

# Uma Abordagem Híbrida para Acompanhamento da Aprendizagem do Estudante Baseada em Ontologias e Redes Bayesianas em Sistemas Adaptativos para Educação

Hiran Nonato M. Ferreira<sup>1,2</sup>, Rafael Dias Araújo<sup>1</sup>,  
Fabiano A. Dorça<sup>1</sup>, Renan G. Cattelan<sup>1</sup>

<sup>1</sup>Faculdade de Computação – Universidade Federal de Uberlândia  
Caixa Postal 593 – CEP 38408-100 – Uberlândia – MG – Brasil

<sup>2</sup>Instituto Federal do Sul de Minas Gerais – IFSULDEMINAS  
Rua Mário Ribola, 409 – CEP 37903-358 – Passos – MG – Brasil

ubimedia@facom.ufu.br

**Abstract.** *Dynamic adaptation of educational content has been an important research topic, but in order to make it happen effectively, student models has been proposed to describe and monitor students cognitive state. In this sense, this paper presents a hybrid student model approach that combines ontologies and Bayesian Networks in order to identify the knowledge of each students based on their characteristics and behavior while using an adaptive educational system. Experiments with virtual students were performed using a functional prototype. The proposed approach has presented positive results, in agreement with experts' expectations.*

**Resumo.** *Adaptação dinâmica de conteúdo educacional tem sido um tópico de pesquisa recorrente na literatura, mas para que aconteça de forma efetiva, modelos de estudantes têm sido propostos com o intuito de descrever e acompanhar o estado cognitivo dos estudantes. Neste sentido, este artigo apresenta uma abordagem híbrida de modelo de estudante que combina ontologias e Redes Bayesianas para identificar o estado de conhecimento do estudante com base em suas características e comportamentos durante a utilização de um sistema educacional adaptativo. Experimentos com estudantes virtuais foram realizados com o apoio de um protótipo funcional. A abordagem proposta apresentou resultados positivos, condizentes com as expectativas de especialistas.*

## 1. Introdução

O Modelo de Estudante (ME) é um dos componentes fundamentais na personalização do processo de ensino-aprendizagem em *Sistemas Tutores Inteligentes* (STI). De acordo com Li *et al.* (2011), a modelagem do estudante é um dos fatores chave que afetam sistemas automatizados de tutoria na tomada de decisões. Um ME bem definido é capaz de fornecer subsídios para a avaliação e o acompanhamento da aprendizagem dos estudantes em ambientes educacionais (Mitrovic e Thomson, 2009). Um ME deve representar não somente informações sobre conhecimento do estudante, mas sim, refletir, o mais fiel possível, o seu processo de raciocínio (Clemente *et al.*, 2011).

A construção de um modelo que permita o acompanhamento da aprendizagem não é uma tarefa simples. Informações e dados que representam o estudante devem ser

levantadas cuidadosamente, o processo de atualização das informações também deve ser claro e, não menos importante, deve-se definir como o ambiente irá prover a adaptação de conteúdo (Millán *et al.*, 2010). É possível encontrar diversas abordagens para modelagem de características dos estudantes, no entanto, a maioria delas, não utiliza modelos probabilísticos para esse fim, e algumas, quando utilizam, não permitem um acompanhamento completo das atividades do estudante.

A partir do exposto, este artigo apresenta um modelo híbrido para modelagem de estudante com capacidade para avaliação e acompanhamento da aprendizagem em sistemas educacionais adaptativos. Neste trabalho, uma ontologia foi empregada para representação das características dos estudantes e uma *Rede Bayesiana* (RB) foi utilizada para inferir sobre seu nível de conhecimento baseado em atividades avaliativas. A abordagem baseada em ontologia foi escolhida por ser interessante para a representação de conceitos e propriedades, pela sua característica que permite reuso e extensão, bem como, pela possibilidade de inferências a partir das informações representadas. A RB é utilizada com o intuito de prover um enfoque probabilístico ao modelo, a partir do qual é possível trabalhar com dados e informações incertas.

O restante deste artigo está estruturado da seguinte maneira: na Seção 2 são apresentados os principais fundamentos que dão suporte ao desenvolvimento deste trabalho; na Seção 3, são discutidos os principais trabalhos relacionados; na Seção 4, são descritos os detalhes do modelo proposto; na Seção 5, é apresentada uma avaliação mostrando a viabilidade da proposta; e, por fim, na Seção 6, são apresentadas as considerações finais e potenciais trabalhos futuros.

## 2. Fundamentação Teórica

Alguns conceitos são importantes para o entendimento do modelo proposto neste trabalho, como é o caso das ontologias. Uma ontologia pode ser definida como uma especificação explícita de uma conceitualização, ou seja, uma formalização dos conceitos e relacionamentos em um domínio (Gruber, 1995). As ontologias possuem grande capacidade de representação semântica, o que permite a sua adaptação, extensão e reutilização em diversos ambientes.

Outro conceito importante diz respeito às RBs. Modelos matemáticos representados por meio de um grafo direcionado acíclico, onde os vértices representam as variáveis do domínio e as arestas representam as relações de dependências entre essas variáveis. Cada vértice possui uma tabela de probabilidade que indica a probabilidade do evento em questão acontecer. As RBs, geralmente, são construídas com auxílio de especialistas, que realizam inicialmente um levantamento sobre os principais tópicos a serem avaliados e, a partir disso, é criado um modelo que representa as relações de dependências entre esses conceitos, definindo os valores para as tabelas de probabilidade de cada evento.

As RBs têm atraído a atenção devido ao seu forte fundamento matemático e pelo seu modo natural de representar incertezas usando probabilidade (Millán *et al.*, 2010). Além dessas vantagens, esse modelo propicia uma representação gráfica das relações entre variáveis de domínio, levando em consideração o peso da relação causal por meio de probabilidades (Vier *et al.*, 2015).

### 3. Trabalhos Relacionados

O uso de ontologias para representar modelos de usuários tem atraído, cada vez mais, a atenção de pesquisadores. Chrysafiadi e Virvou (2013) mostram um crescente número de trabalhos que abordam essa técnica para modelagem de informações educacionais. Entre eles, é possível citar SoNITS (Nguyen *et al.*, 2011), um ME fundamentado em ontologias para um ambiente educacional baseado em redes sociais com o intuito de ajudar na organização do conhecimento e do raciocínio sobre as relações de habilidade.

Clemente *et al.* (2011) apresentam o MAEVIF, uma plataforma de software voltada ao desenvolvimento de ambientes educacionais para treinamentos. Esse ambiente proporciona conteúdo personalizado e fornece o *feedback* mais adequado em cada instante da interação por meio de um ME, que é baseado em ontologias e regras de diagnóstico. São utilizados agentes de software que interagem com uma rede de ontologia capaz de representar informações sobre o perfil, estado atual e atividades desempenhadas pelos estudantes. Também são discutidas algumas regras que podem ser empregadas para realizar inferência sobre diagnósticos.

Em Rezende *et al.* (2015) é descrita uma ontologia para modelagem do perfil e do contexto do aluno em um ambiente *e-learning*, a qual, visa padronizar as informações e facilitar o processo de recomendação de objetos de aprendizagem. A ontologia foi especificada de forma que possa ser adaptada a qualquer ambiente de aprendizagem. Resultados preliminares mostraram a boa adequação em cenários reais.

Outros trabalhos definem Modelos de Estudantes de forma híbrida, ou seja, exploram as melhores características de diferentes abordagens para produzir um modelo que seja mais adaptável ao contexto e domínio do estudante (Chrysafiadi e Virvou, 2015). Um modelo híbrido foi proposto por Sani e Aris (2014), que recorre à Lógica Fuzzy e as técnicas de ontologias para modelar o comportamento de aprendizagem do estudante com o objetivo de melhorar a aprendizagem e aumentar a adaptabilidade do sistema.

Grubišić *et al.* (2013) propõem uma abordagem probabilista baseada em RBs, que permitem tirar conclusões sobre o estado de conhecimento do usuário, e assim, melhorar o processo de ensino/aprendizagem. Neste trabalho, é proposto um método não empírico para determinar as probabilidades condicionais da RB. Isso proporciona maior autonomia do algoritmo, pois dispensa a difícil tarefa de adequar pesos à rede.

Mesmo com diversas abordagens de modelagens utilizando modelos híbridos, a união de RB com ontologias ainda é pouco explorada (Chrysafiadi e Virvou, 2013), sendo possível perceber uma lacuna de estudos que exploram a capacidade de representação das ontologias trabalhando junto com a grande capacidade de processamento de incertezas providas pelas RBs. Esse é justamente o diferencial da proposta ora apresentada, a qual faz o uso conjunto dessas técnicas para prover um modelo conciso, completo e dinâmico para a representação de estudantes em sistemas educacionais adaptativos.

### 4. Descrição do Modelo

A abordagem proposta neste trabalho apresenta características para a descrição dos principais aspectos educacionais que representam o comportamento do estudante em um sistema adaptativo. Estes ambientes são providos de particularidades que, muitas vezes, não são tratadas na maioria dos ambientes convencionais de ensino. Informações como es-

tilos de aprendizagem, contexto de acesso, colaboração e atividades de gamificação são exemplos de características que devem ser tratadas em uma modelagem de estudante.

A partir do exposto, foi conduzido um intenso estudo com o propósito de levantar as principais características e dados que realmente são necessários para descrição de um estudante, para, assim, criar um modelo que fosse conciso e que representasse as principais informações para esses ambientes. As características escolhidas podem ser subdivididas em quatro grupos:

- **Informações Pessoais:** Dados pessoais do estudante, como estilos de aprendizagem segundo a abordagem de Felder-Silverman, preferências e características afetivas.
- **Comportamento:** Informações sobre atividades e comportamentos desempenhados no ambiente, como colaboração, gamificação e percurso.
- **Contexto:** Informações sobre o contexto atual de utilização, como dispositivo, localização e motivo de acesso.
- **Progresso/Conhecimento:** Informações sobre o estado atual do estudante, relatando seus conhecimentos, erros e equívocos.

A partir dessas características, foi definida uma ontologia para representar todas essas informações, conforme detalhado na Seção 4.1. Uma decisão importante sobre a modelagem de estudante é a definição de uma abordagem para descobrir, em meio a tantas informações, aquelas que realmente são úteis para uma personalização e adaptação de conteúdo mais efetiva.

Neste trabalho, optou-se por uma abordagem de construção de modelo que se baseasse em ontologias e RBs. A abordagem proposta une essas duas técnicas para criar um ME híbrido, no qual, a ontologia é utilizada para representação das características e das informações sobre os estudantes, bem como, na inferência de fatos a partir de regras semânticas pré-definidas. Já a RB atua como um modelo probabilístico, auxiliando nas inferências relacionadas às habilidades dos estudantes. As probabilidades de conhecimento determinadas pela rede são repassadas para a ontologia, que, por sua vez, realiza inferências, com base nestas e nas demais informações sobre o estudante já constantes na ontologia. A integração dessas duas técnicas possibilita que as inferências tratadas pelo modelo sejam mais consistentes, considerando também as incertezas inerentes ao processo de avaliação de conhecimento e comportamento do estudante.

#### 4.1. A Ontologia

A escolha de um formalismo mediante ontologias para modelar o estudante é justificável principalmente por duas razões: (i) uma ontologia viabiliza a representação de conceitos e propriedades de modo a serem facilmente reutilizados e, se necessário, estendidos em diferentes contextos da aplicação; (ii) o uso de ontologias permite o *reasoning* das informações representadas. Com isso, é possível a implementação de inferências a partir do desenvolvimento de regras (Clemente *et al.*, 2011).

Para a construção da ontologia, utilizou-se a metodologia definida em Noy e McGuinness (2001). Quanto a sua definição formal, foi adotada a linguagem OWL<sup>1</sup>(*Web Ontology Language*), em particular, a sub-linguagem OWL-DL (*Description Language*).

<sup>1</sup><http://www.w3.org/standards/techs/owl>

A ontologia proposta apresenta características suficientes para abstração de um ME que seja capaz de representar o seu estado atual de conhecimento, possibilitando melhor adaptação e personalização de conteúdo educacional com as reais necessidades de cada aluno. A Tabela 1 apresenta o detalhamento da ontologia criada, listando suas classes, descrições e principais referências na literatura. A Figura 1 detalha o relacionamento entre as classes na ontologia.

**Tabela 1. Classes representadas na ontologia.**

Classe	Descrição	Referência
Personal Information	Informações Pessoais (nome, email, idade, sexo, etc)	Dolog e Nejd1 (2007); Rezende <i>et al.</i> (2015)
Behavior	Comportamento do estudante durante a utilização do ambiente educacional	Clemente <i>et al.</i> (2011)
Colaboration	Atividades de colaboração (comentário, classificação, etc)	Hsiao <i>et al.</i> (2013)
Gamification	Desempenho em atividades de gamificação	Shute <i>et al.</i> (2015); Minovic <i>et al.</i> (2015)
Game	Games disponíveis para pontuação	Shute <i>et al.</i> (2015); Minovic <i>et al.</i> (2015)
Trace	Rastro (atividades) executado pelo estudante em um determinado acesso	Clemente <i>et al.</i> (2011)
Context	Contexto de acesso do estudante	Rezende <i>et al.</i> (2015)
Devices	Dispositivo utilizado pelo estudante durante o acesso	Verbert <i>et al.</i> (2012); Rezende <i>et al.</i> (2015)
Location	Localização atual do estudante durante o acesso	Verbert <i>et al.</i> (2012); Rezende <i>et al.</i> (2015)
Learning Style	Estilos de aprendizagem (abordagem Felder-Silverman)	Mahnane e Laskri (2012)
Preferences	Preferências do estudante	Dolog e Nejd1 (2007); Rezende <i>et al.</i> (2015)
State	Estado atual de conhecimento do estudante	Ting e Phon-Amnuaisuk (2012)
Knowledge	Conhecimento em um determinado tópico (assunto)	Dolog e Nejd1 (2007); Clemente <i>et al.</i> (2011)
Activity	Atividades avaliativas disponíveis para o estudante	Shute <i>et al.</i> (2015)

#### 4.1.1. Regras

O ME proposto possui a capacidade de realizar inferências sobre a performance do estudante com base nas informações descritas na ontologia. Para processar essas inferências, regras podem ser criadas a fim de proporcionar um resultado mais condizente com as reais capacidades dos estudantes. As regras aqui apresentadas combinam diversos aspectos do estudante (comportamento, colaboração, atividades em gamificação, conhecimento, etc.), no sentido de apresentar uma estimativa de performance mais consistente.

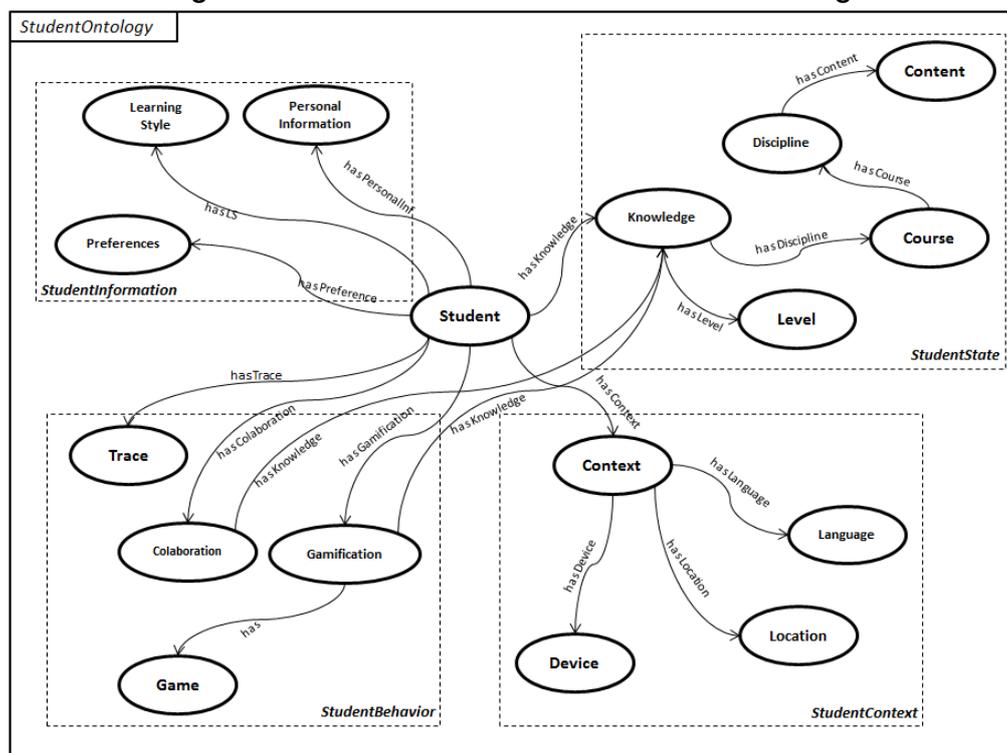
Desta forma, uma vantagem desta abordagem é possibilitar inferir o desempenho do estudante levando-se em consideração diversos aspectos importantes relacionado ao uso do ambiente educacional. A seguir, são descritas algumas regras que podem ser utilizadas para realização de inferências. Outras podem ser desenvolvidas, dependendo da necessidade de cada ambiente. As regras foram desenvolvidas utilizando a linguagem SWRL<sup>2</sup> (*Semantic Web Rule Language*):

**Regra 1:**

```
integer[>LLow, <=LHigh](?gra) ^ grade(?K, ?gra) ^
hasKnowledge(?S, ?K) ^ hasContent(?K, ?C) ^
hasColaboration(?S, ?Co) ^ hasContent(?Co, ?C) ^
colabVal(?Co, baixo) -> hasLevel(?S, D)
```

<sup>2</sup><https://www.w3.org/Submission/SWRL/>

Figura 1. Relacionamento entre as classes na ontologia



A Regra 1 baseia-se em apenas duas métricas para inferir o desempenho do estudante: *hasKnowledge* e *hasCollaboration*. Esta regra presume que, se o estudante possui um nível de colaboração baixo e seu nível de conhecimento em um determinado tópico (*Content*) é considerado bom, ele possui um nível (*hasLevel*) igual a D. É importante frisar que a escala para representar o nível de conhecimento é flexível, determinada pelas variáveis LLow e LHigh.

#### Regra 2:

```
integer[>LLow, <=LHigh] (?gra) ^ grade(?K, ?gra) ^
hasKnowledge(?S, ?K) ^ hasContent(?K, ?C) ^
hasContent(?G, ?C) ^ hasContent(?Co, ?C) ^
hasGamification(?S, ?G) ^ gamVal(?G, alto) ^
hasCollaboration(?S, ?Co) ^ colabVal(?Co, alto) ^
-> hasLevel(?S, B)
```

A Regra 2 baseia-se em três métricas para descrever o nível de conhecimento do estudante: *hasKnowledge*, *hasCollaboration* e *hasGamification*. Esta regra presume que se o estudante possui um alto nível de interação com o ambiente, alto nível de participação em atividades de gamificação e um nível de conhecimento regular, ele possui um nível (*hasLevel*) igual a B.

## 4.2. Integração de Redes Bayesianas no Modelo

A proposta aqui apresentada explora as principais características das RBs com o intuito de tratar as incertezas em relação ao conhecimento obtido pelo estudante. A rede será utilizada como um mecanismo para inferência da probabilidade de conhecimento em determinado conteúdo, a qual usará alguns nós evidências para representar exercícios que os

usuários irão resolver, para, a partir disso, determinar o conhecimento nos demais tópicos estudados.

Uma das grandes vantagens desse modelo é justamente a capacidade de representação de estudante independente do domínio de conhecimento. Neste modelo, o conhecimento é representado por meio das RBs, ou seja, independente da ontologia. Caso seja necessário aplicar o modelo a outro domínio, basta substituir a rede e o modelo funcionará corretamente. A utilização dessas redes, além de considerar as incertezas em relação a avaliação do nível de conhecimento do estudante em determinado domínio, garante ainda uma dinamicidade do modelo, permitindo que a avaliação do conhecimento seja separada das informações do estudante, e assim, um modelo que seja independente e funcional.

A partir das inferências realizadas pela RB, essas informações são repassadas para a ontologia, a qual irá interpretar essas informações juntamente com as outras já obtidas pelo modelo (como comportamento, colaboração, atividades em gamificação, etc.). Com todas essas informações, a ontologia utilizará as regras criadas para inferir o desempenho global do estudante. Vale ressaltar que esse modelo é completamente dinâmico, ou seja, a cada interação do estudante com o ambiente, as variáveis são atualizadas e repassadas para a ontologia, que se encarregará de refazer as inferências a partir dos dados atualizados.

## 5. Avaliação

Para avaliar a viabilidade do modelo, foram conduzidos alguns estudos com o intuito de verificar a consistência na integração da ontologia com uma RB. Esta avaliação busca verificar se o resultado indicado pela ontologia condiz realmente com os valores esperados pelos professores especialistas no assunto. Como o modelo proposto ainda não está integrado a um ambiente de ensino, um protótipo<sup>3</sup> foi desenvolvido e a avaliação foi conduzida a partir de estudantes virtuais, abordagem que tem sido amplamente aplicada em avaliações de Modelos de Estudantes (Grubišić *et al.*, 2013; Vier *et al.*, 2015).

Neste estudo, foi utilizada uma RB para o domínio da disciplina de Introdução a Programação de Computadores, construída e avaliada por três professores. As probabilidades condicionais de cada nó também foram informadas pelos professores. A rede proposta possui um total de 23 nós, que são utilizados para representar os conhecimentos disponíveis no modelo. Dentre os 23 nós na rede, 3 foram escolhidos para receber as informações de entrada da rede (*ConditionalExpressions*, *ComparacionOperators*, *DataType*), ou seja, onde serão realizadas atividades avaliativas para medir o conhecimento do estudante. Outros 5 nós foram utilizados para observação dos valores da saída calculados pela rede (*logigOperators*, *Loops*, *Variables*, *Integer*, *If*). Com intuito de simplificar o entendimento, a Figura 2 apresenta uma parte da rede proposta pelos professores.

A Tabela 2 apresenta informações sobre o estado atual de conhecimento e participação dos estudantes no ambiente simulado. São 10 estudantes que possuem as seguintes informações: probabilidade de conhecimento nos 3 nós de entrada (evidências), bem como, valores referentes a atividades de gamificação e colaboração. Por questão de espaço serão discutidos experimentos somente de dois estudantes.

<sup>3</sup>Protótipo implementado utilizando *OWL API Java* para manipulação da ontologia e *API Smile* para manipulação da RB. Também foi utilizado o *reasonner Pellet* para tratamento das inferências.

Figura 2. Trecho da RB utilizada para avaliação do modelo

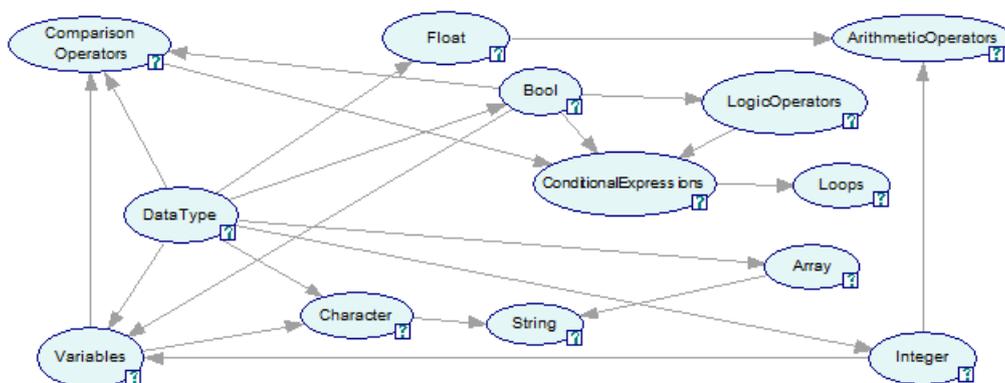


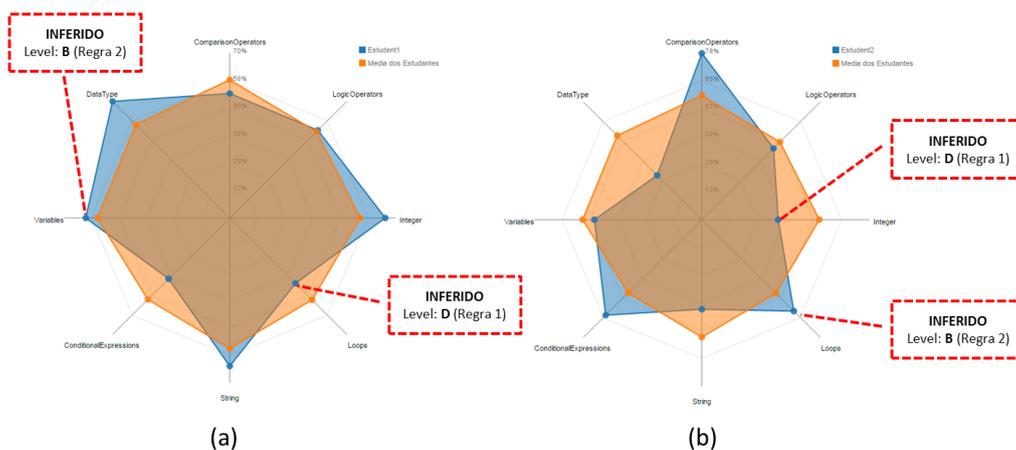
Tabela 2. Valores simulados para os estudantes virtuais

Estudante	Cond. Expr.			Comp. Oper.			DataType		
	PC	Gam	Col	PC	Gam	Col	PC	Gam	Col
Estudante1	0.22	baixo	baixo	0.41	médio	médio	0.85	baixo	médio
Estudante2	0.60	alto	alto	0.90	alto	médio	0.10	alto	alto
...	..	..	..	..	..	..	..	..	..

PC: Prob. de Conhecimento (0.1 - 0.9) - Gam: Atividades de Gamificação - Col: Atividades de Colaboração

Os valores mencionados na Tabela 2 foram submetidos para avaliação a partir do protótipo do ME desenvolvido. A Figura 3 mostra o desempenho de dois estudantes – (a) Estudante1 e (b) Estudante2 – pelo qual é possível observar a probabilidade de um determinado aluno conhecer tal assunto, bem como, a média da probabilidade da turma conhecer esse assunto (probabilidade do estudante em azul e probabilidade média da turma em amarelo). É possível observar também as inferências realizadas pela ontologia.

Figura 3. Probabilidades e inferências realizadas pelo protótipo



Os resultados gerados com o protótipo foram analisados pelos professores especialistas, que concluíram que o modelo é adequado e as inferências foram condizentes com os valores esperados. Segundo os especialistas, os dados gerados para os tópicos que

não possuíam atividades avaliativas apresentam uma relação adequada ao previsto, tendo em vista os valores informados nos nós evidências. As inferências foram consideradas corretas, tendo como base o que foi descrito com as regras na ontologia.

## 6. Conclusões

Este trabalho emprega uma abordagem híbrida para um ME probabilístico, dinâmico e passível de reutilização e extensão. Uma ontologia é usada para descrever as principais características do estudante e uma RB para inferir sobre a probabilidade de conhecimento em determinados conceitos do domínio. Junto a ontologia, são propostas regras semânticas que permitem a inferência do nível de conhecimento do estudante com base em diversas métricas obtidas durante a utilização do ambiente educacional. A utilização da RB garante que o domínio de conhecimento seja completamente separado das demais características, proporcionando assim, que o modelo possa ser adaptado e aplicado a outros domínios, bastando para isso somente a substituição da RB empregada.

Para a validação da proposta foram realizados experimentos em um ambiente simulado, no qual alunos virtuais foram criados com o intuito de verificar se as inferências realizadas pelo modelo correspondiam às expectativas de professores especialistas. Foi utilizada uma RB com 23 nós de conhecimento voltados para o domínio de Programação de Computadores. Resultados mostraram uma boa adequação das regras semânticas, o que comprova que o modelo proposto é adequado para identificação de características comportamentais e a sua integração pode auxiliar atividades de recomendação e personalização de conteúdo em sistemas educacionais adaptativos. Desta forma, esta abordagem automática, dinâmica e probabilística para modelagem do estudante está sendo integrada ao ambiente educacional Classroom eXperience (CX) (Araujo *et al.*, 2013) para auxiliar no apoio individualizado aos estudantes.

Potenciais trabalhos futuros incluem: a integração e a experimentação do modelo proposto em um ambiente real de ensino; a construção de regras semânticas para diagnóstico das principais dificuldades dos estudantes; a implementação de mecanismos para ajudar na recomendação individualizada de conteúdo; e a construção de ferramentas para auxiliar no desenvolvimento colaborativo da RB.

## 7. Agradecimentos

Os autores agradecem o apoio de: CNPq, CAPES, FAPEMIG, PROPP/UFU, IFSULDEMINAS e PET/MEC/SESu.

## Referências

- Araujo, R., Brant-Ribeiro, T., Cattelan, R., De Amo, S., e Ferreira, H. (2013). Personalization of Interactive Digital Media in Ubiquitous Educational Environments. In *Systems, Man, and Cybernetics (SMC), 2013 IEEE International Conference on*, páginas 3955–3960.
- Chrysafiadi, K. e Virvou, M. (2013). Student modeling approaches: A literature review for the last decade. *Expert Systems with Applications*, 40(11):4715–4729.
- Chrysafiadi, K. e Virvou, M. (2015). *Advances in Personalized Web-Based Education, Cap: A Novel Hybrid Student Model for Personalized Education*, p. 61–90. Springer International Publishing, Cham.

- Clemente, J., Ramírez, J., e de Antonio, A. (2011). A Proposal for Student Modeling Based on Ontologies and Diagnosis Rules. *Expert Syst. Appl.*, 38(7):8066–8078.
- Dolog, P. e Nejdil, W. (2007). The Adaptive Web. Cap: Semantic Web Technologies for the Adaptive Web, p. 697–719. Springer-Verlag, Berlin.
- Gruber, T. R. (1995). Toward Principles for the Design of Ontologies Used for Knowledge Sharing. *Int. J. Hum.-Comput. Stud.*, 43(5-6):907–928.
- Grubišić, A., Stankov, S., e Peraić, I. (2013). Ontology based approach to Bayesian student model design. *Expert systems with applications*, 40(13):5363–5371.
- Hsiao, I.-H., Bakalov, F., Brusilovsky, P., e König-Ries, B. (2013). Progressor: social navigation support through open social student modeling. *New Review of Hypermedia and Multimedia*, 19(2):112–131.
- Li, N., Cohen, W. W., Koedinger, K. R., e Matsuda, N. (2011). A Machine Learning Approach for Automatic Student Model Discovery. In *Proc. of 4th International Conference on Educational Data Mining, Eindhoven*, p. 31–40.
- Mahnane, L. e Laskri, M. T. (2012). An Adaptive Hypermedia System Integrating Thinking Style (AHS-TS): Model and Experiment. *International Journal of Hybrid Information Technology*, 5(1):11–28.
- Millán, E., Loboda, T., e Pérez-de-la Cruz, J. L. (2010). Bayesian Networks for Student Model Engineering. *Comput. Educ.*, 55(4):1663–1683.
- Minovic, M., Milovanovic, M., Sosevic, U., e Gonzalez, M. A. C. (2015). Visualisation of student learning model in serious games. *Comp. in Human Behavior*, 47:98 – 107.
- Mitrovic, A. e Thomson, D. (2009). Towards a negotiable student model for constraint-based ITSs.
- Nguyen, C. D., Vo, K. D., Bui, D. B., e Nguyen, D. T. (2011). An Ontology-based IT Student Model in an Educational Social Network. In *Proc. of 13th iiWAS*, p. 379–382.
- Noy, N. F. e McGuinness, D. L. (2001). Ontology Development 101: A Guide to Creating Your First Ontology. Technical report.
- Rezende, P. A., Pereira, C., Campos, F., David, J., e Braga, R. (2015). PERSONNA: proposta de ontologia de contexto e perfil de alunos para recomendação de objetos de aprendizagem. *Revista Brasileira de Informática na Educação*, 23(01):70.
- Sani, S. e Aris, T. N. (2014). Proposal for Ontology Based Approach to Fuzzy Student Model Design. In *Proc. of 5th ISMS*, p. 35–37, IEEE.
- Shute, V. J., D’Mello, S., Baker, R., Cho, K., Bosch, N., Ocumpaugh, J., Ventura, M., e Almeda, V. (2015). Modeling how incoming knowledge, persistence, affective states, and in-game progress influence student learning from an educational game. *Computers & Education*, 86:224 – 235.
- Ting, C.-Y. e Phon-Amnuaisuk, S. (2012). Properties of Bayesian Student Model for INQPRO. *Applied Intelligence*, 36(2):391–406.
- Verbert, K., Manouselis, N., Ochoa, X., Wolpers, M., Drachsler, H., Bosnic, I., e Duval, E. (2012). Context-Aware Recommender Systems for Learning: A Survey and Future Challenges. *IEEE Trans. Learn. Technol.*, 5(4):318–335.
- Vier, J., Gluz, J., e Jaques, P. A. (2015). Empregando Redes Bayesianas para modelar automaticamente o conhecimento dos alunos em Lógica de Programação. *Revista Brasileira de Informática na Educação*, 23(2):45–59.