
**Uma Abordagem para Análise Automática de
Repositórios de Objetos de Aprendizagem
Através de Técnicas de Aprendizagem de
Máquina para Apoio a Recomendação
Personalizada de Conteúdo em Sistemas
Adaptativos e Inteligentes para Educação**

Miller Miranda Mendes



**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**

Uberlândia
2018

Miller Miranda Mendes

**Uma Abordagem para Análise Automática de
Repositórios de Objetos de Aprendizagem
Através de Técnicas de Aprendizagem de
Máquina para Apoio a Recomendação
Personalizada de Conteúdo em Sistemas
Adaptativos e Inteligentes para Educação**

Dissertação de mestrado apresentada ao Programa de Pós-graduação da Faculdade de Computação da Universidade Federal de Uberlândia como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação.

Área de concentração: Ciência da Computação

Orientador: Fabiano Azevedo Dorça

Uberlândia

2018

Dados Internacionais de Catalogação na Publicação (CIP)
Sistema de Bibliotecas da UFU, MG, Brasil.

M538o
2018 Mendes, Miller Miranda, 1986-
 Uma abordagem para análise automática de repositórios de objetos
de aprendizagem / Miller Miranda Mendes. - 2018.
 71 f. : il.

Orientador: Fabiano Azevedo Dorça.
Dissertação (mestrado) - Universidade Federal de Uberlândia,
Programa de Pós-Graduação em Ciência da Computação.
Disponível em: <http://dx.doi.org/10.14393/ufu.di.2018.233>
Inclui bibliografia.

1. Computação - Teses. 2. Objetos de aprendizagem - Teses. 3.
Ensino auxiliado por computador - Teses. 4. Aprendizado do
computador - Teses. I. Dorça, Fabiano Azevedo. II. Universidade
Federal de Uberlândia. Programa de Pós-Graduação em Ciência da
Computação. III. Título.

CDU: 681.3

UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Os abaixo assinados, por meio deste, certificam que leram e recomendam para a Faculdade de Computação a aceitação da dissertação intitulada "**Uma Abordagem para Análise Automática de Repositórios de Objetos de Aprendizagem Através de Técnicas de Aprendizagem de Máquina para Apoio a Recomendação Personalizada de Conteúdo em Sistemas Adaptativos e Inteligentes para Educação**" por Miller Miranda Mendes como parte dos requisitos exigidos para a obtenção do título de **Mestre em Ciência da Computação**.

Uberlândia ___ de Fevereiro de 2018

Orientador: _____

Prof. Dr. Fabiano Azevedo Dorça
Universidade Federal de Uberlândia

Banca Examinadora:

Prof. Dr. Carlos Roberto Lopes
Universidade Federal de Uberlândia

Prof. Dr. Alessandro Vivas Andrade
Universidade Federal dos Vales do
Jequitinhonha e Mucuri

Este trabalho e dedicado a todos envolvidos durante todo o percurso de pesquisa

Agradecimentos

Agradeço muito aos meus pais que sempre me incentivaram em todos os momentos da minha vida, investindo em cursos, educação, alimentando a minha vontade de estudar, aprender e compartilhar os conhecimentos adquiridos. Cresci ouvindo os ensinamentos dos meus pais, os quais diziam que o conhecimento é muito valioso e um grande investimento para a vida.

Agradeço também a minha noiva Bruna, que acompanhou minha trajetória do Mestrado, apoiando-me e dando-me força em todos os momentos, sempre buscando juntos maior conhecimento.

Ressalto as boas amizades criadas durante o tempo de estudos, Victor, Rafael, Hiran, Cleon e aos professor que são essenciais em direcionar o caminho do sucesso, em especial ao Professor Dr. Fabiano Dorça, que sempre esteve presente com seus ensinamentos e conhecimentos ao Professor Dr. Renan Cattelan, que abriu as oportunidade para iniciar as pesquisas e, por fim, a Professora Dr. Márcia, que contribuiu para uma formação sólida de grandes conquistas.

Agradeço a meus amigos fora do ambiente de estudos, aos quais fortaleceram meu equilíbrio, com bons momentos de descontração.

Por fim, deixo meus agradecimentos a todo o corpo docente do Programa de Pós Graduação em Ciência da Computação que foi de suma importância em minha formação, À CAPES , FAPEMIG e FACOM.

“Cada sonho que você deixa para trás, é um futuro que deixa de existir.”
(Steve Jobs)

Resumo

A quantidade de conteúdo educacional digital que é criado continuamente faz com que os repositórios de materiais educacionais fiquem cada vez maiores e a busca por conteúdos específicos e direcionados aumente. Dessa forma, foi realizado um estudo com base nos objetos de aprendizagem gerados em um repositório. Foi aplicado o padrão IEEE LOM para gerar grupos de objetos de aprendizagem que possam ser utilizados para um determinado perfil de estudante. Logo, tem-se uma necessidade que estes objetos estejam organizados para que sua recomendação seja mais eficiente. Sendo assim, este trabalho apresenta uma proposta que faz uso de técnicas de clusterização para agrupar conteúdos educacionais em repositórios com base em estilos de aprendizagem do estudante. Inicialmente, foi realizada uma análise comparativa entre algoritmos de agrupamentos com dados fictícios no qual foram obtidos bons resultados. Com base nestes resultados, foi discutido e implementado um estudo de caso recorrendo a dados reais de estudantes em um sistema educacional.

Palavras-chave: objetos de aprendizagem, estilos de aprendizagem, sistemas educacionais adaptativos, agrupamento, ambiente de aprendizagem, atributos LOM.

Abstract

The amount of digital educational content that is continually created makes the repositories of educational materials increasingly large and the search for specific and targeted content is increasing. Thus, a study was carried out based on learning objects generated in a repository. The IEEE LOM standard was used to generate groups of learning objects that could be used for a given student profile. It is a necessity that these objects be organized so that their recommendation is more efficient. Thus, this paper presents a proposal that uses clustering techniques to group educational content into repositories based on student learning styles. Initially a comparative analysis was performed between grouping algorithms with dummy data in which good results were obtained. Based on these results, a case study using real data from students in an educational system was discussed and implemented.

Keywords: learning objects, learning styles, adaptive educational systems, clustering, learning environment, lom field.

Lista de ilustrações

Figura 1 – Ambientes educacionais	25
Figura 2 – Arquitetura para objetos de aprendizagem adaptativa, adaptado de Mustaro e Silveira (2006)	28
Figura 3 – Metadados IEEE LOM	32
Figura 4 – Felder e Silvernan	35
Figura 5 – Etapas do processo de clusterização, imagem de Jain, Murty e Flynn (1999)	39
Figura 6 – Regras de mapeamento de metadados de OAs que satisfazem EAs do modelo FSLSM, extraído de Dorça et al. (2016)	45
Figura 7 – Processo de Agrupamento de OAs.	47
Figura 8 – Comparativo da quantidade de OAs em cada cluster.	49
Figura 9 – Proposta de implantação	51
Figura 10 – Processamento de aulas	52
Figura 11 – Agrupamento de OAs da disciplina IHC gerados pela plataforma CX.	55
Figura 12 – Algoritmo EM	69
Figura 13 – Algoritmo Kmeans	71

Lista de tabelas

Tabela 1 – Pesquisas relacionadas	29
Tabela 2 – Vetorização de um Objeto de Aprendizagem	48
Tabela 3 – Combinações de Felder e Silverman	48
Tabela 4 – Validação dos resultados da clusterização	50
Tabela 5 – Grau de Pertinência	50
Tabela 6 – Estudante	53

Lista de siglas

AVAI Ambientes Virtuas de Aprendizagem Inteligentes

EAs Estilos de Aprendizagem

FSLSM Felder e Silverman Learning Style Model

IEEE Institute of Electrical and Electronics Engineers

LMS Learning Management Systems

LTSC Learning Technology Standards Committee

LOM Learning Object Metadata

OAs Objetos de Aprendizagem

RNP Rede Nacional de Pesquisa

ROA Repositório de Objetos de Aprendizagem

Sumário

1	INTRODUÇÃO	23
1.1	Motivação	24
1.2	Objetivos e Desafios da Pesquisa	25
1.3	Hipótese	25
1.4	Organização da Dissertação	26
2	TRABALHOS RELACIONADOS	27
3	FUNDAMENTAÇÃO TEÓRICA	31
3.1	Objetos de Aprendizagem	31
3.2	Repositório de Objetos	33
3.3	Estilos de Aprendizagem	34
3.4	Relação entre Estilos de Aprendizagem e Objetos de Aprendizagem	36
3.5	Aprendizagem de Máquina	37
4	PROPOSTA	43
4.1	Abordagem	43
4.2	Resultados	49
5	ESTUDOCASO	51
5.1	Autoria de Objetos	52
5.2	Modelagem do Estudante	53
5.3	Resultados	54
6	CONCLUSÃO	57
6.1	Trabalhos Futuros	58
6.2	Contribuições em Produção Bibliográfica	58

REFERÊNCIAS	61
ANEXOS	67
ANEXO A – ALGORITMO EXPECTATION MAXIMIZATION	69
ANEXO B – ALGORITMO K-MEANS	71

Introdução

O avanço da computação em diferentes frentes tem criado sistemas cada vez mais dinâmicos e que se adaptam às necessidades dos usuários. Especialmente no contexto educacional, abordagens que visam melhorar a experiência de aprendizagem aplicando recursos de recuperação e personalização de conteúdo tem surgido. Em paralelo, o surgimento de Ambientes Virtuais de Aprendizagem e Inteligentes (AVAI) associado às premissas da Computação Ubíqua (WEISER, 1999) tem potencializado a geração de Objetos de Aprendizagem (OAs) capturados e segmentados automaticamente (ARAÚJO et al., 2016).

Os AVAI fornecem maneiras de interação entre sistemas, professores e estudantes, utilizando linguagens e recursos tecnológicos para exibição de informação de forma organizada (ALMEIDA, 2011). O uso de AVAI no meio acadêmico tem se tornando cada vez mais importante e, conseqüentemente, mais buscado (TORRES; AMARAL, 2011). Dessa forma, adequar tais ambientes ao estudante, considerando suas características e individualidades torna-se um fator relevante.

Para isso, a abordagem com Objetos de Aprendizagem (OA) tem sido promissora (AUDINO; NASCIMENTO, 2012). O *Learning Technology Standards Committee* (LTSC), dentro do *Institute of Electrical and Electronics Engineers* (IEEE), tem adotado a definição de OA como qualquer entidade digital ou não-digital que pode ser aplicado para o aprendizado no meio da educação.

Repositórios já são utilizados para facilitar a busca de OAs a partir de suas diferentes áreas, conteúdos e tipos (áudio, vídeo, diagramas, texto, etc.) (SILVA; CAFÉ; CATAPAN, 2011). No entanto, observa-se que os repositórios de OAs possuem uma grande quantidade de dados, o que resulta em OAs que, muitas vezes, não atendem a um determinado perfil do aluno. A clusterização (ou agrupamento) é uma técnica que pode ser aplicada para aumentar a escalabilidade de sistemas de recomendação, na qual OAs podem ser agrupados utilizando métricas de similaridade. Assim, a recomendação de OAs pode ser aplicada em grupos específicos gerados em cada agrupamento.

Um conceito importante para a criação de sistema de recomendação de conteúdo

personalizada são os Estilos de aprendizagem (EAs), que estão diretamente ligados às estratégias as quais um estudante adota para realizar seu aprendizado. Felder e Silverman (1988) propõem um modelo específico para o aprendizado de estudantes por meio de quatro dimensões: percepção, entrada, processamento e organização.

Recomendar conteúdo com base no perfil do estudante é uma abordagem promissora, de acordo com Rolim et al. (2017). As recomendações podem ser realizadas relacionando características individuais, contextuais e também com base nas ações do aluno quando este interage com o conteúdo (ZAINA et al., 2012). Cazella et al. (2009) sugerem a criação de sistemas que possibilitam auxiliar o usuário na busca e seleção de um conteúdo com base em seu perfil. Um dos modelos mais aceitos é o de(FELDER; SILVERMAN, 1988), que propõem um modelo de EAs com quatro dimensões: percepção, entrada, processamento e organização.

Assim, este trabalho propõe uma abordagem para o agrupamento e a recomendação de conteúdo educacional que leva em consideração a relação entre os EAs de Felder e Silverman e os metadados dos OAs, no formato *IEEE Learning Object Metadata* (IEEE LOM). Aplica-se uma estratégia para vetorizar os OAs, de modo a facilitar o processo de agrupamento e, com isso, possibilitar o emprego de técnicas de agrupamento para auxiliar o processo de recomendação. Entende-se que esta abordagem traga vantagens em termos de eficiência, uma vez que possibilita o pré-processamento das características dos EAs atendidos pelos OAs.

1.1 Motivação

Sistemas de Learning Management Systems (LMS) como o Aulanet, o TelEduc, o Moodle, Classroom Experience são responsáveis pela disponibilização de conteúdo educacional utilizando repositórios de aprendizados que são gerados pelos professores.

Em pesquisas, podem ser citados estudos de tecnologia aplicado a sistemas educacionais como (SILVA et al., 2009), ontologias (GLUZ; VICARI, 2010), clusterização (FERREIRA; VASCONCELOS, 2017)

Conforme a Figura 1, pode-se observar que existe o professor que é gerador de conteúdo educacional o qual alimenta os sistemas, e estes sistemas salvam todos estes conteúdos em um repositório de OAs. Posteriormente, são aplicadas varias técnicas para poder criar um processo de recomendação de conteúdo ao estudante.

Com isso a motivação do trabalho tem como fonte principal esta relação de como poder entregar os melhores conteúdo armazenados em repositórios de OAs com base no material didático criado pelos professores em um determinado sistema.



Figura 1 – Ambientes educacionais

1.2 Objetivos e Desafios da Pesquisa

Esta proposta tem como objetivo contribuir para o processo de ensino e aprendizagem com o desafio de comparar as melhores técnicas de agrupamentos de OAs para serem utilizadas no contexto educacional, apoiar o processo de recomendação de conteúdo e, por fim, realizar um estudo de caso de todo o processo. Segue uma listagem detalhada dos objetivos.

Um grande desafio da pesquisa é como tornar possível o uso de técnicas de aprendizagem de máquina em ambientes educacionais, considerando o perfil dos estudantes e as características dos OAs. Para isto, foram definidos os objetivos deste trabalho.

1. Criar uma abordagem na qual seja possível aplicar algoritmos de aprendizagem de máquina em ambientes educacionais
2. Identificar e explorar técnicas de aprendizado de máquina realizando um estudo comparativo para a melhor abordagem no contexto educacional
3. Criar uma forma de melhorar e facilitar o processo de recomendação de conteúdo nos sistemas educacionais utilizando OAs e EAs.
4. Implementar a abordagem proposta em um sistema como estudo de caso recorrendo a dados reais dos estudantes.

Assim esta abordagem tem como objetivo facilitar a recomendação, pois a partir do momento que tem-se OAs em grupos específicos de aprendizagem, isto pode tornar o processo menos complexo.

1.3 Hipótese

Com base nos objetivos definidos na seção 1.2 seguem as hipóteses abaixo.

1. Tornar possível a utilização de aprendizagem de máquina com dados de OAs e EAs.
2. Agrupar os OAs poderá melhorar o processo de recomendação, pois, em repositórios muito grandes, os OAs ficam desorganizados para o processo.

1.4 Organização da Dissertação

Esta dissertação está dividida em seis capítulos. O capítulo 2 mostra um levantamento dos trabalhos encontrados na literatura; O capítulo 3 apresenta os conceitos sobre Objetos de Aprendizagem, Estilos de Aprendizagem, Aprendizagem de Máquina e Clusterização com o objetivo de passar o embasamento teórico necessário para a compreensão da proposta do trabalho; No Capítulo 4 será apresentado, a proposta do trabalho, mostrando a autoria de objeto, modelagem do estudante e o processo da abordagem; com seus resultados; o Capítulo 5 possui a implementação da abordagem em um sistema real e por fim o Capítulo 6 apresenta as considerações finais sobre este trabalho, juntamente com suas limitações e trabalhos futuros.

Trabalhos Relacionados

Existem diversos trabalhos na literatura que se relacionam com esta pesquisa que serão discutidos nesta seção. Alguns deles focados na captura de conteúdo digital, outros nos EAs do estudantes, recomendação de conteúdo, que, juntos, formam uma área de estudo abrangente e com muitas pesquisas.

Peña et al. (2002) possuem uma abordagem que apresenta informações sobre materiais educacionais e preferências dependentes dos EAs do aluno, para fazer recomendações de OA. Para a modelagem do aluno foram utilizadas técnicas de Inteligência Artificial como Case-Based-Reasoning e Lógica Fuzzy. Foi criado um sistema capaz de classificar os alunos de acordo com suas capacidade. Para isto, implementou-se o apoio de agentes inteligentes para examinar as oportunidades de melhorar o ensino e motivar os alunos a aprender de acordo com suas preferências em um ambiente amigável e o mais próximo possível do seu estilo de aprendizagem. Este trabalho faz uma relação entre FSLSM e objetos de aprendizagem.

Mustaro e Silveira (2006) mostram uma arquitetura com base em cinco camadas distintas e que possuem relação entre si conforme Figura 2 a camada de Cursos está direcionada para a organização de conteúdos através de objetos contidos na camada de Objetos de Aprendizagem Reutilizáveis. Para a apresentação destes objetos, ha a camada de Apresentação que possui a função de mais duas outras camadas; a camada de Modelo do Aprendiz, que armazena referencial histórico em relação aos OAs conhecidos, bem como a camada dos EAs, que descreve o perfil individualizado de cada aprendiz frente a um determinado tópico, ou o categoriza em clusters de aprendizes em função de seus estilos de aprendizagem. Este artigo é interessante, pois aborda um arquitetura pela qual e possível conectar vários camadas do sistema educacional.

Em seu trabalho, García et al. (2007) foi realizado uma proposta de detectar como os alunos aprendem: refletir ou agir; de forma constante ou global; intuitiva ou sensivelmente. Neste trabalho, foram avaliados as redes bayesianas na detecção do estilo de aprendizagem de um aluno em um sistema de educação baseado na Web. A rede bayesiana modela diferentes aspectos do comportamento de um estudante enquanto o es-

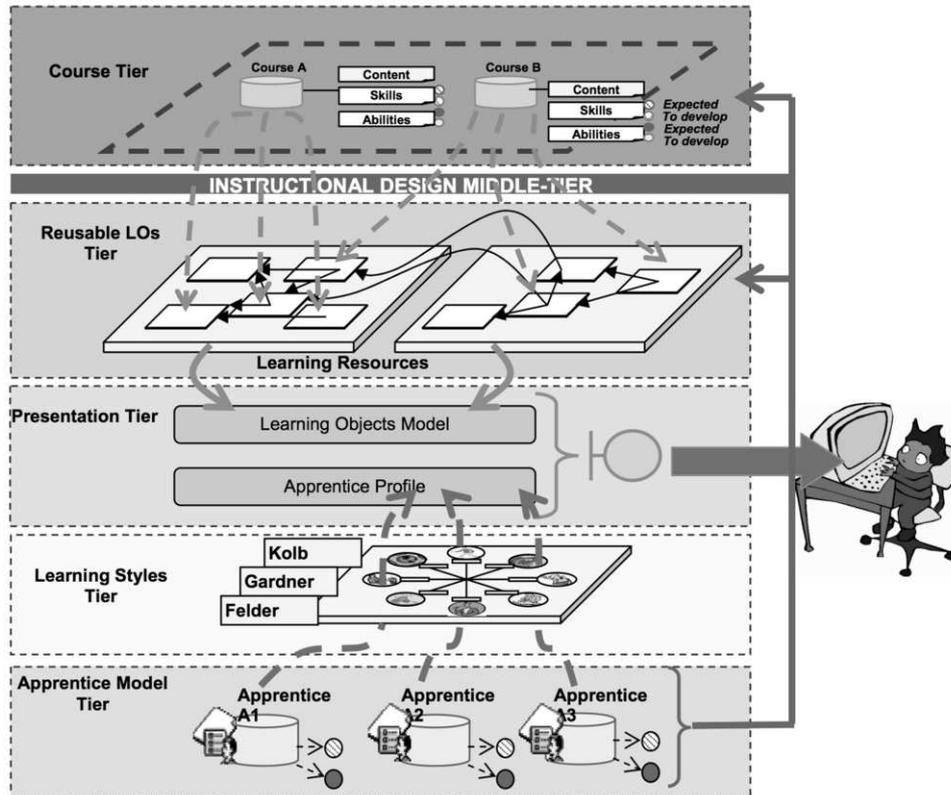


Figura 2 – Arquitetura para objetos de aprendizagem adaptativa, adaptado de Mustaro e Silveira (2006)

tudante utiliza o sistema. A rede, então, infere os estilos de aprendizagem de acordo com os comportamentos modelados.

Cazella et al. (2012) apresentam um sistema de recomendação de OAs baseado na técnica de filtragem colaborativa. O modelo recomenda os OAs aos estudantes de forma automática, com base em seus interesses e nas competências que devem ser desenvolvidas seguindo um plano de aula. Sua proposta, no entanto, não recorre ao modelo FLSM para avaliar o perfil de aprendizagem do estudante.

No domínio educacional, modelos de recomendação de conteúdo têm sido empregados em diferentes contextos. O modelo proposto em Santos et al. (2015) aplica um algoritmo de filtragem colaborativa em *clusters* de OAs e de usuários. Foi realizada uma clusterização com base em conteúdo de duas formas distintas: primeiramente, com os OAs e, em posteriormente, com os usuários, para gerar a recomendação. Entretanto, este modelo não explora a relação entre OAs e EAs para recomendação.

Casagrande, Kozima e Willrich (2015) apresentam uma técnica para avaliar os valores dos elementos de metadados do conteúdo acessado pelos estudantes, a fim de estimar as suas preferências e formular a recomendação correspondente. Seu objetivo é determinar as preferências do estudante a partir de dados que descrevem o conteúdo acessado por este. O conjunto de elementos de metadados a ser observado é dependente do domínio do repositório, permitindo que metadados descritores de objetos de aprendizagem sejam

considerados.

Méndez, Morales e Vicari (2016) estabelecem uma relação entre OAs e EAs na qual é determinado os metadados que são relevantes ou não para cada EA, no qual é informado como atributo positivo ou negativo para aplicar a junção de ambos. Com base nesta proposta de mapeamento entre estilos de aprendizagem e alguns metadados do LOM, a recuperação personalizada do EA se torna possível. Depois de selecionar um conjunto de recursos para um determinado OA ou aos resultados de uma cadeia de pesquisa em um repositório, as comparações podem ser realizadas automaticamente a fim de proporcionar aos alunos recursos que atendam às suas necessidades e preferências em seu processo de aprendizagem.

A Tabela 1 expõe um comparativo da abordagem proposta ante os principais trabalhos relacionados. O trabalho se destaca por apresentar uma abordagem promissora de agrupamentos de OAs de acordo com os EAs atendidos, considerando as 16 combinações possíveis de EAs dentro do modelo de Felder e Silverman. Foram avaliados trabalhos que utilizam clusters de usuários (C. Usuários), cluster de OAs (C. OAs), Estilos de Aprendizagem, Objetos de Aprendizagem e Filtragem Colaborativa. Uma abordagem propõe uma forma vetorial de representar os OAs considerando os EAs que eles atendem, tornando o processo de recomendação por EAs muito mais eficiente. Ainda, com o resultado desta vetorização, torna-se possível aplicar técnicas de agrupamento que, por serem independentes de um repositório ou AVA específico, contribuem para o processo de recomendação personalizada de conteúdo. A única restrição é que OAs tenham metadados segundo o formato IEEE-LOM.

Tabela 1 – Pesquisas relacionadas

Trabalhos	C. OAs	C. Usuários	EA	OA	FC
Pena et. al. 2002			x	x	
Mustaro;Silveira 2006			x	x	
Garcia et. al. 2007			x		
Cazella et. al. 2012			x	x	x
Santos et. al. 2015		x	x	x	
Casagrande et. al. 2015			x	x	
Méndez et. al. 2016			x	x	
Este trabalho	x		x	x	

As pesquisas realizadas com abordagens para melhorar o processo de ensino e aprendizagem vem evoluindo conforme trabalhos citados, podendo observar que alguns trabalhos focam em OAs, outros em EAs, ontologias, Filtragem Colaborativo (FC) utilizando diferentes padrões para representar os OAs dentro de repositórios espalhados pelas universidades.

Portanto, este trabalho possui um grande potencial de contribuição, pois leva em consideração vários trabalhos feitos anteriormente como relacionar EAs com OAs.

Fundamentação Teórica

Nesta sessão, serão apresentadas as definições e os conceitos necessários para o entendimento da abordagem proposta, além de citar trabalhos relacionados ao tema desta pesquisa, que mostram os conceitos propostos por Felder e Silverman Learning Style Model FSLSM e o padrão aplicado para os objetos de aprendizagem.

3.1 Objetos de Aprendizagem

Wiley (2001) considerou que Objetos de Aprendizagem (OA) podem ser definidos por qualquer entidade, digital ou não digital, que possa ser aplicado, reutilizada ou referenciada durante o aprendizado suportado por tecnologias. Segundo Fabre, Tamusiunas e Tarouco (2003) a tecnologia de informática na educação permite criar material didático utilizando multimídias e interatividades que apoiam o processo de ensino e aprendizagem utilizados em sistemas. Um OA pode usar imagens e animações, documentos em texto, apresentações e páginas da Internet. O que faz seu conteúdo interessante e independe de sua forma.

Objetos de Aprendizagem podem ser mais eficientes quando são organizados e classificados em metadados e armazenados em repositórios que facilite a integração a um sistema educacional. Os padrões abertos de OAs evitam que um objeto fique em desuso com o avanço da tecnologia, pois este mantém um padrão para possíveis atualizações sistêmicas passível de interoperabilidade e portabilidade. A Figura 3 exibe graficamente os campos do padrão LOM.

Interoperabilidade é a habilidade de operar por meio de uma variedade de hardware sistemas operacionais e web , com facilidade de operar entre diferentes sistemas. Já, portabilidade quer dizer um OA deve ser compatível em diversas plataformas. O OA deve ser independente da plataforma onde é disponibilizado e dos sistemas de gestão de conteúdos, isto é, um OA deve necessitar apenas de um leitor específico para que possa ser utilizado (TORRÃO, 2007) .

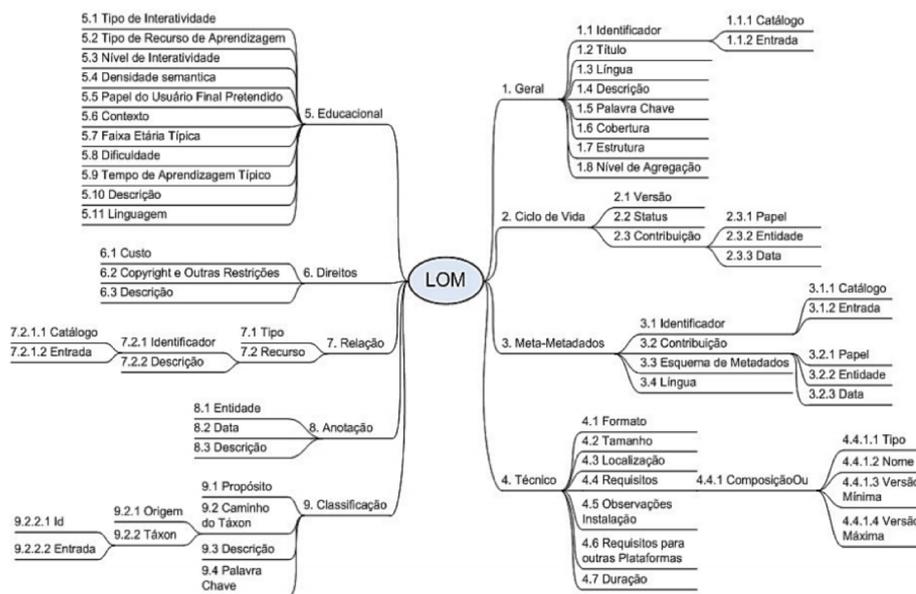


Figura 3 – Metadados IEEE LOM

Além destas características dos OAS, temos também algumas discutidas por SILVA (2004), como autonomia: que é a capacidades de serem utilizados individualmente, desvinculados de outros; interatividade: que é a apresentação do conteúdo de forma dinâmica, permitindo a interação; reutilização: poder estar presente em diversos contextos e propósitos, possibilidade de serem utilizados tanto para seu contexto inicial quanto reutilizados em outras áreas de ensino; agrupamento: agrupamento de diversos módulos de conteúdos específicos, de maneira a garantir um ambiente de aprendizagem mais rico e flexível.

Um OA pode estar dividido em três partes segundo Bettio e Martins (2002) que facilitam a recomendação deste.

1. Objetivos: tem como finalidade mostrar ao aprendiz o que ele poderá aprender com o estudo do OA. Pode, por exemplo, conter uma lista de exercícios para fixação do aprendizado;
2. Conteúdo: mostra todo o material didático que é preciso para que, no final, o aluno atinja os objetivos dispostos na etapa 1;
3. Prática e feedback: uma característica importante dos OAs é que ao final dos estudos pode-se avaliar, para que o aluno veja se atingiu expectativas e ,se não, utilizá-lo novamente, quantas vezes forem necessárias.

Os conteúdos recomendados ao aluno podem ser organizados por meio da catalogação de metadados inserindo valores aos atributos definidos no padrão IEEE-LOM podendo representar este conteúdo como um OA, este padrão leva em conta nove categorias para representar um OA:

1. Geral: representa informações gerais
2. Ciclo de Vida: representa histórico e estado atual
3. Meta-metadata: exibe informações sobre os metadados
4. Técnicos: representam requisitos técnicos
5. Direitos: exibe os direitos, propriedade intelectual e condições de uso
6. Educacional: informações relacionadas aos aspectos educacionais
7. Relação: informa relacionamentos entre os OAs
8. Anotação: informa comentários sobre o uso educacional
9. Classificação: informa o posicionamento do OA frente a sistemas de classificação pré-definido.

Neste trabalho, será utilizada a proposta do LTSC/IEEE Learning Object Metadata (LOM) (IEEE, 2002) como padrão de documento de metadados para descrição de OAs. O padrão IEEE-LOM define OA como qualquer entidade que pode ser empregada na área da educação.

3.2 Repositório de Objetos

A prática de concentrar OAs em um único espaço facilita a pesquisa e a localização desses recursos. Os ambientes utilizados com esse objetivo são chamados de Repositórios de Objetos de Aprendizagem (ROA). A pesquisa nesses ambientes é realizada mediante de campos disponíveis, os quais representam informações a respeito dos próprios objetos, que são chamamos de metadados.

A seguir, será detalhado algumas definições acerca dos ROA, metadados e padrões de encapsulamento dos OAs. Repositórios de objetos de aprendizagem são espaços que permitem o armazenamento, a pesquisa e a reutilização de objetos de aprendizagem. Harman e Koohang (2007) definem um repositório de objetos de aprendizagem como um catálogo digital que facilita a pesquisa por esses recursos.

Segundo Heery e Anderson (2005) dizem que um repositório digital é diferenciado de outra coleção digital pelas seguintes características:

- ❑ o conteúdo é depositado em um repositório, seja pelo criador do conteúdo, o proprietário, ou por terceiros em seu nome;
- ❑ a arquitetura do repositório gerencia o conteúdo por meio de metadados;
- ❑ o repositório deve ser sustentável e confiável, bem apoiado e gerenciado;

- ❑ o repositório oferece um conjunto mínimo de serviços básicos, por exemplo, inserir, obter, pesquisar, controlar o acesso, além de alguns serviços opcionais que podem ser apoiados, como:
 - ❑ melhorar o acesso aos recursos;
 - ❑ novos modos de publicação e revisão por pares;
 - ❑ gestão da informação corporativa;
 - ❑ compartilhamento de dados e reutilização;
 - ❑ preservação dos recursos digitais.

Logo ROA se toram bastante eficientes para armazenamento dos OAs gerados em ambientes educacionais.

Com o aumento da produção de OAs em inúmeras instituições no Brasil e no mundo, percebeu-se que esse conteúdo não seria de grande utilidade para a comunidade de usuários em geral (instituições, professores, alunos), a menos que o conteúdo pudesse ser disponibilizado, localizado e recuperado de forma eficiente e globalizada; caso contrário, o repositório restringe-se ao contexto da instituição que o criou, minimizando seu potencial de compartilhamento e reuso, com isso foi desenvolvido no Brasil uma federação chamada Federação Educa Brasil com o apoio da Rede Nacional de Pesquisa RNP.

Os repositórios de conteúdo educacional podem ser acessados pelos integrantes da federação através de protocolos padronizados ou de outras alternativas para coleta de metadados. Os metadados são armazenados nos servidores da federação e as consultas submetidas pelos usuários são atendidas por ela, podendo conter metadados de objetos de aprendizagem localizados em diversos repositórios.

Portanto, a utilização de OAs tem um fator muito positivo para que os conteúdos digitais fiquem armazenados e organizados, no qual possam ser reaproveitados, posteriormente, com possível interoperabilidade entre sistemas.

3.3 Estilos de Aprendizagem

Existem vários modelos de EA diferentes na literatura, como, por exemplo, Kolb e Kolb (2005), Honey, Mumford et al. (1992), bem como Felder e Silverman (1988). Neste trabalho a pesquisa ficou direcionada no modelo de aprendizagem de Felder-Silverman. A maioria dos modelos de estilos de aprendizagem classificam alunos em poucos grupos, enquanto Felder e Silverman descrevem mais detalhadamente o estilo de aprendizado de um aluno, distinguindo-o entre preferências em quatro dimensões. Outra questão principal é que o FSLSM é baseado em tendências, dizendo que os alunos com uma alta preferência por determinado comportamento também podem agir às vezes diferentemente.

De acordo com Carver, Howard e Lane (1999), o modelo de Felder é o mais apropriado para o material didático de hipermídia e também pode ser visto que o FSLSM é usado com frequência em pesquisas relacionadas aos estilos de aprendizagem em tecnologias avançadas de aprendizagem. Na discussão a seguir, são descritas as quatro dimensões do FSLSM conforme Figura 4 em que cada aprendiz é caracterizado por uma preferência específica para cada uma dessas dimensões.



Figura 4 – Felder e Silverman

A primeira dimensão distingue entre uma maneira ativa e reflexiva de processamento de informações. Os aprendizes ativos aprendem melhor quando trabalham ativamente com o material de aprendizagem, aplicando o material e tentando tudo fora. Além disso, eles tendem a estar mais interessados em comunicação com os outros e preferem aprender trabalhando em grupos que podem discutir sobre o material aprendido. Em contrapartida, os alunos reflexivos preferem pensar e refletir sobre o material. Em relação à comunicação, eles preferem trabalhar sozinhos, ou em um pequeno grupo junto com um bom amigo.

A segunda dimensão abrange a percepção versus a aprendizagem intuitiva. Os alunos que preferem um estilo de aprendizagem sensível gostam de aprender com fatos e material de aprendizagem concreto. Eles gostam de resolver problemas com abordagens padrão e também tendem a ser mais pacientes com detalhes. Além disso, perceber que os alunos são considerados mais realistas e sensíveis; eles tendem a ser mais práticos que os aprendizes intuitivos e gostam de relacionar o material erudito com o mundo real. Em contraste, os aprendizes intuitivos preferem estudar materiais de aprendizagem abstratos, como teorias e seus significados subjacentes. Eles gostam de descobrir possibilidades e relacionamentos e tendem a ser mais inovadores e criativos.

A terceira, a dimensão visual-verbal diferencia os alunos que se lembram melhor de imagens, diagramas e fluxogramas, e alunos que aprende mais de representações textuais, independentemente do fato de serem escritas ou faladas.

Na quarta dimensão, os alunos são caracterizados de acordo com sua compreensão. Aprendizes sequenciais aprendem em pequenas etapas incrementais portanto, têm um progresso de aprendizagem linear. Eles tendem a seguir caminhos lógicos passo a passo na busca de soluções. Em contraste, os aprendizes globais usam um processo de pensa-

mento holístico e aprendem em grandes passos. Eles tendem a absorver o material de aprendizagem quase que aleatoriamente, sem ver conexões, mas depois de terem aprendido material suficiente, de repente, eles entram toda a imagem. Então eles são capazes de resolver problemas complexos, encontrar conexões entre diferentes áreas, e juntar as coisas de maneiras novas, mas eles têm dificuldade em explicar como fizeram isso. Como toda a imagem é importante para os alunos globais, eles tendem a estar mais interessados conhecimentos gerais e um conhecimento amplo, enquanto os aprendizes sequenciais estão mais interessados nos detalhes.

3.4 Relação entre Estilos de Aprendizagem e Objetos de Aprendizagem

Estilo de Aprendizagem, segundo Riding e Rayner (2013), consiste no modo preferencial, individual e habitual, no qual os indivíduos possam organizar e representar informações durante o processo de aprendizagem. Neste trabalho, será abordado o modelo FLSM que é amplamente aplicado para adaptação e personalização dos materiais de aprendizagem. O modelo de Felder foi definido em quatro dimensões e dentro de cada dimensão foram definidos dois EAs antagônicos sendo Intuitivo/Sensitivo, Ativo/Reflexivo, Sequencial/Global e Visual/Verbal. O modelo de Felder é amplamente empregado em vários trabalhos que usam estilos de aprendizagem (FRANZONI et al., 2008; DORÇA et al., 2011). Cada um dos EAs desse modelo é sumarizado a seguir:

Diante disso, um importante ponto para utilizar OAs destaca-se no fato de que estes possuem características de reuso entre diferentes disciplinas das que foram criadas inicialmente. Recomendações de conteúdo são permitidas com base em características relacionadas ao escopo em um determinado contexto. Um sistema de recomendação em um contexto educacional avalia as ações do aluno durante a interação com alguns conteúdos para que possível sugerir e recomendar materiais de acordo com a preferência (FELFERNIG et al., 2007).

A categoria Educacional do LOM é de fundamental relevância para este trabalho para relacionar os OAs com EAs, pois traz importantes características educacionais e pedagógicas dos OAs (HODGINS; DUVAL et al., 2002), sendo esta uma possível informação pedagógica para aqueles que estão envolvidos na experiência de aprendizagem. O foco dos metadados presentes inclui professores, gerentes, autores, e aprendizes.

- Interactivity type: Este campo indica o modo predominante de aprendizagem suportado por um OA. Permite descobrir se um OA possui conteúdo que exige participação do estudante ou se ele traz conteúdo puramente expositivo. Portanto, permite verificar se um OA deve ser recomendado a um estudante ativo ou reflexivo.

- ❑ Learning Resource Type: Este campo indica o tipo específico do OA. Permite verificar se um OA deve ser recomendado para um estudante sensível ou intuitivo. Além disso, este campo permite verificar se um OA deve ser recomendado a um estudante verbal ou visual. Portanto, com o uso dessas informações é possível recomendar um OA a um estudante ativo ou reflexivo.
- ❑ Interactivity Level: Este campo indica o grau de interatividade de um OA. Neste contexto, a interatividade refere-se ao grau de influência e o aspecto ou comportamental de um OA. Permite identificar se um OA é mais apropriado para um estudante ativo ou para um reflexivo.

Além desses campos da categoria Educacional, esta abordagem considera o campo *Structure* da categoria Geral e o campo *Format* da categoria Técnica.

- ❑ Structure: Este campo sugere a estrutura organizacional subjacente de um OA, e permite verificar se o OA é mais apropriado para um aluno global ou sequencial
- ❑ Format: Mostra o tipo de dados técnicos de um OA, e permite determinar se um OA pode ser recomendado para um aluno sensível. Além disso, pelo conteúdo deste campo é possível decidir se um OA deve ser recomendado para um estudante verbal ou visual. Também é possível identificar se um OA é mais apropriado a um estudante ativo ou reflexivo.

As recomendações devem sugerir conteúdo com base nas expectativas dos usuários, alguns sistemas de recomendação propostos por Cazella et al. (2012) visam auxiliar o usuário na busca e seleção de um conteúdo focado em seu perfil. Assim, o usuário terá como resultado de busca apenas os materiais mais próximos e relevantes.

3.5 Aprendizagem de Máquina

Aprendizagem de Máquina pode ser descrito como o desenvolvimento de técnicas computacionais sobre o aprendizado, bem como a construção de sistemas capazes de adquirir conhecimento de forma automática de acordo Mitchell (1997). A intuição humana não pode, nesse caso, ser totalmente abandonada, desde que o programador do sistema aponte os dados representados e o mecanismos usados para sua caracterização. Existem três tipos de aprendizado de máquina:

- ❑ Aprendizado supervisionado são treinados usando exemplos rotulados, como uma entrada onde a saída desejada é conhecida. Por exemplo, uma peça de equipamento pode ter pontos de dados rotulados com “F” (com falha) ou “R” (em funcionamento). O algoritmo de aprendizagem recebe um conjunto de entradas junto com as saídas

corretas correspondentes, e o algoritmo aprende comparando a saída real com as saídas corretas para encontrar erros. Em seguida, ele modifica o modelo de acordo;

- ❑ Aprendizado não supervisionado é usado contra dados que não possuem rótulos históricos. O sistema não sabe a “resposta certa”. O algoritmo deve descobrir o que está sendo mostrado. O objetivo é explorar os dados e encontrar alguma estrutura neles. O aprendizado não supervisionado funciona bem em dados transacionais;
- ❑ Aprendizado semi-supervisionado, é usado para as mesmas aplicações que o aprendizado supervisionado. Mas ele usa tanto os dados rotulados quanto os não rotulados para o treinamento, normalmente uma pequena quantidade de dados rotulados com uma grande quantidade de dados não rotulados (pois os dados não rotulados são mais baratos e precisam de menos esforço para serem adquiridos).

Logo, aplicar técnicas de classificação e reconhecimento de padrões aplicando estratégias de aprendizado de máquina para melhorar o processo de recomendação de conteúdo se torna um fator de relevância na área de educação (MICHALSKI; CARBONELL; MITCHELL, 2013).

A clusterização é uma técnica de aprendizagem de máquina para agrupamento de dados, utilizando algoritmos que avaliam a similaridade entre os atributos presentes nos dados. Com isso, pode-se dizer que elementos pertencentes a um determinado grupo possuem características semelhantes entre si. O fato de agrupar os dados representa uma abordagem inerente para uma melhor compreensão dos dados, sendo importante também para organizar dados similares.

Berkhin et al. (2006) afirmam que o agrupamento é a divisão de dados em grupos. Clusterização desempenha um papel importante em uma ampla gama de aplicações. As aplicações de agrupamento, geralmente, lidam com conjuntos de dados com atributos específicos. Clusterização é o agrupamento de dados usando algoritmos que avaliam a semelhança entre as características apresentadas por um conjunto de dados. Portanto, elementos pertencentes a um certo grupo ou cluster possuem características semelhantes. O agrupamento de dados é uma abordagem que permite a melhor compreensão dos dados, e também é importante organizar dados similares.

Pode ser definido também como um problema de aprendizado não supervisionado, já que a estrutura dos dados e as propriedades que os tornam similares são desconhecidas. O objetivo da clusterização é encontrar uma organização válida e conveniente dos dados, em vez de separá-los em categorias como acontece no reconhecimento de padrões e na classificação de dados Jain, Murty e Flynn (1999), podem observar as etapas de um processo de clusterização na Figura 13.

As etapas apresentadas são:

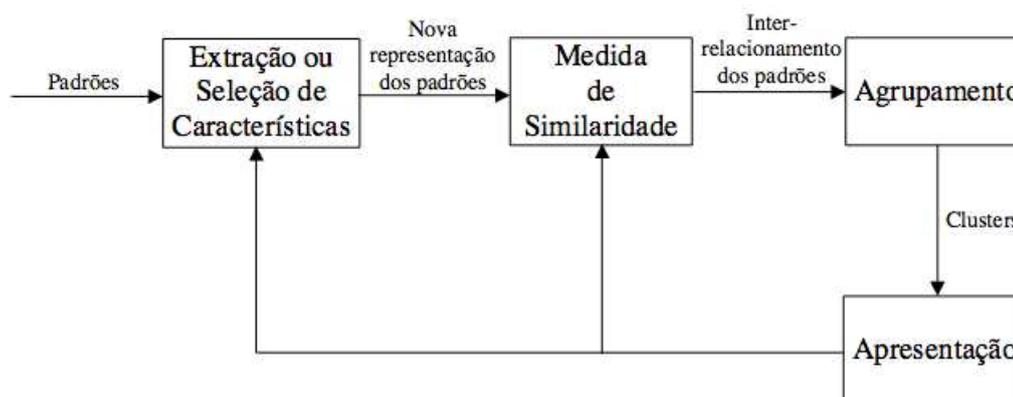


Figura 5 – Etapas do processo de clusterização, imagem de Jain, Murty e Flynn (1999)

- ❑ Seleção de Características: a seleção de características é um processo de identificação do subconjunto mais efetivo dos atributos disponíveis para descrever cada padrão e extração de características é o uso de uma ou mais transformações nos atributos de entrada de modo a exaltar uma ou mais características dentre aquelas que estão presentes nos dados. Qualquer uma ou ambas estas técnicas pode ser usada para obter um conjunto adequado de recursos para usar em agrupamentos
- ❑ Medida de Similaridade: para que a proximidade de dois dados possa ser calculada, é necessário adotar alguma medida de similaridade entre eles. Existem diversas maneiras de quantificar a similaridade, ou dissimilaridade, entre pares de dados. A escolha da medida de similaridade adequada ao problema é fundamental para a clusterização dos dados.
- ❑ Agrupamento: define-se o modo de agrupamento dos dados, que pode ser realizado de diferentes maneiras. Os algoritmos de clusterização são classificados de acordo com as diferentes técnicas empregadas no agrupamento dos dados. Dentre esses algoritmos destacam-se os algoritmos de clusterização hierárquica e os algoritmos por particionamento. Na clusterização por particionamento o conjunto de dados é dividido em um número determinado de clusters uma única vez, no particionamento hierárquico são produzidas diversas partições do conjunto de dados com base na junção ou divisão dos clusters, de acordo com a medida de similaridade.
- ❑ Apresentação/Validação: a qualidade dos clusters encontrados é avaliada, sendo que essa validação pode ser feita com base em índices estatísticos ou mediante por meio da comparação com outros algoritmos. Além disso, a análise dos resultados pode levar à redefinição dos atributos escolhidos e do cálculo de similaridade, definidos nas etapas anteriores.

O processo de agrupamento pode resultar em diferentes particionamentos de um conjunto de dados, dependendo do critério específico selecionado para o processo de clusters.

Assim, existe uma necessidade de pré-processamento antes de assumir uma tarefa de agrupamento em um conjunto de dados. Os passos básicos para desenvolver o processo de agrupamento são apresentados nas seguintes etapas: Seleção de Dados, Algoritmo de agrupamento, Validação dos Resultados e Interpretação dos Resultados (FAYYAD et al., 1996).

De acordo com MacQueen et al. (1967), a técnica mais clássica de agrupamento é chamada k-means. Primeiro, é especificado quantos clusters estão sendo considerados para agrupamento, sendo este o parâmetro k. Então, os pontos k são escolhidos aleatoriamente como centros de clusters. Todas as instâncias são atribuídas ao seu centro de cluster mais próximo de acordo com o métrica de distância euclidiana normal, em seguida, a média das instâncias em cada cluster é calculado entre os elementos. Após os cálculos de distância é atualizado os centroides com seus respectivos clusters. Finalmente, todo o processo é repetido com os novos centros de cluster. A iteração continua até todos os pontos são atribuídos a cada cluster em rodadas consecutivas, indicando que os centroides de cluster se estabilizaram e não possuem mais mudanças de elementos entre os clusters. Uma vez que a iteração se estabilizou, cada ponto é atribuído ao seu centro de cluster mais próximo. A abordagem k-means é um exemplo de um agrupamento de tarefas difíceis, em que cada ponto pode pertencer a apenas um cluster.

Outro algoritmo de clusterização bem conhecido é Expectation-Maximization (EM) que considera a atribuição de pontos para os clusters de modo que cada ponto tenha uma probabilidade de pertencer em um determinado cluster (DEMPSTER; LAIRD; RUBIN, 1977). Como o k-means, este é também um algoritmo para agrupamento de dados numéricos multidimensionais. O algoritmo EM é baseado em máxima probabilidade de verossimilhança. O objetivo do EM é encontrar parâmetros que maximizem a probabilidade de ter recebido medidas de uma variável aleatória distribuído por alguma função de densidade de probabilidade. A função de densidade de probabilidade é dado como um modelo da formula gaussiana. O objetivo do algoritmo EM é facilitar a estimativa do parâmetro de verossimilhança entre elementos.

Outra técnica bem conhecida, que é analisada neste trabalho são as redes de Kohonen ou *SELF ORGANIZED MAP* (SOM) (KOHONEN TEUVO, 1998). É um algoritmo de aprendizagem não supervisionado com uma estrutura simples que possui uma rede neural de aprendizado competitivo, no qual os neurônios de uma camada competem entre si pelo privilégio de permanecer ativos, onde um neurônio com maior atividade seja o único a participar do processo de aprendizado criando, assim clusters dos dados. Uma rede de Kohonen consiste em uma camada competitiva que pode classificar um conjunto de dados de entrada em forma de vetores com quaisquer dimensões usando um mapa.

O aprendizado competitivo é uma forma de aprendizagem não supervisionada no qual os neurônios competem pelo direito de responder a um subconjunto dos dados de entrada. Para o treinamento um vetor de peso associado a cada neurônio se move para se tornar o

centro de um conjunto dos vetores de entrada (VESANTO et al., 1999). Todos os vetores de peso são inicializados com pequenos valores aleatórios. Para cada padrão de entrada, os neurônios calculam seus respectivos valores de uma função discriminante (distância euclidiana, por exemplo) que fornece a base para a concorrência. O neurônio cujo vetor de peso é mais parecido com a entrada é chamada de melhor unidade de correspondência. Este neurônio é ajustado e atualizado para os neurônios mais próximos.

Neste sentido, a relevância os algoritmos de agrupamentos no contexto de organizar os conteúdos de aprendizagem se torna relevante e com grande potencial de obter bons resultados. Na abordagem deste trabalho, serão aplicados algoritmos de clusterização para agrupar os OAs para melhorar o processo de recomendação personalizada de conteúdo.

Proposta

Nesta abordagem foi realizado um estudo de como agrupar OAs com características similares e, a partir desse agrupamento poder recomendar conteúdo para um estudante conforme o seu EA correspondente. Nos próximos tópicos sera explicado como a criação da abordagem foi construída e executada.

4.1 Abordagem

A abordagem proposta apoia o processo de recomendação personalizado em AVAs, é baseado em técnicas de aprendizado de máquinas não supervisionado, especificamente a utilização de técnicas de mineração de dados através de algoritmos bem difundidos (PARK; KARGUPTA, 2002). O objetivo principal é agrupar OAs de acordo com os EAs suportados considerando o FSLSM. Analisando e organizando os OAs armazenados em repositórios é um problema crítico para recupera-los e usá-los eficientemente. Os processos de mineração de dados podem ser divididos em seis etapas sequenciais e iterativas (VESANTO; ALHONIEMI, 2000)

- ❑ definição de problema.
- ❑ aquisição de dados.
- ❑ pré-processamento e pesquisa de dados.
- ❑ modelagem de dados.
- ❑ avaliação.
- ❑ implantação de conhecimento.

Segundo Vesanto e Alhoniemi (2000) afirmam, o objetivo do processo é obter uma visão com possibilidades de recursos de dados e uma visão para o problema com intuito de determinar se os dados são suficientes para selecionar os atributos adequadas

no pré-processamento e modelagem. Normalmente vários conjuntos de dados diferentes e estratégias de pré-processamento devem ser consideradas. Por esta razão, visualizações eficientes e resumos são essenciais.

De acordo com Vesanto e Alhoniemi (2000), cada passo do processo de agrupamento é essencial, o problema define quais os dados utilizados e o que é uma boa solução. A modelagem dos dados possibilita a aplicação e resultados a novos dados, por outro lado, a modelagem de dados sem um bom entendimento do problema e uma análise cuidadosa dos dados, pode gerar problemas. Finalmente, todo o processo de mineração não tem sentido se o novo conhecimento a partir dos resultados não forem considerados.

Como os algoritmos clássicos em *cluster* geralmente funcionam em conjuntos de dados numéricos, uma ontologia foi empregada para representar os OAs como vetores numéricos, proporcionando aos algoritmos os dados e estruturas necessárias para serem agrupados. Neste contexto, foi criada uma metodologia para o desenvolvimento da abordagem, e foi definida da seguinte forma:

1. Estudar e analisar as propriedades EA, considerando a teoria de Felder e Silverman.
2. Estudo e análise de atributos e valores do padrão IEEE LOM
3. Definição de quais campos e valores de metadados pelos quais é possível classificar OAs de acordo com os EAs que eles apoiam.
4. Implementação de um conjunto de regras que represente as relações pedagógicas descobertas no passo anterior.
5. Utilização de ontologia para gerar uma representação vetorizada de OAs modelado no passo anterior.
6. Implementação de algoritmos de mineração para agrupamento automático de OAs, e sua representação vetorizada gerada no passo anterior, e análise dos resultados obtidos, a fim de determinar qual é a técnica mais eficiente desta proposta.
7. Teste da abordagem proposta em um repositório de OAs real.

Considerando as relações pedagógicas encontradas entre FLSM e o LOM, que são aplicados a seguir, um conjunto de regras foi implementado. Essas relações foram definidas de estudo cuidadoso e uma análise dos seguintes fundamentos de base: Felder e Silverman (1988) e IEEE (2002). O primeiro é voltado para avaliar as principais características e preferências de cada tipo de aluno e como eles preferem aprender. O segundo passo é o detalhe sobre os campos LOM e seus conceitos nos quais fornecem explicações semânticas sobre os metadados. Portanto, foi possível vincular ambas as teorias, a fim de fornecer suporte para entrega de conteúdo personalizado levando em conta os EAs dos alunos.

Structure	Format	Interactivity Type (IT)	Learning Resource Type (LRT)		Interactivity Level (IL)
1:Sequential(X):- Structure(X,"atomic"); Structure(X,"linear"). 2:Global(X):- Structure(X,"collection"); Structure(X,"networked"); Structure(X,"hierarchical").	3:Visual(X):- Format(X,"video"); Format(X,"image"); 4:Verbal(X):- Format(X,"text"); Format(X,"audio"); 5:Active(X):- Format(X,"application"). 6:Reflective(X):- Format(X,"video"); Format(X,"audio"); Format(X,"image").	7:Active(X):- IT(X,"active"); IT(X,"mixed"). 8:Reflective(X):- IT(X,"expositive"); IT(X,"mixed").	9:Active(X):- LRT(X,"exercise"); LRT(X,"simulation"); LRT(X,"questionnaire"); LRT(X,"exam"); LRT(X,"experiment"); LRT(X,"problem statem."); LRT(X,"self assessment"). 10:Reflective(X):- LRT(X,"diagram"); LRT(X,"figure"); LRT(X,"graph"); LRT(X,"index"); LRT(X,"slide"); LRT(X,"table"); LRT(X,"narrative text"); LRT(X,"lecture"). 11:Sensitive(X):- LRT(X,"simulation"); LRT(X,"figure"); LRT(X,"graph"); LRT(X,"index"); LRT(X,"table"); LRT(X,"experiment"); LRT(X,"self assessment").	12:Intuitive(X):- LRT(X,"diagram"). 13:Visual(X):- LRT(X,"diagram"); LRT(X,"figure"); LRT(X,"graph"); LRT(X,"experiment"). 14:Verbal(X):- LRT(X,"exercise"); LRT(X,"questionnaire"); LRT(X,"index"); LRT(X,"table"); LRT(X,"narrative text"); LRT(X,"exam"); LRT(X,"problem statem."); LRT(X,"self assessment"); LRT(X,"lecture").	15:Active(X):- IL(X,"medium"); IL(X,"high"); IL(X,"very high"). 16:Reflective(X):- IL(X,"very low"); IL(X,"low"); IL(X,"medium").

Figura 6 – Regras de mapeamento de metadados de OAs que satisfazem EAs do modelo FSLSM, extraído de Dorça et al. (2016)

A Figura 6 apresenta um conjunto de regras dividido em cinco subconjuntos que foram escritas em PROLOG. De acordo com o padrão IEEE LOM no qual foram analisados: *Structure*, *Format*, *Interactivity Type*, *Learning Resource Type* e *Interactivity Level*. Essas regras foram extraídas a partir de uma análise semântica detalhada do LOM. O foco desta análise semântica foi descobrir os campos e valores de LOM que possuem características pedagógicas, considerando o modelo de FSLSM.

As regras no campo nível de iteratividade do subconjunto indicam que um objeto de aprendizagem X é aderente a um aluno reflexivo se tiver nível de interatividade muito baixo, baixo ou médio, e que um objeto de aprendizagem X é aderente a um aluno ativo, se tiver nível de iteratividade médio ou alto, ou muito alto. Como é de conhecimento, estudantes ativos preferem atividades práticas, trabalho em grupo, discussões e experiências (conteúdo com alto nível de interatividade), enquanto estudantes reflexivos aprendem por meio da observação, introspectivamente, em uma relação passiva com o conteúdo (conteúdo com baixo nível de interatividade).

É importante notar que um subconjunto de LOM está sendo usado. Foi considerado um mínimo de regras do LOM que fornece informações suficientes sobre um OA que seja capaz de ser recomendado para um estudante considerando o EA. Este subconjunto é suficiente para caracterizar um OA de acordo com seu EA, permitindo que o sistema os recomende adequadamente aos estudantes. Portanto, para recomendar corretamente os OAs de acordo com o EAs dos alunos, é necessário conhecer sua estrutura, formato, tipo de interatividade, tipo de recurso de aprendizagem e nível de interatividade.

Estudantes sensitivos preferem fatos, dados, exemplos, experimentação e solução de

problemas por métodos padrão, conteúdo abordado de forma mais concreta. Estudantes intuitivos preferem princípios, teorias, modelos matemáticos e inovação (conteúdo mais abstrato) Felder e Silverman. Portanto, de acordo com a Figura 6, OAs que satisfazem estudantes sensitivos possuem características de simuladores, figuras, gráficos, índices, tabelas, experimentos e auto avaliações, considerando que eles podem trazer conteúdos mais concretos, conforme expressado pela regra 11. Diagramas podem ser recomendados para estudantes intuitivos, levando em conta que eles deveriam trazer conteúdo mais abstratos e os diagramas, geralmente, são usados para representar abstrações da realidade. Desta forma, esse tipo de OA é avaliado como mais apropriado para aprendizes intuitivos, como declarado pela regra 12.

Aprendizagem com característica ativo, aprender fazendo, é direcionada por conteúdo que trabalha diretamente na ação produtiva do aluno (FELDER; SILVERMAN, 1988). Os ativos incluem exercícios, simulações, questionários, exames, experiências, declarações de problemas. Este fato é expresso pelas regras 5, 7, 9 e 15 na 6. Aprendizagem reflexiva (por exemplo, aprendizagem passiva) ocorre quando o trabalho do aluno consiste principalmente em absorver o conteúdo exposto a ele (geralmente através de texto, imagens ou som), conforme expressado por regras 6, 8, 10 e 16. Um OA expositivo exibe informações, mas não leva o aluno para qualquer entrada semanticamente significativa. Os conteúdos expositivos incluem ensaios, vídeos, todos os tipos de material gráfico e documentos de hipertexto . Portanto, OAs com alto nível de interatividade são considerados mais adaptados aos alunos ativos, enquanto os OAs com baixo nível de interatividade são mais bem adaptados aos alunos reflexivos.

Um aluno pode ter preferência por informações transmitidas visualmente, consideradas como sendo um aluno visual, ou informações fornecidas como texto ou discurso, e neste caso o aluno é classificado como verbal, como afirmam Felder e Silverman (1988). Portanto, define-se esse material com conteúdo visual e gráfico dominante, como imagem, diagrama, figura, gráfico e os experimentos são adequados para estudantes visuais - como afirmado nas regras 3 e 13 na Figura 6. Material que possui mais conteúdo textual, como áudio, texto, formulários, questionários, entre outros, são adequados para estudantes verbais - como afirmam as regras 4 e 14.

À medida que os alunos sequenciais preferem o conteúdo exibido de forma progressiva e mais restrita a visualização, OAs com estrutura sequencial e apresentação linear são mais bem adaptados para esse tipo de aluno. Esse fato é modelado pela regra 1 na Figura 6. Os estudantes globais preferem OAs com estrutura em rede, que seja permitido uma visão geral e acesso flexível, como declarado pela regra 2.

Com o problema bem definido e os dados detalhados pode-se direcionar para o próximo passo. De acordo com Le, Smola e Vishwanathan (2008), é importante caracterizar os problemas de acordo com o tipo de dados que eles usam. Isto é ótimo, pois ajuda a encontrar novos desafios, já que muitas vezes problemas em tipos de dados semelhantes

pode ser resolvido com técnicas muito semelhantes. Os vetores são uma maneira muito eficiente de representar dados. Desta forma e proposta uma representação vetorial de OAs considerando como eles satisfazem os EAs dos alunos.

O modelo apresentado na Figura 7 é uma visão simplificada do processo de execução, no qual os OAs estão disponibilizados em um repositório em que posteriormente é executado o processo de vetorização utilizando uma ontologia e logo após é feito processamento dos vetores gerando os agrupamentos. Primeiramente, têm-se o repositório de dados contendo os OAs no padrão IEEE LOM no qual serão aplicados os algoritmos de clusterização, depois o processo de vetorização é executado e, por fim, têm-se os grupos resultantes.

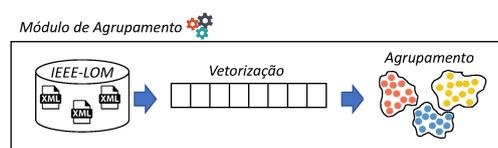


Figura 7 – Processo de Agrupamento de OAs.

Carvalho et al. (2016) propõem uma ontologia capaz de inferir de forma automática usando um conjunto de regras apresentadas na Figura 6. O resultado do processamento a ontologia é uma representação vetorial de OAs, levando em conta seus metadados e os EA relacionados a eles.

O vetor é composto por oito posições, em que cada posição representa a quantidade de regras na Figura 6 que são satisfeitas por um OA para cada um dos oito EA do FSLSM. Assim, torna-se possível agrupar OAs de acordo com EA e, conseqüentemente, suportar a recomendação personalizada de OAs.

A ontologia criada em Carvalho et al. (2016) possui uma classe OA na qual se contém cinco subclasses representando os campos do padrão *IEEE LOM: Structure, Format, Interactive Type, Interactivity Level* e *Learning Resource Type* que pode ser visto na Figura 6. Possui, também, a classe EA, que é composta apenas por indivíduos, onde cada indivíduo representado é um EA de Felder : Ativo, Reflexivo, Intuitivo, Sensitivo, Visual, Verbal, Sequencial e Global. Duas propriedades foram utilizadas *Object Property*, sendo: *has* os conceitos da classe OA e possui relação com suas subclasses, exemplo: *has(OA,video)*. Outro atributo é *is* que é utilizado na inferência dos EAs para cada valor pertencente aos OAs.

Com o uso de Ontologias, é possível ainda modelar regras em linguagens próprias, como a *Semantic Web Rule Language* SWRL (HORROCKS et al., 2004) e *Semantic Query-Enhanced Web Rule Language* SQWRL (O'CONNOR; DAS, 2009). Foram modeladas regras SQWRL para realizar uma contagem de quantas regras SWRL um OA é satisfeito para cada EA do modelo de Felder, gerando um vetor de 8 dimensões, onde cada dimensão

apresenta a quantidade de regras de inferência satisfeitas pelo OA para determinado EA. Todo processo foi denominado de vetorização.

Logo um OA que possui a regra 4 contabiliza um ponto em relação ao estilo Verbal. Um OA que atende as regras 2, 4, 8, 10, 11, 15 pode ser representando na Tabela 2. Esse vetor possui oito parâmetros que são EAs de Felder e Silverman: Sensitivo(Sen), Intuitivo(Int), Ativo(Ati), Reflexivo(Ref), Sequencial(Seq), Global(Glo), Visual(Vis), Verbal(Ver).

Tabela 2 – Vetorização de um Objeto de Aprendizagem

Objeto de Aprendizagem x Felder e Silverman							
Sen.	Int	Ati.	Ref.	Seq.	Glo.	Vis.	Ver.
1	0	2	1	0	1	0	1

Portanto, esse vetor representa um OA com características que podem atender um estudante que seja sensitivo, ativo, global e verbal. Para o processo de recomendação este pode ser um OA a ser recomendado a um estudante. Após a vetorização dos OAs e possível a execução dos algoritmos de agrupamento. No contexto deste trabalho podemos considerar que 16 *cluster* serão gerados no final do processo.

Dorça et al. (2013a) definem um combinação entre as dimensões de Felder, resultando 16 combinações possíveis, ou seja, 16 possíveis combinações de EAs. Para validar os resultados, foi criado um rótulo para cada agrupamento, como exemplo, um grupo que está nos EAs de Sensitivo, Ativo, Global e Verbal será representando da seguinte forma *SenAtiGloVer*. Portanto, nesta abordagem, são considerados 16 possíveis clusters executados pelos algoritmos, pelo fato de possuir quatro dimensões, e dentro de cada dimensão, são definidos dois estilos de aprendizagem conforme tabela 3.

Tabela 3 – Combinações de Felder e Silverman

Dimensão 1		Dimensão 2		Dimensão 3		Dimensão 4	
Ati.(A)	Ref.(R)	Sens(S)	Int.(I)	Vis.(Vi)	Verbal(Ve)	Seq.	Global(G)

Combinações de Estilos de Aprendizagem CEA = (A, Vi, S, Seq), (A, Vi, S,G), (R, Vi, S, Seq), (R, Vi,S,G), (A, Ve, S, Seq),(A, Ve, S,G),(R, Ve, S, Seq), (R, Ve, S,G), (A, Vi, I, Seq), (A, Vi, I,G), (R, Vi, I, Seq), (R, Vi, I,G), (A, Ve, I, Seq), (A, Ve, I,G), (R, Ve, I, Seq), (R, Ve, I,G).

Logo temos

Durante o processo de validação dos resultados, foram utilizadas duas ferramentas para auxiliar na execução dos algoritmos, Weka (HALL et al., 2009) e MatLab (VESANTO et al., 1999). Foram gerados 1600 registros fictícios e consistentes em relação as regras da Figura 1 6, aleatórios e sem ordem. Nestes registros, foram gerados 100 elementos para cada combinação de EAs.

4.2 Resultados

Para realizar os experimentos, foram executados três algoritmos de clusterização: K-Means, EM e SOM. Recorreu-se a um histograma para visualizar a quantidade de OAs classificadas em relação aos clusters. Conforme mostrado na Figura 8, pode-se observar que todos os algoritmos conseguiram clusterizar os OAs dentro das 16 combinações dos EAs.

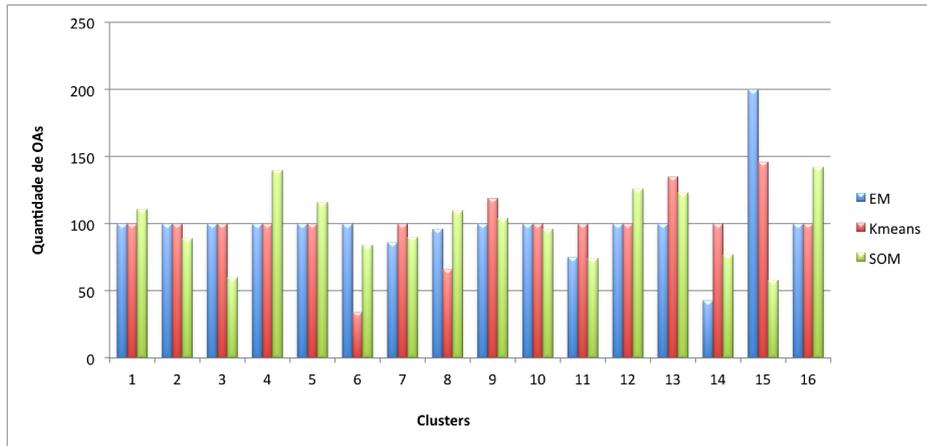


Figura 8 – Comparativo da quantidade de OAs em cada cluster.

Durante a execução da rede Neural SOM, foi utilizado um mapa 4x4 por serem esperados 16 *clusters*, considerando assim que cada neurônio representa um *cluster*. Em relação ao KMeans e EM, foi fixado o número de *cluster* em 16, visto que é necessário informar o número de grupos esperados nesses algoritmos. Com isso, pode-se dizer que houve coerência nos resultados obtidos inicialmente pois todos os OAs foram inseridos em grupos que eram esperados.

Para o *cluster* 15, foi obtida uma variância maior do que nos outros *cluster*, e pode ser observado mais adiante que o EA que difere neste *cluster* é o [Sen,Ati,Glo, Ber] e [Sen,Re,Glo,Ver], como os dados são fictícios e foram gerados valores de formas aleatórias para os metadados dos OAs, alguns casos podem ficar mais discrepantes. Contudo a validação de qualidade dos *cluster* informa que estes estão sendo bem agrupados.

Posteriormente, a qualidade de cada *cluster* foi avaliada aplicando métricas de validação como Pureza(P), que valida se existem diferentes elementos em cada *cluster*, e *F-Measure* (F), que avalia a qualidade de cada *cluster* com base nos cálculos de *precision* e *recall* (XIONG; WU; CHEN, 2009). As métricas (M) são apresentadas na Tabela 4.

Nesse contexto, com os dados apresentados na Tabela 4, os algoritmos K-Means e EM obtiveram melhores resultados pois possuem uma pureza e qualidade maior dos dados em cada *cluster*. O algoritmo SOM mostrou um alto grau de imprecisão nos *cluster*, pois as métricas mostram que cada *cluster* ficaram distribuídas pela metade, de modo geral. Logo, a utilização do K-Means e do EM se mostram favoráveis para o modelo. Sendo

Tabela 4 – Validação dos resultados da clusterização

KMeans			EM			SOM		
C	Qtd	Classes	Qtd	Classes	Qtd	Classes		
1	100	SenRefGloVis	100	SenRefGloVis	111	IntRefSeqVis , IntRefGloVis		
2	100	SenRefSeqVis	100	IntRefSeqVer	89	IntRefGloVis , IntRefSeqVis		
3	100	IntAtiGloVis	100	SenAtiGloVis	60	IntAtiSeqVis , IntAtiGloVis		
4	100	IntAtiGloVer	100	IntAtiGloVer	140	IntAtiGloVis , IntAtiSeqVis		
5	100	IntRefGloVer	100	IntAtiSeqVer	116	SenRefSeqVis , SenRefGloVis		
6	34	SenAtiGloVis	100	IntRefSeqVis	84	SenRefGloVis , SenRefSeqVis		
7	100	SenAtiSeqVer	86	SenAtiSeqVer	90	SenAtiSeqVis , SenAtiGloVis		
8	66	SenAtiGloVis	96	IntAtiSeqVis	110	SenAtiGloVis , SenAtiSeqVis		
9	119	IntRefSeqVis , IntAtiSeqVis	100	SenRefSeqVer	104	SenRefGloVer , SenRefSeqVer		
10	100	SenAtiGloVer	100	IntRefGloVis	96	SenRefSeqVer , SenRefGloVer		
11	100	SenAtiSeqVis	75	SenAtiSeqVis , IntAtiSeqVis	74	SenAtiSeqVer , SenAtiGloVer		
12	100	IntRefGloVis	100	IntRefGloVer	126	SenAtiGloVer , SenAtiSeqVer		
13	135	IntAtiSeqVis , IntAtiSeqVer	100	IntAtiGloVis	123	IntRefSeqVer , IntRefGloVer		
14	100	SenRefGloVer	43	SenAtiSeqVis , SenAtiSeqVer	77	IntRefGloVer , IntRefSeqVer		
15	146	IntRefSeqVer , IntAtiSeqVer	200	SenAtiGloVer , SenRefGloVer	58	IntAtiSeqVer , IntAtiGloVer		
16	100	SenRefSeqVer	100	SenRefSeqVis	142	IntAtiGloVer , IntAtiSeqVer		
M	P: 0,945	F: 0,923	P:0,945	F: 0,928	P: 0,562	F : 0,553		

assim, o EM será utilizado pois levou um pequena vantagem com a métrica F em relação ao K-means.

Para a recomendação com EM, é calculado o Grau de Pertinência(GP) que um determinado OA possui em um *cluster*, conforme a Tabela 5. O GP é a forma de representar o quanto um elemento pertence a um determinado grupo com base na similaridade. Com esta informação, é possível recomendar para um estudante um determinado conteúdo que seja similar aquele grupo, possibilitando recomendar OAs diferentes, mesmo estando em *clusters* diferentes.

Tabela 5 – Grau de Pertinência

C	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
16	0.05	0	0.07	0.01	0.04	0	0	0.03	0	0.01	0.01	0	0	0.01	0.01	0.82

Neste exemplo na Tabela 5, tem-se a representação final de um OA utilizando EM no qual este elemento pertence fortemente ao *cluster* 16, porém vale ressaltar que este elementos possui um pouco de características que poderiam ser utilizadas em outros clusters. Logo, para o processo de recomendação, estes dados podem ser úteis para um determinado cenário onde não existe OAs no *cluster* 3 por exemplo, o recomendador pode fazer um ranking de melhores OAs a serem recomendados com base nestes resultados.

Portanto, essa abordagem se mostra promissora para uma recomendação de conteúdo automática, personalizada com base em OAs e EAs de Felder. Conforme os resultados apresentados, esta abordagem está em direção para a recomendação de conteúdo em diferentes AVAI tornando os sistemas mais inteligentes e personalizados.

Estudo de Caso

Um estudo de caso em uma plataforma com OAs reais foi implementado e está sendo empregado como ferramenta complementar de aprendizagem em uma universidade federal brasileira de ensino superior. A plataforma, chamada de Classroom eXperience (CX) (FERREIRA et al., 2012), utiliza conceitos de computação ubíqua para dar suporte à preparação do material pelo professor (fase chamada de pré-produção), gravar as aulas ministradas em sala de aula (fase chamada de gravação ao vivo) e disponibilizá-las, posteriormente, aos estudantes de forma personalizada (fase chamada de acesso).

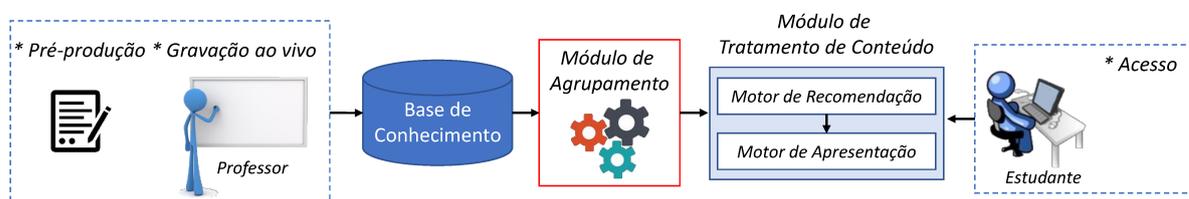


Figura 9 – Proposta de implantação

A Figura 9 mostra uma visão de geral da integração do módulo de agrupamento proposto neste trabalho na plataforma em questão. A plataforma gera OAs para cada aula ministrada e os armazena em uma base de conhecimento, que serve de entrada para o módulo proposto. Uma vez executado e com o agrupamento gerado, esse módulo serve como entrada de dados para o módulo de tratamento de conteúdo do CX, no qual motores de recomendação e apresentação se encarregam de aplicar algoritmos especializados para apresentação personalizada do conteúdo aos estudantes.

A arquitetura do CX possui módulos responsáveis pela geração de OAs já associados com EAs do modelo FLSM, representação das características dos estudantes por meio de um modelo de estudante que também contempla seu EA e um módulo responsável pela personalização e recomendação de OAs.

5.1 Autoria de Objetos

Em Araújo et al. (2014), foi proposta uma abordagem de criação de OAs de forma automatizada a partir da interação do estudante com o sistema, no qual foram definidas algumas etapas:

O processo de captura do sistema está estruturado em cinco fases na Figura 10

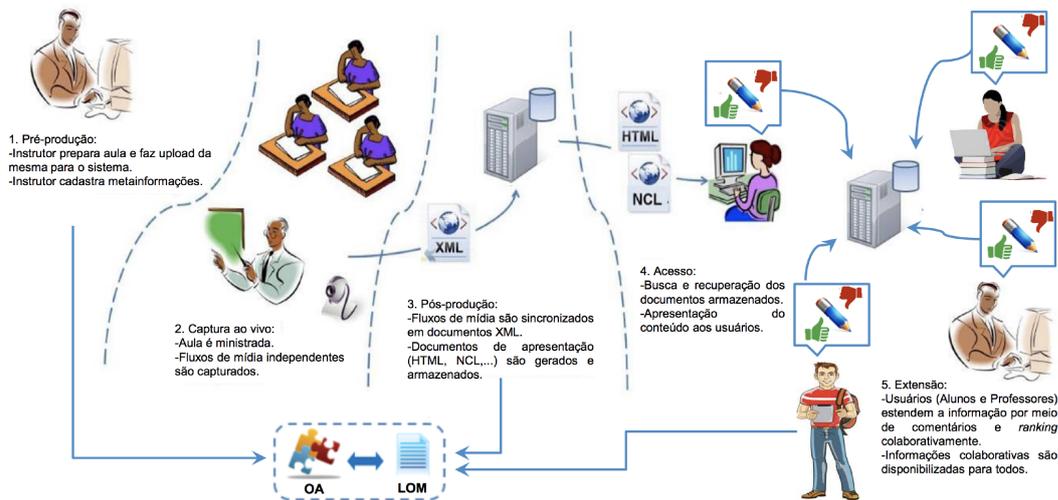


Figura 10 – Processamento de aulas

- ❑ 1: pré-produção, que consiste na preparação do conteúdo para captura, parte em que o professor cria um aula e realiza o salvamento do conteúdo da aula no sistema.
- ❑ 2: gravação “ao vivo”, em que múltiplos fluxos de informação são capturados de dispositivos espalhados pelo ambiente. Todas interações entre professores, alunos e a matéria apresentado são registradas para utilização posterior.
- ❑ 3: pós-produção, em que os fluxos capturados na fase anterior são sincronizados e integrados; Todas interações salvas no passo 2 são processadas e guardadas na base de dados para que possam ser apresentadas ao alunos com as interações da aula.
- ❑ 4: acesso, responsável por disponibilizar aos usuários o conteúdo previamente capturado. Neste momento, os usuários possuem acesso aos conteúdos gerados durante as aulas.
- ❑ 5: extensão, fase responsável por classificar slides e processo de informações colaborativas entre alunos e professores.

Araújo et al. (2016) criaram uma abordagem que, para a segmentação de OAs em Ambientes Educacionais utilizando a funcionalidade de bookmarks colaborativos, que pode são disponíveis tanto por estudantes e professores durante o processo de captura

e acesso da aula captura. Ao acessar a aula capturada, estudantes e professores podem definir seus subtópicos, denominados marcadores de tópicos. A funcionalidade de criação de um novo *bookmark* prove um mecanismo de autocompletar contextual ao digitar um título para o marcador, baseado no conjunto de bookmarks já criados por outros usuários para a aula em questão. Em complemento, também é possível definir valores para o campo de metadado *Learning Resource Type* (LRT) de cada slide indicando o tipo do seu conteúdo, tal como: enunciado, imagem, tabela, exercício, entre outros.

5.2 Modelagem do Estudante

O Modelo de estudante é uma estrutura responsável por armazenar as características do aluno com o objetivo de representar o estudante do mais próximo possível da realidade, ou seja, contendo informações que representam cada indivíduo. Um Sistema Adaptativo e Inteligente para Educação está ligado à qualidade do modelo do estudante. Um sistema pode possuir as melhores e eficientes estratégias para adaptação do conteúdo de maneira personalizada de acordo com o perfil do aluno, mas se as inferências do modelo do estudante sobre suas preferências estiverem incorretas resultados ruins são obtidos (SOSNOVSKY; ISOTANI; MCLAREN,).

Um estudante que tem uma tendência forte para a característica Visual não exclui o fato de que também é possível o aprendizado com uma característica Reflexiva ou Verbal. Assim este trabalho tem como desafio exibir uma proposta para a vetorização dos OAs considerando seus metadados. Assim é possível modelar os estudantes de forma probabilística e dinâmica, que estocasticamente se enquadre a essas categorias pedagógicas ao longo do processo de aprendizagem com maior ou menor probabilidade dentro das 16 categorias possíveis.

Tabela 6 – Estudante

Estilos de Aprendizagem							
Percepção		Processamento		Entrada		Organização	
Sen.	Int.	Ati.	Ref.	Vis	Ver.	Seq.	Glob.
17.0	83.0	35.0	65.0	80.0	20.0	84.0	16.0

De acordo com a Tabela 6, o estudante possui 17 por cento de probabilidade de preferência pelo estilo Sensitivo e 83 pelo estilo Intuitivo, na dimensão Percepção. Na dimensão Processamento, possui 35 por cento de preferência pelo estilo Ativo e 65 por cento Reflexivo. Já na dimensão Entrada, ele apresenta 80 por cento de preferência pelo estilo Visual e 20 pelo Verbal. Por fim, a dimensão Organização, o estudante tem 84 por cento da preferência pelo estilo Sequencial e 16 pelo Global. Então, é possível afirmar que, provavelmente, trata-se de um estudante Reflexivo, Intuitivo, Visual e Sequencial.

Neste contexto, o maior vantagem desta abordagem é a de considerar estocasticamente todas combinações de EAs de acordo com os alunos supondo que os EAs podem mudar ao longo do tempo (DORÇA et al., 2013a). A proposta se baseia na teoria das cadeias de Markov (MC), que é um sistema matemático que modela as mudanças de estado entre um número finito de possíveis estados, e eles são muitas vezes descrito por um grafo direcionado, onde as bordas são rotulados pelas probabilidades de ir de um estado para os outro (MEYN; TWEEDIE, 2009).

As probabilidades dos EA presentes no modelo do estudante podem ser definidas a partir de dados obtidos no questionário, como o *Index of Learning Styles Questionnaire* ILSQ compatível com o modelo FSLSM, ou inicializando igualmente cada EA com o valor de 50 por cento (DORÇA et al., 2013b).

Os resultados obtidos por meio do ILSQ para cada dimensão do FSLSM podem ser classificados de acordo com a diferença entre a quantidade de respostas dos EA. Valores de diferença entre 1 e 3 correspondem a uma preferência leve por um estilo; entre 5 e 7 indica preferência moderada por um deles; e entre 9 e 11 indicam forte preferência por um estilo (FELDER; SPURLIN, 2005).

Neste trabalho são consideradas as respostas do ILSQ para a modelagem do estudante no qual o aluno ao logar no sistema abre uma tela pedindo para responder as perguntas.

5.3 Resultados

Durante o primeiro semestre de 2017, foram gerados 865 OAs relacionados com a disciplina Interação Humano-Computador (IHC), ministrada em na Universidade Federal de Uberlândia para alunos de graduação em Ciência da Computação e Sistemas de Informação. Os OAs referentes a cada uma das aulas da disciplina foram submetidos ao algoritmo EM, uma vez que este obteve bom desempenho nos experimentos com dados sintéticos.

Inicialmente, o algoritmo foi implementado para o cenário de uma aula no qual foi gerado, em na média, três *clusters*. O algoritmo também foi executado considerando todos os OAs da disciplina IHC, ou seja todas aulas de uma disciplina. Nesse cenário, 13 *clusters* foram gerados no total. A Figura 11 apresenta a quantidade de regras atendidas para cada um dos oito EAs em cada *cluster*.

Podem observar, na Figura 11 os números de regras atendidas em cada *cluster* representado por uma barra vertical de 8 cores que representam as dimensões de Felder e Silverman. As regras atendidas em cada *cluster* mostra que a eficiência da abordagem para agrupar OAs considerando os EAs.

Com base no agrupamento de OAs realizado, é possível reduzir a quantidade de material a ser selecionado em um processo de recomendação. O ambiente virtual de aprendizagem pode, então, selecionar um dos *clusters* que mais se enquadra nas características

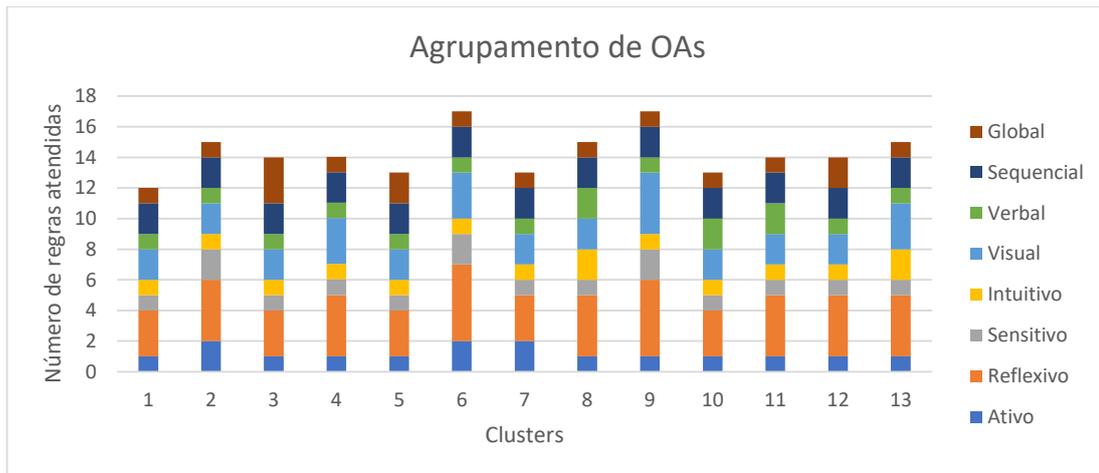


Figura 11 – Agrupamento de OAs da disciplina IHC gerados pela plataforma CX.

de EA de um estudante em específico para recomendar materiais adicionais de forma individualizada.

Portanto, um processo de recomendação se torna mais eficiente pois ao invés de ter que percorrer toda uma lista todos OAs de um repositório o sistema de recomendação pode simplesmente acessar um grupo com características específicas ao estudante, no qual o estudante poderá ter mais facilidade de aprendizagem pois estes OAs possui elementos de conteúdo relacionados ao seu EA.

Em uma segunda disciplina, é possível necessitar de materiais adicionais (extra) mas que são relacionados com a disciplina de IHC para sugerir a um determinado estudante com características que acentuam os EAs Reflexivo e Visual. Nesse caso, os OAs presentes no *cluster* de número 9 poderiam ser selecionados para serem sugeridos. É possível, ainda, executar algum algoritmo de ranqueamento para selecionar apenas os OAs desse *cluster* que mais façam sentido naquele momento para o estudante, o que caracteriza um apoio a recomendação.

Pode-se observar que o algoritmo possui algumas limitações nesse repositório específico, quando um repositório possui pouca diversidade de OAs, os números de *cluster* encontrados são menores, o que resulta para este cenário um baixo aproveitamento dos *clusters* gerados,

Entretanto a abordagem se mostrou eficiente ao agrupar os OAs relacionados aos seus EAs pois foram obtidos vários *cluster* possíveis.

Conclusão

O rápido desenvolvimento da tecnologia forneceu a possibilidade de desenvolver AVAI. Esses sistemas baseados em técnicas de Inteligência Artificial com o objetivo de melhorar a representação e proporcionar aprendizagem que esteja mais adaptada às necessidades reais de cada aluno. AVAI é um recurso interessante para apoiar atividades de ensino-aprendizagem, tais ambientes utilizam técnicas inteligentes para adaptar o conteúdo educacional às necessidades reais dos alunos. O objetivo é proporcionar uma experiência de aprendizado mais personalizada e individualizada. Esses sistemas devem ser capazes de gerar caminhos de aprendizagem para os alunos, com base em seus conhecimentos prévios, atividades e preferências. Em outras palavras, um AVAI deve oferecer personalização às necessidades específicas, conhecimento e experiência de cada aluno (FERREIRA et al., 2016).

Neste contexto, este trabalho apresentou uma abordagem para apoiar a recuperação e a recomendação de OAs que melhor se encaixam em cada aluno específico, considerando a grande variação de perfis de alunos e o grande número de OAs a serem analisados. Como resultado, obteve-se uma abordagem automática e dinâmica para o agrupamento de OAs, considerando o EA tratado pelos estudantes. Para este fim, realizou-se uma análise detalhada sobre as propriedades de cada EA no FSLSM. Além disso, um estudo detalhado do IEEE LOM, incluindo seus campos e propriedades, possibilitando descobrir quais campos e valores do LOM poderiam trazer informações relacionadas ao EA relacionado a um OA específico.

Este trabalho tem como principal contribuição a organização dos OAs de um sistema educacional, contribuindo com o processo de recomendação de conteúdo. A utilização de OAs e EAs facilita o processo de ensino e aprendizagem, apoia o tutor para gerar melhores conteúdos e ajuda também o aluno com a proposta de recomendar conteúdo que sejam mais habituais com as características dos perfis. Logo, existe a relevância em avaliar estratégias para recomendação de conteúdo para facilitar e apoiar os usuário em sistema adaptativos inteligentes.

O desafio em fornecer os OAs mais adequados para diferentes alunos, levando em conta

seus EAs é baseado no fato de que existe uma ampla variedade de estudantes com perfis diferentes, com uma variedade diferentes de preferências, resultando em vários modelos possíveis. Esta condição pode ser ainda mais desafiadora ao considerar que os repositórios têm um número elevado de OAs que devem ser analisado antes de serem recomendados. Neste contexto, a necessidade de um mecanismo efetivo de análise automática de OAs se torna um fator com grande contribuição.

É importante ressaltar a comparação entre três técnicas visando a melhor clusterização. Foi possível identificar a melhor técnica com sucesso utilizando métricas de validações consistentes. Desta forma, a abordagem proposta pode contribuir muito com o processo de recomendação personalizada de conteúdo em AVAI, pois resultados promissores foram obtidos durante os experimentos.

Pode-se observar que a relevância dos OAs em relação aos EAs são muito importantes pelo fato de que um estudado tem mais facilidade em aprender conforme seu perfil. Com isso é possível facilitar o processo de recomendação personalizada de conteúdo considerando EAs em ambientes educacionais.

6.1 Trabalhos Futuros

Como trabalho futuro, é preciso avaliar como foi o impacto nos estudantes e quanto melhoraram os resultados dos estudantes durante o semestre. Precisa ser elaborado uma forma de comparar o processo como um todo anterior ao modelo aplicado.

Como esta abordagem pode-se identificar que processos de aprendizado de maquina podem ajudar muito os processo entre processamento de conteúdo até a entrega deste para os estudantes, podendo ser aplicado em diferentes etapas do processo de ensino-aprendizagem.

Portanto, utilizar aprendizado de máquina para o perfil dos estudantes, conteúdos gerados na aula, acessos de navegação são abordagens que podem ser avaliadas e discutidas para um trabalho futuro.

6.2 Contribuições em Produção Bibliográfica

Na sequência, são apresentadas as produções bibliográficas resultantes desta pesquisa. Inicialmente, foi criado um artigo para o evento do CSBC 2016 com uma ideia inicial sobre o estudo: Mendes, M. M., de Carvalho, V. C., Dorça, F. A., Cattelan, R. G. (2016). Uma Abordagem para a Organização Automática de Objetos de Aprendizagem em Ambientes Educacionais Ubíquos com Base em Estilos de Aprendizagem. ANAIS DO CSBC, 5.

Posteriormente, com resultados fictícios da abordagem foi publicado o artigo no EVENTO LACLO 2017:

Mendes, M. M., Carvalho, V. C., Araújo, R. D., Dorça, F. A., Cattelan, R. G. (2017, October). Clustering learning objects in the IEEE-LOM standard considering learning styles to support customized recommendation systems in educational environments. In Learning Technologies (LACLO), 2017 Twelfth Latin American Conference on (pp. 1-8). IEEE.

Por fim foi publicada uma extensão do artigo anterior :

Mendes, M., Carvalho, V., Dorça, F., Araújo, R. D., and Cattelan, R. (2017, October). Agrupamento e Recomendação de Objetos de Aprendizagem no Padrão IEEE-LOM Considerando Estilos de Aprendizagem. In Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE) (Vol. 28, No. 1, p. 1217).

Referências

ALMEIDA, M. E. B. d. Educação a distância na internet: abordagens e contribuições dos ambientes digitais de aprendizagem. 2003. Disponível em: <www.scielo.br/pdf/ep-v29n2/a10v29n2.pdf>, 2011.

ARAÚJO, R. D. et al. Segmentação Colaborativa de Objetos de Aprendizagem Utilizando Bookmarks em Ambientes Educacionais Ubíquos. **Anais do 27º Simpósio Brasileiro de Informática na Educação**, SBC, Uberlândia, MG, BR, p. 1205–1214, 2016. Disponível em: <<https://doi.org/10.5753/cbie.sbie.2016.1205>>.

_____. Autoria automática de objetos de aprendizagem a partir de captura multimídia e associação a estilos de aprendizagem. **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**, v. 25, n. 1, p. 229, 2014.

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.

BERKHIN, P. et al. A survey of clustering data mining techniques. **Grouping multidimensional data**, v. 25, p. 71, 2006.

BETTIO, R. de; MARTINS, A. Objetos de aprendizado: um novo modelo direcionado ao ensino a distância. **9o. Congresso Internacional de Educação a Distância**, 2002.

CARVALHO, V. et al. Uma ontologia para apoio à recomendação automática e personalizada de conteúdo considerando estilos de aprendizagem de estudantes em sistemas adaptativos para educação. **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**, v. 27, n. 1, p. 1175, 2016. Disponível em: <<https://doi.org/10.5753/cbie.sbie.2016.1175>>.

CARVER, C. A.; HOWARD, R. A.; LANE, W. D. Enhancing student learning through hypermedia courseware and incorporation of student learning styles. **IEEE transactions on Education**, v. 42, n. 1, p. 33–38, 1999.

CASAGRANDE, M. F. R.; KOZIMA, G.; WILLRICH, R. Técnica de recomendação baseada em metadados para repositórios digitais voltados ao ensino. **Revista Brasileira de Informática na Educação**, v. 23, n. 02, p. 70, 2015. Disponível em: <<https://doi.org/10.5753/rbie.2015.23.02.70>>.

CAZELLA, S. C. et al. Desenvolvendo um sistema de recomendação de objetos de aprendizagem baseado em competências para a educação: relato de experiências. **Anais do Simpósio Brasileiro de Informática na Educação**, v. 23, n. 1, 2012.

_____. Recomendação de objetos de aprendizagem empregando filtragem colaborativa e competências. **Simpósio Brasileiro de Informática na Educação (SBIE)**, 2009.

DEMPSTER, A. P.; LAIRD, N. M.; RUBIN, D. B. Maximum likelihood from incomplete data via the em algorithm. **Journal of the royal statistical society. Series B (methodological)**, JSTOR, p. 1–38, 1977.

DORÇA, F. A. et al. An automatic and dynamic approach for personalized recommendation of learning objects considering students learning styles: an experimental analysis. **Informatics in education**, v. 15, n. 1, p. 45, 2016.

_____. 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.

_____. Automatic student modeling in adaptive educational systems through probabilistic learning style combinations: a qualitative comparison between two innovative stochastic approaches. **Journal of the Brazilian Computer Society**, v. 19, n. 1, p. 43–58, 2013.

_____. Comparing strategies for modeling students learning styles through reinforcement learning in adaptive and intelligent educational systems: An experimental analysis. **Expert Systems with Applications**, v. 40, n. 6, p. 2092–2101, 2013.

FABRE, M.-C. J.; TAMUSIUNAS, F.; TAROUÇO, L. M. R. Reusabilidade de objetos educacionais. **RENOTE**, v. 1, n. 1, 2003.

FAYYAD, U. M. et al. Advances in knowledge discovery and data mining. the MIT Press, 1996.

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

FELDER, R. M.; SPURLIN, J. Applications, reliability and validity of the index of learning styles. **International journal of engineering education**, v. 21, n. 1, p. 103–112, 2005.

FELFERNIG, A. et al. Persuasive recommendation: serial position effects in knowledge-based recommender systems. **Persuasive technology**, Springer, p. 283–294, 2007.

FERREIRA, H. N. M. et al. Classroom experience: a platform for multimedia capture and access in instrumented educational environments. **Collaborative Systems (SBSC), 2012 Brazilian Symposium on**, p. 59–64, 2012.

_____. An automatic and dynamic student modeling approach for adaptive and intelligent educational systems using ontologies and bayesian networks. **Tools with Artificial Intelligence (ICTAI), 2016 IEEE 28th International Conference on**, p. 738–745, 2016.

FERREIRA, V.; VASCONCELOS, G. Recomendações de recursos educacionais baseadas em aprendizagem de máquina para autorregulação da aprendizagem. **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**, v. 28, n. 1, p. 1557, 2017.

FRANZONI, A. L. et al. Student learning styles adaptation method based on teaching strategies and electronic media. **Advanced Learning Technologies, 2008. ICALT'08. Eighth IEEE International Conference on**, p. 778–782, 2008. Disponível em: <<https://doi.org/10.1109/ICALT.2008.149>>.

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

GLUZ, J. C.; VICARI, R. M. Milos: Infraestrutura de agentes para suporte a objetos de aprendizagem obaa. **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**, v. 1, n. 1, 2010.

HALL, M. et al. The weka data mining software: an update. **ACM SIGKDD explorations newsletter**, ACM, v. 11, n. 1, p. 10–18, 2009.

HARMAN, K.; KOOHANG, A. Learning objects: standards, metadata, repositories, and lcms. **Informing Science**, 2007.

HEERY, R.; ANDERSON, S. Digital repositories review. **Joint Information Systems Committee**, 2005.

HODGINS, W.; DUVAL, E. et al. Draft standard for learning object metadata (1484.12.1). **IEEE**, v. 1484, p. 1–2002, 2002.

HONEY, P.; MUMFORD, A. et al. The manual of learning styles. **Peter Honey Maidenhead**, 1992.

HORROCKS, I. et al. Swrl: A semantic web rule language combining owl and ruleml. **W3C Member submission**, v. 21, p. 79, 2004.

IEEE. IEEE Standard for Learning Object Metadata. **IEEE Std 1484.12.1-2002**, p. i–32+, 2002.

JAIN, A. K.; MURTY, M. N.; FLYNN, P. J. Data clustering: a review. **ACM computing surveys (CSUR)**, v. 31, n. 3, p. 264–323, 1999.

KOHONEN TEUVO, P. Self-organizing maps of symbol strings. **Neurocomputing**, Elsevier, v. 21, n. 1, p. 19–30, 1998.

KOLB, A. Y.; KOLB, D. A. Learning styles and learning spaces: Enhancing experiential learning in higher education. **Academy of management learning & education**, v. 4, n. 2, p. 193–212, 2005.

LE, Q. V.; SMOLA, A. J.; VISHWANATHAN, S. Bundle methods for machine learning. **Advances in neural information processing systems**, p. 1377–1384, 2008.

MACQUEEN, J. et al. Some methods for classification and analysis of multivariate observations. **Proceedings of the fifth Berkeley symposium on mathematical statistics and probability**, v. 1, n. 14, p. 281–297, 1967.

- MÉNDEZ, N. D. D.; MORALES, V. T.; VICARI, R. M. Learning object metadata mapping with learning styles as a strategy for improving usability of educational resource repositories. **IEEE Revista Iberoamericana de Tecnologías del Aprendizaje**, v. 11, n. 2, p. 101–106, 2016.
- MEYN, S.; TWEEDIE, R. L. Markov chains and stochastic stability. prologue by peter w. glynn. cambridge mathematical library. **Cambridge: Cambridge University Press**. xviii, 2009. Disponível em: <<https://doi.org/10.1017/CBO9780511626630>>.
- MICHALSKI, R. S.; CARBONELL, J. G.; MITCHELL, T. M. Machine learning: An artificial intelligence approach. Springer Science & Business Media, 2013.
- MITCHELL, T. M. Machine learning. 1997. **Burr Ridge, IL: McGraw Hill**, v. 45, n. 37, p. 870–877, 1997.
- MUSTARO, P.; SILVEIRA, I. Learning objects: Adaptive retrieval through learning styles. **Interdisciplinary Journal of E-Learning and Learning Objects**, v. 2, n. 1, p. 35–46, 2006.
- O’CONNOR, M.; DAS, A. Sqwrl: a query language for owl. **Proceedings of the 6th International Conference on OWL: Experiences and Directions-Volume 529**, p. 208–215, 2009.
- PARK, B.-H.; KARGUPTA, H. Distributed data mining: Algorithms, systems, and applications. **Citeseer**, 2002.
- PEÑA, C. I. et al. Un sistema de tutoría inteligente adaptativo considerando estilos de aprendizaje. **Revista UIS ingenierías**, v. 1, n. 2, p. 17–29, 2002.
- RIDING, R.; RAYNER, S. Cognitive styles and learning strategies: Understanding style differences in learning and behavior. **Routledge**, 2013.
- ROLIM, V. et al. Um estudo sobre sistemas de recomendação de recursos educacionais. **Anais dos Workshops do Congresso Brasileiro de Informática na Educação**, v. 6, n. 1, p. 724, 2017.
- SANTOS, H. dos et al. Recomendação de objetos de aprendizagem utilizando filtragem colaborativa: Uma comparação entre abordagens de pré-processamento por meio de clusterização. **Anais do Simpósio Brasileiro de Informática na Educação**, v. 26, n. 1, p. 1127, 2015. Disponível em: <<https://doi.org/10.5753/cbie.sbie.2015.1127>>.
- SILVA, E. L. da; CAFÉ, L.; CATAPAN, A. H. Os objetos educacionais, os metadados e os repositórios na sociedade da informação. **Ciência da Informação**, v. 39, n. 3, 2011.
- SILVA, M. et al. Modelando um sistema educacional de mmc sob a perspectiva da web semântica. **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**, v. 1, n. 1, 2009.
- SILVA, M. d. G. M. Novas aprendizagens. senac. **São Paulo**, 2004.
- SOSNOVSKY, S.; ISOTANI, S.; MCLAREN, B. Evaluating a bayesian student model of decimal misconceptions.
- TORRÃO, S. Produção de objectos de aprendizagem para e-learning. **TecMinho**, 2007.

- TORRES, T. Z.; AMARAL, S. F. do. Aprendizagem colaborativa e web 2.0: proposta de modelo de organização de conteúdos interativos. **Educação Temática Digital**, v. 12, p. 49, 2011. Disponível em: <<https://doi.org/10.20396/etd.v12i0.1203>>.
- VESANTO, J.; ALHONIEMI, E. Clustering of the self-organizing map. **Neural Networks, IEEE Transactions on**, Ieee, v. 11, n. 3, p. 586–600, 2000.
- VESANTO, J. et al. Self-organizing map in matlab: the som toolbox. **Proceedings of the Matlab DSP conference**, v. 99, p. 16–17, 1999.
- WEISER, M. The computer for the 21st century. **SIGMOBILE Mob. Comput. Commun. Rev.**, ACM, New York, NY, USA, v. 3, n. 3, p. 3–11, jul. 1999. ISSN 1559-1662. Disponível em: <<http://doi.acm.org/10.1145/329124.329126>>.
- WILEY, D. A. Instructional use of learning objects. **Agency for Instructional Technology**, 2001.
- XIONG, H.; WU, J.; CHEN, J. K-means clustering versus validation measures: a data-distribution perspective. **Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on**, IEEE, v. 39, n. 2, p. 318–331, 2009.
- ZAINA, L. et al. e-lors: Uma abordagem para recomendacao de objetos de aprendizagem. **Revista Brasileira de Informática na Educação**, v. 20, n. 1, p. 04, 2012.

Anexos

Algoritmo Expectation Maximization

Algorithm 1 The EM algorithm

```

EM_algorithm(D, k,  $\xi$ ) {
  calculates initial guess of profile  $\theta$ 
  do {
     $z \leftarrow E - step(\theta^{(t-1)}, D)$ 
     $\theta^{(t)} \leftarrow M - step(Z^{(t)}, D)$ 
    calculate likelihood( $\theta^{(t)}$ )

    } while likelihood( $\theta^{(t)}$ ) - likelihood( $\theta^{(t-1)}$ ) <  $\xi$ 
  return  $\theta$ 
}
```

Figura 12 – Algoritmo EM

Algoritmo K-means

K-means algorithm

```

K-MEANS ( $\mathbf{D}, k, \epsilon$ ):
1  $t = 0$ 
2 Randomly initialize  $k$  centroids:  $\mu_1^t, \mu_2^t, \dots, \mu_k^t \in \mathbb{R}^d$ 
3 repeat
4    $t \leftarrow t + 1$ 
5    $C_j \leftarrow \emptyset$  for all  $j = 1, \dots, k$ 
   // Cluster Assignment Step
6   foreach  $\mathbf{x}_j \in \mathbf{D}$  do
7      $j^* \leftarrow \operatorname{argmin}_i \{ \|\mathbf{x}_j - \mu_i^t\|^2 \}$  // Assign  $\mathbf{x}_j$  to closest centroid
8      $C_{j^*} \leftarrow C_{j^*} \cup \{ \mathbf{x}_j \}$ 
   // Centroid Update Step
9   foreach  $i = 1$  to  $k$  do
10     $\mu_i^t \leftarrow \frac{1}{|C_i|} \sum_{\mathbf{x}_j \in C_i} \mathbf{x}_j$ 
11 until  $\sum_{i=1}^k \|\mu_i^t - \mu_i^{t-1}\|^2 \leq \epsilon$ 

```

Figura 13 – Algoritmo Kmeans