apresentam uma abordagem para detecção e correção automática de estilos de aprendizagem baseada em cadeias de Markov. A abordagem apresentada neste trabalho é baseada na Combinação de Estilos de Aprendizagem (CEA) e na correção dinâmica das inconsistências no Modelo do Estudante (ME), levando em consideração o forte aspecto não-determinístico do processo de aprendizagem. Além disso, os autores defendem que a eficiência obtida por esta abordagem se deve em grande parte ao fato desta ser baseada em um processo estocástico, que se caracteriza principalmente pela representação da variabilidade e das incertezas inerentes ao processo de aprendizagem de cada estudante. Por fim, a proposta foi avaliada utilizando-se técnicas de simulação computacional (BIERMANN; RAMM, 2002), o que permitiu observar o comportamento do modelo em diferentes contextos e situações. A abordagem proposta apresentou bons resultados quanto à detecção e correção automática, dinâmica e contínua dos estilos de aprendizagem do estudante, através de um processo não determinístico e evolucionário, que atua ao longo de todo o processo de ensino-aprendizagem.

Já em outro trabalho (DORÇA *et al.*, 2012), propõe-se que a cada seção de aprendizagem do curso o estudante seja submetido a um conjunto de objetos de aprendizagem que atendam a uma CEA específica, gerada probabilisticamente de acordo com os valores dos EA armazenados no ME. Ou seja, a CEA é uma combinação de 4 variáveis probabilísticas, definidas pelas 4 dimensões do modelo de Felder-Silverman, onde cada variável possui 2 valores possíveis, e cada valor representa um EA, cuja probabilidade é dada pelo grau de preferência armazenado no ME. A composição de uma CEA é realizada por meio de métodos computacionais para seleção estocástica. Existem diversos métodos de seleção estocástica, dentre outros, o método da roleta (*Roulette Wheel Selection*), amostragem estocástica (*Stochastic Universal Sampling*), torneio simples (*Simple Tournament*) e torneio estocástico (*Stochastic Tournament*) (GOLDBERG, 1989). No entanto, os autores utilizaram o método da roleta devido à sua aderência ao objetivo proposto. Ao fim dos experimentos, também foram obtidos resultados satisfatórios quanto à modelagem automática dos estudantes segundo o modelo de Felder-Silverman.

Em outro trabalho, (DORÇA *et al.*, 2013a), Dorça *et al.* descrevem uma proposta para detectar os EA de estudantes centrada principalmente nos aspectos não determinísticos e não estacionários dos estilos de aprendizagem. O foco do trabalho 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. Por fim, em mais um trabalho relevante destes autores, (DORÇA *et al.*, 2013b), é discutida a avaliação de Sistemas Educacionais Adaptativos, com foco na simulação do comportamento de estudantes baseada em seus EA, e de como o sistema educacional os atende ao longo do curso. Como resultado, é apontado que técnicas de simulação computacional podem ser aplicadas com sucesso na experimentação de novas abordagens para a detecção automática de estilos de aprendizagem, considerando seus diferentes aspectos e características.

O trabalho de Dung e Florea ([DUNG; FLOREA, 2012](#)) apresenta outra proposta para modelagem automática de estudantes usando o modelo FSLSM, bastante influenciada no trabalho de Graf e Liu ([GRAF; LIU et al., 2009](#)). Por meio de um experimento com um curso de nove meses sobre Inteligência Artificial, constituído por 204 OAs, foram avaliados 44 estudantes de graduação que preencheram o questionário ILS como base para avaliação dos métodos de classificação. Com uma abordagem baseada em regras de mapeamento, são considerados o número de visitas e o tempo gasto pelos estudantes em cada OA (que possuem metadados 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 relação ao processo de adaptatividade, 91% dos alunos participantes avaliaram a recomendação dinâmica dos objetos como “boa” ou “muito boa”. O método baseia-se apenas em indicações recolhidas pelo comportamento dos alunos durante um curso online e usa uma regra de mapeamento simples. Não depende de qualquer aspecto da arquitetura do sistema. Portanto, com estes resultados, entende-se que o método proposto pode ser usado para detectar estilos de aprendizagem em diversos sistemas educacionais com eficácia. Por fim, foi implementado um sistema adaptativo denominado POLCA, baseado no método proposto.

No trabalho de Carvalho *et al.* ([CARVALHO et al., 2014](#)) é apresentada uma proposta para personalização do ensino centrada no mapeamento de características de EA para metadados de Objetos de Aprendizagem. Para isso foi desenvolvido um modelo computacional que relaciona o padrão de metadados *Learning Object Metadata* (LOM) com o modelo de Felder e Silverman. O modelo probabilístico de EA, previamente definido por Dorça *et al.* ([DORÇA et al., 2012](#)), é utilizado para que se possa levar em consideração as incertezas relacionadas às preferências de cada usuário. No entanto, ao contrário dos demais trabalhos já citados, os quais exploram métodos para a modelagem de usuário, este trabalho está focado no Modelo Adaptativo de um Sistema Educacional Adaptativo.

Em um trabalho mais recente, Liyanage *et al.* ([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. Além disso, o mesmo módulo estima o EA do aluno por meio das interações realizadas no sistema Moodle. São considerados os logs de visitas e o tempo gasto em cada recurso, aplicados aos métodos baseados em regras propostos por Graf e Liu ([GRAF; LIU et al., 2009](#)). No segundo módulo ocorre a recomendação de OAs compatíveis com cada estilo de aprendizagem; e por fim, no terceiro módulo são disponibilizadas ferramentas para os docentes calibrarem os mecanismos de adaptatividade. Os experimentos para detecção dos EA foram conduzidos em um grupo de 80 estudantes matriculados no Moodle, e alcançaram precisões de 65.00%, 75.00%, 76.25% e 77.50% para as dimensões de processamento, percepção, captação e organização, respectivamente.

No trabalho de Abdullah *et. al* ([ABDULLAH, 2015](#)), os autores conduziram um experimento com 35 alunos para o curso online de Estrutura de Dados oferecido por meio do sistema Moodle. Ao extrair o comportamento dos alunos por meio de dados de registro do Moodle, o estilo de aprendizado foi identificado para cada aluno de acordo com o modelo de Felder-Silverman. Além disso, o estilo de aprendizagem foi comparado com os resultados de um teste realizado no final do curso. A proposta, que estuda a aplicação de árvores de decisão, teve a eficácia da classificação avaliada por meio da curva ROC, em comparação com os resultados do questionário ILS. São alcançados bons resultados com uma precisão média de 76% para as dimensões do modelo de Felder-Silverman. Mais especificamente, são alcançadas taxas de precisão de 90%, 76%, 85% e 70% para as dimensões de processamento, captação, percepção e organização do modelo de Felder-Silverman respectivamente. Os dados dos alunos foram divididos em quatro conjuntos de treinamento e teste com diferentes taxas de validação cruzada. Como conclusão, os autores apontam para o alto grau de precisão ao classificar os estudantes a partir de árvores de decisão, principalmente quanto às dimensões de processamento e percepção. Os autores destacam ainda que os padrões de comportamento relacionados ao comportamento em fóruns, recursos textuais, vídeos, animações, exemplos e exercícios foram relevantes para estes resultados.

Dentre os trabalhos contemporâneos, Silva *et al.* ([SILVA; FERREIRA; PIMENTEL, 2016](#)) propõem um método de apresentação adaptativa de OAs considerando também o modelo Felder-Silverman. Neste caso, as preferências e características de cada estilo foram identificadas e mapeadas para “características de apresentação para OA”, e formaram a base para definição dos critérios de adaptação, cujo objetivo é contribuir para criação de OAs compatíveis com estilos de aprendizagem específicos. Essas características foram adotadas em relação a sequenciamento, apresentação, formato de conteúdo e recursos que compõem um Objeto de aprendizagem, adequados a cada estilo compatível ao estilo do aluno. Essa estrutura foi projetada e composta respeitando os princípios da Teoria Cognitiva da Aprendizagem Multimídia de Mayer (TCAM) ([MAYER, 2005](#)), pois, segundo os autores, os princípios dessa teoria ajudam a evitar o uso inadequado de recursos nos mais variados formatos, que podem acarretar na distração e desmotivação do aluno no uso desse tipo de recurso, o que prejudica o processo de aprendizagem.

Em outro trabalho recente, Rajper *et. al* ([RAJPER *et al.*, 2016](#)) propõem uma técnica para a detecção automática de estilos de aprendizagem de acordo com o modelo de estilos de Kolb. O estudo aplica classificadores baseados em Redes Bayesianas combinados com tarefas de pré-processamento dos dados para prever os estilos preferenciais dos estudantes em um curso online. A coleta de dados para os experimentos é realizada a partir de um curso de ciência da computação, que conta com 863 estudantes matriculados. O comportamento destes alunos no ambiente virtual é usado para mapear os estilos de aprendizagem da sala de aula para o ambiente sistema. Dentre os padrões de comportamento avaliadas, os autores destacam o tempo de login no sistema educacional, contato imediato em caso de dificuldades, ferramenta usada com frequência para contatar o docente em caso de dificuldade, atividades de participação no

quadro de discussões, preferências de leitura, participação no chat, envio de tarefas, dentre outros. Além disso, os alunos do experimento responderam ao questionário padrão denominado *Kolb's Learning Style Inventory* (KLSI), para a construção dos modelos de treino e teste do algoritmo. Como resultado, o uso de redes Bayesianas atingiu 66,67% de precisão na classificação de estudantes Divergentes, 75% para os Assimiladores, 50% para os Acomodadores e 75% para os Convergentes, segundo o modelo de Kolb.

Gonçalves *et al.* (GONÇALVES *et al.*, 2016) realizam um estudo comparativo de novas abordagens para modelagem automática e dinâmica de EA, onde os autores propõem modificações no Modelo do Estudante e no Modelo Pedagógico de uma arquitetura para adaptatividade, como uma extensão ao trabalho de Dorça *et al.* (DORCA *et al.*, 2012). O Modelo Pedagógico tem a função de selecionar uma combinação de estilos de aprendizagem pelo qual o conteúdo didático será adaptado. De acordo com os autores, o sucesso do tratamento individualizado considerando o perfil do estudante está relacionado com a qualidade da escolha dessas combinações. Portanto, neste trabalho é proposta uma modificação do MP, que deixa de considerar apenas as preferências dos EA e acrescenta como parâmetro a média aritmética de desempenho em cada EA, obtida através das avaliações nas sessões de aprendizagem. As soluções propostas neste trabalho proporcionaram uma melhoria de 6,1% no desempenho avaliativo do estudante e uma redução média de 68,3% nos problemas de aprendizagem.

No trabalho de Sena *et al.* (SENA *et al.*, 2016), a proposta é 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 cada dimensão do modelo de Felder-Silverman, foi organizado um modelo oculto de Markov onde os estados ocultos são os próprios estilos. Por exemplo, na dimensão de captação, foi organizado um modelo oculto de Markov onde os estados ocultos representam as duas sub dimensões: visual ou verbal. E assim respectivamente para as demais dimensões. No entanto, os estados observáveis do modelo de captação são representados pelos objetos de aprendizagem: imagem, vídeo, texto e áudio. Para a dimensão de processamento, os estados observáveis são representados pelas preferências do estudante em se interagir em grupo participando de chats e fóruns ou priorizando as atividades individuais com o conteúdo formal e a criação de modelos próprios. Para a dimensão de organização, os estados observáveis são representados pelas preferências do estudante em se interagir de forma sequencial e optando por conteúdos analíticos ou acessando os conteúdos sintéticos e de maneira global. Por fim, a dimensão de percepção foi definida em um modelo oculto de Markov onde os estados observáveis são representados pelas preferências do estudante pelos objetos de aprendizagem: fatos, experiências, dados, teorias, modelagens e abstrações. 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.

5.3 Técnicas para recomendação de recursos educacionais

A arquitetura denominada *iWeaver* (WOLF, 2003), desenvolvida na linguagem de programação Java, é baseada no modelo de estilos de aprendizagem definido por Dunn e Dunn (DUNN; DUNN, 1974) (DUNN; DUNN; PRICE, 1981) (DUNN; GRIGGS, 2003). A proposta de Wolf incorpora aspectos gerais do modelo, enfatizando as características de acessibilidade, navegabilidade e conteúdo personalizado dentro de um ambiente virtual de ensino. A adaptabilidade de conteúdo neste caso é baseada em dois conceitos. O primeiro deles consiste no relacionamento entre os objetos de aprendizagem e seus elementos agregados, juntamente com o domínio psicológico definido pelos estudos de Dunn e Dunn. O segundo conceito são as ferramentas necessárias para a apresentação do conteúdo, levando em consideração a ordem de exibição, bem como os materiais necessários.

Diante disso, o sistema *iWeaver* fornece suporte em estilos de aprendizagem com base em quatro tipos de experiência por meio dos objetos multimídia. Estudantes com inclinação para estilos textuais recebem materiais e componentes com predominância de conteúdo em forma de texto, com hierarquias estruturadas de forma verbal. Por outro lado, estudantes com predominância de estilos visuais recebem conteúdo carregado com figuras, mapas, gráficos, vídeos, diagramas e animações. Aos estudantes com preferência pelo estilo tátil é apresentado um conteúdo com versões interativas, que requerem ação do aluno para troca de experiências com o ambiente. Desta maneira, o estudante passa de mero observador para participante durante o processo de aprendizagem. Além disso, a ferramenta considera os estudantes com propensão ao estilo global, fornecendo a estes, mapas conceituais para um melhor entendimento do assunto em questão, enquanto alunos com perfil reflexivo e cinestésico possuem a opção de obter exemplos adicionais sobre determinado conteúdo educacional. Por último, estudantes com perfil auditivo recebem conteúdo baseado em áudio, onde os conceitos chave são apresentados em arquivos devidamente preparados para serem compreendidos por meio da escuta.

Ao acessar o sistema pela primeira vez, os estudantes são solicitados a preencher um formulário denominado *Building Excellence Inventory* que foi desenvolvido por Dunn e Rundle (RUNDLE; DUNN, 2000) para indicar os índices de predominância de cada estilo de aprendizagem de acordo com o modelo de Dunn e Dunn. De acordo com esta proposta, é construído um modelo inicial do perfil do usuário, porém este perfil é incrementado com as preferências, satisfação com o conteúdo recomendado, progresso e conhecimentos prévios do aluno. Por fim, este perfil também é atualizado e revisado de acordo com o comportamento dos usuários dentro do sistema.

Já a proposta INSPIRE, abreviação para *Intelligent System for Personalized Instruction in a Remote Environment* (PAPANIKOLAOU *et al.*, 2003) é baseada nas metas de cada estudante. Portanto, a adaptatividade proposta é centrada nas opções do que o estudante deseja aprender.

Para isso, o sistema INSPIRE recomenda lições que correspondem ao nível de conhecimento dos alunos, e controla estes materiais por meio do progresso e dos estilos de aprendizagem de cada indivíduo. Nesta abordagem, o estudante é capaz de escolher o conteúdo que deseja acessar, optando pelo tipo de atividades, tarefas e trabalhos em que possui melhor rendimento. Além disso, o estudante pode atualizar seu perfil, alterando informações referentes às suas preferências para receber somente objetos de aprendizagem condizentes com suas ideias.

A estratégia para identificar os estilos de aprendizagem dos alunos neste trabalho é baseada no modelo de estilos de aprendizagem de Honey e Mumford (HONEY; MUMFORD *et al.*, 1992). Portanto, a adaptatividade é fornecida com foco na sequência dos materiais apresentados, na navegação adaptada para cada estilo e na apresentação diferenciada dos objetos. A organização da sequência dos materiais e da navegação disponível no ambiente virtual é disponibilizada por meio das escolhas dos alunos, além do nível de conhecimento e do progresso de aprendizagem no conteúdo em questão. Por outro lado, a apresentação dos objetos é feita considerando os estilos de aprendizagem de Honey e Mumford. Todas as ações e comportamentos do estudante são registrados pelo sistema, porém estas informações não são utilizadas para classificar os estilos de aprendizagem. Para isso, o sistema faz uso do questionário proposto pelos autores do estilo, o qual os alunos são solicitados a preencher durante o primeiro acesso ao ambiente.

O sistema TANGOW (CARRO; PULIDO; RODRIGUEZ, 2001), abreviação para *Task-based Adaptive learner Guidance On the Web*, utiliza de tarefas e métricas para definir modelos de cursos gerenciados via web. O material de um curso neste caso é um conjunto de objetos multimídia associados a uma tarefa específica. A adaptatividade do sistema TANGOW é realizada a partir do modelo de estilos de aprendizagem de Felder-Silverman, incorporando especificamente as dimensões sensorial/intuitivo e sequencial/global. A personalização do conteúdo nesta proposta é modificar a ordem em que os objetos são apresentados ao aluno, recomendando apenas materiais relevantes para o estudante dado um estágio do aprendizado.

A detecção dos modelos de aprendizagem é uma abordagem híbrida. No início do curso os estudantes preenchem o questionário ILS, cujo resultado é classificado em uma escala de três níveis para cada dimensão (nível alto, nível balanceado e nível baixo). Estudantes com nível balanceado em uma das dimensões recebem o conteúdo padrão do curso, seguindo a ordem de apresentação dos objetos que a disciplina forneceria sem os recursos de adaptatividade. Para os estudantes com índices altos ou baixos, o curso será personalizado. Após o início do curso, os dados de interação de cada indivíduo no ambiente serão processados e, desta maneira, o seu comportamento será comparado com os dados oriundos do questionário. Em caso de inconsistência entre os resultados do questionário e o comportamento do estudante, o perfil de aprendizado será então revisado e atualizado.

O sistema LORSys proposto por Ferreira (FERREIRA; RAABE, 2009) é uma abordagem para recomendação de conteúdo de forma adaptável e personalizada a partir de uma

detecção automática e independente dos perfis de usuários. O objetivo deste trabalho é sugerir objetos de aprendizagem padronizados no formato SCORM aos estudantes, utilizando o sistema Moodle como estudo de caso. A avaliação do sistema LORSys foi realizada a partir de um experimento com um pequeno grupo de usuários durante o acesso a um curso na área da Ciência da Computação. Este curso possuía objetos de aprendizagem no padrão SCORM. Foi solicitado aos usuários que interagissem diariamente com os objetos de aprendizagem disponibilizados no ambiente durante duas semanas.

A avaliação foi realizada de duas formas: quantitativa e qualitativa. Na avaliação quantitativa foram analisadas quantas recomendações foram acatadas pelos usuários, ou seja, quantos cliques foram dados sobre links recomendados pelo sistema. Esta informação permitiu realizar a comparação entre os tipos diferentes de filtragem usados e sua eficiência e também analisar a evolução do sistema de acordo com o crescimento de informações armazenadas. A avaliação qualitativa foi realizada perguntando-se aos usuários como eles avaliavam, ao final do período do experimento, as recomendações feitas pela ferramenta. Por meio da avaliação quantitativa, foi possível identificar que as recomendações geradas com a filtragem baseada em conteúdo foram mais aceitas.

Primo e Vicari ([PRIMO; VICARI; BERNARDI, 2012](#)) propuseram um sistema de recomendação de materiais educativos por meio de metadados. Nesta abordagem, os metadados são utilizados para definir as características do conteúdo semântico dos objetos de aprendizagem. Considerando que os materiais presentes na área da educação são concebidos de maneira a atender determinadas estratégias pedagógicas e estilos de aprendizagem, Primo e Vicari afirmam que é comum que o material educativo tenha associado informações de metadados e, para lidar com isso, propõem uma infraestrutura de sistemas de recomendação que incide sobre o pós-processamento das recomendações feitas por qualquer técnica de recomendação tradicional como, por exemplo, um sistema de filtragem colaborativa.

O sistema de recomendação denominado Lassique tem como objetivo observar detalhadamente os metadados dos objetos de aprendizagem presentes no ambiente educacional e também a saída dos algoritmos de filtragem colaborativa. Desta maneira, o sistema funciona como uma ferramenta de auxílio à tomada de decisões por parte do docente. Para a definição do esquema de metadados, foi escolhido o padrão OBAA – derivado do padrão IEEE LOM – que além de abranger aspectos pedagógicos, fornece interoperabilidade entre plataformas de hardware contextualizadas com o domínio educacional brasileiro, incluindo Televisão Digital, dispositivos móveis e a Internet.

Para definir os perfis dos usuários, este trabalho categoriza os estudantes de acordo com suas características educacionais, por meio de uma abordagem híbrida entre filtragem colaborativa e filtragem baseada em conteúdo. O intuito destes métodos é determinar quais objetos de aprendizagem serão recomendados para cada perfil, tomando como base alunos com perfis similares, e também objetos de aprendizagem com características similares.

O Sistema Híbrido de Recomendações (SHR) proposto por Ferro *et al.* (FERRO *et al.*, 2010) é uma proposta de ferramenta para recomendação personalizada de conteúdo no contexto educacional que apresenta uma abordagem mista, combinando técnicas de filtragem baseada em conteúdo, filtragem colaborativa e recomendação não personalizada. A estratégia de Ferro é exibir para os estudantes um conjunto de materiais que sejam compatíveis com seus perfis. O perfil dos usuários é delineado a partir do preenchimento de informações sobre áreas de interesse, que são agrupadas por tipos de assuntos. Com um sistema de pesos, cada área de conhecimento recebe um grau de importância, de maneira que cada peso é atualizado conforme as interações do aluno com os objetos de aprendizagem. Desta maneira, o aluno é solicitado a avaliar os materiais recomendados pelo sistema adaptativo. Esta abordagem combina uma recomendação com base em dados do histórico do usuário com as correlações de comportamento entre os usuários, além das similaridades e características em comum entre os objetos, neste caso, os objetos de aprendizagem.

O processo de construção do modelo para recomendações foi realizado a partir de quatro etapas. Na primeira etapa, é gerada uma lista de materiais didáticos por meio de filtragem colaborativa, considerando a similaridade de perfis dos usuários. Cada item da lista possuirá um valor de compatibilidade entre o usuário e este objeto de aprendizagem. A lista é então ordenada de maneira decrescente a fim de se construir uma ordenação dos materiais didáticos mais recomendáveis a cada usuário. A segunda etapa consiste do cálculo do grau de utilidade de cada item da etapa anterior, desta maneira, é gerada uma nova lista com os mesmos elementos, consistindo em uma ordenação de objetos de acordo com o grau de utilidade. Na terceira etapa, são verificados os itens de maior evidência dentro do ambiente, a partir de uma técnica de recomendação não personalizada. O objetivo nesta fase é qualificar os elementos de acordo com a procura dos usuários, e novamente é gerada uma ordenação de maneira decrescente dos objetos mais requisitados. Na quarta etapa, são utilizadas as listas geradas nas demais etapas para se calcular o grau de utilidade híbrida, que servirá como parâmetro principal para as recomendações.

O trabalho de Zaina *et al.* (ZAINA *et al.*, 2012) apresenta a metodologia denominada *e-Learning Object Recommendation System* (e-LORS), uma abordagem para a recomendação de conteúdo eletrônico baseada no relacionamento entre perfis e objetos de aprendizagem. Nessa proposta, perfis de aprendizagem são descritos por dimensões discretas de maneira a atender diferentes perspectivas de preferência do estudante. Já a metodologia de recomendação usa estas dimensões para filtrar os objetos de aprendizagem – descritos pelo padrão IEEE LOM – mais adequados ao estudante. Para mapear o perfil do aluno foi utilizado o modelo de estilos de aprendizagem de Felder-Silverman, além de determinada uma relação entre as preferências definidas no modelo do aluno com as categorias descritoras dos objetos de aprendizagem do padrão IEEE-LOM. O objetivo neste caso, é verificar o relacionamento entre as dimensões do modelo FSLSM e os objetos de aprendizagem processando-se os metadados que os descrevem. A definição deste relacionamento entre OA e EA torna possível a recomendação dos objetos de aprendizagem que mais bem correspondem ao perfil de aprendizagem de um determinado aluno.

Para a validação da proposta, foi conduzido um experimento com alunos de uma disciplina de Física I durante todo um semestre letivo. Neste período, 297 alunos interagiram com o sistema de recomendação. Em operação, o sistema e-LORS realizou as recomendações de conteúdo considerando as preferências identificadas durante a matrícula dos alunos e os objetos de aprendizagem catalogados no repositório LOM. Ao fim do experimento foi aplicado um questionário para medir a aceitação do sistema por parte dos alunos. Neste questionário, onde cada aluno deveria responder sobre seu grau de satisfação em relação aos objetos oferecidos, 67% dos estudantes consideraram as recomendações satisfatórias. Além disso, destaca-se que a média geral dos alunos que participaram do experimento subiu significativamente em relação aos alunos do período anterior (de 5,42 para 7,55).

No trabalho de Yang *et. al* (YANG; HWANG; YANG, 2013) é desenvolvido um sistema de aprendizagem adaptativa levando em consideração diversas dimensões de recursos personalizados. É proposto um módulo de apresentação personalizada de objetos de aprendizagem baseado no modelo de estilos cognitivos dependentes e independentes de campo, além das quatro dimensões descritas no modelo de Felder-Silverman. Um experimento foi conduzido para avaliar o desempenho da abordagem proposta em um curso de ciência da computação. Cinquenta e quatro participantes foram atribuídos aleatoriamente a um grupo experimental que interagiu com o sistema de aprendizagem adaptativa desenvolvido com base no módulo de apresentação personalizada. Além disso, um grupo de controle interagiu com o sistema de aprendizagem convencional sem apresentação personalizada. Os resultados experimentais mostraram que os alunos do grupo experimental obtiveram melhores resultados de aprendizagem do que os alunos do grupo controle. Um dos diferenciais deste trabalho em relação aos demais, é a aplicação de estilos cognitivos em conjunto com Estilos de Aprendizagem para realizar modelagem de estudantes em sistemas educacionais.

Em trabalhos recentes, Wiedemann *et. al* (WIEDEMANN; BARBOSA; RIGO, 2013) propõem um modelo para recomendação de Objetos de Aprendizagem baseado na análise de similaridade entre históricos de consultas realizadas em repositórios de objetos. O modelo proposto recebe a sequência de OA consultados durante a sessão atual do usuário e localiza sessões cujas sequências de OA consultados sejam similares à sequência da sessão corrente. Os OA encontrados nas sessões similares são então recomendados ao usuário. O modelo proposto utiliza a técnica conhecida como *Dynamic Time Warping* (DTW) para analisar a similaridade entre a sequência de OA consultada durante a sessão atual do usuário e o conjunto completo de sequências armazenadas nos históricos de acessos do repositório. Cada sequência de OA consultada é considerada uma série temporal artificial. Foi desenvolvido um protótipo para avaliação do modelo proposto, a partir de um cenário real de acessos ao sistema Moodle.

Em uma proposta alternativa, Almeida *et. al* (ALMEIDA *et al.*, 2016) buscam explorar as informações geradas por um grupo de usuário em redes sociais no processo de busca e seleção de recursos educacionais de interesse comum de seus membros. De maneira geral, este trabalho

explora as informações geradas por estes estudantes para mapear um sistema de recomendação de objetos de aprendizagem para grupos. Uma das etapas do trabalho foi o desenvolvimento de uma arquitetura capaz de extrair características de grupos de usuários em redes sociais e realizar recomendações de recursos educacionais condizentes com essas características. A avaliação deste modelo se deu por meio de um protótipo e de um estudo de caso. A utilização da revisão sistemática realizada (ALMEIDA *et al.*, 2015) serviu de base para a construção da arquitetura proposta.

O processo de aquisição de informações do perfil inicia-se a partir do login do usuário no *Facebook*. As características retiradas como dados de entrada para o sistema de recomendação são: o nome do grupo, descrição, postagens e horário de maior incidência de publicações (características do grupo); e nome do usuário, idade, histórico educacional, tipo de mídia mais compartilhada, gênero, idiomas de domínio, interesses, dia e horário de maior acesso, dispositivo usado e as conexões de um usuário com outros usuários (características dos membros do grupo). O módulo de recomendação é responsável por realizar buscas em diferentes fontes, estabelecendo a relação entre o perfil do grupo e os recursos educacionais armazenados nessas fontes. Nesse módulo é definida também a prioridade de recomendação a partir da aderência entre os recursos educacionais e o perfil estabelecido para o grupo.

Para realizar o estudo de caso foram criados grupos no Facebook, compostos de participantes voluntários. O primeiro grupo avaliou a recomendação de conteúdo de forma satisfatória, onde 68% dos participantes avaliaram os materiais recebidos como “bom” ou “muito bom”, enquanto o segundo grupo avaliou 90% dos recursos como “bom” ou “muito bom”. De acordo com os autores, o protótipo desenvolvido demonstra viabilidade técnica e aceitação dos usuários em relação à identificação de seus respectivos perfis educacionais e recomendações realizadas.

5.4 Considerações finais

O levantamento da literatura relacionada ao presente trabalho permitiu diversas conclusões a respeito do processo de modelagem de estudantes em sistemas educacionais. Além disso, foi possível compreender os processos de desenvolvimento e avaliação de técnicas para detecção automática de estilos de aprendizagem. Dentre as conclusões obtidas, destaca-se a grande preferência dos demais autores pelo modelo de Felder-Silverman em relação à aplicação de EA em sistemas de recomendação. Esta tendência justifica-se em grande parte pela praticidade de identificação das preferências de estudantes para este modelo, devido aos instrumentos disponibilizados pelos autores para tal. Além disso, o fato do modelo de Felder-Silverman englobar ideias de diversos outros estudos de maneira padronizada contribui para a sua predominância neste contexto. No entanto, conforme avaliado nesta revisão da literatura, este modelo produziu bons resultados em outros trabalhos de detecção automática, o que fornece uma base confiável para sua utilização neste trabalho. Dentre as técnicas de aprendizado de máquina empregadas,

destaca-se o aprendizado Bayesiano, aplicado por diversos autores. Entretanto, árvores de decisão e redes neurais também foram exploradas neste cenário. Por fim, também foram encontrados estudos recentes que exploram a aplicação de estilos de aprendizagem em outros contextos, como por exemplo, jogos educativos (SOFLANO; CONNOLLY; HAINEY, 2015) (WAES; WEIJEN; LEIJTEN, 2014), e apresentam resultados promissores e relevantes para trabalhos futuros.

O trabalho proposto enquadra-se na abordagem de modelagem do usuário baseada em estilos de aprendizagem, para recomendação de conteúdo educacional personalizado. Deste modo, o foco do estudo concentra-se em analisar técnicas e metodologias para a identificação automática das preferências dos estudantes durante o aprendizado em um ambiente virtual de ensino. Para isso, são necessárias etapas de análise e processamento dos dados de interação destes alunos no software de apoio aos estudos, a fim de se induzir modelos preditivos para classificação de EA. Durante a revisão bibliográfica realizada neste trabalho, foram encontradas algumas lacunas nos trabalhos correlatos que podem ser melhorados nesta proposta. Quanto aos estudos analisados em relação à recomendação de recursos educacionais (Seção 5.3), entende-se que as abordagens de recomendação baseadas em metadados dos objetos de aprendizagem são diretamente dependentes de uma base de objetos devidamente rotulados, o que pode ser inviável em determinados cenários reais. Portanto, neste trabalho assume-se que a modelagem de estudantes por meio de padrões de comportamento em ambientes virtuais pode ser mais abrangente, desde que estes dados de interação sejam comumente disponibilizados por diferentes sistemas educacionais. Por outro lado, nos trabalhos presentes na literatura em que são explorados os métodos de modelagem automática dos estudantes (Seção 5.2), notou-se a carência de uma ampla experimentação quanto às técnicas de classificação disponíveis na área de aprendizado de máquina. Para isso, na atual proposta, espera-se contribuir com um estudo detalhado das técnicas aplicáveis a este contexto. Tendo isso em vista, pretende-se ampliar o estado da arte em relação aos trabalhos apresentados por meio de uma abrangente experimentação no que tange aos métodos computacionais que podem ser úteis durante o processo de modelagem de estudantes.

Conforme apontado por Truong (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. Além disso, outro problema em aberto, este apontado por Feldman *et al.* (FELDMAN; MONTESERIN; AMANDI, 2015), é o fato de que trabalhos de detecção automática de EA, em geral, são caracterizados por um número muito grande de aplicações em pequena escala, a partir de

pequenas amostras de estudantes. Neste sentido, os tamanhos de população utilizados para experimentos são relativamente baixos: 10 (GARCÍA *et al.*, 2007), 44 (DUNG; FLOREA, 2012), 75 (GRAF; LIU *et al.*, 2009), 80 (LIYANAGE *et al.*, 2014). Em outros trabalhos, são explorados métodos de simulação do comportamento de estudantes e produção de dados por meio de funções probabilísticas. Neste trabalho, no entanto, espera-se avaliar o comportamento dos alunos em um ambiente real de aprendizado, para que se possa identificar potenciais limitações neste tipo de cenário e apontar métodos de classificação capazes de alcançar eficiência e eficácia, apesar destas limitações. Assim sendo, para fins de experimentação foi selecionada uma amostragem de 105 estudantes, o que é considerado um bom número em comparação aos demais trabalhos. Além disso, valoriza-se a alta quantidade de objetos de aprendizagem disponíveis no curso e a diversidade de características destes materiais.

MATERIAIS E MÉTODOS

6.1 Contexto, participantes e características do curso

Para a realização dos estudos propostos neste trabalho, foi considerado como estudo de caso 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 3, a qual indica o percentual de preferência dos estudantes para cada dimensão.

Tabela 3 – Resultados do questionário ILS.

Processamento		Captação		Organização		Percepção	
Ativo	Reflexivo	Visual	Verbal	Sequencial	Global	Sensorial	Intuitivo
79,38%	20,62%	53,61%	46,39%	69,07%	30,93%	87,63%	12,37%

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. Estes recursos de aprendizagem são constituídos por materiais de diversas características. De maneira geral, ao início de cada capítulo é apresentado um objeto textual de contextualização do tema, onde são introduzidos os principais conceitos a serem discutidos

no módulo, além de apresentar dados do atual cenário quanto a este campo de estudos. Além disso, a maioria dos capítulos apresenta um conjunto de vídeos divididos em duas classes: vídeos ilustrativos e vídeo-aulas. Os vídeos ilustrativos são exemplos práticos de atividades relacionadas ao tema, enquanto as vídeo-aulas correspondem à explicação do conteúdo por parte de um docente. Além dos vídeos, o conteúdo do curso é composto por textos em *PDF*, e textos organizados em formato de livro, onde o usuário navega sequencialmente pelo texto como em uma apresentação de slides. Cada capítulo solicita um desafio para que os estudantes apliquem na prática os conceitos lecionados, e ainda, disponibiliza exercícios em formato de enquete para que os usuários testem seus conhecimentos a respeito do conteúdo. Como materiais de apoio, os docentes proporcionam em cada capítulo um conjunto de referências bibliográficas e uma página de glossário. No glossário, os estudantes interagem com postagens de endereços ou materiais complementares à disciplina, que possam ser de interesse dos colegas. Para interação entre os alunos e professores, cada capítulo disponibiliza um tópico no fórum de discussões, que serve como plantão de dúvidas e discussão de atividades. Conforme mencionado anteriormente, há um alto grau de utilização destes tópicos por parte dos estudantes, onde são registradas diversas postagens, respostas e visualizações diárias. Por fim, em cada capítulo, é solicitado aos estudantes o preenchimento de dois questionários: o primeiro trata de uma auto-avaliação do aluno a respeito de seu aproveitamento naquele módulo; o segundo requer uma avaliação do módulo por parte dos alunos, onde estes apontam as qualidades e deficiências dos materiais apresentados na atual disciplina.

Toda a administração do estudo de caso contou com o suporte das docentes responsáveis pelo conteúdo do curso. Portanto, o auxílio das professoras Dra. Deborah Ferrari, Marina Morettin e Paula Paiva foi fundamental para a condução do trabalho, principalmente nas etapas de mapeamento das características do curso e compreensão dos recursos educacionais.

6.2 Recursos educacionais disponíveis

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 11, 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). Isso ocorre em grande parte dos cursos oferecidos por meio de sistemas de gerenciamento do aprendizado. Arquivos de vídeo com explicações do docente e materiais em texto são fundamentais pois aproximam a experiência de aprendizado online do ensino tradicional, onde o docente expõe os conceitos praticamente da mesma maneira. Portanto, os administradores de cursos online comumente adotam estes tipos de recursos para apresentar o material didático, expor exemplos, conceitos e ideias. Neste trabalho e em outros semelhantes, assume-se que a distinção dos materiais de acordo com o formato de apresentação (vídeo ou

Figura 11 – Recursos educacionais disponíveis no curso avaliado.

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. Idealmente, a preferência de interação dos alunos com cada tipo de recurso deve ser relevante para a classificação quanto a essa dimensão.

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. Consequentemente, 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. Este tipo de recurso é frequentemente adotado em sistemas de gerenciamento do aprendizado, pois aproxima os estudantes e impulsiona o aprendizado colaborativo.

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. Assume-se portanto, que a distinção deste tipo de objeto, ainda que ambos sejam textuais, possa ser proveitosa para a classificação de EA. O mesmo ocorre para recursos com conteúdo introdutório ao tema de cada capítulo.

Figura 12 – Recursos educacionais agrupados por seções.

Ademais, objetos relacionados a formulários de auto-avaliação, avaliação dos capítulos e glossários acompanham a quantidade de capítulos observados. Estes recursos também oferecem informações importantes no processo de compreensão do comportamento dos estudantes, visto que os glossários demandam interação dos usuários entre si (de maneira semelhante aos fóruns) e os formulários indicam considerações dos alunos quanto ao próprio desempenho e quanto à satisfação com os materiais disponibilizados. Neste trabalho assume-se que tais informações podem ser relevantes no processo de extração de características dos estudantes para classificação. 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.

Por fim, os objetos de aprendizagem foram agrupados em diferentes seções durante a apresentação de cada capítulo do curso. As seções de materiais didáticos, por exemplo, são compostas por todos os objetos relacionados a conteúdo introdutório, livros, conteúdo em vídeo e conteúdo textual. Nas seções de atividades foram agrupadas as tarefas e exercícios. Em materiais de apoio, encontram-se as páginas relacionadas a perguntas frequentes, referências bibliográficas e links externos. Nas seções de interação estão os fóruns de discussões e glossários e por fim, os questionários de auto-avaliação e avaliação dos capítulos compõem as seções de avaliação. Na Figura 12, é apresentada a quantidade total de recursos educacionais disponíveis em cada seção, a qual evidencia novamente a predominância de materiais didáticos dentre os componentes do curso.

Os rótulos aplicados aos recursos educacionais foram selecionados com base em trabalhos correlatos ((KULJIS; LIU, 2005), (GARCÍA *et al.*, 2007), (GRAF, 2007), (DUNG; FLOREA, 2012)), mas também levando em consideração as propriedades do curso que serviu como estudo de caso. Por exemplo, uma diferenciação do comportamento dos estudantes quanto a

materiais visuais vs textuais demonstrou bons resultados em outros experimentos. O mesmo para interações com o fórum de discussões. No entanto, os questionários de auto-avaliação e a avaliação dos capítulos são características únicas do presente estudo de caso, e portanto, também foram incorporados às classes de recursos educacionais.

6.3 Padrões de comportamento avaliados

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 ([GRAF; LIU et al., 2009](#)), Garcia *et al.* ([GARCÍA et al., 2007](#)) e Dung e Florea ([DUNG; 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 ([SOLOMAN; FELDER, 1999](#)), os quais apontam as preferências dos estudantes durante o aprendizado e como elas estão relacionadas a cada dimensão do modelo proposto.

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. Além disso, os resultados obtidos nestes experimentos devem ser genéricos e facilmente replicáveis em cursos disponíveis em diferentes softwares de apoio à aprendizagem, apesar dos experimentos conduzidos neste trabalho serem realizados particularmente em dados extraídos do sistema Moodle. Portanto, é fundamental que os padrões de interação entre usuário e sistema considerados neste trabalho sejam comuns para a maioria dos sistemas de gestão do aprendizado. Ou seja, é importante que grande parte dos sistemas educacionais seja capaz de fornecer os dados necessários à tarefa de recomendação de conteúdo, e que os recursos educacionais considerados na pesquisa sejam comumente utilizados pelos docentes.

A partir das premissas citadas, foi selecionado um conjunto dos registros de interação a serem incorporados a esta experimentação: os objetos de aprendizagem referentes à apresentação do material didático, conteúdo introdutório com visões gerais de cada disciplina, materiais

Tabela 4 – Padrões de Comportamento Avaliados.

Categoria	Recursos	Dados Coletados
Materiais Didáticos	Conteúdo Introdutório	Visitas e tempo gasto.
	Livro	Visitas, tempo gasto e navegação;
	Conteúdo Textual	Visitas e tempo gasto
	Conteúdo em Vídeo	Visitas e tempo gasto.
Atividades	Tarefas	Visitas e tempo gasto.
	Exercícios	Visitas e tempo gasto.
Materiais de Apoio	Perguntas Frequentes	Visitas e tempo gasto.
	Ref. Bibliográficas	Visitas e tempo gasto.
	Links Externos	Visitas e tempo gasto.
Interação	Fórum de Discussões	Visitas ao fórum, visitas aos tópicos, criação de tópicos, pesquisas, postagens, média de palavras e tempo gasto.
	Glossário	Visitas, postagens e tempo gasto.
Avaliação	Auto-avaliação	Visitas, tempo gasto e questões respondidas.
	Avaliação do Capítulo	Visitas, tempo gasto e questões respondidas.

de exemplo, vídeos ilustrativos, formulários de auto-avaliação e avaliação de cada capítulo, exercícios, páginas de perguntas frequentes e referências bibliográficas, além dos recursos de comunicação (fórum de discussões e glossário). 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 em cada objeto 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, videoaulas, páginas de perguntas frequentes, referências bibliográficas, e exercícios publicados pelos docentes. Para os formulários de avaliação, onde os estudantes podem avaliar o conhecimento adquirido, foram consideradas informações mais detalhadas: o número de questões respondidas, quantidade de 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. Na Tabela 4, são apresentados os padrões de comportamento investigados nesta proposta.

Figura 13 – Metodologia para a classificação de estilos de aprendizagem.

6.4 Classificação de estilos de aprendizagem

Conforme explorado mais profundamente no capítulo 4, 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 usado 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.

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. Idealmente, o conjunto de teste não deve possuir exemplos em comum com o conjunto de treinamento.

6.4.1 Validação cruzada

A validação cruzada é comumente aplicada em Aprendizado de Máquina para a avaliação da acurácia em modelos de classificação, e tem como objetivo mensurar a capacidade de generalização de um modelo a partir de um conjunto de dados. Esta técnica é amplamente empregada em problemas onde o objetivo da modelagem é a predição, tendo como conceito central o particionamento do conjunto de dados em subconjuntos mutuamente exclusivos, e posteriormente, a utilização de alguns destes subconjuntos para a seleção dos dados de treinamento, enquanto o restante dos subconjuntos são empregados na validação do modelo. Para todos os métodos de particionamento, a precisão final do modelo é obtida pela equação 6.1, onde v representa o número de dados de validação e $\epsilon_{y_i, \hat{y}_i}$ é o resíduo dado pela diferença entre o valor real da saída i e o valor predito. Com isso, é possível inferir de forma quantitativa a capacidade de generalização do modelo.

$$Ac_f = \frac{1}{v} \sum_{i=1}^v \epsilon_{y_i, \hat{y}_i} = \frac{1}{v} \sum_{i=1}^v (y_i - \hat{y}_i) \quad (6.1)$$

O método de validação cruzada denominado *k-fold* consiste em dividir o conjunto total de dados em k subconjuntos mutuamente exclusivos do mesmo tamanho. A partir disto, um subconjunto é utilizado para teste e os $k-1$ restantes são utilizados para estimação dos parâmetros (treinamento); calcula-se, então, a acurácia do modelo tentando-se prever as classes do subconjunto usado como teste. Este processo é realizado k vezes alternando-se de forma circular o subconjunto de teste. Ao final das k iterações calcula-se a acurácia sobre os erros encontrados, por meio da equação descrita anteriormente, obtendo-se assim uma medida confiável sobre a capacidade do modelo de representar o processo gerador dos dados.

6.4.2 Software Weka

Consideradas as etapas do processo de classificação descritas, é fundamental observar que a descoberta de conhecimento em conjuntos de dados requer a experimentação, a análise, e a comparação entre os diversos classificadores encontrados na literatura a fim de se alcançar uma boa acurácia. Para a execução destes experimentos, é necessário o cumprimento de algumas etapas, tais como modelagem do problema, pré-processamento dos dados, execução de algoritmos, e tomada de medições (BATISTA *et al.*, 2003). Em um cenário de aplicação desta técnica para fins científicos, uma alternativa é a utilização de ferramentas de apoio de domínio público, tais como: o MLC++ (KOHAVI; SOMMERFIELD; DOUGHERTY, 1997); Weka (WITTEN; FRANK, 2000); Yale (FISCHER *et al.*, 2002), entre outras. Para fins de experimentação, neste trabalho foi utilizado o pacote de software Weka (*Waikato Environment for Knowledge Analysis*), o qual implementa uma biblioteca de algoritmos de aprendizado na linguagem Java, e fornece diversas funcionalidades para a extração de medidas, seleção de atributos, e análise de resultados. O projeto Weka padroniza as interfaces e produz código uniforme, facilitando a inclusão de novos algoritmos. Ele encontra-se licenciado sob a *General Public License*, sendo, portanto, possível estudar e usar seu código fonte. Nesta ferramenta, são agregados algoritmos provenientes de diferentes abordagens/paradigmas da sub-área da aprendizado de máquina. Além disso, esta ferramenta fornece suporte para a extração de medidas de eficácia dos algoritmos, tais como Precisão, Revocação, F-Measure, curva ROC, e matriz de confusão. Tais funcionalidades foram de grande utilidade para a condução dos experimentos, dado que tornaram prática a extração de resultados e permitiram uma comparação sistemática da qualidade de classificação entre diferentes algoritmos a partir de um mesmo conjunto de dados.

6.4.3 Protocolo de 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 13, 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 6.3 (Tabela 4). 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: 1) com o rótulo

identificado para a dimensão de processamento (ativo ou reflexivo); 2) com o rótulo identificado para a dimensão de captação (visual ou verbal); 3) com o rótulo identificado para a dimensão de organização (sequencial ou global); e 4) com o rótulo identificado para a dimensão de percepção (sensorial ou intuitivo). 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. Tais experimentos possibilitaram a avaliação sistemática de diferentes algoritmos (oriundos de diferentes paradigmas do aprendizado de máquina) aplicados em diferentes dimensões do modelo de Felder-Silverman, o que permite a observação de quais algoritmos podem ser mais apropriados, quais dimensões são mais preditivas, quais padrões de comportamento são relevantes para cada dimensão, entre outras conclusões.

EXPERIMENTOS E RESULTADOS

Os experimentos têm por objetivo demonstrar como diferentes métodos de aprendizado de máquina se comportam na tarefa de classificação de estilos de aprendizagem. A ideia é avaliar diferentes algoritmos aplicados à detecção automática de EA em um cenário real de ensino à distância. Detalhado o processo de construção do conjunto de dados e classificação de estilos de aprendizagem, espera-se apresentar novas evidências e discussões a respeito da eficácia dos classificadores e da modelagem de estudantes para a adaptabilidade de conteúdo em um sistema educacional. Para isso, diversos algoritmos de cada paradigma descrito no Capítulo 4 foram avaliados por meio do software WEKA. Uma análise a respeito da acurácia de cada técnica é detalhada nas seções a seguir. Inicialmente é descrita a etapa de pré-processamento dos dados, imprescindível para a condução dos testes. Em seguida, são explorados os resultados obtidos de acordo com diversas configurações dos dados, com o intuito de identificar qual a metodologia necessária para a obtenção da melhor eficácia. Sendo assim, são descritos os experimentos realizados com classificadores impulsionados por filtros de seleção de atributos e, posteriormente, seleção de exemplos. Para cada uma dessas seções, é apresentada uma discussão a respeito das medidas de desempenho obtidas. Por fim, são apresentadas discussões finais no que se refere ao processo de classificação de estilos de aprendizagem a partir de um paralelo com trabalhos correlatos. Além disso são realizadas considerações finais quanto à efetividade da classificação alcançada e o grau de aplicabilidade em um cenário real de ensino.

7.1 Considerações iniciais

A partir da construção do conjunto de dados, que se deu por meio de consultas SQL realizadas na base de dados do sistema Moodle em produção, foram produzidos arquivos em formato “*.arff*”, que serviram como entrada para o software WEKA. Conforme mencionado anteriormente, a lista de atributos de cada exemplo é composta pelos indicadores do comportamento dos estudantes no sistema Moodle. Como, por exemplo, um contador da quantidade de acessos

daquele aluno a determinado tipo de recurso e o tempo médio gasto em objetos de uma mesma categoria. Para isso, todos os recursos disponíveis no curso foram agrupados em uma única tabela no banco de dados, composta por dois atributos: o código identificador para a modelagem do Moodle, e o rótulo do tipo de recurso de acordo com a Figura 11. Por fim foram incluídos ao conjunto de dados os rótulos obtidos por meio do questionário ILS para cada estudante. Portanto, para a classificação quanto à dimensão de “*processamento*” do FSLSM, foram incluídos todos os atributos extraídos, e por fim a indicação da classe “*ativo*” ou “*reflexivo*”, e assim sucessivamente para as demais dimensões.

Tabela 5 – Algoritmos avaliados para a classificação de EA. Em negrito, os algoritmos com melhor desempenho.

Paradigma Estatístico	Redes Neurais	Baseado em Instâncias	Paradigma Simbólico
Redes Bayesianas; Naive Bayes ; Support Vector Machine.	MultiLayer Perceptron ; Deep Learning.	Classificador kNN ; K-Star.	Hoeffding Tree; J48 ; Random Forest; Random Tree.

Na Tabela 5 são apresentados todos os algoritmos avaliados neste trabalho, provenientes dos diferentes paradigmas descritos no Capítulo 4. 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.

7.2 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. Isso ocorre quando há uma grande desproporção entre o número de exemplos de cada classe, o que faz com que os exemplos da classe minoritária sejam frequentemente classificados incorretamente, além de dificultar a construção de um modelo classificador confiável. 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 de 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 (*AttributeSelection* no WEKA) 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. Os *Wrappers* são bastante populares neste tipo de aplicação, pois calculam uma pontuação para cada subconjunto de atributos na tarefa de classificação. O subconjunto com melhor pontuação torna-se a recomendação do algoritmo. Além disso, os subconjuntos são produzidos via combinação exaustiva ou gulosa.

Em conclusão, conforme ilustrado na Figura 14, 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.

Figura 14 – Metodologia experimental.

7.2.1 Resultados

Naive Bayes

Como observado na Figura 15, o algoritmo *Naive Bayes* alcançou bons resultados para a predição automática de estilos de aprendizagem, especialmente quanto à dimensão de processamento. Neste experimento, o método de seleção de atributos *WrapperSubsetEval* apontou um subconjunto de atributos preditivos para esta tarefa composto por: quantidade de publicações no glossário, visitas aos tópicos do fórum, acessos a conteúdo de livro, acessos às perguntas frequentes, visitas a conteúdo de vídeo e visitas às páginas de tarefas. Na avaliação dos estudantes quanto ao processamento (ativo/reflexivo), o método classificou corretamente 78,5% dos exemplos de entrada, obtendo precisão de 79,4%, revocação de 78,5% e F-Measure correspondente a 78,3%. Estas medidas são consideradas viáveis em um cenário real de modelagem de estudantes por possuir um número de erros relativamente baixo. Para a classificação quanto à captação (visual/verbal), a técnica de aprendizado Bayesiano alcançou 68,7%, 66,3% e 65,1% para precisão, revocação e F-Measure respectivamente. Na dimensão de organização (sequenciais/globais), foi obtido um percentual de 76,3% de precisão, 73,4% de revocação e 72,6% de F-Measure. Por fim, para a dimensão de percepção foram alcançados percentuais de 65,8%, 65,1% e 64,8% para precisão, revocação e F-Measure respectivamente. Apesar de apresentarem resultados inferiores à classificação de estudantes na dimensão ativo/reflexivo, estas últimas tarefas atingiram bons resultados em geral, se equiparados aos trabalhos correlatos.

IBK

O algoritmo *IBk* também alcançou bons resultados para a modelagem automática de estilos de aprendizagem, porém, diferentemente da técnica *Naive Bayes*, neste caso destacam-se os resultados quanto à dimensão de percepção. Neste experimento, o seletor de atributos *WrapperSubsetEval* apontou um subconjunto de atributos preditivos composto por: visitas ao fórum de discussões, quantidade de tópicos criados, publicações no fórum de discussões, acessos a recursos de livro, navegação em objetos em formato de livro e tempo gasto em formulários de auto-avaliação. Na avaliação dos estudantes quanto ao processamento (ativo/reflexivo), o algoritmo baseado em instâncias alcançou precisão de 74,5%, revocação de 72,9% e F-Measure correspondente a 72,4%. Para a classificação quanto à captação (visual/verbal), a técnica *IBk*

Figura 15 – Resultados da classificação com balanceamento de classes e seleção de atributos.

atingiu precisão, revocação e F-Measure de 76,2%. Além disso, na dimensão de organização (sequenciais/globais), foi obtido um percentual de 75% de precisão, 74,4% de revocação e 74,2% de F-Measure. Por fim, na dimensão de percepção (sensoriais/intuitivos), foram alcançados os melhores resultados de classificação com o algoritmo IBk, onde foram obtidos 85,9% de precisão, 84,6% de revocação e 84,4% de F-Measure. Conforme apontado no experimento com aprendizado Bayesiano, estas medidas são consideradas viáveis em um cenário real, visto que a técnica em questão foi capaz de rotular corretamente praticamente todos os exemplos de entrada do conjunto de testes para a dimensão de percepção. Apesar de apresentarem resultados inferiores à classificação na dimensão de processamento, estes experimentos atingiram bons resultados nas demais dimensões, superando o algoritmo *Naive Bayes*.

MultiLayer Perceptron

Já com o algoritmo *MultiLayer Perceptron*, o método de seleção de atributos *WrapperSubsetEval* apontou um subconjunto de atributos preditivos composto por: quantidade de publicações no glossário, quantidade de visitas aos tópicos do fórum, quantidade de buscas realizadas no fórum de discussões, quantidade de acessos a conteúdo de vídeo, média de tempo gasto em conteúdo de vídeo, navegação em livros, média de tempo gasto em exercícios, e tempo gasto em formulários de auto-avaliação. Na avaliação dos estudantes quanto ao processamento (ativo/reflexivo), o algoritmo baseado em redes neurais alcançou precisão de 74,8%, revocação e F-Measure correspondentes a 74,6%. Para a classificação quanto à captação (visual/verbal), a técnica atingiu um percentual de 72,7% de precisão, 71,1% de revocação e 70,5% de F-Measure. Para a dimensão de organização (sequenciais/globais), foi obtido o percentual de 70,1% de precisão, revocação e

F-Measure. Por fim, para a classificação quanto à percepção (sensoriais/intuitivos), o *MultiLayer-Perceptron* obteve 75,1%, 74,5% 74,4% de precisão, revocação e F-Measure respectivamente. Conforme apontado nos experimentos com aprendizado Bayesiano e baseado em instâncias, estas medidas são consideradas viáveis em um cenário real. Porém, apesar de apresentar bons resultados, a técnica de redes neurais não superou os algoritmos *Naive Bayes* e *IBk*.

J48

Por fim, o algoritmo J48 obteve resultados inferiores aos demais avaliados neste experimento, principalmente quanto à dimensão de organização a qual apresentou resultados similares ao de um classificador aleatório, e neste caso, esta classificação não é viável em um ambiente real. Neste experimento, o método de seleção de atributos *WrapperSubsetEval* apontou um subconjunto de atributos preditivos composto por: quantidade de tópicos do fórum criados pelo usuário, quantidade de visitas aos links externos, tempo gasto em conteúdo de livro, quantidade de acessos às tarefas e média de tempo gasto em formulários de auto-avaliação. Na avaliação dos estudantes quanto ao processamento (ativo/reflexivo), o algoritmo baseado em árvores de decisão alcançou precisão e revocação de 67,5% e F-Measure correspondentes a 67,4%. Para a classificação quanto à captação (visual/verbal), a técnica atingiu um percentual de 70% de precisão, 69,9% de revocação e 69,8% de F-Measure. Para a dimensão de organização (sequenciais/globais), foi obtido o percentual de 53,7% de precisão, revocação e F-Measure. Por fim, para a classificação quanto à percepção (sensoriais/intuitivos), a árvore de decisão obteve 78,8%, 78,7% 78,6% de precisão, revocação e F-Measure respectivamente. Avalia-se que o algoritmo J48 atingiu um bom resultado especialmente quanto à dimensão de percepção, porém, em contra-partida, esta técnica foi inferior às demais avaliadas, principalmente quanto à classificação da dimensão de organização.

7.2.2 Discussão

Na Figura 16, 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. Em comparação com outros trabalhos, pôde-se notar que os métodos investigados, aprimorados com pré-processamento, superaram alguns dos trabalhos correlatos mais recentes (comparações com trabalhos correlatos serão discutidas na seção 7.4). Sendo

assim, assume-se que os resultados obtidos nesta fase de experimentos atingiram percentuais de precisão viáveis para um cenário real de adaptatividade em ambientes educacionais, e que o filtro de atributos mostra-se uma tarefa fundamental para este processo.

Figura 16 – Análise comparativa da precisão dos classificadores.

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. Além disso, conclui-se que uma árvore de decisão é a técnica menos indicada para esta aplicação.

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. Além disso, destacam-se os padrões de comportamento relacionados ao tempo gasto em formulários de auto-avaliação, acessos a conteúdo de vídeo e navegação em materiais em formato de livro, os quais também foram bastante selecionados pelo *WrapperSubsetEval*.

Por fim, 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, seguida das dimensões de processamento, captação e organização. 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. Portanto, a avaliação e compreensão da previsibilidade de classificação de cada uma das dimensões é tema para futuros trabalhos.

7.3 Refinamento dos resultados com filtro de exemplos

Conforme destacado anteriormente, o modelo de Felder-Silverman oferece um conjunto de vantagens em sua aplicação para a adaptatividade de conteúdo em sistemas educacionais. Uma delas, é a possibilidade de aplicação do questionário ILS, que além de tornar prática a tarefa de identificação de EA, permite determinar a preferência dos estudantes por meio de escalas de valores, que variam entre -11 e 11. Isso possibilita uma avaliação mais detalhada do quanto um indivíduo está inclinado para certo estilo, visto que a maioria dos demais modelos apenas indica a qual estilo o aluno pertence. Deste modo, um sistema educacional adaptativo pode diferenciar seu comportamento de acordo com o quanto o estudante está alinhado a um estilo. Além disso, assume-se que essa diferenciação pode trazer resultados mais precisos em um contexto de personalização do ensino.

De acordo com Felder e Silverman ([FELDER; SILVERMAN, 1988](#)), um estudante que responde ao questionário ILS e obtém pontuação entre -3 e 3 para determinada dimensão do modelo FSLSM, pode ser considerado neutro em relação a este estilo. Os autores explicam que há casos em que o aluno não está necessariamente adequado por completo a um polo daquela dimensão, e portanto, apresenta comportamento balanceado entre os dois polos. Em certos casos, considera-se que um ensino personalizado com base em EA pode não ser proveitoso para estudantes que se encaixem nessa classe. Para isso, alguns trabalhos presentes na literatura exploram a identificação automática de EA considerando somente indivíduos fortemente inclinados a um estilo de aprendizagem, ou seja, com pontuação abaixo de -3 ou acima de 3 para a dimensão avaliada. Em alguns casos, alunos com EA neutro em uma dimensão são removidos do conjunto de entrada para a classificação, e em outros, a classe “neutro” é adicionada aos rótulos possíveis, com o intuito de levar em conta indivíduos com este perfil.

Sendo assim, uma hipótese levantada por este e por outros trabalhos é a de que quanto mais fortemente inclinado a determinado estilo de aprendizagem é o aluno, mais precisa deve ser sua predição, visto que idealmente, nestas condições, este estudante apresenta comportamento

Figura 17 – Metodologia para extração dos resultados com seleção de exemplos.

mais alinhado com seu EA. Portanto, para uma segunda etapa de avaliação neste trabalho, foi proposta uma abordagem de refinamento dos exemplos que compõem o conjunto de dados de entrada para classificação. Este pré-processamento pode ser entendido como um filtro dos estudantes que participam do experimento, onde serão considerados somente indivíduos fortemente alinhados ao estilo de aprendizagem. Tal abordagem tem como intuito investigar o comportamento dos algoritmos nestas condições, além de buscar evidências de que padrões de comportamento em sistemas educacionais podem efetivamente ser aplicados para a modelagem automática e dinâmica de estudantes. Espera-se portanto, que os resultados alcançados nesta nova etapa superem os primeiros índices de desempenho obtidos.

Sendo assim, o objetivo nesta experimentação foi investigar qual o impacto dos estudantes com perfil de aprendizagem neutro em uma classificação. Ou seja, o quanto esta característica influencia a predição de EA, e de alguma maneira reforçar a existência de graus de inclinação para determinado estilo. Tal experimentação baseia-se na hipótese de que, se a classificação obtém melhores resultados quando são considerados somente os estudantes fortemente inclinados a um estilo, isso indica que os estudantes neutros influenciam negativamente uma classificação binária.

Desse modo, conforme ilustrado na Figura 17, 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) seleção dos exemplos (estudantes) com índice de alinhamento acima de 3 ou abaixo de -3 para o estilo de aprendizagem; 3) filtro das instâncias com *ClassBalancer*; 4) seleção de atributos com *WrapperSubsetEval*; 5) execução do algoritmo em validação cruzada de 10 execuções (*10-fold cross validation*); e 6) extração das medidas de Precisão, Revocação (Recall) e F-measure de cada uma das técnicas de aprendizado de máquina avaliadas.

7.3.1 Resultados

Naive Bayes

Como observado na Figura 18, o algoritmo *Naive Bayes* combinado com refinamento de instâncias alcançou resultados viáveis para a aplicação em um cenário real de modelagem de estudantes, especificamente para as dimensões de processamento e organização. Na avaliação dos estudantes

Figura 18 – Resultados da classificação com filtro de exemplos.

quanto ao processamento (ativo/reflexivo), o método obteve precisão de 78,4%, revocação de 78,1% e F-Measure correspondente a 78,0. E para a organização (sequenciais/globais), foi obtido um percentual de 73,4% de precisão, 69,5% de revocação e 68,2 de F-Measure. Já para a classificação quanto à dimensão de captação (visual/verbal), a classificador Bayesiano alcançou 71,7%, 69,0% e 68,0 para precisão, revocação e F-Measure respectivamente. Por fim, para a dimensão de percepção foram alcançados percentuais de 68,1%, 67,7% e 67,5 para precisão, revocação e F-Measure respectivamente. Entretanto, assume-se que para esta técnica a abordagem não atingiu progressão significativa quando comparada à primeira avaliação experimental, o que neste caso, não evidencia uma diferença de eficácia da classificação para estudantes fortemente inclinados a um estilo.

IBk

Em contrapartida, na avaliação do algoritmo *IBk* (ou classificador kNN), nota-se que o filtro de instâncias influenciou positivamente nas medidas de desempenho, inclusive para a dimensão de percepção, que já havia apresentado resultados satisfatórios anteriormente. Na classificação dos estudantes quanto ao processamento (ativo/reflexivo), o algoritmo baseado em instâncias alcançou precisão de 82,2%, revocação de 79,9% e F-Measure correspondente a 79,6. Para a classificação quanto à captação (visual/verbal), o classificador baseado em instâncias atingiu precisão de 84,0%, revocação e F-Measure de 83,9%. Além disso, na dimensão de organização (sequenciais/globais), foi obtido um percentual de 78,3% de precisão e 78,2% de revocação e F-Measure. Por fim, na dimensão de percepção (sensoriais/intuitivos), foram alcançados os melhores resultados de classificação com o algoritmo IBk, onde foram obtidos 89,8% de precisão,

88,6% de revocação e 88,5% de F-Measure. Portanto, neste caso, conclui-se que a seleção dos estudantes fortemente alinhados com determinado EA resulta em uma modelagem de perfis mais eficaz.

MultiLayer Perceptron

O algoritmo *MultiLayer Perceptron* também apresentou progressão satisfatória quando combinado com refinamento de instâncias, obtendo medidas de desempenho semelhantes às obtidas pelo classificador kNN. Para a avaliação dos estudantes quanto ao processamento (ativo/reflexivo), o algoritmo baseado em redes neurais alcançou precisão, revocação e F-Measure correspondentes a 76,5%. Para a classificação quanto à captação (visual/verbal), a técnica atingiu um percentual de 66,8% de precisão, 66,5% de revocação e 66,5% de F-Measure. Para a dimensão de organização (sequenciais/globais), foi obtido o percentual de 83,7% de precisão, revocação e F-Measure. Por fim, para a classificação quanto à percepção (sensoriais/intuitivos), o *MultiLayer Perceptron* obteve 85,6% de precisão, e 85,6% para revocação e F-Measure. Conforme apontado nos experimentos com aprendizado Bayesiano e baseado em instâncias, estas medidas são consideradas viáveis em um cenário real. Além disso, apesar de uma decadência dos resultados quanto à dimensão de captação, destaca-se a melhoria da eficácia para a predição quanto à organização e percepção.

J48

Por fim, a árvore de decisão J48 combinada com filtro de exemplos também alcançou melhoria considerável em relação à primeira abordagem. A técnica, que inicialmente havia apresentado resultados não viáveis para um cenário real, obteve bons indicadores de desempenho, principalmente para as dimensões de captação e percepção. Na avaliação dos estudantes quanto ao processamento (ativo/reflexivo), o algoritmo baseado em árvores de decisão alcançou precisão de 73,6%, revocação de 73,2% e F-Measure correspondentes a 73,1%. Para a classificação quanto à captação (visual/verbal), a técnica atingiu um percentual de 84,6% de precisão, 83,2% de revocação e 83,0% de F-Measure. Para a dimensão de organização (sequenciais/globais), foram obtidos percentuais de 71,3% de precisão, revocação e F-Measure. Por fim, para a classificação quanto à percepção (sensoriais/intuitivos), a árvore de decisão obteve 85,6%, 85,2% e 85,2% de precisão, revocação e F-Measure respectivamente. Sendo assim, entende-se que a árvore de decisão pode ser aplicada com sucesso em um cenário de modelagem automática de estudantes, se combinada a uma seleção dos estudantes mais fortemente alinhados ao Estilo de Aprendizagem.

7.3.2 Discussão

Os experimentos executados nesta etapa do trabalho têm por objetivo uma investigação aprofundada quanto à efetividade da modelagem de EA com base em padrões de comportamento. Por hipótese, quanto mais fortemente inclinado a determinado estilo de aprendizagem é o aluno, mais precisa deve ser sua classificação, visto que idealmente, este estudante apresenta comportamento mais alinhado com seu EA. Na Figura 19 são apresentadas as medidas

de precisão dos algoritmos avaliados nesta tarefa; os resultados foram coletados a partir das mesmas configurações do primeiro experimento, passando pelo mesmo pré-processamento, porém considerando somente os estudantes que obtiveram pontuação maior do que 3, e menor do que -3 para cada dimensão do FSLSM. Os resultados apontam para precisões máximas de 82,2% (kNN), 84,6% (árvore J48), 83,7% (*MultiLayer Perceptron*) e 89,8% (kNN) para as dimensões de processamento, captação, organização e percepção respectivamente. Conforme pode-se observar, a proposta resultou em um progresso significativo quanto às medidas de desempenho apresentadas pelos primeiros experimentos, que alcançaram 79,4%, 76,2%, 76,3% e 85,9% de precisão para as mesmas tarefas. Desta maneira, supõe-se que a modelagem automática e dinâmica de estudantes baseada em padrões de comportamento tende a produzir maior eficácia para estudantes fortemente inclinados a um estilo de aprendizagem. Além disso, a melhoria de resultados reforça a hipótese de que os padrões de comportamento dos alunos em sistemas educacionais são efetivos e significativos para a identificação de Estilos de Aprendizagem.

Figura 19 – Análise comparativa da precisão dos classificadores com refinamento de exemplos.

Quanto ao desempenho de cada técnica avaliada, os experimentos demonstraram que o aprendizado baseado em instâncias (classificador kNN) alcançou a melhor acurácia nas dimensões de processamento, captação e percepção, enquanto a rede neural *MultiLayer Perceptron* atingiu a melhor precisão para a organização. Além disso, a árvore de decisão J48 apresentou a melhoria mais significativa em relação ao primeiro experimento, igualando-se inclusive ao kNN como melhor resultado para a dimensão de captação. Novamente, o classificador kNN obteve a melhor média de precisão somando-se os resultados nas quatro dimensões do modelo de Felder-Silverman, desta vez com média de 83,6%. Portanto, em caso de escolha da melhor técnica para classificação de EA neste estudo de caso, o aprendizado baseado em instâncias demonstra-se o mais eficaz, pois por si só, alcançou resultados satisfatórios para a modelagem automática em todas as dimensões do modelo de Felder-Silverman. Entretanto, as demais técnicas também

atingiram medidas de precisão viáveis nas maioria das dimensões. Além disso, destaca-se que o aprendizado Bayesiano não demonstrou progressão significativa quando comparado à primeira avaliação experimental, e obteve a pior média de precisão quando considerado o filtro de alunos.

Por fim, no que se refere às dimensões do modelo Felder-Silverman, os resultados demonstraram que novamente a dimensão de percepção foi a mais suscetível aos métodos de classificação, atingindo mais de 89% de precisão em sua predição com o classificador kNN, e mais de 85% com o *MultiLayer Perceptron* e com a árvore de decisão J48. Conforme descrito anteriormente, tais informações podem ser relevantes para trabalhos futuros, pois abrem margem para a investigação de quais características do curso levaram ao sucesso da predição em determinada dimensão. Para um trabalho futuro, há a possibilidade de se investigar por exemplo, quais componentes do curso avaliado neste estudo de caso colaboraram para a classificação acertada dos estudantes quanto à percepção, a partir de paralelos entre as preferências de alunos sensoriais e intuitivos com as propriedades do curso de reabilitação auditiva, bem como, do ambiente virtual de ensino.

7.4 Discussões finais

Dado que este capítulo tem por objetivo demonstrar como diferentes técnicas de aprendizado de máquina se comportam para a classificação de estilos de aprendizagem, de maneira geral, considera-se que a avaliação experimental deste trabalho foi satisfatória. Os experimentos permitiram a validação da metodologia proposta, bem como do estudo de caso avaliado. 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 6, os percentuais apresentados nesta proposta superam os trabalhos mais clássicos que exploram detecção automática de estilos de aprendizagem, como o de Cha *et al.* (CHA *et al.*, 2006), García *et al.* (GARCÍA *et al.*, 2007), Graf *et al.* (GRAF; LIU *et al.*, 2009), e Dung e Florea (DUNG; FLOREA, 2012). Além disso, a precisão obtida pelo segundo experimento encontra-se equiparada aos trabalhos mais recentes ((LIYANAGE *et al.*, 2014) e (ABDULLAH, 2015)), o que sustenta a efetividade da avaliação experimental conduzida.

No entanto, uma análise comparativa dos índices de precisão alcançados pelos demais trabalhos não reflete necessariamente uma superioridade ou inferioridade da atual proposta, visto

Tabela 6 – Comparação da precisão com trabalhos correlatos.

	Processamento	Captação	Organização	Percepção
Cha <i>et al.</i> (CHA <i>et al.</i> , 2006)	66,7%	85,7%	71,4%	77,8%
García <i>et al.</i> (GARCÍA <i>et al.</i> , 2007)	58,0%	—	63,0%	77,0%
Graf <i>et al.</i> (GRAF; LIU <i>et al.</i> , 2009)	79,3%	76,7%	73,3%	77,3%
Dung e Florea (DUNG; FLOREA, 2012)	72,7%	79,5%	65,9%	70,1%
Liyanage <i>et al.</i> (LIYANAGE <i>et al.</i> , 2014)	65,0%	76,2%	77,5%	75,0%
Abdullah <i>et al.</i> (ABDULLAH, 2015)	90,0%	76,0%	70,0%	85,0%
Primeiro Experimento	79,4%	76,2%	76,3%	85,9%
Segundo Experimento	82,2%	84,6%	83,7%	89,8%

que cada trabalho foi conduzido em estudos de caso diferentes, com estudantes, recursos e propriedades de curso diferentes. Além disso, outra questão está relacionada a como avaliar e comparar os resultados apresentados, de modo que existem diferenças quanto ao tamanho da população, discretização das dimensões do estilo de aprendizagem e métricas relatadas. Por exemplo, Felder (SOLOMAN; FELDER, 1999) propõe discretizar as preferências de aprendizagem em 3 intervalos: forte preferência por um estilo em um pólo da dimensão, preferência moderada ou neutra, e forte preferência por um estilo no outro pólo da dimensão. Porém, nem todos os trabalhos utilizam a mesma regra, sendo que em alguns casos os estudantes com preferência neutra são ignorados na amostragem, e em outros, estes estudantes são sempre classificados em um dos pólos (mesmo com uma fraca inclinação a tal estilo). Tais problemas são apontados por Truong (TRUONG, 2016) e Feldman (FELDMAN; MONTESERIN; AMANDI, 2015) como questões em aberto para a área da modelagem de estudantes segundo estilos de aprendizagem. Portanto, a análise comparativa apresentada em relação aos trabalhos presentes na literatura tem por objetivo situar os atuais percentuais de precisão em relação ao estado da arte, pois não há, nesse caso, como constatar uma 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, seleção de atributos e filtro de estudantes fortemente identificados com o EA 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. Tal evidência indica que um alto grau de utilização dos alunos por este meio de comunicação pode ser benéfico para o processo de modelagem de perfis e adaptatividade de conteúdo.

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, a dimensão de percepção do modelo de Felder e Silverman mostrou-se a mais previsível em ambos os experimentos, o que abre caminho para uma investigação mais detalhada de quais fatores influenciaram os bons resultados obtidos para essa dimensão.

CONCLUSÕES

O objetivo desta pesquisa de mestrado foi investigar a aplicação de técnicas de aprendizado de máquina para a modelagem automática de estilos de aprendizagem dos estudantes em um ambiente virtual de ensino. Enquanto os Sistemas de Gerenciamento do Aprendizado convencionais se concentram em apoiar os professores na criação, administração e gerenciamento de cursos online, esses sistemas fornecem pouca ou, na maioria dos casos, nenhuma personalização de conteúdo para os alunos. Em vista disso, sistemas adaptativos têm a proposta de solucionar tal problema, promovendo uma experiência individual para cada usuário com base em suas preferências, conhecimentos prévios, motivações, níveis de conhecimento, e também estilos de aprendizagem. Conforme mencionado anteriormente, este trabalho concentra-se na estratégia de fornecer adaptatividade de conteúdo a partir dos estilos de aprendizagem, e para isso, os EA dos alunos precisam ser conhecidos primeiro.

Conforme apontado por diversos estudos, em tais abordagens a detecção automática de estilos de aprendizagem tem várias vantagens sobre o uso de questionários. Primeiro, porque neste caso os alunos não têm nenhum esforço adicional e só precisam interagir com o sistema para aprender. Em segundo lugar, a abordagem é livre da incerteza gerada ao questionar os alunos sobre suas próprias preferências. Em terceiro lugar, a abordagem tem potencial para ser menos propensa a erros, uma vez que usa dados de um período de tempo em vez de um momento específico. Ou seja, é uma classificação dinâmica e pode ser atualizada constantemente ao passo em que o estudante interage com o sistema, ao contrário de um questionário que resulta em uma classificação estática. Além disso, uma classificação dos indivíduos quanto aos seus EA não auxilia os professores somente para uma recomendação personalizada de conteúdo, mas também para uma conscientização dos alunos quanto às suas próprias características. Desse modo, os estudantes podem compreender melhor suas preferências de aprendizagem, o que motiva os professores a ampliarem suas estratégias ou materiais de ensino, se eles não suportarem diferentes estilos de aprendizagem. Adicionalmente, tal informação permite ao estudante avaliar suas próprias limitações, abrindo caminho para o desenvolvimento de seus pontos fracos.

O presente trabalho teve seu início a partir de uma revisão da literatura, com o intuito de levantar um referencial teórico para a pesquisa a ser conduzida. Esta etapa foi fundamental para compreender de que maneira é realizado o processo de modelagem de usuários em ambientes online, além de revisar quais os métodos comumente aplicados para se recomendar objetos de aprendizagem personalizados para estudantes em cursos oferecidos por meio de sistemas educacionais. Sendo assim, esta tarefa foi fundamental para a condução da pesquisa, visto que permitiu a observação de lacunas que podem ser exploradas quanto ao tema, e também a aquisição de conhecimento de metodologias similares que guiaram o desenvolvimento do estudo proposto. Posteriormente, o trabalho passou por uma revisão dos modelos de estilos de aprendizagem propostos na literatura, que serviram como base para uma avaliação de qual seria a melhor abordagem a ser aplicada. Dentre as diversas propostas, foi selecionado o modelo de Felder e Silverman (FSLSM) por um conjunto de razões. Inicialmente, pelo fato de os autores agruparam em um único modelo importantes descobertas de outros estudos da área. Além disso, pela praticidade para se identificar o estilo de um estudante, devido ao questionário ILS, e do fato deste modelo ser um dos mais adotados em trabalhos de modelagem automática de estudantes, sendo incorporado a diversos sistemas educacionais adaptativos, demonstrando bons resultados quanto à classificação de perfis e recomendação de conteúdo.

Em seguida, foi realizado um estudo a respeito das técnicas de aprendizado de máquina e seus paradigmas. Esta etapa do trabalho foi de fundamental importância para os resultados, pois foram compreendidas as possibilidades para se aplicar os algoritmos durante a experimentação, bem como os pré-processamentos capazes de aprimorar a acurácia em uma tarefa de classificação. No entanto, após a revisão da literatura para construção do referencial teórico, do estudo da teoria dos estilos de aprendizagem e das técnicas de aprendizado de máquina, deu-se início a etapa mais desafiadora do trabalho: a definição da metodologia e execução do estudo de caso. Para a realização da pesquisa, foi avaliado um curso de pós-graduação na área de Fonoaudiologia.

O curso em questão foi ministrado integralmente com auxílio do sistema Moodle, com duração de 18 meses, e contou com 105 alunos matriculados, oriundos de diversas localidades do Brasil. Uma vez iniciado o curso, foram rotulados todos os recursos educacionais disponíveis com o intuito de criar metadados para a observação dos algoritmos. Feito isso, foram definidos os padrões de comportamento dos estudantes a serem avaliados, com base em propostas de trabalhos correlatos. Por fim, extraídos os dados da base do Moodle, foram definidos o protocolo de experimentação, as ferramentas a serem aplicadas para a coleta de resultados, e a metodologia de experimentação, que passou por filtros de seleção de atributos e balanceamento de classes. Sendo assim, a análise experimental definida foi a coleta dos índices de precisão, revocação e F-Measure dos algoritmos de cada paradigma a partir de uma validação cruzada de 10 execuções.

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 métodos foram usados para predizer o perfil de aprendizado, segundo o modelo de Felder-Silverman, dos alunos de um curso de fonoaudiologia, em total de 105 alunos. O processo de classificação contou com uma etapa de balanceamento das classes seguida de uma etapa de seleção de atributos. 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 para a configuração de dados e padrões de comportamento avaliados neste trabalho, a dimensão de percepção do modelo Felder-Silverman foi a mais preditiva em relação às demais. Além disso, pode-se concluir que a seleção de atributos e o rebalanceamento das classes impactou significativamente o desempenho da predição. Também nota-se 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 contribuição para o estado da arte, derivou do programa de mestrado o artigo intitulado “Métodos de classificação aplicados à detecção automática de Estilos de Aprendizagem em um ambiente real de ensino”, publicado nos anais do XXVIII Simpósio Brasileiro de Informática na Educação (SBIE), em 2017 (FERREIRA *et al.*, 2017). Além disso, até o momento da entrega da versão final desta dissertação de mestrado, o artigo intitulado “*A comparative analysis of the automatic modeling of Learning Styles through Machine Learning techniques*” foi aceito com revisões no congresso *Frontiers in Education* (FIE) 2018. Além disso, foi submetido um capítulo de livro intitulado “Detecção automática de estilos de aprendizagem: uma análise comparativa de classificadores aplicados em um cenário real de aprendizado” para a edição do livro “Impactos das Tecnologias na educação”, de 2018.

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, M. A. 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. Citado nas páginas 72, 105 e 106.
- AHA, D. W.; KIBLER, D.; ALBERT, M. K. Instance-based learning algorithms. **Machine learning**, Springer, v. 6, n. 1, p. 37–66, 1991. Citado na página 62.
- AKBULUT, Y.; CARDAK, C. S. Adaptive educational hypermedia accommodating learning styles: A content analysis of publications from 2000 to 2011. **Computers & Education**, Elsevier, v. 58, n. 2, p. 835–842, 2012. Citado na página 23.
- ALIAS, N. A.; ZAINUDDIN, A. M. Innovation for better teaching and learning: Adopting the learning management system. **Malaysian online journal of instructional technology**, v. 2, n. 2, p. 27–40, 2005. Citado na página 30.
- ALMEIDA, K. R. d. Descrição e análise de diferentes estilos de aprendizagem. **Revista Interlocução**, v. 3, n. 3, 2010. Citado na página 44.
- ALMEIDA, R.; CAMPOS, F.; DAVID, J.; STROELE, V. Sistemas de recomendação de recursos educacionais para grupos de redes sociais: um mapeamento sistemático. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2015. v. 26, n. 1, p. 1022. Citado na página 79.
- ALMEIDA, R.; PEREIRA, C. K.; CAMPOS, F.; STROELE, V. Recomendação de recursos educacionais para grupos: buscando soluções em redes sociais. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2016. v. 27, n. 1, p. 996. Citado na página 78.
- AUDINO, D. F.; NASCIMENTO, R. da S. Objetos de aprendizagem–diálogos entre conceitos e uma nova proposição aplicada à educação. **Revista Contemporânea de Educação**, v. 5, n. 10, 2012. Citado na página 31.
- BATISTA, G. E. d. A. P. *et al.* **Pré-processamento de dados em aprendizado de máquina supervisionado**. Tese (Doutorado) — Universidade de São Paulo, 2003. Citado nas páginas 55, 57 e 91.
- BIERMANN, A. W.; RAMM, D. **Great ideas in computer science with Java**. [S.l.]: MIT Press, 2002. Citado na página 70.
- BLACKBOARD. **Blackboard: Education, technology & services**. 2017. Disponível em: <<http://www.blackboard.com/>>. Acesso em: 08/10/2017. Citado nas páginas 23 e 29.
- BLOOM, B. S. The 2 sigma problem: The search for methods of group instruction as effective as one-to-one tutoring. **Educational researcher**, Sage Publications Sage CA: Thousand Oaks, CA, v. 13, n. 6, p. 4–16, 1984. Citado na página 36.

- BRAGA, A. de P.; FERREIRA, A. C. P. de L.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. [S.l.]: LTC Editora, 2007. Citado na página 64.
- BREIMAN, L.; FRIEDMAN, J.; STONE, C. J.; OLSHEN, R. A. **Classification and regression trees**. [S.l.]: CRC press, 1984. Citado nas páginas 60 e 61.
- CARRO, R. M.; PULIDO, E.; RODRIGUEZ, P. Tangow: a model for internet-based learning. **International Journal of Continuing Engineering Education and Life Long Learning**, Inderscience Publishers, v. 11, n. 1-2, p. 25–34, 2001. Citado na página 75.
- CARVALHO, V. C. de; DORÇA, F. A.; CATTELAN, R. G.; ARAÚJO, R. D. Uma abordagem para recomendação automática e dinâmica de objetos de aprendizagem baseada em estilos de aprendizagem. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2014. v. 25, n. 1, p. 1188. Citado nas páginas 25 e 71.
- CAZELLA, S. C.; NUNES, M.; REATEGUI, E. A ciência da opinião: Estado da arte em sistemas de recomendação. **André Ponce de Leon F. de Carvalho; Tomasz Kowaltowski..(Org.). Jornada de Atualização de Informática-JAI**, p. 161–216, 2010. Citado na página 31.
- CHA, H. J.; KIM, Y. S.; PARK, S. H.; YOON, T. B.; JUNG, Y. M.; LEE, J.-H. Learning styles diagnosis based on user interface behaviors for the customization of learning interfaces in an intelligent tutoring system. In: SPRINGER. **International Conference on Intelligent Tutoring Systems**. [S.l.], 2006. p. 513–524. Citado nas páginas 68, 105 e 106.
- CHRYSAFIADI, K.; VIRVOU, M. Student modeling approaches: A literature review for the last decade. **Expert Systems with Applications**, Elsevier, v. 40, n. 11, p. 4715–4729, 2013. Citado na página 35.
- CIACCIA, P.; PATELLA, M.; ZEZULA, P. Deis-csite-cnr. In: **Proceedings of the international conference on very large data bases**. [S.l.: s.n.], 1997. v. 23, p. 426–435. Citado na página 63.
- CLARK, P.; BOSWELL, R. Rule induction with cn2: Some recent improvements. In: SPRINGER. **European Working Session on Learning**. [S.l.], 1991. p. 151–163. Citado na página 60.
- CLARK, P.; NIBLETT, T. The cn2 induction algorithm. **Machine learning**, Springer, v. 3, n. 4, p. 261–283, 1989. Citado na página 60.
- CLARK, R. C.; MAYER, R. E. **E-learning and the science of instruction: Proven guidelines for consumers and designers of multimedia learning**. [S.l.]: John Wiley & Sons, 2016. Citado nas páginas 15 e 30.
- COFFIELD, F.; MOSELEY, D.; HALL, E.; ECCLESTONE, K. *et al.* **Learning styles and pedagogy in post-16 learning: A systematic and critical review**. [S.l.]: Learning and Skills Research Centre London, 2004. Citado na página 40.
- COFFIELD, F.; MOSELEY, D.; HALL, E.; ECCLESTONE, K. **Should we be using learning styles? What research has to say to practice**. [S.l.]: London: Learning and skills research centre, 2004. Citado na página 40.
- CONDE, M. Á.; GARCÍA-PEÑALVO, F. J.; RODRÍGUEZ-CONDE, M. J.; ALIER, M.; CASANY, M. J.; PIGUILLEM, J. An evolving learning management system for new educational environments using 2.0 tools. **Interactive Learning Environments**, Taylor & Francis, v. 22, n. 2, p. 188–204, 2014. Citado na página 31.

DORÇA, F. A.; LIMA, L. V.; FERNANDES, M. A.; LOPES, C. R. 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. Citado nas páginas 25 e 70.

DORCA, F. A.; LIMA, L. V.; FERNANDES, M. A.; LOPES, C. R. Consistent evolution of student models by automatic detection of learning styles. **IEEE Latin America Transactions**, IEEE, v. 10, n. 5, p. 2150–2161, 2012. Citado nas páginas 24, 70, 71 e 73.

DORÇA, F. A.; LIMA, L. V.; FERNANDES, M. A.; LOPES, C. R. A new approach to discover students learning styles in adaptive educational systems. **Brazilian Journal of Computers in Education**, v. 21, n. 01, p. 76, 2013. Citado na página 70.

_____. Simulaç ao de aprendizagem em estudantes como ferramenta para minimizaç ao de custos na avaliaç ao de novas abordagens em sistemas adaptativos e inteligentes para educaç ao a distância: Uma análise experimental. In: **In: XXXIII Congresso da Sociedade Brasileira de Computaç ao (CSBC'2013). II Desafie**. [S.l.: s.n.], 2013. Citado na página 70.

DORÇA, F. A. *et al.* Uma abordagem estocástica baseada em aprendizagem por reforço para modelagem automática e dinâmica de estilos de aprendizagem de estudantes em sistemas adaptativos e inteligentes para educação a distância. Universidade Federal de Uberlândia, 2012. Citado nas páginas 25 e 34.

DUNG, P. Q.; FLOREA, A. M. An approach for detecting learning styles in learning management systems based on learners' behaviours. In: **International Conference on Education and Management Innovation**. [S.l.: s.n.], 2012. v. 30, p. 171–177. Citado nas páginas 24, 25, 35, 71, 81, 86, 87, 105 e 106.

DUNN, R.; DUNN, K. Learning style as a criterion for placement in alternative programs. **The Phi Delta Kappan**, JSTOR, v. 56, n. 4, p. 275–278, 1974. Citado na página 74.

DUNN, R.; GRIGGS, S. The dunn and dunn learning style model and its theoretical cornerstone. **Synthesis of the Dunn and Dunn Learning-Style Model Research Who, what, when, where, and so what**, p. 1–6, 2003. Citado na página 74.

DUNN, R. S.; DUNN, K. J.; PRICE, G. E. **Learning style inventory**. [S.l.]: Price Systems New York, Lawrence, KS, 1981. Citado na página 74.

ENTWISTLE, N. J. Improving teaching through research on student learning. **University teaching: International perspectives**, Garland New York, p. 73–112, 1998. Citado na página 43.

FELDER, R. M. Matters of style. **ASEE prism**, USA, v. 6, n. 4, p. 18–23, 1996. Citado nas páginas 23 e 39.

FELDER, R. M.; SILVERMAN, L. K. Learning and teaching styles in engineering education. **Engineering education**, v. 78, n. 7, p. 674–681, 1988. Citado nas páginas 26, 39, 48, 50 e 100.

FELDMAN, J.; MONTESERIN, A.; AMANDI, A. Automatic detection of learning styles: state of the art. **Artificial Intelligence Review**, Springer, v. 44, n. 2, p. 157–186, 2015. Citado nas páginas 51, 80 e 106.

- FERREIRA, L.; GAZZOLA, M.; FERRARI, D.; ZUPELARI, M.; PAIVA, P.; JR, J. R. Métodos de classificação aplicados à detecção automática de estilos de aprendizagem em um ambiente real de ensino. **XXVIII Simpósio Brasileiro de Informática na Educação**, Recife, 2017. Citado na página [111](#).
- FERREIRA, V. H.; RAABE, A. L. A. Lorsys: Um sistema de recomendação de objetos de aprendizagem scorm para o moodle. **XX Simpósio Brasileiro de Informática na Educação**, 2009. Citado na página [75](#).
- FERRO, M. R. d. C. *et al.* Modelo de sistema de recomendação de materiais didáticos para ambientes virtuais de aprendizagem. Universidade Federal de Alagoas, 2010. Citado na página [77](#).
- FISCHER, S.; KLINKENBERG, R.; MIERSWA, I.; RITTHOFF, O. Yale: Yet another learning environment–tutorial. **Colloborative Research Center**, v. 531, 2002. Citado na página [91](#).
- FORD, N. Learning styles and strategies of postgraduate students. **British Journal of Educational Technology**, Wiley Online Library, v. 16, n. 1, p. 65–77, 1985. Citado na página [43](#).
- FRIEDMAN, N.; GEIGER, D.; GOLDSZMIDT, M. Bayesian network classifiers. **Machine learning**, Springer, v. 29, n. 2-3, p. 131–163, 1997. Citado na página [62](#).
- FÜRNKRANZ, J. Separate-and-conquer rule learning. **Artificial Intelligence Review**, Springer, v. 13, n. 1, p. 3–54, 1999. Citado na página [61](#).
- GARCÍA, P.; AMANDI, A.; SCHIAFFINO, S.; CAMPO, M. Using bayesian networks to detect students’ learning styles in a web-based education system. **Proc of ASAI, Rosario**, p. 115–126, 2005. Citado na página [68](#).
- _____. Evaluating bayesian networks’ precision for detecting students’ learning styles. **Computers & Education**, Elsevier, v. 49, n. 3, p. 794–808, 2007. Citado nas páginas [24](#), [25](#), [35](#), [68](#), [69](#), [81](#), [86](#), [87](#), [105](#) e [106](#).
- GOLDBERG, D. E. Genetic algorithms in search, optimization, and machine learning, 1989. **Reading: Addison-Wesley**, 1989. Citado na página [70](#).
- GOMES, A. S.; CARVALHO, R.; FILHO, I. M.; ROLIM, A.; MONTEIRO, B.; OLIVEIRA, G. Amadeus: novo modelo de sistema de gestão de aprendizagem. **Revista Brasileira de Aprendizagem Aberta e a Distância**, v. 8, p. 1–15, 2009. Citado nas páginas [23](#) e [31](#).
- GONÇALVES, A. V.; VIVAS, A.; ASSIS, L.; PITANGUI, C.; DORÇA, F. Avanços na modelagem automática e dinâmica de estilos de aprendizagem de estudantes em sistemas adaptativos e inteligentes para educação: uma análise experimental. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2016. v. 27, n. 1, p. 1006. Citado nas páginas [25](#) e [73](#).
- GRAF, S. **Adaptivity in learning management systems focussing on learning styles**. [S.l.]: na, 2007. Citado nas páginas [23](#), [31](#), [39](#) e [86](#).
- GRAF, S.; LIN, F.; KINSHUK, M. R.; MCGREAL, R. Intelligent and adaptive learning systems: Technology enhanced support for learners and teachers. **Hershey, PA: IGI Global**, 2012. Citado na página [31](#).

GRAF, S.; LIU, T.-C. *et al.* Supporting teachers in identifying students' learning styles in learning management systems: An automatic student modelling approach. **Journal of Educational Technology & Society**, International Forum of Educational Technology & Society, v. 12, n. 4, p. 3, 2009. Citado nas páginas 24, 25, 35, 69, 71, 81, 87, 105 e 106.

GRASHA, A. F. Learning styles: The journey from greenwich observatory (1796) to the college classroom (1984). **Improving College and University Teaching**, Taylor & Francis, v. 32, n. 1, p. 46–53, 1984. Citado na página 41.

GRASHA, A. F.; RIECHMANN, S. Student learning styles questionnaire. **University of Cincinnati, Faculty Resource Center, Cincinnati, OH**, 1975. Citado na página 43.

HENZE, N.; NEJDL, W. A logical characterization of adaptive educational hypermedia. **New review of hypermedia and multimedia**, Taylor & Francis, v. 10, n. 1, p. 77–113, 2004. Citado nas páginas 15 e 32.

HERRMANN, N. The creative brain. **The Journal of Creative Behavior**, Wiley Online Library, v. 25, n. 4, p. 275–295, 1991. Citado na página 44.

HONEY, P.; MUMFORD, A. **The learning styles helper's guide**. [S.l.]: Peter Honey Maidenhead, 2000. Citado na página 48.

HONEY, P.; MUMFORD, A. *et al.* The manual of learning styles. Peter Honey Maidenhead, 1992. Citado nas páginas 47 e 75.

HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. In: **Spin Glass Theory and Beyond: An Introduction to the Replica Method and Its Applications**. [S.l.]: World Scientific, 1987. p. 411–415. Citado na página 64.

JONASSEN, D. H.; GRABOWSKI, B. L. **Handbook of individual differences, learning, and instruction**. [S.l.]: Routledge, 2012. Citado nas páginas 23, 24 e 39.

JUNG, C. G. Psychological types: or the psychology of individuation. Harcourt, Brace, 1923. Citado na página 40.

KEEFE, J. Learning style: An overview. in national association of their relationship. **British Journal of Educational Psychology**, v. 67, p. 199–212, 1979. Citado nas páginas 23 e 39.

KIRSCHNER, P. A. Stop propagating the learning styles myth. **Computers & Education**, Elsevier, v. 106, p. 166–171, 2017. Citado na página 50.

KOHAVI, R.; SOMMERFIELD, D.; DOUGHERTY, J. Data mining using a machine learning library in c++. **International Journal on Artificial Intelligence Tools**, World Scientific, v. 6, n. 04, p. 537–566, 1997. Citado na página 91.

KOLB, D. **Learning style inventory: Technical manual. Experiential learning: Experience as the source of learning and development**. [S.l.]: Englewood Cliffs, NJ: Prentice-Hall, 1976. Citado nas páginas 45 e 51.

KOLB, D. A. **Experiential learning: Experience as the source of learning and development**. [S.l.]: FT press, 2014. Citado na página 46.

KULJIS, J.; LIU, F. A comparison of learning style theories on the suitability for elearning. **Web Technologies, Applications, and Services**, v. 2005, p. 191–197, 2005. Citado na página 86.

- LIYANAGE, M. P. P. *et al.* Using learning styles to enhance learning management systems. **ICTer**, v. 7, n. 2, 2014. Citado nas páginas 24, 25, 71, 81, 105 e 106.
- MACLEAN, P. D. Some psychiatric implications of physiological studies on frontotemporal portion of limbic system (visceral brain). **Electroencephalography and clinical neurophysiology**, Elsevier, v. 4, n. 4, p. 407–418, 1952. Citado na página 44.
- MAYER, R. E. Principles for managing essential processing in multimedia learning: Segmenting, pretraining, and modality principles. **The Cambridge handbook of multimedia learning**, p. 169–182, 2005. Citado na página 72.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, n. 4, p. 115–133, 1943. Citado na página 64.
- MICHALSKI, R. S. On the quasi-minimal solution of the general covering problem. 1969. Citado na página 60.
- MICHALSKI, R. S.; CARBONELL, J. G.; MITCHELL, T. M. **Machine learning: An artificial intelligence approach**. [S.l.]: Springer Science & Business Media, 2013. Citado na página 53.
- MITCHELL, T. M. *et al.* **Machine learning**. WCB. [S.l.]: McGraw-Hill Boston, MA., 1997. Citado na página 62.
- MONARD, M. C.; BARANAUSKAS, J. A. Aplicações de inteligência artificial: uma visão geral. **São Carlos: Instituto de Ciências Matemáticas e de Computação de São Carlos**, 2000. Citado na página 54.
- _____. Conceitos sobre aprendizado de máquina. **Sistemas Inteligentes-Fundamentos e Aplicações**, v. 1, n. 1, 2003. Citado nas páginas 56 e 60.
- MOODLE. **Moodle - Open-source learning plataforma**. 2017. Disponível em: <<https://moodle.org/>>. Acesso em: 08/10/2017. Citado nas páginas 23 e 29.
- MORGAN, J. N.; MESSENGER, R. C. Thaid, a sequential analysis program for the analysis of nominal scale dependent variables. Survey Research Center, Institute for Social Research, University of Michigan, 1973. Citado na página 60.
- MYERS, I. B. The myers-briggs type indicator: Manual (1962). Consulting Psychologists Press, 1962. Citado nas páginas 40 e 51.
- OLIVEIRA, I. C. A. d. **AdaptMLearning: uma proposta de sistema de aprendizagem adaptativo e inteligente**. Tese (Doutorado) — Universidade de São Paulo, 2013. Citado na página 31.
- PAPANIKOLAOU, K. A.; GRIGORIADOU, M.; KORNILAKIS, H.; MAGOULAS, G. D. Personalizing the interaction in a web-based educational hypermedia system: the case of inspire. **User modeling and user-adapted interaction**, Springer, v. 13, n. 3, p. 213–267, 2003. Citado na página 74.
- PASK, G. A fresh look at cognition and the individual. **International Journal of Man-Machine Studies**, Elsevier, v. 4, n. 3, p. 211–216, 1972. Citado na página 43.

_____. Conversation cognition and learning. a cybernetic theory and methodology. **Elsevier, Amsterdam-Oxford-NewYork**, 1975. Citado nas páginas 43 e 51.

PASK, G.; SCOTT, B. Caste: A system for exhibiting learning strategies and regulating uncertainties. **International Journal of man-machine studies**, Elsevier, v. 5, n. 1, p. 171N141–40IN1252, 1973. Citado na página 43.

PISTORI, H. Tecnologia adaptativa em engenharia de computação: Estado da arte e aplicações. **Universidade de São Paulo (USP), São Paulo**, 2003. Citado na página 54.

POLSON, M. C.; RICHARDSON, J. J. **Foundations of intelligent tutoring systems**. [S.l.]: Psychology Press, 2013. Citado na página 34.

PRATI, R. C. **Novas abordagens em aprendizado de máquina para a geração de regras, classes desbalanceadas e ordenação de casos**. Tese (Doutorado) — Universidade de São Paulo, 2006. Citado nas páginas 54, 55 e 57.

PRIMO, T. T.; VICARI, R. M.; BERNARDI, K. S. User profiles and learning objects as ontology individuals to allow reasoning and interoperability in recommender systems. In: IEEE. **Global Engineering Education Conference (EDUCON), 2012 IEEE**. [S.l.], 2012. p. 1–9. Citado na página 76.

QUALIS. **Plataforma Sucupira**. 2017. Disponível em: <<https://sucupira.capes.gov.br/sucupira/public/consultas/coleta/veiculoPublicacaoQualis/listaConsultaGeralPeriodicos.jsf>>. Acesso em: 25/09/2017. Citado na página 68.

QUINLAN, J. R. Induction of decision trees. **Machine learning**, Springer, v. 1, n. 1, p. 81–106, 1986. Citado na página 60.

_____. Generating production rules from decision trees. In: **ijcai**. [S.l.: s.n.], 1987. v. 87, p. 304–307. Citado na página 60.

RAJPER, S.; SHAIKH, N. A.; SHAIKH, Z. A.; MALLAH, G. A. Automatic detection of learning styles on learning management systems using data mining technique. **Indian Journal of Science and Technology**, v. 9, n. 15, 2016. Citado na página 72.

RUMELHART, D. E.; MCCLELLAND, J. L.; GROUP, P. R. *et al.* **Parallel distributed processing: Explorations in the microstructures of cognition. Volume 1: Foundations**. [S.l.]: The MIT Press, Cambridge, MA, 1986. Citado na página 64.

RUNDLE, S.; DUNN, R. The guide to individual excellence: A self directed guide to learning and performance solutions. **New York, Performance Concepts International**, 2000. Citado na página 74.

RUSSELL, S. J.; NORVIG, P. Artificial intelligence: a modern approach (international edition). {Pearson US Imports & PHIPEs}, 2003. Citado nas páginas 56 e 57.

SAKAI. **Introducing Sakai 11**. 2017. Disponível em: <<https://www.sakaiproject.org/>>. Acesso em: 08/10/2017. Citado nas páginas 23 e 29.

SENA, E. B.; VIVAS, A.; ASSIS, L.; PITANGUI, C. 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. Citado nas páginas 25 e 73.

- SILVA, Z.; FERREIRA, L.; PIMENTEL, A. Modelo de apresentação adaptativa de objeto de aprendizagem baseada em estilos de aprendizagem. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2016. v. 27, n. 1, p. 717. Citado nas páginas [25](#) e [72](#).
- SOFLANO, M.; CONNOLLY, T. M.; HAINEY, T. An application of adaptive games-based learning based on learning style to teach sql. **Computers & Education**, Elsevier, v. 86, p. 192–211, 2015. Citado na página [80](#).
- SOLOMAN, B. A.; FELDER, R. M. Index of learning styles questionnaire. **Retrieved March**, v. 26, p. 2003, 1999. Citado nas páginas [50](#), [87](#) e [106](#).
- SPERRY, R. W. The great cerebral commissure. **Scientific American**, JSTOR, v. 210, n. 1, p. 42–53, 1964. Citado na página [44](#).
- STANFILL, C.; WALTZ, D. Toward memory-based reasoning. **Communications of the ACM**, ACM, v. 29, n. 12, p. 1213–1228, 1986. Citado na página [63](#).
- STANGE, R. L. **Adaptatividade em aprendizagem de máquina: conceitos e estudo de caso**. Tese (Doutorado) — Universidade de São Paulo, 2011. Citado na página [54](#).
- TRAINA, C.; TRAINA, A.; SEEGER, B.; FALOUTSOS, C. Slim-trees: High performance metric trees minimizing overlap between nodes. In: SPRINGER. **International Conference on Extending Database Technology**. [S.l.], 2000. p. 51–65. Citado na página [63](#).
- TRUONG, H. M. Integrating learning styles and adaptive e-learning system: Current developments, problems and opportunities. **Computers in Human Behavior**, Elsevier, v. 55, p. 1185–1193, 2016. Citado nas páginas [51](#), [80](#) e [106](#).
- VALDEPERAS, E. M. **Sistema bayesiano para modelado del alumno**. Tese (Doutorado) — Universidad De Málaga, 2000. Citado na página [34](#).
- VAPNIK, V. **The nature of statistical learning theory**. [S.l.]: Springer science & business media, 2013. Citado na página [62](#).
- WAES, L. V.; WEIJEN, D. V.; LEIJTEN, M. Learning to write in an online writing center: The effect of learning styles on the writing process. **Computers & Education**, Elsevier, v. 73, p. 60–71, 2014. Citado na página [80](#).
- WIEDEMANN, T.; BARBOSA, J. L.; RIGO, S. J. Um modelo para recomendação de objetos de aprendizagem baseado em similaridade de sessões. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. [S.l.: s.n.], 2013. v. 24, n. 1, p. 878. Citado na página [78](#).
- WITTEN, I. H.; FRANK, E. Weka. **Machine Learning Algorithms in Java**, p. 265–320, 2000. Citado na página [91](#).
- WOLF, C. iweaver: towards' learning style'-based e-learning in computer science education. In: AUSTRALIAN COMPUTER SOCIETY, INC. **Proceedings of the fifth Australasian conference on Computing education-Volume 20**. [S.l.], 2003. p. 273–279. Citado na página [74](#).

YANG, T.-C.; HWANG, G.-J.; YANG, S. J.-H. Development of an adaptive learning system with multiple perspectives based on students' learning styles and cognitive styles. **Journal of Educational Technology & Society**, JSTOR, v. 16, n. 4, p. 185, 2013. Citado na página [78](#).

ZAINA, L.; BRESSAN, G.; CARDIERI, M.; JR, J. F. R. e-lors: Uma abordagem para recomendacao de objetos de aprendizagem. **Revista Brasileira de Informática na Educação**, v. 20, n. 1, p. 04, 2012. Citado na página [77](#).