

中图法分类号: TP75 文献标志码: A 文章编号: 1006-8961(2010)11-1681-07

检索信息: 吴柯, 牛瑞卿, 沈焕峰, 凌峰, 陈涛. 结合超分辨率重建的神经网络亚像元定位方法[J]. 中国图象图形学报, 2010, 15(11): 1681-1687

结合超分辨率重建的神经网络亚像元定位方法

吴 柯¹⁾, 牛瑞卿¹⁾, 沈焕峰²⁾, 凌 峰³⁾, 陈 涛¹⁾

¹⁾ (中国地质大学地球物理与空间信息学院, 武汉 430074) ²⁾ (武汉大学资源与环境科学学院, 武汉 430079)

³⁾ (中国科学院测量与地球物理研究所, 武汉 430077)

摘 要: 遥感影像中普遍存在着混合像元, 如何分析和解译混合像元一直是人们研究的热点。亚像元定位方法是将混合像元分解成为亚像元, 并赋予不同的端元组分, 以提高影像整体分类精度的一种技术。本文在神经网络亚像元定位模型的基础上, 结合超分辨率重建理论, 提出一种新型的 BMAP 模型, 在每一个类别的组成成分图像与亚像元定位图像之间建立起高、低分辨率的观测模型, 采用最大后验估计 (MAP) 算法对 BP 神经网络的定位结果进行约束, 最终确定混合像元内部各组分合适的空间位置。通过对模拟的简单图像和长江三峡地区的 ETM 影像进行实验, 结果表明, 与神经网络模型相比, 本文方法能够更加有效地解决亚像元定位的问题, 进一步消除定位过程中产生的误差, 提高精度。

关键词: 混合像元; 超分辨率; BP 神经网络模型; 最大后验估计方法; 观测模型

Sub-pixel mapping method based on ANN and super-resolution reconstructed model

Wu Ke¹⁾, Niu Ruiqing¹⁾, Shen Huanfeng²⁾, Ling Feng³⁾, Chen Tao¹⁾

¹⁾ (Institute of Geophysics and Geomatics, China University of Geosciences, Wuhan 430074)

²⁾ (School of Resource and Environmental Science, Wuhan University, Wuhan 430079)

³⁾ (Institute of Geodesy and Geophysics, Chinese Academy of Sciences, Wuhan 430077)

Abstract: Mixed pixels are always the case in remote sensed images, and how to analysis and explain mixed pixels is of importance in remote sensing applications. Sub-pixel mapping is a technique designed to obtain the spatial distribution of the classes inside the pixels with information of different endmembers to improve the accuracy of the classification. In this paper, a new BMAP model is introduced by combination of the neural network and super-resolution reconstructed technology. The spatial distribution of the sub-pixel can be determined by establishing of observation model between the high-resolution and the low-resolution images after the neural network mapping; with restricted by Maximum A Posteriori (MAP) algorithm. The proposed model was tested on both simple synthetic image and ETM image in the three Gorges area. Results indicate that this method can mapping sub-pixel efficiently, and better performance was observed compared to that of the original ANN model.

Keywords: mixed pixels; super-resolution; BPNN model; MAP; observation model

基金项目: 国家自然科学基金项目 (40901206); 中国博士后科学基金项目 (20090451091); 中国科学院海洋环流与波动重点实验室基金项目 (KLOCAW0906)。

收稿日期: 2009-09-24; **改回日期:** 2009-10-13

第一作者简介: 吴 柯 (1981—), 男。讲师。研究方向为遥感图像处理, 遥感地质应用等。已在国内外期刊发表论文十多篇。

E-mail: tingke2000@126.com。

0 引言

由于传感器空间分辨率的限制以及地物的复杂性等原因,混合像元普遍存在于所获取的遥感影像中,这在地物分布较复杂的区域尤其如此。如果将遥感影像中的像元归为一类,势必会带来分类误差,反映不出地物的真实覆盖情况。如果混合像元能够被分解,而且它的端元组分的丰度能够求得的话,分类将更加精确,这一处理过程现在称之为混合像元分解^[1]。但是,混合像元分解技术只能得到一个像元中各个端元的组成百分比信息,并不能知道各个端元在空间上具体的分布如何。亚像元定位技术正是针对这一问题而提出的,它将混合像元分解成若干个更小的亚像元,通过确定这些亚像元的位置,弥补遥感影像空间细节信息。

Atkinson 于 1997 年首次提出了亚像元空间分布相关性的概念,并把亚像元定位的理论定义为:在保持混合像元分解组分比例结果的基础上,为一个像元中不同的组成成分找到合适的空间位置^[2]。目前,已经提出了多种实用的算法来解决此类问题,例如基于知识推理的分析技术^[3]、线性优化的算法^[4]、遗传算法^[5]、神经网络模型^[6-7]、元胞自动机^[8]等。在已有的一些研究成果当中,前馈型神经网络(BP)模型由于具有良好的非线性映射能力,在处理该类问题中能够取得较好的效果而受到广泛重视。它采用空间相关性假设理论,通过训练与目标类型相邻近的像元,确定网络参数,从而获得最终的定位结果。

但是,利用神经网络模型对遥感影像亚像元定位的结果往往会出现“锯齿状”或者“斑点状”的误差^[8],这种误差在处理过程中无法避免,因为神经网络本身的处理过程就具有一些不确定性的因素,诸如采集样本、选取参数、函数的收敛性等,这都会对结果产生较大的影响,因此,直接利用神经网络模型无法保证在复杂的混合像元内部进行准确的定位。针对这一问题,本文引入图像处理中的超分辨率重建理论,在低分辨率的组成成分影像与高分辨率的定位结果影像之间建立起观测模型,去除在神经网络的定位过程中产生的误差,有效地提高了定位结果的精度。通过模拟的简单数据和真实数据对求解的效果进行了检验。

1 神经网络模型

采用典型的 BP 神经网络来构建亚像元定位模型,它包含相对独立的两大模块:模型纠正(训练)和模拟。在模型纠正模块中,利用训练数据自动获取模型的参数;输入到模拟模块进行模拟运算。网络第 1 层代表了数据输入层,输入的是标准化后的形式,目的是确保即使从不同的影像中,所获取的训练模式是一致的;第 2 层是隐藏层,隐藏层的神经元数目通过经验来确定;第 3 层是输出层,它决定了每个模拟单元在 $s(s > 1)$ 尺度上目标类型的空间分布状况。

整个模型描述了在获取遥感影像的混合组成成分的基础上,8 邻域中间的低分辨率的组成成分比例与在一定尺度空间下,定位的高分辨率亚像元值(0 或 1)的一种对应关系。具体算法的求解方式可以参见文献[6],在模型学习中,神经网络输入层的信号来自研究区的合成图像。隐藏层接收到输入层的信号为

$$I_h = \sum W_{hi} O_i \quad (1)$$

式中, W_{hi} 为输入层与隐藏层之间的权重值, O_i 为输入信号。输出 O_h 可以表示为

$$O_h = f(I_h) = \frac{1}{1 + e^{-I_h}} \quad (2)$$

类似地,输出层所接收到的信号 I_o 和输出的信号 O_o 可分别表示为

$$I_o = \sum W_{oh} O_h \quad (3)$$

$$P_j(k, s) = O_o = f(I_o) = \frac{1}{1 + e^{-I_o}} \quad (4)$$

式中, W_{oh} 为隐藏层与输出层之间的权重值, $P_j(k, s)$ 即为最终结果,意为原尺度上第 k 个像元在 s 尺度上其中第 j 个亚像元被确定为目标类型的概率。该过程可以简单地由式(5)来描述,比如:低分辨率组分比例对应的是一个大小是 3×3 的空间窗口,中心像是 x_{ij} ,令尺度空间 $s = 2$,那么对应的高分辨率的亚像元值输入是一个 2×2 的空间窗口,即

$$\begin{bmatrix} x_{i-1,j-1} & x_{i-1,j} & x_{i-1,j+1} \\ x_{i,j-1} & x_{i,j} & x_{i,j+1} \\ x_{i+1,j-1} & x_{i+1,j} & x_{i+1,j+1} \end{bmatrix} \rightarrow \begin{bmatrix} y_{ij}^1 & y_{ij}^2 \\ y_{ij}^3 & y_{ij}^4 \end{bmatrix} \quad (5)$$

当端元个数为 4 时,依次输出每个亚像元所属该类别的概率 $Y = y_{ij}^k (k = 1, 2, 3, 4)$,如果端元个数

为 N 个,那么,这个式子能够与 N 个 BP 神经网络模型相对应。

$$y_{ij}^k = \begin{cases} 1 & \text{对应目标像元类别} \\ 0 & \text{否则} \end{cases} \quad (6)$$

由于原始图像的混合像元中某一类所占的比例是一定的,因此,对某一类来说,确定亚像元归属类别的问题,是将各个亚像元概率值进行从大到小的排序,依次确定目标类型,选择概率最大的亚像元作为归属为 1 的类型,其余的则赋值为 0。直到满足该类总数为止。这样,亚像元的空间分布得到了确定。

2 超分辨率重建模型

由于高分辨率的影像能够更加详细地表示景物的细节信息,因此,通过软件途径得到高分辨率影像的超分辨率重建技术已经成为了人们广泛研究的热点。单幅影像的超分辨率重建技术经过长期的发展已经形成一套统一的理论体系^[9]。其中,观测模型是超分辨率重建的基础,它描述了低分辨率图像和所求的高分辨率图像之间的关系,每一种超分辨率重建方法都必须基于一种假定模型。例如:图 1 为高、低分辨率影像的简略像素坐标图,重建比率为 $\rho = 4$ 。




图 1 低分辨率影像和高分辨率影像的像素坐标

Fig. 1 Pixel coordinate of low and high resolution images

如果将低分辨率影像的像素 A 投影到高分辨率影像的像素坐标中,它将覆盖高分辨率影像像素前 16 个像素,由此可得观测方程

$$y = [x_1 + x_2 + \cdots + x_{16}] / \rho^2 \quad (7)$$

式中, y 为低分辨率影像像素值, x_i 为高分辨率影像的像素值, ρ 为重建比率。通过此方法,对每一个低分辨率影像的像素都可以建立一个观测方程,组成观测方程组。于是在理想状态下,观测模型的表达式可以写为

$$y = Ax \quad (8)$$

式中, y 表示低分辨率影像像素矩阵; x 表示高分辨率影像像素矩阵; A 为系数矩阵。

把以上的观测模型推广到遥感亚像元定位当中,待处理的分解组成分图像可以看做是低分辨率影像,而定位后的结果图像可以看做是高分辨率影像,由此建立起一个观测模型,进行超分辨率影像重建^[10]。图 2 是一个简单的示意图,其中包含两种不同的端元组分,分别用灰色和白色来表示。图 2 (a) 是原始的 2×2 像元栅格图,表示混合像元分解后的一幅组成分图像,其中每一个像元里面标明的数字代表端元组分在该像元中的百分比含量。图 2 (b) 表示利用 BP 神经网络将原始像元分割成 4×4 的亚像元,计算出来的亚像元的个数,以对亚像元定位。例如:图中占某一端元比例 25% 的像元,可以在亚像元分布图中定位出 4 个亚像元(灰色)来代表这一种端元类型,而其他的 12 个亚像元(白色)代表其他的端元类型。所以,定义图 2(a) 为低分辨率影像,(b) 为高分辨率影像,建立观测模型,重建比率 $\rho = 4$,低分辨率影像每一个像元对应于高分辨率影像的 16 个亚像元,由此建立方程组。




图 2 亚像元定位模型示意图

Fig. 2 2×2 coarse pixels divided into 8×8 sub-pixels

3 改进的亚像元定位

假如影像中含有 N 种不同的地物类别,那么,通过以上的 BP 神经网络模型可以获得 N 幅不同类型的高分辨率影像,设定其中一幅影像是 x_{BP} ,参照式(8),此时的观测模型可以定义为

$$y_{BP} = Ax_{BP} + n \quad (9)$$

式中, n 表示在亚像元的定位过程所产生的种种误差。这里,MAP 高分辨率影像恢复可以定义为在已知 BP 亚像元定位结果的前提下,使恢复到最佳的亚像元定位图像所出现的后验概率达到最大。因

此,最大后验估计方法(MAP)又称为贝叶斯方法^[11-12],它根据贝叶斯准则,提供了一条途径来把与应用相关的数据,以一种最优的方式组合到初始模型中,即

$$\hat{\mathbf{x}}_{\text{MAP}} = \arg \max_x [Pr\{\mathbf{x} | \mathbf{y}_{\text{BP}}\}] \quad (10)$$

根据贝叶斯公式,有

$$\hat{\mathbf{x}}_{\text{MAP}} = \arg \max_x \left[\frac{Pr\{\mathbf{y}_{\text{BP}} | \mathbf{x}\} Pr\{\mathbf{x}\}}{Pr\{\mathbf{y}_{\text{BP}}\}} \right] \quad (11)$$

由于分母对结果没有影响,可以直接消去

$$\hat{\mathbf{x}}_{\text{MAP}} = \arg \max_x [Pr\{\mathbf{y}_{\text{BP}} | \mathbf{x}\} Pr\{\mathbf{x}\}] \quad (12)$$

对上式右端取对数得

$$\hat{\mathbf{x}}_{\text{MAP}} = \arg \max_x [\log Pr\{\mathbf{y}_{\text{BP}} | \mathbf{x}\} + \log Pr\{\mathbf{x}\}] \quad (13)$$

式中, $\log Pr\{\mathbf{y}_{\text{BP}} | \mathbf{x}\}$ 为最大似然函数的对数, $\log Pr\{\mathbf{x}\}$ 代表 $\mathbf{x}$ 先验概率的对数。可以假定分解的丰度子图像噪声是均值为 0、方差为 σ_k^2 高斯噪声,则 $\hat{\mathbf{x}}$ 对 $\mathbf{y}_{\text{BP}}$ 进行估计的整体概率函数为

$$Pr(\mathbf{y}_{\text{BP}} | \mathbf{x}) = \prod_{\forall x,y} \frac{1}{\sigma / \sqrt{2\pi}} \exp\left(-\frac{(\hat{\mathbf{y}}_{\text{BP}} - \mathbf{y}_{\text{BP}})^2}{2\sigma^2}\right) \quad (14)$$

获取亚像元的值以后,图像先验概率密度函数可以假定为以下形式

$$Pr(\mathbf{x}) = \exp\left[-\left(\frac{1}{\lambda} \|\mathbf{Q}\mathbf{x}\|^2\right)\right] \quad (15)$$

式中 λ 为温度参数,用来控制概率密度分布的尖峰; $\mathbf{Q}$ 为一线性高通滤波算子,一般选择如下的 2 维拉普拉斯算子

$$\frac{\partial^2 f(x,y)}{\partial x^2} + \frac{\partial^2 f(x,y)}{\partial y^2} = f(x+1,y) + f(x-1,y) + f(x,y+1) + f(x,y-1) - 4f(x,y) \quad (16)$$

把式(14)、(15)代入式(13),得

$$\hat{\mathbf{x}}_{\text{MAP}} = \arg \max \left[\log \frac{N}{\sigma / \sqrt{2\pi}} - \sum \frac{(\hat{\mathbf{y}}_{\text{BP}} - \mathbf{y}_{\text{BP}})^2}{2\sigma^2} - \frac{1}{\lambda} \|\mathbf{Q}\mathbf{x}\|^2 \right] \quad (17)$$

在上式中,等号右端括号内第一项为常数项,可以直接消除;再把其余两项的负号改为正号,即可以把以上极大化问题转换为如下的极小化问题

$$\hat{\mathbf{x}}_{\text{MAP}} = \arg \min \left[\sum (\hat{\mathbf{y}}_{\text{BP}} - \mathbf{y}_{\text{BP}})^2 + \frac{2\sigma^2}{\lambda} \|\mathbf{Q}\mathbf{x}\|^2 \right] \quad (18)$$

设 $\alpha = \frac{2\sigma^2}{\lambda}$,并把式(9)代入上式,得

$$\hat{\mathbf{x}}_{\text{MAP}} = \arg \min [\|\mathbf{y}_{\text{BP}} - \mathbf{A}\mathbf{x}_{\text{BP}}\|^2 + \alpha \|\mathbf{Q}\mathbf{x}\|^2] \quad (19)$$

由式(8)(9)得

$$\hat{\mathbf{x}}_{\text{MAP}} = \arg \min [\|\mathbf{y}_{\text{BP}} - \mathbf{A}\mathbf{x} - \mathbf{n}\|^2 + \alpha \|\mathbf{Q}\mathbf{x}\|^2] \quad (20)$$

式中 α 为正则化参数。使上式达到最小的必要条件是使 $\|\mathbf{y}_{\text{BP}} - \mathbf{A}\mathbf{x} - \mathbf{n}\|^2 + \alpha \|\mathbf{Q}\mathbf{x}\|^2$ 对 $\mathbf{x}$ 的偏微分为 0,即

$$2\mathbf{A}^T \mathbf{A} (\mathbf{A}\mathbf{x} - \mathbf{y}_{\text{BP}} + \mathbf{n}) + 2\alpha \mathbf{Q}^T \mathbf{Q} \mathbf{x} = 0 \quad (21)$$

整理得

$$(\mathbf{A}^T \mathbf{A} + \alpha \mathbf{Q}^T \mathbf{Q}) \mathbf{x} = \mathbf{A}^T (\mathbf{y}_{\text{BP}} - \mathbf{n}) \quad (22)$$

求解过程中,由于大计算量和奇异矩阵的影响,一般通过迭代过程来寻求上式的最优解。在迭代求解过程中,采用下式对亚像元求解后的图像进行更新:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + [\mathbf{A}^T (\mathbf{y}_{\text{BP}} - \mathbf{n}) - (\mathbf{A}^T \mathbf{A} + \alpha \mathbf{Q}^T \mathbf{Q}) \mathbf{x}_k] \quad (23)$$

选取 BP 神经网络定位图像 $\mathbf{x}_{\text{BP}}$ 作为初始高分辨率影像值,带入方程(23),当相邻两次迭代求解重建图像的差小于设定阈值时,就终止迭代,终止条件为

$$\|\mathbf{x}_{k+1} - \mathbf{x}_k\|^2 / \|\mathbf{x}_k\|^2 \leq d \quad (24)$$

式中 d 为终止迭代的阈值。

综上所述,改进的 BPMAP 亚像元定位的方法主要分为以下几个步骤:

1) 采用 BP 神经网络亚像元定位模型对不同的丰度组成分影像进行亚像元定位,获得初始高分辨率影像图。

2) 选择原始的分解影像与定位的高分辨率影像构成一一对应的关系,确定重建比率,并列出观测方程组,方程组中的未知量是高分辨率影像像素值。

3) 以初始 BP 高分辨率影像图作为已知条件,建立最大后验估计(MAP)模型。通过迭代运算,得出属于不同类别的高分辨率子影像的值。

4) 将像元中的各个亚像元的值进行比较,按照从大到小的顺序排序,重新赋值为 1 或 0,直到满足目标类别的个数为止。

5) 最后对所有不同的子图像进行合并分析,显示出最终的定位分类图。

4 实验与比较分析

4.1 模拟数据

实验采用合成图像来模拟混合像元分解后的丰度图。所谓合成图像是指:将较高分辨率影像中各类型的硬分类结果,用中值滤波器重采样至低分辨率的丰度图。这样做的优点在于,避免了低分辨率与高分辨率影像之间配准而带来的误差,以及利用一般混合像元分解的方法,由于结果的不确定性所带来的干扰。研究结果的误差直接反映该研究模型方法的好坏^[13]。因此,降采样之前的原始影像,可以作为标准的较高分辨率影像,在以下的实验中,选取原始影像的分类图作为结果验证的参考图。

图像中包含的类别个数越多,亚像元定位的过程也越复杂^[14]。为了描述问题的方便,在模拟图像中只包含两种不同的类别:目标和背景。图 3(a)(b)分别是原始影像和参考图像。首先对原始影像降采样,采样尺度为 $s=4$,采样后的图像中 1 个像元对应于采样前的 16 个像元,将其放大后显示如图 3(c)所示,以其作为初始的低分辨率丰度图,如

果直接进行传统最大似然法(MLC)分类,得到的结果如图 3(d),两种物体的交界处存在大量的混合像元,使图中的细节信息大量丢失,而且非常不整齐。图 3(e)(f)分别是利用 BP 神经网络模型, BMAP 模型进行亚像元定位后得到的结果,通过与原始参考图像(图 3(b))相比较,发现它们都要比直接分类所获得的信息充分,但是前者在每个字体的边缘处都出现了锯齿状的现象,这说明了在对丰度图像进行亚像元定位时,两种不同类别之间存在误判,利用 BMAP 模型的结果对这种边缘锯齿状的现象进行了修复,修复程度非常接近于原始参考影像,视觉效果令人满意。

4.2 真实数据

真实数据选取 2002 年 4 月获取的长江三峡地区 ETM 影像(图 4(a)),该影像有 6 个波段,分辨率为 30m,包含长江、湖泊、植被和居民区 4 个不同类别,参考的真实地物类别分布如图 4(b)所示。与模拟数据的处理方法相似,通过分类参考图来直接获取混合像元中各端元组分的丰度图像;然后利用均值滤波器对每个丰度图像进行降采样处理,降采样的尺度因子选取 4,此时图像分辨率变成是 $120\text{ m} \times 120\text{ m}$ 。依次对输入层和输出层输入归属于某一类别的低分辨率丰度图和亚像元的空间分布(0 或 1),并选取合适的连接权和阈值初值、学习速率、网络训练误差,对神经网络进行训练,获得网络连接权值和阈值。由于亚像元定位模型所依据的空间依赖假设更多的是强调空间结构意义上的地理相关性,因此,挑选的样本是从非研究区的类似图像来获得。在本文中,大的数据量会使得网络收敛速度变慢,无法达到最优,所以,为减少神经网络的训练量,只选择部分样本作为训练样本,实验中的样本个数选取 200 个左右,连接权和阈值初值选取 $(-1, 1)$ 之间的随机数,学习速率和网络训练误差分别选取 0.6 和 1×10^{-4} 。MLC 直接硬分类, BP 神经网络模型以及 BMAP 定位模型处理的结果分别如图 4(c)(d)(e)。从目视效果上来看,图 4(c)存在较大的误差,某些区域的形状特征几乎完全消失,利用 BP 神经网络模型恢复的图像,明显好于硬分类结果的图像。但是,在整幅图像上出现了大面积的“斑点”噪声,这些噪声的存在导致定位结果产生大量误判的情况,同时,图像变得非常模糊。BMAP 模型得出的结果图较好地消除了这些噪声,而且在一些空间自相关较弱的零散破碎的目标上以及边缘地区,



图 3 模拟数据的亚像元定位结果

Fig. 3 Sub-pixel mapping results on the artificial image




图 4 真实 TM 影像的亚像元定位结果

Fig. 4 Sub-pixel mapping results on the real TM image

保证了图像的连续性和细节。选择图像右下方城区与植被交界的地方,进行放大 6 倍后分析,图 4 (f)——(i)分别是分类参考、硬分类、BP 网络定位以及 BMAP 定位的图像,可以更加清晰地看出,利用 BMAP 模型将 BP 模型定位结果中居民地和植被的大量噪声消除,效果显著。最后,对比两种算法花费的时间:对选择的 200 个样本训练 500 次,BP 神经网络模型所花费的时间是 3 min 左右;相同的输入,在有效地去除了定位的误差的情况下,BMAP 模型训练只需要 4 min 的时间,因此,BMAP 模型更为有效。

4.3 定量比较分析

利用最大似然法(MLC)、BP 神经网络模型以及 BMAP 模型 3 种方法对上述模拟和真实影像进行处理后的定量分析。由于高分辨率的分类图像是作为真实地物类别的分布,因此主要的精度评价指标采用混淆矩阵,分类的正确率的百分比(PCC)和 Kappa 系数。从表 1 可以看出,利用 BMAP 模型对原始像元信息的估计比较准确,模拟影像和真实影像的分类精度分别提高了 8% 和 12% 左右,比直接利用 BP 神经网络进行估计的结果也提高了 2% 和 3% 左右。真实影像由于混合像元所占的比例比较大,因此 Kappa 系数与 PCC 值提高的幅度也要大一点。对于真实影像中的 4 种地物类别,以原始影像的分类结果为标准,分别选取 100 个点,来作为混淆矩阵的训练样本,表 2—4 给出了利用直接分类的方法、BP 神经网络模型以及 BMAP 模型对退化的 TM

影像进行分类和定位后所得到的混淆矩阵结果,可以得出结论:在利用本文方法得到的定位图像中,4 种地物的分类精度要比前两种方法得到的分类精度高,尤其是对于植被,城区混合的区域,这正是地物比较复杂的区域。

表 1 3 种模型模拟结果的精度统计表

Tab.1 The three accuracy static of the classification results with simulated data

	模拟数据			真实数据		
	MLC	BP	BMAP	MLC	BP	BMAP
PCC	0.887	0.934	0.981	0.710	0.798	0.827
Kappa	0.798	0.872	0.893	0.613	0.731	0.769

表 2 MLC 分类结果混淆矩阵

Tab.2 Confusion matrix of MLC classification result

样区	长江	城区	植被	湖泊
长江	73	10	7	3
城区	8	70	21	17
植被	18	16	67	6
湖泊	1	4	5	74

表 3 BP 神经网络模型分定位结果混淆矩阵

Tab.3 Confusion matrix of BP classification result

样区	长江	城区	植被	湖泊
长江	80	10	9	11
城区	16	78	3	5
植被	3	0	82	6
湖泊	1	12	6	79

表 4 BMAP 模型定位结果混淆矩阵

Tab.4 Confusion matrix of BMAP classification result

样区	长江	城区	植被	湖泊
长江	85	7	4	3
城区	11	81	8	8
植被	0	4	83	7
湖泊	4	8	5	82

5 结 论

亚像元定位是遥感影像混合像元分解的后续研究手段,它的目的是希望能进一步获取得到各端元组分在混合像元中的分布位置。本文在分析了 BP 神经网络求解方式的基础上,结合超分辨率重建技术,提出了一种全新的 BMAP 模型,该模型利用了中间的定位结果信息进行迭代更新,克服了传统 BP 神经网络模型定位误差无法消除的缺点。实验结果证明:这种方法能够较好地消除定位过程中误差的影响,提高精度,无论是处理模拟数据还是真实数据,使结果的精度有较大的提高,为遥感影像的亚像元定位研究提供了一种新的思路。

参考文献 (References)

[1] Zhang Liangpei, Zhang Lifu. Hyperspectral Remote Sensing [M]. Wuhan: Wuhan University Press, 2005. [张良培, 张立福. 高光谱遥感 [M]. 武汉: 武汉大学出版社, 2005.]

[2] Atkinson P M, Cutler M, Lewis H G. Mapping sub-pixel proportional land cover with AVHRR Imagery [J]. International Journal of Remote Sensing, 1997, 18(4) : 917-935.

[3] Powell, R L, Roberts D A, Dennison P E, et al. Sub-pixel mapping of urban land cover using multiple endmember spectral mixture analysis: Manaus, Brazil [J]. Remote Sensing of Environment, 2007, 106(2) : 253-267.

[4] Zhang Hongen, Shi Jiancheng, Liu Suhong. Sub-pixel lakes mapping in tibetan plateau [J]. Advances in Water Science, 2006, 17(3) : 372-382. [张洪恩, 施建成, 刘素红. 湖泊亚像

元填图算法研究 [J]. 水科学进展, 2006, 17(3) : 372-382.]

[5] Mertens K C, Verbeke L P C, Ducheyne E I, et al. Using genetic algorithms in sub-pixel mapping [J]. International Journal of Remote Sensing, 2003, 24(21) : 4241-4247.

[6] Wang Liguo, Zhang Ye, Li Jiao. BP neural network based sub-pixel mapping method [J]. Intelligent Computing in Signal Processing and Pattern Recognition Lecture Notes in Control and Information Sciences, 2006, 34(5) : 755-760.

[7] Tatem A J, Lewis H G, Atkinson P M, et al. Super-resolution target identification from remotely sensed images using a Hopfield neural network [J]. IEEE Transactions on Geoscience and Remote Sensing, 2001, 39(4) : 781-796.

[8] Ling Feng, Zhang Qiuwen, Wang Cheng, et al. Sub-pixel mapping of remote sensing images based on cellular automata model [J]. Journal of Image and Graphics, 2005, 10(7) : 916-921. [凌峰, 张秋文, 王乘, 等. 基于元胞自动机模型的遥感图像亚像元定位 [J]. 中国图象图形学报, 2005, 10(7) : 916-921.]

[9] Andrea Baraldi, Elisabetta Binaghi. Comparison of the multi-layer perceptr on with neuro-fuzzy techniques in the estimation of cover class mixture in remotely sensed data [J]. IEEE Transactions on Geoscience and Remote Sensing, 2001, 39(5) : 994-1005.

[10] Zhang Xinming, Shen Lansun. The development of super resolution restoration from image sequences [J]. Measure and Control Technique, 2002, 21(5) : 33-35. [张新明, 沈兰荪. 超分辨率复原技术的发展 [J]. 测绘技术, 2002, 21(5) : 33-35.]

[11] Gauvain J L, Lee C H. Maximum a posteriori estimation for multivariate Gaussian mixture observations of Markov chains [J]. IEEE Transactions on SAP, 1994, 2(2) : 291-298.

[12] Lee E, Kang M G. Regularized adaptive high-resolution image reconstruction considering inaccurate sub-pixel matching [J]. IEEE Transactions on Geoscience and Remote Sensing, 2003, 41(7) : 826-83.

[13] Mertens K C, Verbeke L P C, Westra T, et al. Subpixel mapping and sub-pixel sharpening using neural network predicted wavelet coefficients [J]. Remote Sensing of the Environment, 2004, 91(2) : 225-236.

[14] Nguyen M Q, Atkinson P M, Lewis H G. Superresolution mapping using a hopfield neural network with fused images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2006, 44(3) : 736-749.