
**OntAES: Uma Ontologia para Sistemas
Adaptativos Educacionais Baseada em Objetos
de Aprendizagem e Estilos de Aprendizagem**

Vitor César de Carvalho



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

Uberlândia
2017

Vitor César de Carvalho

**OntAES: Uma Ontologia para Sistemas
Adaptativos Educacionais Baseada em Objetos
de Aprendizagem e Estilos de Aprendizagem**

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

2017

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

C331o
2017 Carvalho, Vitor César de, 1993
 OntAES : uma ontologia para sistemas adaptativos educacionais
 baseada em objetos de aprendizagem e estilos de aprendizagem / Vitor
 César de Carvalho. - 2017.
 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.2017.78>
 Inclui bibliografia.

 1. Computação - Teses. 2. Web semântica - Teses. 3. Aprendizagem
 - Teses. 4. Ontologias (Recuperação da informação) - 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 – UFU
FACULDADE DE COMPUTAÇÃO – FACOM
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA
COMPUTAÇÃO – PPGCO

Os abaixo assinados, por meio deste, certificam que leram e recomendam para a Faculdade de Computação a aceitação da dissertação intitulada **“OntAES: Uma Ontologia para Sistemas Adaptativos Educacionais Baseada em Objetos de Aprendizagem e Estilos de Aprendizagem”** por **Vitor César de Carvalho** como parte dos requisitos exigidos para a obtenção do título de **Mestre em Ciência da Computação**.

Uberlândia, 17 de Outubro de 2017.

Orientador: _____

Prof. Dr. Fabiano Azevedo Dorça
Universidade Federal de Uberlândia (FACOM/UFU)

Banca Examinadora:

Profa. Dra. Márcia Aparecida Fernandes
Universidade Federal de Uberlândia (FACOM/UFU)

Prof. Dr. Sérgio Crespo Coelho da Silva Pinto
Universidade Federal Fluminense (Departamento de Ciência da
Computação)

Aos meus pais.
Ao meu irmão.
Aos meus amigos.
À Deus.

Agradecimentos

Para a finalização deste trabalho, muitas pessoas foram essenciais. Gostaria de agradecer especialmente:

À Deus, que em sua infinita misericórdia e sabedoria me concedeu forças para prosseguir na luta pela finalização de minha pesquisa.

Ao Prof. Dr. Fabiano Azevedo Dorça, meu orientador, pela confiança durante todos esses anos de trabalho, pelo auxílio e pelos conselhos que algumas vezes ultrapassaram a barreira e me ajudaram a manter a calma e paciência.

Ao Prof. Dr. Renan Cattelan, que ofereceu um espaço em seu laboratório e auxiliou na produção de diversos trabalhos.

Aos amigos e companheiros de pesquisa, Rafael, Hiran, Taffarel e Miller, pelos conselhos, discussões, pelas brincadeiras que concederam várias boas risadas e pelo companheirismo também presente fora do laboratório.

Aos meus pais, que me deram suporte para continuar seguindo em frente no meu trabalho. Agradeço também por suas palavras de grande sabedoria nos momentos mais oportunos.

Ao meu irmão e familiares, pelo apoio, solidariedade e companheirismo, mesmo nos momentos que estive ausente, também pelos momentos de diversão em festas, bares e jogos.

Aos velhos amigos Diego, Tiago, Alexandre, Guilherme, Victor, Diego, Nágilla e Ruyano, que estiveram presentes sempre, mesmo que por pensamento torcendo pela minha conquista.

Aos amigos conquistados nesses anos de mestrado, que compartilharam suas experiências, dificuldades, conquistas e bons momentos comigo.

Aos membros da banca examinadora, por aceitarem o convite.

À CAPES, pelo apoio financeiro por vários meses de pesquisa.

Aos professores da Faculdade de Computação por passar seu conhecimento que foi imprescindível em todo o percurso desses anos de caminhada.

E, por fim, à todos aqueles que torceram e ainda torcem pelo meu sucesso.

*“A persistência é o caminho do êxito.”
(Charles Chaplin)*

Resumo

Diversas abordagens para recomendação personalizada de conteúdo em sistemas adaptativos para educação têm surgido. Muitas têm congado a importância de levar em consideração os estilos de aprendizagem do estudante para que melhores resultados possam ser alcançados no processo de aprendizagem. Estudos recentes comprovam essa tendência.

Este trabalho tem como objetivo apresentar uma proposta de recomendação de objetos de aprendizagem com base no padrão IEEE LOM e no modelo de Estilos de Aprendizagem de Felder-Silverman. Além disso, foi desenvolvida uma ontologia para apoio à essa abordagem.

Como resultado, a ontologia proposta gera uma representação vetorial de objetos de aprendizagem considerando os estilos de aprendizagem satisfeitos por eles. A ontologia, denominada OntAES acompanha todo o processo de ensino, desde a inserção de OAs e estudantes no sistema, até a classificação e ranqueamento de forma personalizada e automática.

Além disso, apresenta uma abordagem comparativa entre forma de calcular o ranking de OAs para cada estudante. A ontologia foi validada através de experimentos, e resultados promissores foram obtidos, demonstrando o potencial de contribuição desta proposta a sistemas adaptativos para educação.

Palavras-chave: Estilos de Aprendizagem, Objetos de Aprendizagem, Recomendação Automática, Personalização Automática, Ontologia, Web Semântica.

Abstract

Several approaches to custom recommendation of content in adaptive systems for education have emerged. Many have conglomerated the importance of taking into account student learning styles so that better results can be achieved in the learning process. Recent studies confirm this trend.

This research aims to present a proposal for the recommendation of learning objects based on the IEEE LOM standard and the Felder-Silverman Learning Styles model. In addition, an ontology has been developed to support this approach.

As a result, the proposed ontology generates a vector representation of learning objects considering the learning styles satisfied by them. The ontology, called OntAES, follows the entire teaching process, from the insertion of OAs and students into the system, to classification and ranking in a personalized and automatic way.

In addition, it presents a comparative approach between how to calculate the OA ranking for each student. The ontology was validated through experiments, and promising results were obtained, demonstrating the potential contribution of this proposal to adaptive systems for education.

Keywords: Learning Styles, Learning Object, Recommendation, Automatic Customization, Ontology, Semantic Web.

Lista de ilustrações

Figura 1 – Representação do Modelo de Felder.	29
Figura 2 – Categorias dos metadados do IEEE LOM. (MACHION, 2007)	31
Figura 3 – As camadas da Web Semântica (KOIVUNEN; MILLER, 2001)	32
Figura 4 – Exemplo de arquitetura de Sistemas de Tutores Inteligentes	38
Figura 5 – Exemplo de regra de inferência genérica em Prolog.	40
Figura 6 – Listagem das regras para mapeamento dos campos do LOM em EA's.	42
Figura 7 – Tela inicial do protótipo	49
Figura 8 – Lista de OAs do repositório do protótipo	50
Figura 9 – Modelo do estudante utilizado no experimento	55
Figura 10 – Modelo do estudante utilizado no experimento	55
Figura 11 – Classificação probabilística do OA 42 em FSLSM.	56
Figura 12 – Classificação probabilística do OA 39 em FSLSM.	56
Figura 13 – Classificação probabilística do OA 21 em FSLSM.	57
Figura 14 – Classificação probabilística do OA 24 em FSLSM.	57

Lista de tabelas

Tabela 1 – Tabela de estilos do Modelo Felder-Silverman (adaptada de Franzoni et al. (2008)).	30
Tabela 2 – Comparação entre os trabalhos correlatos a proposta de trabalho. . . .	35
Tabela 3 – Exemplo de Modelo Probabilístico de Estudante	37
Tabela 4 – Mapeamento dos campos do IEEE LOM para os EAs do FSLSM. . . .	39
Tabela 5 – Mapeamento dos valores do CLEO para os EAs do FSLSM.	41
Tabela 6 – Exemplo de metadado de OA	41
Tabela 7 – Exemplo de contagem de regras verdadeiras para cada EA.	42
Tabela 8 – Exemplo de classificação do OA no modelo probabilístico	43
Tabela 9 – Exemplo do cálculo da pontuação e da distância de um OA para determinado estudante.	43
Tabela 10 – Classes da ontologia e suas respectivas subclasses.	45
Tabela 11 – Classes e indivíduos pertencentes a Ontologia.	46
Tabela 12 – Exemplos de regras SWRL construídas	46
Tabela 13 – Regras SQWRL modeladas	47
Tabela 14 – Lista de Combinações de EAs do FSLSM.	50
Tabela 15 – Conjunto de Estudantes 1	51
Tabela 16 – Conjunto de Estudantes 2	51
Tabela 17 – Experimento com estudantes do CE1 com repositório 1 de OAs. . . .	52
Tabela 18 – Experimento com estudantes do CE2 com repositório 1 de OAs. . . .	52
Tabela 19 – Experimento com estudantes do CE1 com repositório 2 de OAs. . . .	53
Tabela 20 – Experimento com estudantes do CE2 com repositório 2 de OAs. . . .	53

Lista de siglas

AVA	Ambiente Virtual de Aprendizagem
CX	<i>Classroom eXperience</i>
CLEO	<i>Customized Learning Experience Online</i>
EA	Estilo de Aprendizagem
FBC	Filtragem Baseada em Conteúdo
FC	Filtragem Colaborativa
FSLSM	<i>Felder-Silverman Learning Style Model</i> - Modelo de Estilos de Aprendizagem de Felder e Silverman
IA	Inteligência Artificial
LOM	<i>Learning Object Metadata</i>
M101	Metodologia 101
OA	Objeto de Aprendizagem
OntAES	<i>Ontology for Adaptive Educational Systems</i>
OWL	<i>Web Ontology Language</i>
QC	Questão de Competência
RDF	<i>Resource Description Framework</i>
SAIE	Sistemas Adaptativos e Inteligentes para Educação
SQWRL	<i>Semantic Query-Enhanced Web Rule Language</i>
SWRL	<i>Semantic Web Rule Language</i>

SR	Sistema de Recomendação
STI	Sistemas de Tutores Inteligentes
UFU	Universidade Federal de Uberlândia
W3C	World-Wide Web Consortium
WS	Web Semântica
XML	<i>eXtensible Markup Language</i>

Sumário

1	INTRODUÇÃO	23
1.1	Objetivos e Desafios da Pesquisa	25
1.2	Contribuições	25
1.3	Organização da Dissertação	25
2	FUNDAMENTAÇÃO TEÓRICA	27
2.1	Sistemas Tutores Inteligentes	27
2.2	Técnicas de Recomendação	28
2.3	Estilos de Aprendizagem e o Modelo de Felder-Silverman	29
2.4	Objetos de Aprendizagem, o Padrão IEEE Learning Object Metadata e extensões	30
2.5	Web Semântica	32
2.6	Ontologias	33
2.7	Trabalhos Relacionados	34
2.7.1	Análise comparativa	35
3	ONTAES	37
3.1	Classificação e Recomendação de Objetos de Aprendizagem	38
3.2	OntAES: Ontology for Adaptive Educational Systems	43
4	EXPERIMENTOS E ANÁLISE DOS RESULTADOS	49
4.1	Experimentos	49
4.1.1	Experimento 1	52
4.1.2	Experimento 2	53
4.1.3	Experimento Questões de Competência	54
5	CONCLUSÃO	59
5.1	Principais Contribuições	60
5.2	Trabalhos Futuros	60

5.3	Contribuições em Produção Bibliográfica	60
-----	---	----

	Referências	61
--	-----------------------	----

	ANEXOS	65
--	---------------	-----------

ANEXO A	– PUBLICAÇÕES BIBLIOGRÁFICAS	67
---------	--	----

Introdução

É cada vez mais comum observarmos o uso do computador no processo de ensino/aprendizagem. O crescimento desta prática deve muito ao fato do aumento nos cursos de ensino a distância (EAD) oferecidos nas últimas duas décadas (PRETI, 2007). Surgiu então a necessidade de se construir sistemas voltados para o ensino, que facilitassem tanto o trabalho do professor, quanto o do estudante.

Nas tentativas de oferecer algum suporte personalizado ao ensino, foram propostas arquiteturas que evoluíram até os chamados Sistemas de Tutores Inteligentes (STIs). Brusilovsky, Schwarz e Weber (1996) cita que os STIs possuem duas principais características, que são o sequenciamento de conteúdo personalizado e o suporte à solução interativa de problemas.

Estas características tornam os STIs diferentes das outras arquiteturas, já que incorporam técnicas e procedimentos inteligentes que os permitem atuar de forma semelhante a um tutor humano. Na sua descrição clássica, os STIs possuem os seguintes módulos: modelo do estudante, módulo pedagógico, módulo do domínio do conhecimento, modelo do especialista e módulo de comunicação ou interface.

É interessante também, que esses sistemas tragam abordagens de recomendação para aumentar ainda mais a adaptabilidade do curso para os estudantes. O uso de recomendação automática de conteúdo auxilia os estudantes na escolha de quais materiais estudar, onde, com o auxílio do sistema, o aprendiz aproveita apenas os materiais que melhor serão aproveitados por ele.

Essa escolha automática pode ser baseada em diversos fatores, porém, Graf et al. (2007) cita que os estudantes tendem a aprender melhor se o estilo de ensino do conteúdo for compatível com os seus Estilos de Aprendizagem (EA). EA pode ser definido como características de como o aprendiz absorve uma nova informação, algo que muitas vezes não é perceptível a ele (REID, 1998).

O modelo de EA proposto por Felder e Silverman (1988) é amplamente utilizado na área de pesquisa da educação, por trazer uma representação eficiente de estudantes reais em um modelo computacional facilmente processado por sistemas computacionais.

O *Felder-Silverman Learning Style Model* (FSLSM) como é comumente chamado, foi utilizado em diversos sistemas e por isso é seguro dizer que possui extensa experimentação, que comprova sua eficiência.

Ao conteúdo apresentado pelos STIs, damos o nome de Objeto de Aprendizagem (OA), que são recursos virtuais utilizados no ensino, como vídeos, imagens e textos que tem por objetivo trazer informação e conteúdo a ser assimilado por um aprendiz (WILEY, 2002). Porém, para que seja possível se utilizar um OA, é necessário que este possua um arquivo de descrições de seus dados, os chamados metadados.

Existem diversos padrões de metadados, como o DublinCore (WEIBEL et al., 1998), o *Sharable Content Object Reference Model* (SCORM) (BOHL et al., 2002) e o *LTSC/IEEE Learning Object Metadata* (LOM) (IEEE, 2002), utilizado neste trabalho. Esses padrões garantem que os OAs possuem algumas características importantes, como a Interoperabilidade, a Acessibilidade e a Durabilidade.

Os arquivos de metadados são também importantes para que o computador consiga processar informações sobre os Objetos de Aprendizagem, visto que estes são criados para que humanos o entendam. Em geral são construídos a partir de arquivos *eXtensible Markup Language* (XML) (BRAY et al., 1998) que surgiram graças a invenção da Web Semântica (WS).

A WS veio como um esforço para dar semântica a Web convencional, de forma a permitir que sistemas pudessem processar e trabalhar com os dados que encontramos na rede mundial de computadores. Dentre as tecnologias trazidas pelo desenvolvimento da WS, podemos destacar as ontologias.

Ontologias, por definição, são formas que temos para especificar e descrever conceitos, bem como as relações que existem ente eles (GRUBER, 1993). Em trabalhos voltados a educação, ontologias podem ser utilizadas para representar modelos de estudante ou ainda, OAs.

Ao modelar os metadados em uma ontologia, temos a posse de uma rede semântica rica em informações que nos oferece suporte a geração de regras de inferência poderosas em linguagens como *Semantic Web Rule Language* (SWRL) e *Semantic Query-Enhanced Web Rule Language* (SQWRL). Fazendo uso dessas linguagens e de outras tecnologias da WS, podemos construir uma poderosa abordagem de recomendação diferente das convencionais, pois aproveita dos significados dados aos itens apresentados pelo sistema.

Assim, este trabalho procura construir uma abordagem mista de recomendação de objetos de aprendizagem com metadados produzidos no padrão IEEE LOM, tomando por base estudantes descritos pelo FSLSM. Além disso, a abordagem aproveitará de uma ontologia que modela todo o processo, desde a representação dos OAs, até a recomendação propriamente dita.

1.1 Objetivos e Desafios da Pesquisa

O **objetivo geral** do trabalho descrito neste plano é propor, implantar e analisar uma estratégia eficiente para recomendar conteúdo de ensino a estudantes. Para tanto, será proposto uma abordagem de recomendação que leve em consideração objetos de aprendizagem com metadados no padrão IEEE LOM, que recebe uma ontologia para ser usada como base da proposta, facilitando a sua reprodução.

Este objetivo geral pode ser melhor especificado nos seguintes **objetivos específicos**:

- ❑ Propor um mapeamento entre o padrão IEEE LOM e o FSLSM.
- ❑ Propor regras de inferência baseadas no mapeamento desenvolvido.
- ❑ Propor e validar uma modelagem de ontologia que sirva como base para todo o processo de recomendação.
- ❑ Propor, a partir da ontologia modelada, uma representação vetorial dos objetos de aprendizagem, levando em consideração as regras de inferência desenvolvidas.
- ❑ Realizar experimentos e estudos de caso para validar a estratégia criada.

1.2 Contribuições

O trabalho tem como proposta a modelagem e avaliação de uma abordagem de recomendação tomando por base tecnologias e padrões conhecidos. Assim, as principais contribuições esperadas são:

- ❑ Uma modelagem totalmente dinâmica para sistemas de recomendação que seja flexível quanto ao domínio de conhecimento da aplicação.
- ❑ Uma arquitetura baseada em sistemas tutores inteligentes que acompanhe o processo de aprendizagem do estudante, desde a obtenção do conteúdo à apresentação personalizada deste ao aprendiz.

1.3 Organização da Dissertação

Este trabalho tem a seguinte organização textual:

- ❑ O Capítulo 2 trata de conceitos que devem estar claros para um bom entendimento do trabalho
- ❑ O Capítulo 3 mostra como foi desenvolvido o trabalho

- ❑ O Capítulo 4 mostra experimentos realizados após o desenvolvimento e analisa alguns aspectos de seus resultados
- ❑ E, por fim, o Capítulo 5 traz uma conclusão geral do que pode ser tirado do trabalho, além de expor ideias para possíveis trabalhos futuros.

Fundamentação Teórica

Serão apresentados nesta seção, conceitos necessários à compreensão deste trabalho.

2.1 Sistemas Tutores Inteligentes

Inicialmente, percebeu-se que o computador poderia ser usado no processo de ensino/aprendizagem. Assim, começaram a surgir os Ambientes Virtuais de Aprendizagem (AVA), que são ferramentas computacionais que tem como objetivo auxiliar o professor na apresentação do conteúdo de um certo domínio que se deseja ensinar.

Porém, percebeu-se que os estudantes possuem um melhor desempenho no aprendizado se o conteúdo lhes é apresentado de forma personalizada. Foi quando surgiram os Sistemas de Tutores Inteligentes (STIs) (SOUZA, 2000).

Os STIs são sistemas que procuram raciocinar sobre o domínio e as habilidades do estudante para então simular a atenção dada por um tutor humano. Das tarefas básicas dos STIs, temos: aquisição de dados sobre o usuário, processamento de dados, construção ou atualização do modelo do estudante e a utilização deste modelo na atualização do sequenciamento do conteúdo apresentado (personalização automática do curso). O formato básico de um STI contém 5 módulos, que são:

❑ Módulo do Domínio.

Este módulo é o responsável por descrever o conhecimento ao qual o STI abrange. É nele onde estão presentes as competências sobre o objeto de domínio do STI.

❑ Módulo de Estudante.

Módulo que define para o Sistema como o estudante vai ser representado no sistema. Assim, ele armazena as informações sobre comportamento, desempenho, conhecimento e, se presentes no sistema, os estilos cognitivos do aprendiz.

❑ Módulo de Ensino.

É o módulo responsável por aplicar as medidas corretivas, ou seja, auxiliar o estudante a reforçar o que aprendeu ou deveria aprender na lição e/ou aula feita. Geralmente através de um feedback. Wenger (1987) diz que “o aprendizado é uma sequência de transições entre estados do conhecimento, o propósito do ensino é, portanto, auxiliar a travessia dos alunos entre esses estados” e diz que para este fim, o STI deve conseguir alternar entre suporte diagnóstico e didático.

□ Módulo Especialista.

Seu objetivo é analisar como os estudantes expressam seus conhecimentos sobre o domínio da aplicação. Para tal, ele compara as soluções dos estudantes com as disponíveis no módulo do domínio.

□ Módulo de Interface com o Usuário.

Fornece os meios para que o estudante interaja com o STI.

Esse tipo de sistema, se enquadra também dentro do conceito de Sistema Adaptativo e Inteligente para Educação (SAIE), sendo uma de suas subdivisões. E é ainda, dentre todos, o tipo de Sistema mais utilizado nas pesquisas, por se enquadrar bem na maioria dos casos onde se precisa desenvolver um programa que auxilie o aprendizado.

2.2 Técnicas de Recomendação

Em geral, as técnicas de recomendação são utilizadas para identificar padrões de comportamento e utilizá-los como auxílio na interação personalizada com o usuário. Assim, com a ajuda dessas técnicas, é possível que os sistemas apresentem informações diferentes aos vários tipos de usuários que os utilizam. Dentre as técnicas mais conhecidas, podemos destacar as que fazem Filtragem Baseada em Conteúdo (FBC), a Filtragem Colaborativa (FC) e também uma abordagem mista entre elas.

Os sistemas que empregam FBC utilizam de informações anteriores do usuário em relação a um item para recomendar itens similares. Em geral, os itens recomendados são aqueles que tem maior correspondência com que foram acessados previamente e que ao mesmo tempo, são avaliados pelo sistema positivamente (CAZELLA; NUNES; REATEGUI, 2010).

Já aqueles que utilizam de FC levam em consideração as escolhas feitas por usuários que possuem semelhanças ao do utilizador. Assim, com um histórico de decisões feitas, é possível obter médias para os itens e recomendar aquelas que possuem as maiores avaliações (CAZELLA; NUNES; REATEGUI, 2010).

No contexto da educação, os Sistemas de Recomendação (SR) são usados para recomendar materiais didáticos, auxiliando assim os alunos que estão em busca de adquirir

conhecimento, mas também os professores, que podem utilizar deles para apresentar um curso personalizado ao aprendiz (AGUIAR et al., 2014).

2.3 Estilos de Aprendizagem e o Modelo de Felder-Silverman

É fácil perceber que cada estudante possui particularidades na forma com que prefere estudar determinados conceitos. A essas particularidades, chamamos de Estilos de Aprendizagem (EA).

Felder e Silverman (1988) em seus estudos, identificaram um total de oito EAs, divididos em quatro dimensões, como é apresentado na Figura 1. Assim, criaram um dos modelos mais utilizados em sistemas de ensino para representação dos estilos cognitivos dos estudantes, o qual chamaremos de *Felder-Silverman Learning Style Model* (FSLSM).

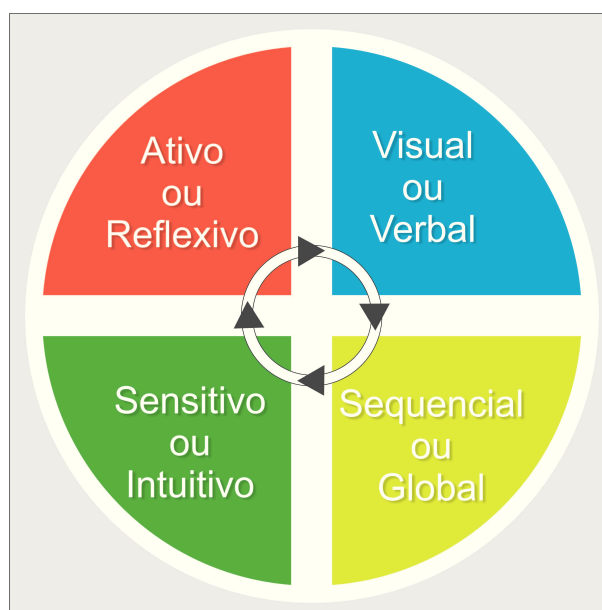


Figura 1 – Representação do Modelo de Felder.

Os EAs do FSLSM não são mutuamente exclusivos, onde cada indivíduo pode ser representado pela combinação de um estilo para cada uma das quatro dimensões, num total de 16 combinações. Este modelo é muito usado por dar a base para representar o perfil dos estudantes em Sistemas Adaptativos e Inteligentes para Educação (SAIE) (GRAF et al., 2007). Na Tabela 1 estão descritas como se identificar as diferenças de cada EA.

Tabela 1 – Tabela de estilos do Modelo Felder-Silverman (adaptada de Franzoni et al. (2008)).

Dimensão do Estilo de Aprendizagem	Tipo	Descrição
Percepção	Sensitivo (S)	Sabe lidar com fatos, dados puros e experimentos, é paciente com os detalhes, mas não gosta de complicações.
	Intuitivo (I)	Sabe lidar com princípios e teorias, fica facilmente entediado quando são apresentados muitos detalhes e tende a aceitar complicações.
Canal de Entrada	Visual (Vi)	Se lembra bem do que viu: imagens, diagramas, tabelas temporais, filmes, etc.
	Verbal (Ve)	Se lembra do que escutou, leu ou disse.
Processamento	Ativo (A)	Aprende bem em grupo e com o material que tem em mãos.
	Reflexivo (Re)	Aprende melhor quando pensa e reflete sobre a informação dada a ele. Trabalha melhor sozinho ou com no máximo mais uma pessoa.
Entendimento	Sequencial (Seq)	Segue um raciocínio linear quando está resolvendo problemas e pode trabalhar com material específico uma vez que compreende ele parcialmente ou superficialmente.
	Global (G)	Tem grandes intuições sobre a informação, pode ter dificuldade de expor como chegou a certo resultado, precisa de uma visão geral.

Dentre os motivos para o uso frequente deste modelo de EAs, pode-se destacar o fato de ser baseado em extensa experimentação (DORÇA et al., 2013). Graf et al. (2009) relata também que os EAs podem ser usados para melhorar o modelo de aluno em sistemas educacionais para fornecer adaptabilidade mais precisas e holísticas.

2.4 Objetos de Aprendizagem, o Padrão IEEE Learning Object Metadata e extensões

Os Objetos de Aprendizagem (OAs) possuem diferentes definições. Uma das mais clássicas, dada por Wiley (2002), descreve os OAs como entidades digitais que tem como objetivo o ensino e podem ser disponibilizadas pela Web e acessadas simultaneamente por um grande número de usuários.

Em geral, um OA deve possuir os seguintes atributos: Interoperabilidade, Acessibilidade e Durabilidade. Interoperabilidade, que é a capacidade de se usar um OA feito em sistemas diferentes daqueles para qual foram criados. Acessibilidade, pois, é preciso que o OA tenha capacidade de serem utilizados remotamente e, Durabilidade, que é a possibilidade de utilizar um OA, sem reprojetado ou recriação, mesmo quando a base tecnológica muda.

Para que essas características se mantenham, é necessário que haja um padrão, como o LOM (IEEE, 2002). O LOM é composto por 68 elementos hierarquizados, divididos em 9 categorias, que descrevem a semântica dos metadados de um OA. Na Figura 2 é possível ver todos os elementos do IEEE LOM, entretanto, neste trabalho utilizou-se apenas 5

desses elementos, são eles: *Structure*, *Format*, *Interactivity Type*, *Learning Resource Type* e *Interactivity Level*.

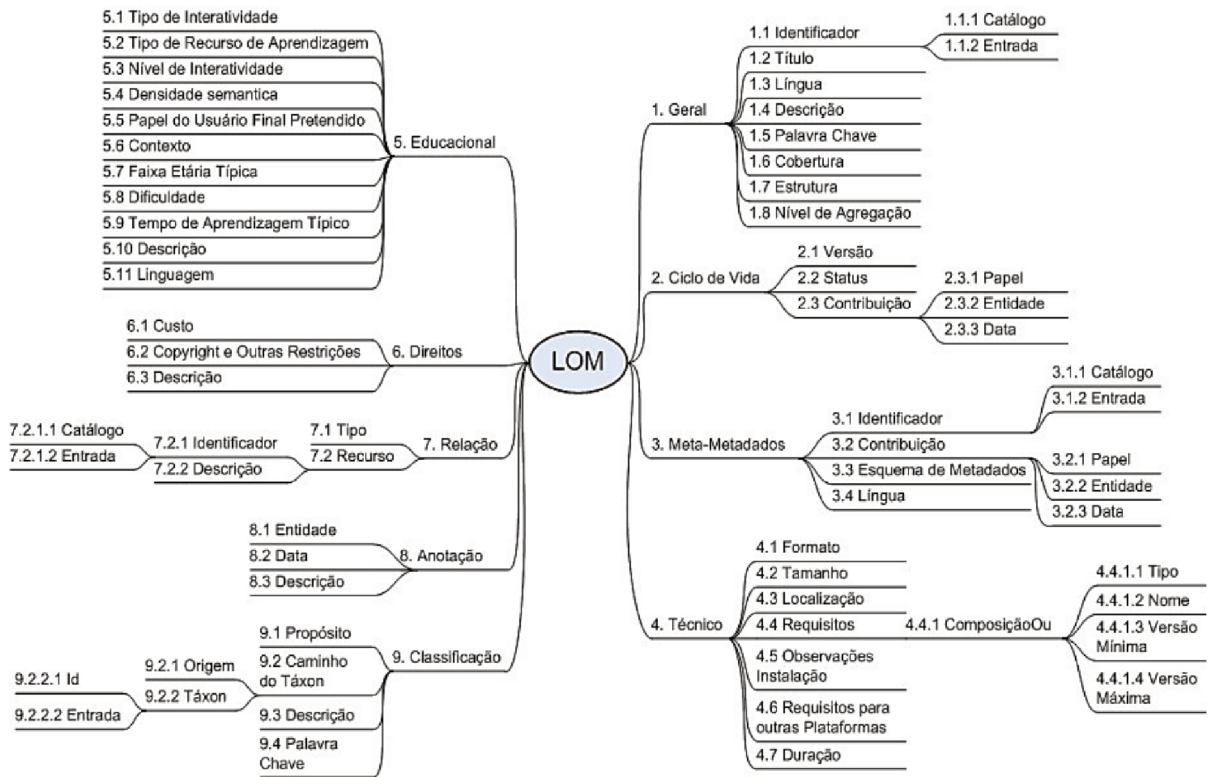


Figura 2 – Categorias dos metadados do IEEE LOM. (MACHION, 2007)

Structure é o campo que oferece uma descrição da estrutura organizacional do OA. *Format* nos mostra o tipo de dado trabalhado pelo OA para facilitar a identificação de quais softwares serão necessários no seu acesso. Os tipos permitidos pelo campo *Format* são definidos pelo registro IANA de tipos MIME(ver RFC2048:1996 (BORENSTEIN; FREED, 1996)).

Interactivity Type fornece informação do tipo predominante de aprendizado no OA (Ativo ou Expositivo). *Learning Resource Type* descreve o tipo específico do OA, com por exemplo: exercício, simulação, questionário, etc. (ver Tabela 11) e, por fim, *Interactivity Level* que informa o nível de interatividade proporcionado pelo OA.

O padrão IEEE LOM, mesmo sendo criado para esta razão específica, pode falhar em descrever com perfeição certos OAs. Nesse sentido, existem extensões do padrão que definem novos termos para algum campo do padrão.

Nesse sentido, foi criado o *Customized Learning Experience Online* (CLEO), que inclui ao campo *Learning Resource Type* vários termos que representam provedores de conteúdo usados comercialmente (CLEO, 2003). Sua especificação inclui também um guia prático de como utilizar a extensão nos arquivos XML de metadados no padrão IEEE LOM.

2.5 Web Semântica

A palavra “Semântica” é como você diz ou escreve alguma coisa de forma que aquilo mostre um significado. Dessa forma, a Web Semântica (WS) pode ser entendida também como “a Web de significados” (YU, 2011). Dito isto, a WS é uma extensão da Web que acrescenta a ela um formato de representação dos dados (KOIVUNEN; MILLER, 2001).

A criação de técnicas para se trabalhar com os dados que conseguimos na WS foi necessária devido ao crescimento da Internet, pois a quantidade de informação se tornou grandiosa e a maior parte não possui uma definição de semântica que seja precisa (PICKLER, 2007).

No W3C (World-Wide Web Consortium) (W3C, 2001), que foi onde surgiu o conceito de WS, foi lançada uma proposta de hierarquia em camadas para a Web, mostradas na Figura 3.

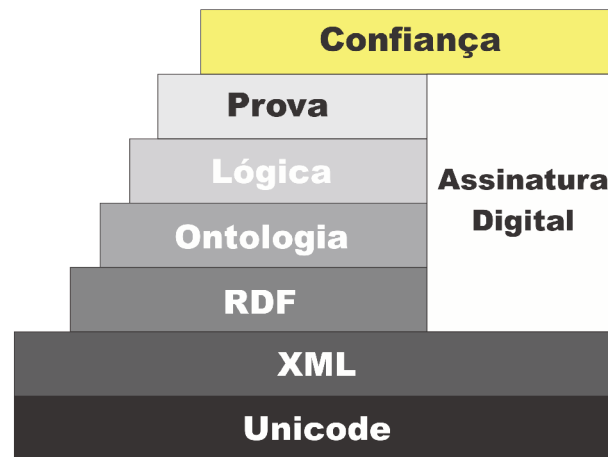


Figura 3 – As camadas da Web Semântica (KOIVUNEN; MILLER, 2001)

A Web semântica é com certeza o tópico mais debatido de pesquisas em Ontologia (FREITAS, 2003), com muitas discussões acerca do tema e muito desenvolvimento. As camadas que compõem seu modelo são:

- Unicode: garante o uso padronizado do mesmo conjunto de caracteres.
- Camada XML: camada que define a estruturação e sintaxe dos itens presentes na WS.
- Camada RDF: uma das camadas mais importante do modelo (YU, 2011), a camada de *Resource Description Framework* (RDF) é a que define mais semântica ao documento, descrevendo os recursos da Web.

RDF é um modelo que define uma forma de descrição semântica para os arquivos que os torna passíveis de processamento por computadores, possibilitando assim, a

codificação, o intercâmbio e o reúso de metadados estruturados, além da construção de elementos de metadados (SANTOS; CARVALHO, 2007).

A representação RDF é feita a partir de triplas no formato (Sujeito, Predicado, Objeto), que garante o poder necessário para a construção de seus arquivos.

- ❑ Ontologias: a camada com maior parte de estudos hoje. É ela a responsável por oferecer a expressividade necessária a representação de ontologias (FREITAS, 2003).
- ❑ Camadas de Lógica: permite a especificação de regras que atuarão sobre instâncias e recursos.
- ❑ Camada de Prova: executa as regras definidas na camada de lógica.
- ❑ Camada de Confiança: avalia se a prova está correta.

De forma geral, as últimas três não tomaram um corpo ainda no modelo de camadas, ficando apenas com um formato mais conceitual.

2.6 Ontologias

O conceito de ontologia em Inteligência Artificial (IA), é conhecido como o conjunto de entidades com suas relações, restrições, axiomas e vocabulário (FREITAS, 2003). Dentre os benefícios de se utilizar ontologias, podemos destacar a utilização de uma linguagem declarativa (SANT'ANNA; CERQUEIRA; SOARES, 2008). Em geral, as ontologias são representadas em arquivos XML descritos em uma linguagem chamada *Web Ontology Language* (OWL).

Numa ontologia OWL pode-se incluir: “relações de taxonomia entre classes; propriedades dos tipos de dados e descrições dos atributos de elementos das classes, propriedades do objeto e descrições das relações entre elementos das classes, instâncias das classes e propriedades” (SANTOS; CARVALHO, 2007).

Freitas (2003) destaca ainda outras vantagens de se utilizar Ontologia. Ontologias são portanto, interessantes de serem utilizadas em sistemas que tem como foco o ensino, por auxiliarem na representação do conhecimento de modo formal e completo, além de ser um conceito maduro e possuir ferramentas bem trabalhadas que auxiliam a empregar o conceito.

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 a *Semantic Query-Enhanced Web Rule Language* (SQWRL) (O'CONNOR; DAS, 2009). A linguagem SWRL foi criada para a criação de regras lógicas de inferência, sendo munida de operadores comuns da lógica proposicional, com algumas limitações, como a falta dos operadores “OR” e “NOT”.

Já o SQWRL foi criado com a intenção de trazer algumas funções do SQL convencional, tendo então como objetivo, criar *queries* de pesquisa dentro das ontologias. O SQWRL possui também a capacidade de receber algumas extensões, denominadas *built-ins*, que acrescentam novas funcionalidades a linguagem.

2.7 Trabalhos Relacionados

Na linha de pesquisa que procura criar formas eficientes de se recomendar conteúdo para os estudantes, é possível encontrar diversas iniciativas. Esta seção traz, portanto, alguns trabalhos que são correlacionados ao descrito neste plano de trabalho.

Vieira e Nunes (2012) utilizaram uma abordagem baseada em filtragem de conteúdo para recomendar OAs no padrão DublinCore (WEIBEL et al., 1998). Os itens recomendados por seu sistema, são aqueles que possuem semelhança em seus descritores, algo que é identificado através da técnica K-Means.

Zaina et al. (2012) propõem em seu trabalho uma abordagem de recomendação de conteúdo eletrônico baseada no relacionamento entre perfis e objetos de aprendizagem. Nele, eles também utilizam do FLSM e do IEEE LOM como padrões de descrição dos perfis de estudante e de metadados dos OAs respectivamente.

O trabalho de Carvalho et al. (2014) traz a abordagem escolhida nesta proposta de recomendação, onde, criada uma base de regras que descreve o relacionamento entre o FLSM e o IEEE LOM. A grande diferença entre este e o trabalho de Zaina et al. (2012) está na apresentação do relacionamento entre os dois modelos, o que é implícito neste último.

Utilizar dos recursos da WS para educação de forma eficiente é uma área em franca expansão (BITTENCOURT; COSTA, 2011), onde, a integração dessas tecnologias auxilia na apresentação personalizada do conteúdo para os estudantes. Nesse aspecto, podemos destacar alguns trabalhos como o de Rezende et al. (2015), onde foi proposta uma Ontologia para o perfil do estudante com objetivo de facilitar a recomendação de conteúdo em sistemas de ensino.

Em seu sistema, Rezende et al. (2015) utilizaram da modelagem dos estudantes por informações destacadas como relevantes em outros trabalhos e modelam também o contexto em que o aluno se encontra. Para a ontologia que implementa este modelo, eles deram o nome de PERSONNA e esta foi integrada à arquitetura que denominaram BROAD-RS.

Gluz e Vicari (2011) propõem uma Ontologia para representação de Metadados nos padrões IEEE LOM, DublinCore e o OBAA (VICARI et al., 2010). Porém, este não oferece recursos além da representação destes metadados, deixando em aberto as possíveis funcionalidades existentes.

E podemos citar também o trabalho de Timm Hinz, Gasparini e Pimenta (2011) que trás uma abordagem para recomendação de objetos de aprendizagem, que utiliza da

observação da interação do estudante com o ambiente AdaptWeb(OLIVEIRA et al., 2003) para recomendar OAs utilizados por outros usuários com comportamento semelhante. O modelo proposto em sua abordagem, utilizou de uma modelagem de estudante criada através de uma ontologia em razão da formalização do método.

2.7.1 Análise comparativa

Dos trabalhos citados, percebe-se que mesmo aqueles que utilizam de Ontologias em suas abordagens, elas apenas modelam o modelo do estudante, deixando de lado os OAs, perdendo assim em poder de representação semântica de seus metadados. O que não ocorre nesta proposta, já que o modelo de Ontologia desenvolvido, modela tanto os OAs, quanto os EAs dos estudantes.

Assim, este trabalho se destaca, pois com a ontologia criada e as ferramentas disponibilizadas em tecnologias de inferência, este trabalho pode agregar eficiência em trabalhos que necessitam representar seus OAs de uma forma mais próxima ao modelo do estudante. O que traz a possibilidade de realizar uma recomendação automática e eficiente dos OAs de acordo com os EAs dos estudantes.

A abordagem proposta trará uma tentativa dessa aproximação, utilizando dos Estilos de Aprendizagem que devem estar presentes ao modelo do estudante. Mostra assim como utilizar dos OAs em uma representação vetorial baseada nos EA, automatizando de forma eficiente os processos de recomendação, considerando os EAs de cada estudante, os metadados e OAs disponíveis.

A Tabela 2 apresenta uma comparação das técnicas e tecnologias utilizadas nos trabalhos supracitados e do apresentado nesta proposta.

Tabela 2 – Comparação entre os trabalhos correlatos a proposta de trabalho.

Referência	Recomendação	IEEE LOM	FSLSM	Ontologia
Vieira e Nunes (2012)	X			
Zaina et al. (2012)	X	X	X	
Carvalho et al. (2014)	X	X	X	
Rezende et al. (2015)	X			X
Gluz e Vicari (2011)		X		X
Timm Hinz, Gasparini e Pimenta (2011)	X			X
Esta proposta	X	X	X	X

OntAES: Ontology for Adaptive Educational Systems

A abordagem proposta por este trabalho utiliza um modelo probabilístico de estudante baseado no Modelo de Estilos de Aprendizagem de Felder e Silverman (FSLSM). Neste modelo probabilístico, a fim de conseguirmos um aumento na precisão do modelo, definimos para cada estilo um valor entre 0 e 100 que é relativo a aderência do indivíduo àquele estilo (DORÇA et al., 2013).

No exemplo da Tabela 3, o estudante pertence ao grupo dos indivíduos reflexivos na dimensão de Processamento, mas mais do que isso, podemos ver o valor relativo a preferência da pessoa também por itens Intuitivos. A utilização desse tipo de modelo se justifica na crença de que os estilos de aprendizagem não passam de preferências dentro de cada dimensão que não excluem a utilização de itens dentro do outro estilo.

Tabela 3 – Exemplo de Modelo Probabilístico de Estudante

Estudante 1							
Ativo	Reflexivo	Visual	Verbal	Sequencial	Global	Intuitivo	Sensitivo
34	66	50	50	0	100	75	25

Dado o contexto, este trabalho se propõe a apresentar uma abordagem de recomendação de Objetos de Aprendizagem (OAs). Para tal fim, a pesquisa foi feita seguindo a seguinte metodologia:

- ❑ Estudo e análise das propriedades dos Estilos de Aprendizagem (EAs), de acordo com o FSLSM.
- ❑ Estudo e análise dos campos dos metadados de OA do padrão IEEE LOM (IEEE, 2002) acrescidos do CLEO (CLEO, 2003)
- ❑ Estudo do trabalho de (DORÇA; RESENDE, 2015) que desenvolveu a primeira relação entre o IEEE LOM e o FSLSM.

- ❑ Redefinição de quais campos do IEEE LOM permitem classificação baseada nos EAs do FSLSM.
- ❑ Remapeamento da relação entre os campos e os EAs do FSLSM.
- ❑ Implementação de regras de inferência que classificam os OAs de acordo com os EAs, usando o mapeamento construído.
- ❑ Criação de uma ontologia que implementa as regras de inferência construídas no passo anterior.
- ❑ Implementação de um protótipo para propósitos de experimentação da abordagem proposta.
- ❑ Análise dos resultados obtidos na execução dos experimentos.

Por padrão, os Sistemas de Tutores Inteligentes (STI) são compostos por 4 módulos, como apresentado na Figura 4, já melhor explicados no Capítulo 2. A abordagem descrita neste Capítulo se inclui no Modelo Pedagógico.

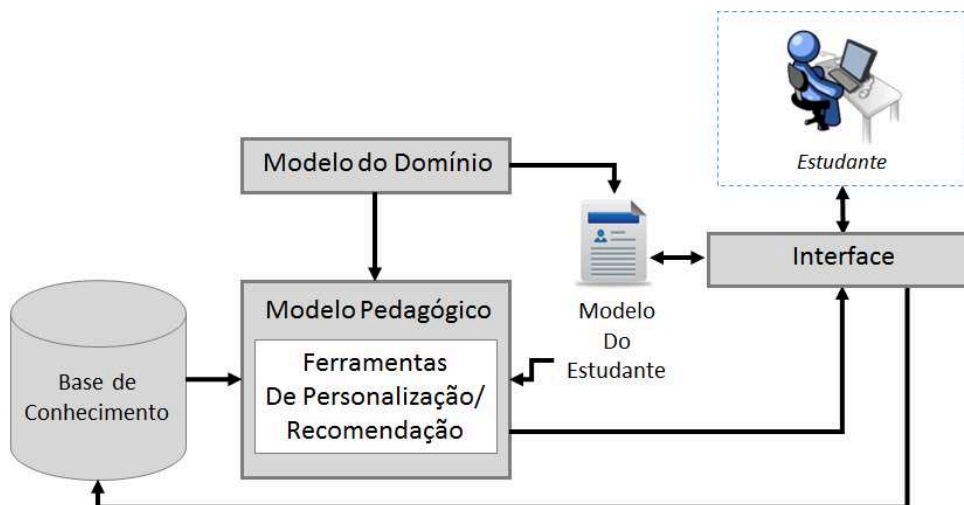


Figura 4 – Exemplo de arquitetura de Sistemas de Tutores Inteligentes

3.1 Classificação e Recomendação de Objetos de Aprendizagem

É possível associar os campos mais relevantes do padrão IEEE LOM (*Learning Object Metadata*) aos EA's do FSLSM. Este estudo foi iniciado por Dorça e Resende (2015), porém, após análise, percebeu-se erros conceituais em algumas associações, assim, foi desenvolvida uma nova associação, apresentada na Tabela 4.

Tabela 4 – Mapeamento dos campos do IEEE LOM para os EAs do FLSM.

Campo do LOM	Valor	Percepção	Entrada	Processamento	Organização
Structure	collection	-	-	-	global
	networked	-	-	-	global
	hierarchical	-	-	-	global
	atomic	-	-	-	sequential
	linear	-	-	-	sequential
Format	audio	-	verbal	reflective	-
	image	-	visual	reflective	-
	text	-	verbal	reflective	-
	video	sensitive	visual	reflective	-
	application	sensitive	visual	active	-
	form	-	verbal	active	-
Interactivity Type	active	-	-	active	-
	expositive	-	-	reflective	-
	mixed	-	-	active & reflective	-
Learning Resource Type	exercise	-	-	active	-
	simulation	-	-	active	-
	questionnaire	sensitive	verbal	active	-
	diagram	-	visual	reflective	-
	figure	intuitive	visual	reflective	-
	graph	-	visual	reflective	-
	index	-	visual	reflective	-
	slide	sensitive	visual	reflective	-
	table	sensitive	verbal	reflective	-
	narrative text	sensitive	verbal	reflective	-
	exam	-	verbal	active	-
	experiment	-	verbal	active	-
	problem statement	sensitive	verbal	active	-
	self assessment	-	verbal	active	-
lecture	-	verbal	reflective	-	
Interactivity Level	very low	-	-	reflective	-
	low	-	-	reflective	-
	medium	-	-	active & reflective	-
	high	-	-	active	-
	very high	-	-	active	-

Nem todos os campos do IEEE LOM fornecem informações coerentes para serem mapeadas nos EAs do FSLSM. Assim, para realizarmos o mapeamento, foram usados os campos:

- ❑ *Structure*, em que verifica-se a existência de ligações do OA a outros OA's, bem como o mecanismo dessa ligação; *Aggregation Level*, que quantifica a granularidade atribuída ao OA;
- ❑ *Format*, no qual se informa quais formatos de mídia estão presentes no OA (vídeo, imagem, texto ou outro formato);
- ❑ *Interactivity Type*, que descreve como é a interação do estudante com o conteúdo (por exemplo, por meio de exercícios), se o OA é apenas expositivo (por exemplo, apenas com textos), ou uma mistura de ambos;
- ❑ *Learning Resource Type*, que serve como um complemento ao campo *Format* (por exemplo, sendo o OA descrito como formato de texto, esse campo especializa de qual tipo específico esse texto é, como uma narrativa, um questionário, entre outras opções dadas pelo padrão);
- ❑ *Interactivity Level*, que complementa *Interactivity Type*, mostrando uma graduação de quão interativo é o OA;

Porém, também durante a análise do IEEE LOM, percebeu-se que os valores padrões do campo *Learning Resource Type* são insuficientes para descrever de forma eficiente todos os OAs existentes. Para resolver este problema, utilizamos o *Customized Learning Experience Online* (CLEO) (CLEO, 2003).

O CLEO traz novos valores para o campo *Learning Resource Type* que complementam os já existentes do IEEE LOM. Assim, um novo mapeamento se fez necessário para o que foi acrescido. Este mapeamento pode ser visto na Tabela 5.

A partir desse mapeamento, foram definidas regras de inferência no formato Prolog (Figura 6) que não foram utilizadas no trabalho, mas serviu como um facilitador na criação das regras. Nesse formato, a regra é interpretada como verdadeira se no predicado *Y* (que representa um campo do IEEE LOM), o OA *X* possui o valor *Z*, como descrito no exemplo da Figura 5.

1.Estilo_Aprendizagem (X) :-
Y (X, Z).

Figura 5 – Exemplo de regra de inferência genérica em Prolog.

Portanto, para a recomendação, inicia-se então o processo que denominamos vetorização do OA, onde representamos o OA através de um vetor que mostra a quais preferências

Tabela 5 – Mapeamento dos valores do CLEO para os EAs do FSLSM.

Campo do LOM	Valor do CLEO	Percepção	Entrada	Processamento	Organização
Learning Resource Type	additional resource	-	-	-	-
	analogy	sensitive	-	reflective	-
	assessment	-	verbal	active	-
	assessment item	-	-	active	-
	attactor	-	visual	-	-
	community	-	verbal	active	-
	definition	intuitive	verbal	reflective	-
	demonstration	intuitive	verbal	reflective	-
	example	sensitive	-	reflective	-
	feedback	-	-	-	-
	glossary	intuitive	verbal	reflective	-
	guidance	-	-	-	sequential
	guideline	intuitive	-	reflective	-
	illustration	-	visual	-	-
	importance	-	-	-	-
	introduction	-	verbal	-	-
	non exemplo	sensitive	-	reflective	-
	note	-	verbal	reflective	-
	objective	-	verbal	-	-
	outline	-	-	-	-
	overview	-	-	-	global
	practice	sensitive	-	active	global
	prerequisite	-	-	-	-
	presentation	-	-	reflective	-
	recall	-	-	-	-
	reference	-	-	-	-
	reinforcement	-	-	-	-
scenario	sensitive	-	reflective	-	
summary	-	-	reflective	global	

de EAs ele melhor atende. Para a vetorização, usamos as regras de inferência apresentadas nos metadados colhidos de cada OA e então realizamos uma contagem de quantas regras são interpretadas como verdadeiras para cada EA.

Tabela 6 – Exemplo de metadado de OA

OA	Structure	Format	Interactivity Type	Interactivity Level	Learning Resource Type
1	atomic	text image	expositive	very low	figure diagram example slide

Na Tabela 6 é apresentado um exemplo de metadados de um OA e a Tabela 7 apresenta o resultado da contagem de regras após o processo de classificação desses metadados. Porém, para a estratégia escolhida de recomendação, é necessário que essa contagem seja

Structure	Format	Interactivity Type (IT)	Learning Resource Type (LRT) + CLEO	Interactivity Level (IL)	
1:Sequential(X):- Structure(X,"atomic"); Structure(X,"linear").	3:Visual(X):- Format(X,"video"); Format(X,"image").	7:Active(X):- IT(X,"active"); IT(X,"mixed").	9:Active(X):- LRT(X,"exercise"); LRT(X,"simulation"); LRT(X,"questionnaire"); LRT(X,"exam"); LRT(X,"experiment"); LRT(X,"problem statement"); LRT(X,"self assessment"); LRT(X,"assessment"); LRT(X,"assessment item"); LRT(X,"community"); LRT(X,"practice").	12:Intuitive(X):- LRT(X,"diagram"); LRT(X,"definition"); LRT(X,"demonstration"); LRT(X,"glossary"); LRT(X,"guideline"); LRT(X,"experiment").	17:Active(X):- IL(X,"medium"); IL(X,"high"); IL(X,"very high").
2:Global(X):- Structure(X,"collection"); Structure(X,"networked"); Structure(X,"hierarchical").	4:Verbal(X):- Format(X,"text"); Format(X,"audio"); Format(X,"form").	8:Reflective(X):- IT(X,"expositive"); IT(X,"mixed").	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"); LRT(X,"analogy"); LRT(X,"definition"); LRT(X,"demonstration"); LRT(X,"example"); LRT(X,"glossary"); LRT(X,"guideline"); LRT(X,"non example"); LRT(X,"note"); LRT(X,"presentation"); LRT(X,"scenario"); LRT(X,"summary").	13:Visual(X):- LRT(X,"diagram"); LRT(X,"figure"); LRT(X,"graph"); LRT(X,"experiment"); LRT(X,"attactor"); LRT(X,"illustration").	18:Reflective(X):- IL(X,"very low"); IL(X,"low"); IL(X,"medium").
	5:Active(X):- Format(X,"form"); Format(X,"application").		11:Sensitive(X):- LRT(X,"simulation"); LRT(X,"figure"); LRT(X,"graph"); LRT(X,"index"); LRT(X,"table"); LRT(X,"experiment"); LRT(X,"analogy"); LRT(X,"example"); LRT(X,"non example"); LRT(X,"practice"); LRT(X,"scenario").	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 statement"); LRT(X,"self assessment"); LRT(X,"lecture"); LRT(X,"assessment"); LRT(X,"community"); LRT(X,"definition"); LRT(X,"demonstration"); LRT(X,"glossary"); LRT(X,"introduction"); LRT(X,"note"); LRT(X,"objective").	
	6:Reflective(X):- Format(X,"video"); Format(X,"text"); Format(X,"audio"); Format(X,"image").			15:Sequential(X):- LRT(X,"guidance").	
				16:Global(X):- LRT(X,"outline"); LRT(X,"overview"); LRT(X,"summary").	

Figura 6 – Listagem das regras para mapeamento dos campos do LOM em EA's.

convertida em valores de proporcionalidade em relação a cada dimensão.

Tabela 7 – Exemplo de contagem de regras verdadeiras para cada EA.

	Entrada		Processamento		Percepção		Organização	
	Visual	Verbal	Active	Reflective	Sensitive	Intuitive	Sequential	Global
OA	2	0	0	8	2	1	1	0

A Tabela 8 contém então o resultado da conversão proporcional dos valores apresentados na Tabela 7. Tomando por exemplo a dimensão de Entrada na Tabela 7, para o EA Visual, temos o valor 2 (dois) e para Verbal, 0 (zero). Portanto, 100% (cem por cento) dos resultados da classificação para esta dimensão, são Visuais e 0% (zero por cento) são Verbais, como descrito na Tabela 8.

Assim, com o resultado da etapa de conversão proporcional e o modelo do estudante, é feito um cálculo de distância e o valor obtido é inverso à relevância OA no ranqueamento do estudante em questão. A Tabela 9 contém um exemplo desse processo final.

Considerando um Estudante E, a relevância de um OA é calculado como a distância

Tabela 8 – Exemplo de classificação do OA no modelo probabilístico

	Entrada		Processamento		Percepção		Organização	
	Visual	Verbal	Active	Reflective	Sensitive	Intuitive	Sequential	Global
OA	100%	0%	0%	100%	66%	34%	100%	0%

Tabela 9 – Exemplo do cálculo da pontuação e da distância de um OA para determinado estudante.

	Entrada		Processamento		Percepção		Organização	
	Visual	Verbal	Active	Reflective	Sensitive	Intuitive	Sequential	Global
Estudante	75%	25%	30%	70%	60%	40%	15%	85%
OA	100%	0%	0%	100%	66%	34%	100%	0%
Diferença	25		30		6		85	
Nota do OA	146							

de Manhattan entre o modelo do estudante e este OA. A fórmula é a apresentada na Equação (1).

$$\sum_{i=1}^8 |OA_i - E_i| \quad (1)$$

Esse cálculo é realizado para cada OA que será apresentado ao usuário e então, o ranking é feito organizando os OAs em ordem não decrescente. Isso deve ao fato de que nos cálculos de distância, quanto menor o valor, mais próximo um ponto está do outro. Considerando que o vetor do modelo do Estudante seja um ponto no espaço e os vetores de OAs são outros, quanto mais próximo eles estão, mas parecidos eles devem ser e, portanto, o OA deve ser mais adequado ao aprendiz.

3.2 OntAES: Ontology for Adaptive Educational Systems

Este trabalho também se propôs a construir uma ontologia que acompanhe todas as etapas da abordagem de recomendação descrita na Seção 3.1. Construir uma ontologia traz diversas vantagens para o processo como os descritos no trabalho de Noy e McGuinness (2001):

- Facilita o compartilhamento da estrutura do trabalho entre pesquisadores e agentes de software (digitais ou não);
- Facilitar o reuso do domínio do conhecimento aplicado;
- Deixar explícito as suposições feitas;

- ❑ Separar o domínio do conhecimento de sua parte operacional;
- ❑ E para analisar o domínio de conhecimento.

A criação dessa ontologia seguiu a Metodologia 101 (M101) (NOY; MCGUINNESS, 2001), que auxilia os pesquisadores no desenvolvimento de suas primeiras ontologias. A M101 é dividida em 7 etapas simplificadas, que serão descritas nessa seção.

A primeira etapa trata de determinar o domínio e escopo da ontologia. Representar os OAs, EAs, o mapeamento entre o padrão IEEE LOM e o FSLSM e; as regras de inferência que foram geradas desse mapeamento são itens desejados na ontologia, pois ela deve acompanhar todos os passos da recomendação que utiliza nossa abordagem. Nessa etapa podemos criar as **questões de competência** (GRÜNINGER; FOX, 1995) que são como perguntas base que devemos garantir que nossa ontologia tenha as respostas e, também, nos auxilia a validar a ontologia ao final.

De acordo com Noy e McGuinness (2001), as Questões de Competência (QCs) são apenas rascunhos e não precisam ser exaustivamente criadas para suprir todas as necessidades da pesquisa. Mas são boas ferramentas para auxiliar na demonstração da utilidade da ontologia e, portanto, na sua validação. São nossas questões de competência:

- ❑ Qual a classificação de um OA X de acordo com o FSLSM, levando em consideração um estudante y ?
- ❑ É possível dizer se um estudante pode tirar proveito de forma eficiente de um determinado OA?

A segunda etapa da M101 diz que é preciso considerar reutilizar ontologias já existentes. No período em que essa pesquisa ocorreu, não haviam ontologias disponíveis de forma pública que supriam nossa necessidade. Isso se dá ao fato de que nosso domínio é provavelmente muito específico e, apesar de existirem pesquisas semelhantes, nenhuma que realizasse o mesmo tipo de mapeamento entre o padrão IEEE LOM e o FSLSM.

Na terceira etapa selecionamos os termos importantes para nossa ontologia. Assim, o que colocamos em evidência são os campos do IEEE LOM que usamos no mapeamento presentes na Coluna 1 da Tabela 4, os valores de cada campo presentes nas Tabelas 4 e 5 e também os nomes de cada dimensão e EA do FSLSM presentes nas linhas 1 e 2 da Tabela 7.

A quarta etapa da metodologia diz para definirmos as classes da ontologia e qual hierarquia de classes (USCHOLD; GRUNINGER, 1996) será utilizada. Foi utilizada a hierarquia do tipo top-down, onde as classes são descritas dos conceitos mais amplos para os conceitos mais específicos.

A Tabela 10 apresenta as classes inseridas na ontologia. Ela não possui subclasses, pois, por definição, se uma classe A é superclasse de uma classe B, então toda instância

Tabela 10 – Classes da ontologia e suas respectivas subclasses.

Format	Input	Organization	Perception
Processing	Learning_Resource_Type	Struct	EA
Interactivity_type	Interactivity_Level	OA	

de B é também instância de A. Esse tipo de relação não é verdadeira entre nenhuma das classes apresentadas.

O quinto passo pede que sejam definidas as propriedades das classes. Nesse passo, incluímos como propriedades das classes, os relacionamentos existentes entre elas. Assim, foram criados:

- **is-part-of**: Criado para representar o relacionamento entre a classe *OA* e os nomes dos campos do IEEE LOM que usamos no mapeamento. E também a classe *EA* e as dimensões do FSLSM.
- **has**: Os OAs que a ontologia recebe, possuem os valores de seus campos representados com o uso desta propriedade, portanto, para dizer que um OA possui o valor “*video*” em seu campo *Format* basta dizermos a Ontologia: “*has(OA, video)*”.
- **is**: Este relacionamento tem como domínio os conceitos pertencentes às subclasses da classe OA. Ele é utilizado na inferência dos EAs para cada valor pertencente aos OAs.

Na sexta etapa definimos as características de cada propriedade, como restrições de tipo, cardinalidade, domínio e alcance. As restrições das propriedades são relacionadas as instâncias criadas na etapa sete do M101.

Assim, para a propriedade *has* somente aceita instâncias definidas das classes correspondentes aos campos do IEEE LOM. E *is* só recebe valores equivalentes aos EAs do FSLSM. Já *is-part-of* é uma propriedade que apenas existe para associar os conceitos das classes corretamente, não recebendo diretamente valores dos usuários.

E, por fim, a sétima etapa é quando criamos as instâncias das classes. A Tabela 11 mostra na primeira coluna as classes da ontologia e na segunda coluna as instâncias de cada uma, denominadas indivíduos.

Assim finalizamos a construção da base da ontologia, e com isso, pudemos adicionar as regras de inferência. Para isso, utilizamos da linguagem *Semantic Web Rule Language* (SWRL) (HORROCKS et al., 2004).

Na Tabela 12 podemos observar algumas regras exemplo. Devido as limitações da linguagem, como a falta do operador de disjunção lógica, foram geradas muitas regras, porém simples. As regras foram modeladas de forma a identificar a quais EAs se relacionam os conceitos apresentados pelos OAs e não com o OA propriamente dito, através da propriedade “*is*”.

Tabela 11 – Classes e indivíduos pertencentes a Ontologia.

Classes	Indivíduos disponíveis
Input	Verbal, Visual
Organization	Global, Sequencial
Perception	Intuitivo, Sensitivo
Processing	Ativo, Reflexivo
Structure	collection, hierarchical, linear, networked
Format	application, audio, image, text, video
Interactivity Type	active, expositive, mixed
Interactivity Level	very_high, high, medium, low, very_low
Learning Resource Type	diagram, exam, exercise, experiment, figure, graph, index, lecture, narrative_text, problem_statement, questionnaire, self_assessment, simulation, slide, table additional resource, analogy, assessment, assessment item, attractor, definition, demonstration, example, feedback, glossary, guidance, guideline, illustration, importance, introduction, non example, note, objective, outline, overview, practice, prerequisite, recall, reference, reinforcement

Tabela 12 – Exemplos de regras SWRL construídas

Regra SWRL	Descrição
<code>has(?o, collection) ->is(collection, Global)</code>	O atributo collection (campo Struct) é mapeado para EA Global
<code>has(?o, table) ->is(table, Sensitivo)</code>	O atributo table (campo LRT) é mapeado para EA Sensitivo
<code>has(?o, table) ->is(table, Verbal)</code>	O atributo table (campo LRT) é mapeado também para EA Verbal
<code>has(?o, table) ->is(table, Reflexivo)</code>	O atributo table (campo LRT) é mapeado também para EA Reflexivo
<code>has(?o, video) ->is(video, Visual)</code>	O atributo video (campo Format) é mapeado para EA Visual
<code>has(?o, video) ->is(video, Reflexivo)</code>	O atributo video (campo Format) é mapeado também para EA Reflexivo
<code>has(?o, mixed) ->is(mixed, Ativo)</code>	O atributo mixed (campo IT) é mapeado para EA Ativo
<code>has(?o, mixed) ->is(mixed, Reflexivo)</code>	O atributo mixed (campo IT) é mapeado também para EA Reflexivo
<code>has(?o, medium) ->is(medium, Ativo)</code>	O atributo medium (campo IL) é mapeado para EA Ativo
<code>has(?o, medium) ->is(medium, Reflexivo)</code>	O atributo medium (campo IL) é mapeado também para EA Reflexivo

...

LRT - Learning Resource Type**IT** - Interactivity Type**IL** - Interactivity Level

Tomando a regra 1 da Figura 6, podemos traduzi-la como apresentado nas fórmulas das Equações (2) e (3). A linguagem SWRL, como já dito, não oferece o operador de disjunção *or*, assim, para o fazermos, temos de separar a regra em várias, portanto, cada regra da Figura 6 foi traduzida em duas ou mais regras SWRL.

$$has(?o, linear) \text{ -- } > is(linear, Sequencial) \quad (2)$$

$$has(?o, atomic) \text{ -- } > is(atomic, Sequencial) \quad (3)$$

Foram modeladas regras *Semantic Query-Enhanced Web Rule Language* (SQWRL) (O'CONNOR; DAS, 2009) para realizar uma contagem de quantas regras SWRL (Tabela 12) um OA satisfaz para cada EA do modelo de Felder, gerando um vetor de 8 dimensões (processo de vetorização do OA). A linguagem SQWRL nos permite realizar consultas

sobre as inferências das regras SWRL. A Tabela 13 apresenta as regras criadas para essa função, cada regra correspondente a um EA.

Tabela 13 – Regras SQWRL modeladas

Regras SQWRL	Descrição da contagem
$OA(?o) \wedge ID(?o, '1') \wedge has(?o, ?x) \wedge is(?x, Ativo) \rightarrow sqwrl:count(?x)$	Valores relacionados a "Ativo" existem no OA de ID "1"
$OA(?o) \wedge ID(?o, '1') \wedge has(?o, ?x) \wedge is(?x, Reflexivo) \rightarrow sqwrl:count(?x)$	Valores relacionados a "Reflexivo" existem no OA de ID "1"
$OA(?o) \wedge ID(?o, '1') \wedge has(?o, ?x) \wedge is(?x, Visual) \rightarrow sqwrl:count(?x)$	Valores relacionados a "Visual" existem no OA de ID "1"
$OA(?o) \wedge ID(?o, '1') \wedge has(?o, ?x) \wedge is(?x, Verbal) \rightarrow sqwrl:count(?x)$	Valores relacionados a "Verbal" existem no OA de ID "1"
$OA(?o) \wedge ID(?o, '1') \wedge has(?o, ?x) \wedge is(?x, Intuitivo) \rightarrow sqwrl:count(?x)$	Valores relacionados a "Intuitivo" existem no OA de ID "1"
$OA(?o) \wedge ID(?o, '1') \wedge has(?o, ?x) \wedge is(?x, Sensitivo) \rightarrow sqwrl:count(?x)$	Valores relacionados a "Sensitivo" existem no OA de ID "1"
$OA(?o) \wedge ID(?o, '1') \wedge has(?o, ?x) \wedge is(?x, Sequencial) \rightarrow sqwrl:count(?x)$	Valores relacionados a "Sequencial" existem no OA de ID "1"
$OA(?o) \wedge ID(?o, '1') \wedge has(?o, ?x) \wedge is(?x, Global) \rightarrow sqwrl:count(?x)$	Valores relacionados a "Global" existem no OA de ID "1"

A essa ontologia desenvolvida denominamos OntAES (*Ontology for Adaptive Educational Systems*). O OntAES então ocupa o lugar de cerne do trabalho, acompanhando todas as etapas da abordagem de recomendação apresentada neste Capítulo.

Experimentos e Análise dos Resultados

Visando ter uma ideia do funcionamento de toda a abordagem, foram realizados experimentos práticos e análises empíricas. Assim, a Seção 4.1 traz informações da nossa base de testes, protótipos e metodologia de experimentação.

4.1 Experimentos

Para que fossem realizadas as experimentações, foi criado um protótipo que implementa as fases intermediárias da recomendação. A Figura 7 mostra a tela inicial do protótipo, onde selecionamos o modelo do estudante que desejamos visualizar os resultados.

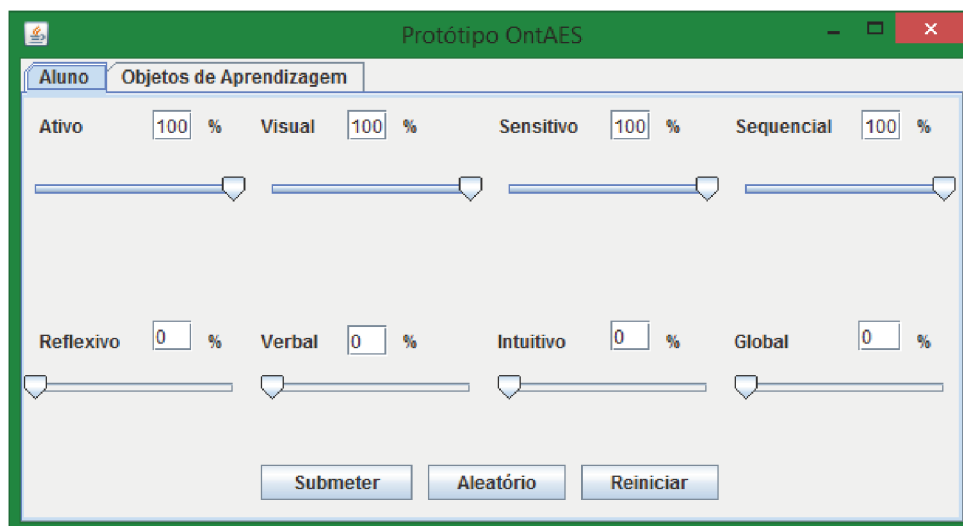


Figura 7 – Tela inicial do protótipo

No protótipo podemos ver também uma listagem dos OAs carregados para teste. A Figura 8 mostra a aba da tela inicial que nos apresenta essa lista.

O protótipo possibilitou a execução de testes automatizados, onde criamos conjuntos de estudantes da seguinte maneira:

Código	Título
1	Plano de Curso
2	Aula 01 - Introdução
3	Aula 02 - Recuperação Booleana
4	Aula 03 - Vocabulário e Lista de Índices
5	Aula 04 - Prática 01 - Construindo Índice Invertido
6	Aula 02 - Visão Geral de Desenvolvimento
7	Aula 03 - Ciclo de Vida das Aplicações
8	Aula 04 - Hello World e Interface Gráfica
9	Plano de Curso
10	Aula 01 - Introdução
11	Definição Trabalho - Parte 1
12	Plano de Curso
13	Aula 01 - Introdução
14	Aula 02 - Arquitetura de Sistemas de Banco de Dad...
15	Aula 05 - Construção de Índices
16	Aula 06 - Prática 02 - Algoritmo de Consultas

Figura 8 – Lista de OAs do repositório do protótipo

Tabela 14 – Lista de Combinações de EAs do FSLSM.

Combinação	Percepção	Entrada	Processamento	Organização
1	sensitivo	verbal	ativo	sequencial
2	sensitivo	verbal	ativo	global
3	sensitivo	verbal	reflexivo	sequencial
4	sensitivo	verbal	reflexivo	global
5	sensitivo	visual	ativo	sequencial
6	sensitivo	visual	ativo	global
7	sensitivo	visual	reflexivo	sequencial
8	sensitivo	visual	reflexivo	global
9	intuitivo	verbal	ativo	sequencial
10	intuitivo	verbal	ativo	global
11	intuitivo	verbal	reflexivo	sequencial
12	intuitivo	verbal	reflexivo	global
13	intuitivo	visual	ativo	sequencial
14	intuitivo	visual	ativo	global
15	intuitivo	visual	reflexivo	sequencial
16	intuitivo	visual	reflexivo	global

- ❑ **Conjunto de Estudantes 1 (CE1):** Organizamos um grupo de 16 estudantes, separados por suas combinações de preferências distribuídos como demonstrado na Tabela 14. Essas são as possíveis combinações de EAs do FSLSM. Utilizamos os valores 75 (setenta e cinco), para o EA dominante em cada dimensão e 25 (vinte e cinco) para o não-dominante, como demonstrado na Tabela 15.
- ❑ **Conjunto de Estudantes 2 (CE2):** Foi criado um conjunto com 4 estudantes que possuem variação nos valores de cada dimensão do modelo. A lista de estudantes pode ser vista na Tabela 16.

Tabela 15 – Conjunto de Estudantes 1

Estudante	Percepção		Entrada		Processamento		Organização	
	Sensitivo	Intuitivo	Verbal	Visual	Ativo	Reflexivo	Sequencial	Global
1	75%	25%	75%	25%	75%	25%	75%	25%
2	75%	25%	75%	25%	75%	25%	25%	75%
3	75%	25%	75%	25%	25%	75%	75%	25%
4	75%	25%	75%	25%	25%	75%	25%	75%
5	75%	25%	25%	75%	75%	25%	75%	25%
6	75%	25%	25%	75%	75%	25%	25%	75%
7	75%	25%	25%	75%	25%	75%	75%	25%
8	75%	25%	25%	75%	25%	75%	25%	75%
9	25%	75%	75%	25%	75%	25%	75%	25%
10	25%	75%	75%	25%	75%	25%	25%	75%
11	25%	75%	75%	25%	25%	75%	75%	25%
12	25%	75%	75%	25%	25%	75%	25%	75%
13	25%	75%	25%	75%	75%	25%	75%	25%
14	25%	75%	25%	75%	75%	25%	25%	75%
15	25%	75%	25%	75%	25%	75%	75%	25%
16	25%	75%	25%	75%	25%	75%	25%	75%

Tabela 16 – Conjunto de Estudantes 2

Estudante	Percepção		Entrada		Processamento		Organização	
	Sensitivo	Intuitivo	Verbal	Visual	Ativo	Reflexivo	Sequencial	Global
1	60%	40%	80%	20%	70%	30%	75%	25%
2	70%	30%	75%	25%	60%	40%	25%	75%
3	18%	82%	33%	67%	10%	90%	75%	25%
4	25%	75%	18%	82%	25%	75%	25%	75%

Além disso, para realizarmos um estudo de caso, foram selecionados dois conjuntos de OAs existentes no Classroom eXperience (CX) (FERREIRA et al., 2012). O CX é uma plataforma multimídia para captura de aulas que interage com dispositivos de computação ubíqua. Além disso, ele pode registrar, armazenar, sincronizar e disponibilizar as diferentes mídias capturadas sendo então, uma grande ferramenta de geração autoral de OAs.

Os conjuntos de OAs selecionados são:

- **Repositório 1:** As aulas das disciplinas de Banco de Dados I, Programação de Dispositivos Móveis e Organização e Recuperação de Informação, também do semestre 2017-1 da UFU ministradas em Monte Carmelo. Para esse conjunto, cada documento representa um dia de aula, podendo inteirar diversos temas. Diferente do conjunto anterior, este não é fixo, por ser construído de forma aleatória a cada execução.

□ **Repositório 2:** As aulas da disciplina de Interação Humano-Computador do semestre 2017-1 da Universidade Federal de Uberlândia (UFU) ministradas em Uberlândia. Para esse conjunto, cada página das aulas teve seus metadados preenchidos como um OA, inteirando um total de 865 documentos.

Os experimentos demonstrados neste Capítulo então apresentam os resultados das combinações entre os conjuntos de estudantes e OAs selecionados. Além disso, a Subseção 4.1.3 apresenta a resposta das Questões de Competência apresentadas no Capítulo 3.

4.1.1 Experimento 1

Neste experimento foi utilizado o repositório 1 de OAs. Na Tabela 17, são apresentados os primeiros 15 OAs recomendados no ranking de cada um dos estudantes do CE1.

Tabela 17 – Experimento com estudantes do CE1 com repositório 1 de OAs.

Resultados																														
Ranking de Objetos de Aprendizagem (posições 1 a 15, IDs à esquerda, relevância calculada à direita)																														
Estudante	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15															
1	54	59	21	74	28	74	52	74	8	79	16	80	25	80	31	80	33	83	42	88	53	92	26	94	46	94	50	97	19	100
2	54	59	28	74	52	74	17	78	8	79	25	80	33	83	53	92	26	94	46	94	19	100	34	114	44	114	37	117	32	119
3	10	52	36	54	43	54	8	55	53	58	39	59	26	60	15	62	50	63	34	64	44	64	3	65	29	66	37	67	32	69
4	17	44	8	55	53	58	26	60	34	64	44	64	37	67	32	69	7	72	46	74	13	75	24	78	6	79	25	80	33	83
5	19	100	28	106	52	106	21	106	54	109	46	126	8	129	25	130	16	130	31	130	33	133	42	138	39	141	53	142	26	144
6	19	100	28	106	52	106	54	109	46	126	17	128	8	129	25	130	33	133	53	142	26	144	34	146	44	146	24	148	37	149
7	39	91	34	96	44	96	36	96	43	96	24	98	37	99	19	100	12	100	23	100	27	100	45	100	10	102	18	102	7	104
8	17	94	34	96	44	96	24	98	37	99	19	100	12	100	23	100	27	100	45	100	7	104	8	105	46	106	53	108	26	110
9	54	59	35	73	28	74	52	74	21	74	47	75	25	80	16	80	31	80	33	83	5	91	53	92	46	94	26	94	50	97
10	54	59	35	73	28	74	52	74	47	75	17	78	25	80	11	82	33	83	53	92	46	94	26	94	8	99	19	100	34	114
11	53	58	26	60	50	63	34	64	44	64	3	65	7	72	51	72	46	74	47	75	8	75	9	75	14	75	5	75	17	76
12	17	44	11	56	53	58	26	60	34	64	44	64	7	72	51	72	46	74	47	75	8	75	9	75	14	75	6	79	25	80
13	19	100	28	106	52	106	21	106	54	109	35	123	47	125	46	126	17	128	25	130	11	132	33	133	20	133	5	141	53	142
14	19	100	28	106	52	106	54	109	35	123	47	125	46	126	17	128	25	130	11	132	33	133	20	133	53	142	26	144	34	146
15	20	83	34	96	44	96	19	100	12	100	23	100	27	100	45	100	18	102	7	104	51	104	46	106	53	108	26	110	50	113
16	20	83	17	94	34	96	44	96	19	100	12	100	23	100	27	100	45	100	7	104	51	104	46	106	11	106	53	108	26	110

Já na Tabela 18, são apresentados os 15 primeiros resultados do ranking dos OAs para cada estudante do CE2. Para analisar os resultados, utilizamos parâmetros semelhantes aos utilizados em trabalhos anteriores (CARVALHO et al., 2014; AGUIAR, 2015).

Tabela 18 – Experimento com estudantes do CE2 com repositório 1 de OAs.

Resultados																														
Ranking de Objetos de Aprendizagem (posições 1 a 15, IDs à esquerda, relevância calculada à direita)																														
Estudante	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15															
1	54	44	16	55	25	55	31	55	33	58	21	59	28	59	52	59	8	60	50	72	26	75	53	77	46	79	19	85	17	91
2	54	51	28	54	52	54	17	58	8	59	25	60	33	63	53	72	26	74	46	74	19	80	34	94	44	94	37	97	32	99
3	20	53	51	78	12	84	23	84	27	84	45	84	18	86	7	92	9	95	14	95	3	99	34	100	44	100	48	100	4	100
4	20	90	17	101	34	103	44	103	12	107	23	107	27	107	45	107	19	107	51	111	7	111	46	113	11	113	53	115	26	117

A análise dos resultados é feita de forma empírica, onde é percebido que alterações nas preferências dos estudantes alteram significativamente os rankings apresentados. Porém, os resultados diferiram do esperado.

Primeiramente, observou-se os metadados dispostos no repositório e o que se percebeu foi uma grande variação nos valores dispostos nos campos do IEEE LOM. O resultado foi um ranking altamente variado e sensível as diferenças de preferências dos estudantes.

Para facilitar visualização, alguns elementos da tabela receberam cores diferentes. Na Tabela 17, os OAs de códigos “54 e 17” ocupam o Top 5 dos rankings da maioria dos estudantes. Ainda assim, suas posições são bem variadas nos rankings e receberam valores diferentes no calculo de relevância para cada estudante.

Essas observações mostram que o modelo é sensível às alterações no modelo do estudante, sejam elas grandes, ou não. Isso é confirmado pelo experimento da Tabela 18, onde dada ênfase em outros OAs, como os de código “34 e 19”, que apesar de aparecerem em 3 dos 4 estudantes, tiveram uma posição bem variada no ranking.

Esse comportamento é bem-vindo e esperado pelo modelo, onde, podemos observar, pela Tabela 16 que os estudantes 1 e 2, por exemplo, possuem preferências semelhantes de EAs, mas valores diferentes em seu modelo. Ainda assim, obtivemos rankings bem variados para recomendação.

4.1.2 Experimento 2

Para este experimento, utilizamos o Repositório 2 de OAs. Na Tabela 19 podemos ver os 15 primeiros resultados do ranking para cada um dos 16 estudantes do CE1.

Tabela 19 – Experimento com estudantes do CE1 com repositório 2 de OAs.

Resultados																														
Ranking de Objetos de Aprendizagem (posições 1 a 15, IDs à esquerda, relevância calculada à direita)																														
Estudante	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15															
1	39	117	99	117	100	117	728	117	83	150	313	150	790	150	1	200	2	200	3	200	4	200	5	200	6	200	7	200	8	200
2	39	167	99	167	100	167	728	167	47	184	83	200	313	200	790	200	378	200	449	200	523	200	688	200	1	250	2	250	3	250
3	39	83	99	83	100	83	728	83	83	100	313	100	790	100	378	150	449	150	523	150	688	150	1	150	2	150	3	150	4	150
4	39	133	99	133	100	133	728	133	47	134	83	150	313	150	790	150	378	150	449	150	523	150	688	150	1	200	2	200	3	200
5	39	117	99	117	100	117	728	117	83	150	313	150	790	150	378	150	449	150	523	150	688	150	1	150	2	150	4	150	6	150
6	47	134	378	150	449	150	523	150	688	150	39	167	99	167	100	167	728	167	83	200	313	200	790	200	1	200	2	200	4	200
7	39	83	99	83	100	83	728	83	378	100	449	100	523	100	688	100	83	100	313	100	790	100	1	100	2	100	4	100	6	100
8	47	84	378	100	449	100	523	100	688	100	39	133	99	133	100	133	728	133	83	150	313	150	790	150	1	150	2	150	4	150
9	39	117	99	117	100	117	728	117	83	150	313	150	790	150	3	150	5	150	7	150	43	150	245	150	518	150	701	150	378	200
10	39	167	99	167	100	167	728	167	47	184	83	200	313	200	790	200	3	200	5	200	7	200	43	200	245	200	518	200	701	200
11	39	83	99	83	100	83	728	83	83	100	313	100	790	100	3	100	5	100	7	100	43	100	245	100	518	100	701	100	378	150
12	39	133	99	133	100	133	728	133	47	134	83	150	313	150	790	150	3	150	5	150	7	150	43	150	245	150	518	150	701	150
13	39	117	99	117	100	117	728	117	83	150	313	150	790	150	3	150	5	150	7	150	43	150	245	150	518	150	701	150	378	150
14	47	134	378	150	449	150	523	150	688	150	39	167	99	167	100	167	728	167	83	200	313	200	790	200	3	200	5	200	7	200
15	39	83	99	83	100	83	728	83	378	100	449	100	523	100	688	100	83	100	313	100	790	100	3	100	5	100	7	100	43	100
16	47	84	378	100	449	100	523	100	688	100	39	133	99	133	100	133	728	133	83	150	313	150	790	150	3	150	5	150	7	150

Já na Tabela 20 estão o Top 15 resultados do ranking dos estudantes do CE2 no repositório 2. As análises feitas levam em consideração as observações do experimento da Subseção 4.1.1.

Tabela 20 – Experimento com estudantes do CE2 com repositório 2 de OAs.

Resultados																														
Ranking de Objetos de Aprendizagem (posições 1 a 15, IDs à esquerda, relevância calculada à direita)																														
Estudante	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15															
1	39	102	99	102	100	102	728	102	83	135	313	135	790	135	1	185	2	185	3	185	4	185	5	185	6	185	7	185	12	185
2	39	147	99	147	100	147	728	147	47	164	83	180	313	180	790	180	378	180	449	180	523	180	688	180	1	230	2	230	3	230
3	3	70	5	70	7	70	43	70	245	70	518	70	701	70	83	84	313	84	790	84	379	86	39	97	99	97	100	97	728	97
4	47	77	378	93	449	93	523	93	688	93	39	140	99	140	100	140	728	140	379	143	1	143	2	143	4	143	6	143	12	143

Para este experimento, ao analisar os metadados no repositório, percebeu-se que os valores inseridos nos campos do IEEE LOM não possuem grande variação, com exceção do campo *Learning Resource Type*. No CX, os metadados são colocados em cada aula/slide

de forma facilitada, porém, ainda manualmente. As observações constatadas nos experimentos abre precedentes para a discussão que o preenchimento manual dos metadados ainda é um grande problema para a recomendação personalizada de OAs.

Olhando agora para os resultados apresentados na Tabela 19, observa-se que assim, como no experimento anterior, obtivemos rankings variados para cada preferência dos estudantes, ainda que uma variação menor que os obtidos pelo repositório 1 (levando em consideração apenas as 15 primeiras recomendações do ranking para cada estudante). Além disso, a variação dos valores de relevância calculados também tiveram uma repetição maior que no experimento anterior.

Esse comportamento não necessariamente é ruim ao modelo e é esperado, pois, apesar dos estudantes terem preferências diferentes, os valores não tem uma variação suficientemente grande para que suas listas de recomendações sejam completamente diferentes. E, observando a Tabela 20, é possível ver que os rankings são diferentes o suficiente para recomendarmos objetos diferentes para cada estudante, ainda que seja apenas o Top 5.

4.1.3 Experimento Questões de Competência

É importante para a validade de uma ontologia que suas Questões de Competência (QC) tenham resultados claros e possíveis. Como a ontologia foi incluída no protótipo e usada como base para todo o processo, esse experimento utilizará dele para apresentar resultados das QCs. Foram determinadas para a OntAES as seguintes QCs:

- 1. Qual a classificação de um OA X de acordo com o FSLSM?
- 2. É possível dizer se um estudante pode tirar proveito de forma eficiente de um determinado OA?

Para este experimento, utilizamos um estudante com o modelo apresentado na Figura 9. Além disso, o repositório utilizado é o segundo, que apresentou melhor comportamento nos experimentos anteriores.

Para o estudante da Figura 9, obtivemos o ranking exibido na Figura 10. Para responder a primeira QC, considerando x como o OA apresentado na Figura 11 vemos que ele é classificado como a combinação 3 da Tabela 14, mostrando que com a OntAES é possível realizar esse tipo de classificação.

Para respondermos a QC 2 podemos analisar o ranking apresentado na Figura 10. O estudante do exemplo pertence a combinação 1 da lista apresentada na Tabela 14, portanto, logicamente o OA ideal para ele, seria um que também pertencesse a mesma combinação do FSLSM e que tivesse os mesmos valores em cada EA.

Sabemos, porém, que isso nem sempre é possível e, na maioria das vezes, é improvável que algum OA assim esteja disponível. Logo, ao utilizarmos o modelo probabilístico do

Figura 9 – Modelo do estudante utilizado no experimento

Notas	Código	Título
88	42	Aula 11 - Prática 8 - Se...
91	39	Aula 09 - Prática 07 - N...
106	21	Aula 06 - Prática 02 - M...
106	24	Aula 08 - Mapeamento ...
112	28	Aula 10 - Prática 03 - M...
112	52	Aula 16 - Prática 06 - S...
115	54	Aula 18 - Prática 07 - Vi...
116	30	Aula 10 - Peso de Ter...
116	49	Aula 14 - Recuperação...
118	55	Aula 15 - Análise de Li...
119	38	Lista Prova 2 e Infos
128	19	Aula 04 - Prática 01 - M...
130	16	Aula 06 - Prática 02 - AI...
130	31	Aula 11 - Prática 04 - P...
131	13	Aula 01 - Introdução

Figura 10 – Modelo do estudante utilizado no experimento

estudante, ranqueamos então do OA que tem a maior probabilidade de ser adequado ao estudante, para aquele que tem a menor probabilidade.

Em nosso experimento, por exemplo, o Top 1 do ranqueamento é o OA apresentado na Figura 11, que está mais próximo, matematicamente falando, do estudante que o Top 2, apresentado na Figura 12.

Observando ainda os Top 3 e 4 do ranking, é possível ver que eles tem o mesmo valor de relevância atribuídos pelo sistema. Porém, observando as Figuras 13 e 14, percebemos que eles pertencem a combinações diferentes do FSLSM. Isso é interessante para o ponto de visto descrito anteriormente, onde para realizarmos a recomendação de bons OAs, eles

Título do Objeto:			
Aula 11 - Prática 8 - Services			
Código:	42	Nota:	88
Ativo:	42 %	Reflexivo:	58 %
Visual:	20 %	Verbal:	80 %
Sensitivo:	100 %	Intuitivo:	0 %
Sequencial:	100 %	Global:	0 %

% Valores

Alterna Visualização

Figura 11 – Classificação probabilística do OA 42 em FSLSM.

Título do Objeto:			
Aula 09 - Prática 07 - Notificações e Dialogs			
Código:	39	Nota:	91
Ativo:	25 %	Reflexivo:	75 %
Visual:	34 %	Verbal:	66 %
Sensitivo:	100 %	Intuitivo:	0 %
Sequencial:	100 %	Global:	0 %

% Valores

Alterna Visualização

Figura 12 – Classificação probabilística do OA 39 em FSLSM.

não necessariamente devem pertencer à mesma combinação que o estudante.

Título do Objeto:			
Aula 06 - Prática 02 - MER-X			
Código:	21	Nota:	106
Ativo:	60 %	Reflexivo:	40 %
Visual:	34 %	Verbal:	66 %
Sensitivo:	50 %	Intuitivo:	50 %
Sequencial:	100 %	Global:	0 %

% Valores

Alterna Visualização

Figura 13 – Classificação probabilística do OA 21 em FSLSM.

Título do Objeto:			
Aula 08 - Mapeamento MER - MR(Modelo Relacional)			
Código:	24	Nota:	106
Ativo:	12 %	Reflexivo:	88 %
Visual:	40 %	Verbal:	60 %
Sensitivo:	100 %	Intuitivo:	0 %
Sequencial:	50 %	Global:	50 %

% Valores

Alterna Visualização

Figura 14 – Classificação probabilística do OA 24 em FSLSM.

Conclusão

Este trabalho apresentou uma abordagem para personalização automática do processo de ensino com base no mapeamento automático de OAs do padrão IEEE LOM em EAs do FSLSM. O processo foi também modelado por uma ontologia a qual foi denominada OntAES.

Os experimentos realizados validaram a proposta e mostraram um modelo de recomendação sensível aos diversos modelos de estudante. A abordagem descrita é flexível ao domínio de execução do sistema em que será incluído, uma vez que foi criado sem se prender a um tema específico.

Das análises empíricas observou-se limitações existentes na escolha do modelo IEEE LOM, que possui metadados extensos a serem preenchidos, o que dificulta a obtenção de bons repositórios, mesmo quando seu preenchimento é feito de forma facilitada em sistemas como o Classroom eXperience. Essa crítica pode porém ser estendida para a grande maioria dos padrões de metadados para documentos virtuais.

O IEEE LOM porém também se torna uma boa escolha, uma vez que é o padrão definido pela IEEE, o que resulta em grande quantidade de publicações feitas baseadas nele. Além da existência de vários suplementos que procuram suprir duas necessidades mais evidentes, como o CLEO, que também foi inserido nesta pesquisa.

O FSLSM também divide opiniões recebendo várias críticas quando utilizada, mas também sendo amplamente usada como modelo do estudante ou parte dele. Graf et al. (2009) defende em seu trabalho que a utilização dos EAs do FSLSM no modelo do estudante proporciona uma adaptação mais holística e precisa.

Por fim, podemos concluir que os resultados do trabalho foram satisfatórios e cumpriram com o que era esperado no início de seu desenvolvimento. A produção da ontologia trouxe também uma base sólida para a abordagem, trazendo uma abstração para o tema útil na adaptação para outros domínios.

5.1 Principais Contribuições

Dentre as contribuições deste trabalho, devem ser destacadas:

- ❑ A definição de um mapeamento consistente entre o padrão IEEE LOM acrescido do CLEO e os EAs do FSLSM. Esse mapeamento foi criado a partir da associação da teoria de cada EA e o significado de cada valor possível para os metadados
- ❑ A criação de uma abordagem de recomendação promissora e independente ao domínio de conhecimento abordado pelo STI a que for implementado.
- ❑ O desenvolvimento de uma ontologia que mapeia e classifica os OAs em uma das possíveis 16 combinações de EAs do FSLSM.

5.2 Trabalhos Futuros

Como perspectivas de trabalhos futuros é possível incluir:

- ❑ Evoluir o mapeamento feito de forma a se adaptar outros padrões de metadados. Dessa forma, os sistemas que utilizarem da abordagem de recomendação desse trabalho poderão reutilizar um conjunto maior de OAs de autores diversos.
- ❑ Desenvolver uma técnica de conversão entre dois ou mais padrões de metadados.
- ❑ Utilizar estudantes reais para os experimentos e colher seu feedback.

5.3 Contribuições em Produção Bibliográfica

A folha de rosto das publicações resultantes deste trabalho podem ser vistas no Anexo A.

Referências

AGUIAR, J. J. et al. Um mapeamento sistemático sobre iniciativas brasileiras em sistemas de recomendação educacionais. In: **Anais do Simpósio Brasileiro de Informática na Educação**. [S.l.: s.n.], 2014. v. 25, n. 1, p. 1123. DOI: <https://doi.org/10.5753/cbie.sbie.2014.1123>.

AGUIAR, J. J. B. **Recomendação de Objetos de Aprendizagem baseada em Estilos de Aprendizagem e Traços de Personalidade**. Tese (Dissertação de Mestrado) — Universidade Federal de Campina Grande, 2015.

BITTENCOURT, I. I.; COSTA, E. Modelos e Ferramentas para a Construção de Sistemas Educacionais Adaptativos e Semânticos. **Revista Brasileira de Informática na Educação**, v. 19, n. 01, p. 85, 2011. ISSN 1414-5685. DOI: <https://doi.org/10.5753/rbie.2011.19.01.85>.

BOHL, O. et al. The sharable content object reference model (SCORM) - a critical review. In: **International Conference on Computers in Education, 2002. Proceedings**. IEEE Comput. Soc, 2002. v. 1, p. 950–951. ISBN 0-7695-1509-6. DOI: <https://doi.org/10.1007/springer>
<>.

BORENSTEIN, N. S.; FREED, N. Multipurpose internet mail extensions (mime) part one: Format of internet message bodies. 1996. DOI: <https://doi.org/10.1109/mic.2010.121>.

BRAY, T. et al. Extensible markup language (xml). **World Wide Web Consortium Recommendation REC-xml-19980210**. <http://www.w3.org/TR/1998/REC-xml-19980210>, v. 16, p. 16, 1998.

BRUSILOVSKY, P.; SCHWARZ, E.; WEBER, G. Elm-art: An intelligent tutoring system on world wide web. In: SPRINGER. **International Conference on Intelligent Tutoring Systems**. [S.l.], 1996. p. 261–269. DOI: https://doi.org/10.1007/3-540-61327-7_123.

CARVALHO, V. C. et al. Uma Abordagem para Recomendação Automática e Dinâmica de Objetos de Aprendizagem Baseada em Estilos de Aprendizagem. In: **Anais do Simpósio Brasileiro de Informática na Educação**. [s.n.], 2014. v. 25, n. 1,

p. 1188. <https://doi.org/10.5753/cbie.wcbie.2015.135>. Disponível em: <<http://br-ie.org/pub/index.php/sbie/article/view/3065>>.

CAZELLA, S. C.; NUNES, M.; REATEGUI, E. B. A ciência da opinião: Estado da arte em sistemas de recomendação. In: **XXX Congresso da Sociedade Brasileira de Computação—Jornada de Atualização em Informática (JAI)**. [S.l.: s.n.], 2010. p. 161–216. Acesso em http://www.inf.pucminas.br/sbc2010/anais/jai/index_arquivos/mini4.htm.

CLEO. **CLEO Extensions to the IEEE Learning Object Metadata**. [S.l.], 2003. Available on <https://www.oasis-open.org/committees/download.php/20490/CLEO_LOM_Ext_v1d1a.pdf>. Accessed in: October, 2016.

DORÇA, F. A. et al. A New Approach to Discover Students Learning Styles in Adaptive Educational Systems. **Revista Brasileira de Informática na Educação**, v. 21, n. 1, p. 25–2013, 2013. DOI: <https://doi.org/10.5753/rbie.2013.21.01.76>.

DORÇA, F. A.; RESENDE, D. T. Recomendação de conteúdo personalizada com base em estilos de aprendizagem: uma abordagem prática. **Revista Brasileira de Informática na Educação**, v. 23, n. 03, p. 12, dec 2015. ISSN 1414-5685. Disponível em: <<http://www.br-ie.org/pub/index.php/rbie/article/view/2867>>.

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

FERREIRA, H. N. M. et al. Classroom Experience: A Platform for Multimedia Capture and Access in Instrumented Educational Environments. In: **2012 Brazilian Symposium on Collaborative Systems**. IEEE, 2012. p. 59–64. ISBN 978-1-4673-4696-2. <https://doi.org/10.1109/sbsc.2012.20>. Disponível em: <<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6391732>>.

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

FREITAS, F. L. G. Ontologias ea web semântica. **Sociedade Brasileira de Computação (SBC). II Jornada de Mini-Cursos de Inteligência Artificial**, p. 1–52, 2003.

GLUZ, J. C.; VICARI, R. M. Uma Ontologia OWL para Metadados IEEELOM, Dublin-Core e OBAA. **Anais do Simpósio Brasileiro de Informática na Educação**, v. 1, n. 1, 2011. ISSN 2316-6533.

GRAF, S. et al. Learning styles and cognitive traits - Their relationship and its benefits in web-based educational systems. **Computers in Human Behavior**, v. 25, n. 6, p. 1280–1289, 2009. ISSN 07475632. <https://doi.org/10.1016/j.chb.2009.06.005>.

- _____. In-depth analysis of the felder-silverman learning style dimensions. **Journal of Research on Technology in Education**, Taylor & Francis, v. 40, n. 1, p. 79–93, 2007. DOI: <https://doi.org/10.1080/15391523.2007.10782498>.
- GRÜNINGER, M.; FOX, M. S. Methodology for the design and evaluation of ontologies. In: . [S.l.: s.n.], 1995.
- GRUBER, T. What is an ontology. **WWW Site** <http://www-ksl.stanford.edu/kst/whatis-an-ontology.html> (accessed on 07-09-2004), 1993.
- HORROCKS, I. et al. Swrl: A semantic web rule language combining owl and ruleml. **W3C Member submission**, v. 21, p. 79, 2004.
- IEEE. **1484.12.1-2002 IEEE Standard for Learning Object Metadata**. 2002. Disponível em: <<http://ieeesa.centraldesktop.com/ltsc/>>.
- KOIVUNEN, M.-R.; MILLER, E. W3c semantic web activity. **Semantic Web Kick-Off in Finland**, p. 27–44, 2001. DOI: [https://doi.org/10.1016/s0098-7913\(03\)00003-0](https://doi.org/10.1016/s0098-7913(03)00003-0).
- MACHION, A. C. G. **Uso de ontologias e mapas conceituais na descoberta e análise de objetos de aprendizagem: um estudo de caso em eletrostática**. Tese (Doutorado) — Universidade de São Paulo, 2007. DOI: <https://doi.org/10.11606/t.45.2007.tde-06042009-122508>.
- NOY, N. F.; MCGUINNESS, D. L. **Ontology Development 101: A Guide to Creating Your First Ontology**. 2001. 25 p. Disponível em: <http://liris.cnrs.fr/alain.mille/enseignements/Ecole{_}Centrale/Whatisanontologyandwhyweneedit.>
- O’CONNOR, M. J.; DAS, A. K. Sqwrl: A query language for owl. In: **OWLED**. [S.l.: s.n.], 2009. v. 529.
- OLIVEIRA, J. P. M. d. et al. Adaptweb: um ambiente para ensino-aprendizagem adaptativo na web. **Educar em revista. Curitiba. Nesp (2003)**, p. 175-197, 2003. DOI: <https://doi.org/10.1590/0104-4060.305>.
- PICKLER, M. E. V. Web semântica: ontologias como ferramentas de representação do conhecimento. **Perspectivas em Ciência da Informação**, SciELO Brasil, v. 12, n. 1, p. 65–83, 2007. DOI: <https://doi.org/10.1590/s1413-99362007000100006>.
- PRETI, O. Educação a distância e globalização: desafios e tendências. **Revista Brasileira de Estudos Pedagógicos**, v. 79, n. 191, 2007. ISSN 21766681.
- REID, J. M. **Understanding learning styles in the second language classroom**. [S.l.]: Prentice Hall Regents, 1998.
- REZENDE, P. A. A. et al. PERSONNA: proposta de ontologia de contexto e perfil de alunos para recomendação de objetos de aprendizagem. **Revista Brasileira de Informática na Educação**, v. 23, n. 01, p. 70, apr 2015. ISSN 1414-5685. DOI:

<https://doi.org/10.5753/rbie.2015.23.01.70>. Disponível em: <<http://www.br-ie.org/pub/index.php/rbie/article/view/2460>>.

SANT'ANNA, F.; CERQUEIRA, R.; SOARES, L. F. G. Nclua: objetos imperativos lua na linguagem declarativa ncl. In: ACM. **Proceedings of the 14th Brazilian Symposium on Multimedia and the Web**. [S.l.], 2008. p. 83–90. DOI: <https://doi.org/10.1145/1666091.16661>

SANTOS, F. C.; CARVALHO, C. L. de. Aplicações de suporte à web semântica. 2007.

SOUZA, J. T. de. **Teoria da revisao de primeira ordem para a modelagem do estudante**. Tese (Doutorado) — Universidade Federal do Ceará, 2000.

Timm Hinz, V.; GASPARINI, I.; PIMENTA, M. S. Em busca de recomendação de objetos de aprendizagem em um ambiente e-learning com uso de ontologias. 2011.

USCHOLD, M.; GRUNINGER, M. Ontologies: principles, methods and applications. **The Knowledge Engineering Review**, Cambridge University Press, v. 11, n. 2, p. 93–136, 1996.

VICARI, R. M. et al. Proposta brasileira de metadados para objetos de aprendizagem baseados em agentes (obaa). 2010.

VIEIRA, F. J. R.; NUNES, M. A. S. N. DICA: Sistema de Recomendação de Objetos de Aprendizagem Baseado em Conteúdo. **Scientia Plena**, v. 8, n. 5, 2012. ISSN 1808-2793.

W3C. **W3C WebSite 2001**. 2001. Disponível em: <<http://www.w3.org/2001/sw>>.

WEIBEL, S. et al. **Dublin core metadata for resource discovery**. [S.l.], 1998. DOI: <https://doi.org/10.17487/rfc2413>.

WENGER, E. Artificial intelligence and tutoring system: Computational and cognitive approaches to the communication of knowledge. **Califórnia: Morgan Kaufmann Publishers. Texto publicado na: Pátio-revista pedagógica Editora Artes Médicas Sul Ano**, v. 1, p. 19–21, 1987.

WILEY, D. Connecting learning objects to instructional design theory: A definition, a metaphor, and a taxonomy. In: _____. **The Instructional Use of Learning Objects**. Bloomington, Indiana, USA: The Agency for Instructional Technology, 2002. p. 3–23. Disponível em: <<http://www.elearning-reviews.org/topics/technology/learning-objects/2001-wiley-learning-objects-instructional-design-theory.pdf>>.

YU, L. **A developer's guide to the semantic web**. [S.l.]: Springer, 2011. ISBN 978-3-662-43796-4.

ZAINA, L. A. M. et al. e-LORS: Uma Abordagem para Recomendação de Objetos de Aprendizagem. **Revista Brasileira de Informática na Educação**, v. 20, n. 1, p. 04, 2012. ISSN 1414-5685. DOI: <https://doi.org/10.5753/rbie.2012.20.1.04>.

Anexos

ANEXO **A**

Publicações Bibliográficas

Neste Anexo são apresentadas as folhas de rosto dos artigos publicados com relação a essa pesquisa.

Uma Abordagem para Recomendação Automática e Dinâmica de Objetos de Aprendizagem Baseada em Estilos de Aprendizagem

Vitor C. de Carvalho¹, Rafael D. Araújo¹, Renan G. Cattelan¹, Fabiano A. Dorça¹

¹Faculdade de Computação – Universidade Federal de Uberlândia (UFU)
Uberlândia – MG – Brasil

vitorcarvalho@comp.ufu.br, rafael@doutorado.ufu.br,

{renan, fabiano}@facom.ufu.br

Abstract. *The adaptation of content delivery in systems aimed at teaching is a research area in full expansion. This is explained by studies showing that students tend to have better performances when the content delivery is customized. In this context, students' learning styles should be observed, due to the importance of this feature to the adaptivity process in such systems. Thus, this paper presents an efficient approach for personalization of the teaching process. Our approach is based on the automatic mapping of students' learning styles characteristics to learning objects' metadata. Promising results, obtained through experiments, are presented and demonstrate the soundness of our proposal.*

Resumo. *A adaptação de fornecimento de conteúdo em sistemas voltados para o ensino é uma área de pesquisa em franca expansão. Isto é explicado por trabalhos que demonstram que estudantes tendem a ter um maior aproveitamento quando a apresentação do conteúdo é personalizada. Nesse contexto, os estilos de aprendizagem dos estudantes devem ser observados, sendo esta uma das mais importantes características a serem consideradas no processo de adaptatividade nesses sistemas. Dessa forma, este artigo apresenta uma abordagem eficiente para personalização do processo de ensino, que se baseia no mapeamento automático de características de estilos de aprendizagem de estudantes em metadados de objetos de aprendizagem. São apresentados resultados promissores, obtidos através de experimentos, que demonstram a validade da proposta.*

1. Introdução

Um objeto de aprendizagem (OA) pode ser definido como qualquer entidade, digital ou não, que possa ser utilizado, reutilizado ou referenciada no ensino assistido por tecnologia [Wiley 2002]. Entende-se por material digital, diversos tipos de mídia – como textos, animações, vídeos, imagens, aplicações ou páginas Web – utilizados para fins educacionais, isoladamente ou em conjunto [Behar and Torrezan 2009].

OA's precisam ser padronizados para garantir algumas propriedades como interoperabilidade e durabilidade. Surgiram, assim, algumas propostas de padronização, como é o caso do LTSC/IEEE *Learning Object Metadata* (LOM) [IEEE 2002]. A partir da

An Automatic and Dynamic Approach for Personalized Recommendation of Learning Objects Considering Students Learning Styles: An Experimental Analysis

Fabiano A. DORÇA, Rafael D. ARAÚJO, Vitor C. de CARVALHO,
Daniel T. RESENDE, Renan G. CATTELAN

*Faculty of Computer Science (FACOM) – Federal University of Uberlandia (UFU)
Campus Santa Monica – Bloco 1B – Sala 1B148
Av. Joao Naves de Avila, 2.121 – Bairro Santa Monica – CEP 38400-902
Uberlandia/MG, Brazil. Phone Number: +55 (34) 3239-4218
e-mail: fabianodor@ufu.br, rafael@doutorado.ufu.br, vitorcarvalho@comp.ufu.br,
danieltr@hotmail.com, renan@ufu.br*

Received: September 2015

Abstract. Content personalization in educational systems is an increasing research area. Studies show that students tend to have better performances when the content is customized according to his/her preferences. One important aspect of students particularities is how they prefer to learn. In this context, students learning styles should be considered, due to the importance of this feature to the adaptivity process in such systems. Thus, this work presents an efficient approach for personalization of the teaching process based on learning styles. Our approach is based on an expert system that implements a set of rules which classifies learning objects according to their teaching style, and then automatically filters learning objects according to students' learning styles. The best adapted learning objects are ranked and recommended to the student. Preliminary experiments suggest promising results.

Keywords: personalized content recommendation; learning styles; learning objects; expert systems; adaptive educational systems.

1. Introduction

The evolution of technology has allowed teachers and students to use the computer as a teaching-learning resource. Currently, it is possible that teachers, even without advanced computer skills, provide digital lessons. However, classic distance education environments, in which prevail the traditional teaching model (the same content presented for all students), have, according to Brooks *et al.* (2006), several limitations.

Uma Ontologia para Apoio à Recomendação Automática e Personalizada de Conteúdo Considerando Estilos de Aprendizagem de Estudantes em Sistemas Adaptativos para Educação

Vitor C. de Carvalho¹, Miller M. Mendes¹, Hiran N. M. Ferreira²
Fabiano A. Dorça¹, Renan G. Cattelan¹

¹ Faculdade de Computação – Universidade Federal de Uberlândia (UFU)
Uberlândia - MG - Brasil.

²Instituto Federal de Educação, Ciência e Tecnologia do Sul de Minas Gerais
(IFSULDEMINAS)
Passos - MG - Brasil

millier@comp.ufu.br, vitor@mestrado.ufu.br

hiran.ferreira@ifsuldeminas.edu.br, {renan, fabianodor}@ufu.br

Abstract: *Several approaches to personalized recommendation of content in adaptive systems for education have emerged. Many of them have considered the importance of taking into account students' learning styles in order to achieve better results in the learning process. Recent studies confirm this trend. Thus, this work aims to present an ontology to support these approaches, using as a basis the IEEE LOM and the model of Felder-Silverman for learning styles. As a result, the proposed ontology generates a vectorial representation of learning objects considering its teaching styles. The ontology has been validated through experiments, and promising results were obtained, demonstrating the potential contribution of the proposal to adaptive systems for education.*

Resumo: *Diversas abordagens para recomendação personalizada de conteúdo em sistemas adaptativos para educação têm surgido. Muitas têm considerado a importância de levar em consideração os estilos de aprendizagem do estudante para que melhores resultados possam ser alcançados no processo de aprendizagem. Estudos recentes comprovam essa tendência. Desta forma, este trabalho tem como objetivo apresentar uma ontologia para apoio à essas abordagens, usando como base o padrão IEEE LOM e o modelo de Felder-Silverman. Como resultado, a ontologia proposta gera uma representação vetorial de objetos de aprendizagem considerando os estilos de aprendizagem satisfeitos por eles. A ontologia foi validada através de experimentos, e resultados promissores foram obtidos, demonstrando o potencial de contribuição desta proposta a sistemas adaptativos para educação.*

1. Introdução

A web pode ser vista como uma grande biblioteca virtual, onde com pouco tempo de busca, é possível se encontrar todo tipo de conteúdo. Porém, a forma como ela foi construída inicialmente dava possibilidade para que apenas os seres humanos pudessem entender o conteúdo apresentado. Para que sistemas computacionais processassem os dados

OntAES: Uma Ontologia para Sistemas Adaptativos Educacionais Baseada em Objetos de Aprendizagem e Estilos de Aprendizagem

Vitor C. de Carvalho¹, Rafael D. Araújo¹, Hiran N. M. Ferreira²
Fabiano A. Dorça¹, Renan G. Cattelan¹

¹ Faculdade de Computação – Universidade Federal de Uberlândia (UFU)
Uberlândia, MG, Brasil.

²Instituto Federal de Educação, Ciência e Tecnologia do Sul de Minas Gerais
(IFSULDEMINAS) – Passos, MG, Brasil

{vitor.carvalho, rafael.araujo}@ufu.br

hiran.ferreira@ifsuldeminas.edu.br, {renan, fabianodor}@ufu.br

Abstract. *This study aims to present an ontology that supports adaptive systems for education based on a relationship between Learning Objects and a Learning Styles model. The ontology, called OntAES, follows the entire teaching process, from the insertion of OAs and students into the system, to classification and ranking in a personalized and automatic way. In addition, it presents a comparative approach between how to calculate the OA ranking for each student.*

Resumo. *Este estudo tem o objetivo de apresentar uma ontologia que auxilia sistemas adaptativos para educação, baseada num relacionamento entre Objetos de Aprendizagem e em um modelo de Estilos de Aprendizagem. A ontologia, denominada OntAES acompanha todo o processo de ensino, desde a inserção de OAs e estudantes no sistema, até a classificação e ranqueamento de forma personalizada e automática. Além disso, apresenta uma abordagem comparativa entre forma de calcular o ranking de OAs para cada estudante.*

1. Introdução

O uso de sistemas computacionais é cada vez mais comum no ensino, onde oferecem apoio tanto ao instrutor quanto ao estudante. Esses sistemas utilizam de Objetos de Aprendizagem (OAs) como tecnologia de conteúdo e em muitos casos fornecem personalização e adaptabilidade com o objetivo de adequar o curso à cada aprendiz de forma individual.

Utilizar OAs como objeto de conhecimento é uma abordagem consistente no contexto do ensino, visto que podem ser definidos como quaisquer recursos virtuais de aprendizagem como vídeos, imagens e textos que tenham como objetivo trazer informação a ser assimilada pelo aprendiz. Além disso, os OAs acompanham metadados que os descrevem para garantir a sua acessibilidade, interoperabilidade e a capacidade de serem reusados por diversos sistemas e autores como, por exemplo, o padrão IEEE-LOM [IEEE 2002].

Em geral, esses sistemas possuem algum grau de personalização, o que é necessário, pois, cada estudante vivencia o processo de aprendizagem de forma diferente, demonstrando aspectos cognitivos que dão ênfase em suas melhores habilidades. A