

DOI:10.16356/j.1005-2615.2021.05.005

鲁棒的低秩鉴别嵌入回归

姚裕¹, 万鸣华¹, 黄伟²

(1. 南京审计大学信息工程学院, 南京 211815; 2. 韩山师范学院计算机与信息工程学院, 潮州 521041)

摘要: 局部保持投影 (Locality preserving projection, LPP) 在特征提取中得到了广泛的应用。但是, LPP 不使用数据的类别信息, 并且采用 L_2 范数来进行距离测量, 对异常值高度敏感。本文从监督的角度考虑 LPP 的权值矩阵, 并结合低秩回归的方法, 提出一种新的模型来发现和提取特征。利用 $L_{2,1}$ 范数来约束损失函数和回归矩阵, 不仅降低了对异常值的敏感性, 而且限制了回归矩阵的低秩条件。然后给出了优化问题的求解方法。最后, 本文将该方法应用于多个人脸数据库和掌纹数据集进行了性能测试, 并将实验结果与现有的一些方法进行比较, 结果表明该方法是有效的。

关键词: 局部保持投影; 低秩回归; 监督; 特征提取; 流形学习

中图分类号: TP391.4 **文献标志码:** A **文章编号:** 1005-2615(2021)05-0692-08

Robust Low-Rank Discriminant Embedded Regression

YAO Yu¹, WAN Minghua¹, HUANG Wei²

(1. School of Information Engineering, Nanjing Audit University, Nanjing 211815, China; 2. School of Computer and Information Engineering, Hanshan Normal University, Chaozhou 521041, China)

Abstract: Locality preserving projection (LPP) has been widely used in feature extraction. However, LPP does not use category information of data, and uses L_2 -norm for distance measurement, which is highly sensitive to outliers. We consider the weight matrix of LPP from a supervised perspective, and combine the method of low-rank regression to propose a new model to discover and extract features. By using $L_{2,1}$ -norm to constrain the loss function and the regression matrix, not only the sensitivity to outliers is reduced, but also the low-rank condition of the regression matrix is restricted. Then we propose a solution to the optimization problem. Finally, we apply the method to a series of face database and palmprint dataset to test performance, and the experimental results show that the proposed method is effective.

Key words: locality preserving projection (LPP); low-rank regression; supervised; features extracting; manifold-learning

特征提取是人脸识别过程中比较重要的组成步骤, 在研究特征提取的过程中, 产生了许多降维的方法^[1-2], 如主成分分析 (Principal component analysis, PCA)^[3] 和线性判别分析 (Linear discrimi-

nant analysis, LDA)^[4]。PCA 和 LDA 是经典的线性降维方法, 它们不能用于处理非线性数据结构。然而, 现实中的高维数据大多是非线性的。对于处理许多高维非线性数据, 流形学习是一个非常有效

基金项目: 2020 年江苏省科研与实践创新计划 (SJCX20_0670) 资助项目; 国家自然科学基金面上 (61876213) 资助项目; 江苏省自然科学基金面上 (BK20201397) 资助项目; 江苏省高校自然科学研究重大 (18KJA520005) 资助项目; 2016 年广东省自然科学基金-粤东西北创新人才联合培养基金 (2016A030307050) 资助项目; 2016 年广东省公益能力研究基金 (2016A020225008) 资助项目; 2017 年广东省科技厅平台建设基金 (2017A040405062) 资助项目。

收稿日期: 2020-10-08; **修订日期:** 2020-12-06

通信作者: 万鸣华, 男, 博士后, 校聘教授, 硕士生导师, E-mail: wmh36@sina.com。

引用格式: 姚裕, 万鸣华, 黄伟. 鲁棒的低秩鉴别嵌入回归[J]. 南京航空航天大学学报, 2021, 53(5): 692-699. YAO Yu, WAN Minghua, HUANG Wei. Robust low-rank discriminant embedded regression[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2021, 53(5): 692-699.

的方法。在基于流形学习的方法中,比较著名的是局部线性嵌入(Locally linear embedding, LLE)^[5]和等度量映射(Isometric mapping, ISOMAP)^[6]。LLE保持数据的局部线性结构,它假设每个点可以表示为该点的一个线性加权组合的邻居,然后希望他们在子空间投影中保持相同的线性关系,这样就可以通过线性关系获得投影向量。然而,传统的LLE方法只能应用于试验数据,对新数据没有很好的映射。与LLE方法相比,局部保持投影(Locality preserving projection, LPP)^[7-8]是很经典的图嵌入方法,能够较好地映射新样本。LPP构造一个邻域加权矩阵,使之前相似的数据在投影后趋于接近。然而,传统的流形学习方法有一些缺点,例如,尽管通过使用图嵌入的方法和度量其相邻点的局部结构的垂直距离来保留重要的局部信息,但其本质上是一种无监督的方法,它没有有效地使用样本标签信息,而标签信息在分类任务中很重要。为了解决这一问题,人们提出了许多LPP的监督方法,如监督局部保持投影(Supervised locality preserving projection, SLPP)^[9]、增强监督局部保持投影(Enhanced supervised locality preserving projection, ESLPP)^[10]和监督主局部保持投影(Supervised principal locality preserving projection, SPLPP)^[11]等,这些监督方法都取得了较好的表现。

近年来,最小二乘回归方法得到了广泛的应用。回归公式不仅可以与传统方法相结合,在传统方法的基础上生成更为简化的模型,还可以将回归矩阵分解为投影矩阵和回归矩阵,对回归矩阵施加低秩约束。这些优点使得模型的特征更加明显。然而,目前的回归公式大多采用 L_2 范数进行度量,对样本异常值(噪声、阴影等)鲁棒性不足,鲁棒回归方法度量的是具有 $L_{2,1}$ 范数的回归模型^[12]。由于 $L_{2,1}$ 范数没有平方运算,减少了异常值对距离的影响,因此,本文使用 $L_{2,1}$ 范数来度量损失函数,使模型更具有鲁棒性。

此外,这些流形学习方法和回归方法通过 L_1 范数正则项约束投影矩阵,相较于 $L_{2,1}$ 范数,不仅增加了计算成本,而且联合稀疏性无法保证。在稀疏要求上,与 L_1 范数不同, $L_{2,1}$ 范数也要求行稀疏。在文献[13-15]中, $L_{2,1}$ 范数被应用于损失函数和正则项的测量来得到鲁棒的联合稀疏特征提取。

传统的流形学习方法在降维方面有其独特的优势,例如LPP方法通过构造最邻近加权图对样本进行约束。但由于这些方法大多使用 L_2 范数进行距离测量,并且是基于无监督的方法,模型缺乏鲁棒性。针对这些问题,本文考虑了鲁棒回归模型

的优点、 $L_{2,1}$ 范数的特征和样本的类别信息,并结合这些模型的优点提出了一种新的模型,该方法称为监督低秩嵌入式回归(Supervised low-rank embedded regression, SLRER)。该方法是一种基于流形学习思想和回归模型的新方法。模型使用 $L_{2,1}$ 范数来作为损失函数的度量,在使模型更鲁棒的情况下获得更多的投影方向,并且将 $L_{2,1}$ 范数引入正则项的约束,增加稀疏性。同时,施加类内以及类间的权值矩阵来进行嵌入分析,充分利用样本的类别信息,最后对重构矩阵进行分解,将矩阵分解为回归矩阵以及投影矩阵,以此来保证重构矩阵的低秩性。利用迭代方法求解模型的最优解,并在数据集测试了该方法的性能。

1 相关工作

1.1 符号和定义

设矩阵 $X=[x_1, x_2, \dots, x_i, \dots, x_n]$ 表示样本矩阵,包含 n 个样本。每个样本是一个 m 维的列向量。

本文采用 $L_{2,1}$ 范数作为损失函数,给出 $L_{2,1}$ 范数的定义如下

$$\|X\|_{2,1} = \sum_{i=1}^n \sqrt{\sum_{j=1}^m x_{ij}^2} = \sum_{i=1}^n \|x^i\|_2 \quad (1)$$

1.2 局部保持投影

LPP捕获嵌入流形结构中的数据的局部几何结构,通过计算邻域图 W 来表示数据点之间的权值关系,图 W 的定义为

$$W_{ij} = \begin{cases} \exp(-\|x_i - x_j\|_2^2/t) & x_i \in C_k(x_j) \text{ 或者 } x_j \in C_k(x_i) \\ 0 & \text{其他} \end{cases} \quad (2)$$

式中: $C_k(x_i)$ 为 x_i 的 k 个最近数据点的集合; W_{ij} 表示矩阵 W 的第 i 行和第 j 列。

假设 $P \in \mathbf{R}^{m \times d}$ 是一个投影矩阵,低维向量 y_i 是由高维向量 x_i 通过 P 的投影得到的,如果高维数据 x_i 与 x_j 接近,那么低维数据 y_i 与 y_j 也应该尽可能接近。因此,LPP的目标函数定义为

$$\min_P \sum_{ij} \|P^T x_i - P^T x_j\|_2^2 W_{ij} \quad (3)$$

经过简单计算,式(3)可转化为

$$\min_P \text{tr} [P^T X(D - W)X^T P] \quad (4)$$

式中: D 为一个对角矩阵,它的元素是 W 这个矩阵的行和, $D_{ii} = \sum_j W_{ij}$ 。对式(4)施加约束 $P^T XDX^T P = I_d$,以避免平凡解,其中 I_d 为 $d \times d$ 的单位矩阵。经过计算,式(4)可转化为特征值问题

$$XLX^T P = XDX^T PA \quad (5)$$

式中: $L = V - W$; A 为关于 P 的特征值矩阵。

1.3 低秩线性回归

低秩线性回归 (Low-rank linear regression, LRLR) 是对传统线性回归的改进。LRLR 在线性回归的基础上对回归矩阵增加了一个低秩约束。目标函数如下

$$\min_D \|Y - X^T D\|_F^2 \quad \text{s.t.} \quad \text{rank}(D) \leq s \quad (6)$$

式中: $s \leq \min(n, k)$; $Y \in \mathbb{R}^{n \times k}$ 为包含样本标签信息的矩阵, 如 x_i 属于第 j 类, 则 $Y_{ij} = 1$, 反之 $Y_{ij} = 0$; $D \in \mathbb{R}^{m \times k}$ 表示的是投影矩阵。通过对投影矩阵 D 的秩进行约束, LRLR 不仅可以有效地将样本中的噪声、阴影、重复样本等信息去除, 同时也能更好地挖掘类间的潜在信息。

2 目标函数以及迭代方法

2.1 SLRER 目标函数

考虑到流形学习和线性回归的优点, 建立样本点与其邻域点之间的关系, 将样本点回归到邻域点, 并通过加权矩阵约束这种关系。还考虑了样本的类别信息, 通过约束各个类别的均值向量之间的关系, 提出了基于 LRLR 的目标函数如下

$$\min_{A,B} \sum_{ij} \|x_i^T - x_j^T Z\|_2 W_{ij}^c - \sum_{ij} \|m_i^T - m_j^T Z\|_2 W_{ij}^b \quad \text{s.t.} \quad \text{rank}(Z) \leq s \quad (7)$$

式中: $s \leq \min(n, m)$ 为低秩约束; $Z \in \mathbb{R}^{m \times m}$ 为回归矩阵; $m_i = \frac{1}{n} \sum_{i=1}^n x_i$ 为每个样本类的均值向量; W_{ij}^c 表示相邻点之间关系的与 LPP 相同的权值矩阵, W_{ij}^b 为 m_i 和 m_j 的权值, 用于调节 m_i 和 m_j 的结构, $W_{ij}^b = \exp(-\|m_i - m_j\|_2^2 / \eta)$, $\eta \in \mathbb{R}$ 。模型 (7) 的第一项是约束样本点及其邻域点, 使重构误差最小, 第二项是通过均值向量约束类间。最后将低秩约束应用到回归矩阵中, 找到局部邻域的低秩表示关系。因此, 模型 (7) 不仅保留了局部结构, 而且通过探索低秩关系找到了全局结构。并且, 在使用 $L_{2,1}$ 范数增强鲁棒性的同时, 笔者在模型中加入回归矩阵的稀疏条件, 得到模型如下

$$\min_{A,B} \sum_{ij} \|x_i^T - x_j^T Z\|_2 W_{ij}^c - \sum_{ij} \|m_i^T - m_j^T Z\|_2 W_{ij}^b + \lambda \|Z\|_{2,1} \quad \text{s.t.} \quad \text{rank}(Z) \leq r \quad (8)$$

式中 $\lambda > 0$ 为正则化参数。但由于模型 (8) 是非凸问题, 很难求解。由文献 [16] 可以看出, 在线性判别子空间中, 低秩线性回归等同于线性回归。对于模型 (8), 可以用相同的方法 [16] 得到如

下模型

$$\min_{A,B} \sum_{ij} \|x_i^T - x_j^T AB\|_2 W_{ij}^c - \sum_{ij} \|m_i^T - m_j^T AB\|_2 W_{ij}^b + \lambda \|AB\|_{2,1} \quad \text{s.t.} \quad A^T A = I_d \quad (9)$$

式中: $A \in \mathbb{R}^{m \times d}$, $B \in \mathbb{R}^{d \times m}$, $Z = AB$ 和 $\text{rank}(Z) = \text{rank}(AB) \leq d$ 。该模型对低秩约束进行分解, 使其易于求解, 并通过正交约束避免了平凡解。在 2.2 节中, 本文将展示如何用迭代算法求解模型 (9)。

2.2 优化方法

在本节中给出模型 (9) 的解, 首先定义矩阵 M

$$M_{ii} = \frac{1}{2\|(AB)^i\|_2 + \delta} \quad (10)$$

式中: M_{ii} 表示矩阵的对角值; $(AB)^i$ 则表示矩阵的第 i 个值。本文增加了 δ 常数约束, 防止分母为 0。由模型 (9) 可得

$$\begin{aligned} \min_{A,B} \sum_{ij} \|x_i^T - x_j^T AB\|_2 W_{ij}^c - \sum_{ij} \|m_i^T - m_j^T AB\|_2 W_{ij}^b + \lambda \|AB\|_{2,1} = & \min_{A,B} \sum_{ij} \text{tr}[(x_i^T - x_j^T AB)^T S_{ij} (x_i^T - x_j^T AB)] - \sum_{ij} \text{tr}[(m_i^T - m_j^T AB)^T J_{ij} (m_i^T - m_j^T AB)] + \\ & \lambda \text{tr}(B^T A^T MAB) = \min_{A,B} \text{tr}[XHX^T - 2B^T A^T XSX^T + B^T A^T XHX^T AB - \\ & \bar{X}F\bar{X}^T + 2B^T A^T \bar{X}J\bar{X}^T - B^T A^T \bar{X}F\bar{X}^T AB + \lambda B^T A^T MAB] \quad (11) \end{aligned}$$

式中

$$S_{ij} = \frac{W_{ij}^c}{2\|(x_i^T - x_j^T AB)^i\|_2 + \delta} \quad (12)$$

$$J_{ij} = \frac{W_{ij}^b}{2\|(m_i^T - m_j^T AB)^i\|_2 + \delta} \quad (13)$$

H 和 F 都是对角矩阵, 其中 $H_{ii} = \sum_{j=1}^n S_{ij}$, $F_{ii} = \sum_{j=1}^n J_{ij}$; δ 仍然是一个受约束的常数。

因为在迭代过程中, 总是使用上次更新的矩阵 A 和 B 计算矩阵 S 和 J , 所以 $\text{tr}(XHX^T)$ 和 $\text{tr}(\bar{X}F\bar{X}^T)$ 在那时变成一个常数, 在计算当前最优解变量 A 和 B 中可以忽略。因此, 模型 (11) 可转化为以下优化问题

$$\begin{aligned} \min_{A,B} \text{tr}[-2B^T A^T (XSX^T - \bar{X}J\bar{X}^T) + & B^T (A^T XHX^T A - A^T \bar{X}F\bar{X}^T A + \lambda A^T MA) B] \\ \text{s.t.} \quad A^T A = I_d \quad (14) \end{aligned}$$

对于两个变量, 本文固定了一个变量。令其对 B 的偏导数为 0, 可得

$$\begin{aligned}
 & -2A^T X S X^T + 2A^T \bar{X} J \bar{X}^T + 2(A^T X H X^T A - \\
 & A^T \bar{X} F \bar{X}^T A + \lambda A^T M A) B = 0 \Rightarrow (A^T X H X^T A - \\
 & A^T \bar{X} F \bar{X}^T A + \lambda A^T M A) B = A^T X S X^T - \\
 & A^T \bar{X} J \bar{X}^T \Rightarrow B = (A^T X H X^T A - A^T \bar{X} F \bar{X}^T A + \\
 & \lambda A^T M A)^{-1} (A^T X S X^T - A^T \bar{X} J \bar{X}^T) \quad (15)
 \end{aligned}$$

对于变量 A , 设 $\Psi = A^T X H X^T A - A^T \bar{X} F \bar{X}^T A + \lambda A^T M A$, 将式 (14) 转换为 $B = \Psi^{-1} (A^T X S X^T - A^T \bar{X} J \bar{X}^T)$ 。将 Ψ 和 B 代入式 (15), 得到优化问题

$$\begin{aligned}
 \min_{A^T A = I_d} \text{tr} [-2B^T A^T (X S X^T - \bar{X} J \bar{X}^T) + B^T \Psi B] = \\
 \min_{A^T A = I_d} \text{tr} [(X S^T X^T A - \bar{X} J \bar{X}^T A) \Psi^{-1} (A^T X S X^T - \\
 A^T \bar{X} J \bar{X}^T)] \quad (16)
 \end{aligned}$$

将 Ψ 代入式 (16) 后, 式 (16) 会转换为

$$\begin{aligned}
 \max_{A^T A = I_d} \text{tr} [(A^T (X H^T X^T - \bar{X} F \bar{X}^T + \lambda M) A)^{-1} A^T \\
 (X S X^T - \bar{X} J \bar{X}^T) (X S^T X^T - \bar{X} J^T \bar{X}^T) A] \quad (17)
 \end{aligned}$$

本文用拉格朗日乘子法来解决这个最大化问题。经过简单计算, 式 (17) 可以转化为特征值问题 $(X H^T X^T - \bar{X} F \bar{X}^T + \lambda M)^{-1} [(X S X^T - \bar{X} J \bar{X}^T) (X S^T X^T - \bar{X} J^T \bar{X}^T)] A = \mathbf{A} \mathbf{A}$ (18)

式中: \mathbf{A} 为 A 所对应的特征值矩阵, 最优解由 \mathbf{A} 所对应的最大 d 个特征向量组成。

算法 1 给出了 SLRER 的整个流程。

算法 1 SLRER

输入: 训练集 X , 维度 d , 迭代数 T , 参数 λ , 权重矩阵 W^c 和 W^b

(1) 初始化 $S = W^c$, $J = W^b$ 和 $H_{ii} = \sum_{i=1}^n S_{ij}$,

$F_{ii} = \sum_{i=1}^n J_{ij}$, M 为单位矩阵。

(2) 初始化 A 为 $d \times s$ 正交矩阵。

(3) 从 $i = 1 : T$ 做

通过式 (15) 更新 B ;

通过式 (18) 更新 A ;

通过式 (12) 更新 S ;

通过式 (13) 更新 J ;

通过式 (10) 更新 M 。

(4) 规范化 A 。

输出: 投影矩阵 A 。

3 实 验

3.1 数据集

ORL 人脸数据库由 40 人组成, 每个人有 10 张

图像, 包含了不同的姿势和面部表情, 每幅图像为 56 像素 \times 46 像素。

FERET 人脸数据库包含 200 人组成的 1 400 张图像, 取自每个个体受不同光照影响的图像, 每幅图像被调整为 40 像素 \times 40 像素。

PolyU 掌纹库包含 100 个不同人的 600 幅图像。这些图像采集了两次, 间隔两个月。每幅图像被裁剪为 128 像素 \times 128 像素。

3.2 随机像素破坏的鲁棒性检验

为了测试 SLRER 在面对不同像素破坏时的鲁棒性, 本文依次在 ORL 和 FERET 数据库中加入高斯噪声和椒盐噪声, 密度分别为 0.2 和 0.1。图 1 是 ORL 和 FERET 数据库的干净图像, 以及高斯噪声和椒盐噪声下的被破坏图像。本文选取每个个体的 p 张图像作为训练样本, 其中 ORL 数据库中, $p = 3, 4, 5, 6$; FERET 数据库中, $p = 2, 3, 4, 5$ 。PCA、LDA、LRR、NPE、LPP、SPP 和 SLRER 对随机像素破坏的最高分类准确率如图 2、表 1 和 2 所示。

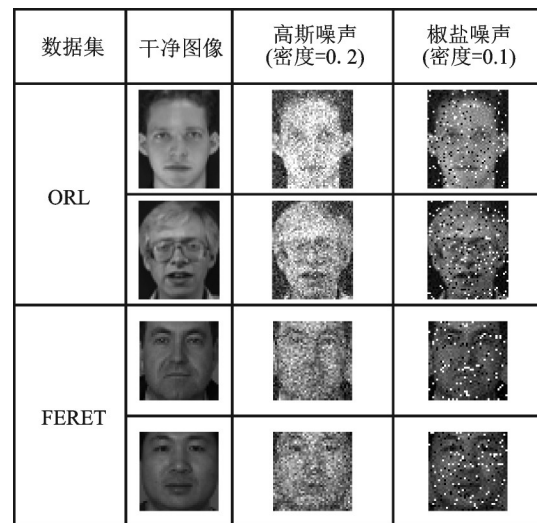
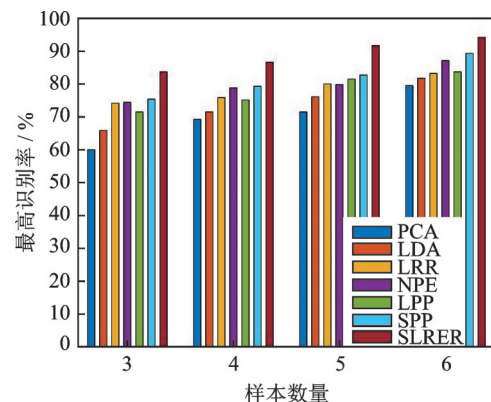



图 1 来自 ORL 和 FERET 数据库的样本图像以及相应的具有不同密度的高斯噪声和椒盐噪声的图像


Fig.1 Sample images from ORL and FERET databases and corresponding images with Gaussian and salt & pepper noise



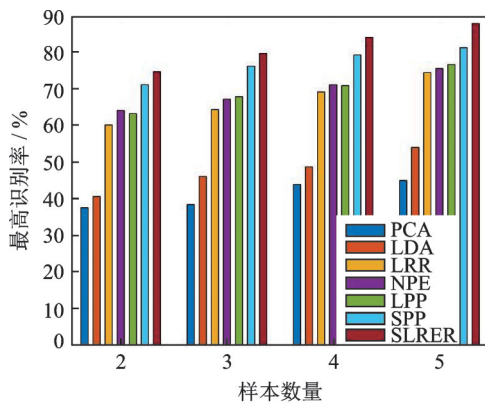
(a) ORL database (Gaussian density=0.2)



(b) ORL database (Salt density=0.1)



(c) FERET database (Gaussian density=0.2)



(d) FERET database (Salt density=0.1)

图2 基于高斯噪声和椒盐噪声在ORL和FERET数据库上的分类精度

Fig.2 Classification accuracy of ORL and FERET databases under Gaussian noise and salt & pepper noise

表1 像素破坏下ORL人脸库上各算法的最高识别率

Table 1 The highest recognition rate of each algorithm in ORL database under pixel damage

算法	高斯噪声(密度等于0.2)				椒盐噪声(密度等于0.1)			
	3	4	5	6	3	4	5	6
PCA	60.10	69.08	71.37	79.56	62.76	70.11	72.75	78.50
LDA	65.78	71.25	75.95	81.62	64.21	71.16	75.06	80.06
LPP	73.92	75.75	80.42	83.04	72.85	76.55	79.12	85.37
NPE	74.28	78.66	79.66	86.95	73.95	77.25	77.21	85.05
LRR	71.25	75.33	81.27	83.65	70.11	73.91	80.11	85.07
SPP	75.21	79.15	82.61	89.05	76.26	82.71	84.25	88.52
SLRER	83.42	86.41	91.51	94.12	84.42	88.5	91.20	93.75

表2 像素破坏下FERET人脸库上各算法的最高识别率

Table 2 The highest recognition rate of each algorithm in FERET database under pixel damage

算法	高斯噪声(密度等于0.2)				椒盐噪声(密度等于0.1)			
	2	3	4	5	2	3	4	5
PCA	35.21	40.75	43.5	48.12	37.52	38.21	43.75	45.12
LDA	39.12	44.50	52.23	55.89	40.55	46.08	48.66	53.80
LPP	62.11	66.39	71.06	77.33	60.09	64.11	69.01	74.25
NPE	61.24	68.25	74.11	77.32	64.05	67.06	71.06	75.33
LRR	63.31	68.52	71.41	75.91	63.21	67.81	70.72	76.56
SPP	70.51	75.25	78.10	83.90	70.99	76.15	79.10	81.11
SLRER	75.6	80.11	83.22	88.51	74.50	79.61	83.95	87.62

3.3 连续像素遮挡的鲁棒性检验

为了进一步测试SLRER在面对不同级别连续遮挡数据时的鲁棒性,在图像中不同位置随机添加一些遮挡块,将图像中遮挡块的大小分别设置为5×5和10×10。图3显示了来自ORL和FERET数据库的原始图像和不同程度连续遮挡下的被破坏图像。PCA、LDA、LPP、NPE、LRR、SPP和SLRER在对不同像素遮挡水平下的最高分类准确率如图4、表3和4所示。






图3 来自ORL和FERET数据库中的样本图像和对应的不同像素块遮挡下的图像


Fig.3 Sample images from ORL and FERET databases and corresponding images under the occlusion of different pixel blocks




(a) ORL database(5×5 block)



(b) ORL database (10×10 block)



(c) FERET database(5×5 block)



(d) FERET database(10×10 block)

图 4 基于 5×5 和 10×10 块遮挡在 ORL 和 FERET 数据库上的分类精度

Fig.4 Classification accuracy of ORL and FERET databases under occlusion of 5×5 and 10×10 blocks

表 3 像素遮挡下 ORL 人脸库上各算法的最高识别率

Table 3 The highest recognition rate of each algorithm in ORL database under pixel occlusion

算法	遮挡块大小 5×5				遮挡块大小 10×10			
	3	4	5	6	3	4	5	6
PCA	57.87	64.37	70.83	76.51	56.42	60.21	66.83	70.21
LDA	66.71	72.34	74.5	80.21	64.27	69.55	72.61	78.25
LPP	68.21	73.33	75.67	81.25	67.21	72.36	76.53	80.67
NPE	70.08	75.99	78.91	85.05	65.5	70.17	73.62	83.25
LRR	73.66	77.11	78.11	83.06	67.34	72.6	78.07	81.95
SPP	78.81	81.66	83.71	85.55	73.46	78.21	83.21	86.53
SLRER	86.07	88.33	90.61	93.58	83.05	86.58	88.51	92.12

表 4 块遮挡下 FERET 人脸库上各算法的最高识别率

Table 4 The highest recognition rate of each algorithm in FERET database under block occlusion

算法	遮挡块大小 5×5				遮挡块大小 10×10			
	2	3	4	5	2	3	4	5
PCA	36.34	37.65	41.75	43.3	33.55	36.14	39.59	42.33
LDA	40.81	45.52	50.25	54.67	40.10	43.53	48.64	52.81
LPP	59.21	61.36	66.21	71.17	56.09	58.11	65.34	69.09
NPE	59.05	65.01	71.98	74.09	57.11	62.03	68.77	72.95
LRR	57.42	64.28	67.69	73.90	55.80	62.61	65.30	72.34
SPP	65.39	70.25	77.65	80.52	63.21	66.96	74.11	78.10
SLRER	75.23	78.16	82.33	87.60	73.32	76.61	81.45	86.12

3.4 PolyU 掌纹库实验测试

PolyU 数据集包含 600 幅图像。每张图像大小被调整为 128 像素×128 像素。为了进一步测试 SLRER 在掌纹数据库上的鲁棒性,本文分别在样本图像上添加了 5×5 遮挡块和 10×10 遮挡块。图 5 为该数据集中的原始图像与 5×5 遮挡块和 10×10 遮挡块的损坏图像。笔者为每个掌纹选择 3 张图片作为训练样本,实验结果如图 6 和表 5 所示。

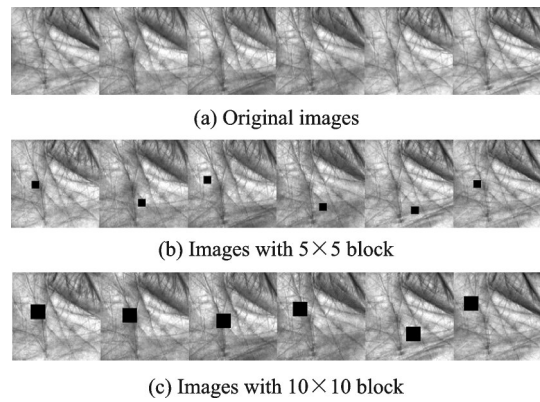


图 5 来自 PolyU 掌纹库的图片

Fig.5 Images from PolyU palmprint database

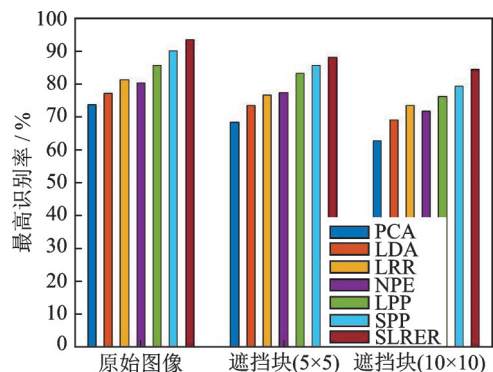


图 6 各算法 PolyU 数据集的分类准确率

Fig.6 Classification accuracy of PolyU dataset of each algorithm

表5 PolyU掌纹库上各算法的最高识别率

Table 5 The highest recognition rate of each algorithm in PolyU database

算法	原始图像	遮挡块5×5	遮挡块10×10
PCA	73.51	68.21	62.52
LDA	77.11	73.32	69.15
LPP	81.24	76.56	73.34
NPE	80.27	77.15	71.69
LRR	85.63	83.12	76.87
SPP	89.92	85.61	79.13
SLRER	93.31	88.70	84.30

4 结果分析

对于人脸数据集,图2和图4显示了所有方法在ORL和FERET数据集上的最高识别率随训练样本数量的变化,最佳识别率列于表1、2和表3、4。由图2、4及表1~4可知,LPP和NPE方法作为流行学习方法,比起PCA和LDA识别率较有提升,因为LPP和NPE都采用了图嵌入的思想,通过权重图来约束样本相邻点的相似度,流行学习方法更侧重于保留数据内在的局部邻域结构。SPP对比LPP和NPE,SPP旨在对每一个样本进行剩余样本的线性重构,对目标函数施加 L_1 范数的正则项,并对权重矩阵进行稀疏表示,在对包含噪声的原始数据时,能通过学习到的最优稀疏重构系数进行更好的投影,在表现性能上略优于LPP和NPE方法。LRR作为一种低秩表示方法,将样本矩阵作为字典并进行自表示,在对噪声的鲁棒性上具有明显的优势。与PCA和LDA相比,因为引入了流形学习的思想,将子空间图嵌入模型融入SLRER中,所以使得SLRER效果更加显著。同时,SLRER在考虑样本流形结构的情况下引入回归矩阵,并通过对回归矩阵的分解来引入低秩特性提取主要特征,从而获得了更好的性能。对比LPP、SPP和LRR,SLRER的识别率提升为5%~15%,这是因为SLRER使用 $L_{2,1}$ 范数作为基本的损失函数度量,替代了 L_2 范数的距离度量方法,省去平方运算,对噪声等异常值敏感度降低,而使用 $L_{2,1}$ 范数作为正则化约束,保证投影矩阵的联合稀疏性。最后,为了测试SLRER的稳定性,图6和表5分别显示了SLRER在PolyU掌纹数据集上原始样本的最高识别率和样本加噪后的最高识别率。从图6和表5中可以看出,SLRER在经过块遮挡干扰后仍能保持良好的识别率,模型具有良好的鲁棒性。

5 结论

线性回归和流形学习方法在特征提取中效果

显著,本文在这基础上提出了一种有监督的低秩重构方法。通过带有类别信息的权重矩阵进行图嵌入学习,对回归矩阵进行低秩重构,分解为回归矩阵及投影矩阵,保留低秩特性。通过在损失函数中引入 $L_{2,1}$ 范数,降低了模型对样本异常值的敏感性,增强了模型的鲁棒性。此外增加了 $L_{2,1}$ 范数正则化项,保证投影联合稀疏特性,从而提取主要特征。在提出求解算法时,通过迭代方法求解回归矩阵,使其更容易获得最优解。最后,对模型进行了实验分析,进一步验证了该方法的有效性。

参考文献:

- [1] 任克强,张静然.基于局部Fisher准则判别投影的人脸识别算法[J].传感器与微系统,2019,38(7):113-116,120.
REN Keqiang, ZHANG Jingran. Face recognition algorithm based on local Fisher criterion discriminant projections[J]. Transducer and Microsystem Technologies, 2019, 38(7): 113-116, 120.
- [2] YANG Jian, ZHANG David, YANG Jingyu. Constructing PCA baseline algorithms to reevaluate ICA-based face-recognition performance[J]. IEEE Transactions on Systems, Man, and Cybernetics. Part B, Cybernetics: A Publication of the IEEE Systems, Man, and Cybernetics Society, 2007, 37(4): 1015-1021.
- [3] ZUO Wangmeng, ZHANG David, YANG Jian, et al. BDPCA plus LDA: A novel fast feature extraction technique for face recognition[J]. IEEE Transactions on Systems, Man, and Cybernetics. Part B, Cybernetics: A Publication of the IEEE Systems, Man, and Cybernetics Society, 2006, 36(4): 946-953.
- [4] NIE Feiping, WANG Zheng, WANG Rong, et al. Adaptive local linear discriminant analysis[J]. ACM Transactions on Knowledge Discovery from Data, 2020, 14(1): 1-19.
- [5] XU Zhijie, ZHANG Jianqin, XU Zhidan, et al. Locally linear embedding by linear programming[J]. Procedia Engineering, 2011, 15: 3041-3045.
- [6] WANG Cheng, FU Weihua, HUANG Haiyang, et al. Isomap-based three-dimensional operational modal analysis[J]. Scientific Programming, 2020. DOI: 10.1155/2020/6348372.
- [7] WANG Aiguo, ZHAO Shenghui, LIU Jinjun, et al. Locality adaptive preserving projections for linear dimensionality reduction[J]. Expert Systems with Applications, 2020. DOI: 10.1016/j.eswa.2020.113352.
- [8] GUO Jinyu, WANG Xin, LI Yuan. Fault detection based on improved local entropy locality preserving projections in multimodal processes[J]. Journal of

- Chemometrics, 2019. DOI: 10.1002/cem.3116.
- [9] ZHANG Zhiwei, YANG Fan, XIA Kewen, et al. A supervised LPP algorithm and its application to face recognition[J]. Journal of Electronics and Information Technology, 2008(3): 539-541.
- [10] CAI Xianfa, WEN Guihua, WEI Jia, et al. Enhanced supervised locality preserving projections for face recognition[C]//Proceedings of 2011 International Conference on Machine Learning and Cybernetics. [S.l.]: IEEE, 2011, 4: 1762-1766.
- [11] LUO Renbo, PI Youguo, LIAO Wenzhi. Research on supervised LPP feature extraction for hyperspectral image[J]. Remote Sensing Technology and Application, 2012, 27(6): 46-52.
- [12] MO Dongmei, LAI Zhihui. Robust jointly sparse regression with generalized orthogonal learning for image feature selection[J]. Pattern Recognition, 2019, 93: 164-178.
- [13] NIE Feiping, HUANG Heng, CAI Xiao, et al. Efficient and robust feature selection via joint $L_{2,1}$ -norms minimization[C]//Proceedings of International Conference on Neural Information Processing Systems. [S.l.]: Curran Associates Inc, 2010.
- [14] ZHANG Zhao, LI Fanzhang, ZHAO Mingbo, et al. Robust neighborhood preserving projection by nuclear/ $L_{2,1}$ -norm regularization for image feature extraction[J]. IEEE Trans Image Process, 2017, 26(4): 1607-1622.
- [15] LAI Zhihui, MO Dongmei, WONG Waikeung, et al. Robust discriminant regression for feature extraction[J]. IEEE Transactions on Cybernetics, 2017. DOI: 10.1109/TCYB.2017.2740949.
- [16] CAI X, DING C, NIE F P, et al. On the equivalent of low-rank linear regressions and linear discriminant analysis based regressions[C]//Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. [S.l.]: ACM, 2013: 1124-1132.

(编辑:胥橙庭)