

Abordagem Hiperídia Educacional Adaptativa para a Personalização do Processo de Ensino Através da *Web*

Alexandre M. F. Bueno, Andreia G. S. Brito, Leonardo C. Brito

Escola de Engenharia Elétrica e de Computação – Universidade Federal de Goiás (UFG)
Av. Universitária, n. 1488 - Quadra 86 - Bloco A - 3º piso 74605-010 - Setor Leste Universitário - Goiânia - Goiás - Brasil

alexmbf@gmail.com, andreia.garcia.brito@gmail.com, brito@eeec.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 evaluation of the student's ability tests. The results showed that the system provided a significant improvement in knowledge retention by the students.*

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 Hiperídia 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 na avaliação dos testes de habilidade dos alunos. Os resultados obtidos mostraram que o sistema proporcionou uma melhoria significativa na retenção de conhecimento por parte dos alunos.*

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* [Leung 2007]. Nas últimas décadas, várias pesquisas têm dado ênfase na criação de técnicas que provêem adaptação (personalização) em sistemas de *e-learning*. Muitas destas técnicas são utilizadas em Sistemas Hipermedia Adaptativos e em ferramentas para autoria destes sistemas, como o NetCoach [Weber 2001a] e o ELM-ART [Weber 2001b].

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 [Brusilovsky 2007], 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 Hipermedia Adaptativos que fazem uso de modelos de usuário que representam incertezas (como em [Henze 1999]) 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 Hipermedia Adaptativos (SHAs)

Os SHAs são uma alternativa ao tradicional “formato único” utilizado pelos Sistemas Hipermedia. Nestes, sempre é fornecido o mesmo conteúdo aos usuários, que precisam se adaptar ao sistema [Brusilovsky 2001]. O objetivo dos SHAs é fornecer ao usuário um ambiente hipermedia dinâmico e adequado às suas necessidades, preferências e características individuais. Um documento hipermedia é formado pela junção entre hipertexto e diferentes tipos de mídias de apresentação, como vídeo, som e imagem; os quais devem ser inseridos em um contexto dinâmico e motivador para o propósito pedagógico.

A hipermedia adaptativa teve um rápido crescimento a partir de 1996, devido à forte expansão da *Web* [Brusilovsky 2001]. Os SHAs para fins educacionais (com conteúdo instrucional) são chamados de Sistemas Hipermedia 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 [Koch 2002]. 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 a utilizá-lo. O seu efetivo conhecimento é muito importante e facilitará a obtenção de resultados positivos;
- Modelo de Usuário (MU): é responsável por armazenar as características do usuário que possam influenciar nas decisões de adaptação tomadas pelo SHA;
- Modelo de Adaptação: contém regras e técnicas que permitem a adaptação do conteúdo, navegação e apresentação. Em SHAEs, este modelo também é chamado de modelo de ensino e também contempla as estratégias pedagógicas que serão utilizadas no processo de aprendizagem.

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 [Brusilovsky 2007]. 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 [Brusilovsky 2001] e [Brusilovsky 1996]. 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. Esta técnica não oferece liberdade de escolha aos usuários, mas é muito utilizada em SHAs, 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 [Jensen 2007] 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.

O processo de inferência em RBs tem como base a Regra de Bayes (1). 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.

$$P(H|e) = \frac{P(e|H)P(H)}{P(e)} \quad (1)$$

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 [Andrade 2000]. 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 [Andrade 2000].

No ML3P, a probabilidade de um indivíduo com habilidade θ responder corretamente ao item i é dada por (2).

$$P_i(\theta) = P(U_i = 1|\theta) = c_i + \frac{1 - c_i}{1 + e^{-Da_i(\theta - b_i)}} \quad (2)$$

Em (2), 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 TRI requer um pressuposto chamado de independência local; ele assume que, dada uma habilidade, as respostas aos diferentes itens apresentados são independentes.

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 como mais uma ferramenta, visando promover maior tempo de estudo e qualidade na aprendizagem. A seguir, são apresentados os principais componentes deste sistema.

O Modelo de Domínio 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, no qual o conceito é exposto de forma bem acessível e didática, ao custo de alguma perda na exatidão; Intermediário, no qual o conceito é exposto de forma abrangente e com a introdução de linguagem técnica; e Avançado, no qual 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.

O Modelo de Aluno (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 conteúdo envolvido. Por fazer uso de uma técnica capaz de lidar com incertezas, o modelo é capaz de responder a questões como: “Se 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?”

Para cada conceito apresentado ao aluno, o sistema faz uso de questões de pré-teste e pós-teste, que representam questões de múltipla escolha, cujo objetivo é quantificar a habilidade 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 estimacão da habilidade do aluno, baseada em todas as respostas, inclusive a última, que ele obteve nos testes já apresentados. Para esta estimacão é utilizado o método EAP (método da TRI).

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. 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 por estes procedimentos, expressas 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
$P(R = 1 s) = \text{prob. fornecida pelo ML3P}$	$P(R = 0 s) = 15\% (\text{slip})$
$P(R = 1 n) = \text{prob. de acerto ao acaso}$	$P(R = 0 n) = 80\%$

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 levando-se em consideração as 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.

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. Deste modo, as respostas dadas aos testes ajustam as estimativas que o sistema possui do aluno, permitindo que no decorrer do uso do sistema seja obtido um plano de ensino personalizado e dinâmico, atualizado a cada interação com o aluno.

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).

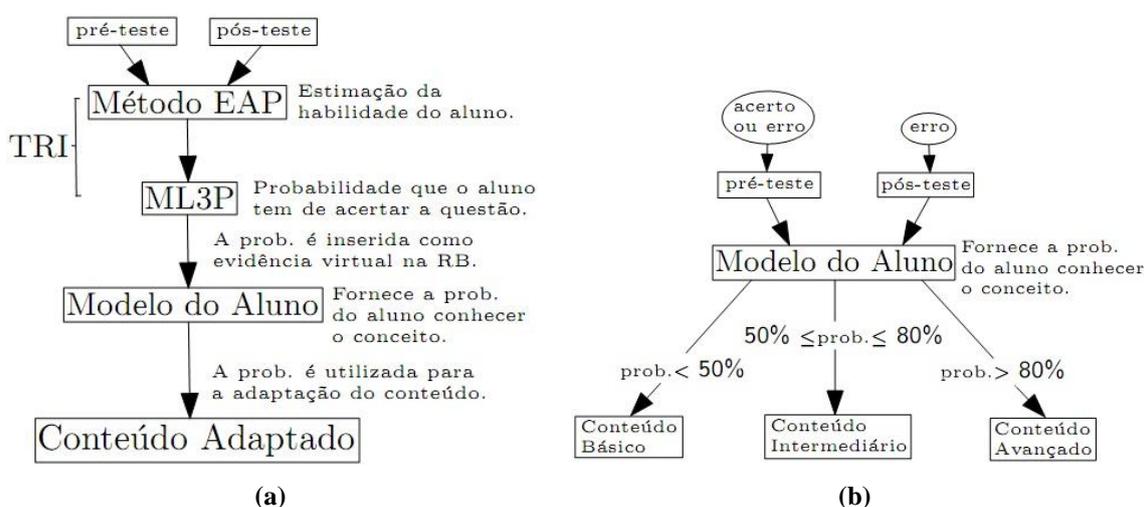


Figura 1. (a) Mecanismo de ajuste do MA quando os testes são respondidos corretamente. (b) Mecanismo geral para a adaptação do conteúdo.

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	$50\% \leq prob. \leq 80\%$	Nível Intermediário
Nível Básico	$prob. > 80\%$	Nível Avançado
Nível Intermediário	$prob. > 80\%$	Nível Avançado

Os parâmetros das questões, referentes ao ML3P, não foram calibrados (estimados), 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 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 teste foi representada pelo inverso do número de itens que ele 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 de 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 [UnBBayes 2011], 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 os resultados globais.

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
Experimental	25	5,84	1,43	1h 26min 42s
Controle	25	5,04	1,74	1h 23min 08s

Em termos percentuais, o grupo experimental obteve, em média, um desempenho 15,87% superior ao obtido pelo grupo de controle. 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. Com $\alpha = 5\%$, a H_0 foi rejeitada

($p < 4,2\%$), evidenciando que houve ganho significativo na retenção de conhecimento no grupo que fez uso do sistema adaptativo. 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% dos 2º pós-testes que foram apresentadas, o grupo experimental acertou 68,2% destes testes, o que evidencia que as atividades de reforço fornecidas pelo sistema adaptativo possibilitaram um melhor desempenho.

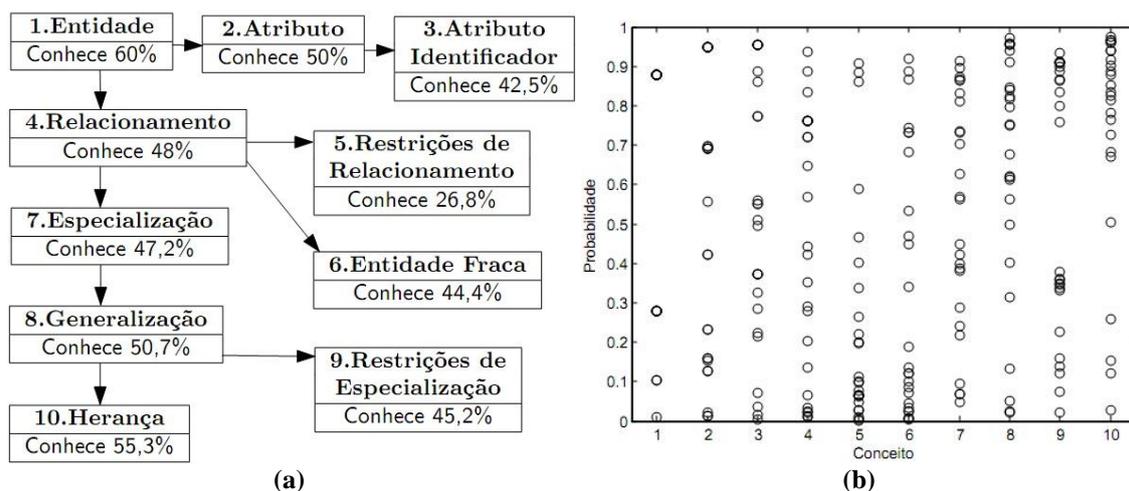


Figura 2. (a) Estrutura da RB e as probabilidades iniciais (após primeira compilação da rede) que os alunos têm de conhecer os conceitos. Os estados “não conhece” não foram representados. Em (b) é apresentada a distribuição das probabilidades de conhecimento ao final de cada conceito (após o pós-teste ou 2º pós-teste, caso exista) 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. Os pré-testes foram respondidos incorretamente em 22,4% dos casos, tendo eles contribuído 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.

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 Hiperídia Adaptativo Educacional que tem por objetivo prover cursos com conteúdo personalizado aos alunos por meio da *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 com essa ferramenta, uma aprendizagem significativa devido ao contexto diferenciado, motivando os alunos a aprender.

Em trabalhos futuros, pretende-se incorporar mais características ao modelo do aluno, tornando-o mais robusto e próximo dos perfis dos alunos. Entre 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.

Referências

- Andrade, D. F. Tavares, H. R. Valle, R. C., Teoria de Resposta ao Item: conceitos e aplicações, Associação Brasileira de Estatística, (2000).
- Brusilovsky, P., Methods and techniques of adaptive hypermedia, *User Modeling and User-Adapted Interaction*, 6 (1996), 87– 129.
- Brusilovsky, P., Adaptive hypermedia, *User Modeling and User-Adapted Interaction*, 11 (2001), 87 – 110.
- Henze, N. Nejd, W., Student modeling for KBS Hyperbook system using Bayesian networks, University of Hannover, (1999).
- Jensen, F. Nielsen, T., Bayesian networks and decision graphs, 2º Edição, Springer, (2007).
- 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.
- 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.
- Mislevy, R. J., Bayes modal estimation in item response models, *Psychometrika*, 51 (1986), 177 – 195.
- UnBBayes, Disponível em <<http://unbbayes.sourceforge.net/>>, Acesso em maio de 2011.
- 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*, (2001a), 35 – 48.
- Weber, G. Brusilovsky, P., ELM-ART: An adaptive versatile system for Web-based instruction, *International Journal of Artificial Intelligence in Education*, 12 (2001b), 351 – 384.