

Modelagem de usuários com redes bayesianas

Clairmont Borges*

Cláudio F. R. Geyer**

CNPq 1.03.04.00-2

Resumo

“Um dos grandes objetivos da Inteligência Artificial é buscar a solução de problemas mesmo em face da incerteza das diversas evidências que levariam à uma solução. Uma das teorias que nos auxiliam na busca deste tipo de solução é a estatística Bayesiana que interpreta a probabilidade como o grau de certeza de um evento. Os métodos bayesianos nos permitem representar quantitativamente esse grau de certeza sobre as incertezas e manipular essas representações segundo as leis da probabilidade clássica.

O teorema de Bayes é de grande importância para o cálculo de probabilidades. Quando melhor compreendido, o teorema mostra-se como a lei fundamental que governa o processo de inferência, visto que o mesmo pode ser entendido como a base para analisar um conjunto de informações disponíveis e chegar a uma conclusão objetiva, expressa numericamente.

A estatística Bayesiana tem origem no nome de Thomas Bayes, mas na verdade foi o matemático francês Pierre Simon de LaPlace (1812) quem desenvolveu o teorema na forma como ele é conhecido e utilizado atualmente.

O teorema de Bayes é um método quantitativo para a revisão de probabilidades conhecidas, com base em nova informação amostral. As Redes Bayesianas são redes de conhecimento através de grafos direcionados acíclicos onde os nós representam variáveis aleatórias com medidas de incerteza associadas e os arcos representam a interdependência destas variáveis e possuem uma quantificação da força deste relacionamento. Nessas redes, podemos calcular a probabilidade de um evento ocorrer condicionado à ocorrência de outro.” [CAR 99].

“A maior dificuldade encontrada ao se trabalhar com redes Bayesianas é o grande esforço computacional exigido. Pois no cálculo das distribuições de probabilidade há uma explosão combinatória. Mas quando é explorada a esparcidade das relações entre as variáveis do problema, pode-se reduzir esse esforço computacional. Graças a esta esparcidade das redes, foram desenvolvidos vários algoritmos de propagação de crença em redes Bayesianas os quais permitem, a partir de uma dada rede, propagar o conhecimento de novos fatos. Assim o conhecimento incerto pode ser atualizado de forma simples e clara, mantendo a consistência e a confiabilidade.” [HRU 97].

As redes Bayesianas possuem várias vantagens para análise de dados. Uma vez que o modelo codifica dependências entre variáveis, ele manipula facilmente situações

* clermont@inf.ufrgs.br

** geyer@inf.ufrgs.br

onde alguns dados estão incompletos. Além disso, uma rede Bayesiana pode ser usada para aprender relacionamentos causais, e portanto pode ser usada para ganhar conhecimento sobre um domínio de problema e também para fazer inferências sobre ele. Pelo fato do modelo Bayesiano possuir semântica causal e probabilística, ele é uma representação ideal para combinar conhecimento prévio e dados.

Redes Bayesianas também podem ser empregadas para ajudar usuários de softwares através da inferência sobre os contextos de operação, ações e consultas feitas pelos usuários. Esta inferência envolve: (i) a construção de modelos Bayesianos para raciocinar sobre os objetivos (que variam com o tempo) dos usuários; (ii) ter acesso ao fluxo de eventos das aplicações de software; (iii) transformar estes eventos em variáveis que podem ser representadas nos modelos dos usuários, além da necessidade de armazenar estes modelos de usuários de forma que possam ser atualizados continuamente. Esta construção de modelos de usuários usando dados de seus comportamentos é uma instância de um problema mais geral normalmente chamado de descoberta de conhecimento.

Nesta apresentação, farei uma introdução ao trabalho que estou iniciando no doutorado, justificando a escolha da abordagem Bayesiana para a modelagem de usuários. Em seguida, tentarei descrever alguns métodos para construir modelos de redes Bayesianas a partir de conhecimento prévio, e também alguns métodos que usam dados para aprimorar estes modelos.

Referências

- [AIMA 99] AI Maganize. AAAI Press, Summer 1999. (Special Issue on Uncertainty in AI).
- [CAR 99] Carneiro, A. L. and Da Silva, W. T. Introdução a redes Bayesinas. Brasília, DF, Relatório de Pesquisa CIC/UnB 02/97, Outubro de 1999.
<ftp://ftp.cic.unb.br/pub/publications/report/rr.99-09.ps.Z>
- [CHIC 94] Chickering, D. M.; Geiger, D.; Heckerman, D. Learning Bayesian Networks is NP-Hard. Technical Report. Microsoft Research.
<ftp://ftp.research.microsoft.com/pub/tr-94-17.ps> (Acessado em 26/1/00)
- [CHIC 97] Chickering, D. M. A Bayesian Approach to Learning Bayesian Networks with local structure. Technical Report. Microsoft Research.
<ftp://ftp.research.microsoft.com/pub/tr-97-07.ps> (Acessado em 26/1/00)
- [FUNG 95] Fung, R.; Del Envero, B. Applying Bayesian Networks to Information Retrieval. Communications of the ACM, March 1995/Vol.38,No3, pp.42-48.
- [HECK 95a] Heckerman, D. & Wellman, M. P. Bayesian Networks. Communications of the ACM, March 1995/Vol.38,No3, pp.27-30.
- [HECK 95b] Heckerman, D. A Tutorial on Learning with Bayesian Networks. Technical Report. Microsoft Research. <ftp://ftp.research.microsoft.com/pub/tr-95-06.ps> (Acessado em 26/1/00)
- [HECK 95c] Heckerman, D. and Geiger, D. Likelihoods and Parameter Priors for Bayesian Networks. Technical Report. Microsoft Research. <ftp://ftp.research.microsoft.com/pub/tr-95-54.ps> (Acessado em 26/1/00)

- [HECK 95d] Heckerman, D.; Mamdani, A.; Wellman, M. P. Real-World Applications of Bayesian Networks. Communications of the ACM, March 1995/Vol.38,No3, pp.24-26.
- [HECK 97a] Heckerman, D. Embedded Bayesian Network Classifiers. Technical Report. Microsoft Research. <ftp://ftp.research.microsoft.com/pub/tr-97-06.ps> (Acessado em 26/1/00)
- [HECK 97b] Heckerman, D.; Meek, C. and Cooper, G. A Bayesian Approach to Causal Discovery. Technical Report. Microsoft Research. <ftp://ftp.research.microsoft.com/pub/tr-97-05.ps> (Acessado em 26/1/00)
- [HRU 97] Hruschka Jr., Estevam. R. & da Silva, Wagner T. Propagacao de Crenca em Redes Bayesianas. Brasilia, DF, Relatorio de Pesquisa CIC/UnB 02/97, Março de 1997. <ftp://ftp.cic.unb.br/pub/publications/report/rr.97-02.ps.Z> (04/09/2000)
- [IEEE 93] IEEE Transactions on Pattern Analysis and Machine Intelligence, v.15, n.3, March 1993 (Special Section on Probabilistic Reasoning).
- [RUSS 95] Russel, Stuart; NORVIG, Peter. Artificial Intelligence: a Modern Approach. New Jersey: Prentice-Hall, 1995.