

文章编号: 1007-4619 (2002)04-285-04

基于径向基函数神经网络的混合像元分解

张 彦¹, 邵美珍²

(1. 北京大学 数学学院, 视觉与听觉信息处理国家重点实验室, 北京 100871; 2. 信息工程大学信息科学系, 郑州 450002)

摘 要: 遥感图像中普通存在着混合像元, 对这部分像元进行分类(即混合像元分解)是遥感图像处理中的难点。基于主分量分析的混合像元分解算法是一种较为成熟的算法, 但它存在着计算量大, 适应性差等缺点。在深入研究混合像元分解原理的基础上, 提出了用径向基函数神经网络拟合分解结果超平面, 以实现混合像元分解的算法, 实验结果证明: 该算法的结果与基于主分量分析的混合像元分解算法结果相近(相关系数达到 0.99), 而计算量大大减少, 具有较强的适应性。

关键词: 混合像元; 主分量分析; 径向基函数神经网络; 曲面拟合(近似)

中图分类号: TP751.1 **文献标识码:** A

1 引 言

在一幅遥感图像中有许多像元都包含有若干表面覆盖类(标准地物)^[1]。这类像元称为混合像元, 对这类像元的分类问题, 即混合像元分解问题, 是遥感图像分类中的一个难点,

基于主分量分析的混合像元分解算法^[2]是解决混合像元分解问题的一种常用算法, 该算法物理意义明确, 易于理解, 但由于该算法要对整个待处理图像进行主分量分解, 所以运算量较大。并且, 即使原处理图像有少许变化, 也需要重新对整幅图像进行主分量分解, 适应性较差。

本文提出了一种基于径向基函数神经网络的混合像元分解算法。该算法利用径向基函数神经网络的自学习功能拟合出像元中每个标准地类所占面积比的超平面, 从而得到混合像元分解结果。实验证明, 该算法结果与基于主分量分析法的结果相近(相关系数达到 0.99), 而计算量大大减少, 同时适应性大大提高。

2 径向基函数神经网络的插值理论^[3]

径向基函数神经网络的网络结构(以一维输出为例)为图 1。




图 1 径向基函数神经网络结构图

Fig.1 Architectural graph of radial-basis function networks

其中, B_1, B_2, \dots, B_n 为输入值。隐含层为径向基函数单元, 输入到输出为线性权值 \vec{w} 。那么这个网络可以实现从输入空间到隐层空间的非线性映射, 及从隐层空间到输出空间的线性映射。设 n 表示输入空间的维数, 那么整个网络实现的就是从 n 维输入空间到一维输出空间的映射函数, 可以写为:

$$s: R^n \rightarrow R^1$$

我们可以将映射 s 看作是一个超曲面 $\Gamma \subset R^{n+1}$, 曲面 Γ 是一个多维输入函数的输出点图。则:

(1) 网络的训练过程可以看成是根据提供给网络的训练样本对曲面 Γ 的拟合过程。

(2) 网络的泛化过程可以看成是在数据间进行插值, 使由拟合过程形成的曲面与真实曲面 Γ 最为近似。

这样径向基函数神经网络的训练过程实际是高维空间中的曲面拟合及泛化过程。

3 基于主分量分析的混合像元分解算法的理论分析

基于主分量分析的混合像元分解算法^[2]的假设条件是:

(1) 每一种标准地物的光谱是一个该地物的纯像素的光谱。

(2) 混合像元的光谱是各种标准地物光谱的线性叠加。

一幅遥感图像在数学上可以表现为 $r \times c$ 维矩阵, 其中: $[D]$ 表示反射率, c 表示时相或波段数, r 表示像素数目。

$$[D] = \begin{bmatrix} d_{11} & d_{12} & \cdots & d_{1c} \\ d_{21} & d_{22} & \cdots & d_{2c} \\ \vdots & \vdots & \ddots & \vdots \\ d_{r1} & d_{r2} & \cdots & d_{rc} \end{bmatrix} \quad (1)$$

基于主分量分析的混合像元分解算法的过程实际上是先求出像素空间的基向量, 然后进行线性旋转, 将基向量旋转为标准地物光谱向量, 这样将像素空间变换到标准地物空间。

$$[D] = [R]_{\text{rel}} [C]_{\text{rel}} \quad (2)$$

其中 $[R]_{\text{rel}}$ 的每个行向量表示每一个像素包含各种标准地物的面积系数, $[C]_{\text{rel}}$ 表示遥感图像上的标准地物光谱组成的矩阵, 第 i 个像素点可以写成下面的形式:

$$\vec{d}_i = r_{i1} \vec{c}_1 + r_{i2} \vec{c}_2 + \cdots + r_{in} \vec{c}_n \quad (3)$$

如果将第一个线性组合系数作为一个坐标轴, 定义为 r_1 , 标准地物光谱 $\vec{c}_1, \vec{c}_2, \cdots, \vec{c}_n$ 作为其他的坐标轴, 因为图像上每个点可以用 $\vec{c}_1, \vec{c}_2, \cdots, \vec{c}_n$ 表示, 每个点的 r_1 值都是第一个坐标轴 \vec{c}_1 , 对应的坐标值, 那么图像上所有点对应的第一个坐标值 r_1 均在一个通过原点的 $n+1$ 维的超平面上, 如图 2 中边框加重平面所示(以三维为例):




图 2 超平面示意图

Fig.2 Hyperplane sketch map: the bold frame plane(three dimensions)

那么, 如果能得到这个超平面, 也就得到了每个像元包含第一种标准地类的面积比, 这样就得到了混合像元的分解结果。

径向基函数神经网络可以拟合各种曲面, 由于确定超平面需要的条件较少, 例如在三维空间中三点即可确定一个平面, 如果选取的训练样本能够使网络的训练结果为我们期望得到的超平面, 我们可能用很少的样本就可以得到正确的输出结果, 那么就可能用较简单的方法解决混合像元分解问题。

4 基于径向基函数神经网络的混合像元分解算法

4.1 网络结构及训练算法的选取

径向基函数神经网络的结构如图 1 所示, 本文使用的是 OLS^[4] 训练算法, 该算法在给出训练样本及中间隐层单元的感受野宽度后, 能够确定中间隐层单元的个数及网络权值。

4.2 训练样本及其个数的选取

与基于主分量的混合像元分解算法相同, 首先选择出标准地物光谱。标准地物光谱的选择方法为: 根据伪彩色图像中地形与颜色信息选取各个类别纯样本点的集合, 再对这些集合进行纯化处理, 选择出纯样本点, 纯样本点的各个波段数值构成标准地物光谱向量。例如水体的标准样本是选定北京郊区某一湖泊中心的一部分图像后, 取出该区域像素的各个波段的数据, 选择光谱值相同的最多的像素作为水体的标准样本。

在选择好标准光谱后, 按照标准光谱的线性组合形成训练样本。

例如:

$$P = RC = \begin{bmatrix} 1 & 0 & 0 \\ 0.1 & 0.3 & 0.6 \\ 0.5 & 0.5 & 0 \end{bmatrix} \begin{bmatrix} \vec{c}_1 \\ \vec{c}_2 \\ \vec{c}_3 \end{bmatrix} \quad (4)$$

其中 P 表示训练样本矩阵, R 表示线性组合系数也是目标矩阵, C 表示标准光谱矩阵, \vec{c}_i 表示标准光谱向量。因为我们要拟合的是超平面, 理论上需要矩阵 R 的秩是空间的维数就够了, 当然样本点数越多效果越好。

4.3 算法的具体步骤为:

(1) 选用径向基函数神经网络, 网络的输入层的单元个数为遥感图像波段数, 输出层个数为标准地类的

个数,分别表示每个像元包含每种标准地类的面积比。

(2) 采用各种标准地物光谱的线性组合作为神经网络的训练样本,目标函数为相应的线性组合系数。选择合适的感受野宽度,采用 OLS 算法训练网络。

网络训练结束后,将每个像素的波段值输入网络,得到的输出即为分解结果。

5 算法实验结果及两种算法实验结果比较和理论分析

5.1 基于神经网络的混合像元分解算法实验结果

以北京市 TM 图像中的两块图像(图版 I 图 3(a)(69 * 78 像素),图版 I 图 4(a)(57 * 69 像素))为实验数据,假设图像包含 3 种标准地类:水体,绿地,建筑。其中线性组合系数为矩阵 R ,感受野宽度为 100,得到分解结果,如图版 I 图 3,图 4 所示。

$$R = \begin{bmatrix} 1 & 0 & 0 & 0.5 & 0.1 & 0.1 \\ 0 & 1 & 0 & 0.5 & 0.3 & 0.1 \\ 0 & 0 & 1 & 0 & 0.6 & 0.1 \end{bmatrix}^T$$

5.2 两种算法实验结果比较及理论分析

表 1 是分别用基于主分量分析的混合像元分解算法^[2]与基于径向基函数神经网络的混合像元分解算法处理这两幅图像,得到分解结果后,计算二者的相关系数得到的结果。

表 1 两种算法分解结果相关系数

Table 1 The correlation coefficients between results of two algorithms

训练样本组合系数	α	相关系数		
		图版 I 图 3(a)	图版 I 图 4(a)	
[1, 0, 0; 0, 1, 0; 0, 0, 1; 0.1, 0.3, 0.6]	100	W	0.9515	0.9813
		A	0.9770	0.9914
		G	0.9241	0.8683
[1, 0, 0; 0, 1, 0; 0, 0, 1; 0.5, 0.5, 0; 0.1, 0.1, 0.1]	1000	W	0.9554	0.9829
		A	0.9924	0.9958
		G	0.9886	0.9710
[1, 0, 0; 0, 1, 0; 0, 0, 1; 0.5, 0.5, 0; 0.1, 0.1, 0.1]	100	W	0.9547	0.9898
		A	0.9749	0.9907
		G	0.9546	0.9343
[1, 0, 0; 0, 1, 0; 0, 0, 1; 0.5, 0.5, 0; 0.1, 0.1, 0.1]	1000	W	0.9992	1.0000
		a	0.9997	0.9999
		g	0.9996	0.9996

表 1 中,两种算法的标准地物光谱是一样的, α 表示神经网络感受野宽度,训练样本是由训练样本组合系数矩阵乘以 3 个标准地物样本组成的矩阵构成的,其目标矩阵是相应的组合系数。相关系数计算公式为:

$$cor = \frac{\vec{x}^T \vec{y}}{\|\vec{x}\| \|\vec{y}\|}$$

表中 W 表示两种算法得到的相同像元包含水体面积比的相关值, A 表示两种算法得到的相同像元包含建筑面积比的相关值, G 表示两种算法得到的相同像元包含绿地面积比的相关值。

通过实验结果我们可以看出影响结果的因素有两个:

训练样本 样本要足够多,才能使网络拟合出所要的超平面,表 1 中第一栏中训练样本有 4 个,第二栏训练样本有 6 个,从相关系数上可以看出第二栏的结果要比第一栏的结果好。这个结果也是可以理解的,因为曲线上的已知点越多那么拟合误差就会越小。

感受野宽度 当训练样本足够多时,感受野宽度就成为影响结果的重要因素。从实验结果上可以看出对第二种组合系数,感受野宽度为 1000 时相关系数就很高了。对于径向基函数神经网络,用 OLS 算法对网络进行训练时,训练样本和感受野宽度是需要确定的。当感受野宽度过大时就会出现过拟合现象,而因为我们要拟合的曲面是超平面,过拟合现象反而可以帮助我们拟合出所要的超平面,实验结果也证明了这一推理。

6 结 论

实验结果及理论分析均表明,当训练样本足够多,感受野宽度选择较大时,用神经网络算法可以得到与基于主分量分解的混合像元分解算法相近的结果。神经网络算法具有以下优点:

(1) 网络结构简单,计算量小。因为要拟合的是一个超平面,所以需要的样本点是较少的,网络结构简单,训练速度快。当网络训练结束后,求解的过程就是已知函数,给出输入求输出的过程,计算量也很小。以图 1 为例,用基于主分量分析的混合像元分解算法处理需要 2.22×10^3 CPU(赛扬 333) 时间,而用基于径向基函数神经网络的混合像元分解算法得到相近结果(相关系数 0.99) 需要 22.42 CPU(赛扬 333) 时间。

(2) 适应性好。与基于主分量分析的混合像元

分解算法不同,只要标准地物光谱不变,图像大小的变化对已经训练好的神经网络没有影响。

本文在详细分析了基于主分量分析的混合像元分解算法原理的基础上,提出了基于径向基函数神经网络的混合像元分解算法,该算法能够拟合出分解结果超平面,而得到分解结果。实验证明,基于径向基函数神经网络的混合像元分解算法可以得到与基于主分量分析的混合像元分解算法非常相近的结果,而计算复杂度大大降低。

参 考 文 献 (References)

[1] Zhu Shulong, Zhang Zhan. Acquisition and Analysis of Remote Sens-

ing [M]. Beijing: Science Press, 2000. [朱述龙,张占.遥感图像获取与分析[M].北京:科学出版社,2000.]

[2] Shao Meizhen, Deng Guanglin. Mixed Image Cell Decomposition Based on Principle Component Analysis [J]. *Chinese Space Science Technology*, 1989, 2:51-56. [邵美珍,邓广林.基于主成分分析的混合像元分解.中国空间科学技术,1989,2:51-56.]

[3] Simon Haykin. *Neural Networks: A Comprehensive Foundation* [M]. New York: McMillan Press, 1994.

[4] Chen S, Cowan C F N, Grant P M. Orthogonal Least Squares Learning Algorithm for Radial Basis Function Networks [J]. *IEEE Trans. Neural Networks*, 1991, 2(2):302-309.

Mixed Image Cell Decomposition Based on Radial-basis Function Neural Networks

ZHANG Yan¹, SHAO Mei-zhen²

(¹. School of Mathematical Science of the Peking University, National Laboratory on Machine Perception, Beijing 100871, China;

². Department of Information Science, University of Information Engineering, Zhengzhou 450002, China)

Abstract: Remote sensing images contain a lot of mixed image cells, and it is difficult to classify these cells. Mixed image cells decomposition algorithm based on principle component analysis is a widely used algorithm, but the large computation amount and less flexibility are its main drawbacks. By researching the curve-fitting (approximation) theory of the radial-basis function neural networks, and the principles of the mixed image cells decomposition algorithm based on principle component analysis, the paper proposes a new decomposition algorithm, which uses the radial-basis function neural networks to fit (approximate) the hyperplane of the decomposition results of the principle component analysis algorithm. Experimental results prove that the results of the new algorithm are almost the same with the results of the principle component analysis algorithm (correlation coefficients are above 0.99). However, the new algorithm has much less computation complexity and more flexibility than the principle component analysis algorithm.

Key words: mixed image cells; principle component analysis; radial-basis function neural networks (RBFN); curve-fitting (approximation)

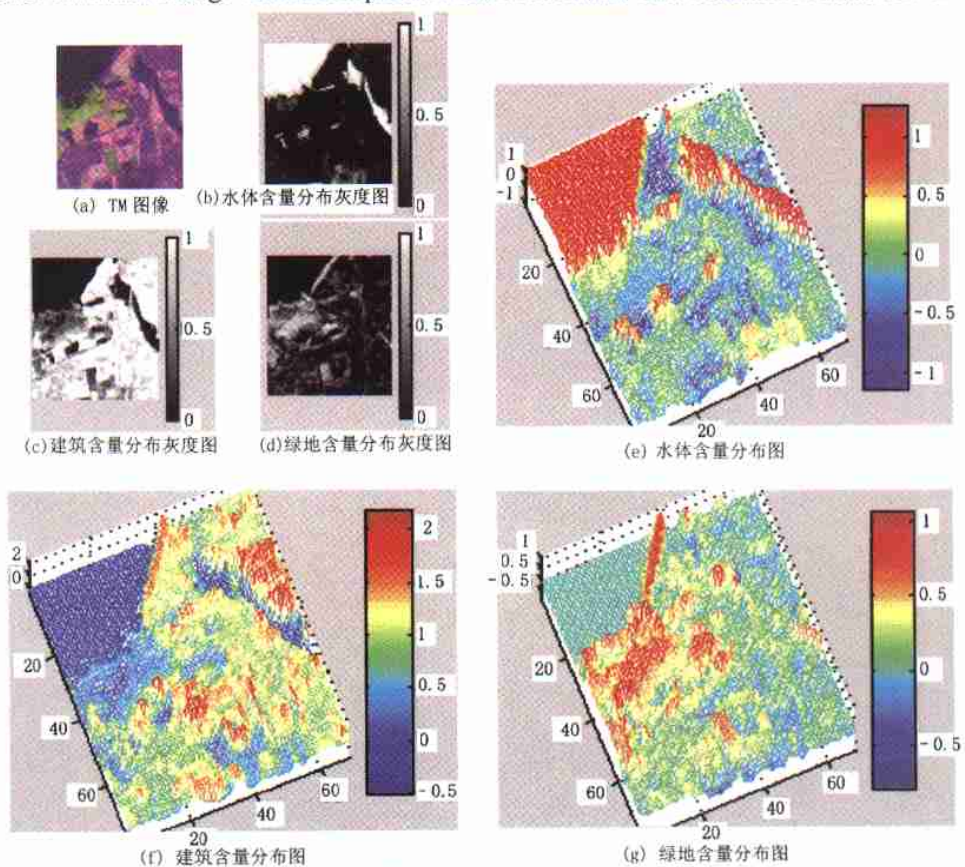


图 3 北京某水库地区 TM 图像混合像元处理结果

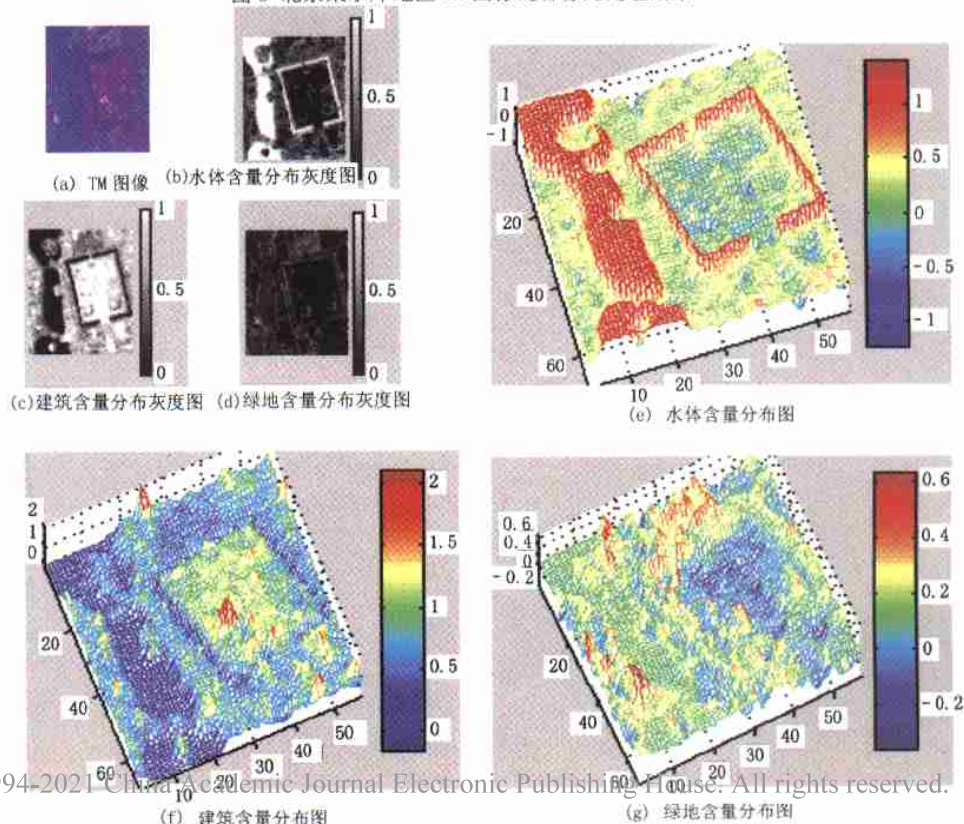


图 4 北京天安门地区 TM 图像混合像元处理结果