

PROPOSTA DE UM SISTEMA HIPERMÍDIA ADAPTATIVO EDUCACIONAL PARA A PERSONALIZAÇÃO DO PROCESSO DE ENSINO ATRAVÉS DA WEB

Alexandre Martins Ferreira Bueno¹, Leonardo da Cunha Brito¹, João Carlos da Silva²

¹Escola de Engenharia Elétrica e de Computação – Universidade Federal de Goiás – Goiânia – GO – Brasil

²Instituto de Informática – Universidade Federal de Goiás – Goiânia – GO – Brasil

alexmbf@yahoo.com.br, brito@eeec.ufg.br, jcs@inf.ufg.br

Abstract

Nowadays, e-learning has become an important source of knowledge, providing content without the limitation of time or space and with independence of classroom and platform. Such an environment includes students with a large diversity of characteristics, which makes necessary, for learning improvement, that the content presented to each student be appropriated to their individual characteristics. In this paper we propose a Web-based Adaptive Educational Hypermedia System that aims to personalize the process of learning. This system makes use of a Bayesian network to represent the student model and of Item Response Theory in the student's ability tests. The results showed that the system provided a significant improvement in knowledge retention by the students.

Keywords – e-learning, Adaptive Educational Hypermedia System, student modeling, Bayesian networks.

Resumo

Hoje em dia, o *e-learning* se tornou uma importante vertente na obtenção de conhecimento, fornecendo conteúdo sem a limitação de tempo ou espaço e com independência de sala de aula e plataforma. Neste ambiente, estão inclusos alunos com as mais variadas características, o que torna necessário, para um melhor aprendizado, que o conteúdo apresentado a cada aluno se adeque às suas características individuais. Neste artigo é proposto um Sistema Hipermissão Adaptativo Educacional que tem como objetivo a personalização do processo de ensino-aprendizagem através da *Web*. Ele faz uso de uma Rede Bayesiana para a representação do modelo do aluno e da Teoria da Resposta ao Item nos testes de habilidade dos alunos. Os resultados obtidos mostraram que o sistema proporcionou uma melhoria significativa na retenção de conhecimento por parte dos alunos.

Palavras-chaves – *e-learning*, Sistemas Hipermissão Adaptativos Educacionais, modelagem do aluno, Redes Bayesianas.

1 Introdução

Com a popularização da *Web*, inúmeras aplicações de *e-learning* têm utilizado este ambiente para prover conhecimento. Estas aplicações podem ser utilizadas pelos professores como auxílio às suas aulas e, principalmente, em educação à distância. A educação baseada na *Web*, ou educação *on-line*, ganhou grande importância. Com o crescimento do *e-learning*, houve um aumento na diversidade de alunos que se utilizam deste meio para obter suas formações acadêmicas ou profissionais. Em geral, estes alunos possuem diferentes características culturais, cognitivas, estilos de aprendizagem, habilidades e interesses.

Deste modo, a diversidade de características dos alunos é um aspecto central em *e-learning*. Além disso, como nos sistemas de *e-learning* geralmente é o aluno quem toma a iniciativa de aprender, existe a necessidade de se fornecer conteúdos que contemplam esta diversidade. Os cursos oferecidos pelos sistemas convencionais nem sempre consideram esta diversidade, apresentando sempre o mesmo conteúdo a todos os alunos. A diversidade de características dos alunos demanda por conteúdo personalizado. Portanto, “um curso para todos” não é mais apropriado em *e-learning* [1]. Nas últimas décadas, várias pesquisas têm dado ênfase na criação de técnicas que provêm adaptação (personalização) em sistemas de *e-learning*. Muitas destas técnicas são utilizadas em Sistemas Hipermissão Adaptativos e em ferramentas para autoria destes sistemas, como o NetCoach [2] e o ELM-ART [3].

Nestes sistemas citados, o modelo do usuário é representado basicamente por regras, relações entre os conceitos e o usuário, e por pares “conceito-valor”. Este modelo não trata as incertezas que são inerentes aos usuários. Segundo [4], não existe dúvida de que na modelagem do usuário muitas vezes é preciso lidar com informações que são incertas ou imprecisas (quando não se tem certeza de que a informação obtida é totalmente verdadeira ou completa). Sistemas Hipermissão Adaptativos que fazem uso de modelos de usuário que representam incertezas (como em [5]) ainda é um tópico em aberto e que merece ser explorado. Tal fato culminou na proposta de um sistema, que será apresentada neste artigo.

2 Fundamentação Teórica

2.1 – Sistemas Hipermissão Adaptativos (SHAs)

Os SHAs são uma alternativa ao tradicional “formato único” utilizado pelos Sistemas Hipermissão. Nestes, sempre é fornecido o mesmo conteúdo aos usuários, que precisam se adaptar ao sistema [6]. O objetivo dos SHAs é fornecer ao usuário um

ambiente hipermídia dinâmico e adequado às suas necessidades, preferências e características individuais. Um documento hipermídia é formado pela junção entre hipertexto e diferentes tipos de mídias de apresentação, como vídeo, som e imagem.

A hipermídia adaptativa teve um rápido crescimento a partir de 1996, devido à forte expansão da *Web* [6]. Os SHAs para fins educacionais (com conteúdo instrucional) são chamados de Sistemas Hipermídia Adaptativos Educacionais (SHAEs). Não existe uma arquitetura clássica para os SHAs. Entretanto, existem propostas de Modelos de Referência para estes sistemas, como o Modelo de Referência Munique [7]. Em geral, estes modelos possuem os seguintes componentes:

- Modelo de Domínio (MD) – é a base de conhecimento do sistema, contém os elementos que serão usados para que o usuário aprenda o domínio que será tratado; estes elementos podem ser definições, exemplos, atividades, questões, entre outros. Geralmente, a estrutura do MD é representada por uma rede de conceitos do domínio envolvido;
- Modelo de Usuário (MU) – é responsável por armazenar as características do usuário que possam influenciar nas decisões de adaptação tomadas pelo SHA. Ele representa a visão que o sistema possui do usuário. O MU funciona como uma referência para o sistema, que busca adaptar seu ambiente a ele. Entre as principais características do usuário que são consideradas estão: conhecimento, interesses, objetivos, *background* e características individuais [4];
- Modelo de Adaptação – contém regras e técnicas que permitem a adaptação do conteúdo, navegação e apresentação. Ele especifica como devem ser feitas as atualizações do MU após a observação do usuário. As regras nele presentes definem como o MD e o MU são combinados para prover adaptação. Em SHAEs, este modelo também é chamado de modelo de ensino e também contempla as estratégias pedagógicas que serão utilizadas no processo de aprendizagem;
- Interface do Usuário – constitui a camada de interação (comunicação) do sistema com o usuário, onde o conteúdo hipermídia, *links* e outros componentes selecionados pelo modelo de adaptação são apresentados.

O conhecimento é a característica do usuário mais importante e mais utilizada pelos SHAs. Um método muito utilizado para a modelagem desta característica é o Modelo *Overlay* (MO). O seu objetivo é representar o conhecimento individual do usuário como um subconjunto do MD, que reflete o conhecimento do especialista no assunto. Assim, ele se baseia na estrutura do MD. Para cada conceito presente no MD, o MO armazena uma estimativa de conhecimento do usuário para este conceito. Quando estas estimativas envolvem probabilidades, utiliza-se de técnicas como Redes Bayesianas para o tratamento destas incertezas. Um MO que modela o conhecimento do usuário é frequentemente chamado de modelo do aluno [4].

Como mencionado, a adaptação pode ocorrer em nível de conteúdo (adaptação de textos, imagens, entre outros), navegação (manipula os *links* disponíveis) e apresentação (adaptações de *layout*). Técnicas de adaptação são encontradas em [6] e [8].

Dentre as técnicas de adaptação do conteúdo está a de Página Variante, que consiste em manter duas ou mais páginas para cada conceito, descrevendo-o de maneiras diferentes, e com cada uma delas adaptada a certo estereótipo de usuário. Dentre as técnicas de adaptação da navegação está a Orientação Direta, na qual o sistema decide qual é o próximo conteúdo mais apropriado a ser apresentado ao usuário, de acordo com as suas características. Geralmente, esta técnica é expressa por um *link* chamado “Próximo”. Esta técnica não oferece liberdade de escolha aos usuários, mas é muito utilizada em SHAEs, em que os usuários geralmente são iniciantes no domínio a ser abordado e apresentam problemas em fazer suas próprias escolhas.

2.2 – Redes Bayesianas (RBs)

As RBs [9] são modelos gráficos (união entre as teorias da probabilidade e dos grafos) para inferência (raciocínio) baseada na incerteza nos quais os nós representam as variáveis e os arcos as relações diretas entre eles. Elas fornecem uma descrição completa do domínio envolvido e apresentam de forma direta e estruturada as dependências existentes entre as variáveis.

Uma RB é composta por um conjunto de variáveis (nós) V e um conjunto de arestas direcionadas (arcos) E , em que:

- Os nós juntamente com os arcos formam um Grafo Acíclico Orientado (GAO), representado por $G = (V, E)$;
- Para cada variável $A \in V$ com pais B_1, \dots, B_n existe uma tabela de probabilidades condicionais representada por $P(A|B_1, \dots, B_n)$ ou, alternativamente, $P(A|pais(A))$. Se A não possui pais, então a tabela é reduzida a uma tabela de probabilidades incondicionais ou a priori $P(A)$;
- Cada nó A é condicionalmente independente de todos os seus não descendentes dado o conjunto de todos os seus pais (condição de Markov). Cada nó A possui um conjunto de estados que ele pode assumir;
- A distribuição conjunta de probabilidade total das variáveis em V é dada por (1).

$$P(V) = P(A_1, \dots, A_n) = \prod_{i=1}^n P(A_i | pais(A_i)) \quad (1)$$

Uma RB possui, então, uma parte qualitativa (estrutura da rede) e outra quantitativa (probabilidades condicionais e a priori); ela representa de forma sucinta a distribuição conjunta das suas variáveis, através das tabelas de probabilidade. A tarefa básica da inferência nas RBs é calcular a distribuição de probabilidade a posteriori para um conjunto de variáveis, dados valores que

foram atribuídos a outro conjunto de variáveis devido a algum evento que foi observado (novas evidências coletadas). O processo de inferência a partir de evidências também é chamado de propagação de evidências.

O processo de inferência em RBs tem como base a Regra de Bayes, apresentada em (2). Ela provê um método para atualizar a crença sobre a hipótese H dado que foi obtida a evidência e (nova informação sobre o estado de determinada variável). $P(H)$ é a probabilidade a priori de H , ela reflete o conhecimento anterior à evidência ser considerada. A probabilidade $P(e|H)$ é chamada de verossimilhança (*likelihood*) e avalia a probabilidade da evidência ser obtida da hipótese. $P(e)$ é uma constante de normalização. $P(H|e)$ é a probabilidade a posteriori, refletindo a probabilidade da hipótese após a consideração da evidência.

$$P(H|e) = \frac{P(e|H)P(H)}{P(e)} \quad (2)$$

Um método exato (que possui erros apenas de arredondamento e precisão) para a propagação de evidências muito utilizado é o algoritmo de Árvore de Junção [10]. Ele faz uso dos métodos de agrupamento e computação local, em que a estrutura da RB é transformada numa estrutura intermediária, na qual os nós representam subconjuntos de nós da RB original e os cálculos são realizados localmente (a um custo menor), no sentido de que um nó necessita se comunicar apenas com seus vizinhos.

Entre os tipos de evidência aplicados às RBs está a Evidência Virtual (*Likelihood*) [11]. Nela, foi observado o estado a_i para a variável A , porém, existe uma incerteza quanto a isto, sendo fornecida uma confiança a respeito desta observação na forma de uma distribuição condicional de probabilidade $P(a_i|A = a_j)$, em que a_j representa todos os estados de A . Estas probabilidades condicionais podem ser assim entendidas: a probabilidade de se observar A no estado a_i dado que o seu verdadeiro estado é a_j .

2.3 – Teoria da Resposta ao Item (TRI)

Atualmente, a TRI é uma das principais técnicas utilizadas pela psicometria (conjunto de técnicas cujo objetivo é mensurar as habilidades cognitivas dos indivíduos). Embora seja utilizada em diversas áreas, ela se destaca especialmente em processos de avaliação educacional. O que esta metodologia sugere são formas de representar a relação entre a probabilidade de um indivíduo dar uma certa resposta a um item ou questão e suas habilidades na área de conhecimento avaliada [12].

Entre os modelos utilizados pela TRI destaca-se o Modelo Logístico de 3 Parâmetros (ML3P). Nele, os itens são tratados de forma dicotômica (corrigidos como certo ou errado), ele avalia apenas uma habilidade do indivíduo e envolve uma única população [12]. No ML3P, a probabilidade de um indivíduo com habilidade θ responder corretamente ao item i é dada por (3).

$$P_i(\theta) = P(U_i = 1|\theta) = c_i + \frac{1 - c_i}{1 + e^{-Da_i(\theta - b_i)}} \quad (3)$$

Em (3), U_i assume o valor 1 quando o indivíduo acerta o item i , ou 0 caso contrário, e D é um fator de escala, constante e igual a 1, utiliza-se o valor 1,7 quando se deseja resultados semelhantes ao da função ogiva normal. b_i , a_i , c_i são considerados os parâmetros do item i . b_i é o parâmetro de dificuldade, quanto maior o seu valor mais difícil é o item, e vice-versa. a_i é o parâmetro de discriminação, baixos valores de a_i indicam que o item tem pouco poder de discriminação, ou seja, indivíduos com baixa ou alta habilidade terão probabilidades semelhantes de acertá-lo. c_i é um parâmetro que representa a probabilidade de acerto ao acaso ou “chute”, indicando a probabilidade de um indivíduo com baixa habilidade acertar o item.

Os parâmetros b_i e a_i são medidos na mesma escala de θ . O modelo apresentado é acumulativo, ou seja, a probabilidade de um indivíduo dar uma resposta correta ao item aumenta com o aumento da sua habilidade. A curva formada por (3), chamada de Curva Característica do Item, possui uma representação em forma de “S” (sigmóide). A TRI requer um pressuposto chamado de independência local; ele assume que, dada uma habilidade, as respostas aos diferentes itens apresentados são independentes.

Uma importante etapa da TRI é a estimação dos parâmetros dos itens (também chamada de calibração) e das habilidades dos indivíduos. Em geral, a estimação é feita através do método da Máxima Verossimilhança e por métodos Bayesianos. Para o cálculo das habilidades dos indivíduos, quando os parâmetros dos itens são conhecidos, um método muito utilizado é a Média a Posteriori (EAP, do inglês *Expected a Posteriori*) [13], que é um método Bayesiano. Ele gera estimativas para todos os padrões de repostas e, por não fazer uso de técnicas iterativas (como o algoritmo Newton-Raphson), é potencialmente mais rápido.

3 Sistema Proposto

O objetivo deste artigo é apresentar a proposta de um SHAE que provê cursos com conteúdo personalizado aos alunos e que faz uso do ambiente *Web* para ensinar. A seguir, são apresentados os principais componentes deste sistema.

3.1 – Modelo de Domínio

O MD é composto pelos conceitos que serão ministrados pelo sistema e pelas relações existentes entre eles (rede de conceitos). Para cada conceito, foram elaborados três níveis de representação, que correspondem a níveis de dificuldade, são eles:

- Básico – em que o conceito é exposto de forma bem acessível e didática, ao custo de alguma perda na exatidão;
- Intermediário – em que o conceito é exposto de forma abrangente e com a introdução de linguagem técnica;
- Avançado – em que o conceito é apresentado de forma mais abrangente e com linguagem técnica.

O conteúdo de nível básico é considerado o mínimo que o aluno deve aprender sobre o conceito. Os elementos (características, princípios, etc.) nele presentes também estão presentes nos outros dois níveis. O nível básico apresenta mais exemplos e imagens que o nível intermediário, que, por sua vez, possui mais exemplos e imagens que o nível avançado. O nível avançado, por ser o mais abrangente, possui elementos que não existem no nível intermediário; este possui elementos que não existem no nível básico. Neste artigo, o nível básico é tratado como inferior ao nível intermediário, que, por sua vez, é considerado inferior ao nível avançado.

3.2 – Modelo do Aluno (MA)

O MA tem como base a estrutura da rede de conceitos do modelo de domínio (modelo *overlay*), em que a característica do aluno que é modelada é o conhecimento. Este modelo é representado por uma Rede Bayesiana, em que cada nó (conceito) possui dois estados: conhece e não conhece. Deste modo, a RB armazena e fornece as probabilidades que os alunos têm de conhecer os conceitos do domínio envolvido.

Por fazer uso de uma técnica capaz de lidar com incertezas, o modelo é capaz de responder a questões como: “O aluno errou uma questão referente a determinado conceito, qual é a chance dele conhecê-lo? Dado que o aluno conhece um conceito que tem grande influência sobre outro conceito, qual é a chance dele conhecer este outro conceito?”

3.2.1 – Mecanismo de ajuste do MA

Para cada conceito apresentado ao aluno, o sistema faz uso de questões de pré-teste e pós-teste, que representam questões de múltipla escolha que têm por objetivo avaliar a habilidade e o desempenho do aluno. As respostas a estas questões são utilizadas para ajustar o MA. A seguir é apresentado o significado de cada um destes tipos de testes:

- O pré-teste é uma questão que é apresentada antes do conceito ser visualizado pelo aluno. Ela não avalia se o aluno conhece ou não o conceito, mas sim se ele é capaz de abstrair as principais características ou ideias que estão presentes nele. Existe apenas uma questão de pré-teste para cada conceito;
- O pós-teste é uma questão que é aplicada após a apresentação de algum dos conteúdos (níveis de representação) do conceito envolvido. Ela avalia o conceito que foi apresentado, indicando se o aluno o aprendeu ou não. Os alunos sempre respondem, para um conceito, a mesma questão de pós-teste, independentemente do nível de dificuldade que eles visualizaram. Ela testa apenas os elementos que estão presentes em todos os níveis de dificuldade do conceito.

As questões de pré-teste são simples. Já as de pós-teste são mais complexas e exigem maior capacidade por parte dos alunos para respondê-las. Após a resposta de cada pré ou pós-teste é feita uma estimativa da habilidade do aluno, baseada em todas as respostas, inclusive a última, que ele obteve nos testes já apresentados. Para esta estimativa é utilizado o método EAP.

Para avaliar as respostas às questões é utilizado o ML3P da TRI. Mais precisamente, este modelo é utilizado quando o aluno acerta a questão, retornando qual é a probabilidade que ele tem, dada sua habilidade (obtida pelo método EAP), de acertar a questão. Deve-se ressaltar que quanto maior for a habilidade do aluno, maior será a probabilidade obtida. Quando o aluno erra a questão, é atribuída uma pequena probabilidade dele conhecer o conceito ao qual ela se refere, representando o fator *slip* (falta de atenção, deslize), e uma alta probabilidade dele não conhecer o conceito que foi ou que será apresentado.

As probabilidades obtidas pelos procedimentos do parágrafo anterior, expressos na Tabela 1, são inseridas como evidência virtual na Rede Bayesiana que compõe o modelo do aluno. A propagação desta evidência pela rede é realizada através do algoritmo de Árvore de Junção. Após a propagação, a rede é capaz de fornecer as estimativas (probabilidades) que o aluno tem de conhecer cada conceito. A Figura 1a resume o mecanismo de ajuste do MA quando os testes são respondidos corretamente.

Tabela 1 - Determinação das probabilidades a serem inseridas como evidência na RB. R representa se o aluno acertou (1) ou errou (0) a questão e s e n representam, respectivamente, se ele conhece ou não o conceito envolvido. As probabilidades para cada estado de R não precisam somar 100%. A probabilidade de acerto ao acaso é o inverso do número de itens da questão.

Questão de pré ou pós-teste	
Acerto	Erro
$P(R = 1 s) = \text{prob. fornecida pelo ML3P}$	$P(R = 0 s) = 15\% (\text{slip})$
$P(R = 1 n) = \text{prob. de acerto ao acaso}$	$P(R = 0 n) = 80\%$

3.3 – Modelo de Adaptação

Para fornecer navegação e conteúdo adaptados às características (conhecimento, neste caso) do aluno, o sistema faz uso da combinação das técnicas de página variante e orientação direta. Esta combinação guia os alunos entre os conceitos e questões existentes e determina quais dos níveis de dificuldade são apresentados para cada um destes conceitos. Este é o mecanismo geral utilizado pelo sistema para prover adaptação. Os próximos parágrafos explicam, em detalhes, a estratégia pedagógica utilizada pelo sistema para a determinação do plano de ensino (sequência de conteúdos e questões apresentada) dos alunos.

A navegação pelo sistema é feita através de *links* chamados “Próximo” ou “Continuar”. Ao acessá-los, o aluno é direcionado para o próximo conteúdo ou questão a ser apresentado. Em geral, para cada conceito, o aluno segue os seguintes passos: primeiro é apresentada a questão de pré-teste, logo após, é visualizado um nível de representação e, por último, é apresentada a questão de pós-teste. Esta sequência pode sofrer alterações (apresentadas adiante) devido ao desempenho do aluno nos testes.

A adaptação do conteúdo é feita através das probabilidades que o aluno tem de conhecer cada conceito, fornecidas pelo seu modelo do aluno. Estas probabilidades são utilizadas para gerar adaptação da seguinte forma:

- Após acerto ou erro do pré-teste – neste caso, a probabilidade é utilizada para determinar qual será o conteúdo mais apropriado a ser apresentado ao aluno. A Figura 1b ilustra este processo;
- Após erro do pós-teste – em que o aluno já visualizou um conteúdo referente ao conceito, porém, como ele errou o teste, é apresentado outro conteúdo envolvendo o mesmo conceito, determinado pela probabilidade. O novo conteúdo é uma atividade de reforço, que visa fazer com que o aluno assimile o conceito. A Figura 1b ilustra este processo;
- Após acerto do pós-teste – em que a probabilidade determina se o aluno está apto a visualizar os elementos adicionais existentes em algum conteúdo de nível superior ao conteúdo que foi apresentado. Estes elementos são chamados de conteúdo simplificado, pois representam apenas uma parte do conteúdo superior. A Tabela 2 apresenta este processo.

Duas restrições são impostas ao mecanismo de adaptação apresentado: quando o aluno erra o pré-teste não pode ser apresentado a ele o conteúdo de nível avançado do conceito envolvido e o conteúdo apresentado após o erro do pós-teste deve ser de nível inferior ou igual ao do conteúdo apresentado antes do erro.

Caso o aluno acerte o pós-teste e não seja determinada a visualização de um conteúdo simplificado, o aluno avança para a questão de pré-teste do novo conceito que será apresentado. Caso o aluno erre o pós-teste, após a apresentação do novo conteúdo referente ao mesmo conceito, é aplicado outro pós-teste, chamado de 2º pós-teste, que tem por objetivo avaliar se o aluno assimilou o conceito. Após respondê-lo, o aluno, mesmo em caso de erro, avança para o novo conceito a ser ministrado, sendo, então, apresentada a sua questão de pré-teste. A resposta deste 2º pós-teste também é utilizada para ajustar o MA.

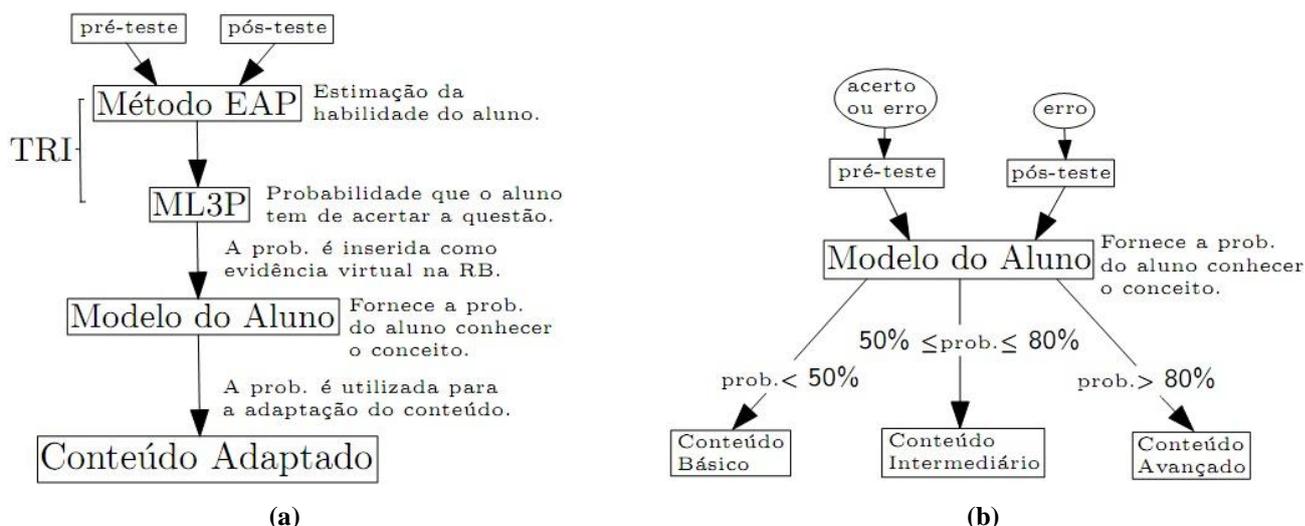


Figura 1 – (a) Mecanismo de ajuste do MA quando os testes são respondidos corretamente. (b) Mecanismo geral para a adaptação do conteúdo.

3.4 – Comportamento do Modelo do Aluno

Em geral, o mecanismo de ajuste do MA vai ao encontro das regras estabelecidas na estratégia pedagógica, diminuindo, em caso de erro nos testes, as habilidades dos alunos e as estimativas que eles têm de conhecer os conceitos, apresentando conteúdos com níveis de dificuldade inferiores (permitindo o acesso a conteúdos expressos de forma mais didática e com mais exemplos). De modo inverso, quando os alunos acertam as questões, ocorre uma melhoria das suas habilidades e estimativas de conhecimento dos conceitos, permitindo o acesso aos conteúdos mais abrangentes e aos conteúdos simplificados.

4 Aplicação Experimental

Para avaliar o sistema proposto foi realizado um experimento, cujo principal objetivo era avaliar a influência dos mecanismos de adaptação nos resultados obtidos. A meta que se desejava alcançar era a melhoria nos níveis de aprendizado dos alunos.

O sistema foi aplicado a duas turmas da disciplina de Banco de Dados do Instituto de Informática da Universidade Federal de Goiás. Para isto, foi criado um mini-curso que envolve os principais conceitos do Modelo de Entidade-Relacionamento (MER).

Foram selecionados 10 conceitos, para os quais foram criados os níveis de representação e os testes, conforme já apresentado. Os conteúdos criados não são extensos, para não sobrecarregar os alunos com excesso de informações. Os testes, em geral, possuíam quatro itens cada. A partir destes conceitos e das suas principais relações também foi criada uma RB (Figura 2a).

Tabela 2 – Mecanismo para apresentação do conteúdo simplificado após o acerto do pós-teste.

Conteúdo anterior ao pós-teste	Prob. do conceito após o pós-teste	Conteúdo simplificado
Nível Básico	$50\% \leq \text{prob.} \leq 80\%$	Nível Intermediário
Nível Básico	$\text{prob.} > 80\%$	Nível Avançado
Nível Intermediário	$\text{prob.} > 80\%$	Nível Avançado

Os parâmetros das questões, referentes ao ML3P, não foram calibrados, devido à falta de turmas disponíveis para a aplicação das questões. Por isto, o parâmetro a recebeu o valor fixo 1 para todas as questões. Para o parâmetro b , como os pré-testes são mais fáceis, foi definido para eles o valor 0,6 e o valor 1 para os pós-testes e 2º pós-testes (foi considerado que eles possuem dificuldades semelhantes). A probabilidade c de cada questão foi representada pelo inverso do número de itens que ela possui.

Para que um estudo comparativo fosse realizado, foi criado um sistema desprovido de mecanismos de adaptação, que foi chamado de sistema tradicional. Neste, a metodologia “um curso para todos” é utilizada. Para uma fácil distinção entre os sistemas, o sistema proposto neste artigo, provido de adaptação, foi chamado de sistema adaptativo.

No sistema tradicional, não são aplicadas as questões de pré-teste e sempre é apresentado ao aluno o conteúdo de nível intermediário de cada conceito. Após a visualização do conteúdo é apresentada a questão de pós-teste do conceito envolvido. Caso o aluno a acerte, ele avança para o próximo conteúdo a ser ministrado. Caso ele a erre, é dada a opção dele avançar para o próximo conceito ou de rever o conteúdo apresentado antes da questão (reforço). Se ele optar por rever o conteúdo, logo após a visualização deste, é apresentada a questão de 2º pós-teste. Após respondê-la, o aluno avança para o próximo conceito. As questões de pós-teste e de 2º pós-teste são as mesmas utilizadas pelo sistema adaptativo.

Em cada turma participante, os alunos foram divididos entre os dois sistemas. O grupo que fez uso do sistema adaptativo foi chamado de grupo experimental, enquanto que o grupo que fez uso do sistema tradicional foi chamado de grupo de controle. Por se tratarem de sistemas voltados para a *Web*, o acesso a eles era feito através de um navegador de Internet qualquer.

Os sistemas utilizados foram implementados na linguagem Java 5. Para o uso da Rede Bayesiana, foi agregado ao sistema adaptativo a *framework* UnBBayes [14], na qual foram feitas adaptações. Para armazenar os dados referentes aos sistemas e alunos foi utilizado o banco de dados PostgreSQL 9. O servidor de aplicações utilizado para gerenciar os sistemas foi o Apache Tomcat 6. Os sistemas e o banco de dados foram hospedados em um computador *desktop* comum, que possuía um processador Intel Core 2 Duo de 2,8GHz e 4GB de memória RAM. O sistema operacional utilizado neste *desktop* era o openSUSE (linux).

5 Resultados

O objetivo que se desejava alcançar com o experimento era a melhoria nos níveis de aprendizado por parte dos alunos que fizeram uso do sistema adaptativo. A comparação entre os resultados obtidos pelos sistemas nos pós-testes foi utilizada para medir se este objetivo foi alcançado. A nota de cada aluno foi composta pelo número de acertos que ele obteve nestes testes. Deste modo, como existiam 10 pós-testes, a nota do aluno poderia variar de 0 e 10. A Tabela 3 apresenta alguns resultados.

Tabela 3 - Estatística descritiva do desempenho e do tempo médio gasto para a realização do curso.

Grupo	Nº de Alunos	Nota Média	Desvio Padrão	Tempo Médio (h)
Experimental	25	5,84	1,43	01:17:53
Controle	25	5,04	1,74	01:14:39

Em termos percentuais, o grupo experimental obteve, em média, um desempenho 15,87% superior ao obtido pelo grupo de controle. A Tabela 4 apresenta um resumo das respostas obtidas nas questões de pós-teste. Também foi realizado um teste estatístico para comparar o desempenho entre os grupos. Para isto, foi utilizado o teste *t-student* para amostras independentes, em que a hipótese nula (H_0) considerava que os grupos possuíam médias iguais e a hipótese alternativa (H_a) admitia que a média do grupo experimental era superior à do grupo de controle. A H_0 foi rejeitada ($p < 0,042$), evidenciando que houve ganho significativo na retenção de conhecimento no grupo que fez uso do sistema adaptativo.

Tabela 4 – Número de acertos e erros obtidos pelos grupos nas questões de pós-teste.

Grupo	Acerto ou Erro	Nº Respostas
Experimental	Acerto	146
Experimental	Erro	104
Controle	Acerto	126
Controle	Erro	124

Tabela 5 – Número de acertos e erros obtidos pelos grupos nas questões de 2º pós-teste.

Grupo	Acerto ou Erro	Nº Respostas
Experimental	Acerto	71
Experimental	Erro	33
Controle	Acerto	57
Controle	Erro	37

As respostas obtidas pelos grupos nas questões de 2º pós-teste foram utilizadas para avaliar seus desempenhos nas atividades de reforço. Enquanto o grupo de controle acertou 60,6% das questões de 2º pós-teste que foram apresentadas, o grupo experimental acertou 68,2% dos 2º pós-testes, o que evidencia que as atividades de reforço fornecidas pelo sistema adaptativo possibilitaram um melhor desempenho. A Tabela 5 mostra um resumo dos resultados obtidos nestes testes.

As Tabelas 6, 7 e 8 apresentam os níveis de representação determinados pelos mecanismos de adaptação do sistema adaptativo. A Tabela 6 indica que apenas 20,4% dos conteúdos apresentados após os pré-testes foram de nível avançado, o que é comum nos processos de aprendizagem, em que muitas vezes o aluno não está apto a visualizar diretamente o conteúdo mais complexo. A Tabela 7 indica que 45 conteúdos simplificados foram apresentados, o que representa que elementos adicionais foram visualizados em 38,8% dos casos em que os pós-testes foram acertados (para este cálculo foram excluídos os casos em que o conteúdo avançado foi visto antes dos testes; nestas situações, não existe conteúdo simplificado a ser visto). A Tabela 8 indica que em 84,6% das atividades de reforço foi apresentado o conteúdo expresso de forma mais simples e didática.

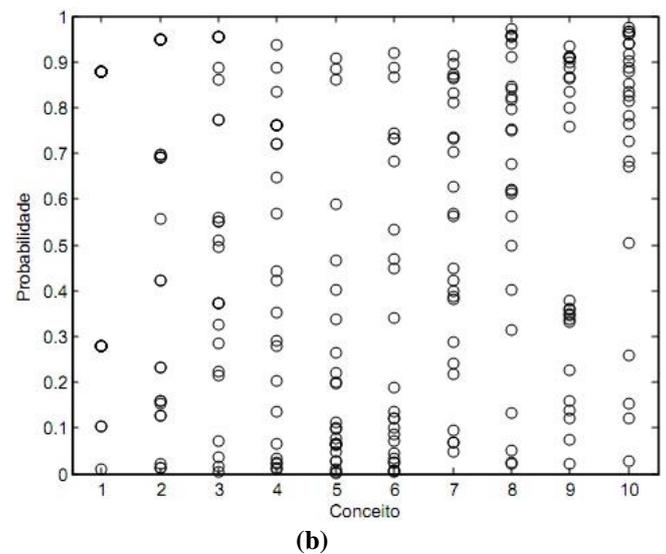
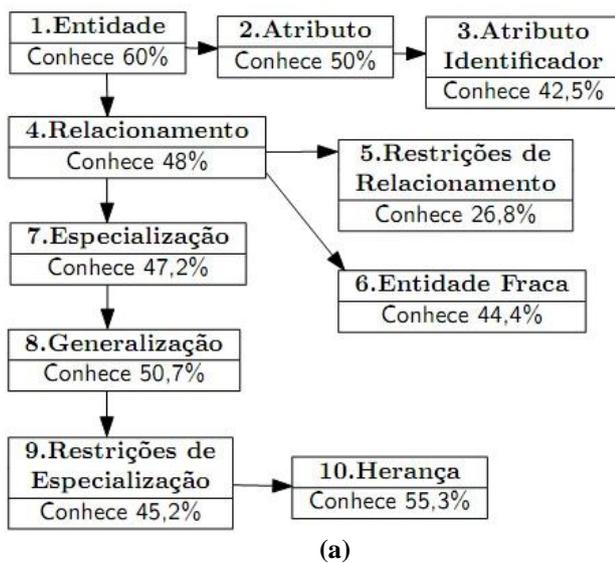


Figura 2 – (a) Estrutura da RB e as probabilidades iniciais que os alunos têm de conhecer os conceitos (os estados “não conhece” não foram representados). Em (b) é apresentada a distribuição das probabilidades de conhecimento ao final de cada conceito calculada pela RB para os alunos.

Da Figura 2b, observa-se que o modelo do aluno, já a partir do 2º conceito, gerou probabilidades de conhecimento dos conceitos muito diferenciadas para os alunos. Isto já era esperado, pois a diversidade dos alunos é um aspecto central em *e-learning*. Como estas probabilidades são utilizadas para prover adaptação, tem-se que conteúdos diferenciados (adaptados) foram apresentados aos alunos. A distribuição dos conteúdos apresentada nas Tabelas 6, 7 e 8 reforça ainda mais este fato.

Os pré-testes foram respondidos incorretamente em 22,4% dos casos, eles contribuíram para que as estimativas diferenciadas da Figura 2b fossem obtidas. Outro aspecto que contribuiu para esta diversidade foi a estrutura da RB criada (Figura 2a), em que um conceito recebe influência de outros conceitos além dos que estão diretamente ligados a ele. Por exemplo, o conceito 3 recebe influência direta do conceito 2 e indireta do conceito 1. Assim, as respostas obtidas nos testes do conceito 1 também irão influenciar nas estimativas que serão geradas para o conceito 3.

Em relação ao desempenho computacional, apesar dos sistemas estarem hospedados em um *desktop* comum, eles exigiram, em média, menos de 8% da sua capacidade de processamento, o que mostra a viabilidade em tempo real dos algoritmos utilizados.

Tabela 6 – Conteúdos apresentados após os pré-testes.

Nível de Dificuldade	Nº Conteúdos
Básico	92
Intermediário	107
Avançado	51

Tabela 7 – Conteúdos simplificados apresentados após os acertos dos pós-testes.

Conteúdo Simplificado	Nº Conteúdos
Intermediário	10
Avançado	35

Tabela 8 – Conteúdos apresentados após os erros dos pós-testes.

Nível de Dificuldade	Nº Conteúdos
Básico	88
Intermediário	16

6 Conclusão

Em *e-learning*, a diversidade de características dos alunos é um importante aspecto, o que torna desejável que o conteúdo fornecido pelos sistemas se adeque às características individuais dos alunos. Diante disto, este artigo propôs um Sistema Hipermídia Adaptativo Educacional que tem por objetivo prover cursos com conteúdo personalizado aos alunos através do ambiente *Web*. Sua principal característica é possuir um modelo do aluno capaz de lidar com incertezas. Este modelo foi representado por uma Rede Bayesiana, que fornece as estimativas que os alunos possuem de conhecer os conceitos presentes no domínio abordado pelo curso. Estas estimativas são utilizadas para prover a adaptação do conteúdo a ser apresentado. O ajuste do modelo do aluno foi feito através das respostas obtidas em testes. Para avaliar o desempenho dos alunos nestes testes, foi utilizado o modelo de 3 parâmetros da Teoria da Resposta ao Item.

Os resultados obtidos através da aplicação deste sistema provido de adaptação foram bastante positivos e demonstraram o potencial das técnicas e da metodologia utilizadas. O sistema realmente forneceu planos de ensino personalizados aos alunos. Espera-se, como consequência do uso desta aplicação, que os alunos sintam-se mais motivados em aprender.

Em trabalhos futuros, pretende-se incorporar mais características ao modelo do aluno, tornando-o mais robusto e próximo do perfil dos alunos. Dentre as características de interesse está o estilo de aprendizagem. Pretende-se também, quando um número maior de amostras for coletado, realizar a calibração dos parâmetros das questões, permitindo que o modelo de 3 parâmetros seja utilizado com um potencial maior.

7 Referências

- [1] Leung, E.W.C. Li, Q., An Experimental Study of a Personalized Learning Environment Through Open-Source Software Tools, **IEEE Transactions on Education**, 50 (2007), 331 – 337.
- [2] Weber, G. Kuhl, H.-C. Weibelzahl, S., Developing adaptive internet based courses with the authoring system NetCoach, **Proceedings of Third workshop on Adaptive Hypertext and Hypermedia**, (2001), 35 – 48.
- [3] Weber, G. Brusilovsky, P., ELM-ART: An adaptive versatile system for Web-based instruction, **International Journal of Artificial Intelligence in Education**, 12 (2001), 351 – 384.
- [4] Brusilovsky, P. Millán, E., User models for adaptive hypermedia and adaptive educational systems, **The Adaptive Web. Lecture Notes in Computer Science**, 4321 (2007), 3 – 53.
- [5] Henze, N. Nejd, W., Student modeling for KBS Hyperbook system using Bayesian networks, **University of Hannover**, (1999).
- [6] Brusilovsky, P., Adaptive hypermedia, **User Modeling and User-Adapted Interaction**, 11 (2001), 87 – 110.
- [7] Koch, N. Wirsing, M., The munich reference model for adaptive hypermedia applications, **Proceedings of the Second International Conference on Adaptive Hypermedia and Web-Based Systems**, (2002), 213 – 222.
- [8] Brusilovsky, P., Methods and techniques of adaptive hypermedia, **User Modeling and User-Adapted Interaction**, 6 (1996), 87– 129.
- [9] Jensen, F. Nielsen, T., Bayesian networks and decision graphs, 2º Edição, **Springer**, (2007).
- [10] Jensen, F. V. Lauritzen, S. L. Olesen, K. G., Bayesian updating in causal probabilistic networks by local computations, **Computational Statistics Quarterly**, 4 (1990), 269 – 282.
- [11] Ding, Z., Bayesowl: a probabilistic framework for uncertainty in semantic web, **University of Maryland**, (2005).
- [12] Andrade, D. F. Tavares, H. R. Valle, R. C., Teoria de Resposta ao Item: conceitos e aplicações, **Associação Brasileira de Estatística**, (2000).
- [13] Mislevy, R. J., Bayes modal estimation in item response models, **Psychometrika**, 51 (1986), 177 – 195.
- [14] UnBBayes, Disponível em <<http://unbbayes.sourceforge.net/>>, Acesso em maio de 2011.