

Um Assistente de Predição de Evasão aplicado a uma disciplina Introdutória do curso de Ciência da Computação

Luis Carlos Martins^{1,2}, Diogo Altoé Lopes¹, André Raabe^{1,2,3}

¹Bacharelado em Ciência da Computação

²Mestrado em Computação Aplicada

³Programa de Pós Graduação em Educação

Universidade do Vale do Itajaí (UNIVALI)

{luca, raabe}@univali.br, diogoaltoe@gmail.com

Abstract. *This paper presents two studies carried out for student dropout probability detection. The first was based on a specialist knowledge (subject teacher) to model a Bayesian Network profile of dropouts in a discipline of algorithms and programming, of the first year of undergraduate in Computer Science. The Dropout Prediction Assistant (DPA) has been incorporated into an Intelligent Tutoring System (ITS), called Alice, aiming to alert the teacher about potential student dropouts. In the second study, we sought to enhance the DPA through the use of KDD (Knowledge Discovery in Database) techniques, adding new variables to the data obtained from ITS Alice and other sources. The article presents the models created, the experiments and discusses the results.*

Resumo. *Este artigo relata duas pesquisas realizadas para detecção de alunos candidatos a evasão. Utilizou-se na primeira o conhecimento do especialista (professor da disciplina) para modelar uma Rede Bayesiana do perfil dos alunos desistentes em uma disciplina de algoritmos e programação, do primeiro semestre de um curso de graduação em Ciência da Computação. O Assistente de Predição da Evasão (APE) foi incorporado a um Sistema Tutor Inteligente (STI) chamado Alice, passando a alertar o professor sobre alunos potenciais desistentes. Na segunda pesquisa, buscou-se aprimorar o APE por meio da aplicação do processo KDD (Knowledge Discovery in Database), acrescentando novas variáveis obtidas com os dados do STI Alice e de outras fontes. O artigo apresenta os modelos criados, os experimentos realizados e discute os resultados obtidos.*

1 INTRODUÇÃO

Um grave problema enfrentado pelas instituições de ensino superior brasileiras é a alta evasão dos alunos. Cursos de graduação das áreas de Ciências, Matemática e Computação apresentaram índice médio de 28% de evasão entre os anos de 2001 a 2005, sendo que os cursos de Ciência da Computação atingiram 32%, segundo dados do Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira – INEP (SILVA FILHO, et. al. 2007).

A democratização do ensino superior evidenciou novos fatores de preocupação nos índices de evasão, como a formação de grupos heterogêneos de alunos em termos de diferenças no desempenho no ensino médio, nas condições sócioeconômicas, no

background cultural, os quais as instituições não têm ainda meios de atender em suas demandas específicas (RIBEIRO, 2005).

Nesse contexto, entende-se ser importante o desenvolvimento de ferramentas que permitam auxiliar na identificação de alunos que apresentam tendências a abandonar os estudos nas disciplinas, possibilitando ao professor e a instituição educacional tomarem as devidas providências para reduzir a evasão desses alunos.

Com esse intuito, em 2005 foi desenvolvido um projeto que utilizou-se de técnicas de raciocínio probabilístico, mais especificamente Redes Bayesianas, para identificar potenciais alunos desistentes. Uma Rede Bayesiana é um modelo gráfico que representa as relações de causalidade entre variáveis de um sistema possibilitando modelar o conhecimento (RUSSEL e NORVIG, 2004). A rede recebe evidências (variáveis de entrada) e retorna a possibilidade de ocorrência de determinados eventos (variáveis de saída).

Buscava-se identificar os alunos com maior propensão a abandonar a disciplina de Algoritmos e Programação do primeiro semestre do curso de Ciência da Computação. Baseado no conhecimento de um especialista, professor da disciplina, foi desenvolvido um modelo do perfil do aluno desistente, que pôde ser incorporado ao Sistema Tutor Inteligente (STI) denominado Alice (RAABE e SILVA, 2005), tornando-se um Assistente de Predição da Evasão (APE).

Em 2008 foi desenvolvido outro trabalho a fim de criar um novo modelo para o perfil do aluno desistente, utilizando o processo de KDD (*Knowledge Discovery in Database*). Buscou-se evidenciar novos padrões ou correlações nos dados registrados no STI Alice, ocultos ao professor, possibilitando uma melhoria nos resultados da predição do assistente.

O objetivo deste artigo é apresentar esses dois trabalhos realizados, procurando evidenciar pontos positivos e negativos em ambas as abordagens. O artigo está organizado da seguinte forma: a seção 2 apresenta o modelo de predição baseado em redes bayesianas e no conhecimento do especialista; a seção 3 apresenta a abordagem de descoberta de conhecimento utilizando data mining educacional. A seção 4 discute os resultados obtidos apontando direções futuras da pesquisa.

2 MODELO DE PREDIÇÃO BASEADO EM REDES BAYESIANAS

2.1 Redes Bayesianas

Segundo Russel e Norvig (2004), uma Rede Bayesiana é uma descrição concisa de distribuições de probabilidade. É definida como um grafo acíclico, tendo os nodos representando variáveis aleatórias, e cada variável tem uma matriz das probabilidades condicionadas, a sua probabilidade específica, dado a combinação de cada uma das possibilidades das variáveis ‘pais’, sendo essas, as únicas variáveis das quais a variável aleatória depende diretamente.

Nassar et. al. (2004) afirma que, as Redes Bayesianas podem ser definidas como um Grafo Acíclico e Orientado (DAG - *Directed Acyclic Graph*), onde os nodos representam as variáveis de interesse e as ligações entre os nodos representam a dependência causal entre as variáveis. A força desta dependência é representada pela probabilidade condicional.

Uma vez que a topologia da Rede Bayesiana tenha sido definida, basta especificar as probabilidades condicionais para os nodos que possuem dependências diretas e usá-las para calcular qualquer outro valor de probabilidade. O cálculo das probabilidades condicionais é realizado de acordo com o conhecimento prévio de informações obtidas a partir dos dados de análise utilizados (RUSSEL e NORVIG, 2004).

Segundo Luna (2004), para construir uma representação probabilística através do modelo de Redes Bayesianas, uma das tarefas consiste em obter estimativas de probabilidades de eventos relacionados aos dados, à medida que novas informações ou evidências sejam conhecidas. Esse processo é denominado inferência em Redes Bayesianas.

A probabilidade condicional indica a probabilidade de um evento (nodo) tal que outro evento ocorreu. Através da relação (ligação) entre os nodos é possível criar um modelo preditivo, que calcula o grau de relação entre os eventos como também permite passar novas evidências. À medida que as evidências vão sendo fornecidas, a propagação destas na rede permite inferir a probabilidade de ocorrência de qualquer nodo da rede (NASSAR *et. al.*, 2004).

2.2 Modelo de Predição da Evasão

Em 2005, surgiu a proposta de desenvolver um sistema que pudesse identificar os alunos com maior propensão ao abandono da disciplina de Algoritmos e Programação do primeiro semestre do curso de Ciência da Computação da Universidade do Vale do Itajaí - UNIVALI. Foi desenvolvido um Assistente de Predição da Evasão (APE), incorporado ao STI Alice (RAABE, 2006), permitindo que a partir dos dados registrados no ambiente se identificassem quais alunos tinham o perfil de um aluno desistente.

Para desenvolver o APE foi necessária a criação de duas aplicações, o cliente (escrito na linguagem de programação PHP e utilizando a biblioteca NuSOAP) e o servidor (escrito na linguagem de programação Java e utilizando a API do ambiente de desenvolvimento Hugin). Para que fosse possível a comunicação entre o cliente-servidor, e que pudesse ser feito via *web*, fez-se necessário a criação de um servidor (Linux) utilizado o Apache Tomcat e os protocolos Axis. A comunicação entre as aplicações foi realizada por meio de uma *String* (texto) de entrada e saída, sendo que essas *Strings* foram definidas segundo gramática na notação BNF (*Backus-Naur Form*).

Objetivando gerar o modelo de evidências que detectasse os possíveis alunos desistentes da disciplina, utilizou-se os dados existentes na base do STI Alice, sendo que todos esses dados foram inseridos ou pelo professor da disciplina, ou pelos alunos durante a interação com as seções do ambiente. A partir desses dados foi possível gerar as variáveis que foram utilizadas para a construção do modelo:

- **nt_exerc:** Média das notas do aluno em exercícios realizados em sala de aula até o presente momento;
- **nt_avalicao:** Média das notas do aluno em avaliações realizadas em sala de aula até o presente momento;
- **fl_programa:** *Flag* especificando se o aluno tem experiência em

programação (0 – Não, 1 – Sim, null – Não informou);

- **fl_repetente:** *Flag* especificando se o aluno é repetente (0 – Não, 1 – Sim, null – Não informou);
- **qtd_exercicio:** Quantidade de exercícios realizados em sala de aula até o presente momento por um determinado aluno;
- **fl_trab20h:** *Flag* especificando se o aluno trabalha mais de 20 horas semanais (0 – Não, 1 – Sim, null – Não informou);
- **qtd_presenca:** Quantidade de presença no diário de aula da disciplina até o presente momento, de um determinado aluno;
- **fl_conversa:** *Flag* especificando se o aluno conversa durante as explicações (0 – Não, 1 – Sim, null – Não informou); e
- **fl_sai_sala:** *Flag* especificando se o aluno costuma sair de sala durante a aula (0 – Não, 1 – Sim, null – Não informou).

Optou-se classificar e agrupar as variáveis por características (*e.g.*, DESEMPENHO, EXPERIÊNCIA, ESFORÇO e COMPORTAMENTO), pois caso todas as variáveis de entrada fossem ligadas diretamente a variável de saída (desistência, por exemplo), faria com que a tabela de probabilidade condicional da variável ficasse complexa de trabalhar, logo, decidiu-se agrupar as variáveis de entrada conforme sugerido pelo especialista. A partir das variáveis e seus respectivos grupos definidos, foi possível modelar a Rede Bayesiana que representa o perfil do aluno desistente baseado no conhecimento do especialista (que também definiu as probabilidades condicionais variáveis de entrada) conforme apresenta a Figura 1.

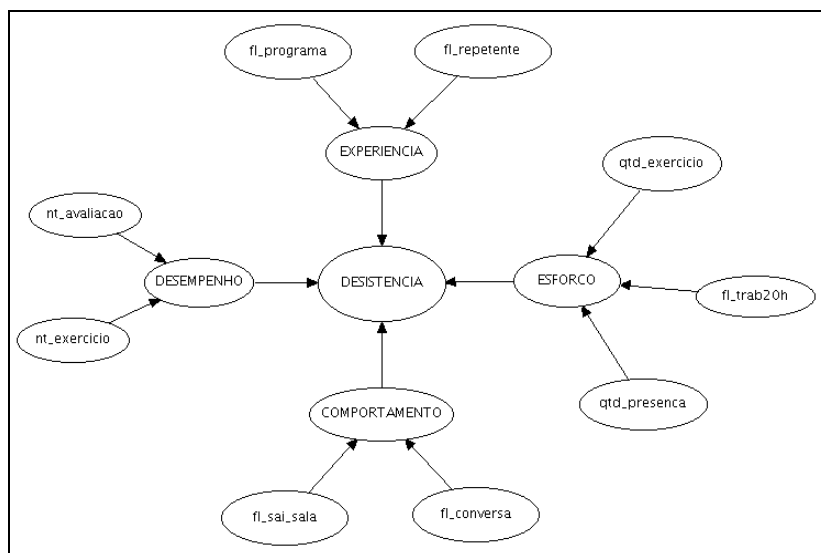


Figura 1. Rede Bayesiana de desistência proposta pelo especialista.

2.3 Resultados

Para definir os resultados encontrados com os experimentos utilizou-se termos como: (i) Verdadeiro Positivo (VP), utilizado quando o assistente consegue identificar um aluno que realmente é desistente; (ii) Verdadeiro Negativo (VN), utilizado quando o assistente identifica um aluno como desistente, mas que não é; e (iii) Falso Positivo

(FP), utilizado quando o assistente deixa de identificar um aluno desistente.

Foram realizados experimentos com o modelo utilizando como amostras duas turmas do segundo semestre de 2005, turmas (A e B) ambas contendo 30 alunos, com intuito de calibrar os pesos das variáveis de entrada e definir o valor do Índice de Predição da Evasão (IPE). Este índice é a probabilidade resultante do nodo desistência. A definição do valor limítrofe deste índice foi um processo crucial, uma vez que ao aplicar a rede, todos os alunos tinham alguma probabilidade de desistirem, e tornou-se necessário definir qual a probabilidade que seria considerada como sendo uma alta chance de desistência.

O processo acabou sendo realizado com base nos dados existentes testando diferentes possibilidades. Por exemplo, usando o IPE com valor 0,4 (40% de probabilidade de desistência) na turma A, onde dos 30 alunos sete abandonaram, teve-se a identificação de apenas quatro desistentes (VP), ou seja, o modelo deixou de identificar três alunos (FP). Como o valor do IPE sendo 0,45, observou-se que na turma A nove alunos foram identificados como desistentes, sendo que desses, seis realmente eram desistentes (VP), três não deveriam ser identificados como desistentes (VN) e um aluno não foi identificado como desistente (FP). A partir dos resultados observados, pode-se gerar a Tabela 1, apresentada a seguir.

Tabela 1. Resultados dos experimentos.

	Turma A		Turma B	
Total de alunos	30		30	
Desistentes	7		10	
Reprovados	1		3 (identificou-se 2)	
Índice de Desistência	0,4	0,45	0,4	0,45
Verdadeiro Positivo	4	6	7	7
Verdadeiro Negativo	0	3	9	13
Falso Positivo	3	1	3	3

Tendo como objetivo avaliar os resultados e escolher o melhor valor para o IPE, tendo em vista que em ambos os experimentos, os valores dos VP foram bem próximos, resolveu-se utilizar como critério decisivo a menor quantidade de FP (*i.e.*, o que menos errasse em deixar de identificar o aluno desistente). Decidiu-se por utilizar então o índice de desistência de 0,45.

Devido ao insuficiente suporte de algumas variáveis no banco de dados e buscando melhorias nos resultados da ferramenta, no trabalho realizado em 2005 buscou-se responder a seguinte pergunta: Com a utilização de um maior número de dados e de outras técnicas de inteligência artificial, é possível descobrir padrões e relacionamentos ocultos ao especialista que ajudariam a modelar o perfil do aluno desistente? A seção a seguir apresenta os procedimentos realizados e os resultados alcançados.

3 MODELO DE PREDIÇÃO UTILIZANDO DATA MINING

3.1 Descoberta de Conhecimento em Bases de Dados

Para Fayyad, Piatetsky-Shapiro e Smyth (1996), em um nível abstrato, o KDD (*Knowledge Discovery in Database*) é direcionado para o desenvolvimento de métodos

e técnicas que dê sentido aos dados. O problema básico do processo de KDD é o mapeamento de baixo nível dos dados (que são tipicamente muito volumosos para entendê-los e digeri-los facilmente) em outra forma que seja mais compacta (*e.g.*, pequenos relatórios), mais abstrata (*e.g.*, uma aproximação descritiva ou modelo do processo que produziu os dados), ou mais útil (*e.g.*, um modelo preditivo para estimar o valor em casos futuros). No centro do processo está a aplicação de métodos específicos de mineração de dados para o descobrimento e extração de padrões.

Dias (2002), define que o termo KDD refere-se a todo o processo de descoberta de conhecimento útil dos dados. A mineração de dados é um passo em particular nesse processo, onde se utiliza de algoritmos específicos para a extração de padrões (*i.e.*, modelos) dos dados. Os demais passos no processo de KDD, como preparação, seleção e limpeza dos dados, utilização apropriada do conhecimento prévio e a correta interpretação dos resultados da mineração, são necessários para garantir que o conhecimento útil seja derivado dos dados. O objetivo é extrair o alto nível de conhecimento do baixo nível dos dados no contexto de um grande conjunto de dados.

Em contextos similares ao problema abordado nesta pesquisa encontra-se o trabalho de Nilakant (2004), que a partir do uso de técnicas de mineração de dados, buscou desenvolver um framework com base na análise das interações entre um STI e o estudante, identificando os problemas específicos da interface do STI que afetam os estudantes, usando essas informações para determinar as causas do problema auxiliando o desenvolvedor do STI a melhorar a forma de interação.

Já o trabalho de Superby e Vandamme (2007) buscou por meio de amostras baseadas num questionário entregue a 533 estudantes de universidades da Bélgica e utilizando técnicas de mineração de dados, classificar os estudantes em três grupos: estudantes de “baixo-risco” (*i.e.*, grande probabilidade de sucesso); estudantes de “médio-risco” (*i.e.*, sucesso dependente das ações tomadas pela universidade); e estudantes de “alto-risco” (*i.e.*, grande probabilidade de reprovarem ou desistirem).

Rovaris Neto (2002) buscou a partir da base de dados de uma instituição de ensino e de um questionário aplicado aos alunos desta instituição, aplicar técnicas de mineração de dados e utilizar o conhecimento em redes bayesianas para simular um Sistema Especialista Probabilístico (SEP) que avalie e estime a probabilidade da evasão dos alunos de um curso de graduação dessa instituição.

O trabalho detalhado no presente artigo assemelha-se a abordagem de Nilakant (2004) ao usar dados provenientes de um STI, porém agrega outras informações de ordem acadêmica como notas e faltas. Assemelha-se ao trabalho de Sperby e Vandamme (2007) e de Rovaris Neto (2002) por buscar identificar a probabilidade de evasão dos estudantes, no entanto, avalia mais de uma técnica para obtenção mais acurada de um Índice de Predição da Evasão.

3.2 Modelo de Predição da Evasão e Experimentos

Buscando evidenciar o grau de predição do assistente (APE) sobre novas amostras, utilizou-se nos experimentos os dados das turmas de 2005, 2006 e primeiro semestre de 2007 como amostras base e teste.

Como a mineração de dados trabalha com a identificação de padrões e correlações nos dados, definiu-se por utilizar as mesmas variáveis do modelo construído

com Redes Bayesianas (*e.g.*, **fl_programa**, **fl_trab20h**, **fl_repetente**) e utilizar novas variáveis a partir dos dados do STI Alice e de outras fontes dentro do contexto do problema:

- **ranking**: é a soma da pontuação obtida com os acessos no STI Alice, levando em consideração as seções acessadas e dependendo da seção, quanto tempo o aluno permaneceu na mesma;
- **nt_discursiva**: é o somatório das notas das questões discursivas dos exercícios realizados pelo aluno;
- **nt_media_discursiva**: é a média das notas das questões discursivas dos exercícios realizados pelo aluno;
- **qtd_discursiva**: é a quantidade de questões discursivas dos exercícios foram realizadas pelo aluno;
- **nt_opcao**: é o somatório das notas das questões objetivas dos exercícios que foram realizados pelo aluno;
- **nt_media_opcao**: é a média das notas das questões objetivas dos exercícios realizados pelo aluno;
- **qtd_opcao**: é a quantidade de questões objetivas dos exercícios que foram realizadas pelo aluno;
- **nt_aluno_exercicio**: é o somatório das notas dos exercícios que foram realizados pelo aluno;
- **nt_media_aluno_exercicio**: é a média das notas dos exercícios realizados pelo aluno;
- **qnt_aluno_exercicio**: é a quantidade de exercícios que foram realizados pelo aluno;
- **m1_aa1**, **m1_aa2**: são as avaliações propostas pelo professor e que compõem a primeira média do semestre (**m1**);
- **m1** e **m2**: são as médias das avaliações realizadas pelo aluno durante a primeira e segunda etapa do semestre (média 1 e média 2), respectivamente;
- **m1_faltas** e **m2_faltas**: são a quantidade de faltas na primeira e segunda média, respectivamente;
- **m2_aa1** e **m2_aa2**: são as avaliações propostas pelo professor e que compõem a segunda média do semestre (**m2**);
- **desistente**: classifica o aluno quanto a sua situação final na disciplina, discretizando-o em três grupos: (0) Reprovado; (1) Desistente; e (2) Aprovado.

Para realizar os experimentos com esse modelo, foram necessárias alterações nos valores das Tabelas de Probabilidades Condicionais (TPC) das variáveis de entrada e dos agrupamentos (*e.g.*, DESEMPENHO, ESFORÇO, COMPORTAMENTO, EXPERIÊNCIA). Os experimentos foram divididos em três grupos:

- Grupo 1: utilizou como amostra base e amostra teste os dados das turmas de 2005 e 2006;
- Grupo 2: utilizou como amostra base as turmas de 2005 e 2006 e como amostra teste a turma de A do primeiro período de 2007; e
- Grupo 3: utilizou como amostra base as turmas de 2005 e 2006 e como amostra teste a turma de B do primeiro período de 2007.

Foi necessária uma fase exploratória para definição dos melhores parâmetros e escolha dos algoritmos de aprendizagem de máquina com melhores resultados de predição. Nesta fase foram avaliados: (i) a melhor forma de representação de alguns dados (i.e., variáveis com valores discretos ou contínuos); (ii) o grau de homogeneidade das amostras; (iii) o nível de predição dos algoritmos.

O resultado desta etapa (que foi apoiada pela ferramenta Weka) apontou um melhor resultado nas predições com os algoritmos OneR, se utilizado com dados referentes apenas ao primeiro bimestre da disciplina, e o NNge, se utilizado para a disciplina como um todo.

Em cada grupo foram realizados experimentos utilizando diferentes valores para o Índice de Predição da Evasão (IPE) e o algoritmo NNge, conforme mostra a Tabela 2.

Tabela 2. Resultados dos experimentos dos grupos 1, 2 e 3.

IPE	Turmas 2005 - 2006				Turma A 2007-1				Turma B 2007-1			
	VP	VN	FP	REPROVADO	VP	VN	FP	REPROVADO	VP	VN	FP	REPROVADO
0,0	4	12	46	2	1	4	9	0	3	1	5	0
0,1	8	19	42	3	3	11	7	0	3	2	5	0
0,2	12	31	38	4	9	19	1	1	3	2	5	0
0,3	26	60	24	13	9	20	1	1	4	9	4	0
0,4	32	76	18	15	10	20	0	1	4	11	4	0
0,5	40	138	10	29	-	-	-	-	8	20	0	1
0,6	41	140	9	29	-	-	-	-	-	-	-	-
TOTAL												
DESISTENTES	50				10				8			
ALUNOS	228				31				31			

A partir dos resultados obtidos, e utilizando como critério decisivo o menor valor de FP pôde-se observar que:

- Nos experimentos com a turma de 2005 e 2006, utilizando o IPE a 0,6 identificam-se corretamente quarenta e um alunos como desistentes (VP), cento e quarenta são identificados como desistentes incorretamente (VN) e deixou-se de identificar nove alunos desistentes (FP). De 228 alunos, 140 foram identificados incorretamente como desistentes, ou seja, 61,40% de VN. VP representam 17,98% do total. Juntos VN e VP somam 79,38%, os outros 20,62% dos alunos realmente não eram desistentes;
- Nos experimentos com a turma A do primeiro período de 2007, nota-se que utilizando a IPE a 0,4 identificam-se corretamente dez alunos como desistentes (VP), vinte são identificados como desistentes incorretamente (VN) e não houve aluno desistente sem ser identificado (FP). De 31 alunos, 20 foram identificados incorretamente como desistentes, ou seja, 64,51% de

VN. VP representam 32,25% do total. Juntos VN e VP somam 96,76%, os outros 3,24% dos alunos realmente não eram desistentes; e

- Nos experimentos com a turma B do primeiro período de 2007, observa-se que utilizando a IPE a 0,5 identificam-se corretamente oito alunos como desistentes (VP), vinte são identificados como desistentes incorretamente (VN) e não houve aluno desistente sem ser identificado (FP).

A partir da análise dos experimentos com as turmas de 2005 e 2006, conclui-se que o total de alunos que foram identificados corretamente (38,60) pelo total dos que foram identificados incorretamente (61,40), indica uma baixa probabilidade de predição, a qual poderia ser interpretada da seguinte forma: para cada aluno identificado corretamente, aproximadamente dois são identificados incorretamente (0,62). Seguindo o mesmo raciocínio, nos outros dois grupos de experimentos há uma redução na probabilidade de predição (0,55).

4 DISCUSSÃO DOS RESULTADOS

A fim de confrontar os resultados dos experimentos do modelo baseado no conhecimento do especialista com o do processo de KDD, utilizou-se em ambos, a mesma base de dados, e apesar de serem duas abordagens diferentes, buscou-se aplicar os mesmos critérios de avaliação.

Buscando aproximar a forma de avaliação dos resultados dos experimentos (com os modelos baseados no conhecimento do especialista e com o processo de KDD), definiu-se utilizar como critério de avaliação a quantidade de acerto na predição da situação final do aluno. Apesar do modelo baseado no processo de KDD ser capaz de prever qual classe o aluno pertence, o mesmo não acontece com o modelo baseado no conhecimento do especialista, que apenas indica a probabilidade do aluno desistir, ou seja, o modelo apenas calcula a probabilidade do aluno ser ou não ser um desistente, enquanto o outro modelo (processo de KDD) classifica o aluno em um dos possíveis perfis (e.g., reprovado, desistente, aprovado).

Observou-se que o modelo baseado no processo de KDD resultou em uma melhor identificação e maior precisão nos resultados. Decidiu-se então, por utilizar no Assistente de Predição da Evasão (APE), o modelo baseado no processo de KDD, utilizando o algoritmo OneR se utilizado com dados referentes apenas ao primeiro bimestre da disciplina, e o NNge se utilizado para a disciplina como um todo. Esta distinção se fez importante uma vez que o assistente de predição deve emitir avisos desde o início da disciplina.

Acredita-se que utilizando mais dados como, por exemplo, condição financeira do aluno (considera-se que apesar de boas notas, bom comportamento e empenho nas atividades, o aluno passa por dificuldades financeiras e se vê obrigado a desistir da disciplina ou do curso), histórico escolar (o aluno já tem um histórico de desistência de disciplinas, podendo talvez, aumentar a possibilidade de ele ser um desistente), dados emocionais (o aluno passa por uma crise familiar, onde essa acaba por levar o aluno a desistir da disciplina) e outros, se poderiam obter resultados mais precisos. Esta perspectiva é o principal foco para continuidade desta pesquisa.

5 REFERÊNCIAS

DIAS, Cristiano Araújo. Descoberta de conhecimento em banco de dados para apoio a tomada de decisão. 2002. 63 f. Monografia (Especialização em Informática Empresarial) - UNESP, São Paulo, 2002.

FAYYAD, Usama; PIATETSKY-SHAPIRO, Gregory; SMYTH, Padhraic. From Data Mining to Knowledge Discovery in Databases. 1996. Disponível em: <www.aaai.org/AITopics/assets/PDF/AIMag17-03-2-article.pdf> Acesso em: abr. 2007.

LUNA, José Eduardo Ochoa. Algoritmos EM para aprendizagem de redes bayesianas a partir de dados incompletos. 2004. 120 f. Dissertação (Mestrado em Inteligência Artificial) - Departamento de Computação e Estatística, Universidade Federal de Mato Grosso do Sul, Campo Grande, 2004.

NASSAR, Silvia M.; ROVARIS NETO, Eugênio; CATAPAN, Araci Hack; PIRES, Maria Marlene de Souza. Inteligência computacional aplicada à gestão universitária: evasão discente. In: IV Colóquio Internacional sobre Gestão Universitária na América do Sul, 2004, Florianópolis. Anais... Florianópolis, 2004. v. 1. p. 1-5.

NILAKANT, K. Applications of Data Mining in Constraint-Based Intelligent Tutoring Systems, 2004. Disponível em: <http://www.cosc.canterbury.ac.nz/research/reports/HonsReps/2004/hons_0408.pdf>. Acesso em 15 set. 2007.

RAABE, A. L. A.; SILVA, J. M. C.. Um ambiente para atendimento as dificuldades de aprendizagem de algoritmos. In: XIII Workshop de Educação em Computação - SBC2005, 2005, São Leopoldo. Anais do XXV Congresso da Sociedade Brasileira de Computação, 2005. p. 2326-2335.

RAABE, André Luís Alice; GIRAFFA, Lúcia Maria Martins. Uma Arquitetura de Tutor para Promover Experiências de Aprendizagem Mediadas. In: XVII Simpósio Brasileiro de Informática na Educação - SBIE2006, 2006, Brasília - DF. Anais do XVII Simpósio Brasileiro de Informática na Educação, 2006. v. 1. p. 589-598.

RIBEIRO, Marcelo Afonso. O projeto profissional familiar como determinante da evasão Universitária: um estudo preliminar. Universidade de São Paulo. Revista Brasileira de Orientação Profissional, 2005.

ROVARIS NETO, Eugênio. E-BAYES – Sistema Especialista para a Análise da Evasão Discente de Cursos de Graduação no Ensino Superior. Dissertação (Mestrado em Programa de Pós-graduação em Ciências da Computação) – Universidade Federal de Santa Catarina, Florianópolis, 2002.

RUSSEL, Stuart J.; NORVIG, Peter. Inteligência artificial. Rio de Janeiro: Campus, 2004.

SILVA FILHO, Roberto Leal Lobo; MOTEJUNAS, Paulo Roberto; HIPÓLITO, Oscar; LOBO, Maria Beatriz de Carvalho Melo. Instituto Lobo para o Desenvolvimento da Educação, da Ciência e da Tecnologia. A evasão no ensino superior brasileiro. Cadernos de Pesquisa, v. 37, n. 132, set./dez. 2007.

SUPERBY, J. F.; VANDAMME, J. P. Determination of factors influencing the achievement of the first-year university students using data mining methods. In: Workshop de Mineração de Dados Educacional: 8th International Conference on Intelligent Tutoring Systems (ITS 2006). Taiwan: Jhongli, 2006.