

文章编号: 1007-4619(2005)05-0596-08

# 基于 DMN 的高光谱图像分割方法研究

曹建农<sup>1,2</sup>, 关泽群<sup>1</sup>, 李德仁<sup>3</sup>

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

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:** 简述高光谱遥感光谱特征体系(包括光谱曲线特征、光谱变换特征和光谱度量特征 3 个层面)。研究马尔科夫网的概念和方法, 生成基于光谱角(SA)特征度量的 DMN, 并以 DMN 为证据对高光谱图像进行分割; 研究和实验表明基于 SA 信息的马尔科夫网可以很好地综合高光谱数据空间特征与光谱特征间的关系, 为进一步数据处理提供优化控制(其实质是概率神经网络)。最后提出未来应用和研究方向。

**关键词:** 马尔科夫网(DMN); 高光谱遥感; SA(光谱角); 最大后验概率; 空间数据挖掘

**中图分类号:** TP751/P231.5 **文献标识码:** A

## 1 引 言

高光谱(Hyper-spectral)遥感图像光谱特征的提取和利用是制约高光谱图像应用的瓶颈<sup>[1]</sup>。地物对象的空间特征和光谱特征分散在几十到上百个波段(图像)之中, 其中包括对地物相似性特征的描述数据(例如, 光谱角)。高光谱信息的充分性和冗余性是共存的, 必须在图像处理之前通过降维来提取主要信息以减少波段(图像)的数量, 实现高光谱图像数据的特征提取和信息压缩<sup>[2]</sup>。文献[1]提出的高光谱遥感数据光谱特征的三层体系较全面的概括了光谱特征的主要方面, 但是它没有涉及这些特征表示问题以及高光谱遥感数据的空间特征与光谱特征的联合与应用方法等研究。本文利用像元的光谱角(SA)相似性特征的空间分布, 基于马尔科夫网(Decomposable Markov Network, DMN)理论与方法, 对这种空间分布的统计概率生成 DMN, 以此网络为证据(实质就是概率神经网络)对高光谱图像进行分割。该方法综合了高光谱图像的光谱特征(63 个波段的光谱特征)和各相似像素的空间位置分布特征(像素在水平和垂直方向的分布)以及光谱角值

的统计特征(光谱角值的统计分布)。

图像分割的研究历史比较长<sup>[3-5]</sup>, 但是利用高光谱特征进行图像分割的研究不多见, 特别是利用 DMN 方法将光谱角余弦(SAC)值的空间特征分布与 SAC 值的统计特征的联合处理应该是一种全新的尝试, 实验表明该方法是有效的。

可分解 DMN 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<sup>[6-8]</sup>。所谓概率网络(PN)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<sup>[9]</sup>。可分解 DMN 是概率网络的一种, 一般简称为马尔科夫网。

马尔科夫网的定义参见文献[9-11], 马尔科夫网是对数据集的概率分布的图结构生成和度量投影, 事实上, 像任何其它函数一样, 概率分布能被多种不同处理近似表示<sup>[12]</sup>。

目前, 对图像数据“智能化”地处理大都带有“图论的网络”色彩。简单说, 马尔科夫网是揭示数据集内在(概率)联系的图论表达。其实质是生成一种网络图结构和相应的连接权参数(神经网络的

收稿日期: 2004-04-05; 修订日期: 2004-07-13

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

作者简介: 曹建农(1963—), 男, 副教授, 毕业于原武汉测绘科技大学航测系, 航空摄影测量与遥感专业, 获得工学学士学位; 毕业于西北大学城市资源系地图制图与遥感专业, 获得理学硕士学位; 现为武汉大学遥感信息工程学院博士研究生。主要研究方向为遥感图像分析、空间数据挖掘。已发表论文近 12 篇。E-mail: caojiannong@163.com。

一种),将其固定后用于图像分割。

马尔科夫网的概念对图像处理具有重要意义。但是,文献 [9] 等对 DMN 的严格定义并不完全适用于图像分析处理和图像模式识别问题<sup>[13]</sup>。我们的目的是为图像分割提供证据,所以,我们认为(或定义)DMN 为:一个具有概率相邻关系的变量分布的图结构和相应的迹度量参数矩阵,形式上依然表示为  $(G, P)$ ,此处的  $G$  与文献 [9] 相同,而  $P$  与文献 [9] 既有区别又有联系。从模式识别的角度看,马尔科夫网主要用于识别过程中证据的获取,特别是获取某种属性的统计近邻关系。

本文研究方法:(1)用 SAC 值获得高光谱遥感影像数据空间近邻位置元素的相似性度量;(2)对相似性度量的 SAC 值进行概率统计,获得空间近邻位置元素 SAC 值的统计量  $p_i$ ;(3)以  $p_i$  为节点生成 DMN,其边表示  $p_i$  之间的概率联系,即获得空间相似性统计量  $p_i$  的抽象近邻关系;(4)以 DMN 为依据(神经网络)进行图像分割。

## 2 光谱相似性度量 (SA)

高光谱遥感影像通常用一个空间-光谱数据立方体 (spatial-spectral data cube) 表达<sup>[1, 14]</sup>。立方体的每一层(图像)为一个波段,每一像元(的空间位置)对应的各波段属性值都构成一个光谱向量,如图 1(a)为原始图像(4、3、2 波段组合),图 1(a)上标出了不同空间像素位置的抽样符号,图 2 是相应于图 1 上不同符号所对应的光谱向量构成的光谱曲线,通过对不同光谱向量(曲线)的分析,可以获得对分割、信息提取等有用的特征。

文献 [1] 提出的光谱特征体系包括光谱曲线特征、光谱变换特征和光谱相似性度量特征 3 个方面,分别对应于全部波段的像元光谱曲线(向量)分析、部分波段的数据变换与组合、光谱相似性度量 3 种应用模式。

光谱相似性度量的主要方法包括光谱角 SA (spectral angle)、光谱信息散度 SID (spectral information divergence),此外,还有一些常见的相似性指标如相关系数、高维空间距离等。

为对高光谱遥感图像进行有效分割以及文献 [1, 14] 的分析结论,本文选择采用光谱角度量作为高光谱数据的光谱相似性度量方式。

光谱角是指在光谱空间上光谱向量所形成的夹角,其算式如下:




图 1 原始图像及采样位置符号

Fig 1 The original image and sampling location marks




图 2 采样位置与其对应的光谱特征曲线

Fig 2 The spectral feature curves relevant to sampling location marks

$$\cos \alpha = \frac{A \cdot B}{|A| |B|} = \frac{\sum_{i=1}^N A_i B_i}{\sqrt{\sum_{i=1}^N A_i^2} \sqrt{\sum_{i=1}^N B_i^2}} \quad (1)$$

式中,  $N$  为波段数,  $A = (A_1, A_2, \dots, A_N)$  和  $B = (B_1, B_2, \dots, B_N)$  分别表示两个光谱向量,其元素  $A_i, B_i$  表示像元在第  $i$  个波段上的反射率,  $\alpha$  为光谱角。在具体的计算中并不要求出实际角度,采用光谱角余弦作为判据即可,同类像元光谱角余弦较大,接近于 1,而不同类像元的光谱角余弦则较小。

光谱角在衡量像元光谱相似性方面具有明显的优越性,光谱角制图模型 SAM (spectral angle

mapping)的高光谱遥感信息分类、聚类等都得到了非常广泛的应用<sup>[1]</sup>。

### 3 DMN 生成原理

#### 3.1 迹度量 (score metric)

迹度量 (score metric)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 (score metric)是贝叶斯度量、描述长度度量 (description length metrics)、熵度量 (entropy)<sup>[15-17]</sup>等。

本文在对上述文献充分理解的基础上,结合高光谱遥感图像分割的实际情况,选择 SAC 值的最大后验联合概率作为搜索网络的迹度量。

复杂图像的分割方法包括:自动多门限分割技术、循环分解法、分块分割再合并方法等<sup>[3]</sup>,这些方法都具有过程比较繁琐的缺点,特别是对直方图的全程依赖使其自动化实现受到一定限制,对峰、谷不明显的图像这是极大的障碍;当光影对图像产生影响时,一般图像分割几乎很难处理;而高光谱图像则可以用光谱向量的统计方式消除光影等随机影响,本文所用的光谱角余弦就具有这样的作用。另外,对近邻像素位置的光谱角余弦值的统计直方图一般不具有明显的峰、谷特征(光谱角余弦矩阵空间相当稀疏,见本节下文),以往的方法不好使用。图像分割的实质是在全局或局部中保留概率相对较大的像素而合并概率相对较小的像素(这种概率应该记录了局部近邻特征),无论哪种方法(自动多门限分割技术、循环分解法、分块分割再合并方法<sup>[3]</sup>)其实都是如此,我们的思想是以一种较为“鲁棒”的方法来代替过于琐碎或精巧的各种处理过程和步骤。

DMN 就具有这样的“鲁棒性”。

所谓网络,是由“树”与“链”共同构成,因为单独的“树”或“链”一般不称作“网”。DMN 就是包含了“树”与“链”所构成的网络。根据理论和实验<sup>[18]</sup>,最小机制(例如 Floyd-Warshall 算法)所生成的网络中,较大边权值的节点间总会断开,并且总是与具有全局最小边权值的节点相连,这样必然形成多个节点与一个节点相连的“树”结构;相反,较小边权值的节点间会依次相连,形成“链”结构。这样,树结构的树根点就具有综合树叶的能力;而链结构的各个节点间就具有相对于间隔点两两独立的关系;可见 DMN 既具有节点综合的能力,又具有节点独立的能力,这正是它的模型特点和鲁棒性所在。

本文利用 DMN 对高光谱图像进行分割,其数

学模型描述如下:

从图像左上角向图像右下角滑动计算 SAC 值。计算每一个中心像元 (i, j) 与其相邻的垂直(下方)和水平(右方)空间位置处像元的 SAC,并将 SAC 值分别记录于该计算单元的中心像元的垂直(下方) (i+1, j)、水平(右方) (i, j+1) 位置处,由此生成光谱角余弦矩阵 (SACM)。SACM 由图像中 (i+1, j) 和 (i, j+1) 位置处的光谱角值共同构成。计算单元形式如图 1(b)。

光谱角余弦矩阵 (SACM) 记录了综合 63 个波段的空间近邻正交位置的像素之间的光谱相似性, SACM 空间相当稀疏,所有值都集中于角端(接近于 1 的一端),表明 SAC 值揭示了像元近邻相似性。

将 SACM 中的数值分为若干个数据级,每一级数值都对应于像元之间的一种相似性程度,对 SACM 中的每一级 SAC 值进行概率统计计算,每一级 SAC 值的概率对应于 DMN 的一个节点;计算各级 SAC 值之间的转移概率(共生概率),每个转移概率对应于马尔科夫网的一条边。

网络的最大后验联合概率度量原理:

设相邻两节点 (i, j) 之间的转移概率为:  $P_{e_i, j}$ ,  $P_{e_i, j} = P_i \cdot P_j$ 。其中,  $P_i$  和  $P_j$  分别是 DMN 的任意两个节点 i 和 j 的概率值。任意两点 (s, t) 间的联合后验概率路径: Path; 定义网络中任意两点之间最大后验联合概率为:

$$D_{s, t}(\text{Path}_{\max}) = \prod_{P_{e_i, j} \in \text{Path}} (P_{e_i, j}); \quad (2)$$

由于网络搜索使用最小化机制,因而设:

$$D_{s, t}(\text{Path}_{\min}) = -\log \{D_{s, t}(\text{Path}_{\max})\}; \quad (3)$$

那么,在网络中的实际搜索路径就变为:

$$D_{s, t}(\text{Path}_{\min}) = -\sum_{P_{e_i, j} \in \text{Path}} \log(P_{e_i, j}); \quad (4)$$

显然,  $D_{s, t}(\text{Path}_{\max}) \Leftrightarrow D_{s, t}(\text{Path}_{\min})$ , 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<sup>[18]</sup>。

由于对数函数的非线性,使得小概率变化速度大于大率,所以,最大后验联合概率网络中同样描述长度下,小概率的取值可能性较高,其图像分割的特征表现为:图像细节保留较多,同时也会造成图像分割比较琐碎(过度分割);但是总体趋势依然是大率占优势。可见,最大率网络突出了极端率值(最大和最小率),一般而言,在图像中大率属性 (SAC 值) 同时对对应着图像的宏观特征和细节,小率属性 (SAC 值) 则一定对应着图像的细节,所

以,基于最大后验联合概率 DMN 的高光谱图像分割可能保留较多细节(在本文实例中将产生一定程度的过度分割)。

### 3.2 搜索原理

对用于高光谱图像分割的 DMN 搜索的实际问题,特别是将其作为图像分割的优化控制网络,我们在网络搜索中不判断索(chord)结构也不顾及集团(clique)的尺寸(这样就会避免产生伪连接),因而也不是通过集团度量来判断网络的总度量是否最优(最小或最大),理由是对高光谱图像分割的问题描述,不能要求 DMN 一定要形成索,因为文献[13]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就是依赖的。也就是说,对于我们的具体问题,如果强制生成索,必然使全域不是最优的节点组合在一起(由于伪连接而引起)。

我们选择 Floyd-Warshall 算法<sup>[18]</sup>,用它来搜索网络中所有节点间的最优路径,它可以表达高光谱图像 SAC 值间的两两概率全局最优组合,在网络中表现为最大联合后验概率的节点“链”或“树”的组合,由此构成网。

迹度量与搜索方式有关,并且决定网络的物理意义。网络状态取决于网络的搜索方式,搜索方式决定了数据挖掘的兴趣,网络状态是事先不可预测的,数据挖掘的意义就在于对挖掘结果的“无知性”<sup>[19]</sup>。

对图 1 所示图像的 SAC 值,使用最大后验概率迹度量所生成的 DMN 有向版(见第 4 节)如图 3 所示,由于网络节点太多(255 个),不便显示,图 3 只显示了 DMN 的矩阵(255×255)的图像形式,图 3(a)的黑灰区域为节点间的最短距离 D;图 3(b)的灰白区域为节点间最短路径的后继点矩阵 Path。




图 3 DMN 的无向版

Fig 3 DMN with direction

## 4 DMN 应用方法

SAC 值之间的转移概率(共生概率)<sup>[3]</sup>是指两个 SAC 值之间的共同出现的频率矩阵,共生 SAC 值概率若用图的边来表示则为无向边,图为无向图(DMN)。为了使图像分割时 SAC 值不会发生局部逆转,我们规定 SAC 值只向一个方向转移,其实质是单方向条件概率,所以, SAC 值共生矩阵(无向图)就成为条件转移矩阵(有向图),所以我们就获得了 DMN 的有向版。

显然,转移矩阵是集图像 SAC 值分布的宏观与微观特征于一体的二阶统计量<sup>[3]</sup>。

下面以最大后验概率的全局网络搜索方法对图像进行分割。

假设:每一对像元 SAC 值可能向整幅图像中任意一个相关(像元对的)SAC 值转移,其理由是:转移矩阵是基于整幅图像的相邻像元 SAC 值共同出现概率的二阶统计量,是整幅图像 SAC 值分布的宏观统计特征。

在上述假设下,在最大后验概率 DMN 中进行相关节点搜索,对图像进行分割。

## 5 实验与分析

实验材料为延安地区航空高光谱数据,包含 63 个波段,通过波段分析与合成实验,发现 4, 3, 2 波段是较好的波段组合,图 1(a)是这三个波段的合成图像,图面清晰,但其中部和南部光影明显。

实验区的实地调绘资料如图 4。通过光谱分析和实地调查(图 4),该地区主要包括:山地(西北部:包括稀疏植被、浓密树影团块和裸地;东南部:大面积树林包括经济林和普通树木)、农田(包括不同长势和类型的农田、裸地、水塘和少许水田)、道路(包括从西南到东北方向的主要道路、田埂小路)、河流及滩地。(注:调绘资料中没有绘出山地中的非经济林木、裸地以及地面建筑、道路、河流等)。

本实验的目的是将上述地物类别的主要轮廓区域从影像中分离出来,而不区分地物类别,其实质是图像分割,它为制图和分类等进一步工作提供地物目标的识别特征。

算法步骤:

(1)从光谱角余弦矩阵(SACM)左上角起,逐行、列每次取出一个 SAC 值;




图 4 实验区实地调绘资料

Fig 4 The investigating data on the spot in plot of experiment



图 5 实验结果

Fig 5 The result of experiment

(2)判断它在 DMN中对应的节点;

(3)在 DMN中,以该节点为起点  $s$ 判断与之具有最大后验联合概率的结束节点  $t$ 若路径数 $\geq 1$ ,则转向(4);若无路径,则  $s$ 点标记值不变,并转向(1);

(4)从  $s$ 到  $t$ 点的备选最优路径中的近邻节点中选出具有最大后验概率的节点  $t_i$ ;

(5)将节点  $s$ 的标记值转移为节点  $t_i$ 的标记值;

(6)将结果返回光谱角余弦矩阵(SACM)中,运算结束后,输出分割图像。

图像分割实验结果如图 5。

对比图 4和图 5可以发现,所有地物类型的区域均被分割出来:山地、农田、道路、河流的轮廓清晰可辨。

分割图像的西北部山地纹理丰富、斑点琐碎,是因为其植被、裸地较多且破碎;东南部山地比较均匀,是因为其主要被树林(经济林和非经济林)浓密地覆盖,山脚下靠近河流中上位置有一处较大白色斑块,在合成影像中由于光影的作用使其不可见,其实它是小片建筑物(农居),被从大片植被中发现出来。

农田区域中田块界限、纹理清晰可辨,光影对分割毫无影响。

道路(包括从西南到东北方向的主要道路、田埂小路)异常清晰。

河流两岸以及河中的旱滩都被分离出来。

上述分割结果对于高光谱遥感数据直接应用于

制图等工作提供了很好的中间成果。

我们利用 SACM对高光谱图像进行分割,其实就是在 SACM数据中找到最佳的分割点,将相似与不相似的图像数据分割开来。

本文提出的 DMN方法,能够自动寻找出 SACM数据中的最佳分割点。

作为对比分析,下面我们研究用其它方法寻找 SACM数据中的最佳分割点的方法及其有效性。

对比实验方法是:不使用 DMN作为优化控制网络,完全基于 SACM对图像进行分割。

对 SACM矩阵矢量化并排序如图 6; SACM矩阵相应的直方图如图 7。




图 6 SACM 矩阵矢量化排序图

Fig 6 Sequent diagram of SACM matrix vector set

从图 6、图 7中的箭头所指的位置可以看出光谱角值在区间  $[0.8, 1]$ 之间存在一个域值,可以用




图 7 SACM 矩阵统计直方图

Fig 7 Statistics histogram of SACM matrix



图 9 阈值为 0.991 的分割图像

Fig 9 The segmentation image with threshold 0.991

来将 SACM 数据分割开来。但是,用什么方法能够自动找到这个最佳的位置,所有类似于文献 [3]所提及的方法等都需要预先设定参数,而且处理过程比较繁琐,这些都限制了其应用。

我们以经验和人工方式分别用阈值 0.94, 0.95, 0.96, 0.97, 0.98, 0.99, 0.991 进行试探性图像分割。当域值取 0.99 时的图像分割结果如图 8,当阈值取 0.991 时的图像分割结果如图 9。

表 1 分割图像综合评判

Table 1 The overall evaluation of segmentation image

分割图像	分割方法或阈值	综合评判结果
图 8	参数: 0.99	91.56
图 5	基于 DMN 的分割	93.66
图 9	参数: 0.991	90.80



图 8 阈值为 0.99 的分割图像

Fig 8 The segmentation image with threshold 0.99

对比图 8 与图 5 以及图 9 与图 5,可以看出,其分割结果比较接近,但是还存在明显差异。结合表 1 的综合评判结果,图 5 的分割效果要优于图 8 和图 9。虽然三幅分割图像都存在过度分割的问题,但是总体而言,图 5 的过分割程度介于图 8 和图 9 之间,即在参数区间  $[0.99, 0.991]$  之外,不会存在优于图 5 的分割结果。另外,我们取分割图像的局部放大比较(见图 10)。可以看出,图 10(a)的均质性略好于图 10(b),但是其纹理不如图 10(b)清晰;图 10(c)的纹理与图 10(b)接近,但是其均质性不



(a) 图 8 的局部 (b) 图 5 的局部 (c) 图 9 的局部

图 10 图 8、图 5、图 9 的局部比较

Fig 10 The comparison of locality in fig 8, fig 5 and fig 9

对上述分割图像用像素数计算(均质区面积)的方法和专家综合评判(纹理和总体分割效果)的方法相结合,得到分割图像的定量分析精度(分割图像自身的相对值)如表 1。评判的依据是外业调绘资料(图 4)。

如图 10(b)。说明图 5 是相对最佳的分割结果。

另外,图 8 和图 9 是用一系列启发式的试探方法得出的结果,是人工参预(参数法)的结果,不利于自动化;而图 5 是基于 DMN 自动识别的结果,便于实际应用。

综上所述,我们可以得出下面结论:

(1)没有 DMN 参与的 SAC 的高光谱图像分割的效果不如用 DMN 作为优化控制网络的 SAC 的高光谱图像分割的效果好。

(2)虽然其它方法(例如,文献[3]所提及的方法等)也能达到分割的目的,但是它们都需要预先设定参数,并且处理过程都比较复杂,这些缺点都限制了其应用,本文方法不需要任何参数。

(3)在 DMN 的优化控制下, SAC 能够自动收敛于其数据性质突变的位置,它的本质是一种神经网络方法。

上述验证过程进一步说明了 DMN 方法对高光谱图像分割的有效性。

我们认为本文提出的图像分割方法具有自适应的性质,它能够自动寻找数据集的优化状态。存在的问题是过度分割的现象,其原因主要是 SAC 的初始数据处理所获得的信息不足而产生,本文光谱角余弦值(SAC)的统计信息只包含了一阶近邻关系,因而像素空间相关性分布信息不足,造成了图像分割比较琐碎和过度(下一步将对高阶近邻关系进行研究,有望改进这一不足);另外,正如 3.1 节所述,光谱角余弦值(SAC)的细节保留较多,也是造成图像分割比较琐碎和过度的原因,这是本文所提方法需要进一步完善的地方。

与其它众多分割方法的比较有待辟专文深入研究。本文作为一种新的图像分割方法的探讨,存在一些不足,但其方法的纯数学性特点是其简洁特征的重要方面。同时任何网络方法(包括各类神经网络)的研究都具有“黑箱”的特征,本文方法也具有这样的印记,但其可解释性却是显然的(本文 3.1 节),因而它可以归于“灰箱”一类,网络方法完全实现“白箱”化的目标尚需长期努力。

## 6 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;并对其在图像分析中应具有的形式作了广义的描述(或定义),实质是如何建立度量模型和网络模型。用光谱角余弦值(SAC)的转移概率矩

阵生成马尔科夫网,以该网络作为图像分割处理的优化控制机制(神经网络证据),实验研究表明马尔科夫网可以很好地揭示图像数据间的抽象概率关系。

我们以高光谱图像分割为例,验证了马尔科夫网在空间数据挖掘中的理论和实用价值,进一步研究还包括:最大后验概率和最小熵的混合准则下 DMN 的生成与应用(它将涉及多网络混合寻优问题);以及最大后验概率和最小描述长度混合准则下 DMN 的生成与应用等问题。

更广泛的应用包括:遥感多波段图像各个光谱区间马尔科夫网生成研究——实质就是图像融合;基于马尔科夫网的图像恢复;基于马尔科夫网的高光谱遥感数据的光谱聚类、分析与表示等。

## 参 考 文 献 (References)

- [1] Du P J, Chen Y H, Fang T, et al. Study on the Extraction and Applications of Spectral Features in Hyper-spectral Remote Sensing [J]. Journal of China University of Mining & Technology, 2003, 32(5): 957-964. [杜培军, 陈云浩, 方涛等. 高光谱遥感数据光谱特征的提取与应用 [J]. 中国矿业大学学报, 2003, 32(5): 957-964.]
- [2] Liu Z, Yi D Y. The Application of Projection Pursuit in Hyper-spectral Image Analysis [J]. Mathematical Theory and Applications, 2003, 32(1): 76-81. [刘卓, 易东云. 投影寻踪方法与高光谱遥感图像数据特征提取的研究 [J]. 数学理论与应用, 2003, 32(1): 76-81.]
- [3] Wang R S. Image Understanding [M]. The University of National Defence and Technology Press, 1998. [王润生. 图像理解. 长沙:国防科技大学出版社, 1998.]
- [4] Roger Fjortoft, Yves Delignon, Wojciech Pieczynski, et al. Unsupervised Classification of Radar Images Using Hidden Markov Chains and Hidden Markov Random Fields [J]. IEEE Trans. On Geoscience and Remote Sensing, 2003, 41(3): 675-686.
- [5] Patrick A. Kelly, Haluk Demir, Keith D. Hartt. Adaptive Segmentation of Speckled Images Using a Hierarchical Random Field Model [J]. IEEE Trans. On Acoustics Speech and Signal Processing, 1988, 36(10): 1628-1641.
- [6] David Heckerman. Bayesian Network for Data Mining Data Mining and Knowledge Discovery [C]. Copy 1997 Kluwer Academic Publishers. Manufactured the Netherlands: 79-119.
- [7] Meera Balakrishnan, Andrew Reibman. Characterizing a Lumping Heuristic for a Markov Network Reliability Model [OL]. IEEE Trans. on Pattern Anal. Machine Intell. Copy 1993: 731-741.
- [8] Xiang Y, Lee J. Local Score Computation in Learning Belief Networks [J]. @. snowwhite.dig.queensh. ca. 2008.6.
- [9] Xiang Y, Wong S K M, Cercone N. A 'Microscopic' Study of Minimum Entropy Search in Learning Decomposable Markov

- Networks[M]. Machine Learning Copy 1997 Kluwer Academic Publishers Manufactured the Netherlands 2665-2692
- [10] Granum E, Thomason M G, Gregor J. On the Use of Automatically Inferred Markov Networks for Chromosome Analysis [A]. Lundsteen C, Piper J. in *Automatically of Cytogenetics* [C]. Berlin: Springer 1989.
- [11] Granum E, Thomason M G. Automatically Inferred Markov Network Models for Classification of Chromosome Band Pattern Structures[J]. *Cytometry*, 1990, **11**: 26-39.
- [12] Chow C K, Liu C N. Approximating Discrete Probability Distributions with Dependence Trees [J]. *IEEE Trans On Information Theory*, 1968, (14): 462-467.
- [13] Pearl J. Probabilistic Reasoning in Intelligent Systems [A]. *Networks of Plausible Inference*[C]. Morgan Kaufmann 1988.
- [14] Wang J N, Zhang B, Liu J G, et al. Hyper-spectral Data Mining—Toward Target Recognition and Classification [J]. *Journal of Image and Graphics* 1999, **4**(11): 957-964. [王晋年, 张兵, 刘建贵等. 以地物识别和分类为目标的高光谱数据挖掘 [J]. *中国图象图形学报*, 1999, **4**(11): 957-964.]
- [15] Bouckaert R R. Properties of Bayesian Belief Network Learning Algorithms[A]. Lopez R, de Mantaras Poole D. *Proc of 10th Conf On Uncertainty in Artificial Intelligence* [C]. Seattle Washington: Morgan Kaufmann 1994: 102-109.
- [16] Heckeman D. Learning Bayesian Networks: the Combination of Knowledge and Statistical Data[J]. *Machine Learning*, 1995, (20): 197-243.
- [17] Wong S K M, Xiang Y. Construction of a Markov Network from Data for Probabilistic Inference [A]. In *Proc 3rd Inter Workshop on Rough Sets and Soft Computing*[C], San Jose 1994: 562-569.
- [18] Xie J X, Xing W X. Optimization of Networks[M]. Beijing: Publishing House of Tsinghua University, 2000. [谢金星, 邢文训. 网络优化 [M]. 清华大学出版社, 2000.]
- [19] Han J W, Micheline Kamber. *Data Mining Concepts and Techniques*[M]. China Machine Press 2001.

## Study on the Approaches for Segmentation of Hyper-spectral Images Based on DMN

CAO Jian-nong<sup>1,2</sup>, GUAN Ze-qun<sup>1</sup>, LI De-ren<sup>3</sup>

(1. School of Remote Sensing and Information Engineering, Wuhan University, Wuhan 430079, China;

2. School of Architecture, Xi'an University of Architecture & Technology, Xi'an 710055, China;

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

**Abstract** Three parts of property systems in hyper-spectral remote sensing data are simply expounded. The paper studies concept and method of DMN, constructs it based on SA, and conducts segmentation of image in line with it. The researches and experiments indicate that the DMN based on SA information may synthesize relation between spatial and spectral features existed in hyper-spectral remote sensing data; and provides control for further treatment of image such as artificial neural network. Lastly, we point out future directions of its application and research.

**Key words** DMN; hyper-spectral remote sensing; SA (spectral angle); maximum posterior probability; spatial data mining