

基于推广流形学习的高分辨遥感影像目标分类

郭亚宁¹ 林伟² 潘泉¹ 赵春晖¹ 胡劲文¹ 马娟娟¹

摘要 针对传统的流形学习算法不能对位于黎曼流形上的协方差描述子进行有效降维这一问题,本文提出一种推广的流形学习算法,即基于 Log-Euclidean 黎曼核的自适应半监督正交局部保持投影(Log-Euclidean Riemannian kernel-based adaptive semi-supervised orthogonal locality preserving projection, LRK-ASOLPP),并将其成功用于高分辨率遥感影像目标分类问题。首先,提取图像每个像素点处的几何结构特征,计算图像特征的协方差描述子;其次,通过采用 Log-Euclidean 黎曼核将协方差描述子投影到再生核 Hilbert 空间;然后,基于流形学习理论,建立黎曼流形上半监督正交局部保持投影算法模型,利用交替迭代更新算法对目标函数进行优化求解,同时获得相似性权矩阵和低维投影矩阵;最后,利用求得的低维投影矩阵计算测试样本的低维投影,并用 K -近邻、支持向量机(Support vector machine, SVM)等分类器对其进行分类。三个高分辨率遥感影像数据集上的实验结果说明了该算法的有效性与可行性。

关键词 协方差矩阵, Log-Euclidean 黎曼核, 流形学习, 目标分类

引用格式 郭亚宁, 林伟, 潘泉, 赵春晖, 胡劲文, 马娟娟. 基于推广流形学习的高分辨遥感影像目标分类. 自动化学报, 2019, 45(4): 720–729

DOI 10.16383/j.aas.2017.c170318

Generalized Manifold Learning for High Resolution Remote Sensing Image Object Classification

GUO Ya-Ning¹ LIN Wei² PAN Quan¹ ZHAO Chun-Hui¹ HU Jin-Wen¹ MA Juan-Juan¹

Abstract It is not adequate to use classical manifold learning techniques to reduce the dimension of covariance descriptors lied on Riemannian manifold. A generalized manifold learning method named Log-Euclidean Riemannian kernel-based adaptive semi-supervised orthogonal locality preserving projection (LRK-ASOLPP) is proposed, and successfully applied to the high resolution remote sensing image classification issue. Firstly, geometric features of each pixel in the image are extracted, and covariance descriptor of each image is calculated. Secondly, the covariance descriptors are mapped into the reproducing kernel Hilbert space by using the Log-Euclidean Riemann kernel. Thirdly, the model of semi-supervised orthogonal locality preserving projection algorithm on Riemannian manifold is constructed based on manifold learning theory. Fourthly, by using the alternating iteration optimization algorithm to solve the objective function, the similarity weight matrix and low dimensional projection matrix are obtained simultaneously. Finally, low dimensional projections of test samples are computed by using the low dimensional projection matrix, and then classifiers such as K -NN, support vector machine (SVM), etc. are used to classify them. Experiment results on three high-resolution satellite images datasets demonstrate the feasibility and effectiveness of the proposed algorithm.

Key words Covariance matrix, Log-Euclidean Riemann kernel, manifold learning, object classification

Citation Guo Ya-Ning, Lin Wei, Pan Quan, Zhao Chun-Hui, Hu Jin-Wen, Ma Juan-Juan. Generalized manifold learning for high resolution remote sensing image object classification. *Acta Automatica Sinica*, 2019, 45(4): 720–729

收稿日期 2017-06-14 录用日期 2017-11-24

Manuscript received June 14, 2017; accepted November 24, 2017

国家自然科学基金(61473230, 61603303), 陕西省自然科学基金(2017JM6027, 2017JQ6005), 中国博士后科学基金(2017M610650), 中央大学基础研究基金(3102017jg02011), 航空科学基金(2014ZC53030)资助

Supported by National Natural Science Foundation of China (61473230, 61603303), Natural Science Foundation of Shaanxi Province (2017JM6027, 2017JQ6005), China Postdoctoral Science Foundation (2017M610650), Fundamental Research Funds for the Central Universities (3102017jg02011), and Aviation Science Foundation (2014ZC53030)

本文责任编辑 胡清华

Recommended by Associate Editor HU Qing-Hua

1. 西北工业大学自动化学院 西安 710129 2. 西北工业大学理学院 西安 710129

1. School of Automation, Northwestern Polytechnical University, Xi'an 710129

随着计算机、空间定位、航空航天以及传感器技术的不断发展,对地观测系统的光谱和频谱分辨率不断增加,时间和空间分辨率不断提高,现代遥感技术已经形成高光谱、高空间分辨率、全天时/全天候、实时/准时的对地观测能力,可以采集到分米甚至纳米级的高分辨率遥感影像^[1]。众所周知,高分辨率遥感影像不仅在现代军事战争中承担及时、准确获取军事信息的重大任务,在城市规划、灾害监测与评估等民用领域也具有广泛应用^[2]。然而,高分辨遥感影像解译技术远远滞后于影像的获取技术,使其在现

sity, Xi'an 710129 2. School of Natural and Applied Sciences, Northwestern Polytechnical University, Xi'an 710129

实应用中并未得到充分利用。大量的理论分析与实验结果表明, 高分辨率遥感影像数据在带来强烈视觉冲击的同时, 也带来了一系列信息处理与模式识别的新问题, 影像空间分辨率的提高并不意味着解译精度也一定提高^[3]。

如何对高分辨率遥感影像数据进行快速准确解译是目前亟待解决的一个难题。目标分类与识别是高分辨率遥感影像解译的关键技术之一。目前, 高分辨率遥感影像目标分类主要存在两个挑战^[4]: 1) 目标的结构特征成为影像分类的主导因素^[5]; 2) 影像光谱特征的统计可分性减弱, 类间方差^[6]减小, 类内方差变大, “同物异谱、同谱异物”的现象普遍存在。因此, 适用于中低分辨率遥感影像的特征(例如强度特征、纹理特征等)及光谱解译方法并不适用于高分辨率遥感影像。

但是, 如果将图像的重构信息和分类识别信息看作是嵌入在低维子空间中的一个流形, 则既可以处理高维数据又可以挖掘数据内蕴几何结构特征的流形学习是解决上述问题的有效途径。近年来, 流形学习被广泛用于行人检测^[7]、视觉物体分类^[8]、高光谱遥感图像分类^[9]、人脸识别^[10]、图像分类^[11]等模式识别和数据分类问题, 及动态目标追踪^[12]、医学图像分割^[13]、显著性检测^[14]等计算机视觉和人工智能领域。

流形是不同维数下的曲线和曲面等几何对象的总称。流形学习本质是通过非线性映射将高维数据投影到低维空间, 提取数据内蕴结构特征, 实现维数约简或数据可视化。Tenenbaum 等^[15] 和 Roweis 等^[16]首先在非欧框架下考虑数据集的几何结构分析问题, 在 2000 年的 *Science* 杂志上分别提出考虑全局几何结构的保测地距离映射(Isometric mapping, Isomap)和考虑局部几何结构的局部线性嵌入(Locally linear embedding, LLE)。Isomap 和 LLE 方法均可以把采样数据所在的低维流形展开成低维子空间。受 Isomap 和 LLE 启发, 各种非线性维数约简算法大量涌现。具有代表性的方法主要包括: 拉普拉斯特征映射(Laplacian eigenmap, LE)^[17]、局部切空间排列(Local tangent space alignment, LTSA)^[18]、最大方差展开(Maximum variance unfolding, MVD)^[19]、黑塞局部线性嵌入(Hessian locally linear embedding, HLLE)^[20]和局部坐标排列(Local coordinates alignment, LCA)^[21]等。

但上述方法中的投影函数均是非线性的, 即没有显式表达。因此, 无法直接利用投影函数求出测试样本或新样本的低维投影, 而需要将其加入训练样本重新训练算法, 且每重新运行一次, 就相当于摒弃了之前的运算结果, 这将耗费大量的时间和计算量, 在实际应用中并不可取。为此, He 等^[22]提

出 LE 的线性化算法: 局部保持投影(Locality preserving projection, LPP); Kokipoulou 等^[23] 和 He 等^[24]提出了 LLE 的线性化算法: 正交邻域保持投影(Orthogonal neighborhood preserving projection, ONPP)和邻域保持嵌入(Neighborhood preserving embedding, NPE)。

虽然线性化方法很好地解决了新样本问题, 但仍存在以下缺点: 1) 均是无监督学习方法, 即没有利用样本类标信息, 不利于分类识别问题; 2) 均是在欧几里得框架下基于数据特征向量化表示的降维算法, 但实际应用中的数据并非全分布在欧氏空间内, 例如对称正定(Symmetric positive define, SPD)矩阵, 其所诱导的空间是非欧、弯曲的黎曼流形。作为一种典型的 SPD 矩阵, 协方差描述子融合了图像多种特征, 对目标大小、形状和光照变化等具有较强的鲁棒性, 近年来被广泛应用于目标跟踪^[10]、人脸识别^[25]、行人检测^[26]等方面。若对大小为 $n_1 \times n_2$ 的协方差描述子进行降维处理, 经典流形学习算法需要首先将其向量化为 $(n_1 \times n_2) \times 1$ 的向量, 然后利用欧氏距离进行相似性度量。但向量化表示通常会忽略数据各维度的变化, 且易破坏数据内蕴几何结构。同时, 利用欧氏距离度量黎曼流形上两点间的相似性会忽略数据特征的空间分布信息。此外, 当数据维度较高时, 将面临“维数灾难”和较大计算复杂度。因此, 传统欧氏框架下的流形学习算法不能有效用于黎曼流形。

为此, 本文结合黎曼流形理论与核方法, 提出一种推广的流形学习算法, 即基于 Log-Euclidean 黎曼核的自适应半监督正交局部保持投影(Log-Euclidean Riemannian kernel-based adaptive semi-supervised orthogonal locality preserving projection, LRK-ASOLPP)算法, 并将其应用于高分辨率遥感影像目标分类研究。该方法是针对高分辨率遥感影像目标分类提出, 但具有通用性, 也适用于其他类图像的分类与识别研究。也可以通过类似的方法将流形学习算法 ONPP 从欧氏空间推广到黎曼流形上。与经典的流形学习算法相比, 本文提出的 LRK-ASOLPP 算法在继承 LPP 优点的同时, 具有如下优点: 1) 该算法成功地将传统的流形学习算法 LPP 推广到黎曼流形上, 无需对协方差描述子进行向量化表示, 就可将其投影成低维向量, 在有效保持图像特性内蕴几何结构的同时, 减少了计算量和存储空间; 2) 在核化的过程中, 通过引用无参 Log-Euclidean 黎曼核, 克服传统核方法中存在的核参数的选择问题; 3) 经典的流形学习通常在原始特征空间中构建近邻图, 本文所提出的算法则充分利用数据特征在低维空间中空间分布与样本点的先验类标信息, 在低维特征空间中构建近邻图来估计数

据特征的内蕴几何结构，并通过交替迭代优化算法进行求解，同时获得相似性权矩阵与低维投影矩阵，以此提高算法性能。

本文内容安排如下：第1节简单介绍图像协方差描述子；第2节基于黎曼流形理论给出了黎曼流形 Sym_d^+ 上的 Log-Euclidean 黎曼核的定义；第3节重点阐述和分析了所提出的 LRK-ASOLPP 算法；第4节是高分辨率遥感影像目标分类的实验结果；最后总结全文。

1 协方差描述子

Tuzel 等^[27]首先提出用协方差矩阵作为图像区域特征描述子，即给定灰度或 RGB 图像 $I \in \mathbf{R}^{W \times H}$ ，记 $F = [f(x, y)] \in \mathbf{R}^{W \times H \times d}$ 为图像 I 的特征张量， $f(x, y) = \phi(I, x, y) \in \mathbf{R}^d$ 表示像素点 (x, y) 处的特征向量。函数 $\phi(I, x_i, y_i) = f_i$ 可以是灰度值、颜色、一阶和二阶（水平、垂直）差分、梯度模、梯度方向以及滤波响应等图像特征信息， (x_i, y_i) 表示第 i 个像素点的位置。给定图像区域 $R \subset F$ ，记 $\{f_i\}_{i=1}^N$ 表示区域 R 内每个像素点处的 d 维特征向量集，则区域 R 的 $d \times d$ 维协方差矩阵为

$$X = \frac{1}{N-1} \sum_{i=1}^N (f_i - \bar{f})(f_i - \bar{f})^T \quad (1)$$

其中， $\bar{f} = \frac{1}{N} \sum_{i=1}^N f_i$ 。

2 黎曼流形 Sym_d^+ 上的 Log-Euclidean 黎曼核

记 $Sym_d^+ = \{X | X \in \mathbf{R}^{d \times d}, X = X^T, uXu^T > 0, \forall u \in \mathbf{R}^d\}$ ，即 $d \times d$ 对称正定矩阵（例如非奇异协方差矩阵）所构成的空间，则 Sym_d^+ 是一个可微的李群流形。对 $\forall X \in Sym_d^+$ ，设 X 点处的切空间为 T_X ，则 $T_X \hookrightarrow Sym_d^+$ 上的指数映射 \exp_X 与 $Sym_d^+ \hookrightarrow T_X$ 上的对数映射 \ln_X 分别为

$$\exp_X(Y) = X^{\frac{1}{2}} \exp(X^{-\frac{1}{2}} Y X^{-\frac{1}{2}}) X^{\frac{1}{2}} \quad (2)$$

$$\ln_X(Y) = X^{\frac{1}{2}} \ln(X^{-\frac{1}{2}} Y X^{-\frac{1}{2}}) X^{\frac{1}{2}} \quad (3)$$

其中， $\exp(\cdot)$ ， $\ln(\cdot)$ 分别为矩阵的指数算子和对数算子。对 $\forall X \in Sym_d^+$ ，根据奇异值分解（SVD）， X 可被分解为 $X = U\Sigma U^T$ ，其中 $\Sigma = \text{diag}\{\lambda_1, \lambda_2, \dots, \lambda_d\}$ ， $\lambda_i, i = 1, 2, \dots, d$ 为特征值， U 为特征值所对应的特征向量所构成的矩阵。则

$$\exp(X) = \sum_{k=0}^{\infty} \frac{X^k}{k!} = U \exp(\Sigma) U^T \quad (4)$$

$$\ln(X) = \sum_{k=0}^{\infty} \frac{(-1)^{k-1}}{k!} (X - I) = U \ln(\Sigma) U^T \quad (5)$$

其中，

$$\exp(\Sigma) =$$

$$\text{diag}\{\exp(\lambda_1), \exp(\lambda_2), \dots, \exp(\lambda_d)\} \quad (6)$$

$$\ln(\Sigma) = \text{diag}\{\ln(\lambda_1), \ln(\lambda_2), \dots, \ln(\lambda_d)\} \quad (7)$$

定义 Sym_d^+ 空间中任意两点 X_i 与 X_j 之间的 Log-Euclidean 测地距离^[28]：

$$d_g(X_i, X_j) = \|\ln(X_i) - \ln(X_j)\|_F \quad (8)$$

其中， $\|\cdot\|_F = \langle \cdot, \cdot \rangle_F$ 是矩阵的 Frobenius 范数。

定义黎曼流形 Sym_d^+ 上的 Log-Euclidean 黎曼核：

$$k_{\ln}(X_i, X_j) = \text{tr}[\ln(X_i) \times \ln(X_j)] \quad (9)$$

由式(5)，(7)，(9)可知，Log-Euclidean 黎曼核无核参数，且充分利用了样本点的正定对称特性，简化了核矩阵的计算过程。

定理 1. Log-Euclidean 黎曼核满足 Mercer 条件。

证明.

1) k_{\ln} 实对称： $k_{\ln}(X_i, X_j) = k_{\ln}(X_j, X_i)$ 因为

$$\ln(X_i) = \ln(X_i)^T, \quad \ln(X_j) = \ln(X_j)^T$$

对 $\forall A, B \in \mathbf{R}^{N \times N}$ ， $\text{tr}[A \cdot B] = \text{tr}[B \cdot A]$ ，故

$$\begin{aligned} \text{tr}[\ln(X_i) \times \ln(X_j)] &= \\ \text{tr}[\ln(X_i)^T \times \ln(X_j)] &= \\ \text{tr}[\ln(X_i) \times \ln(X_j)^T] &= \\ \text{tr}[\ln(X_j) \times \ln(X_i)] & \end{aligned} \quad (10)$$

2) k_{\ln} 正定：对 $\forall X_1, X_2, \dots, X_N \in Sym_d^+$ ， $\forall b_1, b_2, \dots, b_N \in \mathbf{R}$

$$\sum_{i,j=1}^N b_i b_j k_{\ln}(X_i, X_j) =$$

$$\sum_{i,j=1}^N b_i b_j \text{tr}[\ln(X_i) \times \ln(X_j)] =$$

$$\text{tr} \left[\left(\sum_{i=1}^N b_i \ln(X_i) \right)^2 \right] =$$

$$\left\| \sum_i^N b_i \ln(X_i) \right\|_F^2 \geq 0 \quad (11)$$

□

因此, 本文在核化的过程中选用 Log-Euclidean 黎曼核, 以克服传统核方法中存在核参数选择问题.

3 LRK-ASOLPP 算法

算法原理: 1) 提取图像每个像素点处的几何结构特征, 计算图像特征的协方差描述子; 2) 采用 Log-Euclidean 黎曼核将协方差描述子投影到再生核 Hilbert 空间; 3) 基于流形学习理论, 建立黎曼流形上半监督正交局部保持投影算法模型, 利用交替迭代更新算法对目标函数进行优化求解, 获取相似性权矩阵和低维投影矩阵; 4) 利用所求得的低维投影矩阵计算测试样本的低维投影.

3.1 算法模型建立与优化求解

给定数据点 $X = \{X_1, X_2, \dots, X_N\} \subset \mathcal{M}$, \mathcal{M} 是黎曼流形, $X_i \in \mathbf{R}^{d \times d}$, $\{X_i\}_{i=1}^l$ 为有标签集, $\{X_i\}_{i=l+1}^N$ 为无标签集, $Y = \{Y_1, Y_2, \dots, Y_N\} \subset \mathcal{M}'$ 为 X 的低维投影, \mathcal{M}' 是低维投影空间, N 为训练样本的总个数.

3.1.1 模型建立

定义非线性映射 $\phi: \mathcal{M} \mapsto \mathcal{F}$, 将分布在黎曼流形 \mathcal{M} 上的样本点 X_i 投影到再生核 Hilbert 空间 \mathcal{F} :

$$X_i \rightarrow \phi(X_i), \quad i = 1, 2, \dots, N \quad (12)$$

定义低维投影矩阵 $V: \mathcal{F} \mapsto \mathbf{R}^r$, 使得

$$\phi(X_i) \rightarrow Y_i = V^T \phi(X_i), \quad i = 1, 2, \dots, N \quad (13)$$

1) 构建相似性权矩阵

在低维空间中, 利用 k 近邻法寻求每个低维特征 Y_i 的 k 个最近邻点, 记作 $N^{\text{apt}}(Y_i) = \{Y_i^1, Y_i^2, \dots, Y_k\}$, 记 $N_b^{\text{apt}}(Y_i) = \{Y_i^j | l(Y_i^j) \neq l(Y_i), 1 \leq j \leq k\}$ 为 $N^{\text{apt}}(Y_i)$ 中与 Y_i 异类的样本. 定义相似性权矩阵 $W^{\text{apt}} = (w_{ij}^{\text{apt}})$.

$$w_{ij}^{\text{apt}} = \begin{cases} \gamma, & l(Y_i) = l(Y_j) \text{ 或 } Y_i \in N^{\text{apt}}(Y_j) \text{ 有标签, } Y_j \text{ 无标签, 且对每个 } Y_s \in N^{\text{apt}}(Y_j), Y_s \text{ 有标签, } l(Y_s) = l(Y_i) \\ \xi, & Y_i, Y_j \text{ 无标签, 且 } Y_i \in N^{\text{apt}}(Y_j) \text{ 或 } Y_j \in N^{\text{apt}}(Y_i) \\ \zeta, & Y_i \in N_b^{\text{apt}}(Y_j) \text{ 或 } Y_j \in N_b^{\text{apt}}(Y_i) \\ 0, & \text{其他} \end{cases} \quad (14)$$

2) 构建黎曼流形上半监督正交局部保持投影算法模型

$$\begin{aligned} \min_V \frac{1}{2} \sum_{i,j=1}^N \|Y_i - Y_j\|^2 w_{ij}^{\text{apt}} \\ \text{s.t. } V^T V = I \end{aligned} \quad (15)$$

由于对 $\forall V \in \mathcal{F}$ 都有 $V \in \text{span}\{\phi(X_1), \phi(X_2), \dots, \phi(X_N)\}$, 即存在数组使得

$$V = \phi(X) \alpha \quad (16)$$

将 $\phi(X_i)$ 投影到 V 上, 有

$$Y_i = \alpha^T \phi^T(X) \phi(X_i) \quad (17)$$

定义核矩阵 $\mathbb{K} = (K_{ij})_{N \times N}$, 其中

$$K_{ij} = K(X_i, X_j) = \langle \phi(X_i), \phi(X_j) \rangle \quad (18)$$

记

$$\mathbb{K} = \begin{pmatrix} K(X_1, X_1) & K(X_1, X_2) & \cdots & K(X_1, X_N) \\ K(X_2, X_1) & K(X_2, X_2) & \cdots & K(X_2, X_N) \\ \vdots & \vdots & \ddots & \vdots \\ K(X_N, X_1) & K(X_N, X_2) & \cdots & K(X_N, X_N) \end{pmatrix} = (K_{ij}) \quad (19)$$

将式 (16), (18) 和 (19) 代入式 (17), 得

$$Y_i = \alpha^T K_i \quad (20)$$

则由

$$\frac{1}{2} \sum_{i,j=1}^N \|Y_i - Y_j\|^2 w_{ij}^{\text{apt}} = \text{tr}(\alpha^T \mathbb{K} L^{\text{apt}} \mathbb{K}^T \alpha) \quad (21)$$

得优化问题 (15) 的求解等价于求解

$$\begin{aligned} \min_{\alpha} \text{tr}(\alpha^T \mathbb{K} L^{\text{apt}} \mathbb{K}^T \alpha) \\ \text{s.t. } \alpha^T \mathbb{K} \alpha = I \end{aligned} \quad (22)$$

其中, L^{apt} 是 Laplacian 矩阵, $D = \text{diag}\{d_{ij}^{\text{apt}}\}$ 是度矩阵, $L^{\text{apt}} = D^{\text{apt}} - W^{\text{apt}}$, $d_{ij}^{\text{apt}} = \sum_j w_{ij}^{\text{apt}}$.

由 Rayleitz-Riz 定理可知, 上述优化问题的求解等价于求解如下广义特征问题:

$$\mathbb{K} L^{\text{apt}} \mathbb{K}^T \alpha = \lambda \mathbb{K} \alpha \quad (23)$$

其中, $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_r)$ 即为前 r 个 (除 0 之外) 最小特征值 $\lambda_1, \lambda_2, \dots, \lambda_r$ 对应的特征向量.

3.1.2 优化求解

由权矩阵 W^{apt} 的构造方法可知, L^{apt} 由 α 决定, 而由式(23)可知 α 由 L^{apt} 决定, 因此优化问题(22)没有封闭解. 为此, 本文利用交替迭代优化算法对其进行求解. 首先, 给定 α^{t-1} , 求 $L^{\text{apt}}(\alpha^{t-1})$, 然后利用 $L^{\text{apt}}(\alpha^{t-1})$ 求 α^t , 依次循环迭代, 得到局部最优解.

则广义特征问题(23)修正为如下特征问题:

$$\mathbb{K}L^{\text{apt}}(\alpha^{t-1})\mathbb{K}^T\alpha^t = \lambda\mathbb{K}\alpha^t \quad (24)$$

进一步, 由式(20), 训练样本的低维投影为

$$Y = \alpha^T\mathbb{K} \quad (25)$$

由于 $\alpha \in \mathbf{R}^{N \times r}$, $\mathbb{K} \in \mathbf{R}^{N \times N}$, 故 $Y \in \mathbf{R}^{r \times N}$, 即协方差描述子的低维投影是欧氏空间中 $r \times 1$ 维向量. 特别地, 当迭代次数 $t = 1$ 时, LRK-ASOLPP 算法是在数据原始特征空间中构建的近邻图, 此时算法记为 LRK-SOLPP.

3.2 算法描述与计算复杂性分析

3.2.1 算法描述

基于 Log-Euclidean 黎曼核的自适应半监督正交局部保持投影(LRK-ASOLPP)算法描述如下:

算法 1. LRK-ASOLPP 算法

输入. $X = \{X_1, X_2, \dots, X_N\} \subset M$, $X_i \in \mathbf{R}^{d \times d}$, $\{X_i\}_{i=1}^l$ 为有标签集, $\{X_i\}_{i=l+1}^N$ 是无标签集, N 为训练样本的总个数, 降维后的维数 r , 最大迭代次数 T .

输出. $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_r)$, r , $Y = (Y_1, Y_2, \dots, Y_N)$.

1. 根据原始样本空间中数据的类标信息计算 L^{apt} ;
2. $L^{\text{apt}} = D^{\text{apt}} - W^{\text{apt}}$, 其中 W^{apt} 如式(14)所示
3. $D^{\text{apt}} = \text{diag}\{d_{ii}\}$
4. $d_{ii} = \sum_j w_{ij}$
5. 计算 α_0
6. 对式(23)进行广义特征分解
7. 迭代优化计算 α_t
8. **for** $t \leftarrow 1, 2, \dots, T$ **do**
9. 根据 α_{t-1} 计算相似性权矩阵 $W^{\text{apt}}(\alpha_{t-1})$
10. 由 $W^{\text{apt}}(\alpha_{t-1})$ 计算相似性权矩阵 $L^{\text{apt}}(\alpha_{t-1})$
11. 由式(23)计算 α_t
12. **end**
13. Return $\alpha = \alpha^t$, r , $Y = (Y_1, Y_2, \dots, Y_N)$

3.2.2 计算复杂性分析

算法的时间复杂性主要包括计算 L^{apt} 和计算广义特征值. 计算 L^{apt} 的时间复杂性为 $O(kN^2)$, k 是近邻个数, N 是样本总数; 计算广义特征问题(23)的时间复杂性为 $O((N+r)N^2)$. 因此, 算法整体计算时间复杂性为 $O((N+r)N^2)$.

3.3 新样本嵌入

对于测试样本或新样本 X_t , 其低维投影为

$$Y_t = V^T\phi(x_t) = \alpha^T K_t \quad (26)$$

其中,

$$K_t = (K(X_1, X_t), K(X_2, X_t), \dots, K(X_N, X_t))^T$$

4 实验仿真

为验证 LRK-ASOLPP 算法的有效性, 本文选用高分辨率遥感数据集 UCMerced LandUse Dataset^[29], WHU-RS Dataset^[30] 及 Quick bird Dataset 作为实验数据, 从参数设置及其敏感性、低维特征可视化和分类精度三个方面对算法性能进行分析, 并与基于 Log-Euclidean 高斯核局部保持投影(Log-Euclidean Gaussian kernel-based locality preserving projection, KLPP) 算法^[31] 和 LRK-SOLPP 算法进行对比.

4.1 数据集

1) UCMerced LandUse Dataset 共包含 21 类地物, 每类包含 100 张不同时间、地点、光照和拍摄角度等条件下, 大小为 256 像素 \times 256 像素的影像.

2) WHU-RS Dataset 包含 19 类地物, 每类包含 55 张不同时间、地点、光照和拍摄角度等条件下, 大小为 600 像素 \times 600 像素的影像.

3) Quick bird Dataset 包含 17 类地物, 每类包含 80 张不同时间、地点、光照和拍摄角度等条件下, 大小为 400 像素 \times 400 像素的图像.

实验中, 在每个数据集中, 首先将每类图像平均分为 5 个子集, 每次无放回随机选择 3 个子集作为训练样本, 其余 2 个子集作为测试样本, 将图像大小统一调整为 64 像素 \times 64 像素, 并对像素值做归一化处理; 其次, 计算每张图像的每个像素点 (x, y) 处的特征向量 $f(x, y) = (x, y, H_R(x, y), H_G(x, y), H_B(x, y))^T$, 其中 $H_h(x, y) = (h(x, y), |\frac{\partial h}{\partial x}|, |\frac{\partial h}{\partial y}|, |\frac{\partial^2 h}{\partial x^2}|, |\frac{\partial^2 h}{\partial y^2}|)$, $h \in \{R, G, B\}$ 表示图像的一个通道, 再根据式(1)计算协方差矩阵 X , 其中 X 为 17×17 的对称正定矩阵; 然后, 分别利用 KLPP, LRK-SOLPP 和 LRK-ASOLPP 算法将其投影到低维欧氏空间; 最后, 利用 K-NN, K-means, SVM, BP-ANN 等分类器进行分类. 类似十折交叉验证法, 实验重复 10 次, 取分类精度平均值作为算法性能的评价指标.

4.2 参数设置及其敏感性分析

本文提出的 LRK-ASOLPP 算法涉及的参数有 γ , ξ , ζ , k 以及有标签训练样本的个数 l' . 其中, γ , ζ 分别表示同类样本点和异类样本点之间的相似性

权重, ξ 表示 k 个近邻点中类别不确定的点之间的权重。实验中, 取 $\gamma = -\zeta = 8$, $\xi = 1$; 显然, 有标签样本个数越多, 分类精度就越高, 本文实验中均取 $l' = 3$; 设置最近邻参数 k 搜索范围为 $k = \{1, 2, \dots, l - 1\}$, 其中 l 为训练样本的个数。为验证算法 LRK-SOLPP, KLPP 及 LRK-ASOLPP 对最近邻参数 k 的敏感性, 选用 SVM 作为分类器。最佳分类精度随 k 的变化曲线如图 1 所示。

由图 1 可知, 在三个数据集上, 当 $k \geq 12$ 时, 本文提出的 LRK-ASOLPP 算法趋于稳定, 且当 k 分别取 12, 10, 14 时, 分类精度最高, 分别为 0.9428, 0.9645, 0.9487。

4.3 低维特征可视化

以 WHU-RS Dataset 为例。首先从 WHU-RS Dataset 中任选 4 类地物, 以机场、海岸线、桥梁和山脉为例, 然后计算每个像素点处特征向量 $f(x, y) = (x, y, H_R(x, y), H_G(x, y), H_B(x, y))^T$, 其中, $f(x, y) = (x, y, H_R(x, y), H_G(x, y), H_B(x, y))^T$, 其中, $H_h(x, y) = (h(x, y), |\frac{\partial h}{\partial x}|, |\frac{\partial h}{\partial y}|, |\frac{\partial^2 h}{\partial x^2}|, |\frac{\partial^2 h}{\partial y^2}|)$, $h \in \{R, G, B\}$ 表示图像的一个通道, 再根据式(1)计算协方差矩阵 $X \in \mathbf{R}^{17 \times 17}$; 最后, 利用 KLPP, LRK-SOLPP 和 LRK-ASOLPP 算法将其投影到三维空间, 实验结果如图 2 所示。

由图 2 可知, 使用 KLPP 投影后, 类间存在交叉重叠, 而使用本文提出的 LRK-ASOLPP 算法将高维特征投影到低维特征空间后, 类内紧凑、类间分散, 而且明显优于 LRK-SOLPP。

4.4 图像分类仿真实验

本节从三个方面将本文提出的 LRK-ASOLPP 算法与 LRK-SOLPP 和 KLPP 算法进行比较, 分析评价 LRK-ASOLPP 算法的性能。

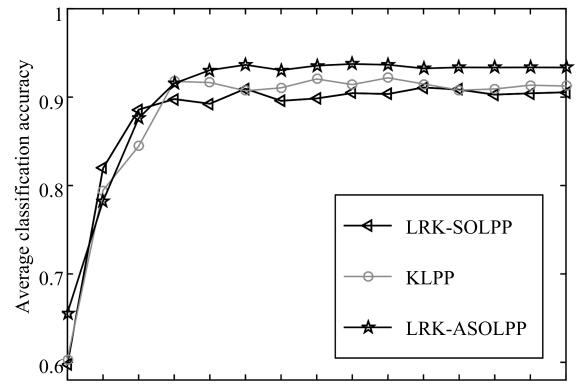
1) 基于特征维数 r 的分类精度

根据图 1 取 $k = 12$, 在三个不同数据集上, 对不同特征维数 r , 算法 KLPP, LRK-SOLPP, LRK-ASOLPP 分别结合 SVM 的分类效果如图 3 所示, 各方法最佳分类精度及其对应特征维数见表 1。

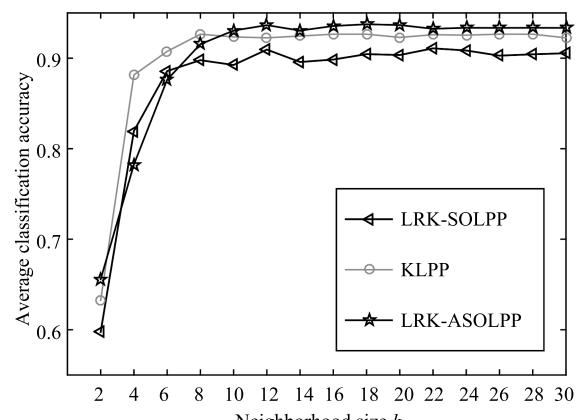
表 1 最佳分类精度 (Ac) 及对应特征维数 (r)

Table 1 The classification accuracy (Ac) and the corresponding feature dimension (r)

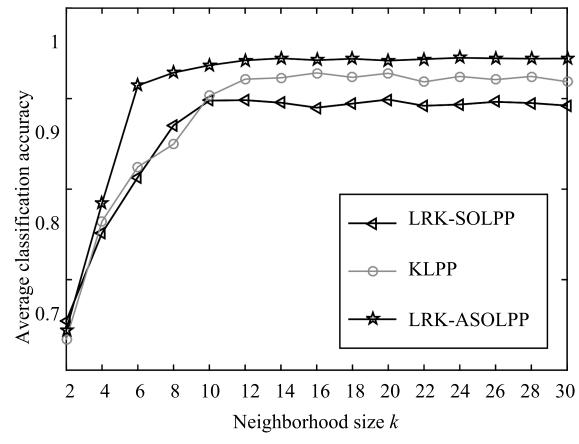
数据集	UCMerced		WHU-RS		Quick bird	
算法	Ac (%)	r	Ac (%)	r	Ac (%)	r
LRK-SOLPP	92.32	45	92.68	25	91.87	45
KLPP	93.15	20	93.64	50	92.84	25
LRK-ASOLPP	94.89	35	96.43	25	95.69	20



(a) UCMerced LandUse dataset



(b) WHU-RS dataset



(c) Quick bird dataset

Fig. 1 Classification accuracy for different values of k

由图 3 及表 1 可知, LRK-ASOLPP 算法分类效果最佳, 且对比 LRK-SOLPP 与 LRK-ASOLPP 的实验结果可知, 选用交替优化迭代求解方法可以明显提高算法的分类精度。

2) 基于训练样本个数的分类精度

对每个数据集, 分别从每类图像中随机选择 2,

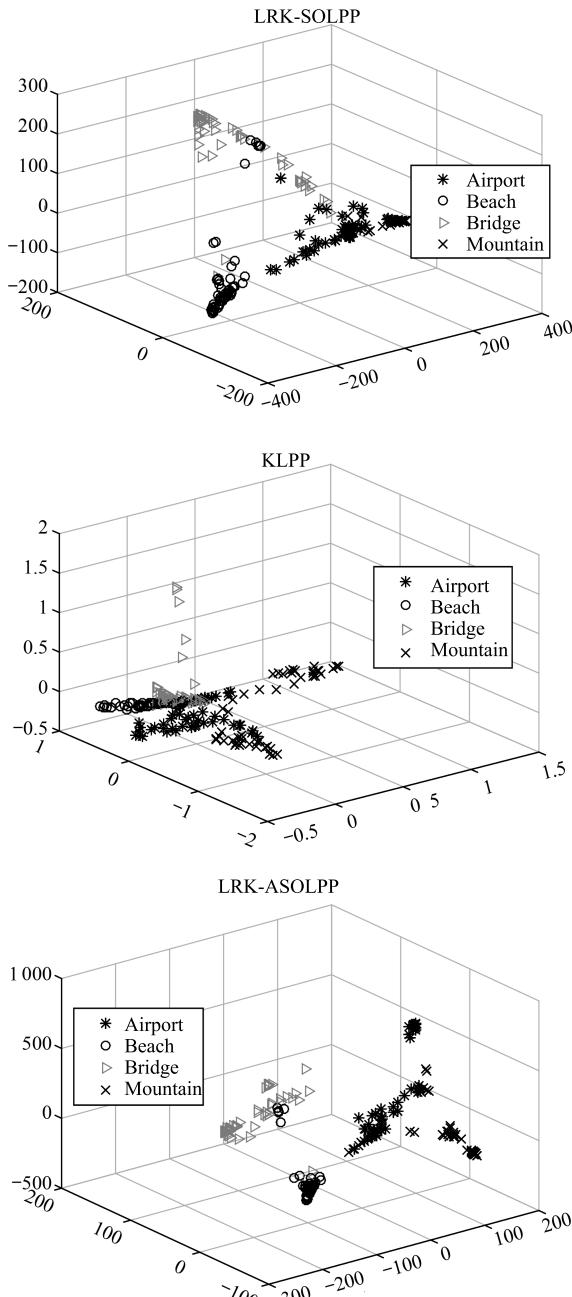


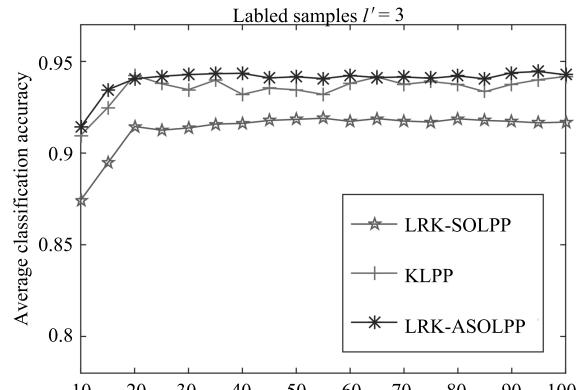
图2 三维特征可视化图
Fig. 2 3D feature visualization

3, 4个子集作为训练样本, 其余子集作为测试样本, 结合 SVM 的实验结果如图 4 所示.

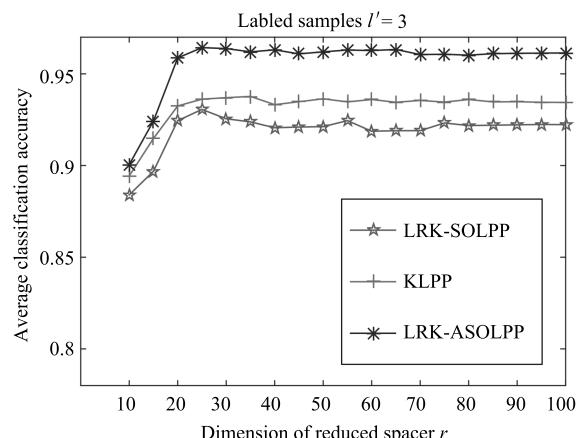
由图 4 可知, 训练样本个数对算法的性能有一定的影响, 即随训练样本的增加, 算法的分类精度提高, LRK-ASOLPP 算法的分类精度最高, 且明显优于 LRK-SOLPP 和 KLPP 算法.

3) 基于不同分类器的分类精度

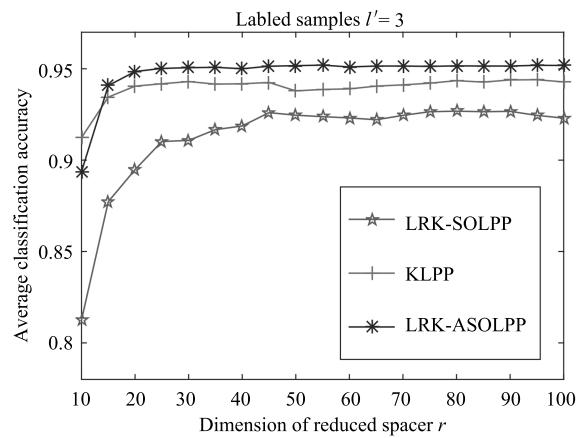
在三个数据集上, 首先利用 LRK-SOLPP, KLPP 及 LRK-ASOLPP 将测试样本的协方差描述子投影到低维空间; 其次, 利用不同的分类器 (K -



(a) UCMerced LandUse dataset



(b) WHU-RS dataset



(c) Quick bird dataset

图3 最佳分类精度随特征维数变化曲线图
Fig. 3 The varying curves of the optimal classification accuracy with feature dimension

NN, K -means, SVM, BP-ANN) 进行分类. 其中, 对于 K -NN 和 K -means, 取 $k = 15$, 对于 SVM, 选择线性核函数. 实验结果如表 2~4 所示.

由上述实验结果可知, 分类器不同, 算法的分类效果也不同. 本文提出的 LRK-ASOLPP 算法结合

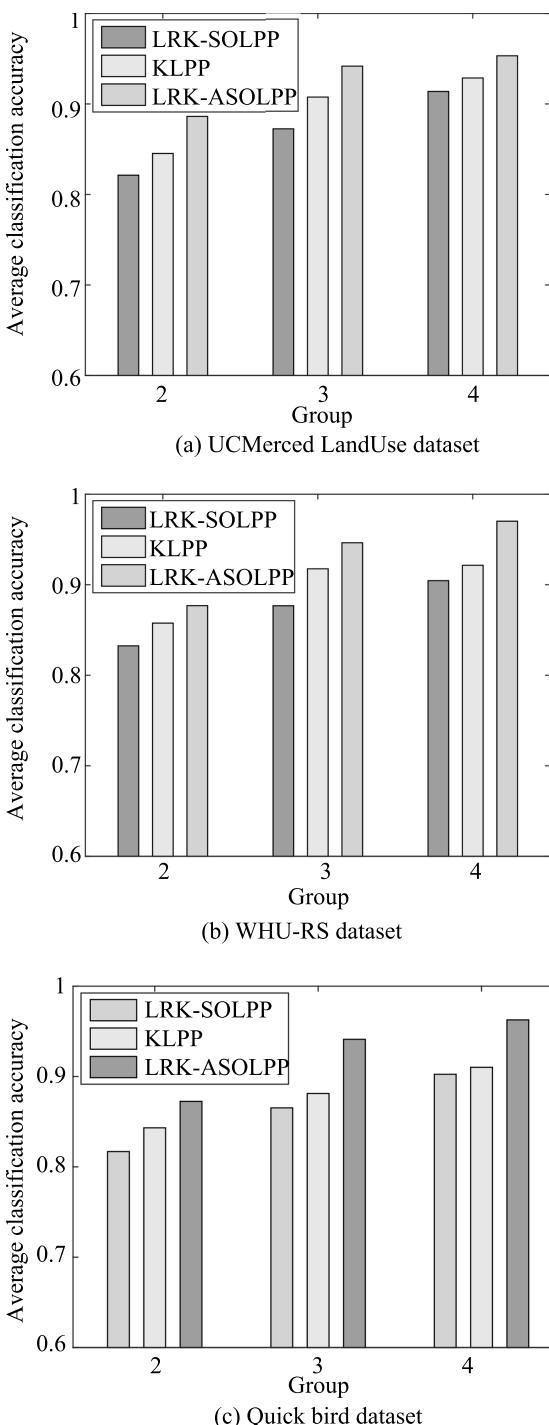


图4 三个数据集上不同训练样本数算法最佳平均分类精度

Fig. 4 The average classification accuracy of different training sample number on three datasets

K-NN, *K*-means 及 SVM 时, 分类效果均优于其他算法, 且与 BP-ANN 结合时, 分类精度最高.

5 结束语

传统的流形学习算法均是欧氏框架下基于图像

表2 UCMerced LandUse dataset 上的最佳分类精度 (Ac) 及对应特征维数 (*r*)

Table 2 The classification accuracy (Ac) and the feature dimension (*r*) on UCMerced LandUse dataset

算法	LRK-SOLPP		KLPP		LRK-ASOLPP	
	分类器	Ac (%)	<i>r</i>	分类器	Ac (%)	<i>r</i>
K-NN		84.45	20		84.38	20
K-means		85.65	20		89.06	25
SVM		87.25	15		90.76	15
BP-ANN	89.82	20	91.64	20	95.34	25

表3 WHU-RS dataset 上的最佳分类精度 (Ac) 及对应特征维数 (*r*)

Table 3 The classification accuracy (Ac) and the feature dimension (*r*) on WHU-RS dataset

算法	LRK-SOLPP		KLPP		LRK-ASOLPP	
	分类器	Ac (%)	<i>r</i>	分类器	Ac (%)	<i>r</i>
K-NN		85.32	30		88.04	20
K-means		88.58	20		89.64	50
SVM		87.68	35		91.76	15
BP-ANN	90.47	20	90.43	20	95.79	20

表4 Quick bird dataset 上的最佳分类精度 (Ac) 及对应特征维数 (*r*)

Table 4 The classification accuracy (Ac) and the feature dimension (*r*) on Quick bird dataset

算法	LRK-SOLPP		KLPP		LRK-ASOLPP	
	分类器	Ac (%)	<i>r</i>	分类器	Ac (%)	<i>r</i>
K-NN		84.98	25		93.65	20
K-means		86.62	20		92.06	50
SVM		88.76	25		90.38	25
BP-ANN	89.45	20	92.56	30	95.89	25

特征向量化表示的降维算法, 而协方差描述子所在的空间是非欧和弯曲的黎曼流形, 对其进行向量化表示并用欧氏距离进行相似性度量容易丢失有效的结构信息. 因此, 本文结合黎曼流形理论与核方法, 将流形学习算法 LPP 从欧氏空间推广到黎曼流形上, 提出 LRK-ASOLPP 算法, 并应用于高分辨率遥感影像目标分类. 1) 提取图像每个像素点处的几何结构特征, 计算图像特征的协方差描述子; 2) 通过采用 Log-Euclidean 黎曼核将协方差描述子投影到再生核 Hilbert 空间; 3) 基于流形学习理论, 建立黎曼流形上半监督正交局部保持投影算法模型, 利用交

替迭代更新算法对目标函数进行优化求解, 同时获得相似性权矩阵和低维投影矩阵; 4) 利用求得的低维投影矩阵计算测试样本的低维投影, 并用 K-近邻和 SVM 等分类器对其进行分类。与传统的流形学习算法相比, 本文提出的 LRK-ASOLPP 算法在降维的过程中无需进行图像特征向量化表示, 有效保留了数据特征的内蕴几何结构和判别信息, 并通过选用无参的 Log-Euclidean 黎曼核克服了传统核方法中的核参数选择问题。实验结果表明, 该算法在高分辨率遥感影像目标分类方面具有良好的分类性能, 为后续的图像目标分类与识别研究提供了有效的方法。但该算法还有很大的研究空间, 例如采用多核学习法来克服核函数与核参数的选择问题, 利用稀疏表示构建相似性权矩阵来克服近邻参数的选择问题等, 后续将继续进行相关的研究。

References

- 1 Ming Dong-Ping, Luo Jian-Cheng, Shen Zhan-Feng, Wang Min, Sheng Hao. Research on information extraction and target recognition from high resolution remote sensing image. *Science of Surveying and Mapping*, 2005, **30**(3): 18–20
(明冬萍, 骆剑承, 沈占锋, 汪润, 盛昊. 高分辨率遥感影像信息提取与目标识别技术研究. 测绘科学, 2005, **30**(3): 18–20)
- 2 Liu Yang, Fu Zheng-Ye, Zheng Feng-Bin. Review on high resolution remote sensing image classification and recognition. *Journal of Geo-Information Science*, 2015, **17**(9): 1080–1091
(刘扬, 付征叶, 郑逢斌. 高分辨率遥感影像目标分类与识别研究进展. 地球信息科学学报, 2015, **17**(9): 1080–1091)
- 3 Tang Yu-Qi. Object-Oriented Change Detection with Multi-Feature in Urban High-Resolution Remote Sensing Imagery [Ph. D. dissertation], Wuhan University, China, 2013.
(汤玉奇. 面向对象的高分辨率影像城市多特征变化检测研究 [博士学位论文], 武汉大学, 中国, 2013.)
- 4 Dai D X, Yang W. Satellite image classification via two-layer sparse coding with biased image representation. *IEEE Geoscience and Remote Sensing Letters*, 2011, **8**(1): 173–176
- 5 Guo Ying-Chun, Yuan Hao-Jie, Wu Peng. Image saliency detection based on local and regional features. *Acta Automatica Sinica*, 2013, **39**(8): 1214–1224
(郭迎春, 袁浩杰, 吴鹏. 基于 Local 特征和 Regional 特征的图像显著性检测. 自动化学报, 2013, **39**(8): 1214–1224)
- 6 Li Qing, Tang Huan, Chi Jian-Nan, Xing Yong-Yue, Li Hua-Tong. Gesture segmentation with improved maximum between-cluster variance algorithm. *Acta Automatica Sinica*, 2017, **43**(4): 528–537
(李擎, 唐欢, 迟健男, 邢永跃, 李华通. 基于改进最大类间方差法的手势分割方法研究. 自动化学报, 2017, **43**(4): 528–537)
- 7 Tuzel O, Porikl F, Meer P. Human detection via classification on Riemannian manifolds. In: Proceedings of the 2007 IEEE Conference on Computer Vision and Pattern Recognition. Minneapolis, MN, USA: IEEE, 2007.
- 8 Jayasumana S, Hartley R, Salzmann M. Kernels on Riemannian manifolds. Turaga P, Srivastava A (eds). *Riemannian Computing in Computer Vision*. Cham: Springer, 2016. 45–67
- 9 Lunga D, Prasad S, Crawfrd M M, Ersoy O. Manifold-learning-based feature extraction for classification of hyperspectral data: a review of advances in manifold learning. *IEEE Signal Processing Magazine*, 2014, **31**(1): 55–66
- 10 Zhou Y J, Bao L, Lin Y Q. Fast second-order orthogonal tensor subspace analysis for face recognition. *Journal of Applied Mathematics*, 2014, **2014**: Article No. 871565
- 11 Huang H B, Huo H, Fang T. Hierarchical manifold learning with applications to supervised classification for high-resolution remotely sensed images. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, **52**(3): 1677–1692
- 12 Zong Wei. New video stream dynamic target tracking algorithm. *Application Research of Computers*, 2015, **32**(3): 954–956
(宗薇. 一种新的视频流动态目标跟踪算法. 计算机应用研究, 2015, **32**(3): 954–956)
- 13 Ertan C H, Wright M J, Thompson P M, Vidal R. Segmentation of high angular resolution diffusion MRI using sparse Riemannian manifold clustering. *IEEE Transactions on Medical Imaging*, 2014, **33**(2): 301–317
- 14 Zhang Y Y, Wang Z P, Lv X D. Saliency detection via sparse reconstruction errors of covariance descriptors on Riemannian manifolds. *Circuits, Systems, and Signal Processing*, 2016, **35**(12): 4372–4389
- 15 Tenenbaum J B, de Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction. *Science*, 2002, **290**(5500): 2319–2323
- 16 Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding. *Science*, 2000, **290**(5500): 2323–2326
- 17 Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation. *Neural Computation*, 2003, **15**(6): 1373–1396
- 18 Zhang Z Y, Zha H Y. Principal manifolds and nonlinear dimensionality reduction via tangent space alignment. *SIAM Journal on Scientific Computing*, 2005, **26**(1): 313–338
- 19 Weiberger K Q, Sha F, Saul K L. Learning a kernel matrix for nonlinear dimensionality reduction. In: Proceedings of the 21st International Conference on Machine Learning. Banff, Alberta, Canada: ACM, 2004.
- 20 Donoho D L, Grimes C E. Hessian eigenmaps: locally linear embedding techniques for high-dimensional data. *Proceedings of the National Academy of Sciences of the United States of America*, 2003, **100**(10): 5591–5596
- 21 Zhang T H, Li X L, Tao D C, Yang J. Local coordinates alignment and its linearization. *Neural Information Processing*. Berlin, Heidelberg: Springer-Verlag, 2008. 643–652
- 22 He X F, Niyogi P. Locality preserving projections. In: Proceedings of the 2003 Conference on Advances in Neural Information Processing Systems. Chicago, IL, USA: MIT Press, 2003. 186–197
- 23 Kokopoulou E, Saad Y. Orthogonal neighborhood preserving projections: a projection-based dimensionality reduction technique. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2007, **29**(12): 2143–2156
- 24 He X F, Cai D, Yan S C, Zhan H J. Neighborhood preserving embedding. In: Proceedings of the 10th IEEE International Conference on Computer Vision. Beijing, China: IEEE, 2005. 1208–1213

- 25 Lu G, Zuo J. Two-dimensional neighborhood preserving discriminant analysis for face recognition. *Pattern Recognition Letters*, 2010, **30**(10): 902–907
- 26 Shen J F, Zuo X, Liu H, Wang H R, Yang W K, Qian C S. Supervised local high-order differential channel feature learning for pedestrian detection. *Neural Processing Letters*, 2017, **45**(3): 1025–1037
- 27 Tuzel O, Porikli F, Meer P. Region covariance: a fast descriptor for detection and classification. In: Proceedings of the 2006 European Conference on Computer Vision. Berlin, Heidelberg, Germany: Springer, 2006. 589–600
- 28 Wang Rui-Xia, Peng Guo-Hua. An image retrieval method with sparse coding based on Riemannian manifold. *Acta Automatica Sinica*, 2017, **43**(5): 778–788
(王瑞霞, 彭国华. 基于黎曼流形稀疏编码的图像检索算法. 自动化学报, 2017, **43**(5): 778–788)
- 29 Yang Y, Newsam S. Bag-of-visual-words and spatial extensions for land-use classification. In: Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems. San Jose, California, USA: ACM, 2010. 270–279
- 30 Xia G S, Yang W, Delon J, Gousseau Y, Sun H, Maître H. Structural high-resolution satellite image indexing. In: Proceedings of the 2010 Symposium: 100 Years-International Society for Photogrammetry and Remote Sensing-Advancing Remote Sensing Science. Vienna, Austria: ISPRS, 2010. 298–303
- 31 Li P H, Wang Q L, Zuo W M, Zhang L. Log-Euclidean kernels for sparse representation and dictionary learning. In: Proceedings of the 2013 IEEE International Conference on Computer Vision (ICCV). Sydney, NSW, Australia: IEEE, 2013. 1601–1608



郭亚宁 西北工业大学自动化学院博士研究生. 主要研究方向为遥感图像处理, 无人机自主防撞感知规避. E-mail: yanngg0924@mail.nwpu.edu.cn

(GUO Ya-Ning) Ph. D. candidate at the School of Automation, Northwestern Polytechnical University. Her research interest covers remote sensing image processing and autonomous collision avoidance, sense and avoid technologies for unmanned aerial vehicles (UAVs).)



林伟 西北工业大学理学院副教授. 2007 年获得西北工业大学博士学位. 主要研究方向为统计建模与遥感图像处理. 本文通信作者.

E-mail: linwei@nwpu.edu.cn
(LIN Wei) Associate professor at the School of Natural and Applied Sciences, Northwestern Polytechnical University.

She received her Ph. D. degree from Northwestern Polytechnical University in 2007. Her research interest covers statistical modeling and remote sensing image processing. Corresponding author of this paper.)



潘泉 西北工业大学自动化学院教授. 1997 年获得西北工业大学博士学位. 主要研究方向为信息融合理论及应用, 目标跟踪与识别技术, 光谱成像及图像处理. E-mail: quanpan@nwpu.edu.cn

(PAN Quan) Professor at the School of Automation, Northwestern Polytechnical University. He received his Ph. D. degree from Northwestern Polytechnical University in 1997. His research interest covers information fusion theory and application, target tracking and recognition technology, and spectral imaging and image processing.)



赵春晖 西北工业大学自动化学院副教授. 2008 年获得西北工业大学博士学位. 主要研究方向为视频图像处理, 目标跟踪识别, 无人机视觉导航.

E-mail: zhaochunhui@nwpu.edu.cn
(ZHAO Chun-Hui) Associate professor at the School of Automation, Northwestern Polytechnical University.

He received his Ph. D. degree from Northwestern Polytechnical University in 2008. His research interest covers video image processing, target tracking recognition, and unmanned aerial vehicle visual navigation.)



胡劲文 西北工业大学自动化学院副教授. 2013 年获得新加坡南洋理工大学博士学位. 主要研究方向为网络控制与滤波.

E-mail: hujinwen@nwpu.edu.cn
(HU Jin-Wen) Associate professor at the School of Automation, Northwestern Polytechnical University. He received his Ph. D. degree from Singapore Nanyang Technological University (NTU) in 2013. His research interest covers network control and filtering.)



马娟娟 西北工业大学自动化学院博士研究生. 主要研究方向为目标跟踪与识别技术.

E-mail: majuanjuan903@163.com
(MA Juan-Juan) Ph. D. candidate at the School of Automation, Northwestern Polytechnical University. Her research interest covers target tracking and recognition technology.)