

# Analizando o desânimo de alunos em ambientes virtuais através da mineração de dados educacionais

Magda Bercht<sup>1</sup>

Fabrcia Damando Santos

Universidade Federal  
do Rio Grande do Sul/UFRGS  
Universidade Estadual  
do Rio Grande do Sul/ UERGS  
fabriaciadamando@gmail.com

Leandro Krug Wives<sup>2</sup>

Universidade Federal  
do Rio Grande do Sul/UFRGS  
R. Paulo da Gama, 110 Prédio  
12105 – 3º Andar, Sala 332  
Porto Alegre – RS  
55-51-3308-3986

<sup>1</sup>bercht@inf.ufrgs.br

<sup>2</sup>wives@inf.ufrgs.br

Sílvia César Cazella

Universidade Federal de Ciências da  
Saúde de Porto Alegre/UFCSPA  
Rua Sarmento Leite, 245  
Porto Alegre – RS  
55-51-3308-3986  
silvio.cazella@gmail.com

## ABSTRACT

This paper presents a study to identify the discouraged students behavior patterns in interaction in a virtual learning environment using educational data mining. The objective of the research was to validate, in a new context, association rules already mined in order to show discouragement when the student performs individual and group activities. Two experiments in university training courses were conducted in a real situation, where the first experiment was to target the search for association rules and the other one to validate these rules. From the adaptation of certain association rules may be possible to obtain a generic model for pattern discovery discouraged student's behavior, which can be used as an aid to the teacher.

## RESUMO

O presente artigo apresenta uma pesquisa que busca identificar padrões de comportamento de alunos desanimados em interação em um ambiente virtual de ensino e aprendizagem por meio da mineração de dados educacionais. O objetivo da pesquisa foi validar, em um novo contexto, regras de associação já mineradas, a fim de evidenciar o desânimo do aluno quando realiza atividades individuais e em grupo. Foram realizados dois experimentos em disciplinas de formação universitária em situação real, onde o primeiro experimento teve como meta a busca por regras de associação e o segundo a validação destas regras. A partir da adaptação de algumas regras de associação pode ser possível obter um modelo genérico para a descoberta do padrão de comportamento do aluno desanimado, que pode ser usado como subsídio ao professor.

## Descritor de Categorias e Assuntos

K.3.1 [Computers and Education]: *Computer Uses in Education*  
– *Distance Learning*.

## Termos Gerais

Experimentation, Human Factors.

## Palavras Chaves

Mineração de Dados Educacionais, Afetividade na educação, Ambientes Virtuais de Ensino e Aprendizagem.

## 1. INTRODUÇÃO

O presente artigo faz parte de uma pesquisa que investiga a importância da afetividade em contexto educacional, principalmente relacionado ao estado de ânimo do aluno desanimado, bem como formas de identificar este estado de ânimo quando o mesmo está interagindo em um ambiente virtual de ensino e aprendizagem (AVEA). Foram utilizadas técnicas de Mineração de Dados Educacionais (MDE) a fim de encontrar padrões de comportamento do aluno desanimado frente às situações de aprendizagem que contemplassem atividades individuais e em grupo no processo de aprendizagem. Para isso, foram feitos dois experimentos, o primeiro aplicou a MDE na busca por Regras de Associação (RA) que representassem o padrão de comportamento do aluno desanimado e o outro experimento buscou validar as RA encontradas a fim de compor um modelo genérico de descoberta do desânimo.

A influência da afetividade na aprendizagem pode limitar, senão, impossibilitar o que é compreendido e aprendido pelo aluno, e nesse sentido algumas pesquisas sustentam que a afetividade pode afetar o aprendizado do aluno, e que conhecer os aspectos afetivos dos alunos favorece ações pedagógicas, podendo auxiliar o professor na tomada de decisões e na intervenção quando necessário [8, 10, 14].

Nesse contexto, a busca pelos aspectos afetivos e comportamentais do aluno pode ser obtida através de suas interações em um AVEA e registros de todas as suas ações no ambiente. [2] atesta que as ações dos alunos no AVEA colaboram na identificação de seus estados afetivos. Nesse sentido, acredita-se que ao aplicar MDE para analisar as ações do aluno no ambiente, seja possível obter regras que representem os padrões de comportamentos relacionados aos estados afetivos dos alunos.

Visando contribuir nessas questões, o presente trabalho tem por objetivo analisar e identificar padrões de comportamento de alunos que estão desanimados em um AVEA, utilizando regras de associação descobertas através da MDE.

O artigo está estruturado da seguinte nas seguintes seções: A seção 2 discorre sobre conceito, etapas e técnicas de mineração de dados educacionais. Na seção 3 são apresentados conceitos sobre afetividade e sua importância na educação. A seção 4 apresenta trabalhos relacionados. A seção 5 descreve o procedimento metodológico e resultados. Por fim, a seção 7 apresenta conclusão.

## 2. MINERAÇÃO DE DADOS EDUCACIONAIS

Atualmente as instituições de ensino armazenam informações referentes aos seus cursos, turmas, disciplinas, alunos, professores, tutores, dentre outras em grandes bases de dados, sendo que esses dados podem estar armazenados tanto em software de gestão educacional quanto em ambientes virtuais de ensino e aprendizagem (AVEA). Os dados relacionados à gestão visam facilitar a administração da instituição, já os dados que estão no AVEA dizem respeito à organização de cursos e disciplinas, bem como monitoramento de alunos, além de oferecer uma infraestrutura tecnológica capaz de atender aos objetivos pedagógicos em uma modalidade de ensino a distância [11].

Neste contexto, o volume de dados gerados por estes ambientes vem aumentando durante os últimos anos, surgindo o desafio em como explorá-los de forma a produzir conhecimentos, extraindo informação útil a partir de dados que dizem respeito ao comportamento dos alunos dentro do ambiente. Para [8] é possível armazenar dados das interações dos alunos em um AVEA para obter indicativos sobre seus comportamentos.

Apesar de algumas ferramentas educacionais e AVEA oferecem relatórios aos professores, tutores e gestores, há um volume de dados gerado muito grande, tornando difícil extrair informações úteis somente através destes relatórios [7]. Além disso, os relatórios que podem ser apresentados diretamente pelas ferramentas, apesar de possuírem informações relevantes, podem ser considerados superficiais, diante da quantidade de dados que estão armazenados e, muitas das vezes pode tornar árduo para o professor extrair informação útil através da junção dos relatórios disponíveis [15]. Dessa forma, a questão em como explorar adequadamente esses dados a fim de extrair informações e realizar uma análise apropriada contempla a área de mineração de dados educacionais (MDE).

MDE é definida como uma área de pesquisa cujo principal foco é o desenvolvimento de métodos para explorar conjunto de dados coletados em ambientes educacionais [1]. Busca desenvolver ou adaptar métodos e algoritmos existentes na mineração de dados, aplicando-os na área educacional, a fim de compreender dados em contextos educacionais produzidos por alunos, professores e suas interações, bem como, também pode ser utilizado para verificar a relação de uma abordagem pedagógica e o aprendizado do aluno [1, 21].

O processo para descoberta de conhecimento que envolve a MDE consiste em quatro etapas apresentadas por [15], descritas a seguir.

- Coleta de dados: a busca dos dados através de uma base de dados de um AVEA onde encontram-se informações sobre as interações dos alunos. No presente caso serão explorados dados oriundos do AVEA Moodle.
- Pré-processamento dos dados: o AVEA Moodle é composto por várias tabelas relacionadas em seu banco de dados e os dados necessários para realizar a mineração precisam ser “limpados” e “transformados” no formato apropriado para ser minerado, ou seja, precisam ser transformados para a análise adequada, para posteriormente transformá-los no formato a ser usado no minerador. Os arquivos a serem usados no

minerador devem ser do tipo ARFF (*Attribute Relation File Format*).

- Aplicação da mineração de dados: uso de algoritmos de mineração de dados a fim de descobrir e resumir o conteúdo de conhecimento de interesse. Nesta etapa é utilizada uma ferramenta específica ou desenvolvido algoritmos de mineração. Nesta pesquisa optou-se pelo uso do minerador WEKA<sup>1</sup> (*Waikato Environment for Knowledge Analysis*).
- Interpretar, avaliar e apresentar os resultados: esta etapa é conhecida, também, como pós-processamento. Os resultados são apresentados e validados por um especialista da área. No presente trabalho, a validação foi feita pelo professor e especialista em computação afetiva.

A figura 1 apresenta as etapas da MDE a partir dos estudos de [15].



**Figura 1: Etapas da MDE**

Além das etapas supracitadas, a MDE possui várias técnicas (associação, classificação, agrupamento ou previsão de séries temporais) que podem ser aplicadas de acordo com o conhecimento que se deseja descobrir. Na presente pesquisa será utilizado a tarefa de Regras de Associação.

RA são aplicadas para explorar um conjunto de dados com o intuito de encontrar regras que representem o padrão de comportamento, no presente caso o padrão de comportamento do aluno desanimado, com enfoque nas atividades realizadas individualmente ou em grupo.

As RA são usadas para descobrir padrões que descrevem características associadas entre os dados, e esses padrões descobertos são representados em forma de regras de implicação obtendo padrões interessantes [20]. Uma RA é tida 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” [12].

Geralmente, duas métricas são usadas para medir a qualidade de uma RA, onde uma é o suporte e a outra é a confiança. O suporte de uma regra é usado 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

<sup>1</sup> <http://www.cs.waikato.ac.nz/ml/index.html>

aparecem nas transações que contenham X [19]. Ambas as métricas foram usadas, de acordo com a literatura, a fim de apoiar na seleção de melhores regras no contexto desta pesquisa, onde selecionou-se àquelas regras que possuem maiores escores para as duas métricas..

### 3. AFETIVIDADE EM CONTEXTO EDUCACIONAL

Atualmente uma nova leitura no contexto educacional tem sido feita sobre as relações entre as dimensões afetivas e cognitivas à qual busca integrá-las e não tratá-las com forma dissociada na a construção do conhecimento. Nesse sentido, [13] afirmava que não há mecanismo cognitivo sem elementos afetivos e vice-versa, podendo sentimentos de sucesso ou fracasso levar a uma facilitação ou inibição da aprendizagem.

Conceitualmente, o termo afetividade diz respeito à habilidade de experimentar sentimentos e a eles reagir, podendo incluir um conjunto de fenômenos afetivos que possuem diferentes origens, intensidades, duração e reações corporais [2, 10, 18]. Ainda para [14, 5] a afetividade é fator determinante nas escolhas humanas, tendo papel fundamental na tomada de decisão e na aprendizagem de um modo geral. Ainda para [22], nosso repertório de comportamentos tem com base nossos estados afetivos, com ênfase na conexão entre emoção, funcionamento social e tomada de decisões, o que tem contribuído para a compreensão do papel do afeto na educação. Para os autores [22], a aprendizagem, a atenção, memória, a tomada de decisão e funcionamento social são afetados pelos nossos estados afetivos.

O afeto ou estado afetivo, como elemento genérico, congrega emoções, sentimentos e, de acordo com [5], pode ser classificado em emoções e estados de ânimo entre outros. Para [5] as emoções se caracterizam por serem fenômenos de grande intensidade e de rápida evolução enquanto os estados de ânimo têm menor intensidade e de evolução mais duradoura no tempo.

Os estados de ânimo são considerados emoções de segundo plano e são as que mais influenciam na tomada de decisão conforme [10]. Ao contrário das emoções primárias, que são as emoções mais instantâneas e curtas, as de segundo plano podem durar dias, o que motiva sua inferência na área educacional [9, 10]. Dessa forma, este estudo optou-se pela análise de estados de ânimo dos alunos uma vez que eles persistem mais tempo, estando presente durante as interações dos alunos em ambientes de ensino e aprendizagem

Os estados de ânimo, fundamentados a partir do trabalho de [17], se dividem em quatro categorias: satisfeito/insatisfeito e animado/desanimado, sendo que cada um possui termos afetivos associados à famílias afetivas de cada categoria.

Apoiada nos trabalhos de [18] e [17, pg. 3], a tabela 1 foi desenvolvida e, apresenta os termos afetivos que remetem ao estado de ânimo desanimado. O estado de ânimo desanimado é representado por 05 famílias afetivas e há termos afetivos correspondentes para cada uma delas.

**Tabela 1: Termos afetivos empregados para o estado de ânimo desanimado**

| Estado de Ânimo Desanimado |                 |
|----------------------------|-----------------|
| Família Afetiva            | Termos afetivos |

|                                 |  |
|---------------------------------|--|
| <b>Culpa / Arrependimento</b>   | Culpado, arrependido, irresponsável, faltoso, pesaroso.  |
| <b>Constrangimento/Vergonha</b> | Envergonhado, acanhado, humilhado, constrangido, dificuldade, desapontamento.  |
| <b>Preocupação/Medo</b>         | Tenso, amedrontado, ansioso, apavorado, assustado, receoso, temeroso, intimidado, aflito, preocupado.  |
| <b>Tristeza / Desamparo</b>     | Entristecido, abatido, choroso, magoado, melancólico, sofrido, deprimido, aflito, fracassado, frustrado, sentir-se incompetente, pesaroso, mal humorado, incomodado, abatido, arrependido, desesperança. |
| <b>Piedade/Compaixão</b>        | Com pena, piedoso, compaixão, consentimento, dó, lástima, compreensão.   |

Estar no estado de ânimo desanimado sugere que o aluno demonstra ou reprime, de alguma forma, as emoções de tristeza, medo, vergonha ou culpa, bem como os possíveis termos afetivos que o representa [10]. Além disso, a autora cita que dependendo do estado de ânimo este pode conduzir o aluno à desistência, porém, ao ser identificado, o estado de ânimo desanimado é passível de enfrentamento e mudanças, o que pode fazer com que o aluno retome o curso e sua aprendizagem.

Klaus Scherer<sup>2</sup> tem desenvolvido pesquisas abordando as emoções e, em especial, os estados de ânimo usando métodos objetivos de medição da experiência emocional sentida ou estado afetivo experimentado por uma pessoa durante determinado evento. Para o autor, não há meios para obter essa inferência a não ser perguntando ao indivíduo, sendo assim, [17] sugere uma lista com emoções para ser empregada em pesquisas que usam respostas livres ou auto-relato para emoções sentidas pelos participantes. Esta lista de emoções foi mapeada por [18] no instrumento GEW 2.0 (*Geneva Emotion Whell*) e adaptado para o português como REA 2.0 (Roda de Estados de Ânimo) [3].

[10] e [8] também afirmam que os estados emocionais se fazem notar no comportamento não verbal, o que favorece sua inferência ao observar o comportamento do aluno. É nessa perspectiva que [6] pode verificar quando os alunos se sentiam desmotivados e desanimados durante o processo de aprendizagem, sendo que os alunos acreditavam que jamais teriam sucesso em determinadas atividades, o que evidenciou o papel da dimensão afetiva no processo de aprendizagem, podendo levar o aluno ao sucesso ou fracasso em sua caminhada para a aprendizagem.

[19] admitem a contribuição da afetividade para a aprendizagem cognitiva e as interações entre professores e alunos favorecem o sucesso escolar. Para os autores, a dimensão afetiva ocupa um lugar central no ensino-aprendizagem e que a cognição é mediada pela afetividade, de forma a resultar em um conhecimento significativo.

É nesse contexto, que se observa a importância da dimensão afetiva no âmbito educacional, sendo discutida de forma a

<sup>2</sup> Professor do Departamento de Psicologia da *Univerity of Genève* e Pesquisador do *Swiss Center for Affective Sciences*.

estreitar a dicotomia ainda existente entre cognição e afetividade nos processos de aprendizagem e, no presente trabalho, a possibilidade de sua inferência permitirá um apoio ao professor na identificação do aluno desanimado.

Sendo assim, apoiar o professor que atua em disciplinas a distância ou semi-presenciais, a descobrir como o aluno se sente em determinadas situações de aprendizagem, possibilita uma nova intervenção do professor junto a esse aluno, podendo ser determinante na quantidade de desistências em cursos EAD, bem como na retomada dos estudos pelos aluno.

#### 4. TRABALHOS CORRELATOS

Pesquisas que associam MDE e aspectos relacionados com a afetividade na busca por modelos e/ou aplicações, com finalidades em aprofundar estudos sobre fenômenos afetivos na educação estão em crescimento [1, 15].

O trabalho desenvolvido por [8] utilizou a MDE para detectar padrões de comportamento associados com o estado afetivo de frustração no aluno. O autor analisou variáveis comportamentais do aluno dentro de um ambiente para ensino de algoritmos, a fim de identificar o aluno frustrado, buscando minimizar desistência na disciplina. A técnica aplicada foi classificação baseada em regras.

Os autores [16] trabalharam com a predição do estado afetivo positivo ou negativo de alunos em ambientes educacionais. Os autores realizaram um experimento onde os alunos resolveram problemas de matemática e foram monitorados e coletados dados como tempo médio de pressionar e soltar teclas do teclado, detecção de suas expressões faciais com apoio do kinect e de um especialista da área, bem como usaram ao final de cada atividade um auto-relato usando questionário SAM (Self-Assessment Manequin), que posteriormente foi analisado juntamente com o apoio de especialista. De posse dos dados dessas diversas fontes, os dados foram minerados usando árvore de decisão e redes bayesianas.

Nos dois trabalhos, a dimensão afetiva foi ponto fundamental das pesquisas e ambas utilizaram técnicas de MDE. Com relação ao primeiro trabalho, a pesquisa aqui desenvolvida tem o enfoque no estado de ânimo desanimado, e este estado de ânimo envolve termos afetivos que incluem a frustração. Já ao considerar o segundo trabalho, a necessidade de ter um especialista da área para analisar expressões faciais ao mesmo tempo em que permite maior acurácia, torna o sistema dependente deste profissional. Na nossa pesquisa, optamos por usar o instrumento de [18] o que nos exime da necessidade de um especialista da área e ao mesmo tempo proporciona maior autonomia.

#### 5. PROCEDIMENTOS METODOLÓGICOS E ANÁLISE DOS RESULTADOS

A presente pesquisa é de natureza aplicada ao ensino e aprendizagem, classificada como exploratória com foco em disciplinas que utilizam AVEA o que permite o acesso aos dados das interações do aluno. Com relação aos procedimentos técnicos, foram desenvolvidos dois experimentos além de apresentar uma abordagem quantitativa obtida através da MDE e técnicas estatísticas com apoio do software SPSS (*Statistical Package for Social Sciences*).

Os dois experimentos (A e B), foram realizados com turmas de alunos da disciplina de Análise de Demonstrações Contábeis, ofertada pelo Departamento de Ciências Contábeis e Atuárias da

UFRGS Os experimentos foram realizados com uma distância temporal de 6 meses e para perfis de estudantes semelhantes, ou seja, para alunos de uma mesma disciplina, mesmo curso, mesmo professor, possuindo os mesmos materiais educacionais e atividades individuais e em grupo.

No experimento A, composto por 44 participantes, foi realizada a mineração de dados para obter RA que pudessem evidenciar alunos desanimados quando realizam atividades apresentadas no Moodle. Nesse sentido, 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 e também as que foram validadas pelo especialista da área. Dessa forma, foram obtidas 8 RA que representam o padrão de comportamento para a evidência do desânimo, quando o aluno realiza atividades individuais ou em grupo [4]. As RA selecionadas estão listadas na tabela 2.

Tabela 2: Regras de Associação

| R | Antecedente   | Consequente   | Conf. | Conv |
|---|---|---|-------|------|
| 1 | q1=Desanimado E<br>Conceito Final = B<br>(12)   | Envio de atividades<br>individuais em atraso<br>=Algumas Vezes (10)             | 0.83  | 1.73 |
| 2 | Envio de atividades<br>individuais em atraso<br>= Algumas Vezes E<br>Conceito Final = B 14                      | q1=Desanimado (10)  | 0.71  | 1.34 |
| 3 | q2=Desanimado<br>Conceito Final = B 12  | Sente dificuldades em<br>realizar atividades em<br>grupo =Algumas Vezes<br>(10) | 0.83  | 1.91 |
| 4 | Envio de atividades<br>em grupo em atraso =<br>Raramente E Teve<br>Dificuldade Conteúdo<br>= Algumas Vezes (12) | q2=Desanimado (10)  | 0.83  | 1.45 |
| 5 | Quantidade de envio<br>de atividades = Baixo<br>(13)  | q2=Desanimado E Teve<br>Dificuldade Conteúdo<br>=Algumas Vezes (9)              | 0.69  | 1.3  |
| 6 | q2=Desanimado E<br>Quantidade de envio<br>de atividades =Baixo<br>(10)  | Teve Dificuldade<br>Conteúdo =Algumas<br>Vezes (9)                              | 0.9   | 1.25 |
| 7 | q5=Desanimado E<br>Quantidade de envio<br>de atividades = Medio-<br>Alto (8)                                    | Conceito Final =B (8)   | 1     | 3.82 |
| 8 | q5=Desanimado E<br>Quantidade de envio<br>de atividades =Baixo 8  | Teve Dificuldade<br>Conteúdo = Algumas<br>Vezes (8)                             | 1     | 2    |

Para [4] 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.

O experimento B, composto por 41 participantes, foi dividido em duas etapas. Para a primeira etapa, foi aplicado um questionário que teve como finalidade identificar variáveis comportamentais a partir da disposição afetiva sentida pelo aluno em interação no AVEA. Para o desenvolvimento do questionário, buscou aporte nos estudos de [2, 12,20], que consideram como o aluno se sente em diversas situações de aprendizagem. Os resultados desse primeiro experimento podem ser analisados através do trabalho de [4]. Na segunda etapa, foi feita a validação/teste das RA mineradas a partir do experimento A e é detalhada a seguir.

Para validar/testar as RA, inicialmente os dados dos logs dos alunos do experimento B tiveram que ser tabulados para serem analisados. Foi necessário agrupar todas as 11 atividades realizadas no Moodle e analisar do log de cada uma delas utilizando os seguintes atributos: *assign-submit* e *assign\_view*. Também foi preciso criar dois quartis, um para representar a quantidade de visualizações de atividades e outro quartil para representar a quantidade de atividades enviadas pelos alunos, os quais receberam os valores: baixo, baixo médio, médio e alto. O quartil que representa a quantidade de atividades enviadas pelos alunos recebeu os seguintes valores: baixo  $\leq 7$ , baixo médio  $> 7$  e  $\leq 9$ , médio  $> 9$  e  $\leq 10$  e alto  $> 10$ . Para o quartil que representa a quantidade de atividades que o aluno visualizou, os valores encontrados foram: baixo  $\leq 41$ , baixo médio  $> 41$  e  $\leq 53$ , médio  $> 53$  e  $\leq 72$  e alto  $> 72$ .

Sendo assim, os atributos selecionados para a validação das RA com o propósito de verificar se o padrão de comportamento obtido através das RA do aluno desanimado permaneceu o mesmo em um novo conjunto de dados. Foi gerada uma tabela composta pelos dados do aluno, dados do questionário, dados tabulados do log totalizando 37 atributos e 41 registros.

Cada RA apresentada na tabela 2 foi testada no conjunto de dados acima, o que gerou uma consulta nesta base. A partir da consulta, os valores obtidos tanto para o antecedente quanto para o conseqüente, ou seja, quantos registros ocorreram no antecedente e no conseqüente foram armazenados. A partir desses valores foi calculada uma taxa de acerto para cada regra testada. As taxas de acerto das RA testadas no novo conjunto de dados podem ser observadas na tabela 3.

Observa-se que algumas regras ficaram sem representatividade, pois não apresentaram nenhum registro com o padrão de comportamento da regra, porém, esse fato ocorreu somente quando o atributo Conceito final = B estava presente na regra. Essa fato foi analisado pelo especialista da área e notou-se que, nesse conjunto de dados da amostra, havia somente 1 único aluno com esse conceito.

**Tabela 3: Taxas de acerto da validação das regras**

| Regra | Taxa de acerto           | Regra | Taxa de acerto         |
|-------|--------------------------|-------|------------------------|
| 1     | Sem representatividade e | 5     | 58%                    |
| 2     | Sem representatividade e | 6     | 70%                    |
| 3     | Sem representatividade e | 7     | Sem representatividade |
| 4     | 100%                     | 8     | 60%                    |

Dessa forma, ao apresentar os dados para o especialista da área a fim de verificar se elas faziam sentido no contexto avaliado, o mesmo sugeriu adaptar as regras que tinham o atributo “Conceito Final = B”, para “Conceito Final  $\leq$  B”. Sendo assim, após a adaptação das regras, as mesmas foram novamente aplicadas à amostra, apresentando melhoria para o uso de tais regras. As taxas de acerto foram novamente recalculadas e são apresentadas na tabela 4.

**Tabela 4: Taxas de acerto da validação das regras adaptadas**

| Regra | Taxa de acerto | Regra | Taxa de acerto |
|-------|----------------|-------|----------------|
| 1     | 77%            | 5     | 58%            |
| 2     | 100%           | 6     | 70%            |
| 3     | 65%            | 7     | 42%            |
| 4     | 100%           | 8     | 60%            |

Ao adaptar as regras e testá-las novamente, foi possível identificar as melhores RA que podem ser utilizadas nesse contexto e as regras sugeridas são as que possuem acerto acima de 60%. Dessa forma, as regras 1, 2, 3, 4, 6 e 8 podem ser utilizadas para apoio na descoberta do aluno desanimado ou que encontra-se em processo para o desânimo, podendo, as regras serem interpretadas e usadas pelo professor na identificação desse aluno.

Como exemplo, ao considerar a regra 2, tem-se a seguinte interpretação: que todos os alunos que enviaram algumas vezes atividades individuais em atraso e que tiveram o conceito  $\leq$  B sentiram-se desanimados enquanto realizavam atividades individuais.

Utilizando a regra 8 como exemplo, temos que ao considerar o atributo q5, que diz respeito a como o aluno se sente quando tem dificuldade com algum conteúdo, observa-se que a regra testada no experimento B diz que 60% dos alunos que se sentem desanimados quando tem dificuldade com um conteúdo e que enviaram menos de 7 atividades, apresentaram dificuldades com o conteúdo algumas vezes.

Dessa forma, através das regras validadas no experimento 2, pode-se observar que mesmo com a adaptação, foi possível identificar prováveis alunos propensos ao desânimo, revelando que podem ser usadas para um modelo genérico de evidência do desânimo, ao analisar ações comportamentais relacionadas às atividades realizadas pelos alunos.

## 6. CONSIDERAÇÕES FINAIS

O presente trabalho teve como objetivo analisar e identificar padrões de comportamento de alunos que estão desanimados em um AVEA, aplicando MDE a fim de realizar esta inferência. Para isso foram feitos dois experimentos com dados de alunos de mesmo perfil, ou seja, pertenciam à mesma disciplina, curso, professor e foi utilizada a mesma didática, porém, em semestres diferentes.

O algoritmo Apriori foi aplicado no primeiro experimento, onde o mesmo foi dividido em três etapas buscando a estratégia de dividir para conquistar partindo de análises locais para globais para obter as melhores regras de associação. Ao final, foram identificadas 8 regras de associação que representam o padrão de comportamento do aluno que realiza atividades individuais ou em grupo estar desanimado.

As regras encontradas foram aplicadas no experimento 2, a fim de obter um modelo de regras genérico para esse perfil de aluno.

Após o experimento, algumas regras foram adaptadas e mostraram-se eficientes na identificação de alunos propensos ao desânimo.

Sendo assim, as reflexões a cerca da temática da dimensão afetiva no contexto educacional e a possibilidade da evidência do desânimo do aluno pode representar um progresso quanto a possibilidade da sua inferência. O desânimo pode levar o aluno ao processo de desistência de uma atividade ou até mesmo de um curso. Uma questão importante, nestes casos, é que esse processo pode ser revertido se ocorrer interferências feitas pelo professor, ou automaticamente por um sistema, quando identificado o estado emocional no aluno, que no presente caso pode ser realizado aplicando as RA encontradas e validadas no experimento.

Dessa forma, sugere-se que as RA encontradas com melhores escores podem ser usadas para compor um modelo computacional genérico que identifique alunos com propensão ao estado de ânimo desanimado e, ao final, apresente os alunos identificados nesse modelo computacional para o professor, a fim de que ele possa acompanhar esses alunos apropriadamente.

Portanto, em trabalhos futuros, pretende-se desenvolver o modelo computacional genérico para a identificação do desânimo e, ao mesmo tempo, apresentar ao professor os alunos desanimados utilizando modelos gráficos como os exemplos dos *dashboards*.

## REFERÊNCIAS

- [1] 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.
- [2] Bercht, M. (2001). Em Direção a Agentes Pedagógicos com Dimensões Afetivas. Tese de doutorado. Universidade Federal do Rio Grande do Sul. Programa de Pós-Graduação em computação.
- [3] Damando, F. S.; Bercht, M.; Wives, L. K. (2014). Disposição Afetiva do Aluno em Interação em um Ambiente Virtual de Ensino e Aprendizagem. XIX Conferência Internacional sobre Informática Educativa - TISE. *Nuevas Ideas en Informática Educativa*. Vol. 10.
- [4] Damando, F. S.; Bercht, M.; Wives, L. K.; Cazella, S. C. (2015). Análise de Evidências do Estado de Ânimo Desanimado de Alunos de um AVEA: uma Proposta a partir da Aplicação de Regras de Associação. II Workshop de Mineração de Dados Educacionais - IV Congresso Brasileiro de Informática na Educação.
- [5] Damásio, A. (1996). *O erro de Descartes: emoção, razão e o cérebro humano*. São Paulo: Companhia das Letras.
- [6] Figueiredo, F. J. Q. (2011) Fatores Afetivos e Aprendizagem de Línguas: foco na escrita e correção de erros. Afetividade e emoções no ensino/aprendizagem de línguas: múltiplos olhares. Mastrella-de-Andrade (Org.). *Coleção Novas Perspectivas em Linguística Aplicada* Vol. 18. Campinas, SP. Pontes Editores.
- [7] Gaudioso, E.; Talavera, L. (2006). Data mining to support tutoring in virtual learning communities: experiences and challenges. In *Data mining in e-learning*. WIT Press.
- [8] 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.
- [9] Jaques, P. A.; Nunes, M. A. S. N. (2012). Ambientes Inteligentes de Aprendizagem que inferem, expressam e possuem emoções e personalidade. In: Seiji Isotani e Fernanda C. A. Campos. (Org.). *Jornada de Atualização em Informática na Educação- JAIE 2012*. 1ed. Porto Alegre: SBC. , V. 1, p. 32-71.
- [10] Longhi, M. T. (2011). *Mapeamento de Aspectos Afetivos em um Ambiente Virtual de Aprendizagem*. Tese de doutorado. PPGIE/UFRGS.
- [11] Machado, L. R.; Longhi, M. T.; Behar, P. A. (2013). *Domínio Tecnológico: saberes e fazeres na educação a distancia. Competência em Educação a Dsitância*. Porto Alegre: Penso.
- [12] 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 No.12.
- [13] Piaget. J. (2014). *Relações Entre a Afetividade e a Inteligência no Desenvolvimento Mental da Criança*. Organização e Tradução: Saltini e Cavenaghi. Rio de Janeiro. Wak Editora.
- [14] Picard. R. W. (2000). *Affective Computing*. The MIT Press.
- [15] 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.
- [16] Santos, O.; Majadas, S. S.; Boticario, J. G. (2013) *Affective state detection in educational systems through mining multimodal data sources*. The 6th International Conference on Educational Data Mining.
- [17] Sacharin, V.; Schlegel, K.; Scherer, K.R.(2013). *Geneva Emotion Wheel rating study (report)*. Swiss Center of Affective Sciences. University of Geneva. August.
- [18] Scherer, K.R. (2005). What are the emotions? And how can they measured? In: *Social Science Information*.
- [19] Silva, M. L.; Cruz, V. A.; Silva, F. F. (2014). A Dimensão Afetiva e sua Relevância no Processo de Ensino Aprendizagem: Uma abordagem Sociocognitiva. *REGET - Revista Eletrônica em Gestão, Educação e Tecnologia Ambiental*. V. 18, N. 3.
- [20] Tan, Pang-Ning; Steinbach, M.; Kumar, V. (2009). *Introdução ao DataMining* Mineração de Dados. Rio de Janeiro: Editora Ciência Moderna Ltda.
- [21] Webber, C. G.; Zat, D.; Lima, M. F. W. P. (2013). Utilização de algoritmos de agrupamento na mineração de dados educacionais. *Revista Renote: Novas tecnologias na educação*.
- [22] Yang, M. H. I.; Damásio, A. (2007). We feel, Therefore Learn: The Relevance of Affective and Social Neuroscience to Education. *Maind, Brain and Education*, Vol.1, N.1.