

文章编号: 1001-0920(2008)10-1081-06

贝叶斯网络扩展研究综述

陈英武, 高妍方

(国防科技大学 信息系统与管理学院, 长沙 410073)

摘要: 贝叶斯网络是一种能够对复杂不确定系统进行推理和建模的有效工具, 广泛用于不确定决策、数据分析以及智能推理等领域. 由于理论和实际的需要, 贝叶斯网络不断扩展, 出现了各种模型和研究方法. 为此, 综述了贝叶斯网络在不同领域的扩展模型以及在不同理论框架下的进展, 并展望了未来的几个发展方向.

关键词: 贝叶斯网络; 扩展模型; 核学习; 代数

中图分类号: TP18 **文献标识码:** A

Survey of extended Bayesian networks

CHEN Ying-wu, GAO Yan-fang

(College of Information Systems and Management, National University of Defense Technology, Changsha 410073, China. Correspondent: GAO Yan-fang, E-mail: gaoyanfangnudt@hotmail.com)

Abstract: As a modeling and inference tool of complex and uncertainty domain, Bayesian networks has extensive applications in uncertainty decision, data analysis and intelligence inference. It extends in many fields so that some models and research methods emerge with the demand of theory and practice. The extended models in various domains and the development of Bayesian networks with new theory frameworks are reviewed. Finally, some promising areas of future research are briefly discussed.

Key words: Bayesian networks; Extended model; Kernel learning; Algebra

1 引言

贝叶斯网络是一种应用有向无环图表示变量间概率依赖关系的图模型, 由 Pearl^[1] 最先提出. 贝叶斯统计和图论的发展为贝叶斯网络提供了坚实的理论基础, 而人工智能、专家系统和机器学习在实践中的广泛应用, 成为贝叶斯网络产生和发展的催化剂. 从统计学角度看, 贝叶斯网络是图模型的一种, 而人工智能学科则将根据数据获得贝叶斯网络的过程视为机器学习的一个特例.

贝叶斯网络经过近 30 年的发展, 在理论及应用上都取得了丰硕的成果. 在概率论、图论和机器学习等理论框架下, 已经系统研究了贝叶斯网络的独立关系、参数学习、结构学习以及推理等基本理论问题, 有关贝叶斯网络的专著也相继出版^[2,3].

本文从贝叶斯网络在不同方面扩展的角度出发, 系统地论述了贝叶斯网络的扩展模型及其在核学习和代数理论等框架下的特点和研究进展.

2 贝叶斯网络模型的扩展

贝叶斯网络的处理范围有一定的限制, 例如: 必须满足无环的要求, 只能处理单一表中的二维“平面”数据, 只能对静态系统建模, 标准贝叶斯网络不便于融合领域中的结构化知识. 然而, 贝叶斯网络为很多模型提供了一个共同的框架, 如朴素贝叶斯模型、隐类模型、混合模型、隐马尔科夫模型、卡尔曼滤波器均是贝叶斯网络的特例, 并使得在一个领域中的结果可以推广到其他领域. 更为重要的是, 贝叶斯网络为发展新模型提供了一个自然的框架^[3].

2.1 在结构化数据中的扩展

实际中的观测数据通常包含结构化的信息, 如类别层次结构以及数据类型结构等. 标准贝叶斯网络不便于融合这类知识, 从而丢失了许多有用的信息. 如何利用结构化知识改进贝叶斯网络, 从而增强贝叶斯网络的解释性, 降低贝叶斯网络建模和推理的复杂度是相关研究的热点内容之一. 有代表性的

收稿日期: 2007-06-21; 修回日期: 2007-09-10.

基金项目: 高等学校博士学科点专项科研基金项目(20059998019).

作者简介: 陈英武(1963—), 男, 湖南益阳人, 教授, 博士生导师, 从事系统规划与决策、项目的研究; 高妍方(1979—), 女, 山东济宁人, 博士生, 从事概率图模型、系统建模与决策的研究.

模型包括面向对象贝叶斯网络(OOBN)和层次贝叶斯网络(HBN).

OOBN^[4-8]通过借鉴面向对象的思想,将类、继承和参考引入到贝叶斯网络中,特别适合于对大型复杂系统建模. OOBN 结合了贝叶斯网络清晰的概率含义和面向对象框架的组织结构,蕴含了许多结构信息. 在 OOBN 中,将多个相同或相似的对象抽象为类,其中子类包含了父类的所有节点,并且继承了其在父类中的条件概率表,参考节点是类中节点的类外父节点在该类中的映射. 图 1 和图 2 分别给出了一个类及其子类的示例. 图中有向边表示因果依赖关系,虚线节点是输入节点,用于从外界获得输入,一般没有父节点;阴影节点是输出节点,用于向外界输出;其他节点是常规节点.

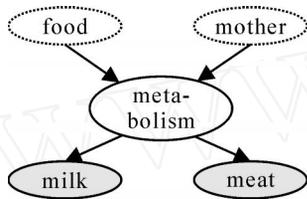
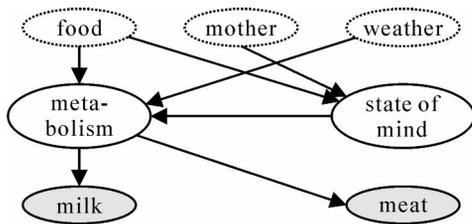
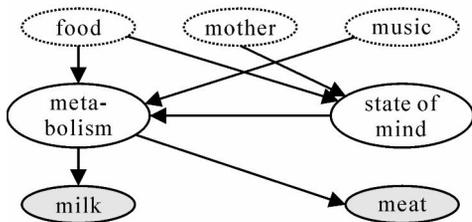


图 1 一个判断牛的种类的类



(a) 肉牛子类



(b) 奶牛子类

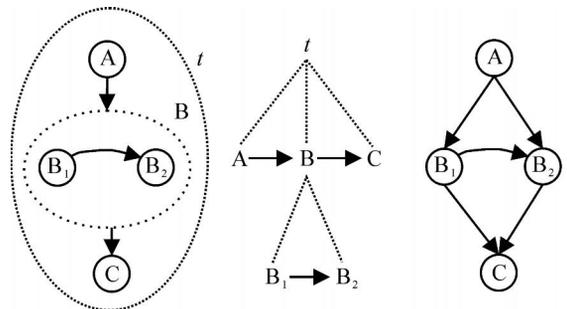
图 2 肉牛和奶牛的子类

与标准贝叶斯网络相比,OOBN 具有如下优势:1)支持自顶向下的建模过程^[5],可以在网络片段尚未完全定义之前利用其来构建贝叶斯网络,然后再对网络片段进行细化,确定内部结构;2)对复杂模型采取小的易于理解的模型片段进行建模,有利于专家知识的提取以及建模人员与专家之间的交流;3)采用面向对象思想,可以比较容易地对复杂系统建立贝叶斯网络模型,降低建模的难度和复杂性,增

强模型的重用性;4)可以采取更有效的概率推理算法.

在一定条件下,利用面向对象的结构化知识,能够提高贝叶斯网络建模和推理的性能. 学习 OOBN 的参数时,如果面向对象的假设成立,OOBN 的参数学习方法不劣于传统方法^[6]. 利用面向对象的知识进行结构学习时效率高于传统的方法^[7],并且增强面向对象的假设能够提高学习 OOBN 模型的质量^[8]. 目前 OOBN 中的推理主要通过将其转换成标准贝叶斯网络或者 MSBN^[5]等两种方法解决. 利用 OOBN 中蕴含的结构信息,尤其是对象中被封装的变量以及模型片段在不同条件下的重用,将会加快推理过程,收敛速度和效率都比标准贝叶斯网络推理算法好,但目前这方面的算法还较为少见.

HBN^[9-11]是在网络结构中融合了数据类型结构的贝叶斯网络. 一个 HBN 包括拓扑结构和概率参数两部分. 概率参数部分的定义与标准贝叶斯网络相同;拓扑结构与标准贝叶斯网络不同,它定性描述了随机变量之间的从属关系(也称为类型结构关系)以及概率依赖关系,其中从属关系可以表示成网状形式或树状形式. 图 3 是一个 HBN 的几种表达形式,其中节点 B 与 B₁, B₂ 之间的关系属于类型结构关系,用虚线连接;而 B 与 A, C 的关系则是概率依赖关系,用实线连接.



(a) 网状结构 (b) 树状结构 (c) 标准贝叶斯网络

图 3 一个简单的 HBN 结构

Gyftodimos 提出 HBN,并研究了相关的建模以及推理方法. 在贝叶斯网络的框架下,参数估计可以直接应用拉普拉斯以及最大似然等方法^[9]. 借鉴标准贝叶斯网络的结构学习,提出了学习 HBN 结构的贝叶斯方法和 MDL 方法,研究结果表明将数据类型结构作为先验,可以缩小结构搜索空间^[9,10]. 当与 HBN 对应的标准贝叶斯网络中不含无向环时,可以直接应用消息传播算法进行推理;反之,则需要对网络中的环进行分解,解决的方法有利用类型知识的 HBN-decycling 推理算法^[11]. 另外,HBN 还可以作为分类器对结构化数据进行分类^[9].

2.2 在复杂关系数据中的扩展

关系数据是实际中最常见的数据存储形式之一,但是标准贝叶斯网络只能处理具有单一表的二维“平面”数据,而对于多表中的多维关系数据则无能为力.在贝叶斯网络的框架下,出现了能够处理多维关系数据的方法,其中最具代表性的为概率关系模型(PRMs).

PRMs^[12-14]是对结构中对象经常变化的复杂系统建模的概率模型.PRMs能够处理对象、对象的性质以及对象之间关系,是一个同时结合了逻辑关系和概率方法的框架.一个PRM中最基本的概念是类和关系,其中类是对对象的划分,关系是定义在类上的二元关系.PRMs主要包括如下4个部分:关系模式、关系构架、概率依赖结构以及相应的参数.

关系模式描述了一组类及其相关的属性,类的属性包括描述该类性质的基本属性以及描述类之间关系的参考槽.图4是一个关系模式,在该模式中,有 professor, student, course, registration 4 个类,而 registration 有 1 个基本属性 satisfaction 和 2 个参考槽 course, student.

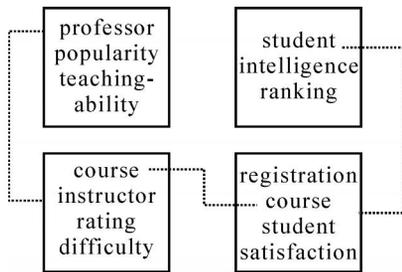


图 4 关系模式

关系构架是关系模式中相同实例的模板,它明确了每个类的对象以及这些对象之间的关系.图5是一个关系构架.

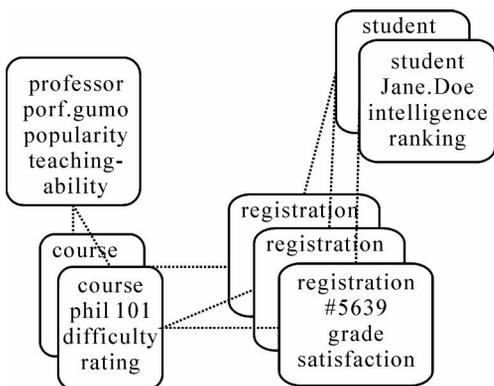


图 5 关系构架

一个PRM包含了概率依赖结构和相应的参数两部分.图6是一个包含了部分概率参数的PRM.概率依赖结构在类的层次上定义了属性及其父节点

之间的依赖关系.一个节点的父节点可以是同一对象中的属性,如一个 professor 的 popularity 依赖于其 teaching-ability; 一个节点的父节点也可以是相关对象中的属性,如一个 student 的 grade 依赖于 registration, course, difficult 以及 registration, student, intelligence. 同每个属性相关的参数是一致的给定父节点的条件概率分布.

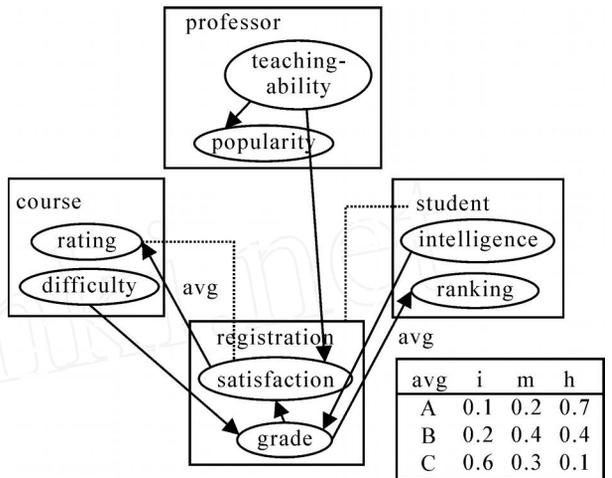


图 6 一个包含了部分参数的PRM

PRMs与标准的贝叶斯网络相比主要有两方面不同:1) PRMs在类的层次上定义了依赖关系模型,可以应用于类中的任何一个对象;2) PRMs利用了模型的关系结构,使得一个对象的属性也可以依赖相关对象的属性.

标准贝叶斯网络的相关方法可以扩展到PRMs中.在参数估计中,ML和贝叶斯方法均可以应用在PRMs中^[12].PRMs需要考察的依赖结构的数量是无限的,因此,在PRMs的结构学习中,需要确定依赖结构的合理性、模型选择准则以及有效的模型搜索程序^[12, 13].在PRMs中进行概率推理,其中蕴含的结构信息有助于提高概率推理效率^[14].在PRMs的框架下,还提出了一些扩展模型,如不确定连接的PRMs和融合属性类别层次的PRMs^[13],RDNs^[15]等.

2.3 在迭代反馈过程中的扩展

很多实际问题中存在循环、反馈以及因素之间互为因果关系等现象.例如,商品的市场价格影响库存量,库存量影响供给量,反过来供给量又会影响市场价格.标准贝叶斯网络具有无环的限制,不能对这种具有迭代和反馈过程的领域进行建模.有环贝叶斯网络(CBN)^[16-18]突破了无环的限制,继承了贝叶斯网络描述非确定性逻辑关系的能力,适于处理该类问题.

有向环概率收敛问题的研究,是利用CBN进行建模和推理的基础.胡玉胜^[16]研究了CBN,证明了

节点均为二值变量的有向环概率收敛. 蒋国萍^[17]应用 CBN 研究具有迭代和反馈过程的软件项目风险, 证明了节点消隐操作可以将有向环化简成简单环(包含两个节点的环)以及有向环的概率收敛性质, 并提出了基于环的极限概率推理方法和基于开关节点的概率推理方法. 周忠宝^[18]应用 CBN 研究反馈控制系统的概率安全评估, 给出了简单环概率收敛的充要条件.

2.4 在时变系统中的扩展

许多随机现象都涉及一些随时间变化的随机变量, 如股票指数的变化、语音的产生以及连续变化的视觉图像等. 标准贝叶斯网络只能对静态系统进行建模. 为了能够对此类动态时变随机过程进行表达和推理, 引入了动态贝叶斯网络(DBN).

DBN^[(19-21)]是单连接(节点只有一个父节点)贝叶斯网络的一个特例. 利用动态时间序列随时间演化的特性, 所有的 DBN 具有相对一致的网络结构. DBN 定义为 (B_0, B) , 其中初始网 B_0 是一个标准贝叶斯网络, 定义了初始时刻的概率分布 $P(Z_0)$; 而转换网 B 则是一个 2- 时间片贝叶斯网络(2TBN), 定义了两个相邻时间片的各变量之间的条件分布, 即

$$P(Z_t | Z_{t-1}) = \prod_{j=1}^N P(Z_j^t | \text{Pa}(Z_j^t)).$$

其中: Z_i^t 是在时间 t 的节点 i , $\text{Pa}(Z_i^t)$ 是 Z_i^t 的父节点. B 中前 1 个时间片中的节点可以不给出参数, 第 2 个时间片中的每个节点都有一个条件概率分布 $P(Z_i^t | \text{Pa}(Z_i^t))$, $t > 0$. 节点 Z_i^t 的父节点可以在同一时间片内, 也可以在前一时间片内. 位于同一时间片内的边可以理解为瞬时作用, 而跨越时间片的边可以理解为时变作用, 反映了时间的流逝. 图 7 是一个 DBN, 每个时间片包含 3 个节点.

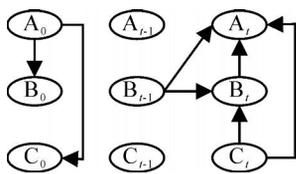


图7 DBN的示例

动态贝叶斯网络包含了两个假设: 一阶马尔科夫假设, 即各点之间的边或者位于同一时间片内, 或者位于相邻的时间片之间, 不能跨越时间片; 齐次性, 即 B 中的参数不随时间变化. 根据初始时刻和相邻时间片之间的条件分布, 可以将 DBN 扩展到第 T 个时间片, 形成一个标准的贝叶斯网络, 结果得到一个跨越多个时间片的联合概率分布

$$P(Z_1, \dots, Z_T) = \prod_{i=1}^T P(Z_i | \text{Pa}(Z_i)).$$

DBN 中初始网的参数学习独立于转换网, 它们均相当于标准贝叶斯网络的参数学习. DBN 的结构学习在数据完备时比较简单, 分为初始网和转换网两部分^[20]; 当数据不完备时, 评分函数不能分解, 这时常见的方法包括 EM 算法^[20]、遗传算法^[22]等. DBN 的概率推理算法比较成熟, 包括边界算法^[21]、接口算法^[21]、直接推理算法^[23]等, 这些算法均具有较高的效率.

3 贝叶斯网络研究方法的扩展

3.1 核学习框架下的贝叶斯网络研究

概率方法与核方法在对系统建模和分析时具有不同的特点:

1) 概率方法能够对随机不确定性进行建模, 并且能够进行概率推理; 概率方法还能够融合异源的数据和知识; 在应用概率模型进行分类时, 并不是绝对地把一个对象分为一个类别, 而是通过计算得出该对象属于某一类的概率, 然后将具有最大概率的类别赋予该对象.

2) 核方法是一系列非线性数据处理方法的总称, 其共同特征是这些方法都应用了核函数. 核方法首先采用非线性映射将原始数据由数据空间映射到特征空间, 进而在特征空间中进行对应的线性操作. 如果数据的坐标分量间的相互作用仅限于内积, 就可使用满足 Mercer 条件的核函数来代替内积运算, 从而越过本来需要计算的映射, 避免维数灾.

如何结合两种方法的优点来解决问题, 引起了研究人员的兴趣^[24-26].

贝叶斯网络作为一种特殊的概率模型, 通过找出问题中潜在的结构, 能够表示对象之间的依赖关系以及条件独立关系, 但是不能处理高维特征空间, 不能保证泛化性能. 核方法能够处理高维特征空间, 并具有较强的泛化能力, 但忽略了对对象中的依赖性, 假定每个对象之间相互独立, 丢失了有用的信息. 为了结合这两种方法的优点, Taskar^[27]提出了结合最大间距思想和马尔科夫网络的 M^3 模型, 该模型能够处理高维结构化数据; Altun 等^[28]提出了隐马尔科夫支持向量机(HMSVM), 与标准的 HMM 训练方法相比, HMSVM 基于最大和柔性间距标准的判别学习, 能够处理特征不独立的情形; Guo 等^[29]研究了基于最大间距准则的贝叶斯网络的训练问题, 并针对一类拓扑结构提出了有效的训练算法, 该算法对任意的拓扑结构收敛到一个近似解; Nakamura 等^[30]研究了布尔型的二类分类贝叶斯网络中的内积空间, 即如何将一个贝叶斯网络的决策函数表示

为维数尽可能小的内积,并给出了内积空间维数的上界和下界.

3.2 代数框架下的贝叶斯网络研究

应用概率方法对系统建模有两个并行的观点:一是基于代数的观点,它涉及被评估的相关系统的代数或逻辑结构;二是基于数值的观点,它主要指概率评估本身^[31].迄今为止,贝叶斯网络的研究主要基于数值的观点.然而,数值方法有自身的缺陷,当精确的数值不可用或者无效时,数值方法就会失效.代数方法能够克服这种缺点,而且代数的观点还提供了另外一个研究贝叶斯网络的视角,拓展了在数值观点下研究得出的结论.

贝叶斯网络确定的联合概率分布根据链规则可以表示成一个分解的因式,这个联合概率分布等价于一个贝叶斯网络.根据这种等价关系,Wong等^[32]研究了描述和刻画贝叶斯网络等价类的代数特征,结果表明两个贝叶斯网络等价当且仅当它们有相同的内在分解因式.Studený^[33]提出了应用一种称为标准 imset 的整数向量表示条件独立关系,研究结果表明,一个贝叶斯网络可唯一地表示成一个标准 imset,并提出了 imset 表示法与图形表示法之间的相互转换方法^[34].在标准 imset 的表示方式下,一个可分解的分值等价的评分准则是标准 imset 的映射函数,这时可以应用标准 imset 表示评分函数并进行结构学习^[35].

另外还有在代数统计观点下的贝叶斯网络研究.代数统计是近几年新出现的研究领域,是研究代数、组合数学、统计学及其相关应用的交叉学科.代数统计主张应用多项式代数作为离散数据统计分析中的工具^[36].从代数统计的观点出发,一个图模型是一个有丰富结构的从低维参数空间到张量积空间的多项式映射.Garcia等^[36,37]研究了贝叶斯网络中条件独立所定义的代数簇以及在模型选择中的应用.Beerenwinkel等^[38]研究了连接贝叶斯网络(CBNs),结果表明经过同调变换后,CBNs是一个环簇且具有一个二次 Grobner 基.

4 评价与展望

贝叶斯网络扩展的模型和研究方法从不同的侧面对贝叶斯网络进行了扩展,提高了处理问题的能力.它们正处于不断发展的阶段,还有许多问题需要解决,主要体现在如下几个方面:

1) 贝叶斯网络的扩展模型各具特点,能够解决不同情形的问题.OOBN 融入了类别层次知识,适合于构建大型贝叶斯网络;HBN 融入了数据类型知识,能够表达更丰富的语义;PRMs 能够对复杂关系数据建模;CBN 突破了无环的限制,适合于对迭代

反馈过程进行建模;而 DBN 则是对动态系统建模的良好工具.但是实际中的问题可能同时具有多种不同的特征,例如,在物价预测这类问题中,存在迭代反馈过程,同时观测数据可能是多维关系数据.因此,需要研究对具有多特征问题建模的方法.已有的研究虽然包括能够对多特征问题建模的扩展模型,如动态概率关系模型(DPRMs)^[39],但是这方面的研究还很少.在贝叶斯网络的框架下,在已有扩展模型的基础上,进一步研究新的扩展模型,从而能够适用于具有多特征的复杂领域.

2) 在扩展模型中应用结构化信息提高模型的建模和概率推理效率,是扩展模型研究的重要内容之一.在学习 OOBN 时利用面向对象的知识,能够提高参数估计以及结构学习的质量;利用 HBN 中的结构化知识,能够缩小搜索结构的范围;PRMs 中的结构化信息能够提高推理的效率.这方面还有许多问题值得进一步研究,例如,如何应用 OOBN 中对象的封装及重用机制,提高 OOBN 的推理效率;当前 PRMs 中搜索合理的依赖结构主要通过穷尽搜索或者贪婪搜索,如何利用 PRMs 中的结构化信息引导搜索方向,从而提高搜索的效率.

3) DBN 中的动态演化是观测系统随着时间的变化,而不是指网络结构随着时间的变化.进一步可以研究网络结构动态演化的扩展模型.

4) 核方法能够处理高维特征空间,且有很强的泛化性,这与概率方法的特点互补.当前应用核方法对贝叶斯网络的研究限于如何提高贝叶斯网络的数据分析能力.利用核方法的特点,探索高效率的建模方法是值得进一步研究的问题.

5) 代数方法具有独特的理论优势,应用代数方法研究贝叶斯网络是对数值方法的补充和扩展.目前的研究主要包括贝叶斯网络等价类的代数特征和贝叶斯网络的代数表示.除了进一步研究构建贝叶斯网络更有效的代数方法,还可以应用代数方法探索贝叶斯网络中的概率推理问题.

6) 把核方法和代数方法应用于扩展模型的建模和推理,也是一个值得研究的方向.

5 结 论

贝叶斯网络自出现以来一直是相关领域的研究热点,相关的扩展模型以及新的研究方法则是近年来的研究重点之一.在贝叶斯网络的框架下,扩展模型和新的研究方法具有许多优势,能够解决更复杂的问题.本文综述了贝叶斯网络扩展的模型和研究方法,分析了当前研究中存在的问题,并说明了未来研究的关键问题和发展方向.

参考文献(References)

- [1] Pearl J. Fusion, propagation and structuring in belief networks[J]. *Artificial Intelligence*, 1986, 29 (3): 241-288.
- [2] Neapolitan R E. Learning Bayesian networks[M]. New York: Pearson Prentice Hall Upper Saddle River, 2004.
- [3] 张连文, 郭海鹏. 贝叶斯网引论[M]. 北京: 科学出版社, 2006.
(Zhang L W, Guo H P. Introduction to Bayesian networks[M]. Beijing: Science Press, 2006.)
- [4] Koller D, Pfeffer A. Object-oriented Bayesian networks [C]. Proc UAI97. San Francisco: Morgan Kaufman, 1997: 302-313.
- [5] Bangs ϕ O, Wuillemin P H. Object oriented Bayesian networks: A framework for top-down specification of large Bayesian networks with repetitive structures[R]. Aalborg: Department of Computer Science, 2000.
- [6] Langseth H, Bangs ϕ O. Parameter learning in object oriented Bayesian networks[J]. *Annals of Mathematics and Artificial Intelligence*, 2001, 32(1): 221-243.
- [7] Langseth H, Nielsen T D. Fusion of domain knowledge with data for structural learning in object oriented domain[J]. *J of Machine Learning Research*, 2004, 4 (3): 339-368.
- [8] Bangs ϕ O. Object oriented Bayesian networks [D]. Aalborg: Aalborg University, 2004.
- [9] Gyftodimos E, Flach P. Hierarchical Bayesian networks: An approach to classification and learning for structured data[C]. Proc of the Work-in-Progress Track at the 13th Int Conf on Inductive Logic Programming. Zagreb: Ruder Boskovic Institute, 2003: 25-36.
- [10] Gyftodimos E, Flach P A. Learning hierarchical Bayesian networks for human skill modelling[C]. Proc of the 2003 UK Workshop on Computational Intelligence. Bristol: University of Bristol, 2003: 55-62.
- [11] Gyftodimos E, Flach P A. Hierarchical Bayesian networks: A probabilistic reasoning model for structured domains [C]. Proc of the ICML-2002 Workshop on Development of Representations. San Francisco: University of New South Wales, 2002: 23-30.
- [12] Friedman N, Getoor L, Koller D, et al. Learning probabilistic relational models[C]. Proc of the 16th Int Joint Conf on Artificial Intelligence. Stockholm: Morgan Kaufman, 1999: 1300-1309.
- [13] Getoor L. Learning statistical models from relational data[D]. Stanford: Stanford University, 2002.
- [14] Koller D. Probabilistic relational models[C]. Inductive Logic Programming 9th Int Workshop. Berlin: Springer Verlag, 1999: 3-13.
- [15] Neville J. Statistical models and analysis techniques for learning relational data [D]. Amherst: University of Massachusetts Amherst, 2006.
- [16] 胡玉胜. 动态 Bayes 网络研究及其应用[D]. 北京: 北京科技大学, 2001.
(Hu Y S. Research on dynamic Bayes network and its application[D]. Beijing: Beijing University of Science and Technology, 2001.)
- [17] 蒋国萍. 软件项目风险管理的贝叶斯网络模型研究 [D]. 长沙: 国防科技大学, 2005.
(Jiang G P. Research of Bayesian network model in software project risk management [D]. Changsha: National University of Defense Technology, 2005.)
- [18] 周忠宝. 基于贝叶斯网络的概率安全评估方法及应用研究[D]. 长沙: 国防科技大学, 2006.
(Zhou Z B. Research on methods and application of probabilistic safety assessment based on Bayesian networks [D]. Changsha: National University of Defense Technology, 2006.)
- [19] Dean T, Kanazawa K. A model for reasoning about persistence and causation [J]. *Computational Intelligence*, 1989, 5(3): 142-150.
- [20] Friedman N, Murphy K, Russell S. Learning the structure of dynamic probabilistic networks[C]. The Proc 14th Conf on Uncertainty in Artificial Intelligence. Madison: Morgan Kaufmann, 1998: 139-147.
- [21] Murphy K P. Dynamic Bayesian networks: Representation, inference and learning[D]. Berkeley: University of California, 2002.
- [22] 王飞, 刘大有, 卢奕南, 等. 基于遗传算法的动态 Bayesian 网结构学习的研究[J]. *电子学报*, 2003, 31 (5): 698-702.
(Wang F, Liu D Y, Lu Y N, et al. Research on learning dynamic Bayesian networks by genetic algorithms[J]. *Acta Electronica Sinica*, 2003, 31 (5): 698-702.)
- [23] 史建国, 高晓光. 离散动态贝叶斯网络的直接计算推理算法[J]. *系统工程与电子技术*, 2005, 27 (9): 1626-1630.
(Shi J G, Gao X G. Direct calculation inference algorithm for discrete dynamic Bayesian network [J]. *Systems Engineering and Electronics*, 2005, 27 (9): 1626-1630.)
- [24] Jaakkola T, Haussler D. Exploiting generative models in discriminative classifiers [C]. *Advances in Neural Information Processing Systems*. Cambridge: MIT Press, 1998, 11: 487-493.
- [25] Jaakkola T, Haussler D. Probabilistic kernel regression models [C]. Proc of the 1999 Conf on AI and Statistics. San Francisco: Morgan Kaufmann, 1999.

(下转第 1091 页)

- basis of the key competitive strength [J]. Logistics Science and Technology, 2006, 29(134): 68-71.)
- [2] 陈剑, 冯蔚东. 虚拟企业构建与管理[M]. 北京: 清华大学出版社, 2002.
(Chen J, Feng X W D. Establishing and administration of the virtual alliance [M]. Beijing: Tsinghua University Press, 2002.)
- [3] 李森, 杨锡怀, 戚桂清. 非同类企业合作策略收益与风险分析[J]. 控制与决策, 2005, 20(11): 1288-1290.
(Li S, Yang X H, Qi G Q. Analysis on income and risk of dissimilar enterprises under co-operation strategy[J]. Control and Decision, 2005, 20(11): 1288-1290.)
- [4] 刘智全, 冯英俊. 供应链企业利益分配问题研究[J]. 学术交流, 2006, 145(4): 77-80.
(Liu Z Q, Feng Y J. Research on the profit distribution of the supplying chain enterprises [J]. Academic Exchange, 2006, 145(4): 77-80.)
- [5] Sunil Chopra, Peter Meindl. Supply chain management strategy: Planning and operation [M]. Beijing: Tsinghua University Press, 2002.
- [6] Xumei Zhang, Bin Dan. The architecture and operation mode of virtual supply chain [J]. Chinese Business Review, 2003, 181(2): 53-54.
- [7] Jean-Jacques Laffont, David Martimort. The theory of incentives-the principal-agent model[M]. Beijing: China Renmin University Press, 2002.
- [8] 慕方中, 刘端阳, 潘晓弘. 一种考虑风险因素的供应链利益分配策略[J]. 商业研究, 2006, 345(13): 17-19.
(Qi F Z, Liu D Y, Pan X H. A distribution strategy of the chain profit considering the factor of risk [J]. Commercial Research, 2006, 345(13): 17-19.)
- [9] Karl Morasch. Strategic alliances as Stackelberg cartels-concept and equilibrium alliance structure [J]. Int J of Industrial Organization, 2000, 265(18): 257-282.
- [10] 孙东川, 叶飞. 动态联盟利益分配的谈判模型研究[J]. 科研管理, 2001, 22(2): 91-95.
(Sun D C, Ye F. Research on negotiation model of the profit distribution of the dynamic alliance [J]. Science Research Management, 2001, 22(2): 91-95.)
- [11] 伯杰. 统计决策论及贝叶斯分析[M]. 北京: 中国统计出版社, 1998: 62-64.
(James O Berger. Statistical decision theory and Bayesian analysis [M]. Beijing: China Statistics Publishing House, 1998: 62-64.)

(上接第 1086 页)

- [26] Tipping M E. Sparse Bayesian learning and the relevance vector machine [J]. J of Machine Learning Research, 2001, 2(1): 211-244.
- [27] Taskar B, Guestrin C, Koller D. Max-margin Markov networks[C]. Proc of NIPS '03. Vancouver, 2003: 97-104.
- [28] Altun Y, Tschantaridis I, Hofmann T. Hidden Markov support vector machines [C]. Proc ICML03. Washington: AAAI Press, 2003: 3-10.
- [29] Guo Y, Wilkinson D, Schuurmans D. Maximum Margin Bayesian networks [C]. Proc of the 21st Conf on Uncertainty in Artificial Intelligence. Virginia: AUAI Press, 2005: 233-242.
- [30] Nakamura A, Schmitt M, Schmitt N, et al. Bayesian networks and inner product spaces [J]. J of Machine Learning Research, 2005, 6: 1383-1403.
- [31] 邓勇, 施文康. 基于条件事件代数的常概率事件模型及应用[J]. 上海交通大学学报, 2002, 36(4): 588-591.
(Deng Y, Shi W K. Model of constant probability event based on conditional event algebra and its application [J]. J of Shanghai Jiaotong University, 2002, 36(4): 588-591.)
- [32] Wong S K M, Wu D. An algebraic characterization of equivalent Bayesian networks [C]. Proc of the IFIP 17th World Computer Congress-TC12 Stream on Intelligent Information Processing. Newtherland: Kluwer, 2002: 177-187.
- [33] Studeny M. Structural imsets: An algebraic method for describing conditional independence structures [C]. Proc of 10th Int Conf IPMU. Perugia, 2004: 1323-1330.
- [34] Studeny M, Vomlel J. Transition between graphical and algebraic representatives of Bayesian network models (extended version) [C]. Proc of PGM '04. Leiden, 2004: 193-200.
- [35] Studeny M. An algebraic approach to structural learning Bayesian networks [C]. Proc of 11th Int Conf IPMU. Paris, 2006: 2284-2291.
- [36] Garcia L D. Algebraic statistics in model selection [C]. Proc of the 20th Conf on Uncertainty in Artificial Intelligence. Banff: AUAI Press, 2004: 177-184.
- [37] Garcia L D, Stillman M, Sturmfels B. Algebraic geometry of Bayesian networks [J]. J of Symbolic Computation, 2005, 39(3/4): 331-355.
- [38] Beerenwinkel N, Eriksson N, Sturmfels B. Conjunctive Bayesian networks [J]. Bemoulli, 2007, 13(4): 893-909.
- [39] Sanghai S, Domingos P, Weld D. Dynamic probabilistic relational models [C]. Proc of 18th Int Joint Conf on Artificial Intelligence. Acapulco: Morgan Kaufmann, 2003: 992-1002.