

Avaliação de Desempenho de Estudantes em Cursos de Educação a Distância Utilizando Mineração de Dados

Ernani Gottardo¹, Celso Kaestner², Robinson Vida Noronha²

¹Instituto Federal de Educação Ciência e Tecnologia do RS (IFRS)
CEP 99.700-000 – Erechim – RS – Brasil

²Universidade Tecnológica Federal do Paraná (UTFPR)
CEP 80.230-901 – Curitiba – PR – Brasil.

ernani.gottardo@erechim.ifrs.edu.br, {celsokaestner,vida}@utfpr.edu.br

Abstract. *For development of distance learning courses, using a Learning Management System (LMS) has become essential. These environments store large volumes of data about activities developed by students. These data can be used in conjunction with Data Mining techniques to discover information to help teachers in managing the learning process. In this work we propose to define a broad and generalized set of attributes to be used to make inferences regarding the performance of students. Experiments have shown the feasibility of this proposal, reaching rates of 76% accuracy in predicting performance.*

Resumo. *Para o desenvolvimento de cursos a distância a utilização de um Ambiente Virtual de Aprendizado (AVA) tornou-se fundamental. Estes ambientes armazenam grandes volumes de dados relativos às atividades desenvolvidas pelos estudantes. Estes dados podem ser utilizados juntamente com técnicas de Mineração de Dados para a descoberta de informações que auxiliem professores na gestão do processo de ensino. Neste trabalho propõe-se a definição de um conjunto de atributos amplo e generalizável a ser utilizado para realizar inferências relativas ao desempenho de estudantes. Experimentos realizados demonstraram a viabilidade desta proposta, atingindo-se índices de 76% de acerto na previsão de desempenho.*

1. Introdução

O crescente uso de softwares de apoio à atividade educacional bem como a utilização de bancos de dados com informações de estudantes têm oferecido desafios aos profissionais de Informática em Educação. Um desses desafios refere-se a como manipular de maneira significativa grandes volumes de informações sobre os estudantes armazenadas nesses repositórios.

Essas informações incluem desde registros de acesso e interações com o sistema, até dados com ricos significados semânticos, como respostas a testes ou participações em fóruns e *chats* (Holliman e Scanlon, 2006; Macfadyen e Dawson, 2010; Romero e Ventura, 2010; Romero-Zaldivar et al., 2012; Merceron e Yacef, 2005).

Identificar as informações relevantes em uma base de dados dessa natureza não é uma tarefa simples e não há relatos de modelos que definem claramente este processo. O professor que deseja obter informações a respeito do desempenho dos estudantes

enfrentará um conjunto de tabelas e dados que, a priori, são de difícil interpretação. Esse professor poderia ser motivado pelas seguintes perguntas:

- Como acompanhar efetivamente um estudante?
- Como verificar se os estudantes estão interagindo entre si?
- Como identificar estudantes com problemas de desempenho?
- Como identificar estudantes desmotivados ou prestes a abandonar o curso?

Haveria uma forma de auxiliar um professor interessado em possíveis respostas para as questões acima? Este trabalho apresenta um estudo preliminar do uso de algumas técnicas de Mineração de Dados em uma base de dados do sistema Moodle (Moodle, 2012). Busca-se, a longo prazo, definir um modelo de análise, inferência ou previsão do comportamento dos aprendizes. Busca-se, a curto prazo, identificar quais parâmetros dessa base de dados possibilitariam uma inferência sobre desempenho futuro dos estudantes.

Na descrição dos resultados deste trabalho, este documento está estruturado em 7 seções. Na Seção 2, analisam-se os trabalhos correlatos. Na seção 3, apresentam-se os critérios utilizados para definição do conjunto de atributos para representação de estudantes. Na seção 4 e 5, são apresentadas, respectivamente, a contextualização e descrição dos experimentos realizados. Na Seção 6, os dados coletados são apresentados em tabelas e analisados. Finalmente, na Seção 7, apresentam-se as conclusões e perspectivas de continuidade deste trabalho.

2. Trabalhos Relacionados

Mineração de Dados é definida por Witten, Frank e Hall (2011) como o processo de descoberta de padrões a partir de um conjunto de dados. Fayyad, Piatetsky-Shapiro e Smyth (1996), completam que os padrões descobertos precisam revelar alguma novidade e serem potencialmente úteis de forma a trazer algum benefício para o usuário ou tarefa a ser desenvolvida.

A técnica de Mineração de Dados utilizada neste trabalho é conhecida como classificação. Segundo Witten, Frank e Hall (2011), técnicas de classificação têm por objetivo desenvolver modelos que possam inferir um aspecto particular dos dados (variável a ser prevista) através de alguma combinação de outros aspectos destes dados (variáveis preditoras).

O processo utilizado para aplicação de técnicas de Mineração de Dados em ambientes educacionais não difere muito da aplicação dessas técnicas em áreas tradicionais como, por exemplo, comércio eletrônico, genética e medicina (Romero e Ventura (2010). Entretanto, os referidos autores destacam que algumas características singulares relativas à área educacional requerem a adaptação de algumas técnicas para o problema específico a ser tratado.

Hämäläinen e Vinni (2011) relatam que em muitas situações de utilização de técnicas de Mineração de Dados Educacionais ou *Educational Data Mining – EDM*, o volume de dados disponíveis pode ser considerado pequeno e o número de atributos grandes, quando comparados com outras áreas que fazem uso de Mineração de Dados.

Técnicas de Mineração de Dados educacionais, segundo Baker, Isotani e Carvalho (2011), têm sido frequentemente utilizadas para: i) fornecer suporte e mensagens de *feedback* a professores; ii) recomendações a estudantes; iii) identificação de grupos de estudantes com características comuns; iv) previsão de desempenho ou risco de evasão.

Romero, Ventura e García (2008) apresentaram um estudo evidenciando as possibilidades de utilização de diversas técnicas de Mineração de Dados tais como, classificação, agrupamento, regras de associação para a extração de informações relevantes sobre estudantes no contexto educacional.

Minaei-Bidgoli et al. (2003) demonstraram a aplicação da CMC (*Combination of Multiple Classifiers*) para classificar estudantes de acordo com a previsão de nota final. Segundo os autores, esta técnica apresentou melhores resultados quando comparada a aplicação de classificadores individualmente.

Nesta linha, outros trabalhos foram desenvolvidos com o objetivo de comparar o desempenho de diversas técnicas de Mineração de Dados aplicadas a problemas de previsão de desempenho (Ibrahim e Rusli, 2007; Kotsiantis, 2012; Romero-Zaldivar et al., 2012) e risco de evasão (Manhães et al., 2011). Os resultados relatados nestas pesquisas demonstram que diversas técnicas de mineração podem ser utilizadas com sucesso no contexto educacional para previsão de desempenho ou risco de evasão.

Como o foco dos trabalhos destacados acima é a comparação de diferentes algoritmos ou técnicas de aprendizagem de máquina, os autores utilizaram um conjunto restrito de atributos. Este conjunto de atributos não reflete todos os aspectos de interação, atividades e tarefas normalmente desenvolvidas por um estudante em um Ambiente Virtual de Aprendizagem (AVA).

Utilizando pesquisas recentes envolvendo previsão de desempenho, Hämäläinen e Vinni (2011) realizaram um estudo para verificar as taxas de acurácia obtidas nestas pesquisas. Os referidos autores destacam que devido às características particulares dos estudos existem variações entre os resultados observados. Porém, destacam que a média de acurácia foi de 72% entre as pesquisas consideradas.

Algumas pesquisas têm relatado o uso, com relativo sucesso, de métodos de EDM para inferir a relação existente entre o estado emocional de estudantes e o desempenho apresentado por esses estudantes (Mcquiggan, Mott e Lester, 2008; D'Mello et al., 2008).

Utilizar técnicas de Mineração de Dados para identificar quando um estudante está tentando manipular o sistema foi o objetivo do trabalho de Baker et al. (2006). Um exemplo de tentativa de manipular é o fato de um estudante solicitar repetidas vezes ajuda do ambiente computacional antes mesmo de tentar resolver a questão.

Levando-se em consideração a natureza social do aprendizado, algumas pesquisas (Li e Huang, 2008; Macfadyen e Dawson, 2010; Rabbany, Takaffoli e Zaiane, 2011) têm focado no estudo de como estudantes participam e interagem em um ambiente de aprendizagem virtual.

Destaca-se nesta abordagem de pesquisa o trabalho de Rabbany, Takaffoli e Zaiane (2011) que investigaram a importância da análise de redes sociais, enfocando a utilização da técnica chamada de “mineração de comunidades”. Esta técnica foi

utilizada para o estudo e descoberta de estruturas relevantes em fóruns de discussão. O referido trabalho envolveu o desenvolvimento de uma aplicação que permite a visualização dos participantes em um fórum de discussão, suas interações, destacando diferentes papéis assumidos pelos estudantes.

3. Representação de Estudantes em um Sistema Virtual

Para a definição e estruturação do modelo de processo de previsão de desempenho, um conjunto de atributos possíveis de serem extraídos de um AVA é proposto neste trabalho. Os atributos propostos são agrupados em três dimensões, descritas a seguir, buscando-se contemplar diversos aspectos de uso e interação do estudante no AVA:

- **Primeira Dimensão: perfil geral de uso do AVA:** nesta dimensão o objetivo é identificar dados que representem aspectos de planejamento, organização e gestão do tempo do estudante para a realização do curso. Para isso definiu-se indicadores gerais de quantidade e tempo médio de acessos aos recursos do AVA. Foram incluídos também atributos que representem atividades rotineiras e regulares dos acessos dos aprendizes.
- **Segunda Dimensão: interação Estudante-Estudante:** com esta dimensão pretende-se verificar se os estudantes interagem entre si usando as ferramentas disponíveis, como fóruns, chats, envio ou recebimento de mensagens. Espera-se, com estes atributos, identificar a existência de colaboração e cooperação entre estudantes. Fato esse denominado por Schrire (2006) como “aprendendo com os outros” (em inglês *learning with others*).
- **Terceira Dimensão: interação Estudante-Professor:** nesta dimensão o objetivo é averiguar como professores ou tutores interagem com estudantes no contexto do AVA. Este tipo de interação tem sua importância destacada por Holliman e Scanlon (2006). Esses autores ressaltam que professores ou tutores têm um papel fundamental no sentido de facilitar e incentivar a colaboração entre estudantes.

4. Contextualização dos Experimentos

Com o objetivo de verificar a adequação do conjunto de atributos propostos, realizaram-se experimentos com uma base de dados Moodle, contendo informações de estudantes em um curso realizado a distância. Nos experimentos não foram incluídos estudantes desistentes, tendo em vista a indisponibilidade de resultado ou nota final nestes casos.

Selecionou-se a partir da base de dados uma disciplina, considerando-se os seguintes requisitos:

- maior quantidade de estudantes que concluíram a disciplina;
- maior quantidade de oferta da disciplina para turmas diferentes;
- disponibilidade do resultado de avaliações do conhecimento dos estudantes e
- maior número de recursos do AVA utilizados.

Baseando-se nos critérios apresentados acima, escolheu-se uma disciplina com um total de 155 estudantes concluintes em quatro turmas diferentes. A partir da identificação da disciplina e turmas objetos de estudo, foram desenvolvidos

procedimentos para extração dos atributos considerados significativos neste trabalho. A Tabela 1 apresenta esses atributos agrupados nas três dimensões propostas na Seção 3 e os descreve de maneira sucinta.

Tabela 1. Atributos propostos para representação de estudantes

Dimensão	Atributo	Descrição
Perfil Geral de uso do AVA	nr_aceessos	Número total de acesso ao AVA
	nr_posts_foruns	Número total de postagens realizadas em fóruns
	nr_post_resp_foruns	Número total de respostas postadas em fóruns referindo-se a postagens de outros participantes (estudantes, professores, tutores)
	nr_post_rev_foruns	Número total de revisões em postagens anteriores realizadas em fóruns
	nr_sessao_chat	Número de sessões de chat que o estudante participou
	nr_msg_env_chat	Número de mensagens enviadas ao chat
	nr_questoes_resp	Número de questões respondidas
	nr_questoes_acert	Número de questões respondidas corretamente
	freq_media_aceesso	Frequência média em que o estudante acessa o AVA
	tempo_medio_aceesso	Tempo médio de acesso ao sistema
	nr_dias_prim_aceesso	Número de dias transcorridos entre o início do curso e o primeiro acesso do estudante no AVA
Interação Estudante-Estudante	tempo_total_aceesso	Tempo total conectado no sistema
	nr_post_rec_foruns	Número de postagens do estudante que tiveram respostas feitas por outros estudantes.
	nr_post_resp_foruns	Número de respostas que o estudante realizou em postagens feitas por outros estudantes.
	nr_msg_rec	Número de mensagens recebidas de outros participantes durante a realização do curso.
Interação Estudante-Professor	nr_msg_env	Número de mensagens enviadas a outros participantes durante a realização do curso.
	nr_post_resp_prof_foruns	Número de postagens de estudantes que tiveram respostas feitas por professores ou tutores do curso
	nr_post_env_prof_foruns	Número de postagens de professores ou tutores que tiveram respostas feitas por estudantes
	nr_msg_env_prof	Número de mensagens enviadas ao professor/tutor durante a realização do curso.
Objetivo da Previsão	nr_msg_rec_prof	Número de mensagens recebidas do professor/tutor durante a realização do curso.
	resultado_final	Resultado final obtido pelo estudante no curso. <u>Representa classe objetivo da técnica de classificação.</u>

Destaca-se que os atributos definidos para capturar aspectos de interação relativos aos fóruns de discussão podem apresentar resultados imprecisos em caso de má utilização do AVA. Como exemplo, cita-se o caso em que um estudante cria um novo tópico no fórum ao invés de responder a uma postagem de um colega ou professor.

É importante observar que o último atributo da Tabela 1, “Resultado_Final”, representa a classe objetivo do processo de classificação. Originalmente, este atributo é representado por valores contínuos. Entretanto, algumas técnicas de classificação requerem que o atributo que representa a classe seja um valor discreto.

Para viabilizar a utilização de alguns tipos de métodos e também para facilitar a interpretação dos resultados, foi realizado procedimento de transformação deste atributo. Utilizou-se para isso a técnica conhecida como discretização (Witten, Frank e Hall, 2011).

Esta tarefa foi executada através do algoritmo de discretização não-supervisionada disponível na ferramenta Weka (Witten, Frank e Hall, 2011). Utilizou-se o método padrão de discretização desta ferramenta conhecido como *equal-width*, que divide o intervalo de valores possíveis em subintervalos de mesmo tamanho.

O número de subintervalos pode ser parametrizado, sendo que neste estudo utilizou-se o valor 3. Este valor foi definido com o objetivo de facilitar a interpretação dos resultados sem prejudicar a identificação de grupos distintos de estudantes baseados em seu desempenho.

Como resultado deste processo, três classes foram criadas. A Tabela 2 apresenta as características individuais de cada classe. A primeira e segunda coluna desta tabela apresentam, respectivamente, o rótulo e a descrição de cada classe. Na sequência, são destacados o número de estudantes e o intervalo de notas para cada uma das classes.

Tabela 2. Distribuição das classes obtidas pelo processo de discretização

Título da Classe	Descrição	Número de Estudantes	Intervalo de Notas
A	Estudantes com desempenho superior	22	87-97
B	Estudantes com desempenho intermediário	109	77-87
C	Estudantes com desempenho inferior	24	67-77

5. Experimentos Realizados

O objetivo principal dos experimentos é verificar a relevância dos atributos propostos na Tabela 1. Busca-se também analisar o impacto da aplicação de técnicas de discretização e seleção de atributos na acurácia da previsão de desempenho de dois classificadores.

Define-se acurácia a proporção entre o número de estudantes corretamente classificados pelos algoritmos em sua respectiva classe e o número total de estudantes considerados no estudo.

Para o desenvolvimento dos experimentos foram utilizados os algoritmos de classificação RandomForest e MultilayerPerceptron (Witten, Frank e Hall, 2011). Esta escolha baseia-se nas conclusões apresentadas por trabalhos correlatos destacados na Seção 2 que demonstraram que estes dois algoritmos obtiveram os melhores resultados.

Para o cálculo da acurácia utilizou-se o método conhecido como “K - *fold Cross-Validation*” (Witten, Frank e Hall, 2011) que consiste de uma técnica para a estratificação da base dados em conjunto de treinamento e teste. Segundo estudos relatados pelos mesmos autores, sugere-se a adoção do número 10 como valor padrão para o número de partições dos dados - K. Adicionalmente, cada algoritmo foi executado 10 vezes, considerando-se a média das execuções como o desempenho final do algoritmo. Desta forma, em cada experimento o classificador foi executado 100 vezes para cada conjunto de treinamento e testes.

No experimento 1, foi utilizado o conjunto de atributos conforme apresentado na Tabela 1. Destaca-se apenas a execução do procedimento já apresentado de transformação do último parâmetro da Tabela 1 para valores discretos.

Para o experimento 2, foram utilizados todos os atributos apresentados na Tabela 1 transformados para valores discretos. Esta alternativa baseia-se no fato de que alguns algoritmos de Mineração de Dados, mesmo os capazes de trabalhar com valores contínuos, podem apresentar melhores resultados quando se utiliza valores discretos (Witten, Frank e Hall, 2011). Desta forma, foi executado processo de discretização supervisionado dos atributos da base de dados original, utilizando-se o algoritmo padrão da ferramenta Weka. Este algoritmo é baseado em Fayyad e Irani (1993).

Witten, Frank e Hall (2011) destacam que muitos algoritmos são projetados para identificar os atributos mais apropriados a serem utilizados em suas decisões. Na prática, entretanto, esses autores destacam que a inclusão de atributos irrelevantes em um conjunto de dados frequentemente tem um impacto negativo.

Desta forma, o experimento 3 foi realizado utilizando-se apenas um subconjunto dos atributos propostos na Tabela 1. Neste processo, utilizou-se o algoritmo de seleção de atributos supervisionado padrão da ferramenta Weka, baseado em Hall (1998). Este algoritmo utiliza abordagem baseada em correlação, considerando que um bom conjunto de características contém atributos que apresentam alta correlação com a classe e baixa correlação entre si. A execução deste algoritmo resultou na identificação dos seguintes atributos:

- NR_LOGINS;
- NR_MSG_REC_PROF;
- NR_CHATS e
- NR_MSG_CHAT.

A Tabela 3 apresenta um resumo com os resultados dos experimentos executados. Nela, o percentual de acurácia médio e o desvio padrão de 100 execuções são apresentados para cada algoritmo e experimento realizado.

Tabela 3. Acurácia média e desvio padrão em 100 execuções dos classificadores utilizados nos experimentos

Classificador	Experimento 1	Experimento 2	Experimento 3
RandonForest	70,6% ± 9,9	76,6% ± 8,5	64,9% ± 10,8
MultilayerPerceptron	66,3% ± 10,5	76,2% ± 8,8	69,4% ± 8,8

6. Análise dos Resultados

Avaliando-se os resultados obtidos e descritos na Tabela 3 percebe-se que, em números absolutos, a utilização do conjunto completo de atributos proposto, juntamente com a técnica de discretização empregada no experimento 2, obteve os melhores resultados em termos de acurácia. Destaca-se que nos dois classificadores utilizados neste experimento esta tendência pode ser observada.

O experimento 3 considerou apenas o conjunto dos 4 atributos mais relevantes apresentados na Seção 5 deste artigo. Conforme apresentado na quarta coluna da Tabela 3, os resultados indicam um menor índice de acurácia para os dois algoritmos investigados, quando comparados com o experimento 2.

Com o objetivo de testar a significância estatística dos resultados obtidos, utilizou-se a técnica de teste estatístico T pareado – “*pair-wise T-Test*” (Witten, Frank e Hall, 2011) com nível significância de 5%. Para a realização deste teste utilizou-se o ambiente *Weka Experiment Environment* – WEE, disponível na ferramenta Weka.

A partir do resultado deste teste, tomando-se como base ou *baseline* o experimento 2, observou-se que:

- Os resultados do experimento 2 foram superiores ao do experimento 3 para os dois algoritmos testados.
- Os resultados do experimento 2 foram superiores ao do experimento 1 para o algoritmo *MultilayerPerceptron*, porém não apresentaram diferença estatisticamente significativa para o algoritmo *RandomForest*.

O principal aspecto a ser destacado a partir destes testes refere-se aos resultados superiores obtidos pelo experimento 2 em relação ao experimento 3. Este fato aponta para a viabilidade da utilização de um conjunto amplo de atributos para representação de estudantes, potencialmente generalizáveis a diversos cenários de cursos EAD.

Destaca-se ainda que as taxas de acurácia entre 76,6% e 76,2% alcançadas no experimento 2 foram superiores às taxas médias de 72% obtidas em trabalhos correlatos pesquisados por Hämäläinen e Vinni (2011).

7. Conclusões e Trabalhos Futuros

Os resultados obtidos com os experimentos realizados apontam para uma possível viabilidade de se realizar inferências relativas ao desempenho de estudantes. Estas inferências poderiam ser úteis para professores: i) acompanhar de maneira individual os estudantes que utilizam um AVA; ii) para definir estratégias pedagógicas específicas que busquem minimizar reprovações.

Mesmo considerando-se um conjunto grande de atributos, obtiveram-se resultados expressivos em termos de acurácia das inferências com os dois algoritmos utilizados. Este resultado torna-se relevante, pois aponta para a possibilidade de utilizar um conjunto amplo de atributos que representem de forma abrangente e generalizável um estudante, considerando a diversidade de cursos EAD existentes.

Os resultados iniciais obtidos nesta pesquisa apontam para a viabilidade de investigações futuras considerando-se a aplicação de procedimentos semelhantes em diferentes cursos, buscando verificar ou ampliar a generalização do conjunto de

atributos propostos. Adicionalmente, considera-se relevante o desenvolvimento de estudos considerando a definição de custos diferentes para erros de classificação para cada classe e a investigação de cenários com diferentes números de classes.

A partir da definição deste conjunto de atributos espera-se que novos esforços sejam feitos em futuras pesquisas na tentativa de dotar os AVAs de recursos inteligentes. Esses recursos poderiam ser de monitoramento e adaptação de conteúdo ou monitoramento dos estudantes na expectativa de identificar casos com risco de desempenho insatisfatório.

Futuros trabalhos poderiam ainda ser desenvolvidos no sentido de avaliar a ampliação do conjunto de atributos propostos, considerando a inclusão de informações relativas às atividades desenvolvidas pelos estudantes fora do AVA. Estas atividades poderiam incluir a utilização de ferramentas específicas de um determinado curso ou mesmo utilizações de Redes Sociais, email, entre outros.

Referências

- Baker, R.S.J.D., Corbett, A.T., Koedinger, K.R., Evenson, S.E., Roll, I., Wagner, A.Z., Naim, M., Raspat, J., Baker, D.J., Beck, J. (2006) “Adapting to When Students Game an Intelligent Tutoring System”. In Proceedings of the International Conference on Intelligent Tutoring Systems, p. 392-401.
- Baker, R.S.J.D., Isotani, S., Carvalho, A.M.J.B.D. (2011) “Mineração de Dados Educacionais: Oportunidades para o Brasil”. Revista Brasileira de Informática na Educação, vol. 19, no. 2, p. 2-13.
- D'mello, S.K., Craig, S.D., Witherspoon, A.W., Mcdaniel, B.T., Graesser, A.C. (2008) “Automatic Detection of Learner’s Affect from Conversational Cues”. User Modeling and User-Adapted Interaction, p. 45-80.
- Fayyad, U. M., Irani, K.B. (1993) “Multi-interval Discretization of Continuous Valued Attributes for Classification Learning”. In: Thirteenth International Joint Conference on Artificial Intelligence, p. 1022-1027.
- Fayyad, U.M., Piatetsky-Shapiro, G., Smyth, P. (1996) “The KDD Process for Extracting Useful Knowledge from Volumes of Data”. Communications of ACM, vol. 39, no. 11, p. 27-34.
- Hall, M. A. (1998) “Correlation-based Feature Subset Selection for Machine Learning”. The University of Waikato, Hamilton, New Zealand.
- Hämäläinen, W., Vinni, M. (2011) “Classifiers for Educational Data Mining”. In: Romero et al. Handbook of Educational Data Mining. Flórida, CRC Press, p. 57-71.
- Holliman, R. Scanlon, E. (2006) “Investigating Cooperation and Collaboration in Near Synchronous Computer Mediated Conferences”. Computers & Education, no. 46, p. 322-335.
- Ibrahim, Z., Rusli, D. (2007) “Predicting students’ Academic Performance: Comparing Artificial Neural Network, Decision Tree and Linear Regression”, In Proceedings of the 21° Annual SAS Malaysia Forum, Kuala Lumpur, Malaysia, p. 1–6.

- Kotsiantis, S.B. (2012) "Use of Machine Learning Techniques for Educational Proposes: A Decision Support System for Forecasting Student's Grades". *Artificial Intelligence Review*, vol.37, no. 4, p. 331-344.
- Li, Y. Huang, R. (2008) "Analyzing Peer Interaction in Computer-Supported Collaborative Learning: Model, Method and Tool". *Lecture Notes in Computer Science (LNCS)*. no. 5169, p. 125-136.
- Macfadyen, L.P., Dawson, S. (2010) "Mining LMS Data to Develop an 'Early Warning System' for Educators: A Proof of Concept". *Computers & Education*, no. 54, p. 588-599.
- Manhães, L.M.B., Cruz, S.M.S., Costa, R.J.M, Zavaleta, J., Zimbrão, G. (2011) "Previsão de Estudantes com Risco de Evasão Utilizando Técnicas de Mineração de Dados". *Anais do XXII SBIE-XVII WIE*, p. 150-159.
- Mcquiggan, S., Mott, B., Lester, J. (2008) "Modeling Self-Efficacy in Intelligent Tutoring Systems: An Inductive Approach". *User Modeling and User-Adapted Interaction*, vol.18, p. 81-123.
- Merceron, A., Yacef, K. (2005) "Educational Data Mining: a Case Study". *Artificial Intelligence in Education*. In *Proceedings of the 12th International Conference on Artificial Intelligence*, p. 467-474.
- Minaei-Bidgoli, B., Kashy, A.D., Kortemeyer, G., Punch, F.W. (2003) "Predicting Student Performance: An Application of Data Mining Methods with the Educational Web-Based System LON-CAPA". *33^a ASEE/IEEE Frontiers in Education Conference*, p. 1-6.
- Moodle (2012), disponível em <<http://moodle.org>>. Acesso em 24/03/2012.
- Rabbany, R.K., Takaffoli M., Zaïane, O.R. (2011) "Analyzing Participation of Students in Online Courses Using Social Network Analysis Techniques". In *Proceedings of the Fourth International Conference on Educational Data Mining*, p. 22-30.
- Romero, C. Ventura, S., García, E. (2008) "Data Mining in Course Management Systems: Moodle Case Study and Tutorial". *Computers & Education*, no. 51, p. 368-384.
- Romero, C. Ventura, S. (2010) "Educational Data Mining: A Review of the State of Art". *IEEE Transactions on Systems, Man, and Cybernetics – Part C: Application and Reviews*. vol. 40, no. 6, p. 601-618.
- Romero-Zaldivar, V.A., Pardo, A., Burgos, D., Kloos, C.D. (2012) "Monitoring Student Progress Using Virtual Appliances: A Case Study". *Computers & Education*, no. 58, p. 1058-1067.
- Schrire, S. Knowledge. (2006) "Building in Asynchronous Discussion Groups: Going Beyond Quantitative Analysis". *Computers & Education*, vol. 46, no. 1, p. 49–70.
- Witten, I.H., Frank E., Hall, M.A. (2011) *Data Mining: Practical Machine Learning Tools and Techniques*. San Francisco: Morgan Kaufmann, 3 ed.