

马尔科夫网的概念、方法及其在图像处理中应用

曹建农^{1,2)} 李德仁^{2,3)} 关泽群²⁾

¹⁾(西安建筑科技大学 建筑学院, 西安 710054) ²⁾(武汉大学遥感信息工程学院, 武汉 430079)

³⁾(武汉大学测绘遥感信息工程国家重点实验室, 武汉 430079)

摘要 研究可分解马尔科夫网(decomposable Markov network DMN)的概念、方法;分析它在空间数据挖掘中的作用与意义。与以往关于DMN的研究不同,本文直接将DMN的结构作为推理依据或应用于问题求解,扩大DMN概念和方法的应用范围。以多光谱遥感为例广泛研究以多种迹度量建立多波段遥感图像间的马尔科夫网,用以解释波段组合效果;以视频图像为例广泛研究以多种粒度(节点数)建立视频图像间的马尔科夫网,通过网络结构分析检测视频图像中的目标差异,用以定位和跟踪违章车辆。研究表明马尔科夫网可以很好地揭示空间数据间的抽象近邻关系,并且这种网络自身就具有表达知识的意义。

关键词 可分解马尔科夫网 多波段遥感 目标检测 概率距离 空间数据挖掘

中图法分类号:TP751 P231.5 文献标识码:A 文章编号:1006-8961(2005)08-0939-10

Study on Application, Approach and Concept of DMN in Image Processing

CAO Jian-nong^{1,2)}, LI De-ren^{2,3)}, GUAN Ze-qun²⁾

¹⁾(School of Architecture, Xi'an University of Architecture & Technology, Xi'an 710054)

²⁾(School of Remote Sensing and Information Engineering, Wuhan University, Wuhan 430079)

³⁾(National Laboratory for Information Engineering in Surveying Mapping and Remote Sensing, Wuhan University, Wuhan 430079)

Abstract The paper studies concept and approach of decomposable Markov network(DMN). Unlike previous studies on DMN, our method directly employs the construct of DMN as the evidence of inference or for problem solving, and enlarges application range of DMN's concept and approach. It analyses DMN's role and importance in spatial data mining, and deeply investigates several score metrics used in constructing DMN between multi-bands remote sensing images, so as to interpret the result of fusion in them, and realizes optimal fusion of bands. Another example of the factual video images with traffic rule violation is also investigated by novel concept of DMN's graininess. Several graininess(nodes) are used to construct DMN between video images for detecting abnormality in them. Hence, the vehicle of traffic peccancy is located and traced. The result of video image simulation shown that our method is feasible and effective. The researches indicate that the DMN may reveal abstract adjacent relations existed in spatial data; and the network itself has capabilities of showing knowledge.

Keywords decomposable markov network, multi-bands remote, target detection, probability distance, spatial data mining

1 引言

马尔科夫场(MRF)理论应用在图像研究领域

已经有很长的历史了^[1-12]。与其有相同理论渊源的马尔科夫网(decomposable Markov network, DMN)概念的产生大约只有不到20年(1985~)的历史^[13]。虽然,在形式上它们对问题处理不同,但在

基金项目:地理信息工程国家测绘局重点实验室基金项目(1469990324233);国家自然科学基金项目(60175022);国家高科技发展计划“863”项目(2001AA135081)

收稿日期:2004-04-06; 改回日期:2005-01-04

第一作者简介:曹建农(1963~),男,副教授。1987年毕业于原武汉测绘科技大学,现为武汉大学博士研究生。主要从事遥感、图像分析和地理信息系统的教学和科研工作。已发表论文10余篇。E-mail: caojiannong@163.com

理论上却有着一脉相承的理解——即利用和揭示研究对象的近邻关系。马尔科夫场理论的应用以假设近邻关系为前提(这种假设的合理性与局限性并存),充分利用研究对象的近邻关系,其局限性表现为高阶近邻关系的处理几乎是不可能的;而且当这种近邻关系表现为抽象性时,马尔科夫场就无能为力了。马尔科夫网理论以概率统计和图论为理论基础,着力于揭示事物内部的各种抽象的近邻关系,通常是为对问题的进一步处理提供中间数据结构,但是,由于图的表现力,在某些情况下马尔科夫网也不失为一种知识的表现形式。因此,对空间数据的马尔科夫网结构的学习就带有很强的数据挖掘色彩。众所周知,数据挖掘结果的解释很大程度上决定于挖掘结果的内容——即所谓数据挖掘的出人意料性^[14],挖掘前只需提出对网络度量的描述,以大致框定对结果的期望。

马尔科夫网的学习源自于概率网络(probabilistic network, PN)的研究,特别是贝叶斯网络(Bayesian network)的研究^[15-17]。所谓概率网络是指记录了依赖关系的特征图结构和记录了依赖强度的量化概率分布的联合模型^[18,19]。马尔科夫网就是概率网络的一种。

2 马尔科夫网的概念

马尔科夫网是可分解马尔科夫网的简称^[13],有些文献所说的马尔科夫网(MN)与本文 DMN 同义。

2.1 相关概念与定义

无向图中的索(chord)是连接两个不相邻节点的链(link)。如果每个长度大于3的闭合环有一个索,则其为索图,如图1所示, G_1 不是索图, G_2 和 G_3 都是索图;图的集团(clique)是被连接节点对的

最大集合, G_2 有4个集团 $\{a,b,c\},\{b,c,d\},\{c,e\},\{c,f\}$;如果 G 是索图, G 的结合树(T(junction tree, JT)是由 G 的集团(T 的所有点集对)所包含的点集构成的树,它们的交集(intersection)是它们之间的唯一路径,被称作两个集团的隔断集(sepset)。一个图拥有结合树 T (JT)当且仅当图是索图^[20],图1中 T_2 是 G_2 的结合树 T (JT)。 G 的结合森林 F (junction forest, JF)是 G 的所有结合树成分 JTs 的集合,图1中 F_3 是 G_3 的结合森林,它包含两个结合树。同样,一个图拥有结合森林 F (JF)当且仅当图是索图。

通过上述相关概念,给出马尔科夫网的定义^[13]:设 $G=(N,E)$ 是一个索图, F 是 G 的JF; N 是图的节点, E 是图的边。 M 是 N 上的PM(probabilistic model), C 是 F 的集团(clique), S 是 F 的隔断集(sepset); $P_M(C)$ 和 $P_M(S)$ 分别是定义在 M 上的 C 和 S 的边缘分布,则有联合概率密度(JPD):

$$P(v) = \frac{\left(\prod_C P_M(c)\right)}{\left(\prod_S P_M(s)\right)}, P(v) > 0$$

被称作在 G (或 F)上 M 的投影分布,其中, v 是 N 的状态(configuration), c 是 v 对 C 的投影, s 是 v 对 S 的投影,称参数对 (G,P) 是 M 对 G 投影的可分解马尔科夫网, G 是DMN的结构, P 是DMN的分布。我们一般简称 (G,P) 是 M 的马尔科夫网。在实际操作中, $P_M(C)$ 由 M 所产生数据估计得出。显然, (G,P) 所定义的PM可以等价于 M ,也可以不等价于 M 。

2.2 问题适用性与定义再思考

马尔科夫网是对数据集的图结构生成和度量投影,事先并不刻意选择数据视角,而只考虑数据集对哪一种度量更敏感,这种敏感度完全反映于最终马尔科夫网络结构的变化,这种结构变化与迹度量相对应。

1992年文献[12]首次将马尔科夫随机场的应用推广到基于图论的方法上来(但完全不是马尔科夫网的概念),这是自从20世纪20年代Ising博士在其博士论文中提出“Ising模型”^[21],20世纪60~80年代马尔科夫随机场广泛应用于图像分类^[7]、恢复^[11]等处理(都是基于图像格网)之后的首次推广,为马尔科夫随机场理论的深入应用开创了先河。

图像数据结构的单纯性(即栅格结构)使得其




图 1 索图说明

Fig. 1 Illustration of chord graph

分析方法受到很大限制,因而出现了众多的改变其数据结构限制的算法——金子塔图像结构、分层逻辑结构、分开合并方法、变换域方法以及基于图结构的马尔科夫随机场方法^[9,10]等。

图论问题的求解与数值问题的求解有很大的不同,涉及到的数据结构更为复杂,数据元素之间的相互关系一般无法用数学方程式来描述(图像数据是典型的非方程式可以表达的)。解决此类问题的关键是设计出适合的数据结构^[22]。目前,对图像数据“智能化”处理大都带有“图论的网络”色彩。研究发现马氏性在图像数据中绝不仅仅存在于空间位置的“近邻”上,简单地说,马尔科夫网是揭示数据集内在概率联系的图论表达,本文认为,对于视频图像处理,它既可以用于视频图像帧间相似性的知识表示,也可以作为进一步处理的证据。

马尔科夫网的概念对图像处理具有重要意义。但是,Xiang^[13]等人对马尔科夫网的严格定义并不完全适用于图像分析处理和模式识别问题。文献[23]表明:在严格的马尔科夫网定义下所生成的网络中,存在变量之间相连接(相邻)却不相依赖的现象,这实质就是伪依赖(伪连接),如果以这样的马尔科夫网作为图像分析处理和模式识别的证据,就会被“伪证”所误导。实质上,Xiang等人对DMN的严格定义,是将DMN作为进一步学习BN的中间过程,在为学习BN对DMN的再搜索中将会剔除DMN中的伪连接;DMN的严格定义可能产生伪连接^[23],但是这对学习BN有利,因为这样会产生一个充裕的待选集合和固定的网络形式进行概率投影(都是为BN推论做准备),相反伪独立对于学习BN是不利的(因此,有许多关于避免伪独立的研究)^[24]。所以,对于以图像分析处理和图像模式识别提供证据为目的的DMN研究,我们认为(或定义)DMN为:一个具有相邻关系的变量集合的图结构和相应的迹度量,形式上依然表示为 (G, P) ,此处的 G 与2.1节意义相同,而 P 与2.1节既有区别又有联系,虽然它们都是图结构的度量,但是此处的 P 没有了“索结构”的约束,而且也可以是其他任何有意义的统计量。从图像识别的角度看,马尔科夫网主要用于识别过程中证据的获取,特别是获取非空间随机场中某种属性的邻域关系,扩大随机场分析的数据内容。问题的实质是:将DMN作为最终决策网(或证据网)而非一个待修正的过渡网络。

3 马尔科夫网生成

3.1 迹度量的评述

3.1.1 迹度量(score metric)

迹度量实质就是可以最好表达变量间差异性的数学模型,在人工智能中常用的迹度量是贝叶斯度量、描述长度度量(description length metrics)、熵度量(entropy)等^[25-34]。

在对上述文献充分理解的基础上,结合多波段图像和视频图像帧间的空间灰度场和概率分布的实际情况,选择了多种距离作为搜索网络的迹度量。

3.1.2 马尔科夫网的粒度概念

粒度是数据仓库的重要概念,指数据仓库的数据单位中保存数据的细化或综合程度的级别,可分为存储粒度和采样粒度^[35,36]。在空间数据库中实施数据挖掘,首先要确定把什么作为处理的元组,称之为空间数据挖掘的粒度^[37]。

从马尔科夫网的定义可知,马尔科夫网是对问题变量集的近邻关系的图描述,近邻关系的搜索结果(图结构)取决于变量规模(变量个数,即图的顶点数 N ;变量关系数,即图的边数 E)。在不同的变量规模中,对问题的描述结果具有不同的精细程度,定义马尔科夫网的粒度为对问题描述的变量规模——即在相应论域中描述问题的变量数。

3.2 马尔科夫网的搜索原理

从对图像分析的DMN搜索的问题实际意义出发,在网络搜索中不判断索结构也不顾及集团的尺寸(这样就会避免产生伪连接)^[23],理由是对多波段图像和视频图像帧间的差异性描述,并不要求它一定要形成索,因为文献[23]表明,图中被隔离的变量是独立的,但是,图中未隔离的变量并不一定是就是依赖的。也就是说,对于具体问题,如果强制生成索,必然可能使全域差异性最大的多波段图像和视频图像帧连接到一起(由于伪连接而引起)。

选择Floyd-Warshall算法^[38],用它来搜索网络中所有节点间的最短路径,这一特性恰好反映了多波段图像和视频图像帧间的两两全局灰度最小差异性的组合,在网络中必然表现为最大差异性的图像间经历的节点数最多,而差异小的图像间直接相连,此性质与马尔科夫网所定义的性质恰好是相辅相成或相反相成的,正如优化理论所说:任何优化问题都可以归结为最小或最大值问题^[39]。

Floyd-Warshall 算法是有关图结构问题中的一个著名算法。该算法通过对表示图的邻接矩阵作迭代计算,解决图的任意一对顶点之间的最短路径问题。用图的节点表示波段图像或一帧序列图像,用图的节点之间的边表示波段图像或一帧序列图像之间的统计相似关系。用加权邻接矩阵表示图,即任意两个节点(即波段图像或一帧序列图像)之间的权表示该两个节点(即波段图像或一帧序列图像)之间的统计相似性(即文中提及的各种统计距离)。由于 Floyd-Warshall 算法的性质就是解决图的任意一对顶点之间的最短路径(即最优化)问题,因此,将上述任意两个节点(即波段图像或一帧序列图像)之间的相似性度量的权值看作图的路径度量,则图像优化问题就转化为图论的最佳路径问题。Floyd-Warshall 算法的实质是一个动态规划过程,适合多路径优化问题。

4 马尔科夫网的图论解释与应用

以多光谱遥感为例广泛研究用多种迹度量建立多波段遥感图像间的马尔科夫网,用以解释波段融

合效果;以视频图像为例广泛研究用多种粒度(节点数)建立视频图像间的马尔科夫网,通过网络结构分析检测视频图像中的目标差异,用以定位和跟踪目标。研究表明马尔科夫网可以很好地揭示数据间的抽象近邻关系,并且这种网络自身就具有表达知识的意义。

4.1 多光谱遥感图像组合效果的马尔科夫网的图论解释与应用

将 TM Landsat-7 Fast-L7A EROS 西安地区两个不同面积范围的 6 波段灰度图像的灰度值看成 6 个波段对不同地物的随机采样,用多种距离来统计各波段间的差异性(相似性),用 6 个顶点($a_1, a_2, a_3, a_4, a_5, a_6$)分别表示 6 个波段图像,用 Floyd-Warshall 算法生成基于最短距离(最小描述长度 MDL)搜索的马尔科夫网如图 2(a)、(b)。

为对比不同时空采样数据,同时对新疆两个地区如图 2(c)、(d)和西安地区不同时期不同面积不同波段数如图 2(a)、(b)、(e)的 TM 图像进行了相应的马尔科夫网生成实验,相应实验资料情况如表 1 所示。为对比不同迹度量的网络结构效果,还使用其它迹度量作了对比实验。

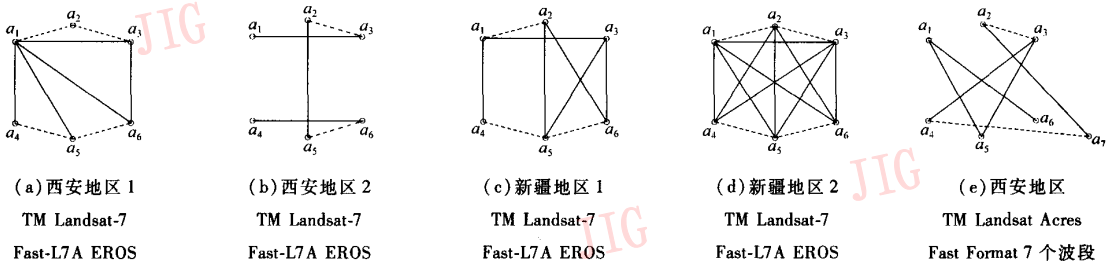


图 2 TM 遥感图像不同地区和时间各波段间的(明氏度量)DMN

Fig. 2 DMN constructed by Minkowski metric between bands of TM remote sensing data with different district and period

表 1 实验区面积和资料来源

Tab. 1 Experiment region area and data type

地区	面积(像素数)	资料来源
西安地区 1	225 × 241	TM Landsat-7 Fast-L7A EROS
西安地区 2	455 × 383	TM Landsat-7 Fast-L7A EROS
新疆地区 1	1 682 × 2 022	TM Landsat-7 Fast-L7A EROS
新疆地区 2	1 326 × 1 507	TM Landsat-7 Fast-L7A EROS
西安地区	225 × 194	TM Landsat Acres Fast Format

4.1.1 基于明氏距离 DMN 的生成和图论解释

明氏(Minkowski)距离的数学公式为

$$d_{ij}^{(p)} = \left(\sum_{i=1}^s |x_{ii} - x_{ij}|^p \right)^{1/p} \quad (1)$$

从上式可以看出,明氏距离对变量中的个体差异性既有保留又有突出(例如,大量的短距离或少量的大距离都不会被偏置),特别是 $p = 2$ 时(即欧氏距离)此特征更加明显,这些特征有利于揭示多波段遥感图像间的宏观差异性。

从图 2 的实验结果可以得出以下结论:

(1) 从数据压缩(波段压缩)的角度分析。图 2(a)中,从 a_2 到 a_4 ;从 a_3 到 a_4 ; a_6 到 a_4 ;均是包含波段数最多的路径。如果用 RGB 3 个原色组成图像,较好的选择就是 a_4, a_3, a_2 和 a_4, a_3, a_6 3 个波段,它们是对 6 个波段的最佳特征表达。这完全符合对 TM 图像波段组合的经验选择。特别是遥感影像处理系

统 ERDAS 将 a_4 、 a_3 、 a_2 波段组合设置为默认组合。验证实验图 2(c)、(d)、(e) 均包含 a_4 、 a_3 、 a_2 是较好组合的结论,只是在其他波段的组合效果上有小的变动,这正好反映了不同地区(包含的不同图像内容)遥感图像各自的特征,也说明了所选择的迹度量恰好揭示了不同地区和时期遥感图像在波段组合上的统计个性特征,正是这些特征使得多波段遥感图像可以在分析不同地面被覆中使用不同波段组合。

另一方面,图 2 中网络的连接强度有很大的区别,这反映了各自地区(地区不同或地区相同面积不同)的地面被覆类型对相应波段的响应强度,如果响应强度是相似的(即各波段对该地区地物的区分能力不大——不同波段图像是相似的),那么,所

有波段图像的组合都是相似的,对应的网络将是完全图(即每两点之间均有连接),如图 3(d)。图 2(d)几乎是完全图(除 a_4 、 a_6 未连接),究其原因发现新疆地区 2 的地物对各波段响应强度相似(对灰度图像显示的观察结论),这使得马尔科夫网趋于全连接,对于该地区只要包含 a_4 、 a_6 波段外加任何另一个波段的 3 波段 RGB 图像都有相似融合结果,如图 4 中 A_2 、 A_3 、 A_4 所示。网络连通性越强(路径越多或结构越复杂),图像组合的可能性就越多,对于波段压缩就越不利,选择迹度量的准则就是要最大可能地区分波段间的差异性,这种差异性越大,网络连通性越弱(路径越少或结构越简单),对于波段压缩就越有利。

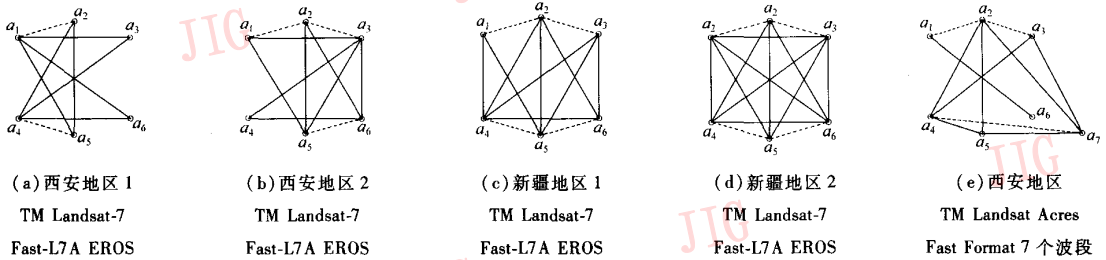


图 3 加入灰度随机性的 TM 遥感图像不同地区和时间各波段间的(明氏度量)DMN
 Fig.3 DMN constructed by Minkowski metric and attending to random of gray scale between bands of TM remote sensing data with different district and period




图 4 新疆地区 1 的融合结果
 Fig.4 Image fusion result of Xinjiang district 1

如果将每幅单波段图像中每个像素的灰度随机性用概率来表示,并且加入迹度量中(明氏距离),那么,对于那些具有较大个性差异的像素,因为出现的概率较低,其距离的个性差异就会被减弱,这样必然削弱各波段图像的个性特征(即使得各波段间的差异性减小),如图 3 所示,相应地区和时期多波段遥感图像的网络结构必然趋于复杂,使得波段组合的混淆性大大增加,对实际工作是不利的。图 3(d)已成为完全连接图,对于波段组合问题它就毫无意

义,即各种组合都是一样的。
 (2)从马尔科夫网的性质来分析。图 2(a)中, a_4 与 a_2 、 a_3 、 a_6 分别是独立的; a_5 与 a_2 、 a_3 以及 a_6 与 a_2 等也均分别是独立的。其中, a_4 分别与 a_3 、 a_2 的独立性最强,根据信息论,独立性越强,则所包含的信息量就越大,所以,如果用 RGB 3 个原色组成图像,唯一的选择就是 a_4 、 a_3 、 a_2 3 个波段,它们是 6 个波段中信息含量最大的组合。其余的网络均能得出类似的结论。

4.1.2 基于其他相似距离 DMN 的生成和图论解释

为了对不同统计距离度量在 DMN 生成中的图论性质进行比较,对明氏 1 阶、3 阶、4 阶统计距离进行了实验,结果均不如明氏 2 阶距离(欧氏距离)生成的网络简洁(图略)。

对马氏(Mahalanobis)距离进行实验。马氏距离为

$$d_{ij}^{(m)} = (x_i - x_j)^T V^{-1} (x_i - x_j) \quad (2)$$

式中, V 是抽样协方差,它将波段间的距离差异看作随机变量,在距离中引入 V 的结果将削弱了波段间

的差异,这对研究波段间关系的目的是不利的。

对马氏距离的网络生成实验如图 5 所示。从图 5(a)、(b)与图 2(a)、(b)的网络结构对比及图 5(c)、(d)与图 2(a)、(b)的网络结构对比中可看出,马氏度量总体上不如明考夫斯基度量,这与两种度量的数学原理有关。马氏距离考虑了波段间的灰度差异性因子,这样就会对波段间的差异性进行了削弱,也就是削弱了波段间的差异,因而,波段间的关系用马氏距离是不利的。同样道理马氏概率加权距离也有使网络趋于复杂的特征。

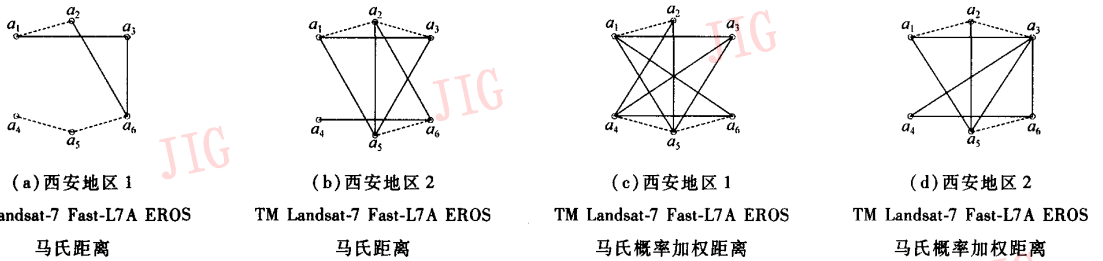



图 5 不加入与加入灰度随机性的 TM 遥感图像在西安地区 1、2 各波段间的(马氏度量)DMN

Fig. 5 DMN constructed by Mahalanobis metric and attending to random of gray scale or no between bands of TM remote sensing data in Xi'an district 1&2

测试协方差距离(correlation)(只用了西安地区 1 进行测试),其公式为

$$d_{x_{ij}} = 1 - \frac{(x_i - \bar{x}_i)(x_j - \bar{x}_j)^T}{[(x_i - \bar{x}_i)(x_i - \bar{x}_i)^T]^{1/2} [(x_j - \bar{x}_j)(x_j - \bar{x}_j)^T]^{1/2}} \quad (3)$$

式中, $\bar{x}_i = \frac{1}{n} \sum_{l=1}^k x_{il}$, $\bar{x}_j = \frac{1}{n} \sum_{l=1}^k x_{jl}$ 。其结果与马氏距离一样,如图 6 所示。在数学上,协方差距离与马氏距离本质上是一致的,因而这种结果也是必然的。



西安地区 1 TM Landsat-7 Fast-L7A EROS correlation 距离

图 6 不加入灰度随机性的 TM 遥感图像在西安地区 1 各波段间协方差距离度量的 DMN

Fig. 6 DMN constructed by correlation metric and no attending to random of gray scale between bands of TM remote sensing data in Xi'an district 1

最后,测试图像熵度量的 DMN,如图 7 所示。对比图 7(a)与图 2(a)可见,不加入图像灰度场随机性的图像熵度量的 DMN 结构不如明考夫斯基距离度量;而加入图像灰度随机性后再对比图 7(b)与图 2(a)可看出,其结论与明考夫斯基距离度量一致。分析原因可知,像素熵就是图像灰度场的像素灰度概率的对数与其自身乘积和取负,再将每个像素的熵加和就是波段图像




图 7 加入与不加入灰度随机性的 TM 遥感图像在西安地区 1 各波段间熵差距离度量的 DMN

Fig. 7 DMN constructed by cross entropy metric and attending to random of gray scale or no between bands of TM remote sensing data in Xi'an district 1

的平均熵 ($\bar{H}_i = -\sum_{i=1}^k p_i \log p_i$; 式中 k 是像素总数), 这样, 也会削弱图像波段间的差异, 所以, 图 7(a) 的结果不佳。如果将图像平均熵按各个像素的灰度概率加权作为其度量结果就是图 7(b), 与图 2(a) 有异曲同工之效。但是, 从图 7(b), 以及更多实验可发现, 图像灰度场概率加权熵度量生成的 DMN 结构较为复杂, 这也与熵度量的特点有关。

综上所述可知, 明氏距离度量是最好的多波段遥感图像波段组合 DMN 的选度量, 而且计算最简单, 效率最高, 对于遥感图像大数据量的特点, 更具有实用性。

因为图 2(d) 是可选组合较少的网络, 最后以它为例, 验证图像融合效果。从图 2(d) 中可以看出 $a_4/a_6/a_1$ 、 $a_4/a_6/a_2$ 、 $a_4/a_6/a_3$ 和 $a_4/a_6/a_5$ 是最好组合, 并且其组合效果是等价的, 图 4 的实验结果 A_2 、 A_3 和 A_4 (为节省篇幅 $a_4/a_6/a_5$ 没有列出) 验证了这一结论, 并且它们的效果均好于常规组合 $a_4/a_3/a_2$, 实验结果如图 4(a) A_1 (由 ERDAS 系统对 TM 图像的常规 $a_4/a_3/a_2$ 组合) 的组合效应明显不如 A_2 、 A_3 和 A_4 , 也验证了这一结论。

4.2 视频图像检测的马尔科夫网图论解释与应用

视频图像是交警部门拍摄的车辆违章视频录像。将其进行 1/6 帧抽样存储为多维矩阵用于实验。目的是发现视频图像中包含违章车辆的第 1 帧图像, 然后对该帧图像中违章车辆进行定位、跟踪。

首先定义“违章”的含义为在车辆接近十字路口人行斑马线一侧 30 ~ 200m 内, 车辆不得穿越道路中心交通隔离实线, 变道行驶。其次, 根据定义提取无车辆行驶时交通十字路口的典型图像生成交通模式图像 (对违章含义的图像描述), 方法是用 Canny 算子^[40]提取并细化边缘, 再交互式选择交通模式描述因子, 最后获得交通模式图像。

将视频图像依次与交通模式图像进行逻辑运算生成序列交通模式图像 (以下简称序列图像)。

使用明考夫斯基 (Minkowski) 2 阶距离 (即欧氏距离) 来生成序列图像间的马尔科夫网。

实验中, 用数字 (1, 2, 3, ...) 分别表示序列图像的帧序号; 用 Floyd-Warshall 算法生成基于最短距离 (最小描述长度 MDL) 搜索的马尔科夫网^[35]。为对比不同粒度所生成马尔科夫网对问题的描述能力, 分别使用 6, 5, 4, 3 个变量作为马尔科夫网的粒度, 所生成的网络如图 8 ~ 图 11。




图 8 6 个节点马尔科夫网
Fig. 8 DMN with 6 nodes




图 9 5 个节点马尔科夫网
Fig. 9 DMN with 5 nodes




图 10 4 个节点马尔科夫网
Fig. 10 DMN with 4 nodes




图 11 3 个节点马尔科夫网
Fig. 11 DMN with 3 nodes

4.2.1 不同粒度视频图像 DMN 的生成和图论解释

当马尔科夫网粒度为 6 帧序列图像时, 每次从序列图像中取相邻连续的 6 帧图像, 依次滑动循环生成 6 个节点的马尔科夫网, 图 8 只显示了非完全图的 3 个网络。图 8(a) 中第 13 帧与第 17 帧间断开没有直接通路, 表明这两帧图像间在该粒度下是全域差异性较大的图像, 即序列图像中一定有异常灰度出现。实际上, 图 12 表明了有、无车辆违章时的序列图像直方图在车辆越线前、后的异常灰度分布。




图 12 有,无违章车辆的典型直方图

Fig. 12 Type histogram of vehicle in (or without) breach of traffic rules

当选定马尔科夫网的粒度后,马尔科夫网只能揭示粒度内变量间的序列图像差异性,所以当粒度区间不包含差异性突变的图像时,马尔科夫网为完全图^[35](图 8 没有显示完全图),从图 8 可见包含突变的(6 帧)粒度区间有 3 个:[12 17]、[13 18]、[14 19]。其中,差异性突变帧序号对(独立节点对)如表 2 所示。

表 2 不同粒度的马尔科夫网及其独立节点对

Tab.2 DMN with its independent pairs of nodes in several graininess

粒度(帧)	粒度区间	独立节点对
6	[12 17]	13-17
	[13 18]	13-18, 14-18, 15-18, 16-18
	[14 19]	14-19, 15-19, 16-19, 17-19, 15-18, 16-18
5	[7 11]	7-9
	[13 17]	13-17, 15-17
	[14 18]	14-18, 15-18, 16-18
	[15 19]	15-19, 16-19, 17-19, 15-18, 16-18
4	[7 10]	7-9
	[14 17]	15-17
	[15 18]	15-18, 16-18, 15-17
	[16 19]	16-19, 17-19, 16-18
3	[7 9]	7-9
	[8 10]	8-10
	[16 18]	16-18
	[17 19]	17-19

表中同一种粒度不同网络间所发现的相互重复的独立节点对用斜体字表示

当马尔科夫网粒度为 5 帧序列图像时,每次从序列图像中取相邻连续的 5 帧图像,依次滑动循环生成 5 个节点的马尔科夫网,图 9 只显示了非完全图的 4 个网络。

从图 9 可见包含突变的(5 帧)粒度区间有 4 个:[7 11]、[13 17]、[14 18]、[15 19]。其中差异性突变帧序号对如表 2 所示。在(5 帧)粒度区间的马尔科夫网中差异性突变帧序号对(独立节点对)

除了包含(6 帧)粒度区间的差异性突变帧序号对(独立节点对)之外,还多了 7 和 9 等节点对。

当将粒度区间减小为 4 帧和 3 帧时,所生成的网络(如图 10、11 所示)和差异性突变帧序号对(独立节点对)如表 2 所示。

从表 2 可以看出粒度 6 到 4 的网络中均有重复的独立节点对,并且不同粒度网络间的独立节点对也相互重复,粗粒度的独立节点对包含细粒度独立节点对,但是粗粒度可能会丢掉一些独立节点对(完全符合一般“粒度”的概念),例如 6 帧粒度丢掉了 7-9 节点对;5 帧和 4 帧粒度都丢掉了 8-10 节点对。

发现独立节点对的目的是为了发现序列图像异常的第 1 帧,根据它来捕捉违章信息。从表 2 可以看出,3 帧粒度所形成的网络可以发现其他粒度所不能发现的独立节点对也能发现其他粒度发现了的独立节点对,并且大大减小了其他粒度网络带来的冗余,实质上发生异常的节点为:7, 8, 9, 10 和 16, 17, 18, 19。对序列图像的直方图分析发现 7, 8, 9, 10 和 16, 17, 18, 19 分别对应车辆即将违章及违章过程即将结束时的图像。在车辆违章过程中和违章之前与之后马尔科夫网都是完全连接图,因为此时各节点间的距离都很接近(很相似——差异性较小),不可能有两个以上边长之和小于该两点直接相连的距离^[35]。当马尔科夫网络粒度较大时(如 6 帧粒度),可以发现独立节点对 13-17、13-18、14-18 等等,它是违章高峰与违章结束后的图像帧间的关系,这种关系模糊性太大(区间跨度太大),不利于节点关系判断以及实时计算,生成的网络结构较复杂不利于网络结构判断,相对计算量较大,这些缺点表明,粒度较小为好。

综合上述分析,以及文献[35]提出的网络流分析的“三角不等式”原理,可以认为 3 帧粒度(马尔科夫网的最小粒度),即从序列图像中每次采样相邻三幅图像生成马尔科夫网是最佳网络粒度。

4.2.2 视频图像检测结果

根据上面的分析,对视频图像中包含违章车辆第一帧的检测问题就转化为判断 3 节点马尔科夫网是否为完全图的问题,而对 3 节点无向图的全连接判断只需简单计算各节点的度数是否为 2^[41],并且出现非全连接图的度数为 1 的节点中序号大者(小者)是包含车辆即将违章(包含车辆违章即将结束)的第 1 帧,如图 11(a)、(b)中 7、8、9、10 都是节

点度数为 1 的帧序号,那么第 10 帧就是包含车辆即将违章的图像,如图 13(a)(箭头所指),如图 11(c)、(d)中 16、17、18、19 都是节点度数为 1 的帧序号,那么第 16 帧就是包含车辆违章即将结束的图像,如图 13(b)(箭头所指)。这样,就将包含违章车辆的序列图像区间 [10 16] 从整个序列图像 [1 19] 中检测出来了。



(a) 第 10 帧 (b) 第 16 帧

图 13 车辆违章前、后的图像

Fig. 13 Images of vehicle a brush with breach of traffic rules, and or end

实际上,只需要确定包含违章车辆的第 1 帧图像(第 10 帧)即可对该车辆定位并跟踪,如图 14 所示,在第 10 帧和第 16 帧之间的图像是包含车辆违章过程的各帧图像,是用灰度梯度下降法和直方图一阶导数法分别定位和跟踪的结果^[42]。



10 11 12 13 14 15 16

图 14 动态窗口跟踪(图中编号为图像序列号)

Fig. 14 Images of dynamic detection(digits down image is number of video images)

5 结 论

本文研究了在人工智能界刚刚兴起的马尔科夫网的概念、方法,并对其在图像处理中应具有的形式进行了广义的描述(或定义),分析它在空间数据挖掘中的作用与意义,特别是在图像分析中的应用问题——实质是如何建立度量模型和网络模型。并实验以多种度量方式建立多波段遥感图像的波段间马尔科夫图,以及以多种粒度方式建立序列图像的帧间马尔科夫网,研究表明马尔科夫网可以很好地揭示图像数据间的抽象相邻关系,并且这种网络自身就具有表达知识的意义,更重要的是可为进一步图像分析处理提供依据。

多光谱遥感数据的各波段间的关系以及序列图像的各帧间的关系对于序列图像的知识挖掘非常重要。多光谱遥感数据的多波段图像或视频对序列图像的模式识别和特征提取都需要基于各波段图像或视频各帧图像间的统计差异性(相似性)来进行^[43]。因此,多光谱遥感图像和序列图像的马尔科夫网络的生成对进一步处理是关键问题。本文以此为例,验证了马尔科夫网在多光谱遥感图像和视频序列图像处理中的理论和实用价值。

参考文献 (References)

- Narendra A. Mosaic models for textures [A]. In: Image Modeling [M], New York: Academic Press, 1980: 1~7.
- Laveen N Kanal. Markov mesh models [A]. In: Image Modeling [M]. New York: Academic Press, 1980: 240~243.
- Modestino J W, Fries R W, Vickers A L. Stochastic image models generated random tessellations of the plane [A]. In: Image Modeling [M], New York: Academic, 1980: 302~325.
- Woods John. Two-dimensional discrete Markov fields [J]. IEEE Transactions on Information Theory, 1972, 18(2): 232~240.
- Stuller J A, Kurz B. Two-dimensional Markovian representations of sampled images [J]. IEEE Transactions on Commun, 1976, 24:1148~1152.
- Kashyap R L, Chellappa R. Estimation and choice of neighbors in spatial-interaction models of images [J]. IEEE Transactions on Information Theory, 1983, 29(1): 60~72.
- Patrick A Kelly, Haluk Derin, Keith D Hartt. Adaptive segmentation of speckled images using a hierarchical random field model [J]. IEEE Transactions on ASSP, 1988, 36(10):1628~1641.
- Florence Tupin, Henri Maitre, Jean-Francois Mangin, et al. Detection of linear features in SAR images: application to road network extraction [J]. IEEE Transactions on Geoscience and Remote Sensing, 1998, 36(2): 434~453.
- Florence Tupin, Isabelle Bloch, Henri Maitre. A first step toward automatic interpretation of SAR images using evidential fusion of several structure detectors [J]. IEEE Transactions on Geoscience Remote Sensing, 1999, 37(3): 1327~1343.
- Florence Tupin. Markovian Methods for SAR Image Processing [EB/OL]. <http://ieeexplore.ieee.org>, 2003-11-2.
- Geman S, Geman D. Stochastic relaxation Gibbs distribution, and the Bayesian restoration of images [J]. IEEE Transactions on Pattern Analysis Machine Intelligent, 1984, 6(6): 721~741.
- Modestino James W, Zhang Jun. A markov random field model-based approach to image interpretation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligent, 1992, 14(6):606~615.
- YANG Xiang, Wong S K M, Cercone N. A 'Microscopic' study of minimum entropy search in learning decomposable markov networks [A]. In: Machine Learning [M], Netherlands: Kluwer Academic Publishers, 1997:2665~2692.

- 14 HAN Jia-wei, Micheline Kamber. Data Mining Concepts and Techniques[M]. Beijing: China Machine Press, 2001.
- 15 David Heckerman. Bayesian network for data mining [J]. Data Mining and Knowledge Discovery, 1997, (1): 79 ~ 119.
- 16 Meera Balakrishnan, Andrew Reibman. Characterizing a Lumping Heuristic for a Markov Network Reliability Model[EB/OL]. <http://ieeexplore.ieee.org>, 2003-11-2.
- 17 YANG Xiang, Lee J. Local Score Computation in Learning Belief Networks [EB/OL]. <http://www.cis.uoguelph.ca/~yxiang/>, 2004-10-8.
- 18 PAN He-ping. Learning Bayesian Networks II-A Computation Algorithm[EB/OL]. <http://ieeexplore.ieee.org>, 2003-11-2.
- 19 PAN He-ping. Learning Bayesian Networks I-A Theory Based On MAP-MDL Criteria[EB/OL]. <http://ieeexplore.ieee.org>, 2003-11-2.
- 20 Columbic M C. Algorithmic Graph Theory and Perfect Graphs[M]. New York: Academic Press, 1980.
- 21 ZHENG Zhao-bao. Random Field Method for image analyses[M]. Wuhan: Publishing House of Wuhan University, 2000. [郑肇保. 图像分析的马尔科夫随机场方法[M]. 武汉: 武汉测绘科技大学出版社, 2000.]
- 22 FENG Jian-hu, CHE Gang-ming, NIE Yu-feng. Principle and Analyses of Numerical Value [M]. Beijing: Publishing House of Science. [封建湖, 车刚明, 聂玉峰著. 数值分析与原理[M]. 北京: 科学出版社, 2001.]
- 23 Pearl J. Probabilistic reasoning in intelligent systems [A]. In: Proceedings of Networks of Plausible Inference [C], Seattle, Washington: Morgan Kaufmann, 1988.
- 24 YANG Xiang, Hu J, Cercone N, et al. Learning Pseudo-Independent Models: Analytical and Experimental Results [EB/OL]. <http://www.cis.uoguelph.ca/~yxiang/>, 2004-10-8.
- 25 Bouckaert R R. Properties of Bayesian belief network learning algorithms [A]. In: Proceedings of Uncertainty in Artificial Intelligence [C], Seattle, Washington: Morgan Kaufmann. 1994: 102 ~ 109.
- 26 Buntine W. Classifiers: a theoretical and empirical study [A]. In: Proceedings of 1991 International Joint Conference on Artificial Intelligence [C], Sydney, 1991: 638 ~ 644.
- 27 Cooper J F, Herskovits E. A Bayesian method for the induction of probabilistic networks from data [J]. Machine Learning, 1992, 9(4): 309 ~ 347.
- 28 Heckerman D. Learning Bayesian networks: the combination of knowledge and statistical data [J]. Machine Learning, 1995, 20(3): 197 ~ 243.
- 29 Herskovits E H, Cooper G F. Kutato: an entropy-driven system for construction of probabilistic expert systems from database [A]. In: Proceedings of 6th Conference on Uncertainty in Artificial Intelligence [C], Cambridge, 1990: 54 ~ 62.
- 30 Lam W, Bacchus F. Learning Bayesian networks: an approach based on the MDL principle [J]. Computational Intelligence, 1994, 10(3): 269 ~ 293.
- 31 Madigan D, Raftery A E. Model selection and accounting for model uncertainty in graphical models using Occam's window [J]. Journal of American Statistical Association, 1994, 89(428): 1535 ~ 1546.
- 32 Wong S K M, Xiang Y. Construction of a Markov network from data for probabilistic inference [A]. In: Proceedings of 3rd International Workshop on Rough Sets and Soft Computing [C], San Jose, 1994: 562 ~ 569.
- 33 Cheeseman P. Overview of model selection [A]. In: Proceedings of 4th International Workshop on Artificial Intelligence and Statistics [C], 1993: 231 ~ 254.
- 34 Sclove S L. Small-sample and large-sample statistical model selection criteria [A]. In: Proceedings of Selecting Models from Data [C], 1994: 31 ~ 39.
- 35 Peng Mu-geng. Realization and Technology of Data Warehouse [M]. Beijing: Publishing House of Electronic Industry, 2002. [彭木根. 数据仓库技术与实现 [M]. 北京: 电子工业出版社, 2002.]
- 36 Inmon W H. Building the Data Warehouse [M]. Wang Zhi-hai interpreting, Beijing: China Machine Press, 2000. [Inmon W H 著. 数据仓库 [M]. 王志海译, 北京: 机械工业出版社, 2000.]
- 37 Di Kai-chang. Spatial Data Mining and Knowledge Discovery [M]. Wuhan: Publishing House of Wuhan University, 2000. [邸凯昌. 空间数据挖掘与知识发现 [M]. 武汉: 武汉大学出版社, 2000.]
- 38 Xie Jin-xing, Xing Weng-xun. Optimization of Networks [M]. Beijing: Publishing House of Tsinghua University, 2000. [谢金星, 邢文训著. 网络优化 [M]. 清华大学出版社, 2000.]
- 39 Wang Ling. Algorithm & Application of Intelligence and Optimization [M]. Beijing: Publishing House of Qinghua University, 2001. [王凌著. 智能优化算法及其应用 [M]. 清华大学出版社, 2001.]
- 40 Canny J. A Computational Approach to Edge Detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1986, 8(6): 679 ~ 698.
- 41 Xu Jin. Self-complementary Graph Theory with Application [M]. Xian: Publishing House of Xi'an University of Electronic Science and Technology, 1999. [许进. 自补图理论及其应用 [M]. 西安: 西安电子科技大学出版社, 1999.]
- 42 CAO Jian-nong. Study on automatic detection for vehicle in breach of traffic rule [J]. Journal of Chang'an University (Nature Science Edition), 2005, 25(1): 64 ~ 68. [曹建农. 违章车辆自动检测方法研究 [J]. 长安大学学报 (自然科学版), 2005, 25(1): 64 ~ 68.]
- 43 YANG Cun-jian, ZHOU Cheng-hu. On automatic detection residence zone in TM image based-on knowledge discovery [J]. Technology and Application of Remote Sensing, 2001, 16(1): 1 ~ 5. [杨存建, 周成虎. 基于知识发现的 TM 图像居民地自动提取研究 [J]. 遥感技术与应用, 2001, 16(1): 1 ~ 5.]