

# Avaliação da percepção de discentes e da avaliação de docentes em relação ao trabalho de conclusão de curso utilizando ferramentas de *data mining* – estudo de caso

Rondinelli de Carvalho Ladeira  
rondinellicl@uol.com.br

Sérgio Henrique de Matos Machado  
sergiojf@ig.com.br

Geórgia Regina Rodrigues Gomes  
georgia@ucam-campos.br



## RESUMO

*O Trabalho de Conclusão de Curso (TCC) representa parte importante na formação do discente e recebe nota máxima como instrumento de avaliação de cursos de graduação proposto pelo MEC. Isso por ser capaz de identificar questões, escolher métodos para resolvê-las, tabular os resultados e analisá-los corretamente, além de formar profissionais que interessam a todos os tipos de mercado. Sua percepção pode ser refletida através da avaliação institucional. Este trabalho teve por objetivo tornar o discente apto, bem como discutir percepções relacionadas ao TCC em um estudo de caso de um curso de Engenharia de Produção de uma universidade privada. Foram entrevistados 54 alunos de TCC e 10 professores orientadores. Mediante o uso de ferramentas de Data Mining (DM), os dados obtidos nas entrevistas foram minerados e clusterizados pelo algoritmo Simple Kmeans, definindo as classes de acordo com certos atributos para diagnosticar e compreender aspectos da relação discente/orientador e suas influências no processo de produção do TCC. Foram obtidos quadros com as clusterizações por atributo sobre a autoavaliação do professor e a avaliação do aluno. A formação de padrões pelos atributos permitiu, à luz dos especialistas, a mensuração da qualidade das atividades de trabalho de conclusão de curso, demonstrando que o DM representa opção válida aos processos de análise e avaliação no ambiente acadêmico.*

**Palavras-chave:** Avaliação do docente, Data Mining, Percepção do discente, Trabalho de Conclusão de Curso (TCC).

## Evaluation of the students' perception and evaluation of teachers in relation to the work completion of course using data mining tools - case study

### ABSTRACT

*The completion of course work (CCW) is an important part in the formation of student receives the maximum score as an evaluation tool for undergraduate courses offered by the MEC, for professionals who are interested to form all types of markets by being able to identify questions, choose methods to solve them, tabulate the results and analyze them properly. Your perception may be reflected by evaluating institucional. This work aims to become fit and discuss their perceptions regarding CCW) in a case study of a course in Production Engineering from a private university. Interviews were held 54 students and 10 teachers. Using tools of Data Mining (DM) data obtained in the interviews were mined and clustered by Simple Kmeans algorithm, setting the classes according to certain attributes to diagnose and to understand aspects of the relationship student / advisor and their influences in the production process of CCW. Frames were obtained with the clusterizações by attribute on self-assessment and evaluation of the student teacher. The formation of patterns in the attributes of light allows specialists to measure the quality of the work activities of completion demonstrating that DM is a valid option to the processes of analysis and evaluation in the academic environment.*

**Keywords:** Teacher evaluation, Data Mining, Student perception, Completion of course work (CCW).

## 1. Introdução

Nos últimos anos, tem-se observado aumento da população universitária com características bastante heterogêneas, como: classe social, gênero, objetivos, expectativas, trajetória acadêmica anterior, faixa etária, situação de trabalho e opção pelo turno, entre outras. As instituições estão se multiplicando para atender a essa demanda, no entanto também é preciso que estejam preparadas não só por meio de inovação tecnológica e novos espaços educativos, mas com a busca de maior conhecimento sobre o estudante de ensino superior (SCHLEICH et al., 2006).

O censo do ensino superior revelou que o total de instituições passou de 1.391 em 2001 para 2.378 em 2010. No que se refere à participação percentual das instituições por categoria administrativa, os totais apresentados mostraram-se relativamente constantes durante a série histórica. Em 2010, esses totais representavam 88,3% de instituições privadas, 4,5% estaduais, 4,2% federais e 3,0% municipais. A evolução do número de instituições de ensino superior é demonstrada na Figura 1.

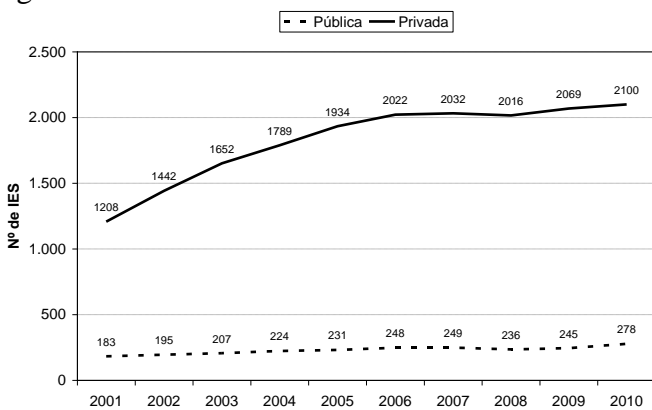


Figura 1– Evolução do número de instituições de educação superior públicas e privadas no Brasil – 2001-2010

Fonte: MEC/INEP, 2012 (modificado).

Schwartzman e Schwartzman (2002) demonstraram a evolução da matrícula no ensino superior público e privado entre 1990 e 2000 (Figura 2).

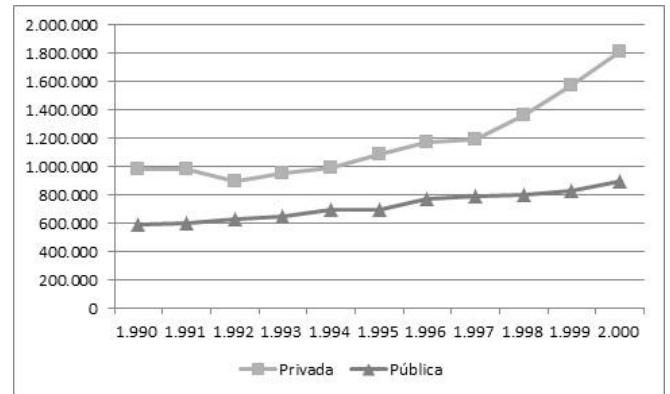


Figura 2 – Evolução da matrícula no ensino superior público e privado, 1990-2000

Fonte: SCHWARTZMAN; SCHWARTZMAN, 2002.

Schleich et al. (2006) notaram em alguns países, e aqui no Brasil especialmente, o empenho por parte do governo em abrir mais vagas. Porém, ainda falta o mesmo empenho na adequação das instalações, das políticas e dos processos educativos diante da diversidade de características e expectativas dessa população. Assim, verifica-se que as instituições de ensino superior, de modo geral, continuam oferecendo cursos padronizados, com currículos fechados, métodos de ensino ineficazes, instalações mínimas de apenas salas de aula, sem considerar a diversidade de características dos estudantes.

Schwartzman e Schwartzman (2002) afirmaram que número relativamente pequeno de instituições (5%) concentra quase que a metade da matrícula no ensino superior privado no país, enquanto no outro extremo 50% das instituições absorvem somente 5% da matrícula. Os referidos autores alertaram para a heterogeneidade do setor, em que poucas instituições são consideradas grandes e englobam a maioria dos alunos, ao passo que as pequenas e médias disputam as poucas matrículas restantes.

Além da forte concorrência, segundo Rios (2010), uma das principais preocupações de cursos em diversas instâncias, desde o fundamental até os de pós-graduação, estão associadas aos índices de evasão. Diversos fatores podem ser citados, como aspectos econômicos, familiares, sociais e vocacionais.

Silva Filho et al. (2007) afirmaram que a evasão estudantil no ensino superior é um problema internacional que afeta o resultado dos sistemas educacionais. As perdas de estudantes que iniciam, mas não terminam seus cursos, são desperdícios

sociais, acadêmicos e econômicos. Verifica-se, em todo o mundo, que a taxa de evasão no primeiro ano de curso é duas a três vezes maior do que a nos anos seguintes. Esse é um problema muito estudado no exterior e influi na relação entre evasão anual e índice de titulação.

Combater a evasão é possível com a utilização do recurso da avaliação institucional, que é ferramenta pedagógica e de gestão determinada pela Lei de Diretrizes e Bases de 1996 (BAGGI; LOPES, 2009).

Como forma de avaliar a qualidade do ensino superior nas diversas unidades de ensino, as faculdades têm-se valido da autoavaliação, ferramenta que estuda o desempenho dos docentes à luz dos discentes. Loureiro et al. (2006) estudaram o desempenho dos docentes com a participação do corpo discente no meio acadêmico.

Gomes et al. (2010) ressaltaram que a baixa produção científica sobre a avaliação do rendimento acadêmico em cursos destinados aos profissionais da área da Saúde se deve ao fato de os profissionais dessa área que atuam como professores universitários optarem por programas de pós-graduação em suas áreas de formação específica, em razão da maior valorização profissional pelas Instituições de Ensino Superior (IES), Conselho Nacional de Pesquisa (CNPq), Coordenação de Aperfeiçoamento de Pessoal do Ensino Superior (CAPES) e demais fundações, a exemplo da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP). Tema esse que certamente contribuiria para diagnosticar as dificuldades dos alunos em certas disciplinas. Assim, as avaliações podem fornecer a base de dados sobre informações da produtividade com o objetivo de prestar às coordenações e instituições informações sobre as atividades de docentes em relação às disciplinas, o relacionamento com o discente, a produção acadêmica. Assim como afirmaram Ribeiro et al. (2010), as instituições recebem um *feedback* por parte de seus clientes, permitindo traçar estratégias para valorização total do curso e das disciplinas.

Segundo Bittencourt et al. (2011), a apresentação de medidas estatísticas descritivas relativas às dimensões presentes em um instrumento de avaliação proposto permite ao corpo docente perceber, de forma sintética, a avaliação da ação ensino-aprendizagem sob a visão do aluno. Os resultados de avaliação propiciam a reflexão entre professores e gestores, contribuindo para aprimorar o projeto pedagógico institucional. O conjunto de informações constituído pelas avaliações de

disciplinas de uma IES é importante fonte de informação que merece ser explorada, permitindo diagnosticar e retroalimentar a instituição sobre a efetividade de seu corpo docente; quantificar a efetividade do docente com vistas à sua promoção; prover informação aos estudantes, buscando orientá-los na seleção de disciplinas e instrutores; e propiciar atividades de pesquisa em Educação.

A autoavaliação interna deve ser relacionada com a avaliação externa dessa forma de produzir conhecimento global para discussões sobre os aspectos da qualidade sobrepondo as interfaces entre os pontos positivos e negativos, com vistas à maximização da qualidade do ensino (SILVA et al., 2010).

Nunes e Helfer (2009) afirmaram que, embora haja consenso a respeito do caráter formativo da avaliação institucional, finalizadas as etapas de diagnóstico do processo, normalmente os responsáveis pela sua condução são tomados por certo desinteresse. Isso porque, “seja da avaliação dos professores pelos alunos, seja da avaliação da instituição pelos docentes, seja de qualquer outra sistematização avaliativa, os protagonistas, em geral, não chegam à fase de intervenções”.

Com o auxílio de modelos matemáticos e ferramentas de mineração de dados, pode-se obter conhecimento de bases de dados com a ajuda de algoritmos que permitem a clusterização, classificação ou regras de associação (ARAÚJO, 2006).

A mineração de dados pode facilitar o entendimento de grande número de dados agrupados. O *knowledge discovery in databases* (KDD) é um processo composto pela seleção de dados, pré-processamento, transformação dos dados e estabelecimento de padrões úteis na extração de conhecimento, ou seja, tradução de dados brutos em informações relevantes. Uma das etapas do processo de KDD é o *Data Mining* (DM) (VIANNA, 2010).

Segundo Harrison (1998), mineração de dados consiste na exploração e análise, por meios automáticos ou semiautomáticos, de grandes quantidades de dados para descobrir modelos e regras significativas.

De acordo com Tan et al. (2009), as técnicas de mineração de dados são organizadas para agir sobre grandes bancos de dados, com o intuito de descobrir padrões úteis e recentes que poderiam, de outra forma, permanecer ignorados. É importante não confundir os termos mineração de dados e descoberta de conhecimento, visto que a descoberta

de conhecimento é todo o processo até que se chegue ao resultado de um padrão de comportamento das variáveis ou relações. Já a mineração de dados é considerada apenas uma das etapas que compõem o KDD.

Para tal finalidade, o objetivo deste trabalho foi utilizar *Data Mining* como forma de avaliar a percepção de alunos através da base de dados da autoavaliação dos professores e a avaliação destes pelos alunos nos Trabalhos de Conclusão de Curso (TCC) do curso de Engenharia de Produção da Universidade Cândido Mendes do ano 2008.

Apesar do objetivo de introduzir o aluno no universo da pesquisa acadêmica, os TCCs formam profissionais que interessam a todos os tipos de mercado, por serem capazes de identificar questões, escolher métodos para resolvê-las, tabelar os resultados e analisá-los corretamente – "A ideia é formar solucionadores de problemas" (AMORIN, 2009).

No instrumento de avaliação de cursos de graduação proposto pelo MEC, o conceito máximo (5) é concedido quando o Trabalho de Conclusão de Curso (TCC) previsto/implantado está regulamentado/institucionalizado de maneira excelente, considerando, em uma análise sistêmica e global, os aspectos carga horária, orientação e coordenação (INEP, 2011).

## 2. KDD (Knowledge Discovery in Databases)

Com base no desenvolvimento das informações, houve a necessidade de a engenharia computacional promover o arquivamento e mineração de dados, permitindo a obtenção de perfis sobre a ótica de um especialista. Dessa forma, como salientaram Galvão e Marin (2009), *Data Mining* é uma das opções mais eficazes para extrair conhecimento a partir de grandes volumes, na revelação de relações ocultas e padrões e gerar regras para a tomada de decisões.

O DM representa uma das etapas do Knowledge Discovery in Databases (KDD). Cardoso (2008) evidenciou que a descoberta do conhecimento através de banco de dados tem como principal etapa o DM. Assim, o processo de KDD utiliza métodos estatísticos e técnicas de inteligência artificial (GALVÃO; MARIN, 2009).

A primeira etapa representa o levantamento das bases para a compilação dos dados em formatos compatíveis com a tabulação de planilhas executáveis pelo software utilizado. Porém, de forma conjunta, a etapa de pré-processamento padroniza os dados compilados em uma matriz atributo-valor que propicia o tratamento matemático e a obtenção de padrões estimativos que permitem o apoio à decisão (ARAUJO, 2006). Tal divisão pode ser evidenciada na Figura 3 (CARDOSO, 2008).

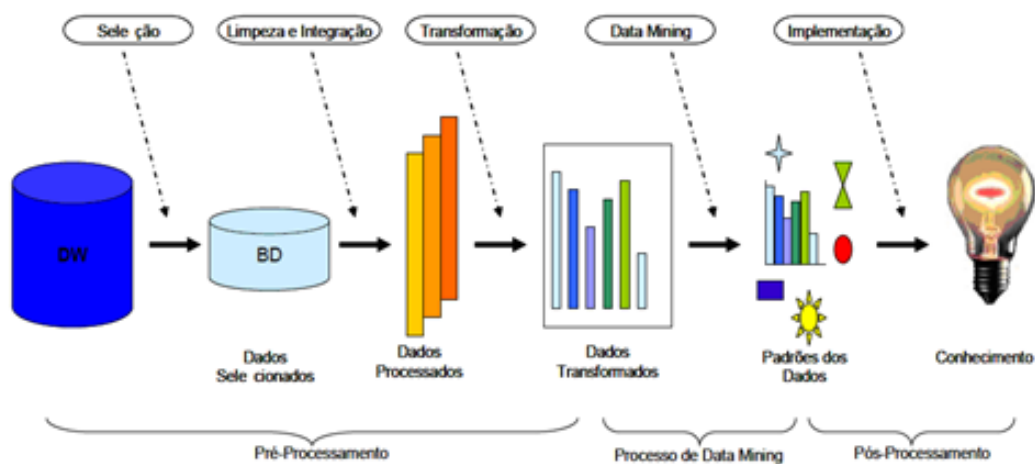


Figura 3 – Etapas do processo do KDD

Fonte: Adaptado de FAYYAD et al., 1996.

Nessa etapa, como descreveram Oliveira e Garcia (2009), é estipulado o domínio dentro do qual serão categorizados os padrões a serem descobertos. Dessa forma, nesse domínio serão necessárias etapas de limpeza, eliminação de ruídos

e adequação de valores que estejam fora de contexto, assim como a escolha de variáveis a serem discutidas.

De acordo com Dias (2010), para que o processo seja realizado com eficiência utiliza-se um



processo chamado de Descoberta de Conhecimento (Knowledge Discovery in Database –KDD ou Descoberta de Conhecimento em Banco de Dados – DCBD), o qual possui várias etapas para tornar possível a identificação de padrões ou o levantamento de algumas informações em forma de conhecimento, o que não é possível descobrir apenas aos olhos humanos.

A etapa de transformação é representada por tarefas de processamentos dos dados por algoritmos, redes neurais, árvores de decisão, lógica nebulosa e tratamentos estatísticos que projetam padrões descritivos e preditivos sobre os objetivos

propostos pela luz dos especialistas (CARDOSO, 2008).

Com o crescimento das bases de dados nas últimas décadas, tornou-se difícil aos olhos humanos identificar conhecimento nesses grandes volumes de dados, trazendo o problema de "muitos dados, mas pouco conhecimento". Diante desse problema surgiram as técnicas que permitem a automatização e análise de forma inteligente e técnicas que procuram transformar grandes bases de dados em conhecimento, que é o objetivo do KDD (FAYYAD, 1996).

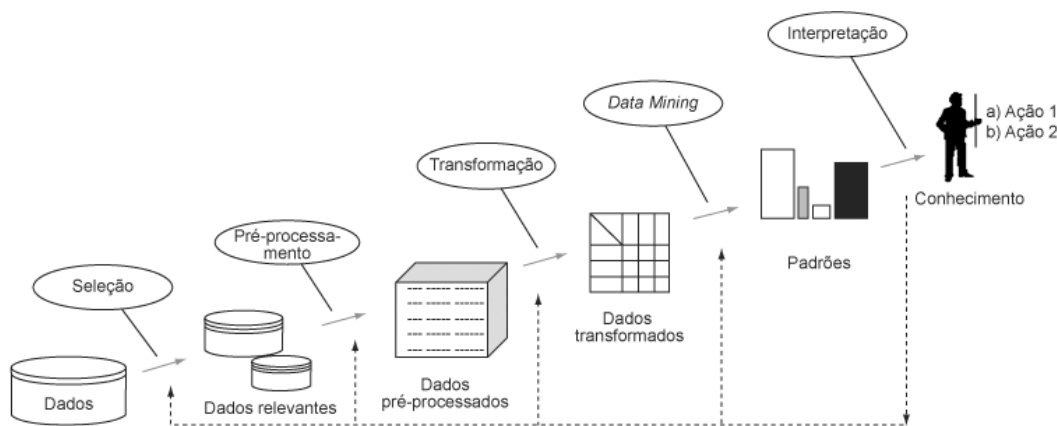


Figura 4 - Etapas do processo KDD

Fonte: FAYYAD et al., 1996.

A tarefa de clusterização é utilizada para separar os registros de uma base de dados em subconjuntos ou clusters (agrupamentos), de tal forma que os elementos de um cluster maximizam a similaridade intracluster e minimizar similaridade de objetos de cluster diferentes. Os algoritmos mais utilizados nessa tarefa são os K-Means, K-Modes, K-Prototypes, K-Medoids e K-ohonem (CARDOSO; MACHADO, 2008). Dessa forma, a clusterização procura grupos de padrões como padrões pertencentes a um mesmo grupo e que são mais similares uns aos outros e dissimilares a padrões em outros grupos (NETO et al. 2010).

A associação consiste em identificar associações entre variáveis simultaneamente. De forma frequente em banco de dados é também comum a procura de associações entre itens durante um intervalo temporal, em que o modelo matemático mais utilizado é o algoritmo Apriori (GOLDSCHMIDT; PASSOS, 2005). A regressão consiste em buscar um atributo numérico (contínuo) sobre um banco de dados para sua implementação, em que são utilizados modelos estatísticos e redes neurais (CARDOSO; MACHADO, 2008).

Após a obtenção de regras, clusters e associações, os resultados podem ser analisados por especialistas e analistas que podem realimentar o sistema quando os resultados não forem satisfatórios, como relataram Dalfovo et al. (2010). Dessa forma, o uso de mineração de dados pode evidenciar, como nunca antes, estudos prospectivos no ambiente escolar para definição e apontamento de ações.

Para o processo de mineração de dados são utilizadas ferramentas computacionais, como *Waikato Environment for Knowledge Analysis – Weka* (SILVA 2010), em que o processamento de arquivos ocorre com as extensões *ARFF*, *CSV*, *MATLAB* e demais com interface em *JAVA* (WEKA, 2010).

### 3. Metodologia

Foram realizadas entrevistas entre os meses de outubro a dezembro de 2008 com 54 alunos graduandos na condição de orientados (90% dos alunos matriculados na disciplina de TCC) e 10

professores (90,9% dos orientadores) orientadores do Curso de Engenharia de Produção da Universidade Cândido Mendes (UCAM-Campos), para coleta das percepções quanto ao desempenho dos orientadores relacionados aos critérios: C1- Conhecimento específico relacionado ao tema da monografia; C2- Experiência em pesquisa; C3- Interesse/comprometimento; C4- Relacionamento interpessoal; C5- Capacidade de expressão; C6- Absorção de críticas; C7- Resolução de problemas; C8- Uso de métodos organizados; C9- Capacidade de estimular; C10- Número de orientados compatível; C11- Tempo disponível; e C12- Seu desempenho geral como orientador/aluno.

Quanto ao desempenho dos alunos, foram obtidas percepções relacionadas aos mesmos critérios, excetuando-se a capacidade de estimular (C9) e o número de orientados compatível (C10), uma vez que se entende que tais percepções não são competências intrínsecas aos alunos.

O recurso de questionários é empregado para levantamento de dados através de amostragens. As informações coletadas ajudam na percepção de satisfação, ideias, origens sociais e econômicas. Todas essas informações podem ser adquiridas de diversas maneiras: questionários, através da interação entre perguntas e respostas; observações; e arquivos. Primeiro, deve-se garantir a confiança para o entrevistado, mostrando a ele para e com quem trabalha e qual o objetivo do estudo. Logo após é determinante apresentar ao respondente a importância e o seu interesse que pode haver pelo tema (GÜNTHER, 2003).

Para o bom aproveitamento do questionário, o entrevistador deve somente aplicar a quem provavelmente possui as informações que procura. O questionário deve ser um mecanismo que auxilie o pesquisador a respeito do que se está pesquisando, portanto não pode possuir um roteiro simples de questões (COBRA, 1991).

O pré-teste é uma etapa válida no questionário, pois possibilita a descoberta de falhas como: complexidade e inconsistência das questões, ambiguidade e perguntas desnecessárias. Nesta etapa aplica-se, então, o questionário a uma pequena parte de entrevistados; logo após, faz-se a tabulação dos dados para, em seguida, avaliar os resultados, a fim de identificar as possíveis falhas, assim como obter a estimativa dos futuros resultados (LISBÔA, 2011).

Chagas (2000) ressaltou a importância da realização de um pré-teste porque é provável que

não se consiga prever todos os problemas e, ou, dúvidas que possam surgir durante a aplicação do questionário. Sem o pré-teste poderá haver grande perda de tempo, dinheiro e credibilidade caso se constate algum problema grave com o questionário já na fase de aplicação. Nesse caso, o questionário terá que ser refeito e estarão perdidas todas as informações.

Os dados coletados foram tabulados em Microsoft Office Excel<sup>®</sup> 2007, pré-processados, aplicados na ferramenta Weka 3.6.4 e clusterizados pelo algoritmo *Simple Kmeans*, definindo-se as classes de acordo com os atributos: Regime de contratação; Experiência de magistério superior; Experiência de magistério no ensino médio; Experiência profissional; Trabalhos publicados (Produção científica); Formação pedagógica; e Nota da TCC.

A escala de percepção dos atributos variou seguindo os critérios representados na Tabela 1.

Tabela 1 – Valores atribuídos à percepção

<b>EXPERIÊNCIA DE MAGISTÉRIO SUPERIOR</b> 0 A 4 – POUCA 5 A 8 – MÉDIA MAIS DO QUE 8 – MUITA
<b>EXPERIÊNCIA DE MAGISTÉRIO – ENSINO MÉDIO</b> <b>EXPERIÊNCIA PROFISSIONAL</b> 0 – NÃO OUTROS – SIM
<b>TRABALHOS PUBLICADOS – PRODUÇÃO CIENTÍFICA</b> ATÉ 3 – BAIXA 4 A 9 – MÉDIA MAIS DO 9 – ALTA
<b>NOTA</b> NOTA $\leq$ 8 – C 8 < NOTA $\leq$ 9 – B NOTA > 9 – A

#### 4. Resultados e discussão

Os Quadros 1 e 2 ilustram a autoavaliação dos professores orientadores e a avaliação do aluno, respectivamente, quanto ao regime de trabalho, sendo 0 para regime parcial, 1 para horista e 2 para integral. Pode-se observar, nesses quadros, que professores enquadrados em regime de horista se autoavaliam bem, porém, quando o aluno o avalia, têm-se notas mais baixas (REGULAR) para os quesitos Conhecimento específico e Número de orientados compatível, enquanto professores de regimes parcial e integral que não se avaliaram tão bem tiveram avaliação ÓTIMA em vários quesitos.

Quadro 1 – Clusterização com atributo Regime de contratação pela autoavaliação do docente

Attribute	Full Data (31)	Cluster#		
		0 (18)	1 (11)	2 (2)
Conhecimento_especifico	BOM	REGULAR	ÓTIMO	BOM
Experiência_em_pesquisa	BOM	BOM	ÓTIMO	BOM
Interesse/comprometimento	BOM	BOM	ÓTIMO	BOM
Relacionamento_interpessoal	ÓTIMO	BOM	ÓTIMO	BOM
Capacidade_de_expressão	BOM	BOM	ÓTIMO	BOM
Absorção_de_críticas	ÓTIMO	OTIMO	ÓTIMO	REGULAR
Resolução_de_problemas	BOM	BOM	ÓTIMO	BOM
Uso_de_métodos_organizados	BOM	BOM	ÓTIMO	PESSIMO
Capacidade_de_estimular	BOM	BOM	ÓTIMO	REGULAR
Nº_de_orientados_compatível	REGULAR	REGULAR	BOM	REGULAR
Tempo_disponível	REGULAR	REGULAR	BOM	REGULAR
Desempenho_geral	BOM	BOM	BOM	BOM
Cluster 0 <-- PARCIAL				
Cluster 1 <-- HORISTA				
Cluster 2 <-- INTEGRAL				
Incorrectly clustered instances : 11.0 35.4839%				

Quadro 2 – Clusterização com atributo Regime de contratação sob a luz dos discentes

Attribute	Full Data (31)	Cluster#		
		0 (13)	1 (7)	2 (11)
Conhecimento_especifico	BOM	BOM	REGULAR	BOM
Experiência_em_pesquisa	BOM	BOM	BOM	ÓTIMO
Interesse/comprometimento	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Relacionamento_interpessoal	BOM	BOM	BOM	ÓTIMO
Capacidade_de_expressão	BOM	BOM	BOM	ÓTIMO
Absorção_de_críticas	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Resolução_de_problemas	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Uso_de_métodos_organizados	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Capacidade_de_estimular	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Nº_de_orientados_compatível	BOM	BOM	REGULAR	ÓTIMO
Tempo_disponível	BOM	REGULAR	BOM	ÓTIMO
Desempenho_geral	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Cluster 0 <-- PARCIAL				
Cluster 1 <-- HORISTA				
Cluster 2 <-- INTEGRAL				
Incorrectly clustered instances : 19.0 61.2903%				

Os Quadros 3 e 4 trazem a autoavaliação e a avaliação dos alunos, respectivamente, acerca do atributo Experiência no magistério superior. Percebe-se, nesses quadros, que os alunos avaliaram os professores com muita experiência (mais que 8 anos) melhor que eles próprios se avaliaram. Os professores com média experiência (5 a 8 anos) não se avaliaram como ÓTIMO, porém os discentes o

fizeram em seis dos quesitos. já os professores com pouca experiência (até 4 anos) se avaliaram melhor do que a avaliação que receberam dos alunos, embora tenham sido classificados como BOM em quase todos os quesitos, excetuando-se o quesito Tempo disponível, que foi REGULAR.

Quadro 3 – Clusterização com atributo Experiência de magistério superior pela autoavaliação do docente

Attribute	Full Data (31)	Cluster#		
		0 (18)	1 (11)	2 (2)
Conhecimento_especifico	BOM	REGULAR	ÓTIMO	BOM
Experiência_em_pesquisa	BOM	BOM	ÓTIMO	BOM
Interesse/comprometimento	BOM	BOM	ÓTIMO	BOM
Relacionamento_interpessoal	ÓTIMO	BOM	ÓTIMO	BOM
Capacidade_de_expressão	BOM	BOM	ÓTIMO	BOM
Absorção_de_críticas	ÓTIMO	ÓTIMO	ÓTIMO	REGULAR
Resolução_de_problemas	BOM	BOM	ÓTIMO	BOM
Uso_de_métodos_organizados	BOM	BOM	ÓTIMO	PESSIMO
Capacidade_de_estimular	BOM	BOM	ÓTIMO	REGULAR
Nº_de_orientados_compatível	REGULAR	REGULAR	BOM	REGULAR
Tempo_disponível	REGULAR	REGULAR	BOM	REGULAR
Desempenho_geral	BOM	BOM	BOM	BOM
Cluster 0 <-- MUITA				
Cluster 1 <-- POUCA				
Cluster 2 <-- MÉDIA				
Incorrectly clustered instances : 10.0 32.2581%				

Quadro 4 – Clusterização com atributo Experiência de magistério superior sob a luz dos discentes

Attribute	Full Data (31)	Cluster#		
		0 (13)	1 (7)	2 (11)
Conhecimento_especifico	BOM	BOM	REGULAR	BOM
Experiência_em_pesquisa	BOM	BOM	BOM	ÓTIMO
Interesse/comprometimento	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Relacionamento_interpessoal	BOM	BOM	BOM	ÓTIMO
Capacidade_de_expressão	BOM	BOM	BOM	ÓTIMO
Absorção_de_críticas	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Resolução_de_problemas	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Uso_de_métodos_organizados	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Capacidade_de_estimular	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Nº_de_orientados_compatível	BOM	BOM	REGULAR	ÓTIMO
Tempo_disponível	BOM	REGULAR	BOM	ÓTIMO
Desempenho_geral	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Cluster 0 <-- POUCA				
Cluster 1 <-- MÉDIA				
Cluster 2 <-- MUITA				
Incorrectly clustered instances : 15.0 48.3871%				

Para a análise dos dados foram relacionados os clusters relativos à Experiência em magistério no ensino médio, cujos resultados foram apresentados em dois agrupamentos: 20 (65%) e 11 (35%), respectivamente, com 35.4839% de agrupamentos incorretos. Os dados relacionados ao aluno na autoavaliação obtiveram os mesmos números de agrupamentos com respectivo valor para 0 16 (52%) e 1 15(48%), com 41.9355% de agrupamentos incorretos.

Para Demo (2006), pessoas bem formadas não só questionam a formação oferecida pelas instituições, como também, principalmente, a sua

própria formação. Avaliar é um processo desgastante e que, se não for bem direcionado, pode trazer prejuízos e não benefícios. O segredo está em transformar todos esses momentos de análise em uma forma de crescimento institucional e profissional (ROSA et al., 2011).

Os dados relacionados com o atributo tempo de magistério permitem, na avaliação do aluno (Figura 2), perceber que os professores com tempo de magistério foram mais bem qualificados em relação ao maior número de atributos, tendo como pontos positivos o relacionamento pessoal, a capacidade de estimular, o uso de métodos



organizados, o conhecimento específico e a capacidade de expressão.

Como a clusterização apresentou divisão com grupos homogêneos para as respostas dos discentes 16 (52%) e 15 (48%), percebe-se que, pela ótica dos alunos, esses mesmos professores se dedicavam a menor número de orientados e apresentavam menor experiência em pesquisa.

Quanto ao ponto da avaliação dos professores sem experiência no magistério, percebeu-se que eles apresentavam comportamento regular para o tempo disponível e para o número de orientandos. Fato que tornou esses quesitos uma relação equânime entre os pontos de vista do professor e do discente, bem como um ponto discrepante em relação aos alunos e aos docentes com experiência no magistério. Esses professores alegaram bons a ótimos desempenhos nos atributos relacionados e obtiveram resultados regulares quando avaliados pelos alunos.

No tocante ao atributo Experiência profissional sob a luz dos docentes, foram obtidos os perfis de agrupamentos, em que a clusterização da autoavaliação por parte dos docentes foi formada por dois grupos: sem experiência profissional e com experiência profissional, respectivamente com 20 (65%) e 11 (35%).

Na avaliação do atributo Experiência profissional do professor por parte do aluno, foram obtidos dois grupos: representados pela falta de

experiência profissional 16 (52%) e pelos docentes com experiência profissional 15 (48%).

Pela análise dos dados, pôde-se perceber que os docentes com experiência profissional são mais concisos em relação ao conhecimento específico do que os docentes sem experiência profissional. Os docentes do grupo com experiência profissional foram mais bem avaliados em outros atributos, como relacionamento interpessoal, resolução de problemas, uso de métodos organizados, assim como, da mesma forma, em relação àqueles clusterizados com experiência em magistério.

Evidenciou-se, assim, que os docentes com experiência profissional e magistério apresentavam pouco número de orientandos e pouca atividade em pesquisa. Na análise entre os pontos de vista discente e docente, foi averiguada ineficiência na disponibilidade de tempo dos profissionais sem experiência profissional.

Para a clusterização com o atributo Trabalhos publicados como variável fixa, tem-se a clusterização apresentada nos Quadros 5 (autoavaliação dos docentes) e 6 (autoavaliação dos alunos), com três agrupamentos divididos, respectivamente, em: grupo 0 - 18 (58%), grupo 1 - 11 (35%), grupo 2 - 2 (6%) e grupo 0 - 13 (42%), grupo 1 - 7 (23%) e grupo 2 - 11 (35%), com 41.9355% e 54.8387% de grupamentos incorretos, respectivamente. O grupos 0 representa alta, o grupo 1 representa baixa e o grupo 2 sem classificação para trabalhos publicados.

Quadro 5 – Clusterização do atributo Trabalhos publicados sob a luz dos docentes

Attribute	Full Data (31)	Cluster#		
		0 (18)	1 (11)	2 (2)
Conhecimento_especifico	BOM	REGULAR	ÓTIMO	BOM
Experiência_em_pesquisa	BOM	BOM	ÓTIMO	BOM
Interesse/comprometimento	BOM	BOM	ÓTIMO	BOM
Relacionamento_interpessoal	ÓTIMO	BOM	ÓTIMO	BOM
Capacidade_de_expressão	BOM	BOM	ÓTIMO	BOM
Absorção_de_críticas	ÓTIMO	ÓTIMO	ÓTIMO	REGULAR
Resolução_de_problemas	BOM	BOM	ÓTIMO	BOM
Uso_de_métodos_organizados	BOM	BOM	ÓTIMO	PESSIMO
Capacidade_de_estimular	BOM	BOM	ÓTIMO	REGULAR
Nº_de_orientados_compativel	REGULAR	REGULAR	BOM	REGULAR
Tempo_disponível	REGULAR	REGULAR	BOM	REGULAR
Desempenho_geral	BOM	BOM	BOM	BOM
Cluster 0 <-- ALTA				
Cluster 1 <-- MEDIA				
Cluster 2 <-- No class				
Incorrectly clustered instances :		13.0	41.9355%	

Pode-se observar, nos dados do Quadro 5, que a autoavaliação do professor demonstra falhas em relação a um número pequeno de discentes que

não se incorporam ao uso de métodos organizados a absorção de críticas, e a capacidade de estimular esses discentes não apresentou clusterização

específica em relação ao volume de publicações. Aqueles professores que apresentaram alto volume de publicações não tiveram tempo suficiente e

número de alunos compatíveis para orientações de TCC.

Quadro 6 – Clusterização do atributo Trabalhos publicados sob a luz dos discentes

Attribute	Full Data (31)	Cluster#		
		0 (13)	1 (7)	2 (11)
Conhecimento_especifico	BOM	BOM	REGULAR	BOM
Experiência_em_pesquisa	BOM	BOM	BOM	ÓTIMO
Interesse/comprometimento	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Relacionamento_interpessoal	BOM	BOM	BOM	ÓTIMO
Capacidade_de_expressão	BOM	BOM	BOM	ÓTIMO
Absorção_de_críticas	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Resolução_de_problemas	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Uso_de_métodos_organizados	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Capacidade_de_estimular	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Nº_de_orientados_compatível	BOM	BOM	REGULAR	ÓTIMO
Tempo_disponível	BOM	REGULAR	BOM	ÓTIMO
Desempenho_geral	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Cluster 0 <-- BAIXA				
Cluster 1 <-- MEDIA				
Cluster 2 <-- ALTA				
Incorrectly clustered instances : 17.0 54.8387%				

Considerando o ponto de vista dos alunos, os professores com maior número de publicações foram mais bem avaliados em todos os atributos em relação aos com baixo ou médio número de publicações. Os docentes com médio número de publicações foram avaliados de melhor forma nos atributos Absorção de críticas, Resolução de problemas, Uso e métodos organizados e Capacidade de estimular os orientandos, isso quando comparados aos docentes com baixo número de publicações.

Na avaliação do aluno (Quadro 7), o doutor é mais bem avaliado nos quesitos: Conhecimento específico, Interesse/comprometimento, Relacionamento interpessoal, Capacidade de expressão, Absorção de crítica, Resolução de problemas, Uso de métodos organizados, Capacidade de estimular, Tempo disponível e Desempenho geral, perdendo em Experiência em pesquisa e nº. de Orientados compatível.

Quadro 7 – Clusterização com atributo Titulação dos docentes sob a luz dos discentes

Attribute	Full Data (31)	Cluster#	
		0 (16)	1 (15)
Conhecimento_especifico	BOM	BOM	ÓTIMO
Experiência_em_pesquisa	BOM	ÓTIMO	BOM
Interesse/comprometimento	ÓTIMO	BOM	ÓTIMO
Relacionamento_interpessoal	BOM	BOM	ÓTIMO
Capacidade_de_expressão	BOM	BOM	ÓTIMO
Absorção_de_críticas	ÓTIMO	BOM	ÓTIMO
Resolução_de_problemas	ÓTIMO	BOM	ÓTIMO
Uso_de_métodos_organizados	ÓTIMO	BOM	ÓTIMO
Capacidade_de_estimular	ÓTIMO	BOM	ÓTIMO
Nº_de_orientados_compatível	BOM	BOM	REGULAR
Tempo_disponível	BOM	REGULAR	BOM
Desempenho_geral	ÓTIMO	BOM	ÓTIMO
Cluster 0 <-- MESTRE			
Cluster 1 <-- DOUTOR			
Incorrectly clustered instances : 11.0 35.4839%			

Na autoavaliação do mestre, apresentada no Quadro 8, ele se avaliou melhor em todos os quesitos:

Quadro 8 – Clusterização com atributo Titulação do professor pela autoavaliação do docente

Attribute	Full Data (31)	Cluster#	
		0 (20)	1 (11)
Conhecimento_específico	BOM	REGULAR	ÓTIMO
Experiência_em_pesquisa	BOM	BOM	ÓTIMO
Interesse/comprometimento	BOM	BOM	ÓTIMO
Relacionamento_interpessoal	ÓTIMO	BOM	ÓTIMO
Capacidade_de_expressão	BOM	BOM	ÓTIMO
Absorção_de_críticas	ÓTIMO	ÓTIMO	ÓTIMO
Resolução_de_problemas	BOM	BOM	ÓTIMO
Uso_de_métodos_organizados	BOM	BOM	ÓTIMO
Capacidade_de_estimular	BOM	BOM	ÓTIMO
Nº_de_orientados_compatível	REGULAR	REGULAR	BOM
Tempo_disponível	REGULAR	REGULAR	BOM
Desempenho_geral	BOM	BOM	BOM
Cluster 0 <-- DOUTOR			
Cluster 1 <-- MESTRE			
Incorrectly clustered instances : 8.0 25.8065%			

Na avaliação do aluno, o bacharel é mais bem avaliado nos quesitos Conhecimento específico, Interesse/comprometimento, Relacionamento interpessoal, Capacidade de expressão, Absorção de crítica, Resolução de

problemas, Uso de métodos organizados, Capacidade de estimular, Tempo disponível e Desempenho geral, perdendo em Experiência em pesquisa e número de Orientados compatível, conforme apresentado no Quadro 9.

Quadro 9 – Clusterização com atributo Formação pedagógica do professor sob a luz dos discentes

Attribute	Full Data (31)	Cluster#	
		0 (16)	1 (15)
Conhecimento_específico	BOM	BOM	ÓTIMO
Experiência_em_pesquisa	BOM	ÓTIMO	BOM
Interesse/comprometimento	ÓTIMO	BOM	ÓTIMO
Relacionamento_interpessoal	BOM	BOM	ÓTIMO
Capacidade_de_expressão	BOM	BOM	ÓTIMO
Absorção_de_críticas	ÓTIMO	BOM	ÓTIMO
Resolução_de_problemas	ÓTIMO	BOM	ÓTIMO
Uso_de_métodos_organizados	ÓTIMO	BOM	ÓTIMO
Capacidade_de_estimular	ÓTIMO	BOM	ÓTIMO
Nº_de_orientados_compatível	BOM	BOM	REGULAR
Tempo_disponível	BOM	REGULAR	BOM
Desempenho_geral	ÓTIMO	BOM	ÓTIMO
Cluster 0 <-- SIM			
Cluster 1 <-- NAO			
Incorrectly clustered instances : 12.0 38.7097%			

No Quadro 10 é apresentada a autoavaliação do professor com Licenciatura. O cluster 0 representa os professores sem formação pedagógica e o cluster 1, os professores licenciados. Na maioria dos atributos, o professor Licenciado se autoavaliou como ótimo. Em todos os atributos, o docente com formação pedagógica se considerou melhor que o docente sem licenciatura.

Quadro 10 – Clusterização com atributo Formação pedagógica do professor pela auto-avaliação do docente

Attribute	Cluster#		
	Full Data (31)	0 (20)	1 (11)
Conhecimento_específico	BOM	REGULAR	ÓTIMO
Experiência_em_pesquisa	BOM	BOM	ÓTIMO
Interesse/comprometimento	BOM	BOM	ÓTIMO
Relacionamento_interpessoal	ÓTIMO	BOM	ÓTIMO
Capacidade_de_expressão	BOM	BOM	ÓTIMO
Absorção_de_críticas	ÓTIMO	ÓTIMO	ÓTIMO
Resolução_de_problemas	BOM	BOM	ÓTIMO
Uso_de_métodos_organizados	BOM	BOM	ÓTIMO
Capacidade_de_estimular	BOM	BOM	ÓTIMO
Nº_de_orientados_compatível	REGULAR	REGULAR	BOM
Tempo_disponível	REGULAR	REGULAR	BOM
Desempenho_geral	BOM	BOM	BOM
Cluster 0 <-- NAO			
Cluster 1 <-- SIM			
Incorrectly clustered instances : 11.0 35.4839%			

As monografias receberam notas A, B ou C, conforme mostrado no Quadro 11, na opinião dos discentes, em que os professores que deram nota B foram mais bem avaliados em todos os quesitos.

Quadro 11 – Clusterização com atributo Notas das monografias sob a luz dos discentes

Attribute	Cluster#			
	Full Data (31)	0 (13)	1 (7)	2 (11)
Conhecimento_específico	BOM	BOM	REGULAR	BOM
Experiência_em_pesquisa	BOM	BOM	BOM	ÓTIMO
Interesse/comprometimento	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Relacionamento_interpessoal	BOM	BOM	BOM	ÓTIMO
Capacidade_de_expressão	BOM	BOM	BOM	ÓTIMO
Absorção_de_críticas	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Resolução_de_problemas	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Uso_de_métodos_organizados	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Capacidade_de_estimular	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Nº_de_orientados_compatível	BOM	BOM	REGULAR	ÓTIMO
Tempo_disponível	BOM	REGULAR	BOM	ÓTIMO
Desempenho_geral	ÓTIMO	BOM	ÓTIMO	ÓTIMO
Cluster 0 <-- C				
Cluster 1 <-- A				
Cluster 2 <-- B				
Incorrectly clustered instances : 15.0 48.3871%				

No Quadro 12 é apresentada a autoavaliação do docente no atributo Notas, em que os mais bem avaliados deram nota A às monografias.

Quadro 12– Clusterização com atributo Notas das monografias pela autoavaliação do docente

Attribute	Full Data (31)	Cluster#		
		0 (18)	1 (11)	2 (2)
Conhecimento_específico	BOM	REGULAR	ÓTIMO	BOM
Experiência_em_pesquisa	BOM	BOM	ÓTIMO	BOM
Interesse/comprometimento	BOM	BOM	ÓTIMO	BOM
Relacionamento_interpessoal	ÓTIMO	BOM	ÓTIMO	BOM
Capacidade_de_expressão	BOM	BOM	ÓTIMO	BOM
Absorção_de_críticas	ÓTIMO	ÓTIMO	ÓTIMO	REGULAR
Resolução_de_problemas	BOM	BOM	ÓTIMO	BOM
Uso_de_métodos_organizados	BOM	BOM	ÓTIMO	PESSIMO
Capacidade_de_estimular	BOM	BOM	ÓTIMO	REGULAR
Nº_de_orientados_compatível	REGULAR	REGULAR	BOM	REGULAR
Tempo_disponível	REGULAR	REGULAR	BOM	REGULAR
Desempenho_geral	BOM	BOM	BOM	BOM
Cluster 0 <-- B				
Cluster 1 <-- A				
Cluster 2 <-- C				
Incorrectly clustered instances : 16.0 51.6129%				

## 5. Conclusão

O Método de Mineração mostrou-se eficaz em descobrir similaridades entre professores com diferentes regimes de contratação, experiência profissional, titulação e outros atributos.

Os resultados indicaram que alunos e professores só concordaram que a experiência no magistério do ensino médio é importante nos quesitos avaliados. Nos demais, enquanto os professores que se autoavaliaram afirmaram que o docente horista seja mais relevante, os alunos preferiram o docente com dedicação integral.

Na autoavaliação, o docente com pouca experiência no magistério superior se julgava melhor, embora o discente optasse pelo professor com muita experiência. O docente acreditava que a experiência profissional fora do magistério era importante; o aluno, não.

O professor considerava que o número de publicações entre quatro e nove era ideal, enquanto o aluno optou por um número superior a nove. Na autoavaliação, os mestres se julgaram mais capacitados, ao passo que os alunos preferiram os doutores na orientação do TCC. Os professores confirmaram a importância da Licenciatura, entretanto os alunos discordaram.

Nas notas dos trabalhos de conclusão, os professores que deram nota B se autoavaliaram melhores, embora os alunos tivessem avaliado

melhor os professores que se atribuíram a nota máxima (A).

Conclui-se que o *Data Mining* se mostrou válido como ferramenta para evidenciar padrões nas avaliações referentes ao TCC da universidade em questão, podendo o método ser adaptado para áreas diferentes das do curso, abordando critérios à luz do conhecimento do especialista.

## 6. Proposta para trabalhos futuros

Como a ferramenta de *Data Mining* demonstrou-se eficaz, sugere-se utilizá-la em outros setores de Avaliação Institucional para identificar pontos críticos, a fim de melhorar a qualidade do curso e evitar a evasão de alunos.

## 7. Referências

- ARAÚJO Júnior, R. H.; TARAPANOFF, K. Precisão no processo de busca e recuperação da informação: uso da mineração de textos. *Ci. Inf.*, v. 35, n. 3, p. 236-47, 2006.
- BAGGI, Cristiane Aparecida dos Santos; LOPES, Doraci Alves. Evasão no ensino superior: um desafio para a avaliação institucional? In: COLÓQUIO INTERNACIONAL SOBRE GESTÃO UNIVERSITÁRIA NA AMÉRICA DO SUL, 9., 2009, Florianópolis. *Resumos...* Florianópolis, nov. 2009. p. 1-11.



- BITTENCOURT, Hélio Radke et al. Desenvolvimento e validação de um instrumento para avaliação de disciplinas na educação superior. **Estudos em Avaliação Educacional**, São Paulo, v. 22, n. 48, p.91-114, abr. 2011.
- BRASIL – INEP. Ministério da Educação. **Instrumento de avaliação de cursos de graduação** – Bacharelados, licenciaturas e cursos Superiores de Tecnologia (presencial e a distância). Disponível em: <[http://download.inep.gov.br/educacao\\_superior/avaliacao\\_cursos\\_graduacao/instrumentos/2011/iac\\_presencial\\_ead\\_bacharelado\\_licenciatura\\_tecnologico.pdf](http://download.inep.gov.br/educacao_superior/avaliacao_cursos_graduacao/instrumentos/2011/iac_presencial_ead_bacharelado_licenciatura_tecnologico.pdf)> Acesso em: 14 jul. 2011.
- BRASIL-INEP. Ministério da Educação. **Sinopses estatísticas da Educação Superior – Graduação**. Disponível em: <<http://www.inep.gov.br/superior/censosuperior/sinopse>>. Acesso em: 12 jul. 2011.
- CARDOSO, O. N. P.; MACHADO, R. T. M. Gestão do conhecimento usando data mining: estudo de caso na Universidade Federal de Lavras. **Rev. Adm. Pública**, v. 42, n.3, p. 495-528, 2008.
- CHAGAS, Anivaldo Tadeu Roston. O questionário na pesquisa científica. **Fecap**, Campinas, v. 1, n. 1, p.1-14, mar. 2000.
- COBRA, Marcos. **Marketing básico: uma perspectiva brasileira**. 3. ed. São Paulo: Atlas, 1991. 762 p.
- DEMO, P. **Leitores para sempre**. Porto Alegre: Mediação, 2006.
- FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. From data mining to knowledge discovery: an overview. In: **Advances in Knowledge Discovery and Data Mining**. Menlo Park, CA: AAAI Press, 1996. p. 1-34.
- GALVÃO, N. D.; MARIN, H. F. Artigo de Revisão: Técnica de mineração de dados: uma revisão da literatura. **Acta Paul Enferm.**, v. 22, n. 5, p. 686-90, 2009.
- GOLDSCHMIDT, R.; PASSOS, E. **Data mining: um guia prático, conceitos, técnicas, ferramentas, orientações e aplicações**. São Paulo: Elsevier, 2005.
- GOMES, Ana Julia Pereira Santinho; ORTEGA, Luis do Nascimento; OLIVEIRA, Décio Gomes de. Dificuldades da avaliação em um curso de Farmácia. **Avaliação** (Campinas), Sorocaba, v. 15, n. 3, p. 203-221, 21 maio 2010.
- GÜNTHER, Hartmut. Como elaborar um questionário. **Planejamento de Pesquisa nas Ciências Sociais**, Brasília, p. 1-15, 2003.
- HARRISON, Thomas H. **Intranet data warehouse**. São Paulo: Berkeley Brasil, 1998.
- INEP. **Censo da educação superior: 2010** – Resumo técnico. Brasília: Inep, 2012. Disponível em: <[http://download.inep.gov.br/educacao\\_superior/censo\\_superior/resumo\\_tecnico/resumo\\_tecnico\\_censo\\_educacao\\_superior\\_2010.pdf](http://download.inep.gov.br/educacao_superior/censo_superior/resumo_tecnico/resumo_tecnico_censo_educacao_superior_2010.pdf)>. Acesso em: 21 nov. 2012.
- LISBÔA, Rogério Trindade. **Método do ranking ponderado de importância, satisfação e esforço para melhoria: descrição e comparação com outros métodos**. 2011. 113 f. Dissertação (Mestrado) – Universidade Cândido Mendes, Campos dos Goytacazes, RJ, 2011.
- LOUREIRO, R. M. T.; SALIBA, N. A.; MOIMAZ, S. A. das S.; ONO, R. Avaliação do desempenho do docente com a participação do corpo discente no ensino superior. **Revista da Abeno**, Brasília, v. 6, n. 2, p. 119-122, 2006.
- NETO, S. A. M.; VILLOWCK, S. R.; STEINER, S.; ARNS, T. M.; DYMINSKI, S. A. Técnicas de mineração visual de dados aplicadas aos dados de instrumentação da barragem de Itaipu/ Visual data mining techniques applied for the analysis of data collected at Itaipu power plant gest. prod., v. 17, n. 4, p. 721-734, **ilus, gra, tab. 2010 dec**.
- NUNES, Ana Karin; HELFER, Carmem Lúcia de Lima. Diagnóstico do desempenho na docência da graduação da UNISC. **Avaliação** (Campinas), Sorocaba, v. 14, n. 1, p. 169-183, 21 mar. 2009.
- OLIVEIRA, A. G.; GARCIA, D. F. **Mineração da base de dados de um processo seletivo universitário**. Disponível em: <<http://www.dcc.ufla.br/infocomp/artigos/v3.2/art07,2009.pdf>>. Acesso em: 11 jul. 2011.
- RIBEIRO, M. O.T.; SHIMODA, E.; SOUZA, D. O. **Ponderação de alguns critérios sobre o conceito geral dos docentes segundo a percepção dos discentes utilizando-se métodos estatísticos** – Estudo de caso em uma universidade particular. [S.l. : s.n.t.].

RIOS, Erenildo da Silva; GOMES, Geórgia Regina Rodrigues; SHIMODA, Eduardo. Correlações entre índice de evasão e perfil acadêmico, financeiro e pessoal dos alunos: estudo de caso em uma universidade particular. In: ENCONTRO MINEIRO DE ENGENHARIA DE PRODUÇÃO, 6., 2010, Coronel Fabriciano. **Anais...** Coronel Fabriciano, MG, 2010. v. 1, p. 1-10.

ROSA, A. I. et al. **O diálogo entre o exame nacional de desempenho dos estudantes e as práticas pedagógicas nos cursos da saúde.** Disponível em: <[http://www.portaldeperiodicos.unisul.br/index.php/Cadernos\\_Academicos/article/view/568/551](http://www.portaldeperiodicos.unisul.br/index.php/Cadernos_Academicos/article/view/568/551)>. Acesso em: 12 jul. 2011.

SCHLEICH, Ana Lúcia Righi; POLYDORO, Soely Aparecida Jorge; SANTOS, Acácia Aparecida Angeli dos. Escala de satisfação com a experiência acadêmica de estudantes do ensino superior. **Avaliação Psicológica**, Porto Alegre, v. 5, n. 1, p. 11-20, jun. 2006.

SCHWARTZMAN, Jacques; SCHWARTZMAN, Simon. O ensino superior privado como setor econômico. **Ensaio: aval. pol. públ. educ.**, Rio de Janeiro, v. 10, n. 37, p. 411-440, Oct. 2002.

SILVA FILHO, Roberto Leal Lobo et al. A evasão no ensino superior brasileiro. **Cadernos de Pesquisa**, São Paulo, v. 37, n. 132, p. 641-659, dez. 2007.

SILVA, R. M.; GOMES, G. R. R.; SHIMODA, E.; SANTOS, T. A. **Percepção dos discentes em relação aos docentes através da aplicação de técnicas e métodos de mineração de dados.** [S.l.]: COBENGE, 2010.

TAN, Pan-Ning; STEINBACH, Michael; KUMAR, Vipin. **Introdução ao DATAMINING Mineração de Dados.** Rio de Janeiro: Ciência Moderna, 2009.

VIANNA, R. C. X.; MORO, C. M. C. B.; MOYSES, S. J.; CARVALHO, D.; NIEVOLA, J. C. Mineração de dados e características da mortalidade infantil. **Cad. Saúde Pública**, Rio de Janeiro, v. 26, n. 3, p. 535-542, mar. 2010.

WEKA – Disponível em: <<http://sourceforge.net/projects/weka/files>>. Acesso em: 10 jun. 2011.

WEKA – Experiences with a Java Open-Source Project. **Journal of Machine Learning Research**,

v. 11, p. 2533-2541, 2010. (Submitted 6/10; Revised 8/10; Published 9/10).

Artigo selecionado entre os 10 melhores do VIII Encontro Mineiro de Engenharia de Produção - EMEPRO 2012.