

# 遥感影像的半监督判别局部排列降维

王雪松, 胡汇涓, 程玉虎

(中国矿业大学信息与电气工程学院, 江苏徐州 221116)

**摘 要:** 针对遥感影像数据具有的高维数和少量已标记样本的特性, 提出一种基于图的半监督判别局部排列降维方法. 首先, 针对全部已标记和未标记样本数据构造相似图和惩罚图. 然后, 基于同类近邻点的分散度最小且不同类近邻点的分散度最大的原则, 分别确立相似图和惩罚图上的优化目标. 最后, 通过同时优化这两种图上的目标函数, 得到从高维到低维的最优映射关系, 从而达到对高维遥感影像数据维数约简的目的. ROSIS 高光谱数据上的实验结果表明, 所提算法能够有效提高高维遥感影像的总体精度和 Kappa 系数.

**关键词:** 半监督; 判别局部排列; 图; 降维; 遥感影像

**中图分类号:** TP751.1 **文献标识码:** A **文章编号:** 0372-2112 (2014)01-0084-05

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.3969/j.issn.0372-2112.2014.01.013

## Dimensionality Reduction of Remote Sensing Image Using Semi-Supervised Discriminative Locality Alignment

WANG Xue-song, HU Hui-juan, CHENG Yu-hu

(School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China)

**Abstract:** Aiming at remote sensing image data having properties of high-dimension and small amount of labeled samples, a dimensionality reduction algorithm called semi-supervised discriminative locality alignment based on graph is proposed. At first, a similarity graph and a penalty graph are constructed according to all labelled and unlabelled samples. Then, based on the principle that the dispersion between neighbours of the same class is minimum and that the dispersion between neighbours of different class is maximum, optimization goals on the similarity graph and on the penalty graph are respectively determined. At last, an optimal mapping from the high-dimensional space to a low-dimensional subspace can be obtained by simultaneously optimizing the two objective functions, which makes the dimensionality reduction of high-dimensional remote sensing images realized. Experimental results on ROSIS hyperspectral data show that the proposed algorithm can effectively improved the overall accuracy and Kappa coefficient of high-dimensional remote sensing images.

**Key words:** semi-supervised; discriminative locality alignment; graph; dimensionality reduction; remote sensing image

## 1 引言

对遥感影像分类而言, 高维数据处理一直是信息处理与实际应用的难题<sup>[1]</sup>. 在分类中往往面临“维数灾难”的问题, 因此, 降维在高维遥感影像分类的实际应用中显得尤为重要. 目前存在的降维算法主要可以分为特征选择和特征提取, 但是由于特征选择受搜索方法和决策准则的显著影响而损失大量信息, 因而更多的研究工作倾向于特征提取. 通过特征提取技术, 原始高维遥感影像被映射或变换至低维空间, 从而可在很大程度上避免维数灾难, 使后续的分类任务更加稳定、高效、易于处

理、产生更优的泛化性能<sup>[2]</sup>. 目前许多特征提取方法被提出并应用于遥感影像降维, 如主成分分析 (Principal Component Analysis, PCA)<sup>[3]</sup>、线性判别分析<sup>[4]</sup>和独立成分分析<sup>[5]</sup>. 但是, 这些传统的线性降维方法都是假定数据集存在于全局线性结构中, 构成数据集的各变量之间是独立无关的, 无法揭示数据内在的非线性结构, 而遥感影像的本质是非线性的. 鉴于此, 基于非线性流形学习, 又出现了等距特征映射 ISOMAP<sup>[6]</sup>和局部线性嵌入<sup>[7]</sup>等方法, 但是这类非线性降维方法只能映射训练集的样本点到低维嵌入空间, 不能直接对新的测试样本进行处理, 限制了其实际应用. 为了克服这些流形学习通

收稿日期: 2012-11-19; 修回日期: 2013-01-21; 责任编辑: 李勇锋

基金项目: 国家自然科学基金 (No. 61072094, No. 61273143); 教育部新世纪优秀人才支持计划 (No. NCET-08-0836, No. NCET-10-0765); 教育部博士点基金 (No. 20110095110016, No. 20120095110025); 霍英东教育基金会青年教师基金 (No. 121066)

常存在的“out of sample”问题<sup>[8]</sup>, Chen 和 Han 给出了基于局部保持投影 (Locality Preserving Projection, LPP) 的遥感影像特征提取算法<sup>[9]</sup>, 可以方便地处理新的测试样本, 能很好地揭示数据的非线性结构. 2008 年, 张田昊提出了片对齐框架这一概念, 并在此基础上提出了一种新的线性降维方法: 判别局部排列 (Discriminative Locality Alignment, DLA)<sup>[10]</sup>. 它既能有效地保存样本的类别信息, 又能解决小样本问题, 但它是一种监督的降维方法, 大量的未标记数据信息不能被有效得到利用. 针对这个缺点, Zhang 等又提出一种半监督 DLA (Semi-supervised DLA, SDLA)<sup>[11]</sup>, 把未标记数据附加到原始标记数据一起作为局部优化对象, 增强了数据的局部几何特性, 相比于监督算法更有优势. 但是同大多数的其他半监督降维方法类似, 它只能借助未标记数据来调整已标记数据的类内分散度, 不能充分利用未标记数据提供的类间距离等有关信息.

近年来, 由于图植入法能够很好地保留数据的统计特性和几何特性, 基于图的方法已经被广泛应用到数据降维中<sup>[12]</sup>. 使用这种连接图, 数据的流形结构可以通过拉普拉斯算子嵌入到低维子空间. 基于图的降维方法能够使数据降维过程更有效、更精确. 为此, 针对遥感影像数据的降维问题, 通过对数据集上的全部样本构造相似图和惩罚图, 提出一种基于图的半监督 DLA (Graph-based SDLA, GSDLA), 能够使所有同类样本尽可能聚集到一起时, 不同类样本尽可能分开, 得到从高维遥感影像输入空间到低维特征空间的最优映射关系.

## 2 判别局部排列

考虑一个高维遥感影像训练数据集  $C = A \cup B = \{a_1, \dots, a_l, a_{l+1}, \dots, a_n\} \in R^{D \times n}$ , 其中已标记数据记为  $A = \{a_1, \dots, a_i, \dots, a_l\}$ , 未标记数据记为  $B = \{a_{l+1}, \dots, a_n\}$ , 其中  $n \gg l$ . 对于  $A$  中的  $a_i$ , 根据它的标签信息, 可以把其他的已标记数据分为两组: 与  $a_i$  属于同一类别和与  $a_i$  不同类别. 对  $a_i$  有如下操作: 选择  $k_1$  个与它同类的近邻数据记为  $a_i^1, a_i^2, \dots, a_i^{k_1}$ ; 与它异类的  $k_2$  个近邻数据记为  $a_i^1, a_i^2, \dots, a_i^{k_2}$ ;  $a_i$  和它的同类  $k_1$  个近邻数据及异类  $k_2$  个近邻数据组成  $a_i$  的一个局部片  $A_i$ , 表示为  $A_i = [a_i, a_i^1, a_i^2, \dots, a_i^{k_1}, a_i^1, a_i^2, \dots, a_i^{k_2}]$ . DLA 线性降维的目的就是寻找一个判别投影矩阵  $W$ , 将高维数据  $A \in R^{D \times l}$  投射到对应低维空间为  $Y \in R^{d \times l}$ , 即  $Y = W^T A$ , 其中,  $d < D$ . 并且, 对于每一个高维局部片  $A_i$ , 对应的低维映射可以表示为低维局部片  $Y_i = [y_i, y_i^1, y_i^2, \dots, y_i^{k_1}, y_i^1, y_i^2, \dots, y_i^{k_2}]$ . 基于间隔最大化原则, 在被投射到的低维子空间的每个片  $Y_i$  中, 希望  $y_i$  与它同类的近邻点之间的距离尽可能小, 同时与它异类近邻点之间的距离

尽可能大. 由局部近邻构成的片可以认为是近似线性的, 得到最小化的目标函数:

$$\arg \min_{y_i} \left( \sum_{j=1}^{k_1} \|y_i - y_i^j\|^2 - \beta \sum_{r=1}^{k_2} \|y_i - y_i^r\|^2 \right) \quad (1)$$

其中,  $\beta$  是位于  $[0, 1]$  的缩放因子, 用来调整不同数据集的类内距离和类间距离.

每一个片  $A_i$  均对应着一个低维重建  $Y_i$ , 所有的  $Y_i$  可以假设选自于一个全局统一坐标  $Y = [y_1, \dots, y_l]$ , 如此:

$$Y_i = Y S_i \quad (2)$$

其中,  $S_i \in R^{l \times (k_1 + k_2 + 1)}$  为选择矩阵.

假设所有的局部优化都用上式描述, 则可以得到全排列如下:

$$\arg \min_Y \text{tr}(Y M Y^T) \quad (3)$$

$$M = \sum_{i=1}^l S_i M_i S_i^T \in R^{l \times l} \quad (4)$$

其中,  $M$  为排列矩阵,  $M_i = \begin{bmatrix} -e_{k_1+k_2}^T \\ I_{k_1+k_2} \end{bmatrix} \text{diag}(\omega_i)$

$$\cdot \begin{bmatrix} -e_{k_1+k_2} & I_{k_1+k_2} \end{bmatrix} = \begin{bmatrix} \sum_{j=1}^{k_1+k_2} (\omega_i)_{jj} & -\omega_i^T \\ -\omega_i & \text{diag}(\omega_i) \end{bmatrix};$$

数向量  $\omega_i = [\underbrace{1, \dots, 1}_{k_1}, \underbrace{-\beta, \dots, -\beta}_{k_2}]^T$ ;  $e_{k_1+k_2} = [1, \dots, 1]^T \in R^{k_1+k_2}$ ;  $I_{k_1+k_2}$  是  $(k_1+k_2) \times (k_1+k_2)$  的单位矩阵.

由线性化公式  $Y = W^T A$ , 目标函数式 (3) 可以表示为:

$$\begin{cases} \arg \min_W \text{tr}(W^T A M A^T W) \\ \text{s.t. } W^T W = I_d \end{cases} \quad (5)$$

其中,  $I_d$  是  $d \times d$  的单位矩阵.

## 3 基于图的半监督判别局部排列

DLA 考虑了样本的局部, 能够处理样本中的非线性分布问题. 此外, DLA 选择每一样本的同类及不同类近邻作为处理对象, 可以有效地保存样本的判别信息; 计算过程避免了矩阵的逆, 能有效解决小样本问题. 但是, DLA 是一种监督的降维方法, 它的学习过程只用到已知的类别标签, 但是标记数据的获取需要大量的人工过程且比较昂贵, 而相对于标记数据而言, 未标记数据数量庞大且容易获得. 因此, 综合利用标记数据和未标记数据的半监督方法受到越来越多的关注.

近年来, 基于图的流形学习降维方法得到了广泛研究. 它通过对数据集定义一个图, 构建数据集中的全部样本作为顶点, 相邻数据点的相似性作为边权值, 从而约束邻近数据点在投射子空间中的距离, 能够更好地保留全部样本的局部几何特性. 为此, 结合基于图的方法, 提出一种半监督 DLA 降维方法. 对于高维遥感影像数据集  $C$ , 分别构造使用全部数据的相似图和惩罚

图,即相似矩阵  $S$  和惩罚矩阵  $P$ ,对应的拉普拉斯矩阵分别为  $L_s$  和  $L_p$ . 相似矩阵用来联合类内分散矩阵,使邻近相似数据在投射子空间中的距离最小化. 惩罚矩阵通过最大化类间距离,使不相似的数据被投射到子空间中的距离最大化.

构造相似图,即是把全部样本集  $C$  中的每个数据点表示为相似图的一个顶点,数据点  $a_t$  和  $a_q$  之间的相似边权值为  $\delta_{tq}$ ,其中,  $t = 1, \dots, l, \dots, n, q = 1, \dots, l, \dots, n$ . 构造惩罚图,即同样把  $C$  的全部数据点表示成惩罚图的顶点,连接数据点之间的惩罚边权值为  $p_{tq}$ . 此处通过引入高斯函数对相似权值和惩罚权值进行定义并选择  $k_3$  作为近邻点数:

$$\delta_{tq} = \begin{cases} \exp(-\frac{\|a_t - a_q\|^2}{2\sigma^2}), & a_q \text{ 为 } a_t \text{ 的 } k_3 \text{ 个近邻点之一} \\ 0, & \text{其他} \end{cases} \quad (6)$$

$$p_{tq} = 1 - \delta_{tq} \quad (7)$$

其中,高斯函数的宽度  $\sigma$  设置为全部数据样本成对距离的平均值的一半.

构造相似图的目的是希望映射后的低维空间同类近邻点的分散度最小,有:

$$\begin{aligned} \arg \min_w \frac{1}{2} \sum_{t=1}^n \sum_{q=1}^n \delta_{tq} (y_t - y_q)^2 \\ = \arg \min_w \frac{1}{2} W^T \left( \sum_{t=1}^n \sum_{q=1}^n \delta_{tq} (a_t - a_q)(a_t - a_q)^T \right) W \\ = \arg \min_w W^T C L_s C^T W \end{aligned} \quad (8)$$

拉普拉斯矩阵为  $L_s = D_s - S$ ,相似矩阵  $S = \{\delta_{tq}\}$ , 对角矩阵  $D_s = \{d_{tq}\} = \{\sum_q \delta_{tq}\}$ , 利用标准化的图拉普拉斯算子,式(8)可以表示为:

$$\begin{aligned} \arg \min_w \frac{1}{2} \sum_{t=1}^n \sum_{q=1}^n \delta_{tq} (y_t / \sqrt{d_t} - y_q / \sqrt{d_q})^2 \\ = \arg \min_w W^T C L_s C^T W \end{aligned} \quad (9)$$

其中,  $d_t = \{\sum_q d_{tq}\}$ ,  $d_q = \{\sum_t d_{tq}\}$ , 得到标准化的拉普拉斯矩阵为:

$$L_s = I - D_s^{-1/2} S D_s^{-1/2} \quad (10)$$

同时,构造惩罚图的目的是希望映射后低维空间不同类近邻点的分散度最大,即:

$$\begin{aligned} \arg \max_w \frac{1}{2} \sum_{t=1}^n \sum_{q=1}^n p_{tq} (y_t - y_q)^2 \\ = \arg \max_w \frac{1}{2} W^T \left( \sum_{t=1}^n \sum_{q=1}^n p_{tq} (a_t - a_q)(a_t - a_q)^T \right) W \\ = \arg \max_w W^T C L_p C^T W \end{aligned} \quad (11)$$

拉普拉斯矩阵为  $L_p = D_p - P$ ,惩罚矩阵  $P = \{p_{tq}\}$ , 对角矩阵  $D_p = \{\sum_q p_{tq}\}$ . 与相似图类似,利用标准化的图拉普拉斯算子,式(11)可以表示为:

$$\arg \max_w W^T C L_p C^T W \quad (12)$$

$$L_p = I - D_p^{-1/2} P D_p^{-1/2} \quad (13)$$

因此,得到基于图的半监督判别局部排列降维算法的目标函数为:

$$\begin{cases} \arg \max_w W^T C L_p C^T W \\ \arg \min_w W^T C L_s C^T W \end{cases} \quad (14)$$

结合式(5)、(9)和(12),目标函数式(14)可重写为:

$$\arg \min_w W^T (A M A^T + \alpha_1 C L_s C^T - \alpha_3 C L_p C^T + \alpha_2 I) W \quad (15)$$

其中,  $\alpha_1$ 、 $\alpha_2$  和  $\alpha_3$  均为正则化参数. 式(15)可转化为通过求解最小特征值对应的特征向量的问题,获得问题的解. 即求解这样一个标准的特征值问题:

$$(A M A^T + \alpha_1 C L_s C^T - \alpha_3 C L_p C^T + \alpha_2 I) W = \lambda W \quad (16)$$

来计算基于图的 DLA 的投影矩阵  $W = [w_1, w_2, \dots, w_d]$ , 其向量是  $d$  个最小特征值  $\lambda_1, \lambda_2, \dots, \lambda_d$  所对应的特征向量.

## 4 实验结果与分析

ROSIS 高光谱数据提供了同步实测的感兴趣训练区域和测试区域. 训练样本和测试样本分别为 9 类地物,图 1(a)~(c)分别为原始高光谱影像数据的假彩色影像、训练样本的感兴趣区域假彩色影像、测试样本的感兴趣区域假彩色影像. 利用 ENVI 4.7 软件将 ROSIS 高光谱影像训练样本和测试样本感兴趣区域所对应的原始数据转换成 ASCII 数据,以便在 Matlab 9.0 环境中处理. 实验过程中,分别利用 PCA, LPP, DLA, SDLA 和 GSDL A 来进行特征提取,然后统一采用最近邻分类器来对降维后遥感影像数据进行分类. 实验过程中,各降维算法的参数设置情况为:GSDL A 中的  $k_1$ 、 $k_2$  和  $k_3$  分别取为 3、5 和 5,使用交叉验证法确定  $\alpha_1$  和  $\alpha_2$  为 1,  $\alpha_3$  为 0.5; LPP 的近邻参数设为 5; 所有降维算法的低维子空间维数均为 20 维. 图 2 直观地给出了 5 种算法在 ROSIS 高光谱影像数据上的分类结果.




图1 原始高光谱影像数据的假彩色影像

由图 2 可以看出,PCA 几乎将全部裸地错分成草地,将大部分的草地错分成裸地,同时,将近三分之一的金属板错分为砖块,错分现象十分严重; LPP 较 PCA

有所改善,但仍将大部分的裸地误分为草地,相当一部分草地错分为裸地,对于金属板和砖块的错分现象并无明显改善.DLA 对裸地的分类相当精确,但仍将相当一部分草地错分成裸地;SDLA 较 DLA 裸地和草地相互

错分现象降低不少,但效果仍然不够理想;GSDLA 在草地和裸地边界处几乎很少有错分的现象,能较好地分开这两类地物,分类效果更加优秀.




图2 分类结果对比

在遥感影像分类领域,通常采用使用者精度、生产者精度、总体精度和 Kappa 系数等指标来衡量分类性能.表 1 给出了 5 种算法在 ROSIS 高光谱影像数据上的使用者精度和生产者精度对比,可以看出:各类地物使用者精度和生产者精度相差最大的是裸地,PCA 的精度最差,GSDLA 的精度最高,这一点与图 2 的分析结果是

一致的;对于所有地物来说,GSDLA 在所有算法中的使用者精度均最高;相比于其它降维算法,GSDLA 除在树和裸地相对于 DLA、柏油房顶相对于 LPP 和砂砾相对于 SDLA 这些地物上的生产者精度略有下降外,在其它地物上的生产者精度均有不同程度提高.

表 1 使用者精度和生产者精度

	PCA		LPP		DLA		SDLA		GSDLA	
	使用者精度	生产者精度	使用者精度	生产者精度	使用者精度	生产者精度	使用者精度	生产者精度	使用者精度	生产者精度
沥青路面	94.59%	82.33%	94.30%	83.42%	94.32%	81.10%	94.11%	82.57%	94.69%	84.34%
树	74.95%	94.96%	77.45%	94.06%	74.94%	95.01%	74.33%	94.44%	78.03%	94.65%
砖块	76.62%	87.06%	76.86%	88.05%	79.77%	84.32%	79.92%	88.85%	85.39%	89.87%
阴影	88.53%	99.64%	88.65%	98.43%	86.77%	99.54%	89.09%	99.35%	92.25%	99.80%
柏油房顶	61.43%	88.42%	62.89%	89.75%	66.10%	89.64%	72.20%	89.58%	76.14%	89.69%
裸地	13.05%	16.23%	42.82%	74.31%	57.04%	96.86%	62.10%	96.84%	79.39%	96.48%
金属板	87.80%	74.12%	88.45%	75.80%	91.30%	95.03%	89.65%	94.30%	96.33%	95.12%
砂砾	67.02%	78.61%	69.48%	78.39%	62.64%	78.18%	69.65%	79.22%	74.41%	78.97%
草地	75.00%	65.09%	90.99%	68.35%	98.79%	69.42%	98.87%	74.42%	98.98%	93.72%

在上述 4 个指标中,总体精度考虑各个类别的相对权重关系,比较客观;而 Kappa 系数考虑使用者和生产者精度之间的关系,表示分类结果与地面真实值相近程度.表 2 给出了 5 种算法在 ROSIS 高光谱影像数据上的总体精度和 Kappa 系数对比,可以看出:无论是监督型 DLA,还是半监督 DLA,它们的总体精度及 Kappa 系数均优于 PCA 和 LPP;在 3 种 DLA 中,GSDLA 的总体精度及 Kappa 系数均最高,其次为 SDLA,这是由于 SDLA 作为一种半监督的降维方法,用大量的未标记数据辅助标记数据进行分类,其分类性能明显高于 DLA;GSDLA 不仅综合考虑了全部样本,使用了大量未标记样本的信息,而且引入了基于图的方法,通过在全部数据集

上构造出相似图和惩罚图,使样本的局部几何信息更加明确,分类精度更为显著,降维效果更好.

表 2 总体精度和 Kappa 系数

	PCA	LPP	DLA	SDLA	GSDLA
总体精度	68.73%	73.82%	77.38%	81.77%	90.74%
Kappa 系数	0.6142	0.6787	0.7345	0.7786	0.8367

5 结论

遥感影像数据具有信息量大且维数高的特点,各波段间存在高相关性和高冗余度,若不加处理地使用这样的数据进行分类器设计,不仅分类正确率不

高,而且计算量大.因此,从信息处理时效性的角度来看,对遥感影像数据进行特征提取是很有必要的.另一方面,在实际的遥感影像分类应用中,通常会有大量的未标记样本,而已标记样本只占很小的比例.因此,仅利用有限的已标记样本将难以学习出遥感影像的内在结构或规律.为此,通过构造最小化全部数据类内距离的相似图和最大化类间距离的惩罚图,提出一种基于图的半监督判别局部排列降维方法,能够使得高维遥感影像数据在投射到低维子空间时,所有样本的同类近邻尽可能地聚集到一起且不同类近邻尽可能分开.ROSIS 高光谱数据上的实验结果表明,所提算法能够有效提高分类性能,适于处理高维遥感影像数据.

## 参考文献

- [1] 宋娟,李云松,吴成柯,王柯俨.基于  $L^\infty$  最小搜索和陪集码的高光谱图像无损及近无损压缩[J].电子学报,2011,39(7):1551–1555.  
Song Juan, Li Yunsong, Wu Chengke, Wang Keyan. Lossless and near-lossless compression of hyperspectral images based on search for  $L^\infty$  minimum and coset coding[J]. Acta Electronica Sinica, 2011, 39(7): 1551–1555. (in Chinese)
- [2] C I Chang. Hyperspectral Data Exploitation: Theory and Applications[M]. USA: John Wiley & Sons, Inc. 2007.
- [3] S P Zhang. Studies of high spectral resolution atmospheric sounding data compression and noise reduction based on principal component analysis method[A]. Proceedings of the 2nd International Conference on Image and Signal Processing[C]. Piscataway: IEEE, 2009. 4693–4697.
- [4] M S Cui, S Prasad, M Mahrooghy, L M Bruce, J Aanstoos. Genetic algorithms and linear discriminant analysis based dimensionality reduction for remotely sensed image analysis[A]. Proceedings of the International Geoscience and Remote Sensing Symposium[C]. Piscataway: IEEE, 2011. 2373–2376.
- [5] J P Sun, Y Liu. The fusion arithmetic of multi-resolution remote sense image based on a modified fast independent component analysis[A]. Proceedings of the 1st Asian and Pacific Conference on Synthetic Aperture Radar Proceedings[C]. Piscataway: IEEE, 2007. 342–346.
- [6] X Wang, S Kumar, T Kaupp, B Upcroft, H F Durrant-Whyte. Applying ISOMAP to the learning of hyperspectral image[A]. Proceedings of Australasian Conference on Robotics and Automation[C]. Australia: ARAA, 2005. 109–112.
- [7] G Matijevic, A Prsa, J A Orosz, W F Welsh, S Bloemen, T Barclay. Kepler eclipsing binary stars III classification of Kepler eclipsing binary light curves with locally linear embedding[J]. Astronomical Journal, 2012, 143(5): 123–128.
- [8] Y Bengio, J F Paiement, P Vincent, O Delalleau, N L Roux, M Ouimet. Out-of-sample extensions for LLE, Isomap, MDS, eigenmaps, and spectral clustering[A]. Proceedings of Advances in Neural Information Processing Systems[C]. Massachusetts: The MIT Press, 2003. 184–191.
- [9] Y W Chen, X H Han. Classification of high-resolution satellite images using supervised locality preserving projections[J]. Lecture Notes in Computer Science, 2008, 5178: 149–156.
- [10] 张田昊. 数据降维算法研究及其应用[D]. 上海: 上海交通大学博士学位论文, 2008.  
Zhang Tianhao. Research on dimensionality reduction algorithms and its applications[D]. Shanghai: Doctoral Thesis of Shanghai Jiao Tong University, 2008. (in Chinese)
- [11] T H Zhang, D Tao, J Yang. Discriminative locality alignment[J]. Lecture Notes in Computer Science, 2008, 5302: 725–738.
- [12] 何强, 蔡洪, 韩壮志, 尚朝轩. 基于非线性流形学习的 ISAR 目标识别研究[J]. 电子学报, 2010, 38(3): 585–590.  
He Qiang, Cai Hong, Han Zhuangzhi, Shang Chaoxuan. ISAR target recognition based on non-linear manifold learning[J]. Acta Electronica Sinica, 2010, 38(3): 585–590. (in Chinese)

## 作者简介



王雪松 女, 1974 年生于安徽泗县, 2002 年获中国矿业大学控制理论与控制工程专业博士学位, 现为中国矿业大学信息与电气工程学院教授、博士生导师. 主要研究方向为机器学习与模式识别、遥感信息处理等.

E-mail: wangxuesongcumt@163.com



胡汇娟 女, 1986 年生于河南泌阳, 2010 年获中国矿业大学学士学位, 现为中国矿业大学控制理论与控制工程专业硕士研究生, 研究方向为遥感信息处理.

E-mail: huhuijuan1012@sina.com



程玉虎 男, 1973 年生于安徽淮南, 2005 年获中国科学院自动化研究所控制理论与控制工程专业博士学位, 现为中国矿业大学信息与电气工程学院教授、博士生导师. 主要研究方向为机器学习与模式识别、智能系统等.

E-mail: chengyuhu@163.com