

非线性混合像元分解的可视化分析与评价

吴波¹⁾ 袁春²⁾

¹⁾(福州大学空间数据挖掘与信息共享教育部重点实验室, 福州 350002) ²⁾(中国地质大学(北京)土地科学技术学院, 北京 100083)

摘要 混合像元的非线性分解通常采用神经网络模型来拟合, 普遍缺乏线性分解模型简单明确的物理意义, 导致难于了解像元混合的特点及误差分布的模式。为此, 提出均方根误差、双变量统计、置信度估计和混合复杂度等可视化方法来评价非线性混合模型分解的结果, 直观地表达出影像中像元的分解精度、混合程度以及误差分布模式等, 从而理解非线性混合模型分解的某些特点。实验以投影追踪学习网络(PPLN)为例, 利用 MODIS 与 ETM+ 数据, 对 MODIS 混合像元分解进行了可视化分析, 一定程度上展现了 PPLN 分解的某些特点。通过与反向传播神经网络(BPNN)分解比较结果表明, PPLN 具有较高的分解精度, 总体误差从 0.1828 降低到 0.1717, 降低了大约 6.5%, 且可视化分析表明混合程度较大的区域发生在城区和稀疏植被覆盖区。

关键词 非线性分解 可视化 混合像元 误差分布

中图分类号: 751.1 文献标志码: A 文章编号: 1006-8961(2010)01-0167-07

Visualized Analysis and Evaluation of Nonlinear Unmixing the Mixed Pixels

WU Bo¹⁾, YUAN Chun²⁾

¹⁾(Key Laboratory of Spatial Data Mining and Information Sharing of Ministry of Education, Fuzhou University, Fuzhou 350002)

²⁾(Department of Land Science and Technology, China University of Geosciences Beijing 100083)

Abstract Nonlinear unmixing of mixed pixels in remote sensing imagery are commonly conducted with neural networks (NN) models, which, however, lacks physically-based interpretation as linear models. This paper the difficulties of knowing patterns of pixel mixture and error distribution to some extent. This paper proposes to use mean square error, bivariate distribution function, confidential error, and synthetically mixture complexity techniques to analyze and evaluate the pixel mixture, which can provide insights in some features of nonlinear mixture models. Experiment with MODIS associated with ETM+ data demonstrates that the visualized method can obtain the decomposition characterization of PPLN model efficiently. In addition, visualized assessment shows that PPLN provides higher accuracy compared with the BP neural network. The overall unmixing error decreases from 0.1828 to 0.1717 in terms of RMSE, improved by 6.5%. The experiment also demonstrates that urban and sparse vegetation are the potential occurrence places where pixels are severely mixed.

Keywords Nonlinear unmixing, visualization, mixture pixel, error distribution

0 引言

由于非线性混合模型具有较高的分解精度和普

适性, 引起了人们广泛的研究兴趣^[1-3]。目前, 非线性混合模型大多数基于神经网络模型来模拟。譬如, Atkinson 等人利用多层感知器 (MLP) 方法证实了非线性混合模型比线性混合模型和模糊 C 均值

基金项目: 国家自然科学基金项目 (40801181); 福建省自然科学基金计划项目 (D0710012)

收稿日期: 2009-02-23 改回日期: 2009-03-13

第一作者简介: 吴波 (1975—), 男, 2006 年于武汉大学获摄影测量与遥感专业博士学位。主要研究方向为遥感信息处理, 时空统计分析。已发表相关论文 30 多篇。E-mail: wavelet778@sohu.com

效果都要好^[2]; 径向基函数 (RBF)神经网络模型也证实优于线性混合像元分解方法^[3]; 自适应共振 (ARTMAP)神经网络模型^[4]和自组织特征映射 (SOM)神经网络模型^[5]也被用来分解混合像元。然而, 尽管人们尝试和验证了各种神经网络的混合像元分解方法的有效性, 却很少研究混合像元非线性分解结果定量及可视化的评价方法。由于神经网络模型分解混合像元通常是一个函数逼近与拟合的过程^[3], 普遍缺乏线性模型简单明确的物理意义和可解释性 (如光谱难于反演), 造成目前混合像元非线性分解的评价大多还是采用目视的或局部样本的方式, 不利于深入了解混合像元非分解模型。因此, 如何理解神经网络等混合像元非线性拟合的特点显得非常重要。

可视化分析是一种对复杂数据进行分析与显示的常用技术, 通过对非线性混合像元分解的误差分布模式和组分之间的相互关系进行可视化分析, 便于了解高光谱像元混合的分布模式和分解方法的特点。目前, 国内外对相关领域的可视化分析大多还限于高光谱数据 3 维立方体可视化表达^[6]或者高光谱数据降维方面^[7-8]。在混合像元分解结果的可视化表达方面, Cai 等人设计一个双层可视化分析方案表达组分信息, 用来挖掘混合像元中隐含信息, 探测出混合像元线性分解结果中亚像元目标^[9]。但利用可视化技术评价混合像元分解精度与分析非线性分解方法特点的文章还比较少见。本文提出几种可视化方法来评价非线性混合模型分解结果及其分解误差的分布特点。与前人研究重点不同, 本文不是对高光谱数据本身进行可视化显示, 也不是挖掘混合像元中隐含的亚像元信息, 而是对混合像元分解后的组分信息与误差分布进行可视化表达与评价。通过对分解结果与分解误差分布模式的可视化分析, 以期直观定量地表达出像元混合模式、分解精度以及分解误差的分布模式, 从而有助于理解非线性神经网络混合模型“黑箱式”分解方法的某些特点。

1 可视化分析方法

假设端元组分的 K 个真实值为 $\theta = [\theta_1, \theta_2, \dots, \theta_k]^T$, 相应的估计值为 $\hat{\alpha} = [\alpha_1, \alpha_2, \dots, \alpha_k]^T$, 本文提出均方根误差、置信度估计、双变量分布函数 (BDF) 以及组分影像的可视化等评价方法来直观定量地评价非线性混合像元分解结果。

1.1 均方根误差

如果记真实值与估计值之间的误差为 $e_i = |\alpha_i - \theta_i|$, 并假设混合像元共分解为 n 个地物, 并且 e_i 代表混合像元第 i 个地物的误差, 则对每个混合像元, 定义均方根误差 (RMSE)

$$\Phi_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (1)$$

式中, n 表示为混合像元由 n 个地物混合而成, 则式 (1) 定义了每个混合像元的端元组分估计值与真实值之间的均方根误差。如果计算出每个像元的 RMSE, 则可以用灰度图的形式表示出来。如果误差值大, 则表现为白亮形式, 否则为灰暗点。也可以对 RMSE 用 3 维数值的形式来表达, 如表面图或密度分割图等。

1.2 双变量分布统计 (BDF)

BDF 函数实质是一种散点图方式的可视化评价方法, 它用平面的横坐标表示估计值, 纵坐标表示真实值, 因此, 可以清楚地表明 n 个地物的分解精度。如果把每个混合像元分解的值与真实值投影到双变量图中, 则可以清楚地表明 n 个地物的分解精度。通常如果影像有 n 个地物, 则用 n 个双变量分布图来表示。良好的估计应当是估计值与真实值接近, 因而散点应该位于 $y = x$ 的直线上, 但由于估计误差和一些其他因素的影响, 合理的估计值与真实值应该在 $y = x$ 的直线左右波动。

1.3 置信度估计

置信度估计是一种统计分析的可视化评价方式, 它定义了分解结果在不同置信区间内的精度情况。对于第 i 种地物端元的组分, 计算出各自的估计值 α_i 与真实值 θ_i 之间的差距 $\pi_i = |\alpha_i - \theta_i|$, 如果 $\pi_i \leq \tau_i$, 认为是可以接受的分解精度, 那么对于一个混合像元 r , 统计所有满足 $\pi_i < \tau_i$ 的混合像元数目, 记为 T_i , $i = 1, 2, \dots, t$ 从而得到第 i 种地物不同的置信度估计。

$$\rho(\tau_i) = \frac{T_i}{\text{Sum}} \quad (2)$$

式中, Sum 为影像的像元数目。以上定义表明, 置信度估计是考虑端元组分估计值与真实值之间的差距位于某个区间内的混合像元数目占总体混合像元数目的比例。如果它的横坐标是估计值与真实值之间差距的不同预定值, 纵坐标是指分解误差在各个预定值内的像元数目占像元总数的百分比, 则把每种地物在各个区间的百分数连接起来, 就形成了所谓

的置信度估计图。容易理解,如果图中曲线以下包含的面积越大则分解精度越高,反之则分解精度低。

1.4 像元混合模式分析

混合像元分解后通常产生一组由灰度影像表示的组分影像。如果组分数目 K 大于 3 也可以任选择其中的 3 个分量分别赋予 RGB 色彩,合成彩色图^[10],但这种方式并没有综合利用全部的组分信息,造成可视化分析的不足,也没有提供像元“混合程度”的分布信息。因此,如何综合表达所有 K ($K > 3$) 个组分影像是可视化分析分解结果的重要问题。本文提出一种综合表现影像组分的可视化方法,首先为 K 维组分影像设计一个 K 维正多边形,取正多边形的中心 O ,连接 O 与多边形的各个顶点 (v_1, v_2, \dots, v_k),再根据每个组分维对应的信息相关度 p_i (百分比),从中心出发取中心到每个顶点长度的百分比长度,取点 v'_1, v'_2, \dots, v'_k ,并连接点 v'_1, v'_2, \dots, v'_k ,在正多边形里边形成一个小多边形。小多边形与大多边形的面积比 p 为该混合像元组分值的整体相关度。

由于每个组分维的排列不同会引起小多边形面积的变化,所以面积比 p 将会有所浮动。针对这个问题,借用概率论的原理来解决,即每两个组分维的相关度的乘积 $p_i p_j$ 出现概率相同,将 $p_i p_j$ 乘以它们出现的概率,就可以得到它们的面积比。其表达式为:

$$S = \sum_{\substack{i \leq k, j \leq k \\ i \neq j}} \frac{2 \times p_i \times p_j}{K \times (K - 1)} \quad (3)$$

理论上,混合像元各组分值之和为 1,因此如果某像元为纯净像元,则在某一顶点上它的长度百分比是 100%,而在其他顶点为 0 因此该点面积比为 0。相反,如果认为在各顶点的长度百分比相等时,像元混合程度“最大”,此时将有 p 取值最大。在这个意义上,如果可视化模型结果表现为像元亮度值越大,则该像元混合程度越高,反之,像元混合程度越低。

2 投影追踪学习网络分解模型

由于投影追踪学习网络 (PPLN) 在混合像元分解中具有以下几个特点: 1) 目前尚未见到 PPLN 应用于混合像元分解研究的相关论文; 2) PPLN 的隐含层激活函数不是预先定义的,具有从数据本身自动确定的特点; 3) 它能够结合鲁棒的回归学习方法,使得 PPLN 适合于高维含噪声数据的逼近^[11]。

这些特点表明, PPLN 比较适合于真实影像的混合像元分解,因此,本文选择 PPLN 来讨论可视化评价非线性混合像元分解精度问题。

设 $\mathbf{X} = (x_1, x_2, \dots, x_p)^T$ 为 PPLN 神经网络模型的输入; $\mathbf{Y} = (y_1, y_2, \dots, y_q)^T$ 为所期望的实际输出值; $\hat{\mathbf{Y}} = (\hat{y}_1, \hat{y}_2, \dots, \hat{y}_q)^T$ 为 PPLN 网络的实际输出,则 PPLN 模型可以表述为

$$\hat{y}_i = \sum_{k=1}^m \beta_{ik} f_k \left| \sum_{j=1}^p \alpha_{kj} x_j \right| = \sum_{k=1}^m \beta_{ik} f_k \left| \alpha_k^T \mathbf{X} \right| \quad (4)$$

式中, $i \in [1, q]$; $\alpha_k^T = (\alpha_{k1}, \alpha_{k2}, \dots, \alpha_{kp})$ 为输入层与隐层的连接权向量, $k = 1, \dots, m$, 且 $\|\alpha_k\| = 1$, f_k 为隐层的第 k 个激活函数, $k = 1, \dots, m$, α_{kj} 为输入层的第 j 个元 x_j 和隐层第 k 个激活函数 f_k 之间的连接权值, $k \in [1, m]$, $j \in [1, p]$, β_{ik} 为隐层第 k 个激活函数 f_k 和输出层第 i 个元 y_i 的连接权值, $k \in [1, m]$, $i \in [1, q]$ 。

PPLN 通常采用交替优化的算法确定 3 类参数: 即输入层权值 α_{kj} , $1 \leq k \leq m, 1 \leq j \leq p$; 隐层激活函数 f_k , $1 \leq k \leq m$ 和输出层权值 β_{ik} , $1 \leq k \leq m, 1 \leq i \leq q$ 这 3 类

定义一个最小化损失函数 L_2 , 则参数的估计可由最小化原则求得:

$$L_2 = \sum_{i=1}^q \omega_i E \left| y_i - \sum_{k=1}^m \beta_{ik} f_k \left| \alpha_k^T \mathbf{X} \right| \right|^2 \quad (5)$$

式中, ω_i 为第 i 类输出误差的方差相对于总体损失函数 L_2 的相对贡献率, $E[\cdot]$ 为数学期望运算。

PPLN 计算的基本思路是把全体参数分成 m 组, 即 α_k , $1 \leq j \leq p$, β_{ik} , $1 \leq i \leq q$ 及 f_k 划入一组, $k = 1, \dots, m$, 共有 m 组。固定其中 $m - 1$ 组, 而对剩下的一组 (设第 k_0 组) $\alpha_{k_0}, \beta_{ik_0}, f_{k_0}$ 进行优化。此时, 再将该组分为 3 个子组 $\left| \alpha_{k_0}, j = 1, \dots, p \right|, f_{k_0}, \left| \beta_{ik_0}, i = 1, \dots, q \right|$, 分别固定其中的两个子组, 对第 3 子组求最优, 再把该子组参数值作为初值, 另选一子组参数在这一初值下求最优。整个优化过程分为两层循环交替进行, 多次重复, 直到误差满足精度要求为止。参数 α_k, f_k 和 β_{ik} 的迭代更新按照下述方法进行^[12]:

- 1) 设 $k = 1$ 给 $\alpha_k, f_k, \beta_{ik}$ 赋初值;
- 2) 先固定 f_k, β_{ik} , 更新 $\hat{\alpha}_k$, 计算公式为

$$\sum_{i=1}^q \omega_i E \left| \frac{\partial^2 u_i}{\partial \alpha_k^2} u_i + \left| \frac{\partial u_i}{\partial \alpha_k} \right|^T \left| \frac{\partial u_i}{\partial \alpha_k} \right| \right| \Delta =$$

$$-\sum_{i=1}^q \omega_i E \left| \left| \frac{\partial u_i}{\partial \alpha_k} \right|^T u_i \right| \quad (6)$$

式中, $u_i = R_{i(k)} - \beta_{ik} f'_k(\alpha_k^T X)$; $\hat{\alpha}_k = \alpha_k + \Delta$ Δ 为参数 α 的增量, $R_{i(k)} = y_i - \sum_{l=k}^q \beta_{il} f'_l(\alpha_l^T X)$, $\frac{\partial u_i}{\partial \alpha_k} = -\beta_{ik} f'_k(\alpha_k^T X)$, $\frac{\partial^2 u_i}{\partial \alpha_k^2} = -\beta_{ik} X^T \times f''_k(\alpha_k^T X)$ 。 f'_k 与 f''_k 分别表示求函数 f_k 的一阶与二阶导数。解出 Δ 后, 以 $\hat{\alpha}_k$ 替代 α_k , 重复迭代, 直到满足设定精度。

3) 由所得的 $\hat{\alpha}_k$, 通过 2 维散点数据 $(z_{kl}, \hat{f}_k | z_{kl})$ 拟合逼近隐层激活函数 \hat{f}_k , 计算公式为

$$\hat{f}_k | \alpha_k^T X | = \frac{\sum_{i=1}^q \omega_i \beta_{ik} R_{li(k)}}{\sum_{i=1}^q \omega_i \beta_{ik}^2} \quad (7)$$

其中, $Z_{kl} = \alpha_k^T X_l$ 。

4) 重复步骤 2) ~ 3), 进行若干次迭代;

5) 给定 f_k 和 α_k , L_2 是 β_{ik} 的二次函数, 由最小二乘法直接得到 β_{ik} 估计 $\hat{\beta}_{ik}$ 的计算公式:

$$\hat{\beta}_{ik} = \frac{E \left| R_{i(k)} f_k | \alpha_k^T X | \right|}{E \left| f_k | \alpha_k^T X | \right|^2} \quad i = 1, 2, \dots, q \quad (8)$$

6) 重复步骤 2) ~ 5), 直到 L_2 满足一定的精度要求;

7) 令 $k = k + 1$ 转步骤 1)。

当所有 m 组参数均优化后, 计算由式 5) 中定义的损失函数 $L_2^{(old)}$, 重复上述步骤 1) ~ 7), 计算损失函数 $L_2^{(new)}$, 不断重复优化 m 组参数, 直到 $|L_2^{(new)} - L_2^{(old)}| / L_2^{(old)}$ 满足一定的阈值 ξ (本文 $\xi = 0.005$)。

3 可视化评价非线性分解模型

3.1 数据预处理

实验数据为三峡地区的 MODIS 影像, 该影像获取时间为 2002 年 4 月 2 日。选取了空间分辨率为 485 5 m 的 6 个波段进行实验, 主要的地物类型为城市、水体、植被和裸土或稀疏植被。图 1 所示的是一块大小为 200×200 假彩色合成影像, 主要地物类型为城市、水体、植被和裸土或稀疏植被。验证数据为同一天获取的 ETM+ 数据。ETM+ 的空间分辨

率为 28.5 m, 相对 MODIS 的精度非常高。因此, 假设 ETM+ 影像相对 MODIS 分辨影像的精度不存在混合像元, 则 ETM+ 的地物硬分类的结果可以折算为低分辨影像中该对应地物的组占比。



图 1 MODIS 实验数据

Fig 1 Experimental data MODIS image

利用多源数据获取低分辨影像组占比的主要步骤如下:

1) 多源影像配准 采用相对或绝对的方式配准高分辨与低分辨影像。

2) 典型区域选择 选择影像中有代表意义的部分区域, 包含影像中所有的地物类型。

3) 高分辨分类 对高分辨影像分类后, 重采样分类图, 使得与低分辨影像空间精度恰好相差整数倍 N 。

4) 统计百分比 开辟大小为 $N \times N$ 的窗口, 统计窗口内各类地物所占的百分比, 即为低分相应辨影像的组占比。

由于 MODIS 与 ETM+ 影像的空间分辨率相差大约 17 倍, 为了能够使得配准比较精确, 先把低分辨 ETM+ 影像采样放大 17 倍, 这使得两影像的像元面积大小一致。再在两影像中选择了以道路、桥

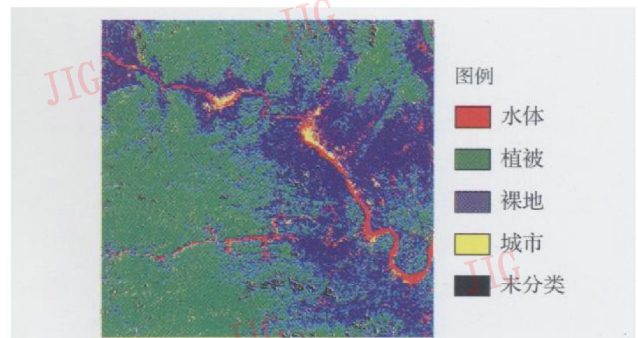


图 2 ETM+ 分类图

Fig 2 Classified map of ETM+ image

梁、河流交叉处等特征点作为影像相对控制点,并保证这些控制点的分布大致均匀。以 ETM+ 为基影像,用最邻近重采样法把影像 MODIS 配准到 ETM+,再用平均滤波的方法把 MODIS 采样为 200×200 大小的影像,这样就保证了 ETM+ 与 MODIS 影像地面分辨率正好相差 17 倍,且各点配准误差均较小,总体 RMS 为 0.47 个像素。对云层进行掩膜处理后,先采用计算机自动分类方法把 ETM+ 为 6 类,最后进行合并为 4 大类:包括水体、植被、裸地或稀疏植被和城区。这样保证 ETM+ 分类精度相对较高,分类结果如图 2 所示。经统计 ETM+ 影像的总体分类精度达到 89.6%, kappa 系数为 0.8566 其中水体、植被、裸地和城区分类精度分别为 92.9%, 86.4%, 85.8% 和 90.32%。这表明,利用 ETM+ 来获取低分辨 MODIS 数据的组分值,并作为“真实组分”来

评价 PPLN 模型分解效果具有合理性。

3.2 可视化评价分解结果

用一个 17×17 的滑动窗口扫描 ETM+ 分类影像,统计窗口内每类地物所占百分比作为相应地物的真实组分值。经过试验,本文 PPLN 的网络拓扑结构设计为 6-10-4 的 3 层结构。由于 PPLN 需要训练学习过程中的参数,因此,每类中都随机选取了 200 个影像点的组分值作为训练样本进行实验。PPLN 训练完成以后,再对其余的数据进行分解,得到组分影像及误差如图 3 所示,从左至右分别为水体、植被、土壤、城区以及误差影像。图 3 中显示亮的部分代表该地物所占的百分比例高,反之代表所占的百分比例低。比较这 4 幅组分图与原始图像,发现提取出来的组分地物都符合实际情况。误差影像分布没有明显的结构信息,这表明 PPLN 分解效果良好。




图 3 MODIS 分解结果以及误差图

Fig 3 Fractional images and error image

由于人眼对灰度影像分辨力的限制,难以从中定量、直观地了解分解误差的大小及空间分布关系。因此图 4 对误差影像进行了 3 维可视化的显示与表达。图 4 中表明绝大部分的像元点分解误差值比较小,只要少部分的数据点分解误差大于 0.5 个别数据点误差大于 1.0 产生了较大的误差,一个可能的原因是由于这些点本身具有很大的噪声。这表明,PPLN 算法不对噪声点过拟合,因而具有较强的抗噪能力。

为了可视化表示研究区域内组分影像的“像元混合程度”,首先需要对 PPLN 分解结果进行预处理,以保证组分影像值范围在 $[0, 1]$ 之内,并且每个混合像元的组分值之和为 1。本文简单地把组分值小于 0 的设置 0 把大于 1 的直接赋值为 1 并对组分值进行拉伸处理,以满足各像元点的组分值之和为 1。然后按照式 (3) 计算每个混合像元组分值的整体相关度,如图 5 所示。




图 4 误差影像的 3 维可视化显示

Fig 4 3D visualization of error image




图 5 像元混合程度模式

Fig 5 The patterns of pixel mixture degree

根据上文对该指标的分析,图 5 在一定意义上表示了地物的相对混合程度。图 5 表明混合程度最大的地方是城区,然后是发生在稀疏植被覆盖区,而茂密植被与水体的混合程度相对较小,这与实际情况相符合。比如,城区本身一般是综合的实体,包含诸如混凝土结构物,植被和水体等地物,因此,混合程度较高,而水体等较简单地物类型比较单一,光谱纯净度相对较高,因此混合程度较低。

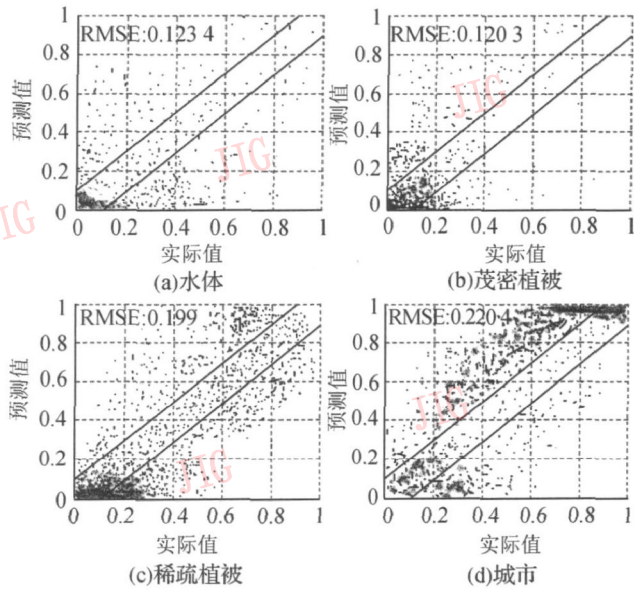


图 6 PPLN 的 BDF 精度评价

Fig 6 Accuracy assessment with BDF

为了定量直观地评价 PPLN 分解的效果,本文进一步采用 BDF 评价方法。图 6 为所绘制的 PPLN 的 BDF 图,并统计出各地物的均方根误差,列于各图的左上角。一般来说,良好估计的 BDF 图的散点应当位于 $y=x$ 的直线上,但由于估计误差和一些其他因素的影响,估计值与真实值应该在 $y=x$ 的直线左右波动。图 6 中上下两条平行直线是给定的 10% 容忍分解误差边界。它的含义是落在两条平行线之间的点数越多,则分解的效果越好。从图 6 可以看出,这 4 种地物大部分的点都落在 20% 的范围内。




图 7 比较 BPNN 与 PPLN 方法的分解结果

Fig 7 Comparisons of fractional RMSE errors between BPNN and PPLN algorithm

图 7 是 BPNN 与 PPLN 两种方法对 4 种地物分解的均方值误差的比较,可以看出 PPLN 分解的 4 种地物的均方值误差都比 BPNN 小,总体误差从 0.1828 降低到 0.1717,降低了大约 6.5%。由于图 7 给出的均方根误差不能反映出估计值与真实值在不同误差边界内的估计值与真实值之间相符合的数量情况。因此,本文使用误差边界置信度曲线来评价 PPLN 模型分解的精度,该方法能够可视化表示分解精度在不同容许误差边界内的分布情况。

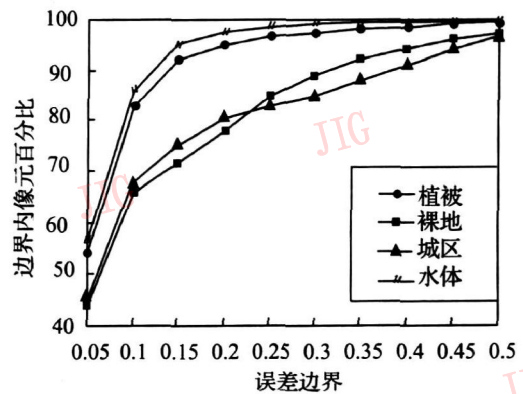


图 8 误差边界置信度曲线

Fig 8 Correct percentage curve within error bounds

图 8 是某影像分解后水体,土壤,植被与城区的置信度估计曲线,从图 8 中可以看出,随着误差边界的扩大,位于误差边界内的像元数量迅速增加。其中对水体与植被两种地物,有 90% 以上的像元在 0.15 的误差边界内,因而分解精度比较高。对于裸地和城区,要保证 80% 的像元在误差边界内需要使用超出 0.2 的误差边界,因而分解精度相对较低。这与图 6 的结果分析一致。

4 结 论

可视化及定量表达混合像元分解结果是一个重要研究方向。本文提出均方根误差、置信度估计、双变量分布函数以及综合表示组分影像等可视化评价方法,并对 MODIS 影像混合像元的分解结果进行了可视化的表达与分析。结果表明,可视化评价在一定程度上能够了解非线性模型分解的特点。误差可视化表明 PPLN 算法对噪声点不存在过拟合,具有较强的抗噪能力。组分影像的综合可视化表明混合程度较大的区域发生在城区和稀疏植被覆盖区,而混合程度较低的区域是水体等内部比较单一的地

物。此外, PPLN 分解的 4 种地物的均方根误差都比 BPNN 低, 且总体误差从 0.1828 降低到 0.1717, 降低了大约 6.5%。就 4 种地物本身, 水体分解精度最高, 其次为植被, 再次为裸地, 最差是城区。

参考文献 (References)

- [1] Wu Bq, Zhang Liang-Pei, Li Ping-xiang. Unmixing of hyperspectral imagery based on support vector nonlinear approximating regression [J]. *Journal of Remote Sensing*, 2006, 10(3): 186-193. [吴波, 张良培, 李平湘. 基于支撑向量回归的高光谱混合像元非线性分解 [J]. *遥感学报*, 2006, 10(3): 186-193.]
- [2] Atkinson P M, Tattnall A R L. Introduction neural networks in remote sensing [J]. *International Journal of Remote Sensing*, 1997, 18(4): 699-709.
- [3] Zhang Yan, Shao Mei-zhen. Mixed image cell decomposition based on radial-basis function neural networks [J]. *Journal of Remote Sensing*, 2002, 6(4): 285-289. [张彦, 邵美珍. 基于径向基函数神经网络的混合像元分解 [J]. *遥感学报*, 2002, 4(4): 285-289.]
- [4] Carpenter G, Gopal S, Macomber S et al. A neural network method for mixture estimation for vegetation mapping [J]. *Remote Sensing of Environment*, 1999, 70(2), 138-152.
- [5] Liu Li-fan, Wang Bin, Zhang Liming. Decomposition of mixed pixels based on bayesian selforganizing map and gaussian mixture model [J]. *Journal of ComputerAided Design & Computer Graphics*, 2007, 19(11): 1381-1386. [刘力帆, 王斌, 张立明. 基于贝叶斯自组织映射和高斯混合模型的混合像元分解 [J]. *计算机辅助设计与图形学学报*, 2007, 19(11): 1381-1386.]
- [6] Jacobson N P, Gupta M R. Design goals and solutions for display of hyperspectral images [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(11): 2684-2692.
- [7] Wessels J, Buchheit M, Espeset A. The development of a high performance high volume distributed hyperspectral processor and display System [C] // *Proceedings of the IEEE Geosci and Remote Sens Symp Toronto, Canada*. IEEE Press, 2002, 4: 2519-2521.
- [8] Tyo J S, Konsolakis A, Diersen D J et al. Principal components-based display strategy for spectral imagery [J]. *IEEE Transactions Geoscience and Remote Sensing*, 2003, 41(3): 708-718.
- [9] Cai S, Du Q, Moorhead R J. Hyperspectral imagery visualization using double layers [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2007, 45(10): 3028-3036.
- [10] Wu Bq, Zhang Liang-pei, Li Ping-xiang. Unsupervised orthogonal subspace projection approach to unmix hyperspectral imagery automatically [J]. *Journal of Image and Graphics*, 2004, 9(11): 1392-1396. [吴波, 张良培, 李平湘. 非监督正交子空间的高光谱混合像元自动分解 [J]. *中国图象图形学报*, 2004, 9(11): 1392-1396.]
- [11] Kennedy L M, Basu M. Application of projection pursuit learning to boundary detection and deblurring in images [J]. *Pattern Recognition*, 2000, 33(12): 2019-2031.
- [12] Hwang J N, Lay S R, Martin B M. Regression modeling in back-propagation and projection pursuit learning [J]. *IEEE Transactions on Neural Networks*, 1994, 5(3): 342-351.