

文章编号 1004-924X(2014)06-1668-09

应用相关近邻局部线性嵌入算法的 高光谱遥感影像分类

刘嘉敏, 罗甫林*, 黄 鸿, 刘亦哲

(重庆大学 光电技术及系统教育部重点实验室, 重庆 400044)

摘要:传统的局部线性嵌入(LLE)算法需用欧氏距离度量近邻,但欧氏距离只表示两点间的直线距离,在高维空间中不一定能反映数据间的真实空间分布,导致近邻选取不稳定。针对此问题,本文提出了相关近邻(CN)LLE(CN-LLE)和相关最近邻分类(CNN)算法。提出的算法首先利用相关系数度量数据间的近邻,实现更准确的局部重构,提取鉴别特征;然后用 CNN 对低维嵌入特征进行分类。在 KSC 和 Indian Pine 高光谱遥感数据集上的地物分类实验结果表明:本文提出的 CN-LLE+CNN 算法比 LLE、LLE+CNN 和 CN-LLE 等算法的总分类精度提升了 2.11%~11.55%,Kappa 系数提升了 0.026~0.143。由于该算法增加了近邻为同类的概率,便于更有效地提取同类数据的鉴别特征,且有更好的稳定性,故能更有效地实现高光谱遥感数据的地物分类。

关键词:高光谱影像分类;流形学习;局部线性嵌入;相关近邻;相关最近邻分类器

中图分类号:TP751.1 **文献标识码:**A **doi:**10.3788/OPE.20142206.1668

Classification of Hyperspectral remote sensing images using correlation neighbor LLE

LIU Jia-min, LUO Fu-lin*, HUANG Hong, LIU Yi-zhe

(Key Laboratory of Optoelectronic Technique System of the Ministry of Education,
Chongqing University, Chongqing 400044, China)

* Corresponding author, E-mail: luofl@cqu.edu.cn

Abstract: Traditional Locally Linear Embedding (LLE) manifold learning algorithm uses Euclidean distance to measure neighbor points. However, Euclidean distance represents the straight line distance between two points and does not necessarily reflect the actual data distribution in a high dimension space, which leads to the instability of neighbor point selection. In order to solve this problem, an algorithm based on Correlation Neighbor LLE (CN-LLE) and Correlation Nearest Neighbor (CNN) classification is proposed. This algorithm uses the correlation coefficient of data to measure the neighbor points and to achieve more effective local reconstruction to extract the distinguishing character. Then, it uses the CNN to classify the reduced dimension data. The experiment results from KSC and Indian Pine hyperspectral remote sensing data sets show that the total accuracy of the proposed CN-LLE+CNN algorithm is improved by 2.11%–11.55% and the Kappa coefficient is im-

收稿日期:2013-07-12;**修订日期:**2013-09-10.

基金项目:国家自然科学基金资助项目(No. 61101168, No. 41371338);中国博士后科学基金资助项目(No. 2012M511906, No. 2013T60837);重庆市博士后科研特别资助项目(No. XM2012001),中央高校基本科研业务费专项资金资助项目(No. CDJXS12120001, No. 106112013120004, No. 106112013120007)

proved 0.026—0.143 as compared with those of LLE, LLE+CNN and CN-LLE. The CN-LLE+CNN algorithm increases the probability of the same class neighbor, can extract the distinguishing characters of the same data effectively and has a better stability. This algorithm can effectively classify hyperspectral remote sensing data of ground objects.

Key words: hyperspectral image classification; manifold learning; Locally Linear Embedding (LLE); Correlation Neighbor(CN); Correlation Nearest Neighbor(CNN) classifier

1 引言

高光谱图像可以提供十分详尽精确的地物光谱信息,给地物分类识别带来了机遇。但由于其具有冗余度大、相关性强、维数高等特点,容易使传统地物分类方法陷入维数灾难^[1-3]。因此,如何有效地提取特征以实现地物分类成为高光谱遥感影像研究的关键。

Bachmann 等^[4]指出高光谱遥感数据具有内在的非线性结构。传统的地物特征提取方法主要有:主成分分析(Principal Component Analysis, PCA)、线性鉴别分析(Linear Discriminant Analysis, LDA)、最小噪声分离(Minimum Noise Fraction, MNF)、独立成分分析(Independent Component Analysis, ICA)等,这些方法都是假设数据为线性结构,在不同优化准则下寻求数据最佳线性模型^[5],它们均无法揭示出高光谱遥感数据的非线性结构。

在高维数据非线性结构的研究中,学者们提出了流形学习,主要方法有:等距映射(Isometric Feature Mapping, ISOMAP)、拉普拉斯特征映射(Laplacian Eigenmaps, LE)、局部线性嵌入(Local Linear Embedding, LLE)等。Chen Y C^[6]等人把 ISOMAP 用于数据处理,Qian^[7]等人利用 LLE、LE 提取特征,这些方法都很好地揭示出了高光谱数据的低维非线性结构,即流形结构,对地物分类具有很好的效果,但受近邻选取方式的影响较大。文献[8]认为传统的多维尺度分析算法(Multidimensional Scaling, MDS)是由欧氏距离度量近邻,而文献[9]和[10]提出,高维空间中欧氏距离只表示两点间的直线距离,不一定能真实体现数据间的空间分布关系,非同类数据间的欧氏距离有可能比同类数据间的小,这就有可能把非同类数据作为近邻,从而不能有效地提取出同类数据的鉴别特征,影响分类效果。因而有学者提出了用测地距离度量近

邻的 ISOMAP 算法,从而减小了空间分布影响和噪声干扰,提高了算法的稳定性。

针对以上问题,本文提出了相关近邻 LLE 和相关最近邻分类算法,该方法通过数据间的相关系数度量近邻,提取出低维鉴别特征,然后使用相关最近邻分类器分类。将本文算法用于 KSC 和 Indian Pine 数据集的地物分类实验结果表明其具有更好的分类效果。

2 LLE 算法简介

LLE 算法^[11]的主要思想是将高维空间中各数据点用 k 个近邻点线性表示,在维数简约后保持各数据点与每个对应近邻点的权值不变,重构维数简约后对应数据点,使重构误差最小。该算法的计算步骤如下:

- ① 取与各数据点欧氏距离最小的 k 个点为近邻点;
- ② 用近邻点对各数据点进行重构,保证重构误差最小,得到重构权值;
- ③ 在低维空间中,对各数据点进行重构,即保持重构权值不变,使重构误差最小,得到低维嵌入结果。

LLE 方法需要先找到各数据的近邻,但不同近邻对最终分类效果影响很大。传统方法用欧氏距离得到的近邻很不稳定,且易受噪声影响。

3 本文算法

假设高维空间数据集为 $\mathbf{X}=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]$, 其中 $\mathbf{x}_i (i=1, 2, \dots, N) \in \mathbf{R}_D$, N 为数据点个数,维数简约后的数据为 $\mathbf{Y}=[\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N]$, $\mathbf{y}_i \in \mathbf{R}_d$ 且 $d \ll D$ 。本文用 CN-LLE (Correlation Neighbor Local Linear Embedding) 来表示相关近邻 LLE 算法,用 CNN (Correlation Nearest Neighbor) 表示相关最近邻分类器。

3.1 相关系数理论

相关系数是描述随机变量 X_i 和 X_j 相关程度的指标,相关系数一般用 $\rho(X_i, X_j)$ 表示,取值为 $-1 \sim 1$ 。 $\rho(X_i, X_j)$ 的绝对值越大说明随机变量 X_i 和 X_j 之间的相关性越大;反之,相关性越小。其定义为:

$$\rho(X_i, Y_j) = \frac{E((X_i - E(X_i))(X_j - E(X_j)))}{\sqrt{D(X_i)} \sqrt{D(X_j)}} \quad (1)$$

其中: $D(X_i)$ 、 $D(X_j)$ 分别为随机变量 X_i 和 X_j 的方差, $E(X_i)$ 、 $E(X_j)$ 分别为随机变量 X_i 和 X_j 的期望。

3.2 光谱曲线间的相关系数

高光谱图像中的每个像素都含有数十至数百个波段,由这些波段构成一条反映该像素特征的连续光谱曲线^[12]。设两条光谱曲线 $f(i)$ 和 $g(i)$ ($i=1, 2, \dots, m$) 分别用向量 a 和 b 表示,其中 m 表示波段数。由式(1)可得 2 条光谱曲线的相关系数公式如下:

$$\rho(a, b) = \frac{\sum_{i=1}^m ((f(i) - \bar{f})(g(i) - \bar{g}))}{\sqrt{\sum_{i=1}^m (f(i) - \bar{f})^2} \sqrt{\sum_{i=1}^m (g(i) - \bar{g})^2}} \quad (2)$$

其中: $\rho(a, b)$ 表示光谱曲线 a 和 b 的相关系数, \bar{f} 和 \bar{g} 分别为光谱曲线 a 和 b 的平均值,即:

$$\bar{f} = \frac{1}{m} \sum_{i=1}^m f(i) \quad \bar{g} = \frac{1}{m} \sum_{i=1}^m g(i) \quad (3)$$

$|\rho(a, b)| \leq 1$, 若 $|\rho(a, b)|$ 的值越大,线性相关性越大;反之,相关性小。

由文献[8]可知,欧氏距离在高维空间中不一定能反映数据间的真实分布关系,同类光谱曲线间的欧氏距离可能比非同类更大,并且不能反映数据间的关联性^[13]。而光谱曲线间的相关系数则能反映光谱曲线间的线性相关性,并且同类光谱曲线相似性很大,由此得到的近邻间线性关系更好,重构也更准确,并且属于同类的概率更大,从而使提取的鉴别特征更有效^[14];同时它是一个基于统计特征的量,只反映数据间的相似程度,与数据的空间几何位置无关,因此数据间的空间位置分布对其值影响小,且稳定性好,对噪声敏感度差,非同类数据间的相关系数值差别较大^[15-16]。

图 1(彩图见期刊电子版)为 KSC 高光谱遥感数据中选取的 3 个数据点 a 、 b 和 c ,其中 a 和 b 为同类数据点, c 为另一类数据点。点 a 与点 b 、




图 1 不同类高光谱数据点的光谱曲线

Fig. 1 Spectral curves of different types of hyper-spectral data points

点 c 间的欧氏距离分别为 $D(a, b) = 548.814 2$, $D(a, c) = 488.914 1$; 点 a 与点 b 、点 c 间的相关系数分别为 $|\rho(a, b)| = 0.998 9$, $|\rho(a, c)| = 0.885 3$ 。由此可知,由欧氏距离得到点 a 的近邻为点 c ,由相关系数得到点 a 的近邻为点 b ,因此,相关系数判断更准确。此例也说明了通过相关系数得到近邻为同类的概率比欧氏距离更大。

根据以上分析,本文提出了利用相关系数度量高光谱遥感各数据点的近邻和相关最近邻分类算法,该算法可以减小把非同类数据点判断为近邻的概率,进而使近邻选取稳定性更好,抗噪声能力更强,能更有效地提取同类数据的鉴别特征,改善地物分类效果。

3.3 CN-LLE 算法

CN-LLE 与 LLE 的主要区别是近邻的度量方式,传统 LLE 由欧氏距离度量近邻, CN-LLE 由相关系数度量近邻。其算法过程如下:

① 找出数据点 x_i 的 k 个近邻点。

在高维空间中由式(2)计算出每个数据点 x_i 与其他数据点的相关系数,选取相关系数最大的 k 个点作为近邻点。

② 计算局部重构权值 W 。

高维空间中的 N 个数据点 x_i 可由各自的 k 个近邻点近似线性地表示。通过使数据点 x_i 的重构误差最小来求出局部重构权值 W_i ,其目标函数为:

$$\min \epsilon(W_i) = \sum_{i=1}^N \left\| x_i - \sum_{j=1}^k w_{ij} x_j \right\|^2 \quad (4)$$

其中: w_{ij} 为 x_i 与 x_j 之间的权值,且 $\sum_{j=1}^k w_{ij} = 1$; 若 x_j 为 x_i 的邻近点,则 $w_{ij} \neq 0$; 否则, $w_{ij} = 0$ 。

根据约束条件,对式(4)采用 Lagrange 乘数法可求得局部重构权值 \mathbf{W} 。

③ 计算低维嵌入结果 \mathbf{Y} 。

\mathbf{x}_i 的 k 个近邻降到低维空间后,成为 \mathbf{y}_i 的 k 个近邻,保持局部重构权值 \mathbf{W} 不变,在低维空间中使重构误差最小,求得 \mathbf{y}_i ,其目标函数为:

$$\min \epsilon(\mathbf{y}_i) = \sum_{i=1}^N \left\| \mathbf{y}_i - \sum_{j=1}^N \omega_{ij} \mathbf{y}_j \right\|^2. \quad (5)$$

为得到唯一解,增加约束:(1)使投影后的重心为坐标原点,设置 $\sum_{i=1}^N \mathbf{y}_i = \mathbf{0}$, (2)对降维后的数据点进行归一化,设置 $\frac{1}{N} \mathbf{Y} \mathbf{Y}^T = \mathbf{I}$, \mathbf{I} 为单位矩阵。

由式(5)可得:

$$\min \epsilon(\mathbf{Y}) = \sum_{i=1}^N \left\| \mathbf{Y} \mathbf{I}_i - \mathbf{Y} \mathbf{W}_i \right\|^2 = \text{tr}(\mathbf{Y} \mathbf{M} \mathbf{Y}^T), \quad (6)$$

其中: \mathbf{I}_i 为单位矩阵的第 i 列, \mathbf{W}_i 为数据点 i 的局部重构权值, $\mathbf{W} = [\mathbf{W}_1, \mathbf{W}_2, \dots, \mathbf{W}_N]^T$, $\mathbf{M} = (\mathbf{I} - \mathbf{W})(\mathbf{I} - \mathbf{W})^T$, 且 \mathbf{M} 为对称、半正定矩阵。

据约束条件,对式(6)用 Lagrange 乘数法得:

$$\mathbf{M} \mathbf{Y}^T = \lambda \mathbf{Y}^T, \quad (7)$$

使其降到 d 维空间中。为使重构误差最小,求 \mathbf{M} 的特征值,并舍去几乎为零的特征值,再取 d 个最小的特征值,并把对应的特征向量组成的矩阵作为低维嵌入结果 \mathbf{Y} 。

3.4 相关最近邻分类器(CNN)

传统的最近邻分类器是通过判断新样本与哪种已知样本间欧氏距离最小,从而判断新样本的类别。由前所述,高维空间中非同类数据间的欧氏距离可能小于同类数据;而取相关性作为评价指标,必然存在同类数据间的相关性大,非同类数据间相关性小。因此,本文提出了相关最近邻分类器。

相关最近邻分类器的主要思想是:计算未知类别数据与已知类别数据间的相关系数,得到与未知类别相关系数绝对值最大的已知类别数据所属的类别,则可判断未知类别数据的类别,如式(8)所示:

$$l_i = \max_{j=1}^N |\rho(\mathbf{y}_i, \mathbf{y}_j^{C_j})|, \quad (8)$$

其中: l_i 为 \mathbf{y}_i 所得到的类别; $\mathbf{y}_i (i=1, 2, \dots, n)$ 为未知类别数据, n 为未知数据点个数; $\mathbf{y}_j^{C_j} (j=1, 2, \dots, p)$ 为已知类别数据, p 为已知数据点个数, C_j 为 $\mathbf{y}_j^{C_j}$ 所属的类别。

3.5 算法步骤

本文算法的具体步骤如下:

- (a) 从数据集 \mathbf{X} 中随机选取一定数量的训练样本和测试样本,训练样本的类别已知;
- (b) 利用相关系数构造训练样本点的近邻;
- (c) 利用式(4)计算局部重构权值 \mathbf{W} ;
- (d) 保持局部重构权值不变,利用式(6)计算低维嵌入结果 \mathbf{Y} ;
- (e) 计算测试样本的低维嵌入;
- (f) 利用 CNN 分类器分类,得到测试样本的类别。

4 实验数据

为验证本文方法的有效性,选取 KSC 和 Indian Pine 高光谱遥感数据集进行实验。

4.1 KSC 数据集

KSC 数据集^[17]是由 NASA 在 1996 年 3 月 23 日通过成像光谱仪(AVIRIS)获取的美国 Florida Kennedy 附近的高光谱影像。该影像由海拔 20 km 左右航空飞行获得,地面分辨率为 18 m,大小为 614 pixel \times 512 pixel,光谱为 400 ~ 2 500nm,波段数为 224,如图 2 所示(彩图见期刊电子版)。剔除大气吸收和噪声影响的波段,将剩余的 176 个波段用于实验研究^[18]。实验中选出常见的 6 类地物信息,类别信息见表 1。



图 2 KSC 的彩色图

Fig. 2 Color image of KSC

表 1 KSC 数据集的类别信息

Tab.1 Class information of KSC data sets

类别	类名	数目	类别	类名	数目
C1	Scrub	761	C4	Spartina marsh	520
C2	Willow swamp	243	C5	Salt marsh	419
C3	Cabbage palm hammock	256	C6	Mud flats	503

4.2 Indian Pine 数据集

Indian Pine 数据集^[19]是由 NASA 在 1992 年 6 月 12 日通过 AVIRIS 传感器获取的美国 Indiana 西北 100 km² 区域的高光谱影像。该影像大小为 145 pixel×145 pixel,光谱为 400~2 450 nm,共包含 220 个波段,如图 3 所示。剔除受大气影响的波段,将剩余 200 个波段用于实验研究^[20]。实验中选出常见的 6 类地物,类别信息见表 2。



图 3 Indian Pine 的假彩色图

Fig. 3 False-color image of Indian Pine

表 2 Indian Pine 数据集的类别信息

Tab. 2 Class information of Indian Pine data sets

类别	类名	数目	类别	类名	数目
C1	Corn-notill	1 434	C4	Hay-windrowed	489
C2	Grass/pasture	497	C5	Soybeans min 2	468
C3	grass/trees	747	C6	woods	1294

5 实验结果与分析

采用 KSC 和 Indian Pine 数据集进行实验时,将本文提出的 CN-LLE+CNN 方法与 LLE+CNN、CN-LLE、LLE、LPP 和 NPE 进行了比较,其中 CN-LLE、LLE、LPP 和 NPE 采用传统的最近邻分类器分类。

参数设置如下:求分类精度的实验中,每次实验从各类样本中随机选取 25 个数据点作为训练样本,50 个数据点作为测试样本,每种算法重复进行 10 次实验,取平均值作为最终结果;对所选地物分类时,通过分析分类精度,每类样本随机选取 25 个数据点作为训练样本,可知近邻数 k 为 5 时分类效果更好,低维嵌入维数设置为 45,高于此维数后本文算法的总体分类精度变化很小。

实验设置如下:为研究近邻数 k 变化对 CN-LLE+CNN 的影响。文中进行了总体分类精度

随 k 值变化实验。为研究相关系数度量近邻、欧氏距离度量近邻以及 CNN 分类器的分类效果,分析了 LPP、NPE、LLE、LLE+CNN、CN-LLE 和 CN-LLE+CNN 的总体分类精度随嵌入维数和近邻数 k 变化实验。为比较分类结果,还对各算法进行了地物分类实验。

5.1 KSC 实验结果与分析

图 4 给出了 CN-LLE+CNN 的总体分类精度随 k 值变化的结果;图 5 给出了各种算法的总体分类精度随 k 值和维数变化的结果,表 3 给出了不同 k 值时不同算法总体分类精度的最高值;表 4 给出了不同算法各类地物的分类精度,表 5 给出了不同算法地物分类的总体精度和 Kappa 系数。

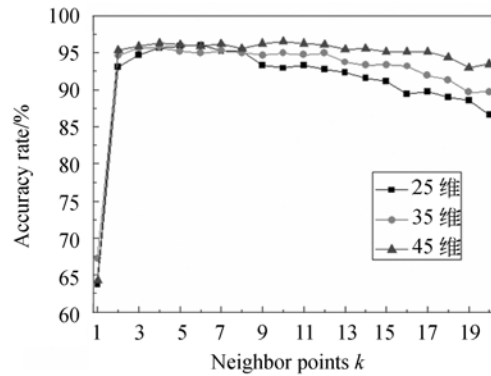


图 4 CN-LLE+CNN 在不同 k 值的总体分类精度
Fig. 4 Overall classification accuracy of CN-LLE+CNN with different k

由图 4 可知,随着 k 的增加,CN-LLE+CNN 的总体分类精度先增加再减小。这是因为随着 k 的增加,能够更准确地拟合各数据点,但 k 过大,则会出现过拟合现象,反而使分类精度降低。

表 3 各算法的最高总体分类精度(平均值±方差(%))(维数)

Tab. 3 The highest overall classification accuracy of different algorithms (mean±var. (%)) (dimension)

算法	$k=4$	$k=5$	$k=6$
LPP	65.53±0.88(26)	66.90±0.54(26)	68.53±0.23(22)
NPE	67.73±0.62(19)	71.07±0.91(26)	73.83±0.22(27)
LLE	86.40±0.07(18)	87.17±0.12(19)	87.07±0.07(16)
CN-LLE	89.90±0.08(30)	90.37±0.07(21)	89.00±0.01(18)
LLE+CNN	90.63±0.02(49)	90.80±0.05(42)	90.33±0.07(46)
CN-LLE+CNN	93.40±0.03(50)	94.00±0.02(43)	93.43±0.03(41)

由图 5、表 3 可知,CN-LLE 和 LLE 的分类精度比 NPE 和 LPP 好很多,这是因为 CN-LLE 和 LLE 为非线性降维,LPP 和 NPE 是线性降维,而在高维空间中高光谱遥感数据是一种非线性结构,采用非线性降维更能揭示出其低维流形结构。对于 CN-LLE 分类精度比 LLE 好是因为相关系数是基于统计特征的量,其受空间分布的影响更小,近邻被判断为同类的概率更大,且近邻选取更稳定,故能更有效地提取同类地物的低维鉴别特征。随着嵌入维数的增加,LLE 的分类精度先增加后减小,LLE+CNN 却是增加到一定程度后保持平稳,并且 LLE+CNN 的分类精度比 LLE 更

好。这是因为同类数据间的相关性大,非同类数据间相关性小,通过 CNN 判断出的类别更准确,并且稳定性更好。CN-LLE+CNN 分类精度比其他算法都好,并且随低维嵌入维数的增加保持得更好,因为先用 CN-LLE 提取出鉴别特征,再用 CNN 分类,可以使前后相容,从而使提取的特征更有效,分类更准确,稳定性更好,受噪声影响更小。当 k 分别为 4、5、6 时,CN-LLE+CNN 最高总体分类精度比 CN-LLE 分别提升了 3.50%、3.63%、4.43%,比 LLE+CNN 分别提升了 2.77%、3.20%、3.10%,比 LLE 分别提升了 7.00%、6.83%、6.36%。




图 5 各算法在不同 k 值不同维度下的总体分类精度

Fig. 5 Overall classification accuracy of different algorithms with different k in different dimensions

表 4 每类地物在不同方法下的分类精度 (%)

Tab. 4 Classification accuracy of each ground object with different methods

算法	C1	C2	C3	C4	C5	C6
LPP	76.87	77.37	75.00	57.88	80.43	69.18
NPE	66.10	65.84	66.41	63.85	77.80	69.18
LLE	78.98	69.96	69.53	79.42	69.93	84.89
CN-LLE	88.17	74.07	81.25	82.31	74.22	83.90
LLE+CNN	91.06	77.78	82.81	88.27	79.71	85.29
CN-LLE+CNN	94.09	86.01	87.11	90.19	82.34	85.88

由表 4 知,CN-LLE+CNN 对每类地物的分类结果比 CN-LLE、LLE+CNN、LLE、NPE 和 LPP 都好,相关性小的地物分类效果尤其突出。由表 5 知,CN-LLE+CNN、CN-LLE 和 LLE+CNN 的总分类精度比 LLE、NPE 和 LPP 都高,其中 CN-LLE+CNN 的最高;CN-LLE+CNN、CN-LLE 和 LLE+CNN 的 Kappa 系数比 LLE、NPE 和 LPP 的大,其中 CN-LLE+CNN 最大。CN-LLE+CNN 比 LLE、CN-LLE 和 LLE+

CNN 的总分类精度提升了 2.89%~11.55%,Kappa 系数提升了 0.036~0.143。

表 5 不同方法的分类结果

Tab. 5 Classification results of different methods

算法	总精度 (%)	Kappa 系数
LPP	72.21	0.658
NPE	68.06	0.610
LLE	77.05	0.715
CN-LLE	82.16	0.778
LLE+CNN	85.71	0.822
CN-LLE+CNN	88.60	0.858

5.2 Indian Pine 实验结果与分析

图 6 给出了 CN-LLE+CNN 的总体分类精度随 k 值变化的结果;图 7 给出了各种算法总体分类精度随 k 值和维数变化的结果,表 6 给出了不同 k 值不同算法总体分类精度的最高值;图 8 给出了不同算法各类地物的分类结果,表 7 给出了不同算法地物分类的总体精度和 Kappa 系数。

由图 6 可知,随着 k 的增加,CN-LLE+CNN 的总体分类精度先增加再减小。由图 7 和表 6 可知,CN-LLE 和 LLE 比 LPP 和 NPE 的分类效果好,CN-LLE、LLE+CNN 和 CN-LLE+CNN 总体分类精度都比 LLE 好,其中 CN-LLE+CNN

最好,其方差比 LLE 小,CNN 比最近邻分类器的分类效果更好,并且更稳定。当 k 分别取 4、5、6 时,CN-LLE+CNN 的最高总体分类精度比 CN-LLE 分别提升了 2.17%、3.96%、2.50%,比 LLE+CNN 分别提升了 2.03%、3.16%、1.16%,比 LLE 分别提升了 5.83%、5.56%、4.50%。




图 6 CN-LLE+CNN 在不同 k 值的总体分类精度
Fig. 6 Overall classification accuracy of CN-LLE+CNN with different k

表 6 各算法的最高总体分类精度(平均值±方差(%))(维数)
Tab. 6 The highest overall classification accuracy of different algorithms (mean±var. (%) (dimension))

算法	$k=4$	$k=5$	$k=6$
LPP	63.67±0.14(40)	67.53±0.24(47)	68.17±0.07(34)
NPE	61.13±0.29(25)	66.20±0.24(47)	65.57±0.44(33)
LLE	79.17±0.14(37)	80.57±0.08(36)	80.33±0.11(24)
CN-LLE	82.83±0.10(28)	82.17±0.07(25)	82.33±0.04(36)
LLE+CNN	82.97±0.04(50)	83.67±0.06(46)	83.67±0.07(50)
CN-LLE+CNN	85.00±0.04(34)	86.13±0.06(50)	84.83±0.05(50)




图 7 各算法在不同 k 值不同维度下的总体分类精度

Fig. 7 Overall classification accuracy of different algorithms with different k in different dimensions




图 8 每类地物在不同方法的分类结果

Fig. 8 Classification results of each ground object with different methods

表 7 不同方法的分类结果

Tab. 7 Classification results of different methods

算法	总精度(%)	Kappa 系数
LPP	67.01	0.581
NPE	65.69	0.570
LLE	71.61	0.643
CN-LLE	79.98	0.745
LLE+CNN	74.74	0.679
CN-LLE+CNN	82.09	0.771

由图 8 可知(彩图见期刊电子版),对于地物的分类结果,CN-LLE+CNN 比 CN-LLE、LLE+CNN、LLE、NPE 和 LPP 都好。由表 7 可知,CN-LLE+CNN、CN-LLE 和 LLE+CNN 的总分类精度比 LLE、NPE 和 LPP 都高,其中 CN-LLE+

CNN 的最高;CN-LLE+CNN、CN-LLE 和 LLE+CNN 的 Kappa 系数比 LLE、NPE 和 LPP 的大,其中 CN-LLE+CNN 的最大。CN-LLE+CNN 的总分类精度比 LLE、CN-LLE 和 LLE+CNN 提升了 2.11%~10.48%,Kappa 系数提升了 0.026~0.128。

6 结 论

传统的 LLE 方法采用欧氏距离度量近邻点,但由于欧氏距离只表示两点间的直线距离,在高维空间中有时不能反映数据间的真实分布,从而导致近邻选取不稳定。针对此问题,本文提出了

相关近邻 LLE 和相关最近邻分类器方法。该方法由相关系数得到各数据点最相关的 k 个点,并将它们作为近邻,再用相关系数对鉴别特征进行分类,由相关系数度量近邻时,判断出同类的概率更大,并且能更有效地提取同类数据的鉴别特征,并且稳定性更好。在 KSC 和 Indian Pine 高光谱遥感数据集上的地物分类实验表明,本文提出的 CN-LLE+CNN 算法能更有效地改善高光谱遥感影像的地物分类,CN-LLE+CNN 的总分类精度比 LLE、LLE+CNN 和 CN-LLE 提升了 2.11%~11.55%,Kappa 系数提升了 0.026~0.143。

参考文献:

- [1] YANG J M, KUO B C, YU P T, *et al.*. A dynamic subspace method for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, 48(7): 2840-2853.
- [2] 黄鸿,杨媚,张满菊,等. 基于稀疏鉴别嵌入的高光谱遥感影像分类[J]. *光学精密工程*, 2013, 21(11):2922-2930.
HUANG H, YANG M, ZHANG M J, *et al.*. Hyperspectral remote sensing image classification based on SDE [J]. *Opt. Precision Eng.*, 2013, 21(11): 2922-2930. (in Chinese)
- [3] 董超,田联房. 最速上升关联向量机高光谱影像分类[J]. *光学精密工程*, 2012, 20(6):1398-1405.
DONG CH, TIAN L F. Hyperspectral image classification by steepest ascent relevance vector machine [J]. *Opt. Precision Eng.*, 2012, 20(6): 1398-1405. (in Chinese)
- [4] BACHMANN C M, AINSWORTH T L. Exploiting manifold geometry in hyperspectral imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(3): 441-454.
- [5] WEN J H, TIAN ZH, SHE H W, *et al.*. Feature extraction of hyperspectral images based on preserving neighborhood discriminant embedding [C]. 2010 *International Conference on Image Analysis and Signal Processing (IASP)*. Zhejiang, 2010: 257-262.
- [6] CHEN Y C, CRAWFORD M M, GHOSH J. Applying nonlinear manifold learning to hyperspectral data for land cover classification [C]. *IGARSS: Proceedings of the 2005 IEEE International Geoscience and Remote Sensing Symposium*, Washington, DC: IEEE Computer Society, 2005: 24-29.
- [7] QIAN H E, CHEN G. A new nonlinear dimensionality reduction method with application to hyperspectral image analysis [C]. *IGARSS: Proceeding of the 2007 IEEE International Geoscience and Remote Sensing Symposium*, Washington, DC: IEEE Computer Society, 2007: 270-273.
- [8] TENENBAUM J B, SILVA V D, LANGFORD J C. A global geometric framework for nonlinear dimensionality reduction [J]. *Science*, 2000, 290: 2319-2323.
- [9] PAN Y, GE S S, MAMUN A Al. Weighted locally linear embedding for dimension reduction [J]. *Pattern Recognition*, 2009, 42: 798-811.
- [10] CARVALHO JUNIOR O A, GUIMARAES R F, GILLESPIE A R, *et al.*. A new approach to change vector analysis using distance and similarity measures [J]. *Remote Sensing*, 2011, 3(11):2473-2493.
- [11] ROWEIS S T, SAUL L K. Nonlinear dimensionality reduction by locally linear embedding [J]. *Science*, 2000, 290: 2323-2326.
- [12] HOSSEINI A, Ghassemian H. Classification of hyperspectral and multispectral images by using fractal dimension of spectral response curve [C]. 20th *Iranian Conference on Electrical Engineering (ICEE)*. Tehran, 2012:1452-1457.
- [13] YE CH Q, LIU X L, ZHANG ZH Y Z, *et al.*. Multi-Spectral and panchromatic image fusion based on region correlation coefficient in nonsub-

- sampled Contourlet transform domain [C]. 2010 *Fourth International Conference on Genetic and Evolutionary Computing (ICGEC)*, Shenzhen, 2010: 517-521.
- [14] YU R L, QIANG W, YU E L, *et al.*. Hyperspectral image classification using kernel method based on the correlation coefficients of neighbor bands [C]. *Second IITA International Conference on Geoscience and Remote Sensing (IITA-GRS)*, Qingdao, 2010, 2: 230-233.
- [15] FALIE D, DAVID L. Correlation coefficient based on independent component analysis[C]. *9th International Conference on Communications (COMM)*, Bucharest, 2012: 59-62.
- [16] XUEJUN Z, XU Q. Spectral characteristics research of the hyperspectral image based on the correlation matrix [C]. *Fourth International Symposium on Information Science and Engineering (ISISE)*, Shanghai, 2012: 372-374.
- [17] HAM J, CHEN Y, CRAWFORD M M, *et al.*. Investigation of the random forest framework for classification of hyperspectral data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(3): 492-501.
- [18] 王立志, 黄鸿, 冯海亮. 基于 SSMFA 与 kNNS 算法的高光谱遥感影像分类[J]. *电子学报*, 2012, 40(4): 780-787.
- WANG L ZH, HUANG H, FENG H L. Hyperspectral remote sensing image classification based on SSMFA and kNNS [J]. *Acta Electronica Sinica*, 2012, 40(4): 780-787. (in Chinese)

作者简介:



刘嘉敏(1973—),男,四川成都人,博士,副教授,硕士生导师,1995年、1998年、2001年于重庆大学分别获得学士、硕士、博士学位,主要从事图像处理、模式识别等方面的研究。E-mail:liujm@cqu.edu.cn



罗甫林(1988—),男,四川内江人,博士研究生,2013年于重庆大学获得硕士学位,主要从事图像处理、模式识别、流形学习、遥感影像智能处理等方面的研究。E-mail:luofl@cqu.edu.cn

(版权所有 未经许可 不得转载)