

基于 EM-EBF 模型的遥感影像分类方法研究

骆剑承¹⁾ 郑江¹⁾ 裴韬¹⁾ 明冬萍¹⁾ 陈秋晓^{1,2)} 沈占锋¹⁾

¹⁾ (中国科学院地理科学与资源研究所资源与环境信息系统国家重点实验室, 北京 100101)

²⁾ (浙江大学城市规划系, 杭州 310027)

摘要 椭球径向基函数神经网络(EBF)是在径向基函数(RBF)映射理论基础上的改进。在保留 RBF 3 层网络结构基础上,EBF 采用了最大期望算法来估计特征空间的混合密度分布参数,用椭球体集合来分解混合密度分布,从而构造了神经网络的中间层基函数的状态。由于遥感数据在特征空间中通常表现为混合密度分布,EBF 模型能够充分利用期望最大(EM)算法获得的最大似然参数估计得到更合理的特征空间的密度分解模型,从而使得 EBF 模型能够保留 RBF 非线性复杂映射能力的同时,获得更合理的分类结果。为此提出了基于 EBF 的遥感分类方法,试验结果表明 EBF 方法比 RBF 方法网络连接更简单、分类精度更高。

关键词 神经网络 遥感影像分类 椭球径向基函数 EM 算法 混合密度

中图分类号:TP391 文献标识码:A 文章编号:1006-8961(2005)06-0698-07

An Elliptical Basis Function Network for Classification of Remote-Sensing Images

LUO Jian-cheng¹⁾, ZHENG Jiang¹⁾, PEI Tao¹⁾, MING Dong-ping¹⁾,
CHEN Qiu-xiao^{1,2)}, SHEN Zhan-feng¹⁾

¹⁾ (State Key Laboratory of Resources and Environmental Information System, CAS, Beijing 100101)

²⁾ (Department of Regional and Urban Planning, Zhejiang University, Hangzhou 310027)

Abstract An elliptical basis function (EBF) network is proposed in this study for the classification of remotely sensed images. Though similar in structure, the EBF network differs from the well-known radial basis function (RBF) network by incorporating full covariance matrices and uses the expectation-maximization (EM) algorithm to estimate the basis functions. Since remotely sensed data often take on mixture-density distributions in the feature space, the proposed network not only possesses the advantage of the RBF mechanism but also utilizes the EM algorithm to compute the maximum likelihood estimates of the mean vectors and covariance matrices of a Gaussian mixture distribution in the training phase, which leads to more reasonable classification. Experimental results show that, compared to RBF network, the EM-based EBF network is more accurate and simpler in structure.

Keywords artificial neural networks, remote sensing image classification, elliptical radial basis functions, EM algorithm, mixture densities

1 引言

从遥感图像中进行专题信息提取和地物分类是遥感定量化分析的重要手段。遥感数据作为地球表面信息的综合反映,具有一定的复杂性和不确定性,

在特征空间中通常表现为呈混合密度分布。在分类算法中如果对混合密度的参数估计不适当,就会给分类结果带来较大的偏差。神经网络(ANN)能够解决这种复杂的分类问题,因而被广泛应用于遥感影像信息提取与分类中^[1,2]。其中,作为非线性函数逼近和一般数据分类的有效模型,径向基函

基金项目:国家自然科学基金项目(40101021)

收稿日期:2003-04-17; 改回日期:2004-12-22

第一作者简介:骆剑承(1970~),男,博士,副主任。主要研究领域包括遥感图像智能处理、分布式地学计算以及数字城市等。E-mail: luojc@reis.ac.cn

数(RBF)模型是对传统多层前向神经网络的一种发展,RBF保留了非线性复杂映射能力的同时,可实现快速训练和避免产生混沌行为,并且模型结构也比较简单^[3]。因此,RBF模型成为进行遥感影像分类的一个好方法^[4,5]。

基于RBF模型的分类型方法主要取决于基函数的中心点及其覆盖范围的选取^[6,7]。基函数中心矢量的选取一般用传统聚类算法即可实现,如K-均值和K-最近邻方法等。基函数的覆盖范围往往采用与中心等距离的球体模型,而通过这种基于球体的基函数的混合重叠形成的混合密度分布函数与现实数据混合密度分布的多样性之间多少会有一些的差距。在实际算法中,为了尽可能与实际混合密度分布相拟合,基函数中心点的获得就需要由大量的中心点集叠加计算,其计算量非常大,而且增加了混合密度函数的复杂度。遥感信息统计密度分布具有复杂性和多样性,在特征空间中往往表现为多种密度分布的混合,很难用传统基于距离的统计方法进行混合密度分布的参数估计。但对于这种混合模型可以采用密度分布降解的办法,用有限个参数化密度分布的组合来逼近整体复杂的混合密度分布^[8-10],期望最大(EM)算法就是针对这种混合密度分布模型而设计的一种有效参数化分解方法。

综合RBF模型的网络结构,将RBF基函数的球体模型扩展为椭球体模型就形成了椭球径向基函数神经网络(EBF)^[11-13]。在EBF模型中,各密度分布的协方差矩阵被合并到基函数中,复杂的混合分布就可以用有限高斯密度函数集的组合来表示,使得EBF模型的处理单元是超椭球体的,从而提高了常规RBF模型的逼近能力。本文提出了采用EM算法来估计EBF模型的基函数参数,发展EBF遥感分类方法,其基本机制包括两部分:首先,通过使用EM算法,可以把稀疏特征空间中遥感数据的混合密度分布分解成可以用概率分布函数椭球传播表示的隐含中心;其次,通过使用线性感知器,建立起隐含层的聚类中心与输出层类别之间的映射关系。

2 混合密度分布及椭球径向基函数(EBF)模型

2.1 遥感数据的混合密度分布特性

模式识别要解决的问题是如何对一系列过程、现象或对象进行识别和描述,这些对象通常由有限

个特征集或性质来规定。参数化概率密度函数(PDFs)可以简化统计决策方法,所以被广泛应用于数据信息提取与分类。和非参数化的神经网络方法相比,这种方法有着明显的优点:通过PDF可以对分类结果做比较清楚的解释;通过贝叶斯理论与其他领域的先验知识进行融合来加强决策能力;当决策模型的所有参数确定之后,PDF的计算会大大地简化而且易于实现。然而,由于信息特征的复杂性,这种统计方法还存在一定的缺点。当特征空间的分布过于离散,或者训练数据不充分也不具有代表性时,特征的分布往往不能很好地服从预先设定的参数化密度分布。在这种情况下,建立在单峰分布和简单统计基础上的PDF模型的估计结果与特征的真实分布之间就存在偏差。

在遥感数据里,某些类别的PDF的确包含有多个峰值。以水体为例,影像上的水体由于不同水深、不同含沙量以及其他外部因素,在特征空间里呈混合密度分布(图1)。此外,在遥感影像上不同类别的目标的分布可能会互相重叠或看起来彼此间非常相似,在这种情况下,由PDF模型得出的结果常常会偏离真实情况,因而引入混合密度模型是十分有必要的。

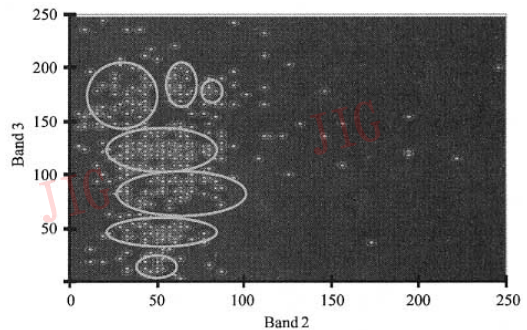


图1 SPOT-HRV影像水体样本的混合分布

Fig. 1 A mixture model of water body sampled from a SPOT-HRV image

有限混合密度模型对于表达复杂现象是一个重要的也十分有效的方法。有限混合密度模型认为数据按不同的混合比例有两种或更多种的分布,其目的是为表达整个数据集的分布而找到一种合理的混合PDF模型,其中每一部分都与隐含在数据中的重要特征相对应^[14,15]。PDF模型中的权重正是该种类别的数据点在整个数据集里所占的比例。因而,模式识别问题通过混合密度模型转变为概率密度函数PDF的参数估计问题。在实际应用中,有限混合密度模型中

往往采用简单的高斯函数形式,而高斯表示法比较简单,需要的仅仅是两套参数,即均值矢量和协方差矩阵。而且高斯密度是对称的、单峰的且具有同向性的,在估计未知的概率密度时若给定均值和方差后则只需要很少的先验知识就可以解决问题。

2.2 RBF 模型的椭球体扩展——EBF 模型

基于混合密度分布模型,RBF 模型就是通过使用基函数非线性映射到高维混合密度特征空间。RBF 模型包括输入层、隐含层和输出层组成的 3 层前馈结构。首先,将特征空间分为不同的超区域,这样混合密度分布才能被参数化地描述;然后,按照一定的线性映射关系,把特征空间的每一个超区域划分为一个亚类,RBF 模型的隐含层的基函数对输入矢量产生一个局部反应,同时将计算出的隐含单元的基函数的线性合并作为输出单元的内容。规范化的 RBF 模型,其输出定义为

$$y(x) = \frac{\sum_j w_j \varphi_j(x)}{\sum_j w_j} \quad (1)$$

其中, x 是输入矢量, w_j 是第 j 个基函数 $\varphi_j(\cdot)$ 的权重。

基函数 φ 可以被看成是隐含层中激活函数,在隐含层中,每一个中心对输入矢量都有一个输出矢量的局部化的接收域。这和混合密度模型中按照统计分布模型把特征空间分为混合区域是一样的。通常从聚类过程中得到基函数的中心与参数。如果提供一组非线性基函数集,RBF 模型就能够在输入与输出空间建立一种近似的关系。理想情况下,为了逼近真实的分布,可以按照实际需要来选择基函数,然而,若单单基于统计理论而构造如此微妙而复杂的参数函数却是不可能的。

一般来说,对于对角协方差矩阵标准基函数的加权而言,RBF 模型表现为一种后验概率。在这样的情况下,网络输出是 N 个球心组成的多维组合,公式如下:

$$y(x) = \frac{\sum_{n=1}^N y_n \exp\left\{-\frac{\|x - x_n\|^2}{2\sigma^2}\right\}}{\sum_{n=1}^N \exp\left\{-\frac{\|x - x_n\|^2}{2\sigma^2}\right\}} \quad (2)$$

其中, $\{(x_n, y_n): n=1, \dots, N\}$ 是一个多维训练数据集。

多数情况下,每一个对角协方差矩阵都有同样的元素控制相应的 RBF 单元的传播。所以,RBF 单元传播范围是超球形的。当特征空间中混合密度的组成部分相互独立时,就可以得到高精度的模式识

别结果。否则,就需要更多的基函数,使得每一个基函数所覆盖的区域的数据被认为有一个相互独立的组成部分。因此,如果在 RBF 模型基函数中纳入完全协方差矩阵,那么不需要使用大量的基函数就可以表达复杂的混合密度分布,这种方法既合理也非常有效。在这样的情况下,隐含单元的传播范围是超椭球的,RBF 模型被扩展为椭球径向基函数模型(EBF),其基函数采用如下公式:

$$\varphi_j(x_p) = \exp\left\{-\frac{1}{2\gamma_j}(x_p - \mu_j)^T \Sigma_j^{-1}(x_p - \mu_j)\right\} \quad (3)$$

$$j=1, \dots, M$$

其中, x_p 是第 p 次输入矢量, μ_j 和 Σ_j 是第 j 次基函数的均矢量与协方差矩阵, γ_j 是控制第 j 次基函数传播的平滑参数,由下式决定:

$$\gamma_j = \frac{3}{5} \sum_{k=1}^5 \|\mu_k - \mu_j\| \quad (4)$$

其中, μ_k 表示第 k 次欧氏空间上 μ_j 的最近距离。这种方法和在聚类过程中普遍使用的 K-最近邻域方法是相似的。

在 EBF 模型隐含层与输出层之间再次采用线性感知器的连接结构。如果在隐含层 i 单元与输出层 j 单元之间有连接,那么 w_{ij} 是该连接的权重。在训练阶段, w_{ij} 可以通过以下过程迭代进行调整,直到其达到收敛:

$$w_{ij}(t+1) = w_{ij}(t) + \Delta w_{ij} \quad (5)$$

其中, $w_{ij}(t)$ 表示第 t 次迭代隐含层中第 i 单元到输出层第 j 单元的连接权重, Δw_{ij} 表示当前迭代过程的调整权重,该调整权重可以用下式计算:

$$\Delta w_{ij} = \eta \delta_j o_j \quad (6)$$

其中, η 表示学习率($0 < \eta < 1$), δ_j 表示输出层中第 j 单元的误差,由下式得到:

$$\delta_j = T_j - o_j \quad (7)$$

其中, T_j 表示输出层中第 j 单元的期望作用, o_j 表示其实际作用。

2.3 基于 EM 算法的 EBF 基函数参数估计

无论是 RBF 模型或 EBF 模型,选择聚类算法来确定隐含层的状态是最重要的一步。EBF 模型中心的参数(包括均值矢量和协方差矩阵),通常采用直接的聚类方法(如 K-均值,K-最近邻域算法)进行估计得到。均值矢量通过对抽样数据平均化直接得到,而协方差矩阵则通过对包含中心的抽样数据的协方差计算得到。但是,如果对均矢量的估计值严重偏离真实均值,则得到的可能是不合适的结果,此

协方差矩阵也不是对真实协方差矩阵的准确估计。鉴于空间数据分布的复杂性与随机性,传统的聚类算法存在以下问题:如何确定初始条件?如何确定最佳的聚类中心数目?如何消除来自噪音数据的被动影响?如何集成专业领域的特定知识?EM 算法正好解决了上述问题。如下是基于 EM 的 EBF 模型参数估计的具体算法。

高斯密度分布公式:

$$f_i(\mathbf{x}; \theta_i) = (2\pi)^{-d/2} |\Sigma_i|^{-1/2} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu}_i)^T \Sigma_i^{-1} (\mathbf{x} - \boldsymbol{\mu}_i) \right\} \quad (8)$$

$i = 1, \dots, g$

其中, θ_i 参数包括均矢量 $\boldsymbol{\mu}_i$ 和协方差矩阵 Σ_i , 由 EM 算法得出的第 i 个混合成分的参数 θ_i 可以按照如下所示 E、M 步骤简单地估计出来:

E-Step

$$\tau_{ij}^{(t+1)} = \tau_i(\mathbf{x}_j; \theta_i^{(t)}) = \frac{\pi_i^{(t)} f_i(\mathbf{x}_j; \theta_i^{(t)})}{\sum_{k=1}^g \pi_k^{(t)} f_k(\mathbf{x}_j; \theta_k^{(t)})} \quad (9)$$

即

$$\tau_{ij}^{(t+1)} = \frac{\pi_i^{(t)} |\Sigma_i^{(t)}|^{-1/2} \exp \left\{ -\frac{1}{2} (\mathbf{x}_j - \boldsymbol{\mu}_i^{(t)})^T \Sigma_i^{(t)-1} (\mathbf{x}_j - \boldsymbol{\mu}_i^{(t)}) \right\}}{\sum_k \pi_k^{(t)} |\Sigma_k^{(t)}|^{-1/2} \exp \left\{ -\frac{1}{2} (\mathbf{x}_j - \boldsymbol{\mu}_k^{(t)})^T \Sigma_k^{(t)-1} (\mathbf{x}_j - \boldsymbol{\mu}_k^{(t)}) \right\}} \quad (10)$$

其中, $\tau_{ij}^{(t)}$ 是属于第 t 步中第 i 成分第 j 个数据点 \mathbf{x}_j 的后验概率, $\pi_i^{(t)}$ 是第 t 步中第 i 成分所占的比例。

M-Step

$$\pi_i^{(t+1)} = \frac{1}{n} \sum_{j=1}^n \tau_{ij}^{(t)} \quad (11)$$

$$\boldsymbol{\mu}_i^{(t+1)} = \frac{1}{n \pi_i^{(t+1)}} \sum_{j=1}^n \tau_{ij}^{(t)} \mathbf{x}_j \quad (12)$$

$$\Sigma_i^{(t+1)} = \frac{1}{n \pi_i^{(t+1)}} \sum_{j=1}^n \tau_{ij}^{(t)} (\mathbf{x}_j - \boldsymbol{\mu}_i^{(t)}) (\mathbf{x}_j - \boldsymbol{\mu}_i^{(t)})^T \quad (13)$$

与传统 RBF 模型相比,基于 EM 进行 EBF 模型参数估计算法的主要优点是:

(1)中心椭球体分布 在传统的聚类算法中,偏差度由欧氏距离来表示,因此隐含层基函数的局部反应是球体的。EM 算法能将局部的反应扩展到超椭球体,不同维方面的差异可得到消除。因此,估计出的高斯混合密度最大可能地保障与现实情况的逼近。

(2)稳定性与可靠性 在迭代的每一步,EM 算法保证似然函数值不断地增加,从而保证稳定性与

单收敛。因此,EM 算法对初始化的要求非常低。

(3)分析表达和计算简单 通过 EM 算法,按照分布密度来搜寻聚类中心。一个中心表示一种分布情况。因此,混合中心是特征空间密度分布的统计解析表达。

(4)确定出的聚类中心数目合理 传统的聚类算法没有确定聚类数目的固定原则。而使用 EM 算法,可以把迭代过程中估计出的比例和密度参数看成自适应的合理聚类数目的重要指标。

(5)利于知识集成 EM 算法的目标是通过最大似然函数来估计模型中的参数。基于贝叶斯理论的一框架,先验知识能够容易被集成到 EBF 模型中。

(6)健壮性 为了提高正确度与可靠性,混合密度模型自然要具有一定的健壮性,这样可以鉴别出单独的密度分布,而不被其他独立的分布或离散的噪音所影响。

3 EBF 遥感分类方法

当数据呈复杂混合密度分布时,EBF 模型对分类问题的解决是十分有效的。在 EBF 模型中,由 EM 算法来确定隐含单元的状态,包括聚类中心及其均值与协方差矩阵的估计,然后由混合密度模型,可以确定输入矢量与相应基函数椭球反应的中心之间的接近程度。所以 EBF 模型比传统的 RBF 模型更适于对遥感数据的分析,利用 EBF 模型能有效地对遥感影像进行信息提取与分类。在具体实现中,基于 EM 算法的 EBF 模型包含 3 个主要的部分(如图 2 所示):EM 算法模块;EBF 模型训练模块;分类模块。

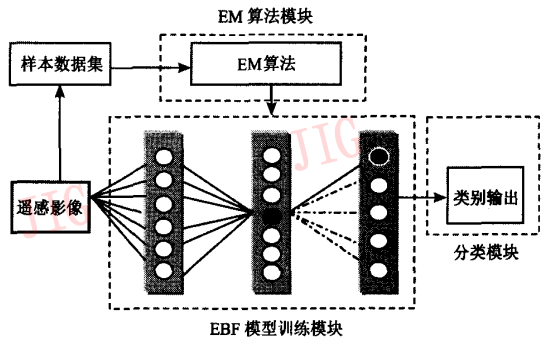


图 2 基于 EM 的 EBF 分类模型结构图
Fig.2 Architecture of the EM-based EBF classification network

基于 EM 聚类思想的 EBF 算法实现步骤如下:

(1)选择抽样数据集 假设由一原始影像,随

机地或有选择地确定充足的样本数据集 $X = \{x_i, x_i \in \mathbf{R}, i = 1, \dots, p\}$ 。

(2) 初始化 确定初始的聚类中心的数目 g , 均矢量 μ_i 和第 i 类别的协方差矩阵 Σ_i 。通常, g 可以是一个结合实际情况选择的一个较大的数, 从数据集中随机选取数据作为均矢量 μ_i 的初始值。随之协方差矩阵 Σ_i 则可以确定出来。

(3) 估计最大似然参数 通过 EM 算法, 当所有的参数趋向一个稳定值时, 就可确定每一聚类中心的参数值。

(4) 确定 EBF 模型聚类中心的最佳数目 应当指出, 现有的 EBF 模型训练技术在选择合理的基函数数目时还存在一定的问题, 这将最终影响它的执行。然而, 通过使用 EM 算法, 聚类中心的数目能得到控制。当迭代过程到达一个稳定状态时, 按照两种指标比例值 π_i 和第 i 类椭圆范围内的抽样数据数目对聚类中心的数目进行增加或删除。首先, 由最大似然法计算当前类包含的数据数目。如果包含最小数目的类的比例值 π_i 低于一个给定的最小值, 应当从当前中心集中删除该聚类中心, 同时过程返回到第 3 步来调整剩下的聚类中心的参数。如果高于给定的最小值, 该聚类中心被保留并执行第 3 步直到一个稳定状态。

(5) 在 EBF 模型训练模块中, 通过迭代规则对隐含层与输出层的单元连接权重进行调整。

(6) 从影像中得到的未知的 X 矢量被反馈到基于 EM 的 EBF 模型中, 从而逐个像素地得到分类结果。

4 应用实例

4.1 试验区与试验数据

利用 EBF 模型进行遥感影像的土地覆盖分类来估测 EBF 模型在实际应用中的效果, 以香港港岛地区为试验区, 所利用的数据是 1999 年 2 月的 3 波段的 SPOT-HRV 数据 (CH1: 0.50 - 0.59 μm ; CH2: 0.61 - 0.68 μm ; CH3: 0.79 - 0.89 μm), 如图版 I 图 1(a) 所示。影像是从原始整幅影像上裁切的 600 \times 800 的数据, 分辨率为 20m, 覆盖面积约为 192km²。该区域的土地覆盖非常复杂, 主城区主要围绕维多利亚港分布, 岛内大部分地区为丘陵, 覆盖不同类型的植被。根据调查和资料所获得的知识并通过目视判读, 确定出 9 种主要的土地覆盖类型作为分类参考, 包括: C1—海水体; C2—内陆水体;

C3—城区; C4—水泥路; C5—裸露地; C6—海滩; C7—城市绿地; C8—坡林; C9—烧荒后草地。

对于一些类型的土地覆盖, 如水体 (C1, C2)、已建成区 (C3, C4)、植被 (C7, C8, C9), 因为在特征空间中的混合密度分布的光谱特性非常接近, 水体和阴暗的建成区 (C1, C2, C3, C4) 很难用目视的方法区分开来。

为每种土地覆盖选择典型的样本数据用于监督分类, 在训练阶段总共选择了总共 3 500 个样本, 其中 2 600 个用于训练, 而其余 900 个用于测试。

4.2 试验结果与比较

具有 2 600 个训练抽样数据的 3 维特征空间的混合密度通过 EM 算法被分解成 62 个聚类中心, 同时估计出每一个聚类中心的最大似然参数。因此, EBF 的隐含层的大小为 62 个节点。在从隐含层到输出层的线性训练阶段, 为避免波动, 训练速率被保持到足够小 (0.02)。通过计算被训练的 EBF 模型中的测试数据集, 可以得到测试误差矩阵 (如表 1 所示)。EBF 模型训练时间大约需要 120s, 整个测试精确度为 76.11%, 图版 I 图 1(b) 为利用 EBF 模型得到的土地覆盖分类结果图。

表 1 EBF 模型分类结果的误差矩阵

Tab.1 Error matrix of classification by the EBF network

	C1	C2	C3	C4	C5	C6	C7	C8	C9	总计
C1	97	18	2	0	0	0	0	0	0	117
C2	2	62	7	0	0	1	0	0	0	72
C3	1	20	76	4	0	0	3	1	6	111
C4	0	0	10	71	6	7	0	0	12	106
C5	0	0	0	7	49	8	0	0	0	64
C6	0	0	0	7	44	71	2	0	0	124
C7	0	0	0	4	1	9	88	1	0	103
C8	0	0	1	2	0	3	5	91	1	103
C9	0	0	4	5	0	1	2	7	81	100
总计	100	100	100	100	100	100	100	100	100	900

训练时间 = 120s, 精度 = 76.11%, Kappa = 0.731

作为比较, 用其他两种普通的分类模型: 最大似然法 MLC (椭球形的单密度模型) 和传统的 RBF 模型法 (超球形的混合密度模型), 对同样的抽样数据也进行了训练与测试。C-均值聚类方法用于决定 RBF 模型隐含层的大小, 结果为 64 节点 (与 EBF 模型接近)。利用 MLC 方法和 RBF 模型的测试结果的误差矩阵如表 2 和表 3 所示。MLC 方法的整体测试精度是 69.11%, RBF 模型为 70.33%。RBF 模型的训练时间为 50s。

表 2 MLC 方法分类结果的误差矩阵

Tab.2 Error matrix of classification by MLC

	C1	C2	C3	C4	C5	C6	C7	C8	C9	总计
C1	98	25	4	0	0	0	0	0	0	127
C2	1	23	5	0	0	0	0	0	1	30
C3	0	46	75	2	0	2	0	1	6	132
C4	0	0	7	64	4	6	0	0	13	94
C5	0	0	0	19	89	60	0	0	0	168
C6	1	5	1	5	7	24	1	0	0	44
C7	0	0	0	6	0	7	84	2	0	99
C8	0	0	2	1	0	0	10	96	11	120
C9	0	1	6	3	0	1	5	1	69	86
总计	100	100	100	100	100	100	100	100	100	900

精度 = 69.11%, Kappa = 0.653

表 3 RBF 模型分类结果的误差矩阵

Tab.3 Error matrix of classification by the RBF network

	C1	C2	C3	C4	C5	C6	C7	C8	C9	总计
C1	91	22	1	0	0	0	0	0	0	114
C2	6	55	9	1	0	1	0	0	0	72
C3	2	22	76	4	0	2	0	1	7	114
C4	0	0	6	67	4	5	0	1	14	97
C5	0	0	0	9	18	3	0	0	0	30
C6	1	0	0	7	78	82	2	0	0	170
C7	0	0	0	4	0	5	81	0	0	90
C8	0	0	2	3	0	2	12	94	9	122
C9	0	1	6	5	0	0	5	4	70	91
总计	100	100	100	100	100	100	100	100	100	900

训练时间 = 50s, 精度 = 70.33%, Kappa = 0.666

比较这 3 种分类方法,可以得到以下结论:

(1) 椭球径向基函数模型 (EBF) 具有径向基函数模型 (RBF) 主要优点。尽管数据是自由分布的, 椭球径向基函数模型 (EBF) 对特征空间的混合分布的分类比传统的统计分类方法更强, 比如试验中对 C3 与 C2 得到了很好的类别区分。

(2) 通过保持同样的隐含层的大小, EBF 模型能够在分类中获得比径向基函数模型 (RBF) 更高的精度。

保证 EBF 模型分类方法成功分类的一个关键是按照混合程度, 选择一个合理的隐含层的大小。为了测试隐含层的大小与整体精度的关系, 选择大小为 20, 30, 40, 50, 60, 80 和 100 中心的隐含层来进行估测。换句话说, 特征空间按不同的尺度大小被划分成不同的超椭球区域。表 4 表明了随着隐含层尺度的增加, 整体分类的精度也呈上升趋势 (应当指出的是计算时间也随之增多), 当达到一定值的时候则趋于稳定。由于在 EBF 模型的基函数中融

入了完全协方差矩阵, 聚类中心能够代表更复杂的特征空间混合密度分布, 而无需使用大量基函数。正如图 3 所显示的那样, EBF 模型在同样的条件下优于 RBF 模型。

表 4 分类精度与隐含层尺度之间的关系

Tab.4 Relationship between accuracy and size of the hidden layer

	EBF 模型中隐含层的尺度							
	20	30	40	50	60	80	100	
	训练时间 (s)	20	40	70	100	120	170	250
C1	96.00	97.00	96.00	97.00	97.00	97.00	97.00	98.00
C2	39.00	40.00	52.00	64.00	62.00	62.00	63.00	63.00
C3	78.00	78.00	82.00	76.00	76.00	80.00	79.00	79.00
C4	71.00	74.00	72.00	72.00	71.00	77.00	77.00	77.00
C5	35.00	39.00	37.00	34.00	49.00	56.00	56.00	56.00
C6	71.00	71.00	70.00	78.00	71.00	69.00	69.00	69.00
C7	90.00	90.00	88.00	89.00	88.00	86.00	86.00	86.00
C8	89.00	91.00	91.00	89.00	91.00	92.00	92.00	92.00
C9	74.00	78.00	80.00	80.00	81.00	78.00	78.00	78.00
平均	71.33	73.00	74.11	75.33	76.11	77.22	77.33	77.33




图 3 EBF 和 RBF 平均精确性比较

Fig.3 Comparison of average accuracy between the EBF and the RBF network

5 结 论

通过对 RBF 模型结构的扩展, 完全协方差矩阵被融入到 EBF 模型, 并由 EM 算法确定 RBF 模型的参数, 本文应用该模型于遥感图像分类。除其在理论上的优点外, 已经证明椭球径向基函数模型在分类中是更为精确的一种方法。与传统的 MLC 和 RBF 分类器比较, EBF 模型结构上更简单, 更准确和更具有说明力。为了使椭球径向基函数神经网络更有效, 还需要展开进一步的研究, 比如要通过集成先验知识的 Bayes 理论来充分利用 EM 算法的优点。

参考文献 (References)

- 1 Atkinson P M, Tatnall A R L. Neural networks in remote sensing [J]. International Journal of remote sensing, 1997, 18 (4): 699 ~ 709.
- 2 Civco D L. Artificial neural networks for land cover classification and mapping [J]. International Journal of Geographical Information Systems, 1993, 7(2): 173 ~ 186.
- 3 Bishop C M. Radial basis functions, Neural Networks for Pattern Recognition[M]. Oxford, New York: Clarendon Press, 1995.
- 4 Bruzzone L, Prieto D F. A technique for the selection of kernel-function parameters in RBF neural networks for classification of remote-sensing images [J]. IEEE Transactions on Geoscience and Remote Sensing, 1999, 37(2): 551 ~ 559.
- 5 Rollet R, Benie GB, Li W, et al. Image classification algorithm based on the RBF neural network and K-means [J]. International Journal of Remote Sensing, 1998, 19(15): 3003 ~ 3009.
- 6 Chen T, Chen H. Approximation capability to functions of several variables, nonlinear functions, and operators by radial basis function neural networks [J]. IEEE Transactions on Neural Networks, 1995, 6(4): 904 ~ 910.
- 7 Gomm J B, Yu D. Selecting radial basis function network centers with recursive orthogonal least squares training [J]. IEEE Transactions on Neural networks, 2000, 11(2): 306 ~ 314.
- 8 Dempster A P, Laird N M, Rubin D B. Maximum likelihood estimation from incomplete data via EM algorithm [J]. Journal of Royal Statistical Society, 1977, 39(1): 1 ~ 38.
- 9 McLachlan G J, Basford K E. Mixture Models: Inference and Applications to Clustering [M]. New York: Marcel Dekker, 1988.
- 10 McLachlan G J, Krishnan T. The EM Algorithm and Extensions [M]. New York: John Wiley & Sons, 1997.
- 11 Mak M, Kung S. Estimation of elliptical basis function parameters by the EM algorithm with application to speaker verification [J]. IEEE Transactions on Neural Networks, 2000, 11(4): 961 ~ 969.
- 12 Mao K Z, Tan K C, Ser W. Probabilistic neural-network structure determination for pattern classification [J]. IEEE Transactions on Neural Networks, 2000, 11(4): 1009 ~ 1016.
- 13 Xu L. RBF nets, mixture experts, and Bayesian Ying-Yang learning [J]. Neuro-computing, 1998, 19(1-3): 223 ~ 257.
- 14 Zhuang X, Huang Y, Zhao Y. Gaussian mixture density modeling, decomposition, and applications [J]. IEEE Transactions on Image Processing, 1996, 5(9): 1293 ~ 1301.
- 15 Tadjudin S, Landgrebe D A. Robust parameter estimation for mixture model [J]. IEEE Transactions on Geoscience and Remote Sensing, 2000, 38(1): 439 ~ 445.

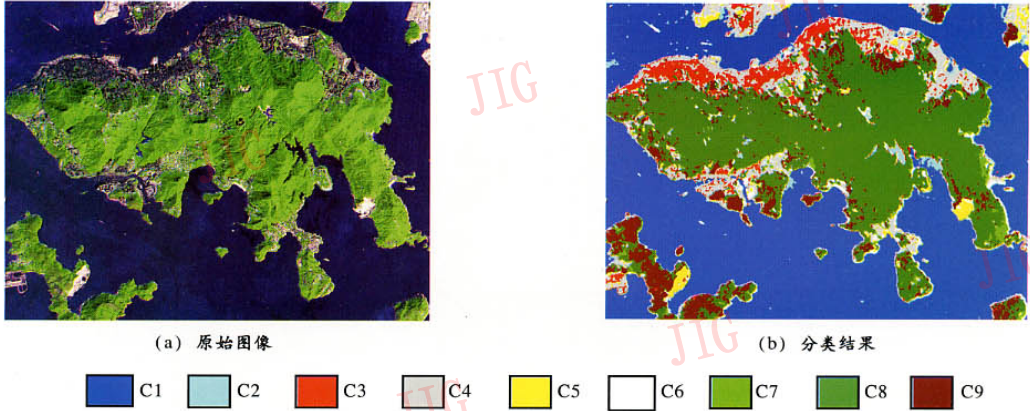


图1 实验区的原始SPOT影像及其EBF土地覆盖分类结果
Fig.1 Original SPOT image and EBF land cover classification result covering the study area

戴 芹等：利用贝叶斯网络进行遥感变化检测




图1 1994年和2003年TM原始图像
Fig.1 TM image of 1994 and 2003

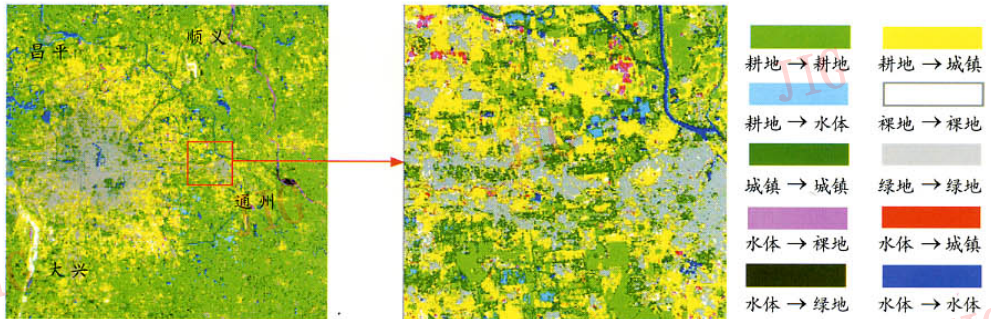


图2 1994年、2003年贝叶斯网络的变化检测结果图
Fig.2 TM image of 1994 and 2003 change detection result map