

利用动态贝叶斯网络进行多时相遥感变化检测

欧阳赞^{①②} 马建文^① 戴芹^{①②}

^①(中国科学院遥感应用研究所 北京 100101)

^②(中国科学院研究生院 北京 100049)

摘要: 利用动态贝叶斯网络(DBNs)在处理不同时相遥感数据时可以一次性输入多个时间段的数据,同时完成分类和建立输出类别之间的关联。采用北京东部地区 1994 年、2001 年和 2003 年 5 月份 Landsat TM 遥感数据进行实验,实验结果表明:基于 DBNs 的变化检测方法是遥感变化检测的一种新的有效方法,在遥感时序数据动态变化分析的研究方面也展示了巨大的发展潜力。

关键词: 贝叶斯网络; 动态贝叶斯网络; 遥感变化检测

中图分类号: TP751

文献标识码: A

文章编号: 1009-5896(2007)03-0549-04

Multi-temporal Remote Sensing Change Detection Using Dynamic Bayesian Networks

Ouyang Yun^{①②} Ma Jian-wen^① Dai Qin^{①②}

^①(Institute of Remote Sensing Applications, Chinese Academy of Sciences, Beijing 100101, China)

^②(Graduate School, Chinese Academy of Sciences, Beijing 100049, China)

Abstract: Utilizing Dynamic Bayesian Networks (DBNs) to deal with multi-temporal remote sensing data, the multi-temporal data of different time can be input simultaneously, and the classification and the acquirement of relationships between the output types can be finished simultaneously. Using the Landsat TM remote sensing data of Beijing eastern area acquired in May of 1994, 2001 and 2003 for the experiment, the experimental results indicate that the DBN-based change detection method is a new effective method of remote sensing change detection, and show its great potential for the research on the analysis of the dynamic changes of remote sensing time-series data.

Key words: Bayesian Networks (BNs); Dynamic Bayesian Networks (DBNs); Remote sensing change detection

1 引言

20 世纪 80 年代晚期涌现出的贝叶斯网络(BNs)^[1],使得建造从证据产生可靠的概率推理的大规模系统成为可能。90 年代进一步研究的可学习的贝叶斯网络^[2],广泛用于人工智能的各个领域^[3]。BNs 将贝叶斯概率方法与有向无环图的网络拓扑结构有机结合。BNs 的优点包括:能够处理不完全数据;能够表示变量间的因果关系;能够充分利用先验知识和样本信息。在 BNs 进一步研究和成功应用的同时,90 年代后期出现了动态贝叶斯网络(DBNs)^[4]。DBNs 是 BNs 的扩展,它将 BNs 利用证据产生可靠概率推理的方法应用于时间序列模型中。DBNs 将每一个时间点上的每个方面都用一个随机变量表示,通过这种方式对变化的环境进行建模。这些变量之间的关系描述了状态是如何随时间演化的。目前 DBNs 的理论和应用的研究已经成为国际上的热点,并在图像跟踪^[5]、语音识别^[6]、交通流量分析^[7]、基因分析^[8]等方面获得了一系列的成果。Intel 公司也将 DBNs 作为未来处理器推理架构的

核心技术进行研究^[9]。但是如何将 DBNs 应用于遥感信息的动态变化分析还缺乏研究。

隐马尔科夫模型(HMMs)^[10,11]和卡尔曼滤波器(KFMs)^[12,13]是动态贝叶斯网络的两个特殊情况。HMMs 和 KFMs 将同一时刻的状态和观察变量分别表示为单一的多元向量,并且假设转换模型和状态模型不随时间变化而变,即所谓的稳态过程假设。不同的是,在 HMMs 中,转换模型为多项分布;而在 KFMs 中,转换模型和观察模型都是线性高斯分布。HMMs 和 KFMs 的限制给它们的应用带来了问题。HMMs 的转换模型参数个数随其状态向量的分量个数的增加是成指数级的,这样的计算复杂度对于复杂系统、大数据量的应用是不可行的。而 KFMs 中高斯分布的单峰性质对很多问题并不适用。如果用 DBNs 来表示 HMMs 和 KFMs,可以发现它们有相同的拓扑结构,这种结构是单一的,并且随时间变化,其状态的变化规律只是简单的复制。DBNs 通过将复杂系统的状态和观察分解成一些组成变量,充分利用了时序概率模型的稀疏性,其拓扑结构较之 HMMs 和 KFMs 更为一般化。而且,DBNs 中变量可以是任意的条件概率分布(CPDs)。因此 DBNs 比 HMMs 和 KFMs 具有更强的表达能力

和可行性。遥感数据在不同时相的分布情况受各种客观条件的影响并不一致甚至相去甚远，并不符合HMMs和KFMs建模的前提。而DBNs的包容性和稀疏性决定了它非常适合对具有多时相、多波段特征的海量的遥感数据建立动态变化关系。

通常使用的遥感数据分类后对比检测方法是对经过几何配准的两个(或多个)不同时相遥感图像分别作分类处理后，获得两个分类图像，并逐个像元比较，生成变化图像，再根据变化检测矩阵确定各变化像元的变化类型^[14]。这种方法的缺点是必须对不同图像分别进行分类处理，并且没有建立前后类型的动态联系。利用BNs进行遥感变化检测的研究已经有了一些成果，文献[15]和文献[16]中分别利用BNs进行分类后变化检测和直接变化检测，这些方法还没有突破静态推理局限。本文提出利用DBNs进行遥感变化检测的方法，不但可同时获取不同时相各像元的类型，而且还能获得各时相的类型与波段间的关系和类型的动态变化规律。

2 动态贝叶斯网络(DBNs)的基本原理与方法

2.1 DBNs 基本原理

DBNs的目的在于描述变量集合 (Z_1, Z_2, \dots, Z_T) 的动态变化。每个时间段的变量集合 Z_t 包括状态变量 $X_t^1, X_t^2, \dots, X_t^m$ 和观察变量 $Y_t^1, Y_t^2, \dots, Y_t^n$ 。Murphy^[14]将一个DBN定义为一个二元组 (B_1, B_-) 。其中， B_1 是一个表示初始时刻状态和观察变量间关系的贝叶斯网络，它定义了联合分布 $p(Z_1)$ ； B_- 是一个表示时刻 $t-1$ 和时刻 t 各变量之间关系的两时段贝叶斯网络，它定义了条件分布 $p(Z_t | Z_{t-1})$ 。这个定义其实隐含地假定了模型是一阶马尔科夫的，即 $p(Z_t | Z_{1:T}) = p(Z_t | Z_{t-1})$ 。因此 (B_1, B_-) 就定义了整个动态贝叶斯网络的联合分布： $p(Z_{1:T}) = p(Z_1) \prod_{t=2}^T p(Z_{t-1} | Z_t)$ 。本文假设时刻 t 的观察变量取决于该时刻的状态变量，即 $p(Y_t^i | Z_{1:T}) = p(Y_t^i | X_t^{1:m})$ 。这样同时也确定了节点的顺序(节点的父节点始终在该节点之前)，可以表示为 $(X_1, Y_1, X_2, Y_2, \dots, X_T, Y_T)$ 。其中， $X_t = \{X_t^1, X_t^2, \dots, X_t^m\}$ ， $Y_t = \{Y_t^1, Y_t^2, \dots, Y_t^n\}$ 。

2.2 DBNs 学习方法

由于DBNs的目的是描述状态变量动态变化关系，而一般的贝叶斯网络学习方法只是将状态变量作为普通随机变量而没有突出其重要性，因此DBNs的结构学习不宜采用一般的网络学习算法。考虑到同时刻状态变量与观察变量以及前后时刻状态变量的因果关系，这里假设DBNs的网络结构中只包含同时刻状态变量到观察变量和前后时刻状态变量的有向边(如图1)。在遥感变化检测中样本点的土地覆盖类型是可以获得的。因此对DBNs的学习采用贝叶斯网络的完整数据学习方法，即在学习时将DBNs的状态变量认为是可观察的。




图1 DBN网络结构

假设网络中每个结点都服从无约束多项分布(如果连续先进行离散化)。设每个离散变量 X_i 的取值范围是 $x_i^1, \dots, x_i^{r_i}$ ，其局部分布 Pa_i 是一个多项分布集合，包括 $pa_i^1, \dots, pa_i^{q_i}$ ($q_i = \prod_{X_i \in Pa_i} r_i$)。令 $p(x_i^k | pa_i^j, \theta_i, S^h) = \theta_{ijk} > 0$ 。其中参数 $\theta_i = ((\theta_{ijk})_{k=2}^{r_i})_{j=1}^{q_i}$ (参数 θ_{ij1} 可以通过 $\theta_{ij1} = 1 - \sum_{k=2}^{r_i} \theta_{ijk}$ 得到)。为表达方便，还定义 $\theta_{ij} = (\theta_{ij2}, \dots, \theta_{ijr_i})$ 。

给定网络结构 S 和训练数据 D ，贝叶斯网络参数学习问题就是计算后验概率 $p(\theta | D, S)$ 。在训练数据的完整性和参数的独立性的假设条件下，给定训练数据 D 后参数 θ_{ij} 仍然保持互相独立^[1]，即

$$p(\theta | D, S) = \prod_{i=1}^n \prod_{j=1}^{q_i} p(\theta_{ij} | D, S)$$

进一步假设 θ_{ij} 服从Dirichlet先验分布：

$$p(\theta_{ij}) = \text{Dir}(\theta_{ij} | \alpha_{ij1}, \dots, \alpha_{ijr_i}) \equiv \frac{\Gamma(\alpha_{ij})}{\prod_{k=1}^{r_i} \Gamma(\alpha_{ijk})} \prod_{k=1}^{r_i} \theta_{ijk}^{\alpha_{ijk}-1}$$

其中 $\alpha_{ij} = \sum_{k=1}^{r_i} \alpha_{ijk}$ ， $\alpha_{ijk} > 0$ 。由于Dirichlet分布是多项分布的共轭先验，因此有

$$p(\theta_{ij} | D, S) = \text{Dir}(\theta_{ij} | \alpha_{ij1} + N_{ij1}, \dots, \alpha_{ijr_i} + N_{ijr_i})$$

N_{ijk} 是训练数据 D 中 $X_i = x_i^k$ 且 $Pa_i = pa_i^j$ 的事件数目。

2.3 寻找最可能状态序列方法

在给定观察变量取值的情况下，什么最可能的状态序列可以产生观察序列？这个问题称为求解最有可能解释(MPE)。本文采用联合树算法^[17,18]。

联合树算法的基本想法是将贝叶斯网络中的证据传播通过一个无向多树即联合树来实现。设 T 为一个联合树，它的节点集合为 C ，边集合为 S 。 T 的任一节点 c 对应着 U (U 为贝叶斯网络中所有节点的集合)的一个子集，这里同样记为 c ，称为团。每一个 $u \in U$ 至少属于一个团节点。连接两个邻接的团节点 c_1 和 c_2 的边定义为一个分割器 $s = c_1 \cap c_2$ 。如果 $u \in U$ 同时属于两个团节点 c_1 和 c_2 ，那么 u 属于从 c_1 到 c_2 的唯一路径上的所有团节点。这个性质称为联合树性质。联合树建立的具体步骤可参考文献[19]。本文假设 T 是连通的，因为如果不连通的可以对连通的几个部分分别处理。对与贝叶斯网络中所有节点对应的一组变量 $X = (x : x \in U)$ ，其联合分布可以表示为

$$f(X) = \prod_{c \in C} \phi_c(c) / \prod_{s \in S} \phi_s(s)$$

其中 $\phi(\cdot)$ 称为势函数, 它表示相应的团(或者边)所包含的所有节点的联合分布。

令 c_1 和 c_2 为 T 的两个邻接的团节点, 并且 s 为连接 c_1 和 c_2 的边。考虑从 c_1 到 c_2 传递最大信息流的影响。首先 s 得到一个新的势函数: $\phi_s^* = \text{Max}_{c_1 \setminus s} \phi_{c_1}$ 。然后 c_2 也得到一个新的势函数: $\phi_{c_2}^* = \phi_{c_2} \lambda_s = \phi_{c_2} \phi_s^* / \phi_s$ 。Jensen 等^[20] 建议将整个联合树的信息传播包括两个阶段。选择任意团节点 c 作为根节点。在开始的集中阶段, 激活的最大信息流从邻接节点向 c 传递。而在分散阶段激活的最大信息流又从 c 向四周传递回去。在这两个阶段都完成之后, 就可以通过势函数进行计算得到最有可能解释。

3 遥感数据处理实验与效果

实验数据是 1994 年、2001 年和 2003 年 5 月份的北京东部地区 TM 遥感数据。选取的研究范围为 311×332 个像元。选用的波段范围为 1-5 波段和 7 波段, 共 6 个波段(30m 分辨率)。图 2(a), 2(b)和 2(c)分别是 1994 年, 2001 年和 2003 年研究区域的 5, 4 和 3 波段合成影像图。

由于本文主要侧重于方法的研究, 因此只将确定的研究区域分成 4 种类型: 城镇用地、裸地、水域和植被。在遥感图像上选取训练和验证数据集。数据选取对 3 个时相的影像同时进行, 这样保证了像元的一致(每个像元对应 3 个时相的波段数据)。表 1 和表 2 分别是试验用训练和验证样本数据集的构成描述。




图 2 1994 年、2001 年和 2003 年的 5, 4, 3 波段合成图

表 1 训练数据集

	1994 年	2001 年	2003 年
城镇用地	1061	1947	1762
裸地	754	1341	1645
水域	606	1021	1119
植被	2741	853	636
总计	5262	5262	5262

表 2 验证数据集

	1994 年	2001 年	2003 年
城镇用地	1033	1878	1701
裸地	746	1316	1585
水域	587	991	1087
植被	2634	815	627
总计	5000	5000	5000

选用的波段是 6 个, 因此每个样本有 6 个属性, 属性值即为对应波段的灰度值。灰度值的可能取值范围多样, 首先对各波段取值进行离散化处理。本文采用基于熵的离散化方法对每个时相的各个波段分别进行离散化。

利用离散化的训练样本波段数据来学习参数。网络结构如图 3。学习结束后用联合树算法对训练的网络和离散化的验证样本波段数据计算样本点各时相的最可能土地覆盖类型序列。表 3、表 4 和表 5 分别是 1994 年, 2001 年和 2003 年的土地覆盖类型计算结果的混淆矩阵。而这 3 个时相的验证样本整体分类精度分别为 86.66%, 86.84%和 85.14%。图 4 中 4(a), 4(b)和 4(c)分别是利用联合树算法计算的 1994 年, 2001 年和 2003 年的土地覆盖类型结果图。图 5 和图 6 分别是 1994—2001 和 2001—2003 的变化检测结果图。从土地覆盖类型计算结果来看, 总体精度较高, 而具体各时相中土地覆盖类型的分类精度除了 1994 年的裸地和水域分类精度较差之外, 其它的都取得较高水平。




图 3 3 个时相土地覆盖类型和波段的 DBN 网络结构

表 3 1994 年土地覆盖类型计算结果的混淆矩阵

	城镇用地	裸地	水域	植被	精度(%)
城镇用地	937	43	51	2	90.71
裸地	66	532	39	109	71.31
水域	49	63	421	54	71.72
植被	64	59	68	2443	92.75

表 4 2001 年土地覆盖类型计算结果的混淆矩阵

	城镇用地	裸地	水域	植被	精度(%)
城镇用地	1585	191	101	1	84.40
裸地	131	1154	29	2	87.69
水域	119	1	857	14	86.48
植被	3	0	66	746	91.53

表 5 2003 年土地覆盖类型计算结果的混淆矩阵

	城镇用地	裸地	水域	植被	精度(%)
城镇用地	1484	142	75	0	87.24
裸地	281	1241	62	1	78.30
水域	54	15	997	21	91.72
植被	3	1	88	535	85.32

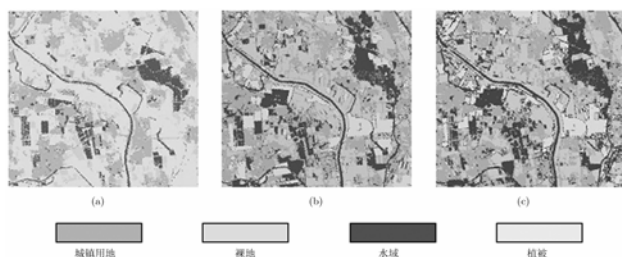
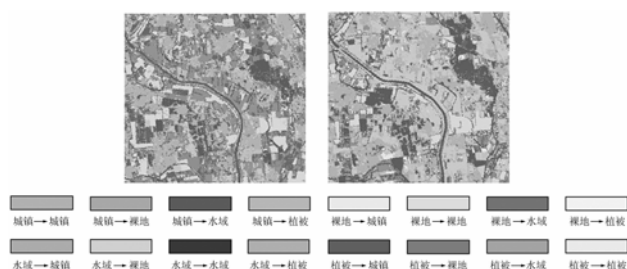



图 4 1994 年、2001 年和 2003 年的土地覆盖类型计算结果

图 5 1994-2001 变化
检测结果图图 6 2001-2003 变化
检测结果图

4 结束语

本文在分析 DBNs 性质的基础上, 结合遥感数据特点和当前遥感变化检测不能表达变化过程关联问题, 探索了利用 DBNs 进行遥感变化检测的方法研究, 在研究中克服了遥感数据量大问题、学习问题和寻找最可能状态序列问题, 通过编程实现算法的稳定运行, 实验取得了较好效果。结果表明 DBNs 为遥感信息动态变化关系的研究方面展示了巨大的发展潜力。由于本文中所用的 DBNs 网络结构还是较为简单, 如何利用更为复杂的 DBNs 网络解决更多特征和更多时相遥感数据变化检测问题是下一步探索的主要任务。

参 考 文 献

- [1] Pearl J. Probabilistic Reasoning in Intelligent Systems. San Francisco, CA: Morgan Kaufmann. 1988, Chapter 3.
- [2] Heckerman D. A tutorial on learning with Bayesian networks. Technical Report MSR-TR-95-06, Microsoft Research, Redmond, USA, 1995: 57.
- [3] 史忠植等. 知识发现. 北京: 清华大学出版社, 2002: 169-198.
- [4] Murphy K P. Dynamic Bayesian Networks: Representation, inference and learning. PhD Thesis, UC Berkeley, 2002.
- [5] Pavlovic V, Rehg J M, Cham T J, and Murphy K P. A dynamic Bayesian network approach to figure tracking using learned dynamic models. Proceedings of IEEE International Conference on Computer Vision 1999, Corfu, Greece, 1999: 94-101.
- [6] Nefian A, Liang L, Pi X, Liu X, and Murphy K P. Dynamic Bayesian networks for audio-visual speech recognition.

Journal of Applied Signal Processing, 2002, 11: 1-15.

- [7] Kwon J and Murphy K P. Modeling freeway traffic using coupled HMMs. Technical report, Department of Computer Science, UC Berkeley, 2000.
 - [8] Zou M and Conzen S D. A new dynamic Bayesian network approach for identifying gene regulatory networks from time course microarray data. *Bioinformatics*, 2005, 21(1): 71-79.
 - [9] Liang Bob. 未来处理器架构进行应用驱动的研究报告. Intel Microprocessor Research Forum. Beijing, China, 2002.
 - [10] Rabiner L R. A tutorial on hidden Markov models and selected applications in speech recognition. *Proc. IEEE*, 1989, 77(2): 257-286.
 - [11] Bengio Y. Markovian models for sequential data. *Neural Computing Surveys*, 1999, 2: 129-162.
 - [12] Roweis S and Ghahramani Z. A unifying review of linear Gaussian models. *Neural Computation*, 1999, 11(2): 305-345.
 - [13] Minka T. From hidden Markov models to linear dynamical systems. Technical report, MIT, 1999.
 - [14] 赵英时等. 遥感应用分析原理与方法. 北京: 科学出版社. 2003, 第 7 章.
 - [15] 陈雪, 戴芹, 马建文, 李小文. 贝叶斯网络分类算法在遥感数据变化检测上的应用. 北京师范大学学报(自然科学版), 2005, 41(1): 97-100.
- Chen Xue, Dai Qin, and Ma Jian-wen, *et al.* Application of Bayesian network classification to remote sensing change detection. *Journal of Beijing Normal University (Natural Science)*, 2005, 41(1): 97-100.
- [16] 戴芹, 马建文, 欧阳赞. 利用贝叶斯网络进行遥感变化检测. 中国图像图形学报, 2005, 10(6): 705-709.
 - [17] Dawid A P. Applications of a general propagation algorithm for probabilistic expert systems. *Statistics and Computing*, 1992, 2: 25-36.
 - [18] Nilsson D. An efficient algorithm for finding the most probable configurations in probabilistic expert systems. *Statistics and Computing*, 1998, 8: 159-173.
 - [19] Jensen F V. An introduction to Bayesian networks. London: UCL Press, 1996: 1-178.
 - [20] Jensen F V, Olesen K G, and Andersen S K. An algebra of Bayesian belief universes for knowledge-based system. *Networks*, 1990, 20: 637-659.
- 欧阳赞: 男, 1981 年生, 博士生, 研究领域为遥感数据处理算法。
马建文: 男, 1953 年生, 研究员, 博士生导师, 主要研究领域为遥感应用模型与方法研究。
戴 芹: 女, 1978 年生, 博士生, 研究领域为遥感信息处理与应用。