

Uma ferramenta para visualização das tendências de evasão geradas por mineração de dados a partir das interações em fóruns de discussão

Francisco da Conceição Silva¹, Luis Carlos Costa Fonseca¹, Reinaldo de Jesus Silva¹,
Josenildo Costa da Silva²

¹Departamento de Engenharia da Computação
Universidade Estadual do Maranhão (UEMA) – São Luis – MA – Brazil

²Departamento Acadêmico de Informática
Instituto Federal de Educação, Ciência e Tecnologia do Maranhão (IFMA)
São Luis – MA – Brasil

{fransconcfs, lccfonseca, reinaldosilvarrrb}@gmail.com,
jcsilva@ifma.edu.br

Abstract: *This work shows the working version of a tool to present the dropout trends generated by data mining in Virtual Learning Environments from the students interactions in discussion forums. It enables stakeholders ease in understanding the results and serves to aid in decision making. The same has as input files with classification rules generated by algorithms based on decision tree and files containing the data used in mining. As a result, it shows the dropout trends, disapproval and approval of students and tells you how many and which ones are inserted in each rule.*

Resumo: *Este trabalho mostra a versão funcional de uma ferramenta para apresentar as tendências de evasão geradas por mineração de dados em Ambientes Virtuais de Aprendizagem a partir das interações de alunos em fóruns de discussão. Ela possibilita às partes interessadas facilidade na compreensão dos resultados e serve de auxílio na tomada de decisão. A mesma tem como entrada arquivos com regras de classificação geradas por algoritmos baseados em árvore de decisão e arquivos contendo os dados utilizados na mineração. Como resultado, apresenta as tendências de evasão, reprovação e aprovação de alunos, bem como informa quantos e quais deles se inserem em cada regra.*

1. Introdução

As ferramentas colaborativas e de comunicação tem sido usadas largamente nos contextos educacionais e os Ambientes Virtuais de Aprendizagem (AVA's), que são uma modalidade de Ensino a Distância (EAD), estão cada vez mais sendo inseridos em universidades, escolas e empresas. Essa comunicação ocorre de diversas formas, tais como *chats*, fóruns

de discussão, *wikis*, dentre outras. Os fóruns, especialmente, consistem em espaços para discussões e trocas de ideias sobre assuntos definidos por seus participantes, possibilitando uma experiência de aprendizagem favorável ao processo pedagógico [Abawajy, 2012].

Na EAD existe um problema recorrente e muito desafiador, que é a evasão de alunos e para Abbad *et al.* (2010), as altas taxas de desistência estão preocupando as instituições que oferecem esta modalidade de ensino. Diante disso: quais fatores influenciam, direta ou indiretamente, na evasão e reprovação de alunos? E ainda, como deve ser um modelo computacional que se proponha fazer esse diagnóstico?

Uma característica comum em AVA's é sua capacidade de coletar e armazenar uma grande quantidade de dados sobre os alunos. Esses dados podem ser, por exemplo, registros de acesso, interações diversas com o sistema e as mensagens em fóruns. Este grande volume de dados possibilitou, em paralelo ao avanço das técnicas de mineração de dados, um estudo mais acurado do fenômeno da evasão. Identificar as informações relevantes em base de dados como essa não é uma tarefa fácil e o professor que deseja obter informações a respeito do desempenho dos alunos terá à sua disposição tabelas e dados de difícil interpretação. Para um gestor educacional seria de grande relevância poder identificar alunos desmotivados ou prestes a abandonar o curso.

No intuito de possibilitar essa identificação e exibição de forma mais compreensiva, este trabalho apresenta uma versão funcional de uma ferramenta para visualização das tendências de evasão geradas por mineração de dados em AVA's, a partir das interações de alunos em fóruns de discussão, servindo como ponto de partida aos interessados diretos (professores, tutores, gestores, etc.) na tomada de decisão. A ferramenta utiliza as regras de classificação geradas por algoritmos baseados em árvore de decisão e os dados utilizados na mineração para mostrar essas tendências, bem como em quais regras os alunos aparecem.

Para isso, fez-se um estudo bibliográfico visando ampliar a compreensão sobre evasão na EAD, foram investigadas e definidas as técnicas de mineração de dados utilizadas nos experimentos realizados, foi feito um estudo da base de dados de um AVA para obter os dados necessários ao modelo preditivo de mineração e implementada a versão funcional da ferramenta para visualização de diagnóstico.

O trabalho está organizado da seguinte forma: na **seção 2** é feita uma revisão de literatura, abordando o que há de mais recente em pesquisas sobre os tópicos tratados; na **seção 3** são apresentados alguns trabalhos relacionados; na **seção 4** são apresentados os procedimentos metodológicos referentes aos experimentos de mineração de dados e visualização de diagnóstico; na **seção 5** é feita a análise dos resultados obtidos; na **seção 6** temos as conclusões e trabalhos futuros; por fim, as referências.

2. Referencial Teórico

Esta seção apresenta uma visão geral a respeito dos tópicos tratados neste trabalho, mostrando o que há de pesquisas em cada assunto abordado.

2.1 Evasão na EAD

A evasão de alunos é um dos principais problemas na EAD e refere-se à desistência definitiva do aluno em qualquer etapa do curso [Abbad *et al.*, 2010]. A **tabela 1** mostra a distribuição dos índices de evasão registrados entre 2010 e 2013, segundo o censo da EAD [Abed, 2013], onde no ano de 2013 foi registrado um aumento significativo nos índices de evasão em todos os tipos de cursos apresentados, sendo que o índice médio em cursos regulamentados totalmente a distância foi de 19% e de semipresenciais foi de 14,6%.

Tabela 1. Índices de evasão registrados no período 2010-2013 no Censo EAD-BR [ABED, 2013, p.32].

Tipo de cursos	2010	2011	2012	2013
Autorizados pelo MEC	18,6%	20,5%	11,74%	16,94%
Livres não corporativos	22,3%	23,6%	10,05%	17,08%
Livres corporativos	7,6%	20%	3%	14,62%
Disciplinas EAD	—	17,6%	3,10%	10,49%

Para Romero *et al.* (2012), o fracasso escolar é conhecido como “o problema das mil causas”, dado que uma série de fatores do tipo pessoal, acadêmico (quanto maior a escolaridade, menor a evasão), físico, familiar, social, dentre outros, podem influenciar no fracasso ou abandono de curso por parte dos alunos.

A identificação de indicadores de evasão em cursos a distância é importante para que seja possível proporcionar as condições necessárias que a reduza ou elimine. Para isso, são necessários métodos e ferramentas de análise de dados a fim de observar o comportamento dos alunos para auxiliar as partes interessadas na tomada de decisão. A Mineração de Dados Educacionais (MDE) é uma abordagem indutiva muito interessante que cria modelos para descobrir automaticamente informações ocultas presentes nos dados dos alunos que podem ser utilizadas na melhoria da aprendizagem [Romero *et al.*, 2008].

2.2 Interações em Fóruns de Discussão

Os fóruns são uma poderosa ferramenta de comunicação assíncrona e consistem em espaços de discussões e trocas de ideias a respeito de temas propostos por seus participantes. Sendo um espaço aberto para alunos e professores, os fóruns devem ser utilizados como estratégia de comunicação e diálogo entre tais atores, fazendo com que eles se movimentem na busca de entendimento e produção do saber [Scherer, 2009].

Pesquisas recentes indicam que, quando bem concebidos, os fóruns motivam e melhoram a experiência de aprendizagem dos participantes, favorecendo o processo pedagógico e possibilitando ao aluno lograr êxito em cursos a distância [Abawajy, 2012]. Conforme este autor, o objetivo final de fóruns de discussão assíncrono é criar um ambiente de aprendizagem online para atingir altos níveis de aprendizagem e para isso, aponta algumas das principais características que podem influenciar e diferenciar os vários tipos de

fóruns de discussão: grau de interação; requisitos de participação; volume e frequência de postagens; *feedback* do professor e demais participantes.

A discussão é normalmente considerada uma poderosa ferramenta para desenvolver habilidades pedagógicas, como o pensamento crítico, colaboração e reflexão. Os fóruns de discussão oferecem muitas vantagens pedagógicas, como incentivo à reflexão, análise e pensamento de ordem superior.

3. Trabalhos Relacionados

Esta seção descreve alguns trabalhos relacionados ao propósito desta pesquisa e que são de grande relevância na área da MDE.

Kampff (2009) propõe uma arquitetura para sistemas de alertas, tanto pré-definidos como gerados a partir de mineração de dados, para identificar comportamentos e características de alunos com risco de evasão ou reprovação e alertar o professor. Para a autora, a avaliação da arquitetura apontou que as intervenções realizadas contribuíram para a redução dos índices de reprovação e evasão dos alunos na disciplina acompanhada.

Romero *et al.* (2013) desenvolveu uma ferramenta de mineração específica para o Moodle com o objetivo de prever notas finais de alunos em cursos nesse ambiente, além de facilitar ao professor a análise e compreensão dos resultados obtidos. Alguns experimentos foram realizados usando dados disponíveis (numéricos) e filtrados (filtro por linha, filtro por coluna e balanceados) de 438 alunos de 7 cursos de engenharia no Moodle da Universidade de Cordova. Para o autor, os resultados dos modelos obtidos usando dados categóricos e algoritmos de árvores de decisão são mais compreensíveis que aqueles que usam dados numéricos porque favorecem a compreensão e permitem ao professor fazer uma interpretação do modelo obtido para a tomada de decisão.

Santana (2014) propôs a aplicação de técnicas de classificação em um conjunto de dados de alunos de um curso na modalidade a distância para obter resultados como forma de apoio à tomada de decisão. Para isso, comparou algumas técnicas de classificação na interação Perfil de Uso do AVA, tendo como variável alvo o desempenho do aluno. Os resultados que foram considerados satisfatórios pelo autor foram gerados pela aplicação da técnica de árvore de decisão J48, que alcançou taxa de 74% de precisão.

4. Procedimentos Metodológicos para os Experimentos de Mineração de Dados e Visualização de Diagnóstico

Esta seção descreve os procedimentos metodológicos adotados para a realização dos experimentos de mineração de dados e visualização de diagnóstico a partir da ferramenta proposta neste trabalho.

Os experimentos foram realizados utilizando conjuntos de dados obtidos de um curso técnico em um Ava/Moodle de uma instituição de ensino. O curso escolhido foi o de Técnico em Informática, composto de 25 disciplinas e com um total de 1171 alunos. Dentre essas disciplinas, foi selecionada a de Sistemas Operacionais, oferecida no segundo módulo. Ela disponibilizou três fóruns de discussão e do quantitativo de alunos do curso,

considerou-se apenas 502 para a criação dos conjuntos de dados, porque eles participaram em algum momento da disciplina.

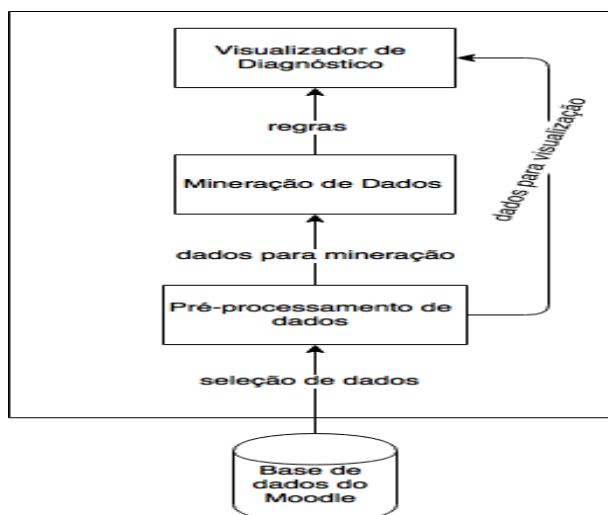


Figura 1. Arquitetura da ferramenta para visualização de diagnóstico de evasão

A **figura 1** mostra a arquitetura da ferramenta proposta e as subseções seguintes fazem sua descrição.

4.1 Pré-processamento de dados

A seleção de dados consistiu em obter os atributos que registram as interações dos alunos nos fóruns de discussão e a definição dos atributos de cada tupla foi realizada manualmente, considerando o quantitativo de participação em fóruns e as postagens nas discussões, conforme sugerido por Abawajy (2012), por representarem fortes indicadores de interação nesta atividade, sendo que a tabela de sumarização ficou com 9 atributos (ver **tabela 2**).

Tabela 2. Atributos da tabela de sumarização.

Atributo	Descrição
nota_media_em_foruns	nota média do aluno nos fóruns
qtd_posts_forum1	quantidade de postagens no fórum 1
qtd_posts_forum2	quantidade de postagens no fórum 2
qtd_posts_forum3	quantidade de postagens no fórum 3
total_foruns_por_aluno	total de fóruns que o aluno participou
total_posts_em_todos_os_foruns	total de postagens em todos os fóruns
media_posts_por_forum	média de postagens por fórum
desempenho	desempenho do aluno nos fóruns
resultado	resultado final do aluno na disciplina (atributo classe)

A distribuição das classes referentes ao resultado do primeiro conjunto de dados está assim apresentada: Aprovado Por Média = 288 (57,37%), Aprovado Por Final = 148

(29,48%), Reprovado Por Média = 63 (12,55%) e Reprovado Por Final = 3 (0,6%). Estas classes foram transformadas em apenas duas, sendo que foi mantida a classe Aprovado Por Média (doravante chamada de **A.P.M**), enquanto que as demais foram transformadas na classe Tendência à Evasão e Reprovação (doravante chamada de **T.E.R**), sendo obtida uma nova distribuição: A.P.M = 288 (57,37%) e T.E.R = 214 (42,63%).

Este procedimento foi adotado porque a aprovação por média é o que se espera de um aluno em uma situação ótima, entretanto, quando isso não acontece, significa que alguns fatores influenciaram para que o mesmo tivesse desempenho abaixo do esperado. Desta forma, a classe T.E.R representa os alunos nesta condição, sendo que o baixo desempenho pode ser também um forte indício de evasão do aluno.

Após isso, o primeiro conjunto de dados foi definido com 502 alunos e 9 atributos e corresponde aos dados originais. O segundo conjunto de dados foi obtido a partir do primeiro através de um filtro por linha, que consistiu em manter apenas os alunos que participaram de pelo menos um fórum da disciplina, o que resultou em apenas 353 alunos, sendo mantidos os 9 atributos e a distribuição das classes referentes ao resultado ficou assim: A.P.M = 247 (69,97%) e T.E.R = 106 (30,03%).

4.2 Mineração de Dados

O Weka (*Waikato Environment for Knowledge Analysis*) é uma API que disponibiliza uma variedade de algoritmos para as mais diversas tarefas de aprendizado de máquina. Neste trabalho, os modelos gerados a partir de árvores de decisão utilizaram os algoritmos **J48**, **BFTree** e **SimpleCart**, e os baseados em estatística utilizaram os algoritmos **BayesNet** e **NaiveBayes**, todos do Weka.

Foi aplicada ainda uma técnica de validação de dados, chamada *cross validation 10-folds*. Esta técnica consiste em dividir os dados em dez partições aleatórias, onde nove dessas partições são destinadas ao conjunto de treinamento e uma partição para o conjunto de testes [Romero *et al.*, 2013], possibilitando melhor avaliação do modelo obtido.

4.3 Visualização de Diagnóstico

Após a mineração de dados, as regras geradas pelos modelos baseados em árvore de decisão foram adaptadas para uso na ferramenta proposta e, juntamente com os dados de alunos utilizados na mineração, foram carregados na ferramenta para apresentar o diagnóstico.

Esta ferramenta representa uma ampliação da análise que se faz a partir do Weka, pois apresenta de forma mais detalhada quantitativos de alunos em cada tendência trabalhada, e na regra de classificação específica em que eles se inserem. Além do mais, possibilita ampliar a compreensão aos interessados diretos (professores, tutores, gestores, etc.) na tomada de decisão.

5. Análise dos Resultados

Os resultados obtidos nos experimentos de mineração de dados deste trabalho são analisados a partir da versão funcional da ferramenta proposta para a visualização de

diagnóstico como fins de teste e análise do seu funcionamento. Antes, porém, são apresentadas brevemente algumas taxas referentes ao desempenho dos classificadores, conforme mostrado na **tabela 3**.

Tabela 3. Desempenho dos classificadores nos experimentos.

Método	Algoritmo	dados originais			dados filtrados			Classe
		<i>Precision</i>	<i>Recall</i>	<i>F-Measure</i>	<i>Precision</i>	<i>Recall</i>	<i>F-Measure</i>	
Árvore de Decisão	J48	0,693	0,621	0,655	0,650	0,245	0,356	T.E.R
		0,739	0,795	0,766	0,744	0,943	0,832	A.P.M
		0,719	0,721	0,719	0,716	0,734	0,689	
	BFTree	0,659	0,640	0,649	0,579	0,311	0,405	T.E.R
		0,738	0,753	0,746	0,753	0,903	0,821	A.P.M
		0,704	0,705	0,705	0,701	0,725	0,696	
	SimpleCart	0,678	0,631	0,654	0,571	0,264	0,361	T.E.R
		0,739	0,778	0,758	0,743	0,915	0,820	A.P.M
		0,713	0,715	0,714	0,692	0,720	0,682	
Bayesianos	Naive Bayes	0,704	0,621	0,660	0,529	0,255	0,344	T.E.R
		0,741	0,806	0,772	0,738	0,903	0,812	A.P.M
		0,725	0,727	0,724	0,676	0,708	0,672	
	BayesNet	0,682	0,640	0,660	0,477	0,396	0,433	T.E.R
		0,744	0,778	0,761	0,758	0,814	0,785	A.P.M
		0,718	0,719	0,718	0,674	0,688	0,679	

Para a avaliação do desempenho dos algoritmos foram utilizadas as métricas *Precision* (percentual de amostras positivas classificadas corretamente sobre o total de amostras classificadas como positivas), *Recall* (percentual de amostras positivas classificadas corretamente sobre o total de amostras positivas) e *F-measure* (média ponderada de *Precision* e *Recall* e representa uma boa métrica para avaliar qual algoritmo utilizar). Os valores em negrito representam a média ponderada das medidas e permitem identificar mais facilmente o classificador com melhor desempenho.

Em dados originais, as taxas de *Precision* e *Recall* dos algoritmos nas classes trabalhadas se mantiveram com um bom equilíbrio, oscilando entre **0,62** e abaixo de **0,81**, enquanto que o *Recall* de todos os algoritmos para a classe T.E.R, referente a dados filtrados, ficou abaixo de **0,40**, embora a medida de *Precision* tenha oscilado entre **0,47** e **0,65**. O processo de filtragem piorou o *Recall* de T.E.R e isso pode ser atribuído, também, ao desbalanceamento que há entre as classes A.P.M e T.E.R. Além disso, a precisão do classificador fica menor quando há menos dados disponíveis [Romero *et al.*, 2013].

As técnicas baseadas em árvores de decisão obtiveram índices significativos de precisão nos experimentos realizados, sendo que o algoritmo J48, em geral, obteve as melhores médias nos experimentos (*Recall* = 0,721 e *F-Measure* = 0,719 com dados originais; *Recall* = 0,734 e *F-Measure* = 0,689 com dados filtrados).

5.1 Diagnóstico através da ferramenta desenvolvida para este trabalho

Na **figura 2** são exibidas as tendências geradas na árvore de decisão, juntamente com o total de alunos que fazem parte de cada uma dessas tendências. Através desta tela é possível ver quais alunos se inserem em cada tendência. Percebe-se que o percentual de alunos com tendência à aprovação na disciplina em estudo foi de 86,69%, enquanto que o percentual de alunos com tendência à evasão e reprovação correspondeu a 13,31%. O modelo preditivo utilizado nesta ferramenta indica ainda que a participação em fóruns pode ser considerada um forte indicador para um melhor desempenho do aluno.

ALUNOS COM TENDÊNCIA À EVASÃO E REPROVAÇÃO = 47 (13,31%)					
id_aluno	nota_media_em_foruns	qtd_posts_forum1	qtd_posts_forum2	qtd_posts_forum3	total_foruns_por_aluno
Aluno1180	5.33	1	1	1	3
Aluno1212	2.83	1	0	0	1
Aluno1217	3.00	1	0	0	1
Aluno1278	3.08	1	0	0	1

ALUNOS COM TENDÊNCIA À APROVAÇÃO = 306 (86,69%)					
id_aluno	nota_media_em_foruns	qtd_posts_forum1	qtd_posts_forum2	qtd_posts_forum3	total_foruns_por_aluno
Aluno1000	8.67	1	1	1	3
Aluno1001	8.00	1	1	1	3
Aluno1002	7.33	1	1	1	3
Aluno1004	7.50	1	1	1	3

Figura 2: Tela com as tendências de evasão, reprovação e aprovação de alunos.

TOTAL DE REGRAS GERADAS = 7	
1 - nota_media_em_foruns <= 5.33 and total_foruns_por_aluno <= 2 and qtd_posts_forum3 <= 0 and qtd_posts_forum2 <= 0 and nota_media_em_foruns <= 2.75: A.P.M (18.0/8.0)	<
2 - nota_media_em_foruns <= 5.33 and total_foruns_por_aluno <= 2 and qtd_posts_forum3 <= 0 and qtd_posts_forum2 <= 0 and nota_media_em_foruns > 2.75: T.E.R (27.0/8.0)	>
3 - nota_media_em_foruns <= 5.33 and total_foruns_por_aluno <= 2 and qtd_posts_forum3 <= 0 and qtd_posts_forum2 > 0 and qtd_posts_forum2 <= 1: A.P.M (13.0/4.0)	>
4 - nota_media_em_foruns <= 5.33 and total_foruns_por_aluno <= 2 and qtd_posts_forum3 <= 0 and qtd_posts_forum2 > 0 and qtd_posts_forum2 > 1: T.E.R (4.0/1.0)	>
Total de alunos desta regra = 4	
idAluno	
Aluno1303	
Aluno570	
Aluno576	
Aluno613	
5 - nota_media_em_foruns <= 5.33 and total_foruns_por_aluno <= 2 and qtd_posts_forum3 > 0: A.P.M (6.0/1.0)	>
6 - nota_media_em_foruns <= 5.33 and total_foruns_por_aluno > 2: T.E.R (10.0)	<
7 - nota_media_em_foruns > 5.33: A.P.M (275.0/63.0)	>

Figura 3: Tela com as regras de classificação adaptadas a partir do algoritmo J48.

A **figura 3** mostra a tela onde são exibidas as regras geradas na árvore de decisão, bem como o total de alunos que fazem parte de cada regra e, como visto, o algoritmo gerou uma árvore de decisão composta por 7 regras. Conforme tratado por Abawajy (2012), os fóruns podem motivar e melhorar a experiência de aprendizagem dos participantes, favorecendo o processo pedagógico, além de possibilitar ao aluno lograr êxito em cursos a distância. Nesse sentido, as regras de classificação, para o contexto deste trabalho,

corroboraram o argumento do autor, uma vez que a maioria dos alunos que participaram dos fóruns de discussão da disciplina em estudo obteve aprovação.

Através das regras de classificação geradas pelo algoritmo J48 é possível apontar quais fatores são mais indicativos para diagnosticar alunos com tendência à evasão e reprovação. Elas indicam, principalmente, que a **nota média em fóruns**, o **total de fóruns por aluno** e **quantidade de postagens nos fóruns 2 e 3**, foram fatores importantes para definir o resultado do aluno na disciplina.

Cada regra gerou um quantitativo de alunos e ao observá-las mais a fundo, vê-se que aqueles cuja nota média em fóruns foi maior que 5.33 foram aprovados sem depender de outras condições, perfazendo um total de 275 alunos (**regra 7**). Os alunos que obtiveram nota média em fóruns menor que 5.33 e participaram de até 2 fóruns foram classificados como com tendência à evasão e reprovação, num total de 6 (**regra 6**). Nas demais regras, houve um número maior de indicadores que influenciaram no resultado final do aluno.

A partir da análise das regras é possível observar a distribuição das classes em cada regra, e como pode-se ver, a classe A.P.M está distribuída em quatro das 7 regras obtidas (**regras 1, 3, 5 e 7**), sendo que a classe T.E.R está presente nas **regras 2, 4 e 6**.

6. Conclusões e Trabalhos Futuros

Este trabalho investigou como os dados armazenados em um AVA podem ser transformados em informações potencialmente úteis para apoiar o acompanhamento de alunos em cursos EAD. Através dos experimentos realizados buscou-se obter um modelo preditivo com alta precisão que fosse capaz de prever quando um aluno apresenta características tendenciosas à evasão a partir de suas interações em fóruns de discussão.

As técnicas baseadas em árvores de decisão são recomendadas no contexto educacional, uma vez que elas geram um resultado mais compreensível e fácil de interpretar ao usuário que as utilizar para a tomada de decisão [Romero *et al.*, 2013]. Desta forma, são as mais indicadas, dentre as testadas, para a geração de um diagnóstico mais preciso das tendências de evasão e reprovação de alunos. Os modelos gerados a partir de dados filtrados apresentaram baixo *Recall* na classe T.E.R, enquanto que esta mesma medida em modelos gerados com dados originais ficou bem mais equilibrada. A partir dos modelos gerados por árvore de decisão foi possível criar um diagnóstico mais detalhado dessas tendências para auxiliar as partes interessadas na tomada de decisão.

A ferramenta apresentada neste trabalho ainda não está finalizada, apesar das funções que possui. Como trabalhos futuros, pretende-se adicionar novas funcionalidades a ela e, para isso, seguem alguns desafios: mostrar a situação individual de cada aluno de forma mais detalhada, implementar a exibição dos indicadores de evasão e reprovação, integrá-la como um módulo do Moodle, dentre outros.

Através da mineração de dados em AVA's é possível verificar a relação entre uma abordagem pedagógica e o aprendizado do aluno, a fim de que o professor avalie se sua

abordagem realmente está ajudando ou não o aluno a ter um bom desempenho nas atividades propostas.

Agradecimentos

Este trabalho foi financiado pela Fundação de Amparo à Pesquisa do Maranhão - FAPEMA e Fundação de Apoio ao Ensino, Pesquisa e Extensão - FAPEAD. O trabalho teve ainda como co-autor Lanyllo Araujo dos Santos (Universidade Estadual do Maranhão - UEMA).

Referências

- ABAWAJY, J. Analysis of Asynchronous Online Discussion Forums for Collaborative Learning. **International Journal of Education and Learning**, v. 1, n. 2, p. 2012.
- ABBAD, Gardênia da Silva; ZERBINI, Thais; SOUZA, Daniela Borges Lima de. **Panorama das pesquisas em educação a distância no Brasil**. In: Estudos de Psicologia, 15(3), setembro-dezembro/2010. Disponível em: <<http://www.scielo.br/pdf/epsic/v15n3/a09v15n3.pdf>>. Acesso em: 15 out. 2015.
- ASSOCIAÇÃO BRASILEIRA DE EDUCAÇÃO A DISTÂNCIA. **Censo EAD.BR. Relatório Analítico da aprendizagem a distância no Brasil 2013**. Disponível em: http://www.abed.org.br/censoead2013/CENSO_EAD_2013_PORTUGUES.pdf. Acesso em 24 abr 2015.
- KAMPPFF, A. J. C. **Mineração de Dados Educacionais para Geração de Alertas em Ambientes Virtuais de Aprendizagem como Apoio à Prática Docente**. 2009. Tese (Doutorado) – PPGIE/UFRGS.
- MOODLE Org. Community driven, globally supported (2015). Disponível em: <<https://moodle.org/>>. Acesso em: 20 abr. 2015.
- ROMERO, C., VENTURA, S., G, ENRIQUE. (2008). **Data mining in course management systems: Moodle case study and tutorial**. Computers & Education, 51(1): 368–384.
- _____, VERA, C., M., SOTO, S., V. Predicción del Fracaso Escolar mediante Técnicas de Minería de Datos. **IEEE-RITA Vol. 7, Núm. 3, Nov. 2012**.
- _____. ESPEJO, P., G, P. G., ZAFRA . A. (2013). **Web usage mining for predicting final marks of students that use Moodle courses**. Disponível em: <<https://www.deepdyve.com/lp/wiley/web-usage-mining-for-predicting-final-marks-of-students-that-use-moodle-courses-P23vC7HY6h/1>>. Acesso em 23 de abril de 2015.
- SANTANA, Leandro, C. (2014). Avaliação do Perfil de Uso no Ambiente Moodle Utilizando Técnicas de Mineração de Dados. **Revista Brasileira de Informática na Educação. Pág. 269**.
- SCHERER, Suely. **Educação bimodal: habitantes, visitantes ou transeuntes?** In: VALENTE, J. A. e BUSTAMANTE, S. B. V. Educação a Distância: prática e formação do profissional reflexivo. São Paulo: Avercamp, 2009. 259 p.