

# Modelagem do Processo de Aprendizado Colaborativo Através de Redes Bayesianas

João Paulo Valdivieso Borges, Thereza Patrícia Pereira Padilha

Laboratório de Inteligência Computacional – Centro Universitário Luterano de Palmas  
Caixa Postal 160 – 77.054-970 – Palmas-TO

{joapaulo, thereza}@ulbra-to.br

***Resumo.** Este trabalho apresenta uma modelagem do aprendizado colaborativo realizada na ferramenta de manipulação de redes Bayesianas *Bayesware Discoverer*, tendo como suporte a teoria de Bayes. Para esta modelagem, foram utilizadas as variáveis provenientes de um banco de dados armazenado pelo ambiente de aprendizado colaborativo *RESOLVE*, desenvolvido no *CEULP/ULBRA*, que expressam possíveis atitudes num processo de ensino-aprendizado em grupo.*

***Palavras-chave:** redes bayesianas, aprendizado colaborativo.*

## 1 Introdução

A facilidade de comunicação introduzida pelo avanço das redes de comunicação tem viabilizado o desenvolvimento de vários ambientes de aprendizado colaborativo para a Educação a Distância via Internet. Esse avanço tem possibilitado a interação síncrona e assíncrona entre os participantes (aluno-aluno ou aluno-professor), independentemente de tempo e local. Um importante tópico de pesquisa relacionado com os ambientes de aprendizado colaborativo diz respeito à análise das interações dos alunos na execução das atividades. Muitas interações de alunos no aprendizado colaborativo podem ser capturadas e armazenadas num banco de dados para análises futuras. Entretanto, a extração de informações úteis nesse banco é quase impossível sem o uso de técnicas de mineração [PADILHA, 2005].

Na literatura, existem várias ferramentas de mineração de dados que tem como finalidade a construção de redes Bayesianas. A maioria dessas ferramentas é alimentada por um banco de dados que, automaticamente, gera as redes bayesianas apresentando um conjunto de tabelas de probabilidades [RICH E KNIGHT, 1993]. Um exemplo desse tipo de ferramenta e que tem sido bastante utilizada em domínios que existem incertezas é o *Bayesware Discoverer*.

Neste caso, o artigo tem como objetivo apresentar uma modelagem do processo de aprendizado colaborativo com a utilização das Redes Bayesianas. Para isso, dados das interações dos alunos que estão num banco de dados serão analisadas automaticamente pela ferramenta *Bayesware Discoverer*. A partir da rede bayesiana obtida, serão realizadas inferências na rede a fim de identificar um novo conhecimento que possa auxiliar professores no acompanhamento das atitudes dos alunos.

## 2 Conhecimento Incerto

Existem vários domínios de aplicação que são alimentados com informações incertas, com valores do tipo contínuo, como por exemplo, as estatísticas definidas pelo IBGE, nas quais são armazenados valores numéricos. Nestes casos, é necessário que existam evidências de apoio para que se inicie um processo de análise dos dados [RICH E KNIGHT, 1993]. Para problemas que não precisam de uma previsão totalmente segura, a disponibilidade de informações sobre futuras possibilidades de resultados facilita o entendimento de conclusões.

Segundo Russell e Norvig, a incerteza surge por causa do entendimento incompleto e/ou incorreto de um agente sobre as propriedades de um determinado ambiente [RUSSELL, 2004]. A manipulação desse conhecimento incerto é bastante utilizada na área de diagnósticos médicos. Nesses casos, o conhecimento de um agente sobre um determinado domínio fornece apenas um grau de crença sobre as sentenças.

Diante disso, é importante obter um sólido entendimento sobre a teoria da probabilidade (teorema de Bayes) e as redes bayesianas (estatística bayesiana) que são uma forma de representação de conhecimento incerto em que possibilita a visualização de situações futuras dadas algumas evidências. Assim, nas próximas subseções serão abordados alguns conceitos relevantes para o entendimento da modelagem incerta no domínio de aprendizado colaborativo.

### 2.1. Teorema de Bayes

A noção fundamental da estatística bayesiana é a probabilidade condicional  $P(H|E)$ , no qual  $H$  é a hipótese e  $E$  é a evidência. Para computar a probabilidade de uma hipótese  $H$ , é necessário levar em conta o valor da evidência  $E$ . Quando não existir evidências, tem-se a probabilidade incondicional  $P(H)$  [RUSSELL, 2004].

A partir dessas probabilidades, surgiu o teorema de Bayes, que está apresentado pela Equação 1:

$$P(H|E) = \frac{P(E|H) \cdot P(H)}{P(E)} \quad (1)$$

Um exemplo de aplicação deste teorema é encontrar a probabilidade de um paciente com rigidez no pescoço ter meningite, sendo uma probabilidade condicional o fato de o paciente ter a rigidez[RUSSELL, 2004].

Assim, querendo chegar a uma outra probabilidade condicional, que é o paciente ter meningite, temos que o médico sabe que a meningite faz o paciente ter uma rigidez no pescoço durante aproximadamente 50% do tempo. Sabe-se que 1/50.000 é a possibilidade de um paciente ter meningite, e para qualquer paciente ter rigidez no pescoço é 1 / 20 (probabilidades incondicionais). Sendo assim, temos a Evidência *paciente ter meningite*, e a hipótese *rigidez no pescoço*. Utilizando o Teorema de Bayes, temos:

$$P(E | H) = 50\% \text{ ou } 0,5; P(E) = 1 / 50.000; P(H) = 1 / 20. \text{ Então, } P(H | E) = 0,0002.$$

Enfim, espera-se que 1 em 5.000 pacientes com rigidez no pescoço tenha meningite[RUSSELL, 2004].

## 2.2 Redes Bayesianas

Redes Bayesianas são grafos acíclicos direcionados, mostrando as relações de causalidade entre as variáveis. Nestes grafos, as elipses são as variáveis (atributos) e as ligações representam os relacionamentos de influência entre as variáveis.


A partir dos cálculos estatísticos, cada variável terá uma tabela de valores de probabilidades para que suas possíveis ações sejam realizadas. Assim, na utilização de uma ferramenta de análise de Redes Bayesianas é possível definir hipóteses sobre uma determinada variável, tendo respostas sobre as influências por ela dadas de acordo com as ligações existentes entre as outras variáveis.

Para exemplificar a construção de uma Rede Bayesiana, pode-se analisar a relação entre a hipótese frio e as evidências ventilador e clima. Neste caso, as probabilidades da hipótese frio variando as suas evidências pode ser visualizada na Tabela 1.

**Tabela 1.** Probabilidades condicionais para Rede Bayesiana

Probabilidades condicionais	Valor
P(Frio   Ventilador, Clima)	0,95
P(Frio   Ventilador, ¬ Clima)	0,8
P(Frio   ¬ Ventilador, Clima)	0,9
P(Frio   ¬ Ventilador, ¬ Clima)	0,1

Na Figura 1 pode ser ilustrada a rede Bayesiana deste exemplo de aplicação em que ventilador e clima influenciam a variável frio.



**Figura 1.** Exemplo de Redes Bayesianas

Para verificar inferências numa rede bayesiana deve-se definir algumas evidências. Neste caso, são feitas suposições dos valores que poderiam obter as evidências, observando a forma que cada evidência infere no valor da hipótese, e quais as variações obtidas pelos seus valores. Por exemplo, se existir uma de ação do ventilador e o clima não estiver com temperatura alta, há uma probabilidade de 80% de possuir frio.

### 3 Aprendizado Colaborativo

Apesar de alguns pesquisadores utilizarem os termos colaboração e cooperação indistintamente, na literatura, o significado desses termos ainda é muito discutido. Segundo Brna, são apresentados quatro aspectos relacionados a esses termos [BRNA 1998]:


- **Divisão de trabalho:** quando a tarefa é dividida entre os membros, como uma atividade na qual cada pessoa é responsável por uma porção da solução do problema, tem-se a cooperação; e a colaboração envolve o empenho mútuo dos membros em um esforço coordenado para solucionar juntos o problema;
- **Estado da colaboração:** dado o aspecto descrito anteriormente, a colaboração pode ser considerada tanto um estado como um processo, pois os membros cooperariam em um processo e manteriam a colaboração como um estado;
- **Propósito da colaboração:** os participantes têm como propósito aprender a colaborar ou apenas colaborar para aprender um certo assunto;
- **Relação contratual:** em contextos típicos de sala de aula, podem se observar relações contratuais tanto explícitas quanto implícitas entre professor-aluno e aluno-aluno.

Na colaboração, os membros têm um determinado contrato, mesmo que implícito, com os demais membros do grupo. Já na cooperação, esse contrato torna-se mais explícito, visto que cada membro é responsável por uma certa tarefa.

Para Borghoff e Schlichter, a comunicação entre os membros de um grupo é um aspecto muito importante para o trabalho/aprendizado cooperativo. Neste sentido, esses autores apresentam uma classificação dos termos colaboração e cooperação (representados pelos verbos colaborar e cooperar, respectivamente) baseado no grau de interação entre membros, observando principalmente a intensidade do fluxo de informação entre eles, como pode ser observado na Figura 2 [BORGHOFF E SCHLICHTER 2000].

No grau mais baixo de comunicação, relativo à informação, o emissor e o receptor têm um pequeno contato, pois a informação tem somente um sentido. No próximo grau, a coordenação, o emissor e o receptor têm um contato direto e coordenam as informações e atividades. Incrementando o grau de comunicação, tem-se a colaboração, em que emissor e receptor esforçam-se em busca de uma meta comum. O grau mais alto de comunicação ocorre durante uma cooperação entre indivíduos, grupos e organizações.

Neste caso, há metas comuns e compartilhamento de planos, e os encontros face-a-face são considerados fatores importantes.



**Figura 2** Intensidade do Fluxo de Informação entre Membros  
[BORGHOFF E SCHLICHTER 2000].

Como se pôde observar, muito tem sido escrito sobre como melhor definir o termo colaboração. No entanto, para a comunidade em geral, esse termo não é visto como incerto, pois a colaboração refere-se a um grupo de pessoas trabalhando juntas para realizar uma determinada tarefa. Da mesma forma, isso acontece com o termo aprendizado colaborativo. Nesse trabalho, o significado do termo colaboração está relacionado com a realização de atividades em que um grupo de pessoas, não necessariamente ao mesmo tempo, têm uma meta para atingir.

Segundo Dillenbourg, o aprendizado colaborativo é uma situação em que duas ou mais pessoas aprendem ou tentam aprender alguma coisa juntas. Essa definição é ainda insatisfatória segundo o próprio autor, pois pode ser interpretada de várias formas diferentes: a) Duas ou mais - um par, um pequeno grupo (3 a 5 membros), uma classe (20 a 30 membros), uma comunidade (centenas de membros) e assim por diante; b) aprender alguma coisa - acompanhar um curso ou resolver problemas; c) juntas - através de diferentes formas de interação síncrona ou assíncrona, com frequência em relação ao tempo ou não [DILLENBOURG, 1999]. Enfim, o aprendizado colaborativo pode ser rotulado como um contrato didático no qual se espera que formas de interação aconteçam entre pessoas, porém não há como garantir que essas interações realmente ocorram.

Para Panitz, o aprendizado colaborativo é uma situação na qual alunos se reúnem em grupo em busca de conhecimento, respeitando as habilidades individuais. Existe um compartilhamento de responsabilidades entre os membros do grupo para a realização das ações. A premissa desse aprendizado é baseada num consenso de construção do

conhecimento através da cooperação entre os membros do grupo e não da competição [PANITZ, 1997].

Em [KOMOSINSKI, 2000] é apresentada uma lista de benefícios do aprendizado colaborativo baseada nas investigações realizadas por outros pesquisadores. A seguir, são apresentados alguns desses benefícios:

1. desenvolve habilidades de pensamento crítico de mais alto nível através da discussão;
2. promove a interação e familiaridade entre aluno e professor;
3. incrementa a satisfação do estudante com a experiência de aprendizagem e, conseqüentemente, a retenção de conteúdos;
4. desenvolve habilidades de comunicação oral e social;
5. estimula a formação de equipe e uma abordagem baseada em equipe para a solução de problemas enquanto mantém a responsabilidade individual.

#### **4 Experimentos**

Vários estudos na área da Inteligência Artificial serviram para construção de ferramentas que automatizem os estudos de Redes Bayesianas. Estes softwares constroem as redes a partir de tabelas de banco de dados que armazenam uma quantidade de ações produzidas pelo uso de determinado número de variáveis.

Para a construção do modelo, foi utilizada a ferramenta Bayesware Discoverer [BAYESWARE, 2000] que proporciona a criação e o manuseio das Redes Bayesianas oferecendo as tabelas de probabilidade condicional ou incondicional de cada nó.

Para construção do modelo proposto, foi utilizado um conjunto de dados obtidos durante dois experimentos realizados com o ambiente de aprendizado colaborativo RESOLVE [PADILHA, 2005].

Este banco de dados possui 18 variáveis e 90 exemplos. Dentre essas variáveis, existem 11 discretas, que expressam aspectos cognitivos, e 07 contínuas, que expressam aspectos numéricos. As variáveis discretas são: regularidade, desempenho, envolvimento, confirmação, apoio, tarefa, solicitação, informação, motivação, discussão e suporte. Os possíveis valores para estas variáveis são: muito\_baixo, baixo, médio, alto e muito\_alto, exceto desempenho que varia entre os valores baixo, médio e alto.

As variáveis contínuas, por sua vez, são: utilização\_do\_chat, utilização\_do\_editor, utilização\_da\_votação, acesso\_ao\_ambiente, tempo\_de\_acesso, utilização\_da\_agenda, utilização\_dos\_formulários. A variável Desempenho classifica cada exemplo utilizando os valores baixo, médio e alto.

Para construção das redes, inicialmente houve uma mudança no formato dos dados, pois estavam armazenados em uma tabela do programa Excel (extensão .xls). Esta modificação foi feita para dados separados por tabulações, no formato do bloco de notas (.txt), formato aceito pela ferramenta. Esta extensão de arquivo armazena os mesmos dados, separados por espaços definidos pela tecla TAB, definindo assim os dados das determinadas colunas.

Os experimentos foram então realizados de acordo com o tipo de variável (discretas ou contínuas): a primeira rede bayesiana foi feita utilizando somente as variáveis qualitativas e a segunda, usando somente as variáveis quantitativas, ambas com o incremento da variável desempenho.

A rede gerada pelo primeiro experimento é apresentada na Figura 2. Foi possível verificar as seguintes ligações: Regularidade influencia Desempenho, que influencia Confirmação e Apoio. Apoio influencia Solicitação que, por sua vez, influencia Informação e Motivação. Esta última influencia Tarefa que influencia Discussão. Por fim, Envolvimento influencia Tarefa e Suporte.

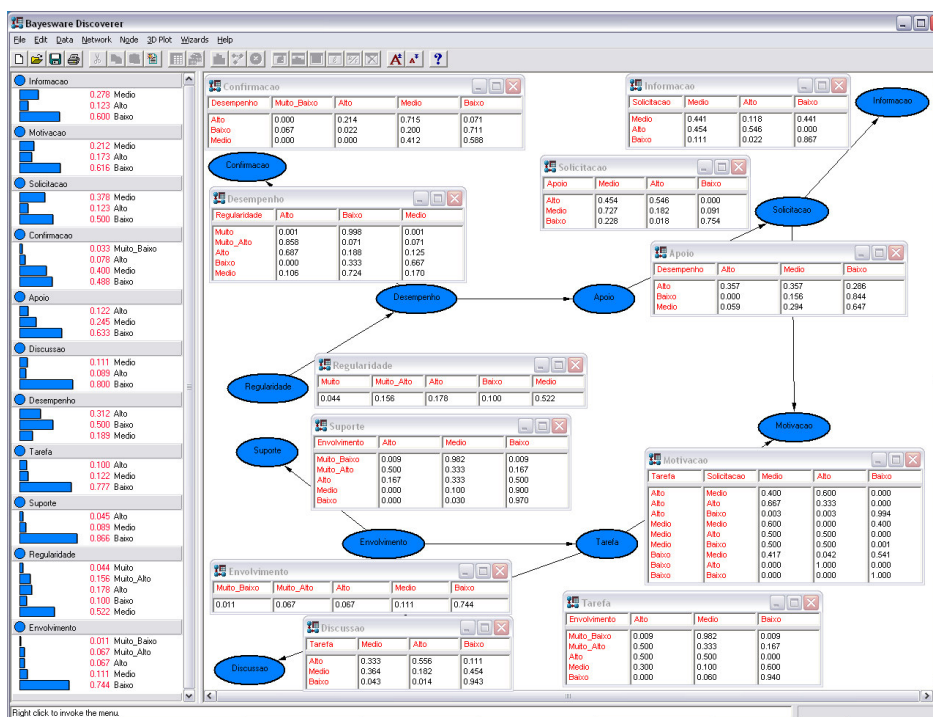


Figura 2. Rede Bayesiana com variáveis discretas – Experimento 1.

É possível observar também as tabelas de probabilidade dos nós da rede. Em cada tabela, tem-se a distribuição probabilística dos seus possíveis valores.

Realizando algumas inferências, foi possível observar que no exemplo das variáveis Motivação, Solicitação e Tarefa, a variável Solicitação inferiu à variável Motivação uma grande subida de valor ao colocá-la como 100% alta. Em números, nesta suposição a variável Motivação cresceu seu valor de 17,3% para 87,2% alta. No entanto, supondo o mesmo com a variável Tarefa, esta influenciou a variável Motivação em apenas 26,9% alta. Colocando o Valor da Solicitação como 100% alta e Tarefa como 100% baixa, tivemos uma inferência resultante a 100% alta na variável Motivação.

No segundo experimento, a rede gerada pode ser mostrada na figura 3. As seguintes influencias foram criadas: variável Utilização\_Do\_Chat influencia Tempo\_De\_Acesso, Utilização\_Do\_Editor, Desempenho e Utilização Da\_Votação. Esta última influencia Acesso\_Ao\_Ambiente, que influencia Utilização\_Da\_Agenda, e que influencia Utilização\_Dos\_Formulários.

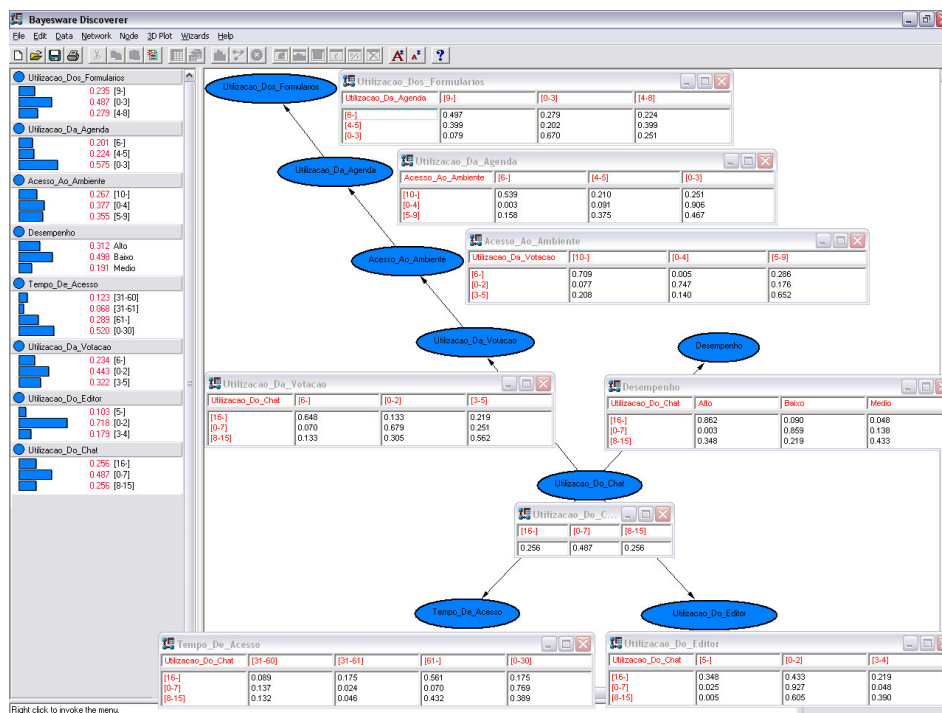


Figura 3. Rede Bayesiana com variáveis contínuas – Experimento 2.

Deste experimento, foi possível observar que todas as variáveis influenciaram umas as outras, porém com poucas variações. Fazendo suposições nos valores da variável Utilização\_do\_chat, foi possível ver que, ao colocar 100% em seu valor mais alto (de 16 acessos ou mais), houve maior inferência na variável Utilização\_da\_votação, que passou valor mais alto (de 6 acessos ou mais), de 23,4% para 64,8%. Fazendo testes com a variável Utilização\_do\_chat inferindo a variável Desempenho, foi possível ver uma alteração de 31,2% para 86,2%, em seu valor mais alto.

## 5 Considerações Finais

O entendimento do processo de aprendizado colaborativo é um tópico de pesquisa importante devido ao fato do crescente número de sistemas de EaD disponíveis. Pode-se concluir que a utilização da ferramenta Bayesware Discoverer auxilia no entendimento, estatisticamente, do processo de aprendizado colaborativo através de sistemas de ensino-aprendizado via Web. Assim, é possível analisar e ter possíveis conclusões sobre as ações mais praticadas e a ligação que possui entre elas. Os experimentos com a



ferramenta Bayesware Discoverer foram realizados a partir de um conjunto de 90 registros sobre as interações dos alunos num ambiente de aprendizado colaborativo [PADILHA, 2005]. Nesses experimentos, foram executadas duas fases: a primeira contendo somente variáveis discretas e a segunda somente variáveis contínuas. Neste trabalho, podemos observar as fortes interações entre as variáveis discretas, sendo muito útil para a modelagem, a influencia que teve da variável Discussão para Tarefa e Envolvimento, mostrando que esta interação entre os alunos, e principalmente as discussões criadas por eles melhorou o desempenho da conclusão das Tarefas e o Envolvimento obtido no decorrer do aprendizado. Já no experimento com as variáveis contínuas, foi notável que todas as variáveis que auxiliam no processo de aprendizado influenciaram fortemente o Desempenho, mostrando também a importância delas nos softwares de ensino via Web.

## 6. Referências Bibliográficas

BAYESWARE LIMITED (2000). “Bayesware Discoverer”, Disponível em <http://www.bayesware.com>.

BORGES, J. P. V.; PADILHA, T. P. P. (2005) “Modelagem do processo de aprendizado colaborativo através de Redes Bayesianas”, Congresso Científico, IV, Jornada de Iniciação Científica, V, p. 188–191.

BORGHOFF, U. M.; SCHLICHTER, J. H. (2000) “Computer- Supported Cooperative Work: introduction to distributed applications”. [S.l.]: Springer.

BRNA, P. (1998) “Modelos de colaboração”, Revista Brasileira de Informática na Educação, n. 3, p. 09–15.

COPPER, G. F. (1999) “The computational complexity of probabilistic inference using Bayesian belief networks”, Artificial Intelligence 42, 393-405.

DILLENBOURG, P. (1999) “Introduction: What do you mean by collaborative learning? Advances in learning and instruction series”, Collaborative Learning: Cognitive and Computational Approaches, p. 1–19, 1999.

KOMOSINSKI, L. J. (2000) “Um Novo Significado para a Educação Tecnológica fundamentado na Informática como Artefato Mediador da Aprendizagem”, Tese de Doutorado, PPGEP-UFSC.

- MARTINEZ, A.; MARCOS, J. A.; FLUENTE, P.; DIMITRIADIS, Y. (2002) "Towards a data model for the evaluation of participatory aspects of collaborative learning. Proceedings of the Conference on Computer Support for Collaborative Learning", Workshop on Designing Computational Models of Collaborative Learning Interaction (CSCL'2002), p 45-51.
- PADILHA, T. P. P. (2005) "Uma Avaliação das Interações de Alunos em Atividades Colaborativas Apoiadas em Técnicas de Mineração para Identificação de Parâmetros para Análise de Desempenho", Tese de Doutorado, PPGCC-UFSC.
- PADILHA, T. P. P.; ALMEIDA, L. M.; ALVES, J. B. M. (2004) "Mining Techniques for Models of Collaborative Learning", 7th International Conference on Intelligent Tutoring Systems, Maceió, p 89 - 94.
- PANITZ, T. (1997) "Collaborative versus cooperative learning - a comparison of the two concepts which will help us understand the underlying nature of interactive learning", Cooperative Learning and College Teaching, v. 8, n. 2, p. 3-5.
- RICH, E. & KNIGHT, K. (1993) "Inteligência Artificial", 2.ed. São Paulo, Makron Books, 267p.
- RUSSELL, S. J., NORVIG, P. (2004) "Inteligência Artificial", 2ª Edição, Editora Elsevier, Rio de Janeiro - RJ.