

## Recomendação de Recursos Educacionais Baseada em Aprendizagem de Máquina para Autorregulação da Aprendizagem

Victor A. S. Ferreira<sup>1</sup>, Germano C. Vasconcelos<sup>1</sup>

<sup>1</sup>Centro de Informática – Universidade Federal de Pernambuco (UFPE)  
50.740-560 – Recife, PE – Brasil

{vasf, gcv}@cin.ufpe.br

**Abstract.** *The growth of distance education in Brazil is stimulating the development of solutions to motivate students, minimize evasion and enhance student performance. Data gathered in virtual learning environments (AVA) have been considered to extract behavioral patterns and use them to improve performance. AVAs have been improved to process information and suggest strategies that enhance the level of student learning. This work develops a recommendation model based on auto-regulation patterns of learning in AVAs with the employment of machine learning and data mining algorithms. A software platform to recommend education activities was built to (1) analyze the performance of students according to a score; (2) extract behavior characteristics which influence performance, and (3) recommend actions to improve student performance. Experiments conducted with a database of more than 30.000 students of a Brazilian university, with several performance metrics, showed the proposed solution was capable of capturing learning profiles with over 0.95 AUROC (Area under the Roc Curve).*

**Resumo.** *O aumento da educação à distância no Brasil tem estimulado o desenvolvimento de soluções para redução da evasão nos cursos e melhoria de desempenho dos estudantes. Dados gerados de interações em ambientes virtuais de aprendizagem (AVA) têm sido analisados na busca por padrões que auxiliem no acompanhamento da aprendizagem. AVAs têm sido aprimorados considerando peculiaridades existentes no perfil dos estudantes, para indicação de atividades e/ou estratégias de aprendizagem que aumentem seu desempenho. Este trabalho desenvolve um modelo de recomendação baseado em padrões de autorregulação da aprendizagem em AVAs, fundamentado em algoritmos de aprendizagem de máquina e mineração de dados. Foi construída uma solução em software de recomendação de recursos educacionais que possibilita (1) analisar o desempenho dos estudantes a partir de uma pontuação; (2) extrair características de comportamento que influenciam no desempenho; e (3) recomendar ações que promovam a melhoria do desempenho. Experimentos realizados com uma base real de universidade brasileira com mais 30.000 estudantes, e várias métricas de desempenho, indicam que a solução foi capaz de capturar o perfil de aprendizagem com performance superior a 0,95 (Área Sob a Curva ROC); e a recomendar ações para melhoria da aprendizagem.*

## 1. Introdução

O crescente desenvolvimento de artefatos tecnológicos e da interação via internet tem provocado mudanças nos processos de ensino e aprendizagem, com ambientes computacionais de ensino e conteúdos digitais sendo vistos como suporte efetivo aos processos educacionais. De acordo com o Relatório Analítico da Aprendizagem a Distância no Brasil (2015) elaborado pela Associação Brasileira de Educação a Distância (ABED), houve um aumento significativo no número de matrículas realizadas em cursos desta modalidade ofertados por diferentes categorias administrativas. Órgãos públicos, instituições públicas municipais e instituições privadas com fins lucrativos, por exemplo, apresentaram aumento de 60%, 50% e 45%, respectivamente, no número de matrículas nos cursos totalmente a distância. Com isso, grandes bases de dados são criadas, provindas das interações entre os usuários, e armazenam dados com informações valiosas sobre o comportamento dos estudantes.

Nesse panorama, é desafiador para o professor acompanhar essas interações nas diferentes ferramentas de comunicação e plataformas de aprendizagem, de modo a contribuir para a melhoria do desempenho acadêmico e motivação dos alunos. Tem sido frequente encontrar Ambientes Virtuais de Aprendizagem (AVAs) que utilizam uma camada de inteligência, que possibilitem analisar as atividades dos estudantes e tornem o processo sobre as interações entre os estudantes mais rico em informações e mais flexível no controle da aprendizagem (PEREIRA, 2007). Além disso, tornar os AVAs mais atrativos é uma tarefa desafiadora (FERRO, 2010), com funcionalidades incorporadas como avaliações automáticas do nível de aprendizagem, captura das características dos alunos/atividades de melhor desempenho e/ou recomendações de materiais didáticos e ações que potencializem o aprendizado.

Sistemas de recomendação (SR) são agentes de informação personalizados que fornecem recomendações de itens de utilidade para o usuário (BURKE, 2007). SRs têm sido utilizados em diversos domínios, como comercial e educacional (COSTA et al., 2013). SRs educacionais podem usufruir das mesmas estratégias dos SRs comerciais, sendo seu objetivo a melhoria dos processos de ensino e aprendizagem. Na literatura, há diversos trabalhos envolvendo a recomendação de recursos educacionais. Nestes estudos, é recorrente a análise do perfil do estudante, do seu contexto e de suas preferências (BREMIGARTNER et al., 2015; FERREIRA et al., 2013; AGUIAR et al., 2015).

Ainda observa-se recomendações baseadas em conteúdo (REIS et al., 2014), bem como sistemas que fazem recomendação baseada em pares (MULLER et al., 2013). Não observa-se, contudo, a exploração de variáveis comportamentais relacionadas à autorregulação da aprendizagem, considerada uma das competências-chave para iniciar e manter a aprendizagem ao longo da vida (COUNCIL, 2002), envolvendo o estudante no controle ativo de sua própria aprendizagem e de seus resultados. Diante disso, torna-se relevante investigar como SRs educacionais podem contribuir no desempenho de estudantes na modalidade de educação a distância pela exploração de indicadores comportamentais de autorregulação da aprendizagem armazenados nas bases de dados dos AVAs.

Este trabalho investiga um modelo de recomendação baseado em padrões de autorregulação da aprendizagem em AVAs, fundamentado em algoritmos de aprendizagem de máquina. A solução construída como um projeto de mineração de

dados é composta por três módulos que realizam, respectivamente (1) análise do perfil dos estudantes quanto ao desempenho através de uma pontuação; (2) extração do comportamento dos estudantes que apresentam bom e mau desempenho; e (3) sugestão de ações visando à melhoria do aprendizado. A solução foi criada a partir da análise de um conjunto de dados de AVA utilizado em cursos a distância da Universidade de Pernambuco. Neste artigo são apresentadas a descrição conceitual do sistema e a análise de resultados dos experimentos realizados com diversas métricas de desempenho e algoritmos de aprendizagem de máquina.

## 2. Trabalhos Relacionados

Sistemas de recomendação de recursos educacionais são objeto de estudo de várias pesquisas. Em Bremgartner *et al.* (2015), foi proposta uma arquitetura pedagógica multiagente adaptativa para recursos e atividades em AVAs, visando a promover o aprendizado do estudante em função do perfil. Foram usados sistemas multiagentes para manipular dados dos alunos e seus modelos de perfil no banco de dados do AVA. Como resultado, observou-se que correções realizadas por outros alunos ajudaram no desempenho acadêmico, e que recomendações de arquiteturas pedagógicas podem ajudar a construir o conhecimento do aluno de forma útil e eficaz.

Em Santos *et al.* (2015), o objetivo foi aprimorar sistemas de recomendação baseados em filtragem colaborativa dentro de um contexto educacional. O estudo envolveu a recomendação de objetos de aprendizagem de um repositório (Merlot) e avaliou a eficácia de técnicas de clusterização, aplicadas a usuários e objetos de aprendizagem (OA), nas recomendações. A clusterização de OAs apresentou-se melhor que a abordagem sem clusterização e ilustrou-se que sua aplicação antes de técnicas de filtragem colaborativa aprimora a qualidade das recomendações.

Reis *et al.* (2014), apresentaram uma arquitetura com base em recomendação colaborativa para o professor direcionar conteúdos para grupos específicos de alunos (pré-configurados) e nível de conhecimento sobre cada assunto (básico, médio ou avançado). De acordo com a dinâmica de acesso, a arquitetura automatiza a recomendação de conteúdos, conforme características do usuário e do contexto.

Casagrande *et al.* (2013), desenvolveram uma técnica de recomendação simples e escalável aplicada a repositórios digitais voltados ao ensino. Foi utilizada recomendação colaborativa aplicada à Biblioteca Digital de Literatura Brasileira (BD-LB) e observado que, apesar do número reduzido de usuários, a precisão média de 80% demonstrou a boa qualidade dos conteúdos recomendados. Os resultados mostraram que houve ganho significativo de tempo de processamento com o uso de agrupamento (4,6s) quando comparada com a solução sem agrupamento (7,3s).

Ribeiro *et al.* (2013) desenvolveram um módulo adicional ao AVA Moodle, a partir do conjunto de hashtags atribuídas nas postagens dos fóruns, empregando a técnica de atribuição de pesos a documentos, e empregaram um algoritmo de classificação e ranqueamento de conteúdos a partir dos termos mais citados. Uma técnica de recomendação baseada em conteúdos foi utilizada, mostrando-se eficientes nas recomendações padronizadas e caráter diversificado, segundo interesse do usuário.

Apesar dos diversos trabalhos sobre SRs educacionais, não observa-se estudos que considerem indicadores comportamentais de autorregulação da aprendizagem na recomendação de objetos de aprendizagem, sendo este o foco deste trabalho. A

exploração de tal habilidade é necessário por possibilitar aos estudantes que adquiram conhecimento sobre a própria aprendizagem, bem como desenvolvam habilidades para gerenciá-la e regulá-la (ZIMMERMAN & MOYLAN, 2009).

### 3. Desenvolvimento da Solução

#### 3.1. Base de Dados Utilizada

Para a construção da solução foi empregada uma base de dados de um acordo de cooperação científica com o Núcleo de Educação a Distância da Universidade de Pernambuco. Nesta base são disponibilizados dados históricos do AVA Moodle utilizado na instituição nos últimos sete anos, dos semestres 2009.2 a 2016.1. Os dados são provenientes do trabalho desenvolvido por Rodrigues (2016). Após entendimento da arquitetura do banco de dados do AVA Moodle, foi extraído um conjunto de 33 variáveis comportamentais do banco de dados da plataforma. Essas variáveis representam comportamentos dos alunos de acordo com construtos usados como referência na teoria de autorregulação da aprendizagem (ZIMMERMAN & MOYLAN, 2009; ZEIDNER et al, 2000), foram empregadas em Rodrigues (2016), e foram também analisadas neste trabalho com respeito à capacidade preditiva. As variáveis foram categorizadas como segue:

- **gerenciamento de tempo:** qtd\_media\_semanal\_acessos, tempo\_medio\_postagem\_forum, qtd\_time\_out, tempo\_medio\_abertura\_atividade\_e\_realizacao, qtd\_acesso\_ambiente, qtd\_acesso\_ambiente\_manha, qtd\_acesso\_ambiente\_tarde, qtd\_acesso\_ambiente\_noite e qtd\_acesso\_ambiente\_madrugada;
- **autoavaliação:** qtd\_respostas\_topico\_principal, qtd\_pageviews, visualizacao\_desempenho\_rel\_grupo, qtd\_visualizacao\_notas\_atividades;
- **busca por ajuda:** qtd\_msgs\_enviadas\_ao\_professor, qtd\_msgs\_enviadas\_ao\_tutor, qtd\_msgs\_geral\_enviada\_aluno, qtd\_msgs\_geral\_recebida\_aluno, qtd\_topicos\_criado\_tirar\_duvidas, qtd\_postagem\_tirar\_duvidas, qtd\_postagem\_respondida\_outro\_aluno, qtd\_postagem\_respondida\_prof\_tutor, qtd\_geral\_msgs\_enviadas\_colegas\_diferentes;
- **estratégia e realização da tarefa:** qtd\_visualizacao\_aba\_conteudo, horario\_mais\_atividades, turno\_mais\_atividades, qtd\_atividades\_atrasadas, tempo\_medio\_abertura\_atividade\_e\_realizacao, qtd\_pageviews, qtd\_postagens\_forum;
- **estabelecimento de metas:** qtd\_atividades\_realizada\_prazo, qtd\_postagens\_forum, qtd\_respostas\_professores\_alunos.

Na preparação dos dados foram realizadas integração das bases de dados, extração, transformação e limpeza das variáveis para construção da tabela de análise. Esta etapa resultou em um base de dados com 30.217 instâncias, dividida em conjuntos independentes de treinamento (modelagem), com 21.058 (~70%) observações, e 9.159 (~30%) para teste e validação dos algoritmos (HAIR *et al.* (2009)).

Para consistência, a construção dos modelos foi realizada por meio de validação cruzada ou *k-fold cross-validation* (WITTEN; FRANK, 2005), que particiona o conjunto de dados em subconjuntos mutuamente exclusivos, onde  $k-2$  subconjuntos diferentes, repetidos  $k$  vezes, são usados para estimação dos parâmetros do modelo

(dados de treinamento) e os demais 2 subconjuntos (dados de validação ou de teste) são empregados na validação do modelo. Nesta pesquisa, foi aplicado *10-fold cross-validation*, comumente recomendado.

### 3.2. Modelo de Recomendação Proposto

O modelo é composto por três módulos (Figura 1): *i) módulo 1*: classificação de perfis de conhecimento do aluno, *ii) módulo 2*: extração de regras de comportamento, e *iii) módulo 3*: sistema de recomendação de ações para melhoria do desempenho.

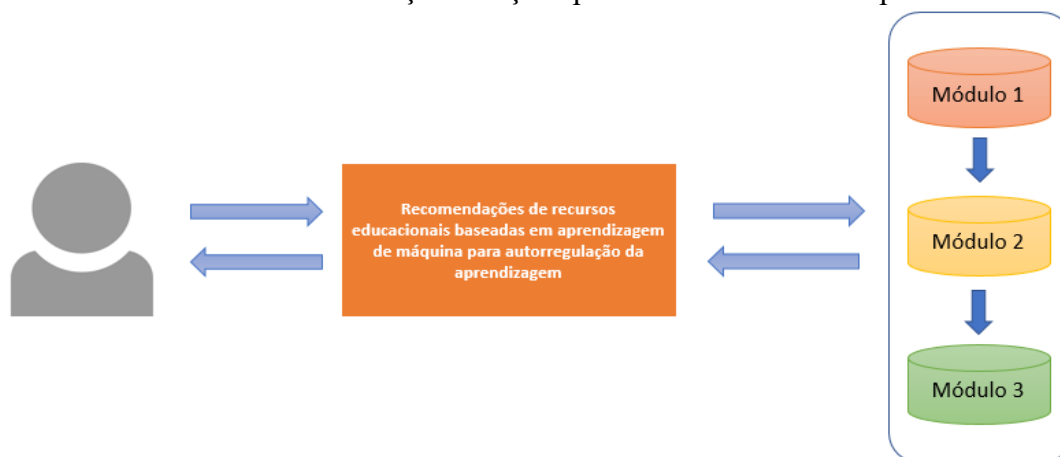


Figura 1. O modelo de recomendação proposto

#### 3.2.1. Módulo 1: Classificação de Perfis

No módulo 1, um modelo de classificação foi projetado para classificar perfis de conhecimento dos alunos quanto a performance. As técnicas de classificação *Random Forest* e *J48* foram consideradas pelo seu desempenho em aplicações de classificação de padrões (Lorenzetti, 2016).

*Random Forest* (WITTEN; FRANK, 2005) é um tipo de *ensemble learning*, um método que gera um conjunto de classificadores, cada um construído a partir de um subconjunto dos dados. Múltiplas árvores de decisão são geradas e são utilizadas na classificação de novas entradas (padrões) em um esquema de votação. Esse algoritmo é bastante utilizado em grandes bases de dados, pela simplicidade, velocidade e desempenho. O segundo algoritmo analisado, *J48* (WITTEN; FRANK, 2005), constrói árvores de decisão a partir de um conjunto de dados de treinamento utilizando o conceito de Entropia. O *J48* gera árvores de decisão para classificação de maneira semelhante ao *Random Forest*. Um aspecto relevante do *J48* é a capacidade de lidar com variáveis qualitativas contínuas e discretas, e quantitativas, das bases de dados.

Os algoritmos foram testados com um conjunto de métricas para análise consistente dos resultados na base dos estudantes. Medidas mínimas de 88% para *Precision*, *Recall* e *F-Measure*, 0,77 de *Kappa* e 0,95 para a *Curva Roc* (*Receiver Operating Characteristics*) foram obtidas com o classificador *Random Forest*, enquanto com a árvore de decisão *J48* foram alcançados 87% para as mesmas 3 primeiras métricas de desempenho, e 0,77 de *Kappa* e 0,88 para a *Curva ROC*. Os valores obtidos, acima de 87% para a maioria das métricas indica um desempenho elevado considerando valores típicos obtidos em tarefas de classificação de padrões. A Tabela 1 relaciona todos os valores obtidos.

**Tabela 1. Estatísticas dos algoritmos Random Forest e J48 no R**

Algoritmos	Métricas				
	<i>Precision</i>	<i>Recall</i>	<i>F-Measure</i>	<i>ROC Area</i>	<i>Kappa</i>
Random Forest	0,888	0,888	0,888	0,956	0.7727
J48	0,873	0,873	0,872	0,879	0.7416

### 3.2.2 Módulo 2: Extração de Regras

No módulo 2, de extração de conhecimento por indução de regras, os algoritmos OneR, JRIP e PART (WITTEN; FRANK, 2005) foram investigados. Assim como nos algoritmos de classificação, as mesmas métricas de desempenho foram empregadas para avaliação dos métodos.

**Tabela 2. Métricas para análise dos algoritmos de extração de regras**

Algoritmos	Métricas				
	<i>Precision</i>	<i>Recall</i>	<i>F-Measure</i>	<i>ROC Area</i>	<i>Kappa</i>
JRIP	0,874	0,874	0,874	0,901	0.7456
PART	0,866	0,865	0,865	0,910	0.7285
ONE R	0,815	0,814	0,814	0,809	0.6222

Como observado na Tabela 2, o algoritmo JRIP obteve desempenho levemente superior ao algoritmo PART em termos de *Precision*, *Recall* e *F-Measure* e superior ao algoritmo OneR, nas mesmas métricas. Em termos de *Curva ROC*, uma métrica comumente considerada robusta para comparação de modelos, o algoritmo PART obteve desempenho superior ao JRIP e bastante superior (10 pontos) ao algoritmo OneR. Considerando também os valores *Kappa*, ficou evidenciado um desempenho superior dos algoritmos JRIP e PART frente ao algoritmo OneR.

Foram extraídas 219 regras no total, e para efeito de representatividade foram selecionadas aquelas com número de casos igual ou superior a 100, por representar cerca de 86% do total de registros treinados. Com isso, 46 regras resultantes foram utilizadas na criação da proposta de recomendação de recursos educacionais. Dessas 46 regras, 37 estão associadas a estudantes que apresentaram bom desempenho, enquanto que 9 são relativas aqueles com desempenho ruim.

O Quadro 1 ilustra regras relativas a desempenhos RUIM e BOM. Para efeito ilustrativo, a Regra 1 pode ser lida como: “Em 4885 ocorrências, quando o aluno realiza atividades no turno da manhã, posta uma ou menos vezes em fóruns, entra na disciplina uma ou menos vezes em dias distintos, acessa cinco ou menos vezes o ambiente no turno da manhã e não esgota o tempo na plataforma, tem desempenho RUIM”.

Já a Regra 3 pode ser lida da seguinte forma: “ Em 404 ocorrências, exceto em 3, quando o aluno tem uma média semanal de acessos ao ambiente menor ou igual a

aproximadamente zero, posta pelo menos uma atividade no prazo, acessa o ambiente pelo menos três vezes no turno da manhã e não acessa o ambiente no turno da madrugada, tem o desempenho RUIM. Em 3 casos, idênticos a este, o aluno possui desempenho RUIM”

A interpretação das regras possibilita perceber alguns fatores que influenciam no desempenho acadêmico, a exemplo do (1) turno em que os estudantes realizaram mais atividades, (2) a frequência de acesso ao ambiente, (3) a entrega de atividades no prazo, por disciplina, e (4) a interação do aluno com colegas, professores e tutores no AVA.

**Quadro 1. Exemplo de regras geradas na classificação dos dados**

<b>Regra 1: DESEMPENHO RUIM</b>	<b>Regra 2: DESEMPENHO BOM</b>
Turno do dia em que realizou mais atividades =MANHÃ AND Quantidade geral de postagens de um(a) aluno(a) em fóruns $\leq 1$ AND Quantidade de dias distintos que o aluno entrou na disciplina $\leq 1$ AND Quantidade de acessos do(a) aluno(a) ao ambiente por turno (Manhã) $\leq 5$ AND Quantidades de Time Out $\leq 0$ : DESEMPENHO RUIM (4885.0)	Quantidade de atividades entregues por um(a) aluno(a) no prazo, por disciplina $> 1$ AND  Quantidade de atividades entregues por um(a) aluno(a) no prazo, por disciplina = PELO MENOS 2: DESEMPENHO BOM (849.0/397.0) (desempenho bom/desempenho ruim)
<b>Regra 3: DESEMPENHO RUIM</b>	<b>Regra 4: DESEMPENHO BOM</b>
Média semanal da quantidade de acessos de um(a) aluno(a) ao ambiente $\leq 0.000096$ AND Quantidade de atividades entregues por um(a) aluno(a) no prazo, por disciplina $\leq 1$ AND Quantidade de acessos do(a) aluno(a) ao ambiente por turno (Manhã) $\leq 3$ AND Quantidade de acessos do(a) aluno(a) ao ambiente por turno (Madrugada) $\leq 0$ AND Quantidade de acessos do(a) aluno(a) ao ambiente $\leq 8$ : DESEMPENHO RUIM (404.0/3.0)(desempenho ruim/desempenho bom)	Quantidade geral de postagens de um(a) aluno(a) em fóruns $> 3$ AND Média semanal da quantidade de acessos de um(a) aluno(a) ao ambiente $> 1.5$ AND Turno do dia em que realizou mais atividades $\neq$ MANHÃ AND Tempo médio entre a criação de um tópico no fórum temático e a primeira postagem do aluno $> 212.22$ (minutos) AND Quantidade de atividades entregues por um(a) aluno(a) no prazo, por disciplina = PELO MENOS 1 AND Quantidade de acessos do(a) aluno(a) ao ambiente por turno (Madrugada) $\leq 2$ : DESEMPENHO BOM (144.0/1.0)(desempenho bom /desempenho ruim)

### 3.2.3. Módulo 3: Recomendação de Ações

No módulo 3, um modelo de recomendação foi concebido a partir da classificação dos perfis e extração de regras. Um conjunto de recomendações foi elaborado objetivando

melhorar o desempenho acadêmico dos estudantes em ambientes virtuais de aprendizagem. Foi observado como variáveis comportamentais de autorregulação da aprendizagem se apresentam em estudantes com bom desempenho e traçaram-se metas a serem atingidas por aqueles com desempenho ruim. Exemplos de recomendações e situações para os estudantes com desempenho ruim podem ser conferidas no Quadro 2. Algumas recomendações são aplicáveis a mais de uma situação de aprendizagem, atuando de forma complementar a outras recomendações.

**Quadro 2. Exemplos de recomendações de recursos educacionais**

	Situação de Aprendizagem do Estudante	Recomendações
1	Alunos que realizam atividades pela manhã, com quantidade geral de postagem menor ou igual a um, com um dia ou menos de acesso à disciplina e com cinco ou menos acessos à plataforma pela manhã.	<p>[REC1.1] Recomendar atividades em diferentes turnos e dias e pré-definir o turno e dia de entrega, de modo a incentivar o acesso do aluno à disciplina em diferentes dias e realização de atividades em diferentes turnos.</p> <p>[REC1.2] Recomendar texto e/ou vídeo relacionado aos fóruns que o aluno ainda não postou, incentivando a participação dele nessas discussões.</p>
2	Alunos que realizaram mais atividades pela manhã, que postaram em fóruns duas ou menos vezes, que submeteram atividades em um tempo médio menor que 1.25, que fizeram a primeira postagem após a criação de um tópico em fórum temático em um tempo menor ou igual a 106.61min, que não visualizou o <i>checklist</i> de atividades, que entrou na disciplina uma vez ou menos, em dias distintos, que fez quatorze ou menos leituras ao fórum, que outros alunos, professores ou tutores não responderam suas postagens em fóruns, que não fizeram nenhum acesso ao ambiente no período da madrugada, que acessou ao ambiente no turno da manhã nove ou menos vezes .	<p>[REC2.1] Recomendar atividades em diferentes turnos e dias e pré-definir o turno e dia de entrega, de modo a incentivar o acesso do aluno à disciplina em diferentes dias e realização de atividades em diferentes turnos.</p> <p>[REC2.2] Recomendar a professores e tutores alunos com baixo desempenho, incentivando o envio de suas respostas às postagens feitas por esses alunos no fórum.</p> <p>[REC2.3] Recomendar texto e/ou vídeo relacionado às postagens no fórum, incentivando a participação do aluno a responder postagens feitas pelos colegas.</p> <p>[REC2.4] Recomendar texto e/ou vídeo relacionado aos fóruns que o aluno ainda não postou, incentivando a participação dele nessas discussões.</p>

Como próximo passo na validação das recomendações, protótipos de baixa fidelidade foram criados para validação por professores que utilizam AVAs em sua prática pedagógica. Essa validação objetiva identificar a percepção dos professores sobre as recomendações elaboradas, sendo possível evoluir a proposta a partir dos *feedbacks* recebidos.



#### 4. Considerações Finais

Ao analisar-se a literatura da área é possível identificar diferentes propostas de SRs educacionais. Não observa-se, contudo, estudos que considerem indicadores comportamentais de autorregulação da aprendizagem na recomendação de objetos de aprendizagem. Este trabalho desenvolveu um modelo de recomendação educacional baseado em indicadores de autorregulação da aprendizagem em AVAs e construiu uma ferramenta de *software* para recomendação de recursos educacionais em AVAs. A solução, composta de 3 módulos capazes de avaliar o desempenho do estudante, extrair regras comportamentais que indicam desempenho, e sugerir atividades para melhoria de desempenho, respectivamente, foi testada em uma base de dados com mais de 30.000 instâncias de um ambiente de universidade pública no Brasil.

Os resultados gerados evidenciam o caráter promissor da solução para uso em ambientes de ensino à distância. Foi gerado adicionalmente um conjunto de scripts em R para análise de dados, construção de classificadores e extração de regras, disponíveis para pesquisadores interessados em novos trabalhos. O estudo tem algumas limitações como a definição do limiar de corte de 100 casos para as regras interpretadas e a falta de avaliação de educadores e alunos do modelo de recomendação desenvolvido. Ajustes no sistema estão sendo realizados para permitir a variação na seleção das regras pelo nível de suporte e confiança das regras. Quanto à avaliação do modelo de recomendação, será um dos próximos passos da pesquisa.

#### Referências

- Aguiar, J., Fechine, J., & Costa, E. (2015). Recomendação de Objetos de Aprendizagem baseada na Popularidade dos Objetos e nos Estilos de Aprendizagem dos Alunos. In *Simpósio Brasileiro de Informática na Educação (SBIE)*, vol. 26, no. 1, p. 1147.
- Associação Brasileira de Educação a Distância–ABED (2015). Relatório Analítico da Aprendizagem a Distância no Brasil. Acesso em 03 de Março de 2017. Disponível em <<https://goo.gl/F4XaGc>>.
- Bremgartner, V., Netto, J. F., & de Menezes, C. (2015). Explorando arquiteturas pedagógicas recomendadas por meio de agentes e ontologia de modelo do aluno em ambientes virtuais de aprendizagem. In *Simpósio Brasileiro de Informática na Educação (SBIE)*, vol.26, no.1, p. 1157.
- Burke, R. (2007). Hybrid web recommender systems. *The adaptive web*, vol. 4321, Springer Science & Business Media.
- Casagrande, M. F. R., Kozima, G., & Willrich, R. (2013). Técnica de Recomendação Baseada em Metadados para Repositórios Digitais Voltados ao Ensino. In *Simpósio Brasileiro de Informática na Educação (SBIE)*, vol. 24, no. 1, p. 677.
- Costa, E., Aguiar, J., & Magalhães, J. (2013). Sistemas de Recomendação de Recursos Educacionais: conceitos, técnicas e aplicações. In *Jornada de Atualização em Informática na Educação (JAIE)*, Campinas, SP.
- Council, E. U. (2002). Council resolution of 27 June 2002 on lifelong learning. Official Journal of the European Communities, 9, 1-3.

- dos Santos, H., Cechinel, C., Araújo, R., & Brauner, D. (2015, October). Recomendação de Objetos de Aprendizagem Utilizando Filtragem Colaborativa: Uma comparação entre abordagens de pré-processamento por meio de clusterização. In *Simpósio Brasileiro de Informática na Educação (SBIE)*, vol. 26, no. 1, p. 1127.
- Ferreira, L. G. A., Barbosa, J. L. V., & Gluz, J. C. (2013). Um Modelo de Recomendação Ubíqua de Conteúdo para Grupos de Aprendizes. In *Simpósio Brasileiro de Informática na Educação (SBIE)* v, 24, 697-706.
- Ferro, M. R. D. C. (2010). Modelo de sistema de recomendação de materiais didáticos para ambientes virtuais de aprendizagem. Dissertação de Mestrado. Universidade Federal de Alagoas, Maceió - AL.
- Hair, J. F., Black, W. C., Babin, B. J., Anderson, R. E., & Tatham, R. L. (2009). *Análise multivariada de dados*. Bookman Editora.
- Lorenzetti, C. D. C., & Telöcken, A. V. (2016). Estudo Comparativo entre os algoritmos de Mineração de Dados Random Forest e J48 na tomada de Decisão. In *Simpósio de Pesquisa e Desenvolvimento em Computação (SPDC)*, vol. 2, no. 1.
- Müller, L., & Silveira, M. S. (2013). Podes me ajudar? Apoiando a formação de pares em sistemas de ajuda em pares através de técnicas de recomendação. In *Simpósio Brasileiro de Informática na Educação (SBIE)*, vol. 24, no. 1, p. 868.
- Pereira, A. T. C., Schmitt, V., & Dias, M. R. A. C. (2007). *Ambientes virtuais de aprendizagem. AVA-Ambientes Virtuais de Aprendizagem em Diferentes Contextos*. Rio de Janeiro: Editora Ciência Moderna Ltda.
- Reis, G., & Barrère, E. (2014). Recomendação Colaborativa de Conteúdos Educacionais para Dispositivos Portáteis. In *Simpósio Brasileiro de Informática na Educação (SBIE)*, vol. 25, no. 1, p. 934.
- Ribeiro, F. A. A., Fonseca, L. C. C., & de Sousa Freitas, M. (2013). Recomendando Objetos de Aprendizagem a partir das hashtags postadas no Moodle. In *Simpósio Brasileiro de Informática na Educação (SBIE)*, vol. 24, no. 1, p. 82.
- Rodrigues, R. L. (2016). Uma abordagem de mineração de dados educacionais para previsão de desempenho a partir de padrões comportamentais de autorregulação da aprendizagem. Tese de Doutorado, Centro de Informática - UFPE, Recife-PE.
- Sanches, F. (2008). *Anuário Brasileiro Estatístico de Educação - ABRAEAD*. Associação Brasileira de Educação a Distância - ABED.
- Witten, I. H., Frank, E. (2005). *Data Mining: Practical machine learning tools and techniques*. 2nd ed. Morgan Kaufmann.
- Zimmerman, B. J., & Moylan, A. R. (2009). Self-regulation: Where metacognition and motivation intersect. *Handbook of metacognition in education*, 299-315.
- Zeidner, M., Boekaerts, P. & Pintrich, P. (2000). *Handbook of self-regulation*, 13-39. New York: Academic Press.