

## AGENTE DE RECOMENDAÇÕES DE ESTUDO E DE ORGANIZAÇÃO DE ATIVIDADES DIDÁTICAS

Ubiratan Campos<sup>1</sup>; Gislaíne Cristina Micheloti Rosales<sup>2</sup>; Wellington Camargo<sup>3</sup>; Fernando Vieira Duarte<sup>4</sup>; Regina B. Araújo<sup>5</sup>

### **Grupo 4.5. Tecnologias na EaD: desafios, estratégias e dificuldades**

#### **RESUMO:**

*Este trabalho propõe um Agente de Recomendações (AR) cuja finalidade é guiar o estudante de educação a distância durante suas atividades no ambiente virtual. A partir de um Framework de Coleta de Dados baseado em rede de sensores que monitoram os ambientes digital (sensores lógicos) e físico (sensores físicos) que cerca o usuário, coletamos informação semântica dinâmica em tempo de execução. Nosso AR faz uso de redes Bayesianas para realizar inferências e apresenta recomendações, tais como: agenda de estudos; sugestões de conteúdo a serem estudados e prioridade; tempo de dedicação a cada disciplina, unidade de aprendizagem, material e atividade; exercícios a serem realizados e prazos; lembrete de eventos. O AR apresentado encontra-se em fase de implementação e testes. O espaço de análise que se pretende investigar para avaliação do AR proposto envolve estudantes de educação a distância de cursos oferecidos pela Universidade Aberta do Brasil.*

**Palavras-chave:** agente de recomendações; lógica probabilística; aprendizagem; recomendação preventiva.

#### **ABSTRACT:**

##### **AGENT OF STUDY RECOMMENDATIONS AND ORGANIZATION OF TEACHING ACTIVITIES**

*This paper proposes a Recommendations Agent (RA) whose purpose is to guide distance education students while performing activities in virtual environment. From a Data Collection Framework based on sensors network that monitor the digital environment (sensors logical) and physical environment (physical sensors) surrounding the user, we collect dynamic semantics information at runtime. Our RA use Bayesian networks to inferences and presents recommendations such as: studies schedule; suggestions of content to be studied and priority, time dedicated to each discipline, learning unit, material and activity, exercises to be performed and deadlines; event reminder. The presented RA is being implemented and tested. The scope of analysis that intends to investigate involves students of distance education courses offered by Open University of Brazil.*

**Keywords:** recommendation agent; probabilistic logic; e-learning; preventive recommendation.

<sup>1</sup> Estudante na Universidade Federal de São Carlos (UFSCar) - udcampos@gmail.com

<sup>2</sup> Professora e pesquisadora no Instituto Federal de Educação, Ciência e Tecnologia de São Paulo - gimicheloti@gmail.com

<sup>3</sup> Estudante a Universidade Federal de São Carlos (UFSCar) - well.talk@gmail.com

<sup>4</sup> Estudante e Pesquisador na Universidade Federal de São Carlos (UFSCar) - duarte@gmail.com.br

<sup>5</sup> Professora e pesquisadora na Universidade Federal de São Carlos (UFSCar) - regina@dc.ufscar.br

## 1. Introdução

O uso de tecnologias da informação em ambientes virtuais de ensino-aprendizagem tem melhorado os processos educacionais [23]. Desde a popularização da Educação a Distância (EaD) baseada em Internet, pesquisadores buscam meios de aprimorar o processo de ensino-aprendizagem e melhorar a experiência que os participantes deste processo têm com o ambiente virtual. Neste sentido, diversas soluções computacionais têm sido propostas, incluindo: avaliação da aprendizagem [25, 20, 34, 9]; supervisão do processo de ensino-aprendizagem [21, 11, 12, 8] e sistemas de recomendação de conteúdo [32, 30, 17, 11, 31, 16, 35]. Convencionalmente, aplicações que apoiam a supervisão do processo e aplicações para avaliação possuem recursos direcionados aos professores ou tutores da disciplina; enquanto que os sistemas de recomendação focam no apoio aos estudantes a fim de melhorar suas experiências em aprendizagem eletrônica.

Portanto, criar interfaces mais agradáveis que proporcionem melhor fluxo de informação é uma necessidade cada vez mais presente em EaD, porém apenas disponibilizar a informação não é suficiente, é necessário criar estratégias de estudo que respeitem as características e necessidades individuais, tais como conhecimento prévio do estudante, estilo de aprendizagem, habilidades cognitivas, tempo disponível para dedicação aos estudos, entre outras. Segundo o último censo divulgado em 2010 pela Associação Brasileira de Educação a Distância (ABED)<sup>6</sup> o índice de evasão escolar nos cursos de graduação das instituições públicas brasileiras é de 17% [16]. Os motivos da evasão também são apontados na pesquisa, dentre eles 65,2% estão relacionados a problemas financeiros, em 39,1% dos casos os alunos alegam falta de tempo para o estudo, os restantes 47,8% dos alunos alegam que não se adaptaram ao método de ensino. A fim de minimizar este último índice, apresentamos um Agente de Recomendação e Organização de Estudos (AR) que possui três objetivos principais. O primeiro objetivo é facilitar a organização do tempo de estudo disponível do aluno de acordo com as atividades a serem realizadas. O segundo objetivo consiste em indicar estratégias didáticas de acordo com o comportamento dos estudantes durante suas atividades de aprendizagem considerando a proposta pedagógica do curso e os objetivos e metas traçados pelo professor durante o planejamento da disciplina. O último objetivo é prover aos estudantes novas maneiras de monitorar, em tempo real, seu desempenho acadêmico em relação aos demais alunos. Neste último caso, particularmente, nosso AR permite aos estudantes obterem uma visão geral de suas interações e seu desempenho acadêmico comparado aos demais, assim como a relação de postagens em interações individuais ou coletivas.

As recomendações realizadas por nosso AR são adaptativas, isto é, se modificam de acordo com as interações realizadas pelo aluno no ambiente, tais como a realização de uma atividade avaliativa, acesso aos materiais de estudo e alteração do perfil pessoal. Desta forma, baseado no contexto do usuário o AR reavalia as prioridades e quando necessário altera a estratégia de estudo recomendada, propondo novas ações e indicando o tempo necessário para executá-las. As recomendações realizadas pelo nosso AR são apresentadas durante todo o desenvolvimento do curso enquanto ele navega pelo SGA. Sendo assim, essas recomendações possuem caráter preventivo, ou seja, o AR norteia as ações do aluno para que consiga priorizar quais são as atividades mais urgentes e também aquelas em que

<sup>6</sup> ABED é uma sociedade científica, sem fins lucrativos, voltada para o desenvolvimento da educação aberta, flexível e a distância.

seu rendimento encontra-se abaixo do esperado, direcionando os recursos disponíveis para realizar essas atividades.

Alguns fatores propostos nesse trabalho são inovadores, dentre eles encontram-se: (i) o AR é independente de plataforma de SGA, ou seja, pode ser utilizado em diversos ambientes de aprendizagem (por exemplo, *Moodle* e *SAKAI*), atuando de forma transparente para o aluno como complemento ao SGA e, (ii) nosso AR pode ser utilizado em qualquer curso ou disciplina independente da área do conhecimento. O primeiro fator apontado deve-se à separação entre o processo de inferência realizado pelo AR e a coleta de contextos, uma vez que essa captura de contextos é realizada por uma rede de sensores físicos e lógicos que monitora o usuário, sendo esta também extensível à plataforma de sistema operacional e independente de SGA. O segundo fator é possível, pois os dados de contexto coletados por sensores a partir do SGA e, portanto, o processo de inferência realizado sobre esses dados consideram informações comuns em aprendizagem eletrônica, tais como notas, acessos às atividades e materiais, frequência, objetivos, entre outros. O especialista do domínio, ou seja, o professor detentor do conhecimento e dos objetivos pode ajustar as variáveis que influenciam no comportamento do AR de acordo com sua proposta pedagógica, permitindo o replanejamento da disciplina durante sua oferta sem comprometer o funcionamento o AR.

Este artigo está organizado da seguinte forma: A seção II apresenta os trabalhos relacionados. A seção III apresenta uma descrição sobre o sistema de recomendação, incluindo a rede probabilística usada para gerar as recomendações. A seção IV apresenta a proposta da agenda do estudante gerada pelo AR, seguida de conclusões e referências bibliográficas.

## 2. Trabalhos Relacionados

Os SGAs herdam da internet características que possibilitam a navegação e a interação de forma dinâmica e não linear. Esta nova abordagem de apresentação de conteúdo educacional, gerou necessidade de novas abordagens para o processo de ensino-aprendizagem. Partindo da tentativa de adaptação do ambiente virtual aos moldes do ambiente real, passando por tentativas de simulação de um ambiente real dentro do ambiente virtual, até abordagens completamente novas baseadas unicamente em ambientes virtuais e suas diversas formas de interação.

A partir do rastreamento das interações de alunos no SGA, ZAIANE (2002) apresenta a proposta de um ambiente adaptável e com um recomendador de fluxo de navegação, que utiliza os perfis de alunos, os históricos de acesso e os padrões de navegação coletivos para recomendar aos alunos quais seriam os melhores caminhos a serem seguidos durante suas interações com o SGA. A escolha dos melhores caminhos de aprendizagem é baseada em técnicas simples de mineração de dados web, mineração de regras de associação, que detectam os caminhos mais acessados e os caminhos acessados por alunos que obtiveram sucesso na aprendizagem. Já TANG & MCCALLA (2003) propõem um ambiente envolvente, que recomenda conteúdo adquirido da Internet além do conteúdo disponibilizado pelo professor. Neste sistema, um rastreador varre a base de dados NEC's CiteSeer com uso de técnicas de mineração de dados Web, em busca de novos artigos científicos relacionados com o assunto abordado em cada unidade de estudo e armazena estes artigos em um repositório. Com a aplicação de técnicas de filtro colaborativo e agrupamento de dados em clusters, o

sistema seleciona os artigos que devem ser recomendados de acordo com as frequências de acesso. KRIŠTOFIČ (2005) também apresenta um sistema de recomendação adaptativo que utiliza técnicas de reconhecimento de padrões para efetuar recomendações aos alunos. Diferentemente das propostas anteriores, a arquitetura do sistema é independente do sistema de hipermídia adaptativo subjacente. A integração com o ambiente de aprendizagem é feita através de interfaces, que permitem a coleta de dados do SGA e indicam qual o assunto abordado na sessão de estudo. Com base na sessão atual e nos padrões de comportamento descobertos, o sistema recomenda uma sequência de conceitos relevantes que o aluno deve estudar, com foco na sequenciação de currículo. O uso de técnicas de mineração de dados para recomendação de links integrada ao sistema AHA! (*Adaptive Hypermedia Architecture*) é descrito em (ROMERO, 2007). O sistema recomenda uma lista com os próximos links a serem visitados por um aluno, a fim de auxiliar o aluno a encontrar o melhor caminho entre os materiais de aprendizagem. A ferramenta de mineração é um *applet* Java que minera os dados de registros de acessos dos alunos, separando-os de acordo com semelhanças de perfil e identifica quais são as sequências de acesso que os alunos fazem ao percorrer os recursos disponíveis no SGA. Toda esta parte de mineração de dados é executada de forma off-line e produz como resultado, um conjunto de arquivos em formato XML (*eXtensible Markup Language*) que são utilizados pelo motor de recomendação do sistema AHA!. O processo de mineração de dados tem interferência direta dos autores de cursos, que seleciona conjuntos de dados a serem minerados e as sequências de acesso de maior interesse através da interface gráfica do sistema. No presente trabalho, as variáveis que influenciam o Agente de Recomendação são ajustadas de acordo com a proposta pedagógica do curso, que indica os objetivos que devem ser atingidos, a relevância de cada objetivo e as atividades que influenciam o cumprimento do objetivo. SCHIAFFINO et al. (2008) apresentam o agente de recomendação eTeacher, um tutor inteligente que recomenda atividades educacionais com base no perfil do aluno e no desempenho do alunos. O perfil do aluno é dado principalmente pelo estilo de aprendizagem do aluno. As dimensões de percepção, de processamento e de compreensão do Modelo de Estilo de Aprendizagem de Felder & Silverman (1988) são utilizadas para classificar o estilo de aprendizagem do aluno. O eTeacher utiliza Redes Bayesianas para inferir automaticamente o estilo de aprendizagem do aluno pela observação de ações do aluno dentro do ambiente de aprendizagem, pela análise dos registros de log relativos aos acessos do aluno e pelo uso de parâmetros de desempenho do aluno. Este recomendador foi utilizado em um curso de Inteligência Artificial usando um sistema de e-learning SAVER para fornecer recomendações aos alunos sobre o tipo de material de leitura, os exercícios feitos, os exames e os lembretes de eventos futuros e dos prazos de tarefas. Neste nosso trabalho também propõem-se a recomendação de conteúdo educacional e sugestões de organização para o aluno adequar as suas necessidades e cumprir os objetivos do curso. GASPARINI et al. (2010) implementam uma personalização do ambiente virtual de aprendizagem AdaptWeb®, que permite a adequação do conteúdo apresentado ao aluno de acordo com o cenário e o contexto em que o aluno está envolvido. Com uso de ontologias, criaram um contexto rico em informações que estende a modelagem tradicional do aluno, que aliado ao estilo de aprendizagem modelado por Felder & Silverman (1988), possibilita que a interface do usuário seja adaptada e personalizada para cada aluno. Neste trabalho, GASPARINI et al. (2010) destacam que a modelagem cultural do aluno é fundamental para personalização de SGA, pois é no contexto cultural que estão inseridas as preferências e o padrão de comportamento do aluno. Esta adaptação é possível através da arquitetura

proposta para o sistema. O AdaptWeb® passa as informações do SGA para o sistema de monitoramento, que detecta eventos de aprendizagem e aciona o serviço de gerenciamento de contexto, que antecipa as próximas recomendações de adaptação encaminhando os cenários possíveis para o motor de adaptação do AdaptWeb®, que personaliza o SGA e sutilmente realiza sugestões ao aluno (por exemplo, link para chat, material de alta ou baixa resolução, material com conhecimento avançado do assunto). O foco do trabalho é promover a personalização do SGA com uso de informações de contexto e efetuar a modelagem de cenários que se alteram de acordo com o contexto. A arquitetura pesada, a infraestrutura necessária e o alto acoplamento com o ambiente de aprendizagem, tornam a solução proposta por GASPARINI et al. (2010) difícil de ser utilizada e transportada para outros SGAs. Em nosso trabalho, propomos a utilização de uma arquitetura mais leve, implementada com padrões de projeto para eliminar o acoplamento da solução com o SGA e a utilização de redes de sensores e agentes inteligentes para aquisição de informações em tempo real.

De forma semelhante e baseados nos conceitos propostos por ZAIANE (2002), TANG & MCCALLA (2003) e KRIŠTOFIČ (2005), o trabalho de KLAŠNJA-MILIĆEVIĆ et al. (2011) apresenta o desenvolvimento de um SGA para ensino de linguagens de programação, que recomenda as sequências de execução de atividades pedagógicas com objetivo de auxiliar os alunos no processo de aprendizagem. O sistema desenvolvido é chamado de Protus, acrônimo de Programming Tutoring System. Através da aplicação do questionário Index of Learning Styles, proposto por Felder & Soloman (1996), obtém-se o estilo de aprendizagem do aluno e, para complementar a modelagem do aluno, utiliza as informações estáticas contidas no perfil do aluno no SGA. O Protus utiliza o algoritmo AprioriAll (Tong & Pi-Lian, 2005) para mineração de dados nos registros de log do servidor do SGA, que descobre os padrões comportamentais de interação e as sequências de acessos aos recursos do SGA, e cria uma lista indexada das sequências de acesso mais frequentes. Com base nas sequências de acessos de alunos que obtiveram resultados satisfatórios em atividades de avaliação de aprendizado e também do estilo de aprendizagem de cada aluno, o sistema Protus apresenta uma lista de recomendações que contempla a forma de apresentação e a sequência dos conteúdos de aprendizagem. A arquitetura geral do sistema Protus está dividida em cinco módulos, sendo quatro suportados por ontologias de respectivo interesse e um módulo monitor da sessão do usuário no SGA. Uma desvantagem destacada na proposta do sistema Protus é a limitação do domínio da área do conhecimento, que dificulta a utilização em outras áreas do conhecimento. Neste nosso trabalho, o objetivo é fazer recomendações que auxiliem o aluno, de forma independente de conteúdo e de SGA, e com foco nos objetivos propostos pelos professores.

### 3. Sistema de Recomendação

O propósito geral dos sistemas de recomendação é pré selecionar informações que o usuário possa estar interessado. No contexto da aprendizagem eletrônica o AR indica ações que podem ser tomadas pelo estudante a fim de auxiliá-lo a melhor desempenhar suas atividades SGA. Nosso AR classifica o aluno de acordo com seu estilo de aprendizagem considerando o modelo proposto por Felder & Silverman [28, 29]. O modelo apresenta 4 dimensões (percepção, processamento, compreensão e retenção) que determinam 16 estilos de aprendizagem possíveis. O AR classifica o estilo de aprendizagem do aluno a fim de

determinar a lista recomendações inicial que é atualizada de acordo com as interações realizadas pelo estudante no SGA. Dados sobre a interação do aluno são utilizados para alterar as variáveis de controle que permitem o processo de inferência do AR. Desta forma, as inferências realizadas objetivam guiar o usuário para que consiga atingir os objetivos propostos pelo educador.

É importante ressaltar que a utilização do AR é facultativa ao aluno, permitindo a ele habilitar ou desabilitar as intervenções do AR a qualquer momento. A interface do AR é simples, objetiva e personalizável. Permitindo ao aluno escolher quais informações lhe são apresentadas. A figura 1 ilustra a interface com a recomendação feita ao estudante durante sua navegação no SGA para lembrá-lo das atividades a serem realizadas.

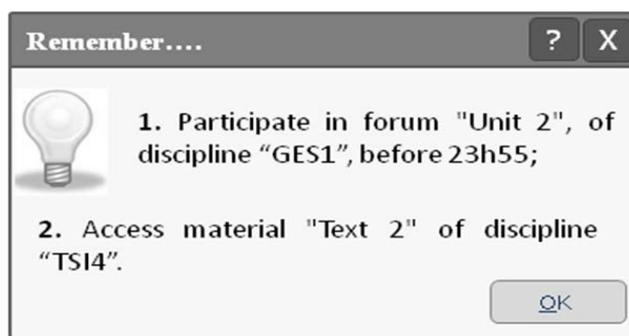


Figura 1. Recomendação feita pelo AR ao estudante enquanto navega no SGA.

### 3.1. Dados utilizados no processo de inferência do AR

Conforme mencionado anteriormente, os dados utilizados no processo de inferência do nosso AR são obtidos a partir de um *Framework* de Coleta de Dados [15] que usa rede de sensores físicos e lógicos para monitoramento das ações e intenções de interação do usuário. Os sensores lógicos são componentes de software que podem ser implementados de duas maneiras distintas: (i) *Javascript* para monitoramento das interações realizadas dentro do navegador, ou (ii) agentes inteligentes para monitoramento das ações realizadas fora do navegador.

O uso desta abordagem possibilita acesso a um rico e relevante conjunto de dados que podem afetar o processo educacional e, portanto, potencializar a ação do AR. O *framework* de coleta possibilita acesso a três tipos de dados: (i) interações do estudante dentro do ambiente virtual, tais como: acesso a um fórum de discussão, incluindo hora do acesso, tempo em que o estudante permaneceu conectado, mensagens postadas, mensagens lidas, tempo necessário para digitar a mensagem, palavras-chave utilizadas, se a mensagem é uma réplica ou novo tópico; caminho de navegação entre materiais e exercícios do curso; ordem de digitação das respostas; quantas vezes um campo *checkbox* foi marcado e desmarcado (o que permite identificar possíveis dúvidas do aluno em questões); cliques realizados; tipos de conteúdos visitados e frequência de visitaçao; (ii) interações do estudante fora do ambiente virtual, tais como as atividades paralelas realizadas enquanto estuda. Essas atividades incluem: ouvindo música, assistindo um vídeo, interagindo a partir de ferramenta de comunicação instantânea, entre outras; e (iii) características da rede e do dispositivo do usuário, tais como: taxa e velocidade de transmissão, largura de banda,

latência, tamanho de tela do dispositivo e sistema operacional utilizado. Além desses dados, o monitoramento do SGA permite acesso às informações sobre o desempenho acadêmico do estudante, como nota e frequência.

O AR apresentado neste artigo utiliza os dados obtidos pelos sensores para refazer as recomendações conforme a ocorrência de eventos gerados a partir das interações do estudante. Não entraremos em detalhes sobre a coleta de dados por não ser o objetivo principal deste artigo.

### **3.2. Rede Probabilística do Agente de Recomendações**

Durante o ciclo de aprendizagem, um aluno realiza diversas ações no SGA, tais como a configuração das preferências pessoais, os resultados da interação com o ambiente (por exemplo, respostas de questionários ou de exercícios, o tempo utilizado para ler um determinado conteúdo, número de cliques do mouse), as interações com o grupo de estudo, as interações com o tutor, as interações com o professor, entre outras. De acordo com [6], na descoberta de informações relevantes sobre ações dos alunos no SGA, há a necessidade de lidar com a informação que é incerta (aquela em que não se tem certeza que seja absolutamente verdadeira) e/ou imprecisa (os valores tratados não estão completamente definidos). Desta perspectiva, as técnicas de raciocínio numericamente aproximadas, tal como as Redes Bayesianas (RB), são adequadas para esta finalidade. A RB é um modelo probabilístico que representa as relações entre os parâmetros incertos de um domínio e fornece um modelo gráfico em que cada nó representa uma variável aleatória e cada arco representa uma relação de influência causal ou correlação probabilística entre as variáveis. Cada nó da RB é condicionalmente independente do resto dos nós (com exceção de seus descendentes) dado o estado de seus pais. Assim, as informações coletadas dos alunos são fontes de evidências que podem ser utilizadas para obter informações relevantes sobre as variáveis aleatórias utilizadas pelo Agente de Recomendação. A partir de pesquisas realizadas com um grupo de alunos de graduação em curso a distância e também entrevistas realizadas com pedagogos que atuam diretamente com EaD, foram identificados e selecionados os fatores potenciais que podem influenciar na aprendizagem dos alunos. Estes fatores foram mapeados em variáveis aleatórias e modelados em RB.

A figura 2 apresenta um recorte do grafo que representa a Rede Bayesiana utilizada pelo nosso AR, onde cada nó da rede representa uma variável envolvida. Para cada um desses nós, é gerada uma tabela de probabilidade condicional (TPC), que determina a probabilidade de cada estado possível do nó dado para cada combinação possível de estados de seus pais. O conjunto das TPCs é utilizado para especificar a distribuição de probabilidade conjunta representada pela RB [12]. Desta forma, a inferência do AR é dada pelo cálculo do produto da distribuição de probabilidade de cada nó dados seus pais.

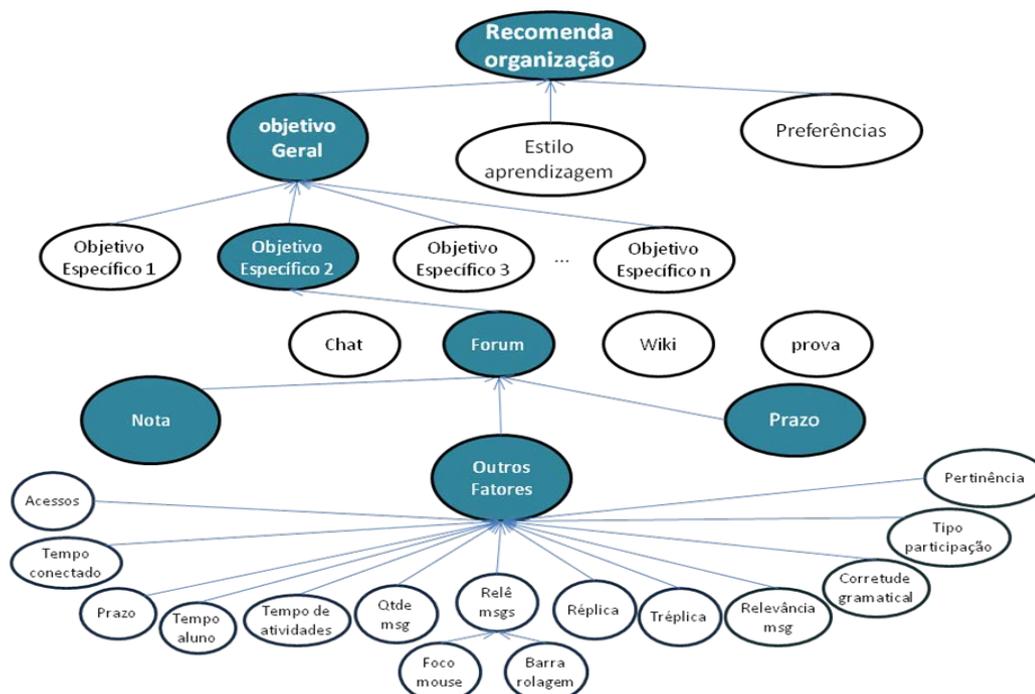


Figura 2. Recorte do grafo das variáveis utilizadas pelo AR, com ênfase na atividade fórum. O nó “Qtde msg” é uma abreviação para “Quantidade de mensagens”. A indicação “msg” foi adotada como abreviação para “mensagens” para facilitar a visualização dos nós que compõem a RB.

Em nosso trabalho, separamos as variáveis em dois grupos: as variáveis objetivas e as variáveis de controle. As seções seguintes descrevem cada um deles.

### 3.3. Variáveis Objetivas

No conjunto de variáveis objetivas, encontram-se as variáveis que se estão relacionadas à proposta pedagógica do educador, ou seja, seus pesos podem variar a cada curso ou disciplina, de acordo com o que foi estabelecido pelo professor, seja durante o planejamento da disciplina ou durante o seu replanejamento que pode acontecer com a disciplina ainda em curso. Por exemplo, dados como o peso das notas que compõe a média ponderada em uma disciplina podem fazer parte deste conjunto de variáveis.

As duas variáveis objetivas incluídas no grafo apresentado na figura 2 são “Objetivo geral” e “Objetivo específico”. A variável “objetivo geral” indica o valor mínimo necessário para considerar o aproveitamento do aluno como satisfatório. O peso desta variável tem influencia significativa no AR na determinação das recomendações. Posteriormente, esta variável é utilizada para avaliar se as recomendações realizadas foram adequadas e se ajudaram, ou não, o aluno a atingir os objetivos propostos. O conjunto de variáveis do tipo objetivo específico é utilizado para determinar a variável “objetivo geral”. Objetivos específicos são elencados pelos professores e relacionam critérios para que os alunos tenham bom aproveitamento, exemplos incluem: peso de atividades, número de acessos mínimo, número de postagens esperado, tipo de participação, relevância das mensagens, corretude gramatical, etc. Mais adiante será apresentado o detalhamento de um desses objetivos específicos.

### 3.4. Variáveis de Controle

As variáveis de controle possuem maior caráter probabilístico. Elas indicam qual a probabilidade de um evento influenciar no processo de ensino-aprendizagem, de modo que o aluno atinja os objetivos propostos pelo educador. Estas variáveis podem ser personalizadas pelo professor, permitindo a ele, indicar o quanto cada variável afeta o processo de aprendizagem para sua disciplina. A seguir são apresentadas algumas das variáveis deste conjunto.

*Estilo de aprendizagem:* baseado no modelo de Felder, esta variável influencia na apresentação do conteúdo recomendado ao aluno.

*Preferências:* é a forma como o aluno prefere manter a apresentação de seu ambiente virtual, ou seja, qual é a cor da pele do SGA, como são apresentados os textos, quantas disciplinas podem ser exibidas ao mesmo tempo, ou seja, a forma como configura seu perfil dentro do ambiente.

*Nota:* representa o aproveitamento do aluno em atividades avaliativas. Apesar de ser determinante no conjunto de variáveis, esta é a variável que mais pode gerar incertezas durante o período de estudos, pois é possível que seu valor somente seja conhecido após o fim do processo. Nestes casos onde o valor desta variável não é conhecido, o AR utiliza a variável “Outros Fatores” para inferir a probabilidade do aluno conseguir o aproveitamento mínimo esperado.

*Outros Fatores:* é a principal variável relacionada ao objetivo deste trabalho, pois é a responsável pelas recomendações realizadas durante o processo de aprendizagem e antes do encerramento de uma atividade ou disciplina.

A variável “Outros Fatores” é influenciada por um conjunto de variáveis a partir de uma relação diagnóstica, conforme ilustra a figura 2. Dentre essas variáveis encontram-se:

*Acessos:* determina a quantidade de acessos do aluno aos recursos do SGA,

*Tempo de atividades:* indica o tempo que o aluno deve realizar determinada tarefa, relacionando outras duas variáveis independentes, que são *tempo aluno* (tempo que o aluno tem disponível) e *prazo (deadline)* da atividade). Desta forma, o AR calcula os tempos a fim de ajudar o aluno a realizar suas tarefas e o alerta quando não estiver dedicando tempo necessário para finalizá-las.

*Relê mensagens:* esta variável quantifica as releituras realizadas em mensagens postadas, tais como em fóruns de discussão. O valor desta variável é calculado a partir de outras duas variáveis independentes, *foco do mouse* e *barra de rolagem*.

*Réplica:* é a variável que quantifica o número de réplicas que o aluno fez a mensagens de atividades, como por exemplo, em um fórum de discussão. Esta variável pode ser classificada com intensidade baixa, se o aluno fez postagens em quantidade abaixo do que foi indicado pelo professor; intensidade esperada, se o aluno fez as postagens na quantidade indicada pelo professor; e, intensidade alta, se o aluno fez as postagens acima da quantidade indicada pelo professor. Caso o professor não tenha indicado a quantidade esperada de réplicas, a informação de intensidade da variável não é considerada.

*Tréplica:* esta variável quantifica o número de tréplicas que o aluno fez a uma mensagem de atividade, como por exemplo, um fórum de discussão. Assim como na variável anterior, esta também pode ser classificada em intensidade.

*Relevância da mensagem:* essa variável determina se uma mensagem postada é relevante para a discussão. Para obter um valor mais adequado para esta variável, é necessária a intervenção do professor ou tutor que leia a mensagem do aluno e a classifique em um nível de relevância. No entanto, para não inviabilizar a ação do nosso AR, calculamos automaticamente o valor desta variável a partir de duas abordagens conjuntas, a utilização de palavras chave e o tamanho do texto digitado. Desta forma, o AR atua independente da intervenção do professor.

### 3.5. Atribuindo valores às variáveis

Considerando a complexidade da RB utilizada por nosso AR, bem como dos cálculos envolvidos, será utilizada uma modelagem reduzida da rede probabilística, com algumas variáveis, a fim de ilustrar seu funcionamento.

Na figura 3 a parte do grafo que será considerada neste exemplo.

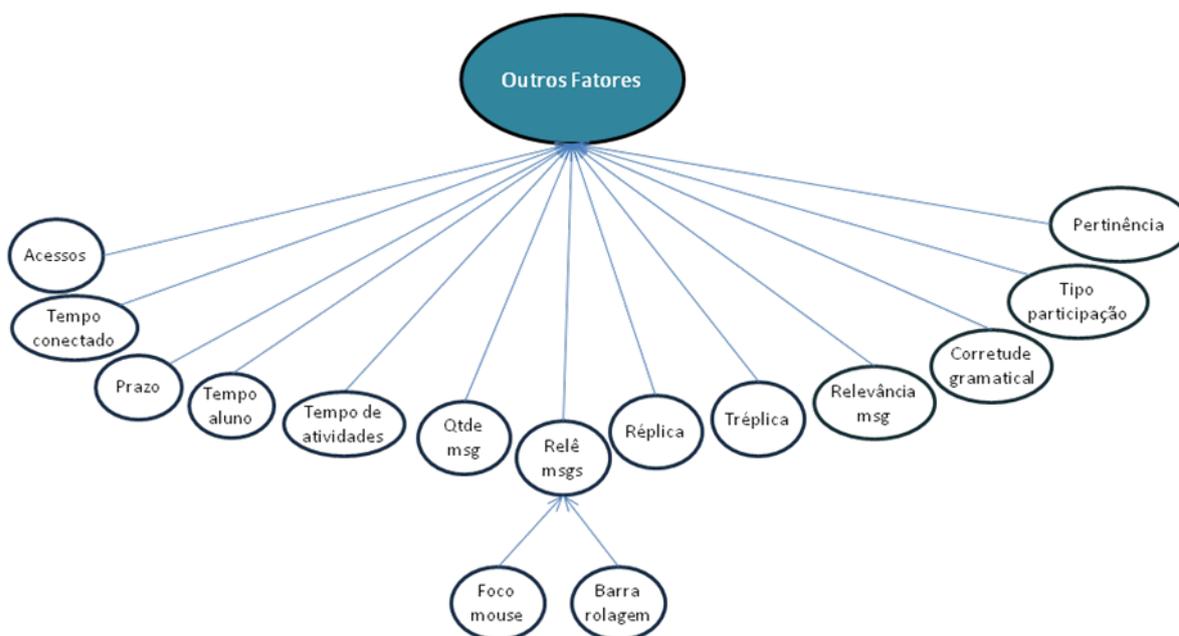


Figura 3. Grafo ilustrando três níveis da RB.

O grafo da figura 3 possui três níveis. Neste caso, a tabela condicional do nó filho “Outros fatores” é construída levando em consideração os resultados condicionais das tabelas de alguns de seus pais. Em outras palavras a probabilidade da variável “Outros fatores” (nó filho) é influenciada pelas outras variáveis que estão imediatamente abaixo dela (nós pais). Após a construção da tabela de um nó filho, é possível calcular as probabilidades condicionais desse nó em relação aos seus pais, possibilitando a resposta de algumas perguntas, como as descritas a seguir:

- Dado que a quantidade de acessos indica que o aluno esteve conectado o mínimo esperado aos recursos disponíveis, qual a probabilidade de que acesso influencia em “Outros fatores”?

• Dado que a quantidade de mensagens indica que o aluno está participando na disciplina conforme esperado, qual a probabilidade de que a quantidade de mensagens influencia em “Outros fatores”?

As probabilidades da tabela condicional de “Outros fatores”, que é pai de “Objetivo específico”, são determinantes para responder as seguintes perguntas:

• Dado que temos evidência que o aluno deve atingir o “Objetivo específico”, qual é a probabilidade de que a variável “Outros fatores” influencie esses resultados?

• Dado que a probabilidade de que “Outros fatores” influencie a variável “Objetivo específico” seja alta, qual é a variável de controle que mais influencia nesse resultado?

Esta última pergunta norteia o Agende de Recomendações, ou seja, a partir da inferência probabilística é possível encontrar a variável que mais influenciou em “Outros fatores”, e sugerir uma ação.

Considerando somente as variáveis “Acesso”, “Qtde msg” e “Relê msg”, será apresentado a seguir um modelo utilizando valores de referência aleatórios:

*Acessos*: indica a quantidade de acessos que o aluno fez aos recursos do SGA. Neste exemplo, consideramos adequado o acesso de, pelo menos, 1 vez aos materiais de estudo e, pelo menos, 3 vezes as atividades avaliativas. Será considerado adequado, se o aluno acessou pelo menos 80% da quantidade esperada, e não adequado se o aluno acessou apenas 20% ou menos.

*Qtde msg*: a quantidade adequada de postagens varia de acordo com a atividade proposta pelo professor, por isso, os valores de referência desta variável são definidos por ele durante o planejamento da disciplina. Neste caso, consideramos que se a quantidade de mensagens postadas for 40%, ou inferior, da quantidade considerada adequada pelo professor, indica que o aluno não está interagindo na intensidade esperada.

*Relê msg*: este nó possui dois nós pais, foco do mouse e barra de rolagem. O sensor lógico que monitora o foco do mouse, por exemplo, entrega um valor que pode variar de 0 a 1 e que representa a porcentagem de mensagens de um tópico de fórum que receberam o foco do mouse por, pelo menos, 10 segundos. Esse valor de 10 segundos é, aproximadamente, o tempo mínimo necessário para leitura de uma mensagem com 100 caracteres. Esse valor também é recalculado considerando o tamanho da mensagem. Da mesma forma, o sensor que monitora a barra de rolagem entrega para o AR um valor de 0 a 1, indicando a porcentagem em que a barra foi deslocada. Sendo assim, se o foco do mouse for considerado 40% adequado, então o aluno não está lendo as mensagens de forma adequada. Para barra de rolagem consideramos releitura adequada quando, pelo menos, 80% da barra foi deslocada e 20% para releitura inadequada.

### 3.6. Calculando as probabilidades

Para calcular as probabilidades condicionais, usamos a regra de Bayes, que pode ser descrita pela expressão abaixo:

$$P(b|a) = P(a|b) \times P(b)/P(a)$$

O exemplo demonstrado nesta seção calcula a influência que as variáveis FM (foco do mouse) e BR (barra de rolagem) possuem sobre a variável RM (relê msg), ou seja, quais são

as probabilidades que condicionam a não releitura das mensagens. Neste caso, serão analisadas apenas as saídas falsas da tabela “rele mensagens” (RM=F), conforme apresentado a seguir.

$$P(RM = F) = \sum_{FM, BR} P(FM = FM_i, BR = BR_i, RM = F)$$

$$P(RM = F) = 0,76$$

$$P(FM = F \mid RM = F) = \sum P(FM = F, BR = BR_i, RM = F) / P(RM = F)$$

$$P(FM = F \mid RM = F) = 0,456 / 0,76 = \mathbf{0,6 \text{ ou } 60\%}$$

A partir dos cálculos apresentados, o AR infere que se o aluno não tem foco do mouse, há 60% de possibilidade dele não ter relido as mensagens. A seguir, o cálculo realizado para a variável BR (barra de rolagem).

$$P(BR = F \mid RM = F) = \sum P(FM = FM_i, BR = F, RM = F) / P(RM = F)$$

$$P(BR = F \mid RM = F) = 0,672 / 0,76$$

$$P(BR = F \mid RM = F) = \mathbf{0,88 \text{ ou } 88\%}$$

A partir dos cálculos apresentados, o AR infere que se o aluno não rolou a barra de rolagem, há 88% de possibilidade dele não ter relido as mensagens.

#### 4. Conclusões

O Agente de Recomendações apresentado neste trabalho, converge com as necessidades dos alunos de EaD, atuando diretamente em dois grandes fatores críticos responsáveis pela evasão escolar, a falta de tempo e a adaptação ao método de ensino. Para isso, uma metodologia de estudos é proposta que orienta o aluno e ao mesmo tempo se adapta ao seu tempo disponível. O AR contribui não só para indicar os caminhos a seguir, mas também para motivar o aluno, pois ao aceitar a ajuda do agente, o aluno recebe *feedbacks* positivos e motivacionais.

Considerando os aspectos tecnológico e pedagógico, nosso Agente de Recomendações contribui com a facilidade de uso em cursos e disciplinas de cursos de EaD, apoiando os professores e educadores na forma de relacionar os objetivos educacionais com o dia a dia dos alunos no ambiente virtual de aprendizagem.

## 5. Referências

- Anuário Brasileiro Estatístico de Educação Aberta e a Distância, 2007 Coordenação: Fábio Sanchez. -- 3. ed. -- São Paulo : Instituto Monitor, 2007.
- A. Klačnja-Milićević , A. Vesin, M. Ivanović and Z. Budimac “E-Learning personalization based on hybrid recommendation strategy and learning style identification,” *Computer & Education*, V, 56, p. 885-899, 2010.
- A. Klačnja-Milicevic, B. Vesin, M. Ivanović. And Z. Budimac (2011), “E-Learning personalization based on hybrid recommendation strategy and learning style identification,” *Computers & Education*, 56(3), 885–899.
- A. Kristofic, “Recommender System for Adaptive Hypermedia Applications,”. IIT.SRC 2005, April 27, 2005, pp. 229-234.
- A. Ortony, G. L. Clore, A. Collins, “The Cognitive Structure of Emotions,” Cambridge University Press, Cambridge, UK (1988)
- BRUSILOVSKY, P., MILLÁN, E. User Models for Adaptive Hypermedia and Adaptive Educational Systems. In Brusilovsky, P. Kobsa, A., Nejd, W. (Eds.), *The adaptive web - Lecture Notes in Computer Science*, Volume 4321/2007, 3-53, 2007. Heidelberg: Springer.
- C. Eugene, “ Bayesian Networks without Tears,” *AI Magazine* Volume 12 Number 4 (1991).
- C. M. Chen, M. C. Chen and Y. –L. Li, “Mining key formative assessment rules based on learner profiles for web-based learning systems,” In: 7th IEEE International Conference on Advanced Learning Technologies, Niigata. Proceedings of the 7th IEEE International Conference on Advanced Learning Technologies, 2007, pp. 584-588.
- C. M- Chen and M. C. Chen, “Mobile formative assessment tool based on data mining techniques for supporting web-based learning,” vol 52, 2009, pp.256-273.
- C. Romero,S. Ventura, J. A. Delgado and P. DeBra, “Personalized Links Recommendation Based on Data Mining,” in *Adaptive Educational Hypermedia Systems. EC-TEL 2007, LNCS 4753*, pp. 292–306, 2007.
- C. Wolf, “iWeaver: towards ‘learning style’ –based e-Learning,” In: *Australasian Computing Education Conference (ACE2003) Conferences in Research and Practice in Information Technology*, Vol. 20.
- F. V., JENSEN, T. D., NIELSEN, Bayesian Networks and Decision Graphs. New York : IEEE Computer Society Press, 2007.
- G. Blair, A. T. Campbell,. D. C. Schmidt, “Middleware technologies for future communication networks,” *IEEE Network*, v. 18, n.1, p. 4 - 5, 2004.
- G. B. M. Vitor, “ A Web Semântica no Contexto Educativo”, Trabalho de Doutorado em Engenharia Electrotécnica e de Computadores, Faculdade de Engenharia da Universidade do Porto.
- G. C. M, Rosales, R. B, Araujo and J. L, Otsuka,; “Logical Sensor Networks to the monitoring of learning events”, In: *INCT-SEC Internal Workshop (INCT-SEC 2011)*, 7-9 December, Águas de Lindóia, Brazil, 2011.

G. Simic, D. Gasevic, and V. Devedzic, "Semantic web and intelligent learning management systems," In Proceedings of the SW-EL workshop at International Conference on Intelligent Tutoring Systems (ITS2004), Maceio-Alagoas, Brazil, 2004.

I. Gasparini, M. S. Pimenta, J. P. M. Oliveira and A. Bouzeghoub A, "Combining Ontologies and Scenarios for Context-Aware e-Learning Environments," 28th Annual International Conference on Design of Communication ACM SIGDOC, 229-236.

I. Myers-Briggs and P. B. Myers. "Gifts Differing: Understanding Personality Type," Mountain View, CA: Davies-Black Publishing, 1980, 1995.

J. Enright, B. Chu and O. R. Zaiane, "Intelligent functional dependency tutoring Tool," 16th International Conference on Computers in Education (ICCE 2008), Taipei, Taiwan, October 27-31, 2008, pp. 171-172.

J. L. Otsuka, H. V. Rocha and D. M. Beder, "A multi-agent Formative assessment support model for learning management systems," In: 7th IEEE International Conference on Advanced Learning Technologies, 2007, Niigata. Proceedings of the 7th IEEE International Conference on Advanced Learning Technologies.

J. Jovanovic, V. Devedzic, D. Gasevic, M. Hatala, T. Eap and G. Richards, Brooks, C., "Using semantic web technologies to analyze learning content," IEEE Internet Computing. 45-53. 2007

J. P. M. de Oliveira, M. A. de O. C. Brunetto, M. L. P. Júnior, M. S. Pimenta, C. H. F. P. Ribeiro, J. V. Lima, V. de Freitas, V. S. P. Marçal, I. Gasparini, M. A. Amaral, "Adaptweb: um ambiente para ensino- aprendizagem adaptativo na Web," Educar, Curitiba, Especial, p. 175-197, 2003. Editora UFPR.

L. Lazzarotto, J. L. Braga, A. P. Oliveira and F. J. V. " A educação em ambientes virtuais: proposição de recursos computacionais para aumentar a eficiência do processo ensino-aprendizado," Revista Brasileira de Informática na Educação, Volume 19, Número 2, 2011.

L. P. Dringus and T. Ellis, "Using data mining as a strategy for assessing asynchronous discussion forums," Computer & Education, Vol. 45, 2005, pp.141-160.

O. R. Zaiane, J. Luo, "Towards evaluating learners behaviour in a web-based distance learning environment," In: International Conference on Advanced Learning Technologies (ICALT 2001), 6-8 August, Madison, USA, 2001.

O. R. Zaiane (2002). Building a Recommender Agent for e-Learning Systems. International Conference on Computers in Education 2002 (ICCE'02). pp.55.

Relatório analítico da aprendizagem a distância no Brasil, Associação Brasileira de Educação a Distância (Abed), 2010.

R.M. Felder and L.K. Silverman, "Learning and Teaching Styles in Engineering Education," *Engr. Education*, 78(7), 674-681 (1988). The article that originally defined the Felder-Silverman model and identified teaching practices that should meet the needs of students with the full spectrum of styles. The paper is preceded by a 2002 preface that states and explains changes in the model that have been made since 1988.

R.M. Felder and R. Brent, "Understanding Student Differences." *J. Engr. Education*, 94(1), 57-72 (2005). An exploration of differences in student learning styles, approaches to learning

(deep, surface, and strategic), and levels of intellectual development, with recommended teaching practices to address all three categories.

S. Fatahi and N. Ghasem-Aghaee N, “Design and Implementation of an Intelligent Educational Model Based on Personality and Learner’s Emotion,” *International Journal of Computer Science and Information Security (IJCSIS)*, Vol. 7, No. 3.

S. J. H. Yang, “Context aware ubiquitous learning environments for peer-to-peer collaborative learning. *educational technology and society*,” 9 (1), 188-201, 2006.

S. Schiaffino, P. Garcia and A. Amandi (2008), “eTeacher: Providing personalized assistance to e-learning students,”. *Computers & Education*, 51(4), 1744–1754.

T. Y. Tang and G. Maccalla, “Smart Recommendation for an Evolving E-Learning System,” *Workshop on Technologies for Electronic Documents for Supporting Learning, AIED'2003*.

W. Huang, D. Webster, D. Wood and T. Ishaya, “An intelligent semantic e-learning framework using context-aware Semantic Web technologies,” *British Journal of Educational Technology*. Vol 37 No 3 21, 22, 23, 24 2006 pp. 351–373

Z. Yu, Zhou, Xingshe, L. Shu, “Towards a semantic infrastructure for context-aware e-learning,” *Journal Multimedia Tools and Applications*, Vol 47, n 1, pp. 71-96, 2010.