

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE INFORMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO

DIEGO ALESSANDRO PEREIRA DOS SANTOS

**Recomendação Sensível ao Contexto
Aplicada à Educação Híbrida**

Dissertação apresentada como requisito parcial para a obtenção do grau de Mestre em Ciência da Computação.

Orientador: Prof. Dr. José Palazzo Moreira de Oliveira

Porto Alegre
2022

CIP – CATALOGAÇÃO NA PUBLICAÇÃO

Santos, Diego Alessandro Pereira dos

Recomendação de Recursos Educacionais em um ambiente de educação híbrida / Diego Alessandro Pereira dos Santos. – Porto Alegre: PPGC da UFRGS, 2022.

63 f.:il.

Dissertação (Mestrado) – Universidade Federal do Rio Grande do Sul. Programa de Pós-Graduação em Computação. Porto Alegre, BR – RS, 2022. Orientador: José Palazzo Moreira de Oliveira

1.Sistemas de Recomendação. 2.Ontologias. 3. Sensibilidade ao Contexto. 4.Educação Híbrida. I. Oliveira, José Palazzo Moreira de Oliveira. II. Título.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: Prof. Carlos André Bulhões

Vice-Reitora: Prof^ª. Patricia Pranke

Pró-Reitor de Pós-Graduação: Prof. Júlio Otávio Jardim Barcellos

Diretora do Instituto de Informática: Prof^ª. Carla Maria Dal Sasso Freitas

Coordenador do PPGC: Prof. Claudio Rosito Jung

Bibliotecária-chefe do Instituto de Informática: Beatriz Regina Bastos Haro

AGRADECIMENTOS

Primeiramente a Deus, pelo fôlego de vida, pela força e por permitir que tudo isso fosse possível.

À minha amada esposa, amiga e companheira de vida, Juliane, pela paciência durante as necessárias ausências, e principalmente pelo suporte e incentivo em todos os momentos. Sou eternamente grato por ter você ao meu lado.

Aos meus pais, Gilnei e Sandra, por proporcionar uma base sólida para a nossa família, de caráter e de sabedoria, essenciais para a conclusão desta etapa. Aos meus irmãos, Nicolas e Ana, pela compreensão e apoio, assim como aos demais familiares que participaram deste processo.

Ao Prof. Dr. José Palazzo, meu orientador, pelo profissionalismo e generosidade com que orientou este trabalho. Obrigado pelo acolhimento, estímulo e disponibilidade durante todo esse processo, que me permitiram receber um pouco do seu vasto conhecimento e experiência. Sinto-me grato e honrado por conhecê-lo e poder trabalhar sob sua orientação.

Aos demais colegas do grupo de pesquisa, em especial ao Gabriel, ao Leonardo e ao Mcdonnell, pelo estímulo e compartilhamento de ideias e experiências.

À UFRGS, seus professores e técnicos-administrativos, que trabalham de forma exemplar, disponibilizando educação e pesquisa pública, gratuita e de qualidade.

Ao IFSul - Campus Saporanga, pelo apoio logístico que me permitiu realizar esta pesquisa com dedicação integral. Aos colegas do IFSul, em especial ao Alfredo e ao Cassiano, pelo suporte oferecido durante esse processo com a alteração em suas rotinas de trabalho.

RESUMO

Ambientes de educação híbrida são aqueles que combinam instrução presencial com instrução mediada por computador, e têm ganhado espaço nos meios de discussão sobre novas metodologias educacionais. Vários benefícios são observados na utilização dessa metodologia, dentre eles: aumento do desempenho acadêmico e das habilidades sociais dos estudantes, aumento da flexibilidade de ensino e aprendizagem, aumento da satisfação do estudante, diminuição das taxas de evasão e aumento da retenção escolar. O papel das TICs é central nesse cenário, podendo colaborar com o que se chama aprendizagem ubíqua, ou seja, um ambiente de aprendizado diário que fornece conteúdo e interação a qualquer hora e lugar aos alunos. Sistemas de recomendação são muito úteis nesses ambientes, provendo a sugestão de conteúdos e atividades de forma personalizada aos usuários. Neste âmbito, este trabalho propõe um modelo para recomendação de recursos de aprendizagem sensível ao contexto em um ambiente de educação híbrida, utilizando ontologia. Para avaliar o modelo, foram utilizadas regras SWRL (*Semantic Web Rule Language*) através do motor de inferência Pellet. A abordagem foi avaliada através de um estudo de caso que representa a situação de um aluno em um ambiente de educação híbrida, com diversas opções de recursos, em que as escolhas podem variar de acordo com o seu perfil geral e acadêmico, além do seu contexto atual. Então, as regras de recomendação são executadas, tendo como resultado a sugestão de recursos para o aluno, onde verificou-se que o modelo é capaz de inferir relações entre o aluno e os recursos de aprendizagem, levando em conta o seu perfil, a tecnologia disponível e a sua localização. Assim, foi apresentada a verificação da abordagem proposta, possibilitando a reprodução dos procedimentos e testes realizados.

Palavras-chave: Sistemas de Recomendação. Ontologias. Sensibilidade ao Contexto. Educação Híbrida.

Context-aware Recommendation applied to blended learning

ABSTRACT

Blended learning environments are those that combine face-to-face instruction with computer-mediated instruction and have gained space in the means of discussion about new educational methodologies. Several benefits are observed in this methodology, including an increase in academic performance and students' social skills, an increase in teaching and learning flexibility, an increase in student satisfaction, a decrease in dropout rates, and an increase in school retention. The role of ICTs is central in this scenario, collaborating with ubiquitous learning, that is, a daily learning environment that provides content and interaction anytime and anywhere to students. Recommender systems are very useful in these environments, providing users with personalized suggestions for content and activities. In this context, this work proposes a model for recommending learning resources in a blended learning environment, using ontology. To evaluate the model, SWRL rules were used through the Pellet inference engine. The approach was evaluated through a case study that represents a student's situation in a hybrid education environment, with several options of resources, in which the choices may vary according to their educational and administrative profile, in addition to their current context. Then, the recommendation rules are executed, resulting in the suggestion of resources for the student, so it was verified that the model is capable of inferring relationships between the student and the learning resources, taking into account his profile, the technology available and your location. Thus, the proposed approach was verified, enabling the reproduction of the performed procedures and tests.

Keywords: Recommender Systems. Ontologies. Context Awareness. Blended Learning.

LISTA DE FIGURAS

Figura 2.3 - Tipos de Ontologias	19
Figura 4.1 - Visão geral do modelo	33
Figura 4.2 - Modelo de Aluno	34
Figura 4.3 - Modelo de Localização	36
Figura 4.4 - Modelo de Tecnologia	37
Figura 4.5 - Modelo de Recursos de Aprendizagem	38
Figura 4.6 - Classes do Modelo Geral Desenvolvido	40
Figura 4.7 - Relação entre os modelos de aluno, localização, tecnologia e recurso de aprendizagem	41
Figura 5.1 - Visão geral do uso do modelo.....	44
Figura 5.2 - Modelo Instanciado com um aluno em sua residência	46
Figura 5.3 - Perfis geral e acadêmico do modelo instanciado com aluno em sua residência ..	47
Figura 5.4 - Resultado das Regras Inferidas pelo Pellet com aluno em sua residência	49
Figura 5.5 - Modelo instanciado para o cenário de um aluno em um campus	50
Figura 5.6 - Perfis geral e acadêmico do modelo instanciado - aluno em um campus	51
Figura 5.7 - Resultado das Regras Inferidas pelo Pellet com aluno em um campus	53

LISTA DE TABELAS

Tabela 3.1 - Comparativo entre os trabalhos relacionados	27
--	----

LISTA DE ABREVIATURAS E SIGLAS

ASTD	American Society for Training and Development
AVA	Ambiente Virtual de Aprendizagem
EAD	Ensino a Distância
ELARS	E-Learning Activities Recommender System
ERE	Ensino Remoto Emergencial
FGV	Fundação Getúlio Vargas
FSLSM	Felder - Silverman Learning Style Model
GPS	Global Positioning System
GSP	Generalized Sequential Patterns
IMS-LD	Instructional Management Systems-Learning Design
KIF	Knowledge Interchange Format
KNN	K Nearest Neighbor
LOM	Learning Object Metadata
MOOC	Massive Open Online Course
OIL	Ontology Interchange Language
OWL	Web Ontology Language
TIC	Tecnologia da Informação e Comunicação
RBC	Recomendação Baseada em Conhecimento
SADE	Sistema de Acompanhamento do Desempenho de Estudantes
SR	Sistema de Recomendação
SWRL	Semantic Web Rule Language
UML	Unified Modeling Language
VAK	Visual, Auditory and Kinesthetic
W3C	World Wide Web Consortium
XOL	XML-Based Ontology Exchange Language

SUMÁRIO

1 INTRODUÇÃO.....	10
2 FUNDAMENTAÇÃO CONCEITUAL.....	13
2.1 Ensino Híbrido.....	13
2.1.1 Modelos de Ensino Híbrido.....	14
2.1.1.1 Modelos de Rotação.....	14
2.1.1.2 Modelo Flex.....	14
2.1.1.3 Modelo <i>à la carte</i>	15
2.1.1.4 Modelo virtual enriquecido.....	15
2.2 Sistemas de Recomendação.....	16
2.2.1 Recomendação baseada em conhecimento.....	17
2.3 Ontologias e Web Semântica.....	18
2.4 Considerações finais do capítulo.....	20
3 TRABALHOS RELACIONADOS.....	22
3.1 Apresentação dos trabalhos.....	22
3.2 Análise dos trabalhos.....	27
3.3 Considerações finais do capítulo.....	29
4 ABORDAGEM DESENVOLVIDA.....	31
4.1 Metodologia utilizada.....	31
4.2 Especificação da Ontologia.....	35
4.3 Modelagem desenvolvida.....	42
4.3 Considerações finais do capítulo.....	44
5 ESTUDO DE CASO.....	46
5.1 Possibilidade de Utilização.....	46
5.2 Regras de Inferência.....	47
5.3 Cenário de Uso 1 - Residência.....	48
5.4 Cenário de Uso 2 - Campus.....	52
5.5 Considerações finais do capítulo.....	56
6 CONCLUSÃO.....	57
REFERÊNCIAS.....	59

1 INTRODUÇÃO

O ambiente educacional tem passado por diversas mudanças digitais nos últimos anos, muito em função da evolução cultural e do aumento do acesso aos avanços tecnológicos por parte da população em geral.

A maior parte dos alunos usa dispositivos móveis em sala de aula, mesmo quando em desacordo às normas estabelecidas. Muitas vezes esse movimento é uma atitude de iniciativa de busca de informação, o que evidencia uma oportunidade de desenvolvimento nas áreas de computação e educação (NAGUMO e TELES, 2016).

Nesse contexto, o ensino híbrido voltou a ganhar força nos espaços de discussão sobre novas metodologias educacionais. O conceito de ensino híbrido tem sido estudado e difundido há vários anos (VALIATHAN, 2002) (PINA, 2004) (OLIVER, 2005) (GRAHAM, 2006). Em 2003, a American Society for Training and Development (ASTD) já apontava o ensino híbrido como uma das 10 maiores tendências a emergir na indústria do conhecimento (ROONEY, 2003). Em trabalhos atuais, pesquisadores vêm investigando tanto a implementação como os efeitos da educação híbrida em diferentes ambientes educacionais (RAFIOLA et al., 2020) (VO, 2020) (ANTHONY et al., 2020) (BRUGGEMAN et al., 2021).

Mais recentemente, Agarwal (2021) trata sobre algumas tendências de mudanças nas práticas educacionais nos próximos anos, apontando o ensino híbrido como uma das práticas mais promissoras no futuro próximo. Ele mostra que eventos recentes, como a pandemia da COVID-19, fizeram acelerar o processo de mudança em várias práticas educacionais que já estavam sendo pensadas, destacando o papel do hibridismo nesse movimento. Cabe registrar que, em geral, as práticas alternativas realizadas durante a pandemia da COVID-19 não foram práticas de ensino híbrido, mas sim ensino remoto emergencial (ERE), pois apesar de utilizar recursos computacionais a distância, não havia um planejamento em termos de metodologias e de adequação dos planos de cursos de acordo com os fundamentos do ensino híbrido. Fica claro que essa necessária adaptação poderia ter sido mais produtiva caso essa metodologia já estivesse implantada de uma forma mais efetiva.

Entre as vantagens práticas da educação híbrida, algumas se destacam, conforme o estudo realizado por Ali (2019): aumento do desempenho acadêmico e de habilidades sociais dos estudantes, aumento da flexibilidade de ensino e aprendizagem, assim como o aumento da satisfação do estudante. Verifica-se, ainda, diminuição das taxas de evasão e aumento da retenção escolar.

Uma mudança de cultura que se percebeu necessária para a efetivação da prática do ensino híbrido é o acesso a equipamentos e internet de forma ampla pela população. Nota-se que o aumento do uso da tecnologia no cotidiano das pessoas está cada vez mais evidente com o passar dos anos. O poder computacional que antes era restrito a Centros de Processamento de Dados e profissionais especializados em Tecnologia da Informação, hoje está ao alcance de cidadãos leigos em escritórios, casas ou mesmo na rua, através de dispositivos móveis. Atualmente há 424 milhões de dispositivos digitais em uso no Brasil (em torno de 2 dispositivos por cidadão), divididos entre 190 milhões de computadores e 234 milhões de smartphones, conforme aponta estudo conduzido pela FGV (MEIRELLES, 2020), que também indicou um crescimento maior na aquisição e no uso de dispositivos móveis em relação a computadores. Assim, apesar de os dispositivos móveis não serem uma solução para todas as práticas educacionais, nota-se que uma mudança na cultura digital já está ocorrendo rapidamente para a população em geral, tornando o ambiente propício para as práticas do ensino híbrido.

A união do uso da tecnologia móvel na educação com o conceito de computação pervasiva pode ser aplicada ao ambiente universitário, cooperando para o desenvolvimento de um smart campus e para a prática do aprendizado ubíquo. A aprendizagem ubíqua pode ser definida como um ambiente de aprendizado diário suportado por dispositivos móveis e redes sem fio na vida cotidiana das pessoas (OGATA et al., 2009), tendo como principal objetivo fornecer conteúdo e interação a qualquer hora e lugar aos alunos (HWANG et al., 2008). Nesse sentido, a aprendizagem inclui a vivência real aumentada por informações virtuais, devendo ser adaptada ao aluno e seu ambiente. Assim, em função das necessidades de aprendizagem do aluno, os conteúdos, atividades, bem como a interação com colegas ou professores podem ser personalizados (ESSALMI et al., 2012).

Nota-se que há vários trabalhos que focam no planejamento e na implementação das práticas pedagógicas do ensino híbrido. Não foi encontrada na literatura, porém, uma proposta que vise auxiliar o cotidiano do aluno frente às diferentes opções de atividades que ele pode realizar no ambiente híbrido, com recomendações de atividades que levem em conta as especificidades deste ambiente. Sistemas de recomendação geram sugestões de itens interessantes para os usuários (RICCI et al., 2011), sendo então úteis para essa finalidade.

Alunos em um ambiente de ensino híbrido podem se encontrar em diferentes situações, por exemplo, em relação a condições de equipamentos utilizados ou em relação ao momento no processo de ensino (virtual ou presencial). Sistemas sensíveis ao contexto são úteis nesses ambientes, pois são aqueles que usam informações de contexto (ciência dos

recursos e dos relacionamentos deles com o usuário no ambiente) para prover informações e/ou serviços relevantes para o usuário (DEY, 2001).

Assim, em função da clara oportunidade de pesquisa nesse subdomínio da computação aplicada à educação, a questão de pesquisa deste trabalho é: **como desenvolver um modelo semântico para recomendação de recursos educacionais sensível ao contexto aplicado a ambientes de educação híbrida?**

Em relação aos aspectos metodológicos da pesquisa científica, quanto à natureza, o presente trabalho se mostra uma pesquisa aplicada, visto que foca em aplicar os conhecimentos a fim de colaborar com a educação híbrida. Para isso, são necessários procedimentos técnicos de pesquisa específicos, como a pesquisa bibliográfica, a fim de realizar a fundamentação conceitual, seguido pela pesquisa experimental, onde o objeto de estudo é delimitado e são verificadas as possibilidades de aplicação.

2 FUNDAMENTAÇÃO CONCEITUAL

Este capítulo apresenta os fundamentos relacionados com a abordagem proposta neste trabalho, organizados em cinco seções. A seção 2.1 apresenta o Ensino Híbrido e suas implementações, domínio no qual se aplicou esta pesquisa. Na seção 2.2, são abordados os conceitos referentes a Sistemas de Recomendação, com destaque para a recomendação baseada em conhecimento e a sensibilidade ao contexto, conceitos utilizados neste trabalho. A seção 2.3 versa sobre os aspectos de Web Semântica e Ontologias, como agentes para a modelagem do conhecimento. Por fim, são apresentadas algumas considerações finais sobre o capítulo.

2.1 Ensino Híbrido

Segundo Graham (2006), há três definições frequentemente mencionadas em relação ao ensino híbrido: combinação de modalidades de ensino, combinação de métodos de ensino e combinação de instrução presencial com instrução mediada por computador. Em seguida, mostra que as duas primeiras definições são tão abrangentes que englobariam todos os sistemas de ensino. Graham define, então, que sistemas de ensino híbrido são aqueles que combinam instrução presencial com instrução mediada por computador.

No trabalho de Valiathan (2002) são apresentadas três categorias de modelos de aprendizagem híbrida: aprendizagem orientada a habilidades, aprendizagem orientada a atitudes e aprendizagem orientada a competências. A primeira ocorre com ensino de conhecimento específico e requer feedback regular e apoio de um tutor ou facilitador. No modelo orientado a atitudes, há conteúdo que lida com o desenvolvimento de novas atitudes e comportamentos. O modelo orientado a competências é utilizado para facilitar a transferência de conhecimento específico, que geralmente é encontrado em especialistas.

Bacich et al. (2015) apresentam uma definição mais ampla, onde a expressão ensino híbrido está fortemente ligada à educação híbrida, no sentido de que não há uma forma única de aprender e na qual a aprendizagem é um processo contínuo, ocorrendo de formas diversas, em diferentes espaços. Essa abordagem amplia as oportunidades de trabalho unificado entre as referidas áreas.

2.1.1 Modelos de Ensino Híbrido

Quanto à implementação, existem diferentes formas aplicadas ao ensino híbrido. Horn e Staker (2015) organizam essas formas em: Modelos de Rotação, Modelo Flex, Modelo à la Carte e Modelo Virtual Enriquecido. A seguir, é apresentada uma breve descrição desses modelos.

2.1.1.1 Modelos de Rotação

Modelos de rotação são modelos em que há rotação por grupos de alunos e/ou períodos e equipamentos, sendo dividido em quatro: rotação por estações, laboratório rotacional, sala de aula invertida e rotação individual, conforme descrito a seguir:

a) Rotação por estações: nesse modelo, a rotação ocorre dentro de sala de aula ou de um conjunto de salas de aula, sendo o ensino conduzido pelo professor em pequenos grupos.

b) Laboratório Rotacional: semelhante à rotação por estações, porém os estudantes se encaminham para o laboratório de informática para a parte de ensino on-line.

c) Sala de Aula Invertida: os estudantes têm aulas on-line de forma independente, durante o período fora da escola, enquanto o tempo de sala de aula é utilizado para assistência durante o que seria a “lição de casa”.

d) Rotação Individual: os estudantes alternam em um esquema individualmente personalizado entre modalidades de aprendizagem. Um professor ou um software estabelece o cronograma para cada aluno.

2.1.1.2 Modelo Flex

No modelo flex o ensino on-line é a espinha dorsal da aprendizagem e às vezes encaminha os estudantes para atividades presenciais. Os estudantes avançam pelo curso nesse modelo conforme suas necessidades individuais. A disponibilidade dos professores é principalmente para oferecer ajuda e ainda iniciar projetos ou discussões que aprofundem a aprendizagem. Esse modelo foi inicialmente utilizado em laboratórios de recuperação de notas e centros de educação alternativa, onde se mostrou eficiente e aumentou o seu alcance para outros ambientes de ensino.

2.1.1.3 Modelo *à la carte*

O modelo *à la carte* é verificado em qualquer disciplina ou curso que um estudante faça inteiramente on-line enquanto também frequenta uma escola tradicional. Nesse modelo, o professor tutor é o professor on-line. É frequentemente utilizado como atividade extracurricular, onde o aluno busca qualificação em algum tema que a escola não oferece de forma estrutural, como uma língua estrangeira ou atividades de arte, por exemplo.

2.1.1.4 Modelo virtual enriquecido

Cursos no modelo virtual enriquecido oferecem sessões de aprendizagem presencial, mas permitem que os estudantes façam o resto do trabalho on-line. Muitos desses programas começaram como escolas on-line que, percebendo a necessidade de suporte dos alunos, desenvolveram programas combinados. A maior diferença deste modelo para o modelo flex é que naquele o ensino ocorre baseado na modalidade online, e os encontros presenciais são ocasionais, enquanto neste, apesar de não haver encontros presenciais diários, eles são frequentes, obrigatórios e formam a base do processo de ensino. No Brasil este modelo também ficou conhecido em muitas universidades à distância como semi-presencial.

É importante registrar que os modelos de ensino não são uma regra engessada onde se opta por um caminho em detrimento dos outros. É possível a alternância de uso entre eles, bem como uma combinação de modelos, resultando em uma abordagem mista.

No estudo conduzido por Schiehl e Gasparini (2017), verificou-se que a maior parte dos trabalhos realizados sobre ensino híbrido, 62,5%, utilizam o modelo Suplementar (trabalho inicial em sala de aula e continuação em ambientes virtuais), equivalente ao Modelo Virtual Enriquecido, apresentado por Horn e Staker, e que a maioria das aplicações foram realizadas em ambientes universitários ou pós-universitários. Também foi apontado que 56% deles utilizam um AVA (Ambiente Virtual de Aprendizagem) como ferramenta para combinar o ensino presencial com ferramentas on-line, sendo também utilizados: Google, Facebook, dentre outros.

O modelo ontológico proposto neste trabalho pode ser utilizado em qualquer abordagem de ensino híbrido, porém optou-se pelo foco no modelo virtual enriquecido para a avaliação através do estudo de caso, em função de sua ampla utilização, mesmo que muitas vezes chamado de semi-presencial.

2.2 Sistemas de Recomendação

Os sistemas de recomendação são sistemas que geram sugestões de itens interessantes para a utilização dos usuários (RICCI et al., 2015), tendo como maior benefício a diminuição da sobrecarga de informação sobre o usuário, tornando a interação deste com o sistema uma atividade mais atrativa e personalizada, tendo em vista que as sugestões orientam os usuários frente às opções existentes (CAZELLA, 2010). Como consequência, outros benefícios podem ser apontados na utilização de sistemas de recomendação, como o suporte a tomada de decisões, a fidelização de clientes, o aumento de receitas, dentre outras (JANNACH e ADOMAVICIUS, 2016).

Os itens a serem recomendados podem ser os mais variados, como filmes, músicas, livros, vídeos, etc (TAKAHASHI, 2015). O desenvolvimento de sistemas de recomendação tem sido objeto de empresas a fim de agradar e fidelizar seus clientes, como a Netflix ao recomendar uma série, o YouTube ao recomendar um novo vídeo, ou até mesmo a recomendação de amizades, pelo Facebook.

De acordo com a técnica aplicada na recomendação, os SRs podem ser classificados a seguir (BURKE, 2007 apud RICCI et al, 2015):

- **Recomendação baseada no conteúdo:** sugere itens cujas características correspondem aos perfis do usuário. Nessa abordagem, o sistema aprende a recomendar itens que são similares aqueles que o usuário tenha avaliado positivamente no passado, geralmente a partir das características relacionadas ao item avaliado. Por exemplo, se um usuário avaliar positivamente um determinado gênero de filme, o SR aprenderá a recomendar outros filmes aquele gênero futuramente.
- **A Filtragem Colaborativa:** recomenda itens bem avaliados por outros usuários com perfis / interesses semelhantes. A similaridade de dois usuários é calculada com base na similaridade no histórico de avaliações dos usuários. É considerada a técnica mais popular e amplamente implementada de SR.
- **Recomendação baseada em demografia:** recomenda itens baseado no perfil demográfico do usuário. Essa abordagem entende que diferentes recomendações devem ser dadas para diferentes nichos demográficos. Por exemplo, recomendações que são geradas a partir da idade do usuário, ou mesmo o redirecionamento de sites a partir do país do qual o usuário o acessa.

- Recomendação baseada em conhecimento (RBC): usa requisitos explicitamente definidos do usuário e conhecimento do domínio modelado para recomendar itens que atendam as necessidades e preferências do usuário. Nesses sistemas, uma função de similaridade estima o quanto as necessidades do usuário correspondem às recomendações. Um tipo de SR baseado em conhecimento é o SR baseado em restrições, que é similar ao primeiro. A principal diferença entre eles é que enquanto o primeiro utiliza uma função de similaridade para gerar a correspondência entre o usuário e o item, o segundo gera tal correspondência através de regras explícitas, baseado no conhecimento do domínio.
- Recomendação baseada em comunidade: recomenda itens baseado nas preferências dos amigos do usuário. Também conhecido como sistemas de recomendação social, esse tipo de SR modela e adquire informações sobre as relações sociais dos usuários e as preferências dos amigos do usuário, para então recomendar baseado nas avaliações fornecidas por eles.
- Recomendação híbrida: combina mais de uma abordagem de recomendação. Geralmente, o objetivo de ter uma abordagem híbrida é combinar os pontos fortes de uma abordagem para cobrir as limitações da outra. Por exemplo, sistemas que utilizam filtragem colaborativa têm dificuldades para recomendar itens novos, já que eles ainda não têm classificação. Isso não é um problema, porém, para a abordagem baseada em conteúdo, já que esta considera apenas as características do item a ser recomendado.

Tendo em vista a utilização do conceito da recomendação baseada em conhecimento neste trabalho, a próxima subseção abordará um pouco mais sobre este tópico de sistemas de recomendação.

2.2.1 Recomendação baseada em conhecimento

A RBC é especialmente útil em casos onde há limitações para as técnicas de filtragem colaborativa e baseada em conteúdo. Alguns exemplos são quando os itens recomendados demandam grande complexidade e/ou pode haver o problema de *cold start*. O problema de *cold start* caracteriza-se pela limitação que o SR apresenta de não poder recomendar itens que ainda não foram avaliados ou mesmo quando o usuário é recente e não possui análise de similaridade. Assim, a RBC consegue lidar com essas situações por explorar os requisitos

explícitos do usuário e o conhecimento sobre o domínio para fazer as recomendações (FELFERNIG et al., 2015).

Uma diferenciação frequentemente feita dentro da recomendação baseada em conhecimento são: recomendação baseada em casos e recomendação baseada em restrições. Ambos os sistemas são muito semelhantes em relação ao conhecimento usado e as suas funcionalidades. A diferença está na forma de encontrar as recomendações. Enquanto a recomendação baseada em casos usa métricas de similaridade para sugerir os itens aos usuários, a recomendação baseada em restrições utiliza bases de conhecimento que contêm regras explícitas que relacionam os requisitos do cliente com as propriedades dos itens (BRIDGE et al., 2005) (ZANKER et al., 2010) (FELFERNIG et al., 2015).

Felfernig et al (2005) sugerem que a base de conhecimento para a recomendação pode ser definida em dois grupos de variáveis (V_u , V_i) e três conjuntos de restrições (Cr , Cf , Ci), conforme descrito a seguir:

- Propriedades do usuário (V_u) - descrevem os possíveis requisitos do usuário. No domínio de serviços financeiros, a disposição de assumir riscos seria um exemplo de propriedade do cliente e a disposição de assumir riscos = baixo representa um requisito concreto do usuário.
- Propriedades do item (V_i) - descrevem as propriedades de um determinado agrupamento de produtos. São exemplos: tipo de produto, período de investimento recomendado ou retorno esperado do investimento.
- Restrições (Cr) - servem para restringir as possíveis instâncias de propriedades de usuários. Por exemplo, curtos períodos de investimento são incompatíveis com investimentos de alto risco.
- Condições de filtro (Cf) - definem a relação entre os requisitos usuários e o agrupamento de produtos fornecidos. Um exemplo de condição de filtro é o seguinte: clientes sem experiência no domínio de serviços financeiros não devem receber recomendações que incluem produtos de alto risco.
- Item (Ci) - representam as instâncias permitidas das propriedades do produto em função das restrições.

2.3 Ontologias e Web Semântica

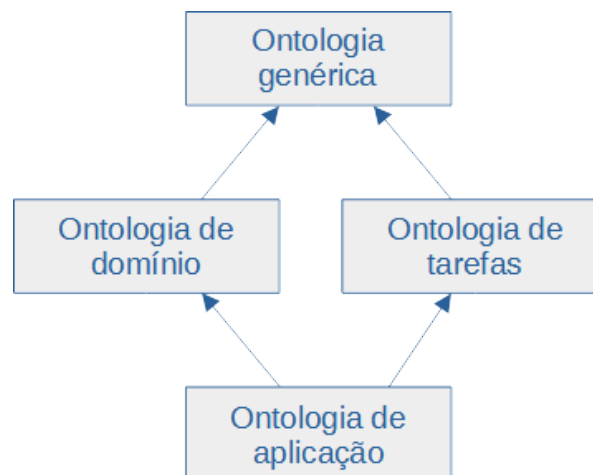
O termo ontologia tem origem na filosofia, e é derivado do grego: *onto* (ser) e *logos* (linguagem, palavra), que se refere a uma descrição sistemática da existência. Uma ontologia

pode ser definida como uma especificação formal e explícita de uma conceituação (GRUBER, 1993). Trata-se de um modelo abstrato da realidade em que todos os tipos de conceitos utilizados e suas restrições de uso são definidos explicitamente e formalmente, fazendo com que seja entendida tanto por humanos quanto por máquinas.

Segundo Guarino (1997, 1998), com base em seu conteúdo as ontologias podem ser classificadas da seguinte forma:

- Ontologias genéricas: também chamadas de ontologia de topo, descrevem conceitos amplos, como, elementos da natureza, tempo, matéria, evento, ação, independentes de um domínio específico, focando em teorias básicas do mundo. Concentram-se em conceitos abstratos.
- Ontologias de domínio: expressam conceitos de domínios específicos, descrevendo o vocabulário relacionado a um domínio genérico, por exemplo computação ou educação.
- Ontologias de tarefas: descrevem tarefas ou atividades que venham a contribuir com a resolução de problemas, independentemente do domínio em que ocorram, isto é, descrevem uma atividade ou tarefa em si de forma genérica, por exemplo, diagnósticos ou vendas.
- Ontologias de aplicação: expressam conceitos relacionados a um domínio e a uma tarefa específicos. São especializações dos termos das ontologias de domínio e de tarefa correspondentes.
- Ontologias de representação: descrevem as conceituações que fundamentam os formalismos de representação de conhecimento.

Figura 2.3 - Tipos de Ontologias



Fonte: Guarino (1998)

Diversas linguagens foram desenvolvidas para a criação de ontologias, alguns exemplos são: CycL (*Cyc Language*), KIF (*Knowledge Interchange Format*), OIL (*Ontology Interchange Language*), XOL (*Language for Ontology Exchange*) e OWL (*Web Ontology Language*), dentre as quais a OWL se tornou a principal (ALMEIDA et al., 2003). Desenvolvida e recomendada pelo *World Wide Web Consortium* (W3C) a OWL é uma linguagem da Web Semântica projetada para representar conhecimento rico e complexo sobre coisas, seus grupos e relações. OWL é uma linguagem baseada em lógica computacional de forma que o conhecimento expresso por ela pode ser explorado por programas de computador, por exemplo, para verificar a consistência desse conhecimento ou tornar o conhecimento implícito em explícito. As ontologias modeladas em OWL podem ser publicadas na *World Wide Web* e podem referir-se ou ser referidos a partir de outras ontologias OWL (W3C, 2012) (ALMEIDA et al, 2003).

A web semântica é uma extensão da atual web, onde a informação tem um significado bem definido, através da inserção de estrutura ao conteúdo significativo das páginas web, fazendo com que computadores e pessoas possam trabalhar em cooperação. Tal extensão tem o potencial de aumentos significativos nas possibilidades de desenvolvimento de funcionalidades, utilizando a capacidade de as máquinas processarem e entenderem os dados, ao invés de apenas exibi-los como hoje (BERNERS-LEE et al., 2001). Nota-se que este é um momento de transição, que depende do aumento do volume de dados com anotação semântica e não apenas marcação sintática, que é a maior parte atualmente.

Berners-Lee et al. (2001) indicam que o desafio para a web semântica é fornecer uma linguagem que expresse dados e regras para raciocinar sobre os dados e que permita que regras sejam exportadas para a web independente do sistema de representação existente. Uma linguagem indicada para realizar a transição da atual web para a web semântica é a OWL, através da criação de ontologias. Ou seja, a utilização de ontologias desenvolvidas em OWL, com a representação do conhecimento de forma complexa, possibilita o avanço para a web semântica.

2.4 Considerações finais do capítulo

Através da fundamentação conceitual foi possível analisar os principais conceitos a serem utilizados neste trabalho. A busca dentre as estratégias de recomendação mostrou que a recomendação baseada em conhecimento é a mais adequada, já que permite trabalhar com a

complexidade do domínio ao mesmo tempo em que lida melhor o problema de partida a frio. Verificou ainda que o uso de ontologias é o mais indicado, visto que ao mesmo em que permite a criação de um modelo de usuário (aluno) e das atividades a serem desenvolvidas, permite a validação deste modelo através de regras SWRL (Linguagem de Regras da Web Semântica, do inglês *Semantic Web Rule Language*), possibilitando a geração de recomendações úteis ao dia a dia do aluno.

3 TRABALHOS RELACIONADOS

Diversos estudos são encontrados na literatura que abordam a recomendação de recursos de aprendizagem, principalmente focados no *e-learning*, utilizando diferentes técnicas com essa finalidade. Não foi encontrada na literatura o uso de ontologias em sistemas de recomendação focada na educação híbrida. Assim, buscou-se reunir trabalhos que abordem a modelagem de aluno e de recursos de aprendizagem ou a recomendação de recursos de aprendizagem e o uso de ontologias para a modelagem e para recomendação. Primeiramente são apresentados os principais trabalhos encontrados na literatura. Em seguida, é feita a análise dos trabalhos em comparação com o modelo desenvolvido.

3.1 Apresentação dos trabalhos

No trabalho de Hoic-Bozic et al. (2015) foi apresentada a implementação de um ambiente de educação híbrida com o uso do sistema ELARS (Sistema de recomendação de atividades de *e-learning*, do inglês *E-Learning Activities Recommender System*) para recomendar recursos educacionais. O sistema ELARS recomenda quatro tipos de e-atividades (*e-tivities*): atividades opcionais, possíveis colaboradores (outros estudantes), ferramentas de web 2.0 e orientação.

Wonoseto e Rosmansyah (2017) desenvolveram um sistema de recomendação baseado em conhecimento aplicado a uma escola na Indonésia. Foram considerados o conhecimento do estilo de aprendizagem e a teoria da aprendizagem colaborativa, realizando a modelagem em duas etapas: identificação dos estilos de aprendizagem e recomendação baseada no estilo de aprendizagem e na colaboração. Para identificação dos estilos de aprendizagem, baseados na teoria de Flaming, os autores aplicaram um questionário VAK (visual, auditivo ou cinestésico, do inglês *Visual, Auditory and Kinesthetic*), a fim de modelar os alunos a partir dos estilos de aprendizagem VAK. Então, em uma segunda etapa, os objetos de aprendizagem foram agrupados dentro das características para serem recomendados aos alunos de acordo com os seus estilos de aprendizagem. Cada aluno também recebeu a indicação de um colaborador com o mesmo estilo de aprendizagem, porém com diferença de rendimento escolar.

Um modelo de *blended learning* apoiado por sistemas de recomendação foi proposto por Saied e Nasr (2018), que realizaram uma recomendação com base na correspondência entre o aluno e o recurso recomendado. Os autores realizaram duas modelagens: modelagem

de grupo e modelagem de conteúdo. Para a modelagem de grupo, foi aplicada uma abordagem de filtragem colaborativa de dois níveis a fim de agrupar os alunos de acordo com as semelhanças e diferenças entre suas preferências, enquanto na modelagem de conteúdo foram utilizadas técnicas de indexação e mineração de texto, utilizando o Nutch, motor de pesquisa de código aberto (<http://nutch.apache.org>). Como estratégia de recomendação foi adotada a filtragem baseada em conteúdo, através da mineração de modelos de aluno, mineração de regras de associação, rastreamento e indexação de recursos de aprendizado e extração das preferências do usuário.

No trabalho de Bouihi e Bahaj (2019) foi proposta uma arquitetura para recomendação de objetos de aprendizagem para o ensino a distância. A partir da arquitetura clássica de 3 camadas (apresentação, negócio e persistência), foi proposta a inserção de uma camada semântica entre as camadas de negócio e persistência. A camada proposta é composta por dois subsistemas semânticos: um sistema baseado em ontologia e um sistema baseado em regras SWRL. O subsistema baseado em ontologia é usado para modelar o conteúdo e o contexto do objeto de aprendizagem, de forma a fazê-lo reutilizável e compartilhável. O subsistema baseado em regras, por sua vez, é usado para recomendação, feita baseado na relevância do objeto de aprendizagem. Essas regras foram organizadas em quatro categorias: Regras de Histórico de Aprendizagem, Regras de Desempenho de Aprendizagem, Regras de Aprendizagem de Redes Sociais e Regras de Caminho de Aprendizagem. Os autores definiram os valores 5, 10 e 20 como peso de relevância para recomendação dos objetos de aprendizagem (baixo, médio e alto). Esses valores são atualizados a cada execução das regras SWRL.

Mendes et al. (2017) apresentaram o SADE (Sistema de Acompanhamento do Desempenho de Estudantes), um sistema que faz recomendações de objetos de aprendizagem a partir do perfil do desempenho dos alunos. A modelagem do perfil do aluno é realizada em duas etapas: primeiramente, são coletados os seus dados pessoais em um formulário de cadastro, então, no decorrer do uso, o sistema coleta informações a partir do desempenho do aluno nas avaliações realizadas pelo docente, classificando-o em 5 níveis (A, B, C, D e E). Para recomendação foi utilizada a técnica baseada em conteúdo, fazendo uso das informações da base de dados do aluno em função do seu desenvolvimento nas avaliações.

Tarus et al. (2018) propuseram uma abordagem de recomendação híbrida baseada em consciência de contexto e mineração sequencial de padrões para recomendar recursos de aprendizagem para alunos em ambientes de EAD. Os autores usaram consciência de contexto para inserir informação contextual sobre o aluno como nível de conhecimento e objetivos de

aprendizagem. Com o uso das informações contextuais, foi empregada Filtragem Colaborativa na estratégia de recomendação, através do coeficiente de correlação de Pearson e do algoritmo kNN (K Nearest Neighbor). Para filtrar as recomendações de acordo com os padrões de acesso, foi utilizada mineração sequencial de padrões, através do algoritmo GSP (Generalized Sequential Patterns) a fim de minerar os logs web.

Em Jeevamol e Renumol (2021) foi proposto um sistema de recomendação de conteúdo de *e-learning* baseado em ontologia para resolver o problema de *cold start*. A proposta é composta por 3 componentes principais: interfaces, ontologias e unidade de medida de similaridade de aluno e objeto de aprendizagem. No componente de ontologias foram construídas 3 ontologias: aluno, para modelar informações pessoais e de estilo de aprendizagem de acordo com FLSM (*Felder - Silverman Learning Style Model*); log de aluno, para modelar a trilha de aprendizado do aluno e; material, para modelar os objetos de aprendizagem, a partir do padrão LOM (*Learning Object Metadata*). Na unidade de medida de similaridade é utilizada ontologia para gerar recomendações em condições de partida a frio, combinado com técnicas de filtragem colaborativa e baseada em conteúdo.

Em Harrathi et al. (2017) foi apresentada uma proposta de sistema de recomendação de atividades de aprendizagem no contexto de MOOCs (Curso Online Aberto e Massivo, do inglês *Massive Open Online Course*), com o objetivo de auxiliar o aluno a seguir o processo de aprendizagem e diminuir a evasão. Foi utilizada a recomendação baseada em conhecimento como técnica para realizar a recomendação das atividades a distância, baseado em ontologia. O sistema utiliza ontologia para modelar e representar o conhecimento do domínio, o aluno e as atividades de aprendizagem.

A arquitetura do sistema proposto é composta por 3 camadas: interface do usuário, operação do sistema e banco de dados. A camada de interface do usuário é responsável por enviar os dados para alimentar o módulo de modelo do aluno e apresentar as recomendações vindas da camada de operação do sistema. A camada de operação do sistema contém 4 módulos: módulo de modelo do aluno, módulo de modelo do domínio, módulo de geração de recomendação e módulo de exibição de recomendação. A camada de banco de dados do sistema abstrai 3 bases de dados utilizados pelo sistema: base de dados do modelo do aluno, base de dados de regras e base de dados de atividades de aprendizagem.

O modelo de domínio foi baseado em uma ontologia relativa à especificação IMS-LD para especificar a estrutura de um curso MOOC. O perfil do aluno é composto por 4 subclasses: nível de conhecimento; características do aluno; estilo de aprendizagem e

preferências. A ontologia de atividades de aprendizagem tem 6 subclasses: dificuldade, tipo, hora de início, duração e prioridade.

Labib et al. (2017), focados no ensino a distância, apresentaram uma ontologia para modelar o perfil do aluno baseado na criação de inter-conexões entre as diferentes dimensões de modelo de estilo de aprendizagem, estilo de aprendizagem e as características relevantes do aluno. Os autores selecionaram as teorias de estilo de aprendizagem mais utilizadas nos últimos anos e fizeram um levantamento de como algumas características do aluno se relacionam com cada estilo de aprendizagem que possui alguma compatibilidade. As teorias utilizadas foram: modelo estilos de mente de Gregorc, modelo Honey e Munford, Estilos de Riding, Estilos de Myer Briggs, Estilos de Felder Silverman e Estilos de Kolb. As dimensões exploradas na ontologia foram: decisão, compreensão, modo de acesso, estilo de vida, organização e processo.

Os autores utilizaram a metodologia On-to-knowledge, apresentada em Sure et al. (2009), que possui 5 fases. Na fase 1 - *Estudo de Viabilidade*, foram coletadas informações sobre as bases de dados científicas relacionadas aos modelos de estilos de aprendizagem. Na fase 2 - *Partida*, foi realizado o processo de extração das características do aluno. Já na fase 3 - *Refinamento*, foram executadas 3 sub-fases: definição de uma taxonomia de base para formular a ontologia orientada a aplicação; elicitación, onde são definidos muitas entidades de conhecimento e; formalização, onde as entidades são organizadas em hierarquias. Nas fases 4 e 5 - *Avaliação e Manutenção*, após a utilização de *reasoner*, foram aplicadas várias *queries* de exemplo para testar a consistência e verificar a utilidade da ontologia.

No trabalho de Machado e Oliveira (2014), foi desenvolvido um sistema de recomendação de objetos de aprendizagem sensível ao contexto para usuários móveis em um smart campus. Os autores propuseram uma arquitetura cliente servidor em que o controlador de interface ficou no lado cliente, enquanto no lado servidor foram projetados três serviços: um mecanismo de raciocínio, a base de conhecimento e o coletor de contexto. Os autores desenvolveram um modelo que possui quatro dimensões de informações: de perfil, de tecnologia, de localização e de objetos de aprendizagem. Para modelar os objetos de aprendizagem, foi utilizado o padrão LOM. A partir de uma interface não intrusiva, o aluno recebe recomendações baseadas em regras em função de sua localização em um Campus.

Obeid et al. (2018) apresentaram uma proposta de sistema de recomendação baseado em ontologia para alunos de graduação. A abordagem utiliza de ontologia aprimorada com técnicas de aprendizagem de máquina para orientar estudantes no ensino superior, no sentido de avaliar pontos vocacionais fortes e fracos, interesses e capacidades do aluno, com a

finalidade de identificar interesses, requisitos, preferências e capacidade dos alunos para recomendar o curso e a universidade adequada. Os autores realizaram a pesquisa entre estudantes franceses e libaneses através dos portais das universidades.

O sistema proposto possui quatro partes principais: 1 - coleta de dados explícita e implícita, através dos dados preenchidos em seu perfil (explícita) e da proposta de uma pesquisa aos aluno para coletar informações sobre seus interesses (explícita); 2 - ontologia, que fornece suporte ao sistema pela modelagem do conhecimento do domínio, através da criação de três ontologias, instituição de ensino, emprego e estudante; 3 - aprendizado de máquina, que processa informações, criando e agrupando modelos de perfis de aluno e enviando os resultados para o mecanismo de recomendação híbrida; 4 - recomendação, através da compatibilidade entre alunos e interesses, realiza as recomendações e salva as informações de recomendação de alunos para ser utilizado posteriormente.

Ouf et al. (2017) realizaram um estudo detalhado sobre os trabalhos que utilizam ontologia em ambientes de ensino, verificando que a maior parte dos estudos são focados na personalização de objetos de aprendizagem, ignorando outros fatores. Os autores propõem, então, um *framework* para ambientes de ensino a distância, usando ontologia e SWRL. A arquitetura da proposta é composta de quatro camadas: 1 - Interface, que apresenta os resultados das recomendações; 2 - Mecanismo de Raciocínio Semântico, responsável pela personalização através do uso de *reasoners*, utilizando SWRL; 3 - Camada Semântica, que contém as representações semânticas dos componentes do processo de aprendizagem e; 4 - Metadados Semânticos, realiza a anotação dos conceitos e das suas relações.

A abordagem contém quatro ontologias, que formam a camada semântica: modelo de aluno, objetos de aprendizagem, atividades de aprendizagem e métodos de ensino. O modelo de aluno possui várias categorias: pessoal, conhecimento, comportamental, preferências, objetivos de aprendizagem e segurança. A ontologia de objetos de aprendizagem consiste em diferentes módulos. Um módulo inclui um conjunto de domínios, e cada domínio é composto por um ou mais assuntos, que incluem o conhecimento de diferentes assuntos associados ao aluno. A ontologia de atividades de aprendizagem define atividades como brainstorming, estudo de caso, trabalho em grupo, entre outros. A ontologia de métodos de ensino define métodos como reflexão, aprendizado baseado em projetos, *workshops*, dentre outros.

3.2 Análise dos trabalhos

Hoic-Bozic et al. (2015) focaram o trabalho na educação híbrida ao unir ensino presencial com ensino EAD e também enquanto metodologia educacional, ao combinar diferentes abordagens pedagógicas, com foco na aprendizagem colaborativa e baseada em problemas. A solução, porém, teve a implementação focada na recomendação de recursos EAD, não prevendo recursos de aprendizagem físicos. A abordagem proposta também não leva em consideração o contexto do aluno, como localização e tipo de tecnologia utilizada.

O trabalho de Wonoseto e Rosmansyah (2017) apresenta a modelagem do perfil do aluno com o objetivo de recomendar objetos de aprendizagem utilizando recomendação baseada em conhecimento. Não é explorado o hibridismo enquanto alternância entre presencial e a distância, também não é feita a modelagem de contexto para estas recomendações.

A proposta de Saied e Nasr (2018) realizou a modelagem de aluno e trabalhou com recomendação no ambiente de educação híbrida, sem explorar, porém, a possibilidade de recomendação de recursos físicos e nem a modelagem de contexto do aluno para realizar as recomendações.

O trabalho de Bouihi e Bahaj (2019) define uma camada semântica para modelagem e recomendação, porém não define as dimensões de contexto que serão utilizadas na modelagem e, por ter foco no EAD, não apresenta a possibilidade de recomendação de objetos de aprendizagem físicos.

Em Mendes et al. (2017) é realizada a modelagem do perfil do aluno e são geradas recomendações de objetos de aprendizagem, porém não é levado em consideração o contexto do aluno no momento da recomendação. Também não é explorada a web semântica na solução.

Tarus et al. (2018) apresentaram a modelagem de aluno a partir de contexto e realizaram recomendação de objetos de aprendizagem, porém utilizaram apenas algoritmos de mineração de dados, sem utilizar de semântica na abordagem. Ainda, a proposta contempla apenas objetos de aprendizagem *e-learning*, sem a possibilidade de utilização em educação híbrida.

O trabalho de Jeevamol e Renumol (2021) modelou o perfil do aluno e os objetos de aprendizagem, com o objetivo de gerar recomendações de objetos, utilizando ontologia com foco em mitigar o problema de partida a frio. Os autores não abordaram a consciência de

contexto e não há foco na recomendação de recursos físicos, o que permitiria aplicação na educação híbrida.

Harrathi et al. (2017) apresentaram a modelagem de perfil de aluno e trataram de recomendação, utilizando ontologias. Não houve, porém, a utilização de consciência de contexto do aluno e nem foi prevista a utilização de atividades de aprendizagem físicas, uma vez que o foco do trabalho era a aplicação em cursos MOOC.

Labib et al. (2017) exploraram a modelagem de perfil de aluno utilizando ontologia. Um dos objetivos é ajudar os professores na personalização do conteúdo didático, porém não foi utilizada nenhuma técnica de recomendação via sistema. O trabalho também não abordou a consciência de contexto.

O trabalho de Machado e Oliveira (2014) realizou a modelagem de perfil de aluno e de contexto utilizando ontologias com a finalidade de recomendar objetos de aprendizagem. Como o foco do trabalho era o cenário de um *Smart Campus*, o hibridismo não foi explorado na abordagem, tampouco a adaptação da recomendação em função da tecnologia disponível, uma vez que o objetivo era a utilização de dispositivos móveis.

Obeid et al. (2018) realizaram a modelagem do perfil de aluno e abordaram recomendação utilizando web semântica com ontologias. Uma vez que o trabalho não é focado em recursos de aprendizagem, não é contemplada a modelagem de contexto e nem abordada a educação híbrida.

Ouf et al. (2017) apresentaram a modelagem do perfil de aluno, e utilizaram de web semântica através de ontologia. Não foi, porém, abrangida a sensibilidade ao contexto e nem explorado o hibridismo no trabalho.

A tabela 3.1 apresenta um resumo da comparação entre os trabalhos apresentados com o presente trabalho.

Tabela 3.1 - Comparativo entre os trabalhos relacionados

Trabalho	Modelo de aluno	Recomendação	Contexto	Hibridismo	Ontologia
Hoic-Bozic et al. (2015)	x	x		x	
Wonoseto e Rosmansyah (2017)	x	x			x
Saied e Nasr (2018)	x	x		x	
Bouihi e Bahaj (2019)		x			x
Mendes et al. (2017)	x	x			
Tarus et al. (2018)	x	x	x		
Jeevamol e Renumol (2021)	x	x			x
Harrathi et al. (2017)	x	x			x
Labib et al. (2017)	x				x
Machado e Oliveira (2014)	x	x	x		x
Obeid et al. (2018)	x	x			x
Ouf et al. (2017)	x	x			x

Fonte: O Autor.

3.3 Considerações finais do capítulo

Neste capítulo foram apresentados artigos relacionados ao trabalho desenvolvido, que abrangem modelagem de perfil de aluno, sistemas de recomendação de recursos de aprendizagem, sensibilidade ao contexto, hibridismo e ontologia.

Nota-se que existem muitos esforços de pesquisa no sentido de recomendação de recursos de aprendizagem e que realizam a modelagem do perfil de aluno. Alguns trabalhos utilizam de web semântica e ontologia, poucos trabalhos abordam o hibridismo e a sensibilidade ao contexto. Foram estudados trabalhos que se dedicam a modelar o perfil de aluno e tratam da recomendação de recursos de aprendizagem, inclusive com web semântica e ontologias. Assim, o presente trabalho pode colaborar com o que já foi realizado através da exploração da sensibilidade ao contexto do aluno e da aplicação no ambiente de educação

híbrida, ao modelar recursos de aprendizagem físicos e digitais, com seus respectivos requisitos de uso e o contexto do aluno nas dimensões de localização e de tecnologia, que permitem enriquecer o processo de recomendação.

No próximo capítulo será apresentado o modelo ontológico desenvolvido neste trabalho. Para isso, será descrita a finalidade do desenvolvimento do modelo, em seguida será explicada a metodologia utilizada, então será apresentada a especificação da ontologia e, por fim, serão mostrados alguns aspectos da modelagem realizada no editor de ontologias Protegé.

4 ABORDAGEM DESENVOLVIDA

O problema de sobrecarga de informações, já conhecido nos ambientes educacionais, se potencializa no ambiente de educação híbrida, pois além das inúmeras opções que o aluno precisa lidar para escolher um recurso educacional que lhe ajude no processo de aprendizagem, existem limitações específicas em função do contexto em que o aluno vive e está no momento. Por exemplo, o aluno pode possuir uma residência com suporte a conexão de alta velocidade e computador de alto processamento, ou uma residência sem conexão, e contar apenas com um smartphone com conexão via dados móveis. Este trabalho propõe um modelo ontológico para recomendação de recursos de aprendizagem aplicado à educação híbrida.

No dia a dia, um exemplo que pode ser usado é um aluno que está em casa, e deseja utilizar um recurso de aprendizagem para o auxiliar na realização de uma tarefa para a próxima semana. Ele possui inúmeras opções de pesquisa e a busca de recursos não leva em consideração as suas condições de uso. Isso gera o que se chama de sobrecarga cognitiva e diminui a eficiência do seu estudo.

Para lidar com esse problema foi desenvolvido um modelo que conta com aspectos do perfil do usuário (geral e acadêmico), além de considerar três dimensões de contexto: tecnologia, localização e os dados dos recursos de aprendizagem. Assim, espera-se auxiliar o aluno no processo de escolha dos recursos disponíveis, diminuindo o tempo de procura dos mesmos, auxiliando o processo de aprendizagem. O modelo será melhor detalhado nas próximas subseções, com a apresentação da modelagem de cada um dos aspectos de contexto.

4.1 Metodologia utilizada

Há diversas maneiras de modelar um domínio, ou seja, não existe apenas uma alternativa considerada correta. A metodologia utilizada na construção do modelo ontológico proposto neste trabalho foi a “*Ontology development 101*”, proposta por Noy e McGuinness (2001). A metodologia proposta pelos autores apresenta uma maneira simples e interativa, como um passo-a-passo para a construção de uma ontologia, o que justifica sua escolha neste trabalho. O processo é dividido em sete passos a serem seguidos durante o desenvolvimento do modelo, descritos a seguir:

Passo 1. Determinar o domínio e o escopo da ontologia. Para esta tarefa, os autores sugerem algumas questões:

- *Qual é o domínio que a ontologia irá cobrir?* A ontologia cobrirá o domínio da educação híbrida.
- *Para que vamos usar a ontologia?* Vamos utilizar a ontologia para recomendar atividades e/ou recursos educacionais nesse ambiente.
- *Para quais tipos de perguntas as informações na ontologia devem fornecer respostas?* A ontologia deve responder às perguntas se o aluno está no ambiente escolar ou fora dele; se possui capacidade para utilizar determinado recurso fora do ambiente escolar; quais os recursos estão disponíveis em função da sua localização e do horário disponível.
- *Quem usará e manterá a ontologia?* A ontologia será utilizada por alunos, professores e pelo administrador do sistema. A mesma será mantida pelo administrador do sistema responsável pela dimensão pedagógica.

Os autores da metodologia de modelagem sugerem, ainda, que sejam realizadas perguntas que a base de conhecimento deveria ser capaz de responder, perguntas específicas, que servem como prova real para a ontologia. No domínio deste trabalho, podem ser feitas perguntas como: Quais recursos de aprendizagem podem ser recomendados para um aluno que está em casa e possui computador com alto processamento? Quais assuntos um aluno precisa estudar antes de poder receber a recomendação de um recurso de aprendizagem de um determinado assunto?

Passo 2. Considerar o reuso de ontologias. Considerar o que outras pessoas fizeram e checar se isso pode ser refinado ou ampliado quase sempre vale a pena. Isso pode até mesmo se tornar um requisito em algumas situações, por exemplo, caso o sistema a ser desenvolvido tenha que interagir com outro já comprometido com outra ontologia ou vocabulários controlados. O uso de sistemas de representação do conhecimento facilitam essa tarefa, já que permitem importar e exportar ontologias de forma rápida e prática, frequentemente independente do formalismo.

Após o estudo da fundamentação conceitual e dos trabalhos relacionados, não foram encontradas ontologias que tratem de recomendação de recursos de aprendizagem na educação híbrida. Existem, porém, diversos trabalhos que realizam a modelagem de perfil de aluno com o objetivo de recomendar, principalmente na área do *e-learning*, como em Gasparini et al. (2011) e Rezende et al. (2018). Neste trabalho foram utilizados conceitos da base ontológica do trabalho de Machado e Oliveira (2014) que realizaram a modelagem de perfil de aluno para a recomendação de objetos de aprendizagem em um *smart campus*.

Apesar deste trabalho não fazer uso de nenhuma ontologia já construída especificamente, muitos aspectos de trabalhos como os supracitados foram levados em conta para a construção do perfil de aluno, visto que a ideia de contexto do usuário é utilizada, assim como o aspecto de recursos digitais, que podem ser vistos como os objetos utilizados no *e-learning*.

Passo 3. Enumerar termos importantes na ontologia. No processo de modelagem é útil descrever os termos importantes dentro do domínio, termos que gostaríamos de usar em sentenças ou explicar ao usuário. Neste momento, não há necessidade de se preocupar com sobreposição de conceitos, relações entre os termos, propriedades que determinados conceitos devem ter, ou mesmo se um conceito será uma classe ou uma propriedade. É importante obter uma lista abrangente de termos. Algumas questões são sugeridas:

- *Sobre quais termos gostaríamos de falar?* Gostaríamos de falar sobre aluno, recurso de aprendizagem, campus, ambiente acadêmico, tecnologia, disciplina, tarefa, residência, perfil de aluno, equipamento, recomendação.
- *Quais propriedades têm esses termos?* Alguns termos têm suas propriedades já claramente definidas, como, aluno tem residência, localização, tecnologia, tarefa, disciplina, função acadêmica, trabalho, agenda e distância para um recurso de aprendizagem físico. A tecnologia tem características de tamanho de tela, velocidade de conexão, processamento e GPS. Um local tem pontos espaciais: latitude e longitude. Um recurso de aprendizagem tem assunto de abrangência. Recursos de aprendizagem físicos tem um local de armazenamento e recursos de aprendizagem digitais tem requisitos mínimos para utilização.
- *O que gostaríamos de falar sobre esses termos?* Gostaríamos de falar sobre os recursos de aprendizagem que devem ser recomendados para determinado aluno em determinada situação.

Passo 4. Definir as classes e a hierarquia de classes. Há algumas abordagens que podem ser utilizadas na construção de uma hierarquia de classes. No processo *top-down*, são definidos inicialmente os conceitos mais gerais do domínio, seguido pela especialização dos conceitos. No processo *bottom-up* são definidas as classes mais específicas do domínio, seguido pelo agrupamento dessas classes em conceitos mais genéricos. Uma outra abordagem é a combinação das duas primeiras, onde se define primeiramente os conceitos mais notáveis, para então especializar ou generalizar de acordo com o caso.

Neste trabalho foi utilizada a combinação das duas primeiras abordagens, onde primeiramente foi feita a definição dos principais conceitos, a partir do passo 3, para então fazer as devidas especializações e generalizações.

Primeiras classes definidas: aluno, recurso de aprendizagem (físico e digital), local (residência, campus, ambiente acadêmico), perfil de aluno, tarefa, disciplina, agenda, função acadêmica, assunto, trabalho, tecnologia, equipamento (computador, notebook e dispositivo móvel).

Passo 5. Definir as propriedades das classes. Após a definição das classes, o próximo passo é descrever a estrutura interna dos conceitos. Provavelmente muitos dos termos enumerados no passo 3 que restaram após a definição das classes no passo 4 serão propriedades das classes. Deve-se então definir, para cada propriedade da lista, a qual classe ela pertence, que se tornam slots da classe. Os autores definem alguns tipos de slots, conforme segue: I) intrínsecas, II) extrínsecas, III) partes, caso um objeto seja estruturado; e IV) relações: relacionamentos entre os membros individuais da classe com outros itens.

Algumas propriedades das classes que podem ser observadas inicialmente são: localização, distância, latitude e longitude, importantes para determinar o contexto de localização; e processamento, conexão, tamanho de tela e GPS, úteis para modelar o contexto de tecnologia do aluno.

Passo 6. Definir as restrições das propriedades (*slots*). Definidas as propriedades das classes, essas propriedades devem receber características / restrições, que podem ser de diferentes formas, como cardinalidade, tipo de valor ou domínio e alcance de um slot. A cardinalidade define quantos valores um slot pode ter. O tipo de valor do slot define qual tipo de valor pode ser usado para preencher o slot, como string, booleano ou enumeração (lista de valores pré-definidos). Já na restrição por domínio e alcance, define-se quais classes são permitidas para os slots (alcance) e quais as classes às quais um slot está vinculado ou a classe cuja propriedade descreve um slot (domínio).

No desenvolvimento da ontologia algumas restrições definidas são: *temLocalização*, tem "Aluno" como domínio e "Local" como alcance; *temPadraoConexão*, *temPadrãoProcessamento* e *temPadrãoTamanhoTela*, que tem tecnologia como domínio e uma lista de valores (1, 2, 3) como alcance; os valores de latitude e longitude foram definidos com o tipo de valor float; o slot *temGPS* teve o tipo de valor definido como booleano; as propriedades de objeto *temRequisitoPadrãoConexão*, *temRequisitoPadrãoProcessamento*, *temRequisitoTamanhoTela* tem um recurso de aprendizagem digital como domínio e uma lista

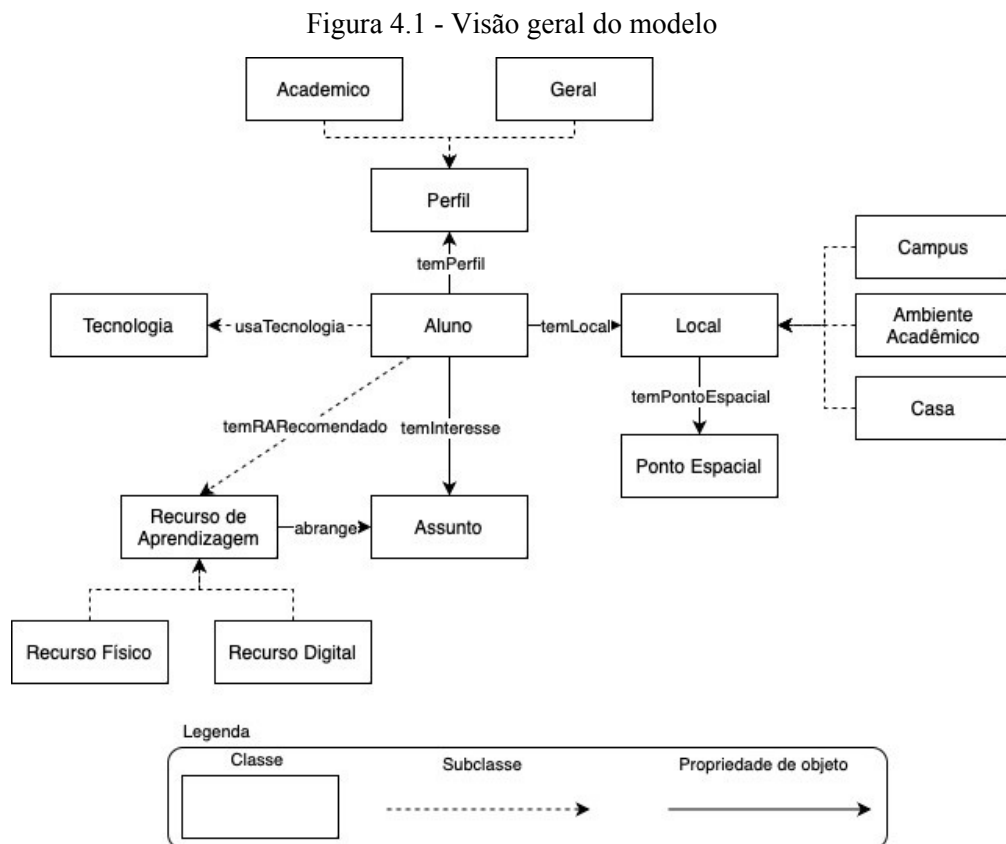
de valores (1, 2, 3) como alcance; *consideraDistanciaProximo* teve um valor definido de *integer* como alcance tendo aluno como domínio.

Passo 7. Criar instâncias. A criação de instâncias individuais das classes é a última etapa da modelagem. Para isso, deve-se escolher a classe, criar uma instância individual dessa classe e preencher os valores dos slots.

Como exemplo de instâncias criadas neste trabalho estão os alunos Murilo e Miguel. Também são instâncias o campus Sapiranga do IFSul, instância da classe Campus, subclasse de Local, e a residência do aluno Murilo, instância da classe Residência. Na seção 6 é apresentada uma descrição detalhada das instâncias criadas através de um estudo de caso que tem o objetivo de avaliar a proposta.

4.2 Especificação da Ontologia

A figura 4.1 apresenta a visão geral do modelo desenvolvido, com os aspectos de informações utilizados para a chegar à recomendação de recursos de aprendizagem ao aluno.



Fonte: O Autor.

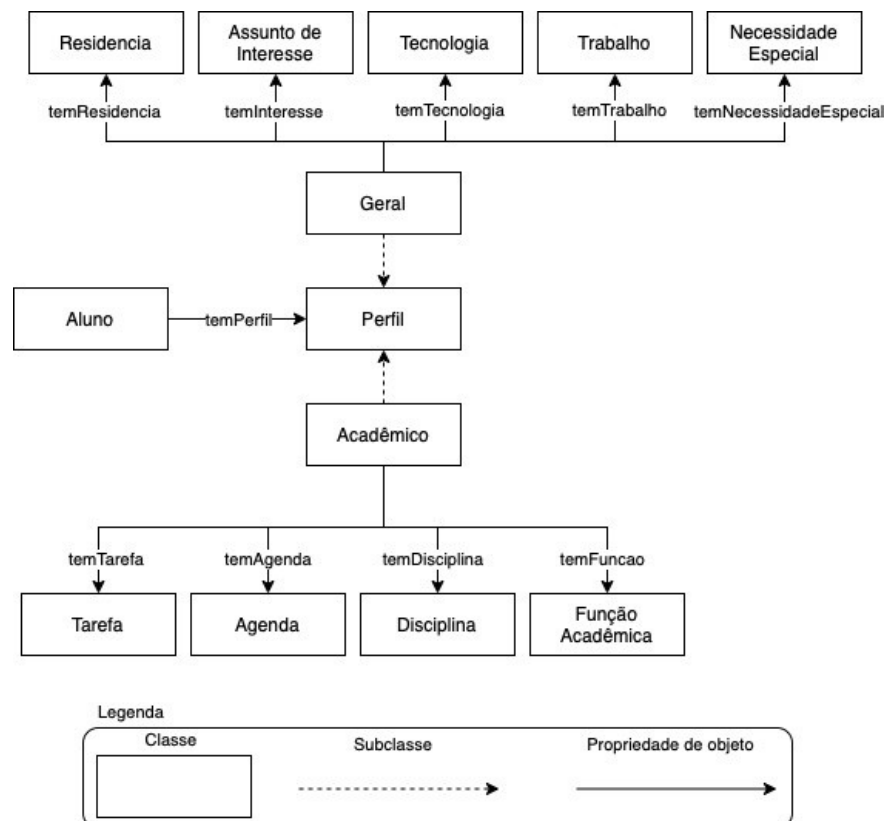
O aluno é o centro do modelo, que tem dois perfis: geral e acadêmico. Ele se relaciona com os aspectos de localização, tecnologia e assunto de interesse, de forma a ter a recomendação de aprendizagem recomendado.

Tecnologia refere-se aos aspectos tecnológicos que dizem respeito ao aluno, como o tipo de conexão, tamanho de tela do equipamento, presença ou não de GPS e capacidade de processamento.

Local descreve a perspectiva de localização física do aluno. O local possui pontos espaciais que o descrevem (latitude e longitude) e podem ser capturados automaticamente pelo dispositivo do aluno ou inseridos manualmente dependendo do contexto. No modelo, foram descritos subclasses específicas para o objetivo da recomendação que são: casa, campus e ambiente acadêmico.

Recurso de aprendizagem é a classe que define os objetos que serão recomendados ao aluno a partir do seu perfil, e das suas relações com os aspectos de tecnologia e localização. Foram modeladas duas subclasses: recurso de aprendizagem físico e recurso de aprendizagem digital. É importante esta definição pois em um ambiente de educação híbrida este fator é determinante para a recomendação ou não de um determinado recurso em um dado momento de estudo do aluno.

Figura 4.2 - Modelo de Aluno



Fonte: O Autor.

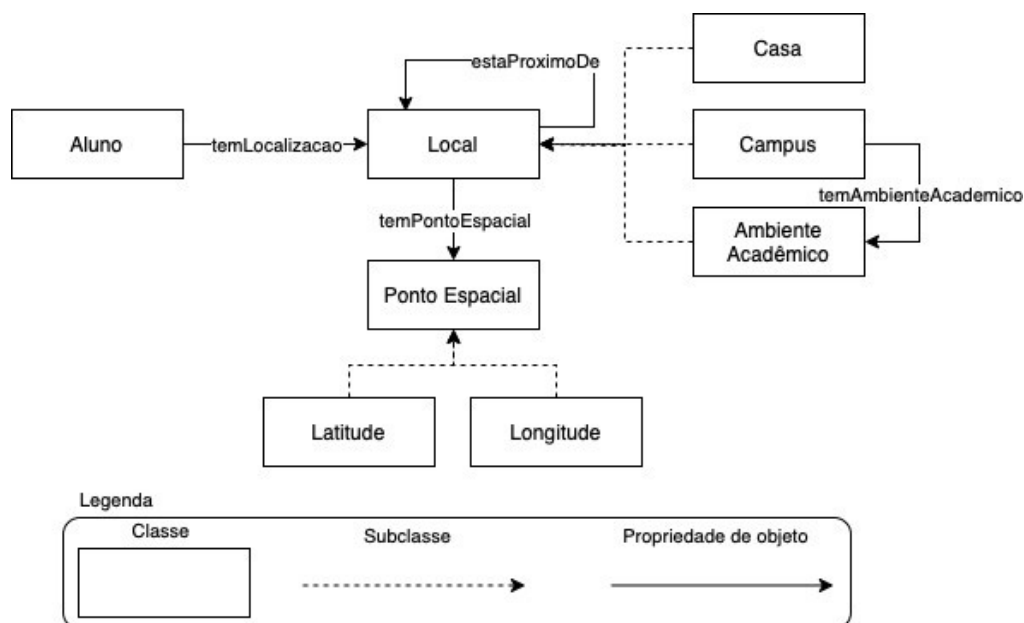
Para modelar o perfil do *Aluno* foram descritas duas subclasses: Geral e Acadêmico. O perfil Acadêmico retrata as características acadêmicas do aluno, que estão diretamente ligadas ao seu vínculo escolar. Ele se relaciona com as seguintes classes:

- Tarefa: descreve uma tarefa específica a que o aluno está ligado, por exemplo, "Trabalho de Algoritmos de Classificação".
- Agenda: a agenda do *Aluno* descreve seus compromissos acadêmicos, que podem ser os demandados pelo professor ou mesmo por conta do aluno a partir do seu método de organização.
- Disciplina: o aluno está sempre vinculado a no mínimo uma disciplina. Uma disciplina será relacionada a aulas, como será apresentado no modelo de Recursos de Aprendizagem,
- Função Acadêmica: o aluno tem por padrão a condição de aluno, mas pode ter outros vínculos, como "Bolsista" ou "Estagiário", por exemplo.

O perfil Geral apresenta as características que o aluno possui independente de sua relação escolar: Nesse contexto, o aluno possui relação com as seguintes classes:

- *Residência*: descreve as condições de habitação do aluno. Essas condições são especialmente importantes em uma situação de educação híbrida, onde a residência se torna uma extensão do ambiente escolar.
- *Assunto de Interesse*: define os assuntos pelos quais o Aluno busca conhecimento de forma espontânea. Esse interesse pode partir da necessidade gerada na participação de uma aula em que o assunto seja abordado ou mesmo anteriormente a qualquer sugestão acadêmica.
- *Tecnologia*: descreve os aspectos tecnológicos a que o Aluno tem acesso. O aluno pode possuir um computador com alta capacidade de processamento ou apenas um smartphone para participar das atividades didáticas. Pode possuir conexão por fibra óptica ou apenas os dados móveis de sua operadora de telefonia celular.
- *Trabalho*: descreve a relação com trabalho a que o aluno se encontra. Ele pode, por exemplo, trabalhar em uma área relacionada com o curso de que participa ou não. Pode trabalhar em uma carga horária de 44 horas semanais ou ter disponibilidade total para o curso.
- *Necessidade Especial*: define os possíveis aspectos que geram limitações físicas para o uso da tecnologia.

Figura 4.3 - Modelo de Localização



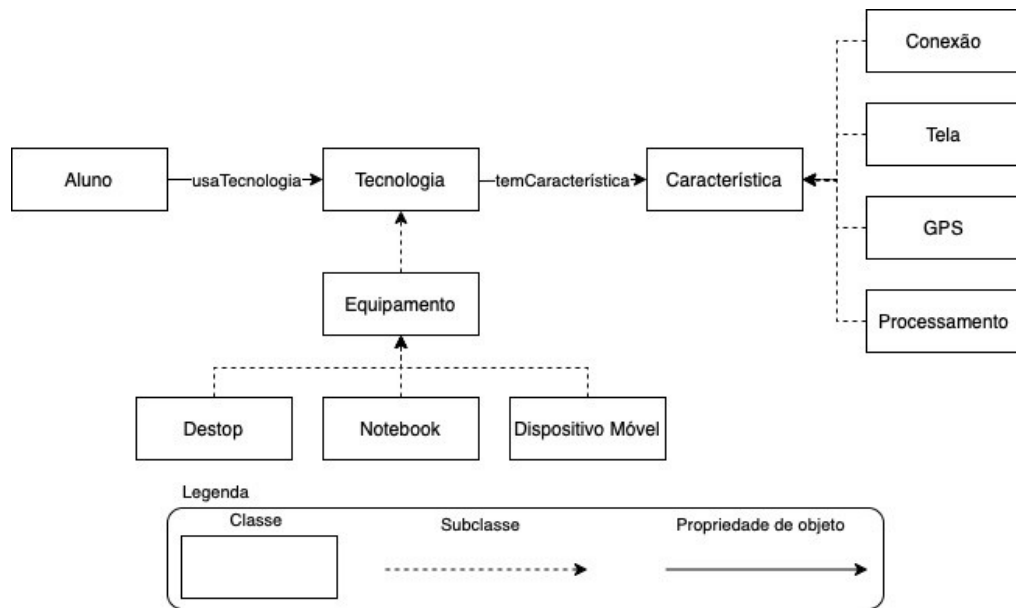
Fonte: O Autor.

O modelo de **Localização** descreve os tipos de locais em que o aluno pode estar no momento em que será feita a recomendação. O local também se relaciona com o aluno através da relação de *possuiCasa*, como atributo que ajuda a definir o perfil do aluno. O local possui as seguintes subclasses:

- *Casa*: um local que descreve estritamente a casa do aluno.
- *Campus*: descreve o local de estudo do aluno em sua visão macro. Entende-se que se o aluno está no campus pode ter acesso a qualquer recurso de atividade presencial que está disponível nele.
- *Ambiente Acadêmico*: descreve um local específico dentro de um campus, para fins acadêmicos como, por exemplo, "*Biblioteca*", "*Sala de Aula*" ou "*Sala de Apoio*".

Um Local possui a descrição das suas coordenadas geográficas, o que é descrito pela classe Ponto Espacial, através da propriedade de objeto *possuiPontoEspacial*. São descritas Latitudo e Longitudo como subclasses de Ponto Espacial. O modelo não pretende descrever a obtenção dos dados de latitudo e longitude, que podem ocorrer tanto automaticamente através do GPS no dispositivo em utilização pelo aluno quanto manualmente através da inserção dos dados.

Figura 4.4 - Modelo de Tecnologia



Fonte: O Autor.

O modelo de **Tecnologia** descreve os recursos tecnológicos que interagem com o aluno. Existem duas esferas que interagem com o aluno em relação à tecnologia: *possuiTecnologia* (que se refere ao perfil geral do aluno) e *usaTecnologia* (que diz respeito ao contexto de tecnologia no momento em que o aluno está utilizando o sistema de recomendação).

A classe Equipamento possui três subclasses que definem equipamentos específicos do aluno:

- *Desktop*: descreve um computador desktop que dentre as características mais específicas, se destacam possuir tela grande, geralmente com maior capacidade de processamento e de difícil mobilidade.
- *Notebook*: apresenta características semelhantes ao desktop, porém com maior mobilidade.
- *Dispositivo Móvel*: foram classificados como Dispositivos Móveis os equipamentos que apresentam tela menor, com altíssima capacidade de mobilidade, como smartphones e tablets.

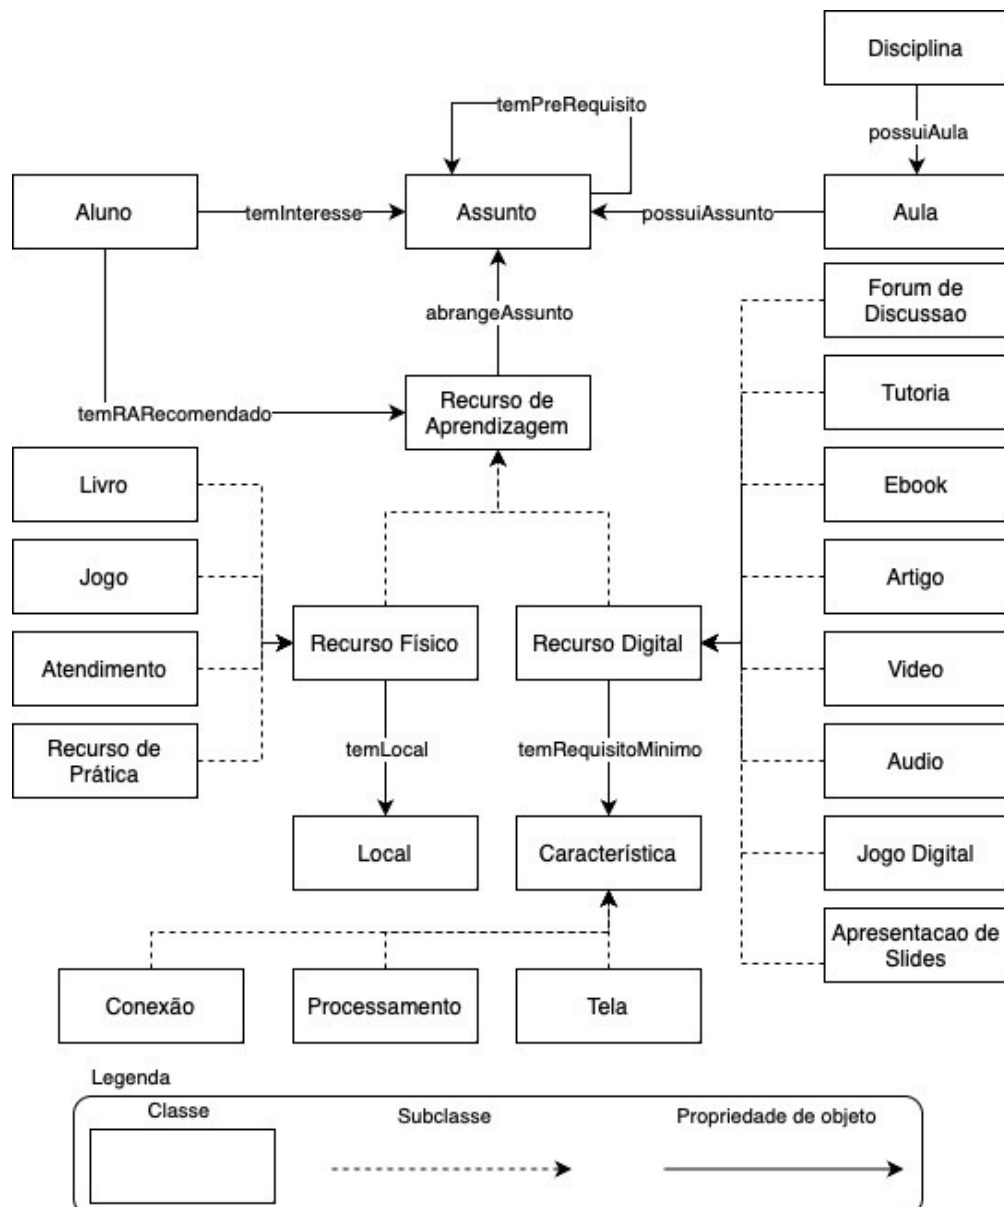
Para modelar as características de cada equipamento foram descritas 4 propriedades de dados:

- *Conexão*: descreve a capacidade de conexão de dados que o equipamento possui em determinado momento. É digno de registro o fato de que muitos alunos utilizam suas redes de dados móveis para suas atividades acadêmicas. Nesse

contexto, seja utilizando um dispositivo móvel ou um notebook através do roteamento de rede móvel, tal conexão demanda a atenção no momento da recomendação de recursos.

- *Tela*: o aluno pode estar utilizando um equipamento com tela pequena ou grande no momento da recomendação.
- *GPS*: descreve se o equipamento é equipado com GPS para localização automática do aluno.
- *Processamento*: propriedade que objetiva classificar a capacidade de processamento do equipamento em uso pelo aluno.

Figura 4.5 - Modelo de Recursos de Aprendizagem



Fonte: O Autor.

O modelo de Recursos de Aprendizagem descreve os recursos que são recomendados ao aluno durante o uso do sistema. A propriedade de objeto *temInteresse* relaciona o Aluno a um Assunto. Por sua vez, a classe Recurso de Aprendizagem se relaciona com um Assunto através da propriedade de objetivo *abrange*, inverso de *éAbrangidoPor*.

Uma Aula possui vários *Assuntos* a serem abordados, o que é expresso através da propriedade de classe *possuiAssunto*. Um Assunto pode ter pré-requisitos para ser tratado enquanto dentro do planejamento da aula, através da propriedade *temPreRequisito*, sendo os pré-requisitos também da classe Assunto.

Neste trabalho a modelagem foi feita a partir de uma *Disciplina*, que possui *Aulas*, através da propriedade *possuiAula*. Para especificar os recursos de aprendizagem, foram modeladas as subclasses Recurso Físico e Recurso Digital. Dentro de cada uma delas, foram criadas subclasses a fim de permitir o processo de recomendação dos recursos de forma direta. As subclasses descritas estão abaixo:

- Recursos Digitais: Fórum de Discussão, Tutoria, Ebook, Artigo, Vídeo, Áudio, Jogo Digital, Slides.
- Recursos Físicos: Livro, Jogo, Atendimento, Recurso de Prática (recursos de aprendizagem, geralmente disponíveis em salas de meios, que ajudam o aluno em atividades práticas)

Os Recursos Físicos possuem um Local estabelecido de armazenamento através da propriedade *temLocal*. Por possuírem um local físico definido para seu armazenamento, os recursos de aprendizagem físicos também podem ter seus valores de distância calculados a partir do aluno. Assim, a partir de um valor máximo de distância definido para ser próximo, através da propriedade de objeto *temProximidade*.

Os Recursos Digitais possuem requisitos mínimos de execução, através da propriedade de objeto *temRequisitoMinimo*. Esses requisitos são as características em relação a Conexão, Processamento e Tela, que se relacionam com as características de Tecnologia. Essa relação é importante para a efetivação da recomendação de recursos digitais.

A propriedade de objetivo *temRARecomendado* é utilizada para comunicar o *Aluno* com o Recurso de Aprendizagem. Esta ligação é o maior dos objetivos a serem alcançados através das regras de inferência que irão avaliar a viabilidade do modelo, sobre as quais será tratado em detalhes no próximo capítulo.

4.3 Modelagem desenvolvida

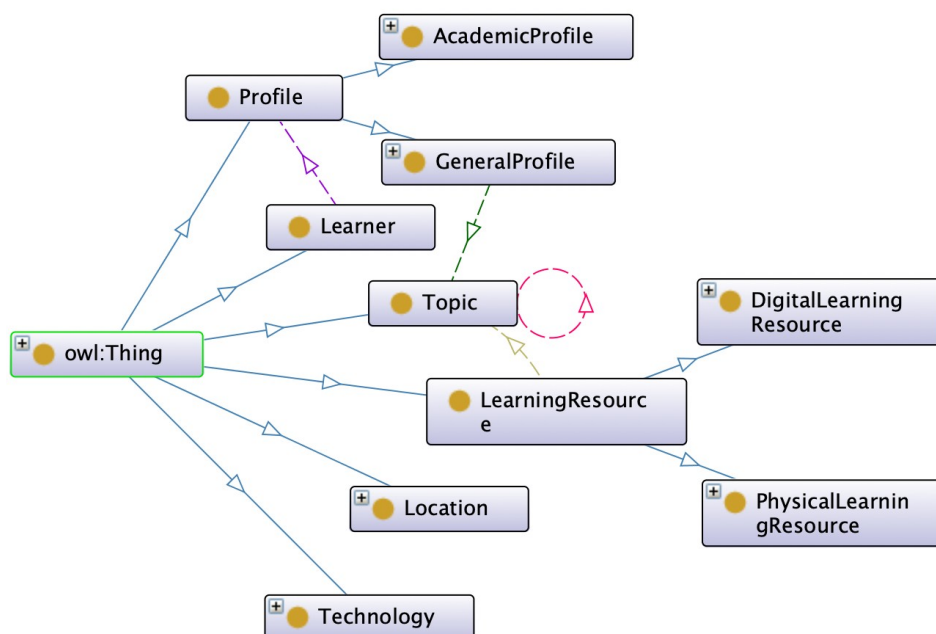
Isonati e Bittencourt (2015) apontam vários editores de ontologias disponíveis para uso da comunidade, como: Apollo (KMI, 2022), OntoStudio (Semafora, 2022), Protégé (Stanford, 2022), TopBraid Composer (TopQuadrant, 2022) e Hozo (Mizoguchi-Lab, 2022), dentre os quais o Protégé destaca-se como o mais utilizado pela comunidade internacional. Neste trabalho foi utilizado o Protégé na versão 5.5.0 para a construção da ontologia.

O modelo geral define os conceitos centrais da ontologia, com os quais todas as demais classes se relacionam, o que é apresentado na figura 4.6. Algumas propriedades de objeto foram omitidas para permitir uma melhor visualização das classes. Nestas imagens do Protégé (figura 4.6 e figura 4.7), as linhas contínuas apresentam o conceito de subclasse, enquanto as linhas tracejadas apresentam propriedades de objeto. As cores das linhas tracejadas indicam propriedades de objetos específicas, uma vez que no modelo cada propriedade é única. Como o Protégé não imprime o nome das propriedades de objeto, aqui é possível apenas notar que existe a diferença através das cores das linhas tracejadas.

A classe *Learner* se relaciona com a classe *Profile* através da propriedade de objeto *hasProfile*. *AcademicProfile* e *GeneralProfile* são subclasses da classe *Profile*, que modelam, respectivamente o **Perfil Acadêmico** e o **Perfil Geral** do aluno. Cabe notar que o aluno se relaciona com determinado assunto, classe *Topic*, através da propriedade de objeto *hasInterestIn* em seu *GeneralProfile*. A classe *LearningResource* se relaciona com a classe *Topic* através da propriedade de objeto *coversTopic*, e tem duas subclasses *DigitalLearningResource* e *PhysicalLearningResource*. Um **Topic** pode ter um pré-requisito que é outro **Topic**, modelado através da propriedade de objeto *hasPrerequisite*.

Foram descritos ainda propriedades de objeto inversas, de forma a enriquecer a semântica do modelo. Alguns exemplos de propriedades de objetos inversas são: *isCoveredBy*, inversa de *coversTopic*, uma vez que um tópico é abrangido por determinado recurso de aprendizagem, e; *isPrerequisiteOf*, inversa de *hasPrerequisite*, já que assim como um **Topic** pode ter um pré-requisito, pode ser muito útil verificar quais os **Topics** que são pré-requisitos de outros.

Figura 4.6 - Classes do Modelo Geral Desenvolvido

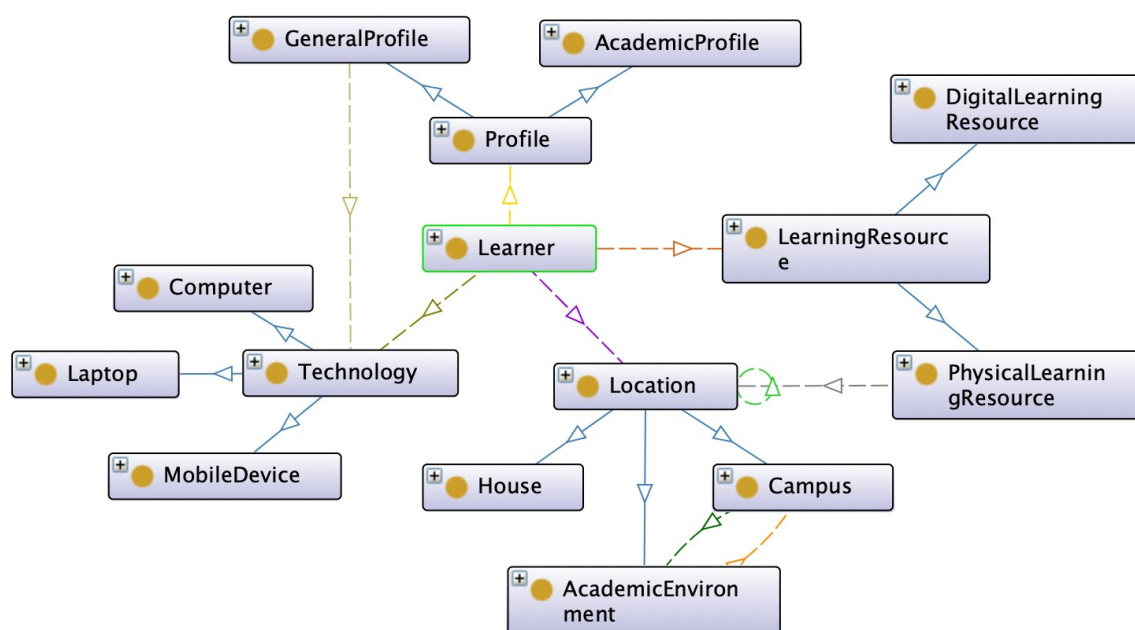


Fonte: O Autor.

O relacionamento mais detalhado entre o perfil do aluno, tecnologia, localização e recursos de aprendizagem é apresentado na figura 4.7. O perfil geral do aluno se relaciona com a tecnologia através de uma propriedade de objeto *hasTechnology*. Por outro lado, a classe do aluno se relaciona com tecnologia através da propriedade *usesTechnology*, que define a tecnologia que o aluno está utilizando no momento que é feita a recomendação. Isso foi modelado desta forma, visto que um aluno que está em sua residência, mesmo que utilizando um smartphone com tela pequena, pode receber uma recomendação de um recurso que exija maior capacidade computacional caso possua em sua residência um computador que atinga os requisitos mínimos do recurso.

É possível notar também a relação que o aluno possui com um local, através da propriedade de objeto *hasLocation*, o que é importante para a recomendação de recursos físicos. A classe *PhysicalLearningResource* se relaciona com a classe *Location* através da propriedade de objeto *hasStorageLocation*, pois tem um local de armazenamento, por exemplo um Livro que é armazenado em uma biblioteca. A classe *Location* também possui uma propriedade de objeto para definir um local seja próximo a outro, *isNearOf*, o que também pode ser utilizado para realizar uma recomendação.

Figura 4.7 - Relação entre os modelos de aluno, localização, tecnologia e recurso de aprendizagem



Fonte: O Autor.

4.3 Considerações finais do capítulo

Este capítulo apresentou a abordagem desenvolvida neste trabalho, descrevendo primeiramente os objetivos, seguido pela metodologia e então a especificação da ontologia desenvolvida.

A apresentação da metodologia “*Ontology development 101*” para o desenvolvimento da ontologia mostrou-se importante por descrever os passos necessários para o desenvolvimento de um sistema de recomendação baseado em regras aplicado à educação híbrida. Apesar de haver outras metodologias disponíveis, esta se apresenta como uma receita prática para ser aplicada, fazendo com que o desenvolvimento ocorra ao mesmo tempo em que se aprofunda no conhecimento do domínio.

A ontologia desenvolvida apresentou, além do perfil do aluno, três aspectos contextuais levados em consideração no modelo: tecnologia, localização e recursos de aprendizagem. A partir destes aspectos, com os dados da base de conhecimento, é possível gerar recomendações de recursos de aprendizagem para o aluno.

Para gerar as recomendações, será utilizado um motor de inferência que, a partir dos dados coletados, relaciona o **Aluno** com **Recurso de Aprendizagem** através da propriedade de objeto *temRARecomendado*.

No próximo capítulo será apresentado um estudo de caso a fim de avaliar o modelo desenvolvido, que apresentará como funciona a recomendação dos recursos através do motor de inferência.

5 ESTUDO DE CASO

Neste capítulo é apresentado um estudo de caso a fim de avaliar a abordagem desenvolvida neste trabalho. Segundo Yin (2015), um estudo de caso caracteriza-se como uma investigação empírica que investiga um fenômeno contemporâneo em profundidade em seu contexto de mundo real, especialmente quando os limites entre o fenômeno e o contexto puderem não ser tão claramente evidentes. Neste sentido, é desenvolvido o estudo de caso a partir de possibilidades de utilização da proposta, onde são relatadas recomendações feitas a partir do perfil do aluno e do contexto em que se encontra, dentro de um ambiente de ensino híbrido. Primeiramente, é apresentada uma possibilidade de utilização do modelo desenvolvido. Então, é feita uma apresentação sobre os mecanismos de inferência utilizados na proposta. Por fim, dois cenários de uso são apresentados com a aplicação de regras SWRL, uma para a situação de uso pelo aluno a partir de sua residência e outra para o uso pelo aluno em um ambiente acadêmico do campus.

5.1 Possibilidade de Utilização

Em um ambiente de educação híbrida, existe a demanda de recomendação de atividades educacionais a um aluno com base em suas características, conhecimento e contexto.

Quanto às suas características, o aluno pode ter um perfil geral e um perfil acadêmico. No perfil acadêmico são consideradas as características educacionais do aluno, como o conhecimento prévio de determinado assunto e os objetivos de aprendizagem do aluno, através das relações com as tarefas e as disciplinas. Já no perfil geral, as características que o aluno tem independentemente de sua situação escolar são levadas em conta, como habitação, assuntos de interesse e trabalho.

O sistema também armazena o conhecimento do aluno através dos assuntos com os quais já interagiu e das aulas que já participou.

Em relação ao contexto, o aluno pode estar presencialmente no campus ou fora dele. Também pode estar utilizando computador, notebook ou dispositivo móvel, com suas diferentes características tecnológicas, como tamanho de tela, capacidade de processamento e velocidade de conexão.

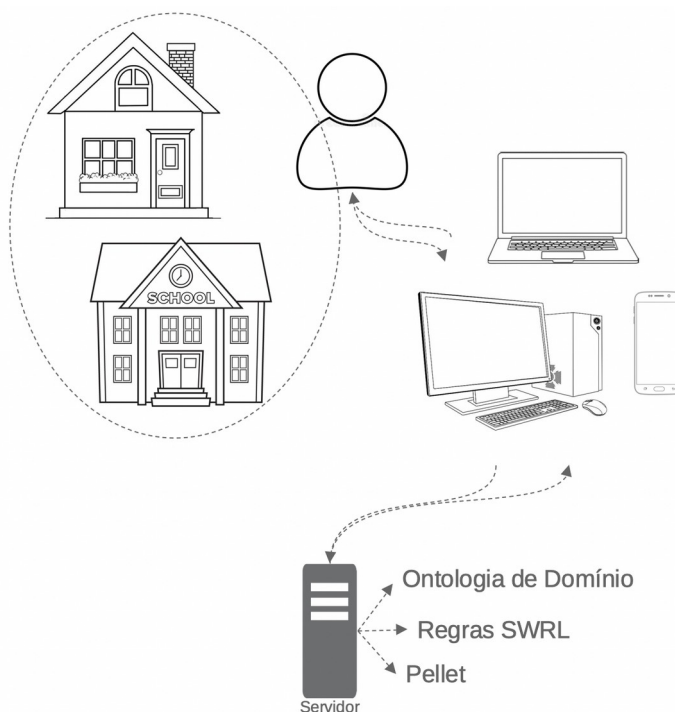
Os assuntos de interesse podem ser atribuídos pelo próprio aluno ou pelo sistema a partir do conhecimento das aulas das quais o aluno está participando. Por exemplo, um aluno

que esteja cursando a disciplina de Engenharia de Software, e tem uma aula com assunto "Métodos Ágeis", poderá ter incluído assuntos como "Métodos Ágeis" e "Scrum" automaticamente pelo sistema, e talvez haja necessidade de indicar um assunto pré-requisito, como "Processos de Software".

Ao utilizar um sistema que utiliza o modelo proposto, poderão ser recomendados recursos de aprendizagem a partir das características supracitadas, de acordo com o conhecimento do domínio.

A figura 5.1 apresenta uma visão geral de possibilidade de uso do modelo:

Figura 5.1 - Visão geral do uso do modelo



Fonte: O Autor.

5.2 Regras de Inferência

Para realizar a filtragem que efetiva a recomendação dos recursos de aprendizagem, são utilizadas regras SWRL. SWRL foi proposta em Horrocks et al. (2004) como uma linguagem de extensão da sintaxe da OWL através da combinação das sublinguagens OWL DL e OWL Lite com a RuleML. Assim, a SWRL amplia a capacidade de representação semântica da OWL através de regras de lógica de primeira ordem, sendo recomendada pela W3C para este fim.

As regras são constituídas por antecedente \Rightarrow conseqüente, onde, a partir da satisfação dos critérios do antecedente gera-se o conseqüente. Uma representação dessa sintaxe é a seguinte:

$$\mathbf{temPai}(?x1, ?x2) \wedge \mathbf{temIrmao}(?x2, ?x3) \Rightarrow \mathbf{temTio}(?x1, ?x3)$$

A regra acima pode ser lida da seguinte forma: se um indivíduo $?x1$ tem como pai o indivíduo $?x2$, e $?x2$ tem como irmão o indivíduo $?x3$, então o indivíduo $?x1$ tem como tio o indivíduo $?x3$.

Para executar as regras SWRL, é feito uso de um motor de inferência, ou *reasoner*. Existem vários *reasoners* disponíveis para utilização e compatíveis com o software Protegé, utilizado neste trabalho, dentre os quais se destacam: FaCT ++, HerMiT, ELK, Pellet e Racer. Dentre esses, o Pellet destaca-se por, além de ser *Open Source*, oferecer um conjunto de funcionalidades como suporte a regras, total classificação incremental e maior expressividade de lógica descritiva combinando dois perfis nativos (MACHADO e DE OLIVEIRA, 2014), assim, optou-se por utilizar o Pellet como motor de motor de inferência.

Neste trabalho foram utilizadas as regras SWRL para que, a partir das características do perfil do aluno, sua localização e tecnologia em uso fossem recomendados recursos de aprendizagem úteis para a execução de determinada tarefa acadêmica. Para isso, serão apresentados dois cenários de uso simulando um ambiente de educação híbrida, um com o aluno em sua residência e outro com o aluno em um campus, o que é apresentado a seguir.

5.3 Cenário de Uso 1 - Residência

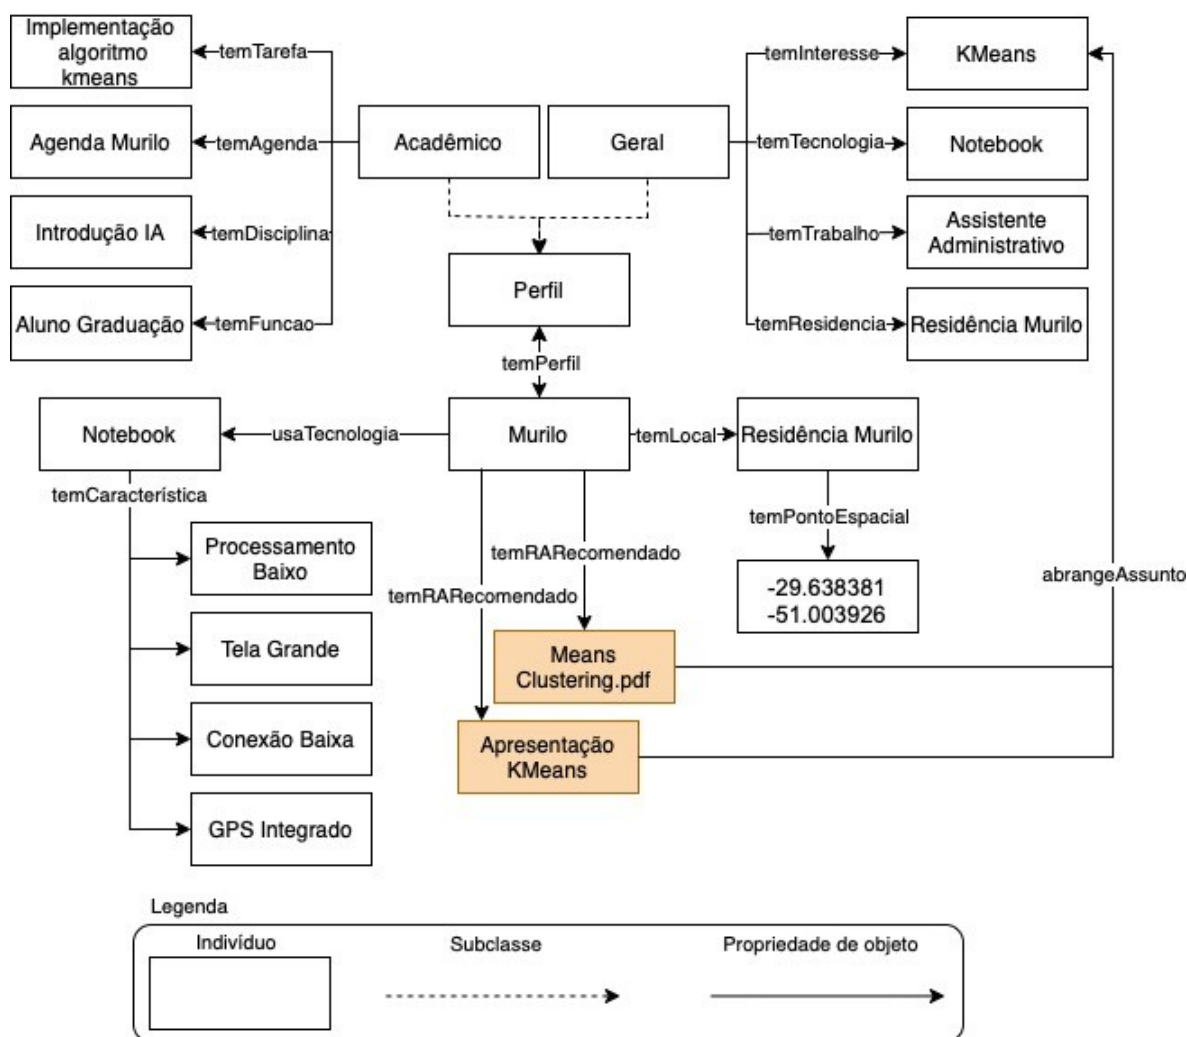
Murilo é aluno do curso de Engenharia de Computação, que é ministrado na modalidade de ensino híbrido. O programa do curso adotou o modelo virtual enriquecido, ou seja, o curso acontece em sua maior parte de forma on-line, com alguns encontros presenciais regulares. Na disciplina de Introdução à Inteligência Artificial, após a apresentação do conteúdo, o professor solicita que seja realizada uma atividade prática de implementação do algoritmo k-means, que terá sua conclusão e debate no próximo encontro presencial.

Após o professor inserir a aula no sistema com o assunto e a tarefa a ser realizada, "k-means" é adicionado como assunto de interesse de Murilo.

No próximo acesso ao sistema, verifica-se que Murilo está acessando através de um dispositivo móvel e que está em sua residência. Murilo não possui computador com alta

capacidade de processamento e sua conexão não é de alta velocidade. A partir daí, o sistema infere as regras de recomendação a fim de retornar algumas sugestões de recursos de aprendizagem com a finalidade de auxiliar o Murilo na realização da tarefa. A figura 5.2 representa essa instância do modelo:

Figura 5.2 - Modelo Instanciado com um aluno em sua residência



Fonte: O Autor.

Na figura 5.2 é possível ver a forma como os recursos de aprendizagem se relacionam com o perfil de aluno e com as características da tecnologia em uso. Dentro do modelo, vários aspectos podem ser levados em consideração para realizar a recomendação. Neste estudo de caso, considera-se que se o aluno está em sua residência, então serão apresentados apenas recursos de aprendizagem digitais. Uma vez que os recursos digitais têm requisitos mínimos definidos para seu bom aproveitamento, também será considerada a satisfação da tecnologia que está a disposição do aluno, a fim de recomendar apenas aqueles que podem ser utilizados

efetivamente. Para isso, de posse da informação do dispositivo à disposição do aluno, o sistema verifica qual é o seu padrão de processamento e qual é o requisito mínimo de processamento para cada recurso de aprendizagem digital. Então, faz a comparação através da função *built-in swrl:lessThanOrEqual()*, para verificar se o requisito de processamento é menor ou igual ao padrão de processamento do dispositivo. O mesmo processo é repetido para verificar os padrões de tamanho de tela e de conexão. Os padrões de processamento, tamanho de tela e conexão são descritos no modelo de tecnologia, enquanto os requisitos mínimos são definidos no modelo de recursos de aprendizagem (recurso de aprendizagem digital). Por fim, a relação do recurso de aprendizagem com o perfil do aluno é demonstrado através da correspondência do assunto de interesse do aluno com a abrangência do recurso a ser recomendado.

Na figura 5.3 é apresentado um recorte da tela do Protegé com os perfis geral e acadêmico do modelo instanciado para o cenário de um aluno em sua residência. Nesse cenário, é importante registrar que além das relações do perfil acadêmico através da disciplina, da agenda e da tarefa a ser realizada, o interesse em um assunto, modelado no perfil geral do aluno, o relacionam com o recurso de aprendizagem a ser recomendado pelo sistema.

Figura 5.3 - Perfis geral e acadêmico do modelo instanciado com aluno em sua residência

The image displays two screenshots from the Protegé interface, showing the configuration of two instances: MuriloGeneralProfile and MuriloAcademicProfile.

MuriloGeneralProfile Instance:

- Description:** MuriloGeneralProfile
- Types:** GeneralProfile
- Property assertions:**
 - hasTechnology LaptopN4020
 - hasJob AdministrativeAssistant
 - hasInterestIn TopicKMeans
 - hasHouse MuriloHouse

MuriloAcademicProfile Instance:

- Description:** MuriloAcademicProfile
- Types:** AcademicProfile
- Property assertions:**
 - hasAcademicRole GradStudentRole
 - hasTask KMeansImplementationTask
 - hasSchedule LearnerMuriloSchedule
 - hasSubject SubjectIntroductoryAI

Fonte: O Autor.

A regra SWRL desenvolvida para efetivar a recomendação descrita anteriormente está apresentada a seguir:

```

Learner(?l) ^
House(?h) ^
Profile(?p) ^
Topic(?topic) ^
DigitalLearningResource(?resource) ^
hasProfile(?l, ?p) ^
hasLocation(?l, ?h) ^
usesTechnology(?l, ?technology) ^
hasConnectionPattern(?technology, ?connection) ^
hasConnectionPatternRequirement(?resource, ?connectionRequirement) ^
swrlb:lessThanOrEqual(?connectionRequirement, ?connection) ^
hasProcessingPattern(?technology, ?processing) ^
hasProcessingPatternRequirement(?resource, ?processingRequirement) ^
swrlb:lessThanOrEqual(?processingRequirement, ?processing) ^
hasScreenSizePattern(?technology, ?screenSize) ^
hasScreenSizePatternRequirement(?resource, ?screenSizeRequirement) ^
swrlb:lessThanOrEqual(?screenSizeRequirement, ?screenSize) ^
hasInterestIn(?p, ?topic) ^
coversTopic(?resource, ?topic) ->
hasRecommendedLR(?l, ?resource)

```

A figura 5.4 mostra uma imagem da tela do Protégé onde é apresentado o resultado da recomendação. As propriedades de objeto em amarelo são as obtidas através do raciocínio sobre a regra apresentada, utilizadas pelo motor de inferência Pellet, a partir da instância do modelo.

Nota-se que, a partir das características apresentadas (localização, tecnologia utilizada e interesse do aluno), o modelo foi capaz de inferir que o aluno Murilo terá o artigo digital *Means Clustering* e a apresentação de slides *Apresentação KMeans* recomendados a fim de auxiliar na execução da sua tarefa de implementação do algoritmo k-means, dentro da disciplina de Introdução à Inteligência Artificial.

Figura 5.4 - Resultado das Regras Inferidas pelo Pellet com aluno em sua residência

Fonte: o autor.

5.4 Cenário de Uso 2 - Campus

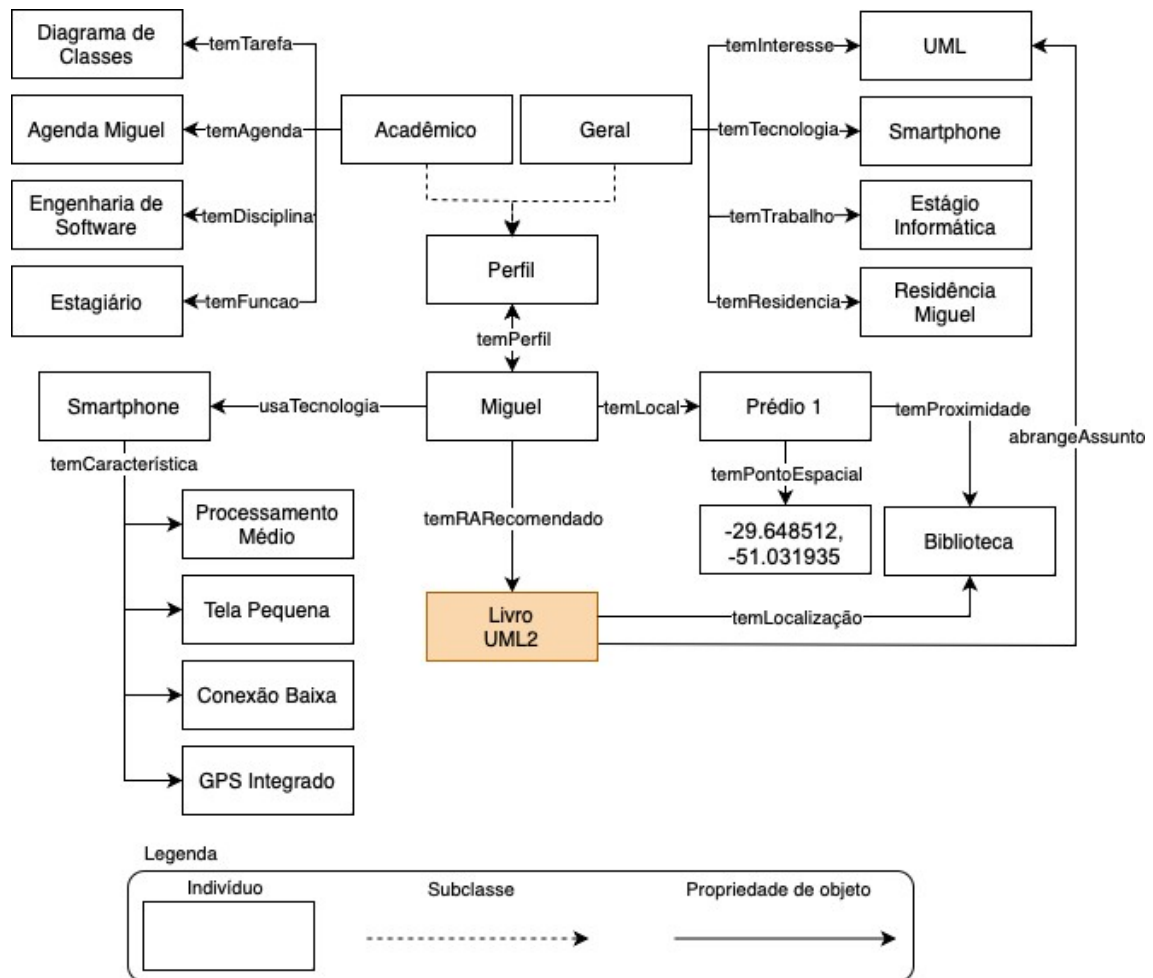
Em um outro cenário, Miguel é aluno do curso de Ciência de Computação, que também é ministrado na modalidade de ensino híbrido. O modelo adotado pelo programa do curso foi o Modelo Flex, no qual o curso tem seu foco de forma on-line e por vezes o aluno é encaminhado para atividades presenciais específicas.

Durante a disciplina de Engenharia de Software o professor adiciona no AVA uma tarefa de desenvolvimento de Diagrama de Classes a partir das orientações do enunciado. A tarefa é totalmente on-line, e sua conclusão se dará a partir da submissão do diagrama no ambiente e posterior apresentação de forma remota.

Após verificar a tarefa a ser realizada, Miguel adiciona o assunto "UML" na sua lista de interesse.

No dia seguinte, Miguel está no campus em função de outra demanda acadêmica, e acessa o sistema. Verifica-se que Miguel está acessando o sistema através de um smartphone e que está a 30 metros da biblioteca do campus. Com essas informações, o sistema infere regras definidas na ontologia para recomendar recursos de aprendizagem que possam ser úteis para a realização da tarefa. A instância desse modelo é apresentada na figura 5.5.

Figura 5.5 - Modelo instanciado para o cenário de um aluno em um campus



Fonte: O Autor.

A figura 5.5 demonstra como os recursos de aprendizagem se relacionam com o perfil do aluno e com a sua localização. Assim como para recomendar recursos disponíveis à distância, vários aspectos poderiam ser considerados para recomendar recursos em um campus. Uma vez que o aluno está no campus, serão apresentados os recursos de aprendizagem físicos disponíveis. Para a recomendação de tais recursos, o principal fator levado em conta foi a proximidade estipulada na ontologia. Assim, o sistema irá recomendar os recursos que abrangem o assunto de interesse do aluno e que estejam dentro do que se considera próximo. Neste cenário, foi definida a distância de 30 metros para que um recurso seja considerada próximo ao aluno.

Os perfis geral e acadêmico instanciados no Protégé são apresentados na figura 5.6, onde é possível verificar a forma como o aluno está relacionado com as suas características.

Figura 5.6 - Perfis geral e acadêmico do modelo instanciado - aluno em um campus

The image displays two screenshots of a software interface showing ontology profiles for 'MiguelGeneralProfile' and 'MiguelAcademicProfile'.

MiguelGeneralProfile:

- Description:** MiguelGeneralProfile
- Types:** GeneralProfile
- Property assertions:**
 - Object property assertions:
 - hasHouse MiguelResidence
 - hasInterestIn TopicUML
 - hasTechnology SmartphoneSS10
 - hasJob InformaticsInternship
 - Data property assertions: +
 - Negative object property assertions: +
 - Negative data property assertions: +

MiguelAcademicProfile:

- Description:** MiguelAcademicProfile
- Types:** AcademicProfile
- Property assertions:**
 - Object property assertions:
 - hasSchedule LearnerMiguelSchedule
 - hasSubject SubjectSoftwareEngineering
 - hasAcademicRole GradStudentRole
 - hasTask ClassDiagramTask
 - Data property assertions: +
 - Negative object property assertions: +
 - Negative data property assertions: +

Fonte: O Autor.

Uma vez que os recursos a serem recomendados são físicos e levarão em conta a distância para o aluno, antes de fazer a recomendação de tais recursos é necessário encontrar os locais próximos para ele. A seguir é descrita a regra aplicada para inferir os locais que são considerados próximos ao aluno.

$$\begin{aligned}
 &Learner(?l) \wedge \\
 &Location(?location) \wedge \\
 &hasDistanceFromLearner(?location, ?d) \wedge \\
 &considersDistanceAsClose(?l, ?dp) \wedge \\
 &swrlb:lessThanOrEqual(?d, ?dp) \rightarrow \\
 &hasProximity(?l, ?location)
 \end{aligned}$$

Ao executar o reasoner, ele irá calcular as distâncias de todos os ambientes acadêmicos do campus para o aluno e inferir os locais considerados próximos, ou seja, aqueles com menos de 30 metros de distância.

Então, a partir dos locais próximos ao aluno (biblioteca, nesse caso), a regra SWRL irá filtrar os recursos de aprendizagem físicos que estejam vinculados com esses locais através da propriedade de objeto *hasStorageLocation* e que tenham a relação com o assunto de interesse

do aluno, através da propriedade de objeto *coversTopic*. A regra SWRL instanciada para este cenário está apresentada abaixo.

```

Learner(?l) ^
Topic(?topic) ^
Profile(?p) ^
AcademicEnvironment(?ae) ^
PhysicalLearningResource(?resource) ^
hasProfile(?l, ?p) ^
hasStorageLocation(?resource, ?ae) ^
hasProximity(?l, ?ae) ^
hasInterestIn(?p, ?topic) ^
coversTopic(?resource, ?topic) ->
hasRecommendedLR(?l, ?resource)

```

O resultado da recomendação é apresentado na figura 5.7. A partir das características do perfil do aluno e da sua localização, assim como a descrição de proximidade definida para o aluno, a recomendação é realizada.

Miguel está no corredor do Prédio 1 e, a partir de sua localização, a regra instanciada primeiramente verifica quais são os locais que são considerados próximos a ele. É inferido então que a Biblioteca está próxima através da propriedade de objeto *hasProximity*. Essa informação é utilizada pela regra que retorna os recursos de aprendizagem, então, através da propriedade de objeto *hasRecommendedLR* infere o recurso de aprendizagem *BookUML2UmaAbordagemPratica*.

Figura 5.7 - Resultado das Regras Inferidas pelo Pellet com aluno em um campus

Fonte: O Autor.

5.5 Considerações finais do capítulo

Neste capítulo foi feita uma avaliação do modelo desenvolvido através do uso de estudo de caso, com a apresentação de dois cenários de uso, onde foram simuladas situações em que um aluno na modalidade de ensino híbrido esteja utilizando um sistema desenvolvido a partir deste modelo para receber recomendações de recursos de aprendizagem em diferentes contextos. No primeiro cenário, um aluno está em sua residência e recebe recomendações a partir da tecnologia disponível para estudo. No segundo cenário, um aluno está no campus e recebe recomendações a partir da proximidade com a localização dos recursos físicos disponíveis. Em ambos os casos, o interesse do aluno é considerado, a partir do seu perfil modelado.

Nota-se a vantagem de usar a técnica de recomendação baseada em conhecimento, pois, a partir das descrições semânticas é possível obter melhores resultados em uma situação de usuários novos, pois podem receber recomendações a partir de sua localização e da tecnologia em uso, o que auxilia na solução do problema de partida a frio.

Outra vantagem é que ao utilizar a semântica da aplicação em um nível conceitual mais alto, o conhecimento do domínio se torna entendível por agentes computacionais e humanos, como sugerido por Berners-Lee et al. (2001).

No próximo capítulo será apresentada a conclusão deste trabalho, apontando as suas contribuições e algumas possibilidades de trabalhos futuros.

6 CONCLUSÃO

Ambientes de ensino híbrido têm aumentado nos últimos anos e podem contar com apoio tecnológico para serem desenvolvidos com maior eficácia, de forma planejada. O ensino híbrido visa unir o melhor de cada modalidade de ensino, presencial e a distância, promovendo flexibilidade nos processos de ensino e de aprendizagem, sem perder a interação proporcionada pelo contato presencial. Ao mesmo que o hibridismo traz vantagens decorrentes desta união, apresenta desafios que não havia em cada modalidade separadamente. Um desses desafios é o alto número de recursos de aprendizagem que um aluno pode encontrar em cada momento de estudo, e que dependem de situações específicas além de seus objetivos de aprendizagem, como sua localização e a tecnologia de que dispõe ou que está em utilização. Essa situação pode acarretar em sobrecarga cognitiva e em desmotivação, grandes responsáveis pela diminuição do rendimento escolar e pela evasão.

Sistemas de recomendação sensíveis ao contexto são úteis nesse tipo de situação, uma vez que podem filtrar as opções que o usuário possui de forma a diminuir a sobrecarga cognitiva, sendo capazes de lidar com a especificidade de cada usuário para realizar a recomendação de forma mais apropriada.

Neste trabalho foi apresentado o desenvolvimento de uma ontologia para recomendação de recursos de aprendizagem em ambientes de educação híbrida sensível ao contexto. A principal dimensão de contexto levada em consideração foi a localização, uma vez que na educação híbrida a residência do aluno se torna uma extensão do ambiente escolar. Assim, foram modelados recursos de aprendizagem físicos e digitais, para serem recomendados de forma diferente em situação de uso em um ambiente acadêmico ou em uma residência. Outra dimensão de contexto considerada foi a tecnologia que o aluno dispõe e que está em uso no momento, de forma que possam ser filtrados recursos de aprendizagem de acordo com a capacidade tecnológica à disposição do aluno.

Após a apresentação do modelo, um estudo de caso foi apresentado, com o desenho de dois cenários de uso, um cenário a partir de um ambiente acadêmico e outro a partir de uma residência. Assim, foi possível verificar que o modelo desenvolvido cumpre os objetivos propostos de viabilizar a recomendação de recursos de aprendizagem em um ambiente de educação híbrida.

Alguns aspectos não foram abordados por estarem fora do escopo do trabalho, e apresentam-se como limitações. Dentre eles, são dignos de destaque a segurança e a privacidade dos dados necessários para este tipo de aplicação.

Como trabalhos futuros, pretende-se gerar um módulo e integrá-lo a um AVA. Posteriormente, pretende-se realizar a validação através de testes com alunos em um ambiente real de educação híbrida. Outro trabalho futuro será a pesquisa sobre a aplicabilidade da modelagem de estilos de aprendizagem, com sua possível utilização, aumentando a personalização da recomendação. Por fim, pretende-se inserir outras dimensões de contexto, como atividade e tempo.

REFERÊNCIAS

AGARWAL, Anant. The future of learning is blended.

ALI, Ramiz. **Is blending the solution?: a systematic literature review on the key drivers of blended learning in higher education**. 2019.

ALMEIDA, Mauricio B.; BAX, Marcello P. Uma visão geral sobre ontologias: pesquisa sobre definições, tipos, aplicações, métodos de avaliação e de construção. **Ciência da informação**, v. 32, n. 3, p. 7-20, 2003.

ANTHONY, Bokolo et al. Blended learning adoption and implementation in higher education: a theoretical and systematic review. **Technology, Knowledge and Learning**, p. 1-48, 2020.

BACICH, Lilian; NETO, Adolfo Tanzi; DE MELLO TREVISANI, Fernando. **Ensino híbrido: personalização e tecnologia na educação**. Penso Editora, 2015.

BARTOLOMÉ PINA, Antonio Ramón. Blended learning. Conceptos básicos. **Pixel-Bit: Revista de Medios y Educación**, 23, 7-20., 2004.

BERNERS-LEE, Tim; HENDLER, James; LASSILA, Ora. The semantic web. **Scientific american**, v. 284, n. 5, p. 34-43, 2001.

BOUIHI, Bouchra; BAHAJ, Mohamed. Ontology and Rule-Based Recommender System for E-learning Applications. **International Journal of Emerging Technologies in Learning**, v. 14, n. 15, 2019.

BRIDGE, Derek et al. Case-based recommender systems. **The Knowledge Engineering Review**, v. 20, n. 3, p. 315-320, 2005.

BRUGGEMAN, Bram et al. Experts speaking: Crucial teacher attributes for implementing blended learning in higher education. **The Internet and Higher Education**, v. 48, p. 100772, 2021.

BURKE, Robin. Hybrid web recommender systems. **The adaptive web**, p. 377-408, 2007.

CAZELLA, Sílvio César; NUNES, M. A. S. N.; REATEGUI, Eliseo. A Ciência da Opinião: Estado da arte em Sistemas de Recomendação. JAI Jorn. **Atualização em Informática da SBC. Rio Janeiro, RJ PUC Rio**, p. 161-216, 2010.

DEY, Anind K. Understanding and using context. **Personal and ubiquitous computing**, v. 5, n. 1, p. 4-7, 2001.

ESSALMI, Fathi et al. A fully personalization strategy of E-learning scenarios. **Computers in Human Behavior**, v. 26, n. 4, p. 581-591, 2010

FELFERNIG, Alexander et al. Constraint-based recommender systems. In: **Recommender systems handbook**. Springer, Boston, MA, 2015. p. 161-190.

FELFERNIG, Alexander; ISAK, Klaus; KRUGGEL, Thomas. Testing knowledge-based recommender applications. **OEGAI Journal, Special Issue on Recommender Systems**, v. 24, n. 4, p. 12-18, 2005.

GASPARINI, Isabela et al. Modelo do usuário sensível ao contexto cultural em um sistema e-learning adaptativo. **Informática na educação: teoria & prática**, v. 14, n. 1, 2011.

GRAHAM, Charles R. Blended learning systems. **The handbook of blended learning: Global perspectives, local designs**, v. 1, p. 3-21, 2006.

GRUBER, Thomas R. A translation approach to portable ontology specifications. **Knowledge acquisition**, v. 5, n. 2, p. 199-220, 1993

GUARINO, Nicola (Ed.). Formal ontology in information systems: **Proceedings of the first international conference (FOIS'98)**, June 6-8, Trento, Italy. IOS press, 1998

GUARINO, Nicola. Understanding, building and using ontologies. **International journal of human-computer studies**, v. 46, n. 2-3, p. 293-310, 1997.

GUEDES, Gilleanes TA. **UML 2-Uma abordagem prática**. Novatec Editora, 2018.

HARRATHI, Marwa; TOUZANI, Narjess; BRAHAM, Rafik. A hybrid knowledge-based approach for recommending massive learning activities. In: **2017 IEEE/ACS 14th International Conference on Computer Systems and Applications (AICCSA)**. IEEE, 2017. p. 49-54.

HOIC-BOZIC, Natasa; DLAB, Martina Holenko; MORNAR, Vedran. Recommender system and web 2.0 tools to enhance a blended learning model. **IEEE Transactions on education**, v. 59, n. 1, p. 39-44, 2015.

HORN, Michael B.; STAKER, Heather; CHRISTENSEN, Clayton. **Blended: usando a inovação disruptiva para aprimorar a educação**. Penso Editora, 2015.

HORROCKS, Ian et al. SWRL: A semantic web rule language combining OWL and RuleML. **W3C Member submission**, v. 21, n. 79, p. 1-31, 2004.

HWANG, Gwo-Jen; TSAI, Chin-Chung; YANG, Stephen JH. Criteria, strategies and research issues of context-aware ubiquitous learning. **Journal of Educational Technology & Society**, v. 11, n. 2, p. 81-91, 2008.

ISOTANI, Seiji; BITTENCOURT, Ig Ibert. **Dados abertos conectados: em busca da web do conhecimento**. Novatec Editora, 2015.

JANNACH, Dietmar; ADOMAVICIUS, Gediminas. Recommendations with a purpose. In: **Proceedings of the 10th ACM conference on recommender systems**. 2016. p. 7-10.

JEEVAMOL, Joy; RENUMOL, V. G. An ontology-based hybrid e-learning content recommender system for alleviating the cold-start problem. **Education and Information Technologies**, v. 26, n. 4, p. 4993-5022, 2021.

KINSHUK, D. P.; GRAF, D. S. **Ubiquitous learning**. **Encyclopedia of the Sciences of Learning**, p. 3361-3363, 2012.

KMI. 2022. Apollo Ontology Editor. 2014. Disponível em: <<http://apollo.open.ac.uk/>>. Acesso em 10 Jul. 2022.

LABIB, A. Ezzat; CANÓS, José H.; PENADÉS, M. Carmen. On the way to learning style models integration: a Learner's Characteristics Ontology. **Computers in Human Behavior**, v. 73, p. 433-445, 2017.

LEIDL, Don M.; RITCHIE, Lauren; MOSLEMI, Neda. Blended learning in undergraduate nursing education—A scoping review. **Nurse Education Today**, v. 86, p. 104318, 2020.

MACHADO, Guilherme Medeiros; DE OLIVEIRA, José Palazzo Moreira. Context-aware adaptive recommendation of resources for mobile users in a university campus. In: **2014 IEEE 10th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)**. IEEE, 2014. p. 427-433.

MEIRELLES, F. S. (2020). Pesquisa anual do uso de ti.[s. 1.], 2019.

MENDES, Tiago de Avila et al. Um software baseado no perfil de estudantes para recomendação de objetos de aprendizagem. 2017.

MIZOGUCHI-LAB. 2022. Hozo Ontology Editor. Disponível em: <<http://www.hozo.jp/>>. Acesso em 10 Jul. 2022

NAGUMO, Estevon; TELES, Lucio França. O uso do celular por estudantes na escola: motivos e desdobramentos. **Revista brasileira de estudos pedagógicos**, v. 97, p. 356-371, 2016.

OBEID, Charbel et al. Ontology-based recommender system in higher education. In: **Companion Proceedings of the The Web Conference 2018**. 2018. p. 1031-1034.

OGATA, Hiroaki et al. LORAMS: linking physical objects and videos for capturing and sharing learning experiences towards ubiquitous learning. **International Journal of Mobile Learning and Organisation**, v. 3, n. 4, p. 337-350, 2009.

OLIVER, Martin; TRIGWELL, Keith. Can 'blended learning' be redeemed?. **E-learning and Digital Media**, v. 2, n. 1, p. 17-26, 2005.

OSGUTHORPE, Russell T.; GRAHAM, Charles R. Blended learning environments: Definitions and directions. **Quarterly review of distance education**, v. 4, n. 3, p. 227-33, 2003.

OUF, Shimaa et al. A proposed paradigm for smart learning environment based on semantic web. **Computers in Human Behavior**, v. 72, p. 796-818, 2017.

RAFIOLA, Ryan et al. The Effect of Learning Motivation, Self-Efficacy, and Blended Learning on Students' Achievement in The Industrial Revolution 4.0. **International Journal of Emerging Technologies in Learning (iJET)**, v. 15, n. 8, p. 71-82, 2020.

REZENDE, Paulo Alceu et al. Recomendação Baseada no Perfil e Contexto Tecnológico do Aluno. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. 2018. p. 1273.

RICCI, Francesco; ROKACH, Lior; SHAPIRA, Bracha. Introduction to recommender systems handbook. In: **Recommender systems handbook**. Springer, Boston, MA, 2011. p. 1-35.

ROONEY, J. E. Blending learning opportunities to enhance educational programming and meetings [Tekst]. **Association Management [Tekst]**, n. 55, p. 5, 2003.

SAIED, Mohamed; NASR, Mona. Blended learning model supported by recommender system and up-to-date technologies. **International Journal of Advanced Networking and Applications**, v. 10, n. 2, p. 3829-3832, 2018.

SCHIEHL, Edson Pedro; GASPARINI, Isabela. Modelos de ensino híbrido: Um mapeamento sistemático da literatura. In: **Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)**. 2017. p. 1.

SEMAFORA. 2022. OntoStudio. <<https://www.semafora-systems.com/ontobroker-and-ontostudio-x>>. Acesso em 10 Jul. 2022.

STANFORD. 2022. Protégé Ontology Editor. [Online] 2014. Disponível em: <<http://protege.stanford.edu/>>. Acesso em 10 Jul. 2022.

SURE, York; STAAB, Steffen; STUDER, Rudi. Ontology engineering methodology. In: **Handbook on ontologies**. Springer, Berlin, Heidelberg, 2009. p. 135-152.

TAKAHASHI, Marcos M.; HIRATA JR, Roberto. Estudo comparativo de Algoritmos de Recomendação. **Universidade de São Paulo**, 2015.

TARUS, John K.; NIU, Zhendong; KALUI, Dorothy. A hybrid recommender system for e-learning based on context awareness and sequential pattern mining. **Soft Computing**, v. 22, n. 8, p. 2449-2461, 2018.

TOPQUADRANT. 2022. TopBraid Composer Standard Edition. 2022. Disponível em: <<https://archive.topquadrant.com/topbraid-composer-install/>>. Acesso em 10 Jul. 2022.

VALIATHAN, Purnima. Blended learning models. *Learning circuits*, v. 3, n. 8, p. 50-59, 2002.

VO, Minh Hien; ZHU, Chang; DIEP, Anh Nguyet. Students' performance in blended learning: disciplinary difference and instructional design factors. **Journal of Computers in Education**, v. 7, n. 4, p. 487-510, 2020.

W3C 2012. <<https://www.w3.org/OWL/>>. Acesso em 05 Mar. 2022.

WONOSETO, Muhammad Galih; ROSMANSYAH, Yusep. Knowledge based recommender system and web 2.0 to enhance learning model in junior high school. In: **2017 International Conference on Information Technology Systems and Innovation (ICITSI)**. IEEE, 2017. p. 168-171.

YANES, Nacim; SASSI, Sihem Ben; GHEZALA, Henda Hajjami Ben. Ontology-based recommender system for COTS components. **Journal of Systems and Software**, v. 132, p. 283-297, 2017.

YIN, Robert K. **Estudo de Caso-: Planejamento e métodos**. Bookman editora, 2015.

ZANKER, Markus; JESSENITSCHNIG, Markus; SCHMID, Wolfgang. Preference reasoning with soft constraints in constraint-based recommender systems. **Constraints**, v. 15, n. 4, p. 574-595, 2010.