

Análise de evidências do estado de ânimo desanimado de alunos de um AVEA: uma proposta a partir da aplicação de regras de associação

**Fabírcia Damando Santos^{1,2}, Magda Bercht¹,
Leandro Krug Wives¹, Silvio César Cazella³**

¹PGIE – Universidade Federal do Rio Grande do Sul (UFRGS)

²Universidade Estadual do Rio Grande do Sul (UERGS)

³Universidade Federal de Ciências da Saúde de Porto Alegre (UFCSPA)

fabriciadamando@gmail.com, bercht@inf.ufrgs.br, wives@inf.ufrgs.br,
Silvio.cazella@gmail.com

Abstract. *This paper reports a research of students interacting in a virtual learning environment to discover discouraged student behavior patterns using educational data mining. The main objective was to show discouragement, when the student makes individual or group activities, using the task of association rules. As a result, it became clear that discouraged students sent less than 50% of the activities and had difficulty with the subject matter, which was show in the final grade. Eventually, these rules will be implemented computationally, to support the teacher in analysis of student's state of mood.*

Resumo. *Este artigo apresenta uma pesquisa realizada com alunos em interação em um ambiente virtual de ensino e aprendizagem a fim de descobrir padrões de comportamento do aluno desanimado utilizando mineração de dados educacionais. O principal objetivo foi evidenciar o desânimo, quando o aluno realiza atividades individuais ou em grupo, utilizando a tarefa de regras de associação. Como resultado, foi possível evidenciar que os alunos desanimados enviaram menos de 50% das atividades e tiveram dificuldades com o conteúdo, o que refletiu no conceito final. Futuramente, essas regras serão implementadas computacionalmente, para subsidiar o professor na análise de estado de ânimo dos alunos.*

1. Introdução

O presente trabalho faz parte de uma pesquisa que investiga e salienta a importância em considerar a afetividade no ambiente educacional apoiado por tecnologia, principalmente o desânimo no aluno. Investigações sobre emoções no contexto educacional têm mostrado que afetos relacionados ao desânimo, tais como: culpa/arrependimento, constrangimento/vergonha, preocupação/medo, tristeza/desamparo, piedade/compaixão, envolvem a crença da falha, produzindo comportamentos relacionados à incapacidade e impotência, levando o aluno ao abandono [Weiner 2007; Scherer 2005; Longhi 2011].

Em Ambientes Virtuais de Ensino e Aprendizagem (AVEA), os dados comportamentais do aluno podem apoiar a identificação dos seus estados afetivos, e podem ser obtidos através das interações realizadas quando o aluno executa tarefas e

utiliza as ferramentas do ambiente [Bercht 2001]. Sendo assim, ao ter acesso a esses dados, torna-se possível analisá-los com o uso de técnicas de Mineração de Dados Educacionais (MDE), de modo a descobrir padrões de comportamentos através do volume de dados existente. Pesquisas como as de Gottardo, Noronha e Kaestner (2014), Iepsen (2012) e Rigo *et al* (2014) aplicaram a MDE a fim de descobrir padrões de comportamento de alunos que podem evadir ou reprovar em cursos ou disciplinas.

Nesse artigo é apresentado um experimento o qual se utiliza da MDE para descobrir relacionamentos significativos através da tarefa de Regras de Associação (RA). O objetivo é encontrar RA que apresentem padrões de comportamento que possam determinar o desânimo de um aluno em relação às atividades realizadas por ele em um AVEA.

A contribuição da pesquisa compreende as regras de associação descobertas, através da combinação de dados de logs e de questionários, que são usadas para evidenciar o padrão de comportamento do aluno desanimado, servindo de subsídio para o professor na identificação desse aluno.

O artigo está estruturado em seções descritas a seguir. A seção 2 traz fundamentos teóricos sobre aspectos afetivos ligados à educação e técnicas empregadas na MDE. A seção 3 aborda os trabalhos relacionados e na seção 4 é descrito o procedimento metodológico utilizado. A seção 5 dedica-se à análise e resultados do experimento e, por fim, na seção 6, as conclusões e trabalhos futuros.

2. Referencial Teórico

Durante muito tempo o estudo das emoções e afetos foi quase exclusivo dos filósofos, psicólogos bem como dos poetas, porém, atualmente, também é investigado utilizando suporte tecnológico. Estudos sobre o reconhecimento dos estados afetivos por computadores, ou a capacidade de fazer com que computadores pudessem os reconhecer e responder adequadamente a eles é um campo de pesquisa dedicada à Computação Afetiva (CA) [Picard 2000].

Uma das áreas de aplicação da CA é a Educação, visto que a CA pode auxiliar na solução de desafios da aprendizagem ao utilizar métodos e técnicas que permitam desenvolver programas que reconheçam os estados afetivos do aluno, podendo subsidiar o professor e prover assistência personalizada ao aluno [Picard 2000; Jaques e Nunes 2012; Baker, Isotani e Carvalho 2011; Iepsen 2013, Rigo *et al.* 2014].

Estados de ânimo foram abordados, nesta pesquisa, pois são fenômenos afetivos que têm uma maior duração no tempo, além de serem muito comuns nas atividades de aprendizagem dos alunos [Picard 2000; Scherer 2005; Weiner 2007; Longhi 2011]. Para Weiner (2007), os afetos envolvidos nos estados de ânimo têm recebido pouca atenção em contextos educacionais, e podem ser “despertados” ou inferidos em ambientes virtuais. A escolha pelo desânimo deu-se pelo fato dele ser percebido como um estado afetivo que influencia de maneira negativa no comportamento de aprendizagem do aluno, eventualmente conduzindo-o a desistir de um curso, porém, pode ter implicações desejáveis em como possibilidade de retomada da aprendizagem do aluno [Weiner 2007; Longhi 2011].

Nesse sentido, Scherer (2005) desenvolveu um instrumento usado como método de obtenção do auto-relato para inferência dos estados de ânimo, conhecido por *Geneva Emotion Wheel* (GEW), que atualmente, está na sua segunda versão. O GEW 2.0 é representado em formato de roda, dividido em quatro quadrantes correspondentes aos estados de ânimo (animado, desanimado, satisfeito e insatisfeito), abrangendo um total de 20 famílias afetivas, além de permitir selecionar a intensidade do que foi ou é sentido, que pode variar de acordo com os círculos que acompanham cada família afetiva

Este instrumento foi adaptado para o presente trabalho, adotando um formato em português chamado de *Roda de Estados de Ânimo* (REA 2.0), usado como auto-relato pelo aluno frente ao seu sentimento relacionado às várias situações de aprendizagem. Através da REA 2.0 o aluno pode selecionar uma família afetiva e sua intensidade. A REA 2.0 foi implementada (detalhes na seção 4) computacionalmente para ser utilizada no experimento e pode ser observada na Figura 1.

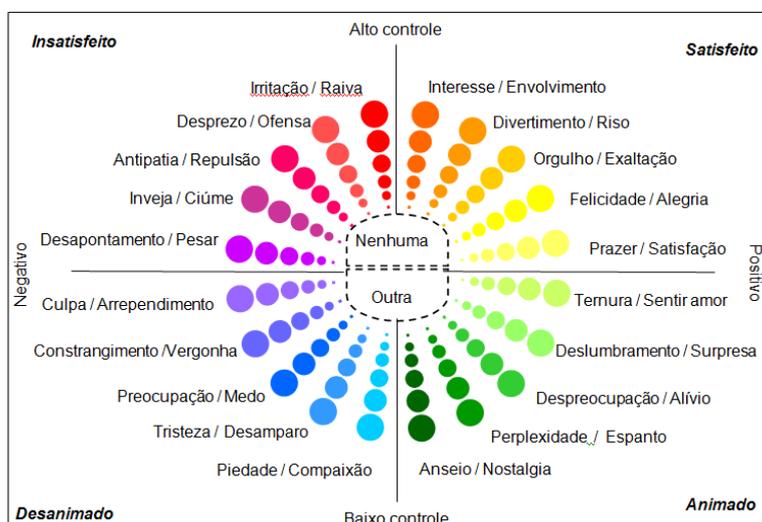


Figura 1. Roda de Estados de Ânimo 2.0 adaptada a partir de Sacharin, Schlegel e Scherer (2013) e Longhi (2011)

Para identificar um estado de ânimo de um aluno no AVEA é preciso obter suas variáveis comportamentais, ou seja, ações consideradas como importantes definidoras do comportamento do aluno, podendo ser usadas como indicadores para identificar o seu estado afetivo [Bercht 2001]. No presente trabalho, foram usadas as variáveis comportamentais vindas dos *logs* do AVEA Moodle além de dados de dois questionários aplicados que são descritos na seção 4.

Uma das dificuldades para a análise das variáveis comportamentais existentes nos AVEA se deve ao grande volume de dados gerados pelas interações do aluno, porém, uma maneira de manipular esses dados é através do uso das técnicas de MDE.

2.2. Mineração de dados educacionais

MDE é uma área de investigação científica centrada no desenvolvimento de métodos para descobertas em dados oriundos de ambientes educacionais, com intuito de compreender melhor o comportamento do aluno e o contexto no qual desenvolve o seu

aprendizado [Baker 2010]. Para Baker (2014) a MDE pode ajudar a desenvolver tecnologias melhores e mais inteligentes para apoiar alunos e professores.

Nesse sentido, Romero, Ventura e García (2008) apontam que a MDE pode ser aplicada para melhorar o aprendizado, ao prover cursos adaptativos e com recomendação baseada no comportamento do aluno, além de poder fornecer *feedback* personalizado aos alunos e professores em várias situações. Pode ser usada para verificar a relação de uma abordagem pedagógica e o aprendizado do aluno, descobrir fatores que influenciam o aprendizado, analisar comportamento do aluno evasor, dentre outras situações [Baker, Isotani e Carvalho 2011; Costa *et al.* 2012; Rigo *et al.* 2014].

Para realizar a mineração é preciso passar por várias etapas que compreendem o Processo de Descoberta de Conhecimento, como pode ser observado na Figura 2.



Figura 2: Processo de descoberta de conhecimento (adaptado de Tan, Steinbach e Kumar 2009)

Para seguir as etapas apresentadas na Figura 2, é preciso saber o objetivo que se pretende alcançar a fim de escolher tarefas, técnicas e métodos mais adequados (associação, classificação, agrupamento ou previsão de séries temporais). Dessa forma, na presente pesquisa emprega-se a tarefa de Regras de Associação (RA) para explorar um conjunto de dados, a fim de encontrar regras que representam padrões de comportamento do aluno desanimado com relação às atividades realizadas.

RA são usadas para descobrir padrões que descrevem características altamente associadas entre os dados, e os padrões descobertos são representados em forma de regras de implicação obtendo padrões interessantes [Tan, Steinbach e Kumar 2009]. As regras de associação fazem parte do tipo de aprendizado não supervisionado, utilizando instâncias sem a definição de um atributo classe ou atributo alvo e realiza uma análise exploratória dos dados. O campo de aprendizagem de máquina não-supervisionado envolve a aprendizagem de padrões na entrada, quando não são fornecidos valores de saída específicos [Russell e Norvig 2004].

Tan, Steinbach e Kumar (2009) definem RA como uma expressão de implicação no formato $X \rightarrow Y$, sendo que X e Y são conjuntos distintos de dados. Para a implicação $X \rightarrow Y$, X é o lado esquerdo da regra ou o antecedente e Y é o lado direito da regra, ou seja, o conseqüente, podendo ser interpretado como uma expressão lógica do tipo “Se X então Y ” [Nomelini *et al* 2010].

Para se medir uma regra, usa-se o *suporte* para determinar a frequência na qual uma regra é aplicada em um determinado conjunto de dados, e a *confiança* para determinar a frequência na qual os itens Y aparecem nas transações que contenham X [Tan, Steinbach e Kumar 2009].

Dentre as técnicas usadas para RA tem-se o algoritmo Apriori. O algoritmo Apriori, descrito por Tan, Steinbach e Kumar (2009), parte do princípio que, se um conjunto de itens é frequente, então todos os seus subconjuntos também deverão ser

frequentes, ou seja, se $\{x, y, z\}$ é um conjunto de itens frequentes, qualquer transação que contenha $\{x, y, z\}$ deve conter seus subconjuntos $\{x,y\}$, $\{x, z\}$, $\{y,z\}$, $\{z\}$, $\{x\}$, $\{y\}$.

3. Trabalhos relacionados

Trabalhos têm sido desenvolvidos com o objetivo de identificar questões relacionadas com a afetividade no contexto educacional [Picard 2000; Lago 2011; Longhi 2011; Iepsen 2012]. Alguns envolvem o uso de MDE bem como de CA.

A pesquisa desenvolvida por Iepsen (2012) buscou detectar o estado afetivo frustrado do aluno que cursava a disciplina de algoritmo. O autor utilizou uma amostra de 14 alunos e capturou suas interações através em uma ferramenta de edição de algoritmos. Os atributos usados foram número de erros de sintaxe do código, tempo dedicado a resolução de um mesmo exercício (duração), número de tentativas de executar um programa e número de programas anteriores ao atual sem uma compilação correta. A mineração, utilizando regras de associação, foi feita usando o software *WizRule*, adotando grau de confiança de 70% e suporte 3. Com relação às regras geradas, 7 delas foram selecionadas, pois indicavam o estado “frustrado” e foram aplicadas para identificar o aluno frustrado no ambiente.

A pesquisa de desenvolvida por Majadas, Santos e Boticario (2013), utilizou a MDE para descobrir o estado afetivo do aluno. O foco foi sobre a mineração textual a fim de encontrar palavras com conotação afetiva, onde termos positivos e negativos foram identificados, porém é necessário redefinir certos dados para obter melhores resultados nos novos experimentos.

Um dos diferenciais do trabalho aqui apresentado com os demais está na abordagem dos estados de ânimo, com enfoque no aluno desanimado. Vale ressaltar que, de acordo com Scherer (2005), o estado de ânimo desanimado engloba famílias e termos afetivos os quais incluem a frustração. Além disso, o ambiente de estudo é o Moodle, que é de amplo acesso e está presente na maioria das instituições de ensino, possuindo uma enorme quantidade de variáveis comportamentais, o que permite maior amplitude da proposta apresentada.

4. Procedimento Metodológico

Foi realizado um experimento com duas turmas de alunos da disciplina de Análise de Demonstrações Contábeis, ofertada pelo Departamento de Ciências Contábeis e Atuárias da UFRGS, no semestre de 2014/2. A amostra da pesquisa consistiu no total de 44 alunos para as duas turmas, os quais consentiram em participar da pesquisa. Foram desenvolvidos dois questionários, que se encontram online, bem como foi aplicada a mineração de dados para obter RA que possam evidenciar alunos desanimados quando realizam atividades no Moodle.

O primeiro questionário, composto por sete questões, foi implementado em linguagem de programação PHP e banco de dados MySQL e é composto pelas questões relacionadas à REA 2.0. As questões usadas abordavam sobre como o aluno se sentia diante as diversas situações de aprendizagem, como exemplo: *O que você sente quando envia atividades individuais atrasadas? O que você sente quando envia atividades em grupo atrasadas?* Dentre outras.

O segundo questionário, complementar ao primeiro, composto por 8 questões, contou com questões sobre dificuldade no uso de ferramentas, formas de apoio que o professor poderia usar com a turma, formas de solicitação de ajuda ao professor, envio de atividades individuais e em grupo, acompanhamento da disciplina, dentre outras. Os dois questionários dispunham um total de 34 variáveis possíveis de serem exploradas.

Além dos dados dos dois questionários, também foi necessário usar os dados de interação dos alunos no Moodle. Esses foram obtidos pelo *log* do Moodle e apresentou 26.611 interações nas mais diversas funcionalidades do ambiente. Os *logs* relacionados com as atividades totalizaram 5928 interações para os 44 alunos.

O *pré-processamento* foi a fase mais exaustiva, necessitando tabular os dados dos questionários e dos *logs*, reduzindo de 21.611 para 5928 interações analisadas. A discretização de dados a fim de diminuir a quantidade de atributos e chegar a um modelo mais compreensível foi feita usando o SPSS (*Statistical Package for the Social Sciences*).

Foram analisadas 12 atividades propostas pelo professor, onde o *log* de dados para cada atividade era composto por 6 variáveis, dentre as quais foram selecionadas somente as que apresentam a visualização e envio de atividades, representadas respectivamente por *assign_view* e *assign_submit*, pois essas duas resumem praticamente as outras, além de apresentarem o que é preciso para a mineração quando o aluno visualiza e envia a atividade. As respostas da REA 2.0 foram agrupadas por quadrantes. Foi criada uma nova variável a partir do quartil gerado para o atributo *quantidade de envios de atividades*, devido à necessidade em transformar um atributo contínuo em categórico. Sendo assim, os valores assumidos para os quartis gerados com relação à quantidade de envios de atividades, foram: Baixo (≤ 6), Médio (> 6 e ≤ 7), Médio Alto (> 7 e ≤ 10) ou Alto (> 10).

A etapa de a *transformação dos dados* dedicou-se a gerar arquivos do tipo ARFF (*Attribute Relation File Format*) para serem usados no minerador Weka¹ (*Waikato Environment for Knowledge Analysis*). Após realizar as etapas iniciais da descoberta de conhecimento, desde a seleção dos dados até a transformação desses dados, a mineração foi realizada. Para a etapa de mineração decidiu-se utilizar tarefa descritiva no experimento conduzido, desta forma a Tarefa de Regras de Associação foi selecionada, e frente a literatura consultada e amostra de dados a ser analisada, o algoritmo Apriori foi adotado.

A mineração ocorreu em três etapas, com enfoque em separar para conquistar, buscando a implicação por questão (REA 2.0) e variáveis observáveis (*log* de atividades), a fim de encontrar um padrão de comportamento por contexto de questão e depois verificar se os padrões se repetiam, e considerá-los como globais.

¹ O download por ser obtido através do endereço eletrônico: <http://www.cs.waikato.ac.nz/ml/weka/downloading.html>

5. Análise dos resultados

Nesse experimento, o algoritmo Apriori foi configurado para gerar 10 regras para cada etapa, onde esta quantidade de regras mostrou um resultado mais significativo e legível ao especialista. Além da definição dos valores para o fator de suporte mínimo de 0.2 e suporte máximo 1.0 para 44 instâncias. Para as 10 regras geradas, foram consideradas válidas somente as regras de associação mais significativas, ou seja, as que satisfazem altos índices de interesse com como *confidence* (confiança) e *conviction* e que apresentavam o desânimo na regra [Assunção 2012]. Dessa forma, o algoritmo Apriori foi aplicado para as três etapas seguintes, as quais apresentam os atributos utilizados e, posteriormente, a listagem das regras selecionadas (tabela1).

➤ Etapas 1 – Contexto da questão 1:

- Q1(*O que você sente quando envia atividades individuais atrasadas? - aplicada usando a REA 2.0;*
- Individual_envio_atraso (*Você envia atividades individuais com atraso? - respostas: nunca, raramente, algumas vezes, quase sempre e sempre;*
- Disciplina_dificuldadeConteudo (*Você já teve dificuldade com algum conteúdo na disciplina? respostas: nunca, raramente, algumas vezes, quase sempre e sempre;*
- Conceito_Final (cujos valores podem ser: A, B, C, D, E, FF);
- QuartilEnvioSIM (representa a quantidade de envios das atividades, podendo ter os valores *Baixo, Medio, MedioAlto, Alto*).

➤ Etapa 2 – contexto da questão 2:

- Q2 (*O que você sente quando envia atividades em grupo atrasadas?*)
- Grupo_Envio_Atraso (*Você envia atividades em grupo com atraso? - respostas: nunca, raramente, algumas vezes, quase sempre e sempre;*
- Grupo_Sente_Dificuldade (*Você sente dificuldade em realizar atividades em grupo? respostas: nunca, raramente, algumas vezes, quase sempre e sempre;*)
- Disciplina_dificuldade_Conteudo (*idem etapa 1*);
- Conceito_Final (*idem etapa 1*);
- QuartilEnvioSIM (*idem etapa 1*).

➤ Etapa 3 – contexto da questão 5:

- Q5: (*O que você sente quando tem dificuldade em algum conteúdo?*);
- Disciplina_dificuldadeConteudo (*idem etapa 1 e 2*);
- Conceito_Final (*idem etapa 1 e 2*);
- QuartilEnvioSIM (*idem etapa 1 e 2*).

A etapa de *interpretação* foi feita pelo especialista da área e usada para suporte de tomadas de decisão na disciplina em questão. A estratégia de dividir em etapas

auxiliou a busca pelo objetivo do trabalho, evidência do desânimo. Para cada etapa, 10 regras foram geradas, porém, foram selecionadas somente as regras cujas medidas de interesse (*conviction* e *confidence*) fossem mais significativas, bem como regras que tinham o desânimo como atributo. As regras selecionadas para cada etapa estão consolidadas na tabela 1, abaixo.

Tabela 1. Resultado das melhores regras geradas para o estado de desânimo.

Eta pa.	Nº Re gra	Antecedente	Consequente	Conf	Conv
1	2	$q1=Desanimado$ E $Conceito_Final=B$ 12	$Individual_Envio_Atraso=Algu$ $masVezes$ 10	0.83	1.73
1	10	$Individual_Envio_Atraso=$ $AlgumasVezes$ E $Conceito_Final=B$ 14	$q1=Desanimado$ 10	0.71	1.34
2	1	$q2=Desanimado$ $Conceito_Final=B$ 12	$Grupo_Sente_Dificuldade=Alguma$ $sVezes$ 10	0.83	1.91
2	5	$Grupo_Envio_Atraso=Raram$ $ente$ E $Disciplina_TeveDificuldadeC$ $onteudo=AlgumasVezes$ 12	$q2=Desanimado$ 10	0.83	1.45
2	8	$QuartilEnvioSIM=Baixo$ 13	$q2=Desanimado$ E $Disciplina_TeveDificuldadeConteu$ $do=AlgumasVezes$ 9	0.69	1.3
2	9	$q2=Desanimado$ E $QuartilEnvioSIM=Baixo$ 10	$Disciplina_TeveDificuldadeConteu$ $do=AlgumasVezes$ 9	0.9	1.25
3	1	$q5=Desanimado$ E $QuartilEnvioSIM=MedioAlto$ 8	$Conceito_Final=B$ 8	1	3.82
3	2	$q5=Desanimado$ E $QuartilEnvioSIM=Baixo$ 8	$Disciplina_TeveDificuldadeConteu$ $do=AlgumasVezes$ 8	1	2

Dessa forma, 8 regras puderam evidenciar o desânimo, observou-se o aluno desanimado enviou menos da metade das atividades previstas, já que o total de atividades eram 12 e o quartil baixo representa o envio de até 6 atividades e, algumas ainda foram entregues com atraso. Além disso, o aluno sentiu dificuldade com o conteúdo e, esse padrão de comportamento, refletiu no conceito final do mesmo.

Sendo assim, essas regras representam um padrão de comportamento e podem ser utilizadas como apoio na evidência do estado de ânimo desanimado do aluno ao realizar atividades, devendo ser monitoradas e bem acompanhadas, pois esse padrão de comportamento pode servir de subsídio para apoiar o professor a identificar esse aluno.

6. Conclusão

O presente trabalho teve como objetivo identificar regras de associação que apresentassem padrões de comportamento do aluno no estado de ânimo desanimado,

que fossem observadas em relação às atividades realizadas no AVEA, sejam elas individuais ou em grupo.

Foi aplicado o algoritmo Apriori em três etapas, buscando a estratégia de dividir para conquistar partindo de análises locais para globais. Embora cada etapa tenha gerado 10 regras, foram consideradas somente as melhores regras de associação as que obtiveram melhores escores das medidas de interesse *conviction* e *confidence* e que contemplasse o desânimo, consolidando em um total de 8 regras de associação que representam o padrão de comportamento para a evidência do desânimo, quando o aluno realiza atividades individuais ou em grupo.

Apesar do conjunto de dados do experimento ser considerado pequeno, as regras de associação geradas apontaram que os alunos que se sentiram desanimados, enviaram menos de 50% das atividades e tiveram dificuldades com o conteúdo, o que refletiu no conceito final. A dificuldade em acompanhar conteúdos e a não participação em atividades, pode desencadear possíveis desistências ou baixo rendimento do aluno no curso. Esse resultado motiva novos experimentos, em conjuntos de dados maiores, a fim de comparar as regras geradas e realizar testes efetivos em conjuntos de dados maiores.

Pretende-se, em trabalhos futuros, implementar computacionalmente as RA encontradas para subsidiar professores, no sentido de apoiá-los na inferência do aluno desanimado ou que encontra-se em processo de desânimo.

Agradecimento

Agradecemos a CAPES pelo suporte através do Projeto Pró-Ensino na Saúde nº39.

Referencias

- Assunção, A. S. (2011). Descoberta Direta e Eficiente de Regras de Associação Ótimas. Dissertação de Mestrado. Universidade de São Paulo. Programa de Pós-Graduação em Ciências da Computação e Matemática Computacional
- Baker, R. S. J. (2010). Data Mining for Education. To appear in McGaw, B., Peterson, P., Baker, E. (Eds.) International Encyclopedia of Education (3rd edition). Elsevier, Oxford, UK
- Baker, R. S. J.; Isotani, S.; Carvalho, A. M. J. B. (2011). Mineração de Dados Educacionais: Oportunidades para o Brasil. Revista Brasileira de Informática na Educação. V.19, N.02.
- Baker, R. S. J. (2014). Educational Data Mining: An Advance for Intelligent Systems in Education. IEEE Intelligent Systems, 29 (3), 78-82.
- Bercht, M. (2001). Em Direção a Agentes Pedagógicos com Dimensões Afetivas. Tese de doutorado. Tese de doutorado. Universidade Federal do Rio Grande do Sul. Programa de Pós-Graduação em Computação.
- Costa, E.; Baker, R.; Amorin, L.; Magalhães, J.; Marinho, T. (2012). Mineração de Dados Educacionais: Conceitos, Técnicas, Ferramentas e Aplicações. Jornada de Atualização em Informática na Educação – JAIE. 23º Congresso Brasileiro de Informática na Educação.

- Gottardo, E.; Noronha, R. V.; Kaestner, C. A. A. (2014). Estimativa de Desempenho Acadêmico de Estudantes: Análise da Aplicação de Técnicas de Mineração de Dados em Cursos a Distância.
- Iepsen, E. F. (2013). Ensino de Algoritmos: Detecção do Estado Afetivo de Frustração para Apoio no Processo de Aprendizagem. Tese de Doutorado. Universidade Federal do Rio Grande do Sul. Programa de Pós-Graduação em Informática na Educação.
- Jaques, P. A.; Nunes, M. A. S. N. (2012). Ambientes Inteligentes de Aprendizagem que Inferem, Expressam e Possuem Emoções e Personalidade. Jornada de Atualização em Informática na Educação. 23º Congresso Brasileiro de Informática na Educação.
- Lago, N. A. (2011). Me, Myself and You: Autoestima e Aprendizagem de Línguas. Afetividade e Emoções no Ensino/Aprendizagem de Línguas: Múltiplos Olhares. Campinas: Pontes Editores.
- Longhi, M. T. (2011). Mapeamento de Aspectos Afetivos em um Ambiente Virtual de Aprendizagem. Tese de doutorado. Universidade Federal do Rio Grande do Sul. Programa de Pós-Graduação em Informática na Educação.
- Majadas, S. S.; Santos, O.; Boticario, J. G. (2013) Affective State Detection in Educational Systems Through Mining Multimodal Data Sources. The 6th International Conference on Educational Data Mining.
- Nomelini, J. Rezende, S. O.; Yamamoto, C. H.; Framartino, L. A. et al. (2010). Emprego de Regras de Associação para Extração de Padrões Mercadológicos de Touros Nelore com Avaliação Genética. Revista Brasileira de Zootecnia. Vol.39 N°12.
- Picard, R. W. (2000). Affective Computing. The MIT Press.
- Rigo, S. J.; Cambuzzi, W.; Barbosa, J. L. V.; Cazella, S. C. (2014). Aplicações de Mineração de Dados Educacionais e Learning Analytics com Foco na Evasão Escolar: Oportunidades e Desafios. Revista Brasileira de Informática na Educação. V. 22, N.01.
- Romero, C. M.; Ventura, S.; García, E. (2008). Data Mining in Course Management Systems: Moodle Case Study and Tutorial. Computers & Education 51, pg. 368-384, Elsevier.
- Russel, S.; Norving, P. (2004). Inteligência Artificial. Rio de Janeiro: Elsevier, 5ª Edição.
- Sacharin, V.; Schlegel, K.; Scherer, K. R. (2013). Geneva Emotion Wheel Rating Study. Geneva, Switzerland: University of Geneva, Swiss Center for Affective Sciences.
- Scherer, K. R. (2005). What are the emotions? And how can they measured? In: Social Science Information.
- Tan, Pang-Ning; Steinbach, M.; Kumar, V. (2009). Introdução ao DataMining Mineração de Dados. Rio de Janeiro: Editora Ciência Moderna Ltda.
- Weiner, B. (2007). Examining Emotional Diversity in the Classroom: An Attribution Theorist Considers the Moral Emotions. In Emotion in Education, Elsevier.