



Fig.2 Relationship between the samples of j -th class and dictionary atoms
图 2 第 j 类样本和字典原子之间的关系

2 基于 SPD 流形潜在稀疏表示分类算法

本节将介绍基于 SPD 流形潜在稀疏表示分类算法.首先,将 SPD 矩阵映射到 RKHS 中,提出了核空间潜在稀疏表示模型及潜在分类模型;然后,使用 Nyström 方法得到 SPD 矩阵在 RKHS 中的近似表示来学习核空间中的潜在字典和潜在矩阵.

2.1 核空间潜在稀疏表示模型

本小节介绍核空间潜在稀疏表示模型及潜在分类模型.现有 M 类样本,测试样本 $Y \in S_n^+$ 和潜在字典: $D = \{d_1, d_2, \dots, d_N\}$, $d_i \in S_n^+$.该字典在核空间中的表示形式可以被写为: $\psi(D) = [\varphi(d_1), \varphi(d_2), \dots, \varphi(d_N)]$,潜在矩阵^[28]: $W \in R^{N \times M}$.核空间的潜在稀疏表示模型如下:

$$\tilde{v}_j = \arg \min_{v_j \in R^N} (\|\varphi(Y) - \psi(D)diag(Wc_j)v_j\|_2^2 + \lambda \|v_j\|_1) \tag{6}$$

\tilde{v}_j 是样本 $\varphi(Y)$ 相对于第 j 列潜在向量 Wc_j 的稀疏系数,该潜在向量表示核空间中第 j 类样本与字典中原子的关系.则该测试样本与第 j 类样本的重构误差为

$$Err_j = \|\varphi(Y) - \psi(D)diag(Wc_j)\tilde{v}_j\|_2^2 \tag{7}$$

通过公式(7),可以求得测试样本对于每一个类样本的重构误差.那么我们可以根据重构误差的大小来给测试样本进行分类,并将测试样本划分到重构误差最小的一类:

$$identity(Y) = \arg \min_j (Err_j), j = 1, 2, \dots, M \tag{8}$$

由于核映射 φ 没有具体的表达形式,所以公式(6)的第 1 项和公式(7)都需要利用核技巧改写.其中,公式(6)中的第 1 项可以改写为

$$\begin{aligned} \|\varphi(Y) - \psi(D)diag(Wc_j)v_j\|_2^2 &= \|\varphi(Y) - \sum_{i=1}^N Wc_{j,i}v_{j,i}\varphi(d_i)\|_2^2 \\ &= k(Y, Y) - 2v_j^T diag(Wc_j)K(Y, D) + v_j^T diag(Wc_j)K(D, D)diag(Wc_j)v_j \end{aligned} \tag{9}$$

公式(9)中的 $K(Y, D) = [k(Y, d_1), k(Y, d_2), \dots, k(Y, d_N)]^T$, $K = [k_{i,j}]_{N \times N}$; $k_{i,j} = k(d_i, d_j)$.其中,经过改写后的公式(6)的优化问题是核化 Lasso 问题^[23,26,27,34],也可以用 CVX 工具包^[23,35]进行优化求解.同理,公式(7)也可以通过利用核技巧改写求得重构误差.由公式(9)可知,核空间潜在稀疏表示分类方法无须知道核映射 φ 的具体形式,只需要知道测试样本与字典原子通过核函数所得到的向量 K 和字典原子之间通过黎曼核函数得到的核矩阵 K ,就可以得到测试样本 Y 的稀疏系数及对于每一个类样本的重构误差,然后根据重构误差的大小将测试样本分类.

2.2 核空间潜在字典学习模型

核空间的潜在字典和潜在矩阵^[28]在我们提出的分类算法中起着至关重要的作用,但是核映射 φ 没有明确的形式,阻碍了核空间中潜在字典和潜在矩阵的更新.为了能够得到核空间的潜在字典和潜在矩阵,我们使用

Nyström 方法得到训练样本在核空间的近似表示,通过样本的近似表示去学习核空间的潜在字典和潜在矩阵^[28].

现有 M 类样本,训练样本集为: $X=\{X_1, X_2, \dots, X_M\}$,其中, $X_j=\{X_{j,1}, X_{j,2}, \dots, X_{j,m}\}$ 为第 j 类样本的子集,该子集中的每个样本都是 SPD 矩阵且样本的个数为 m .对于该训练集合,可以使用第 1.2 节中的 Nyström 方法得到训练样本在 RKHS 中的近似表示: $Z(X)=[Z(X_1), Z(X_2), \dots, Z(X_M)]$,其中, $Z(X_j)$ 为第 j 类的 m 个训练样本集合 X_j 的核空间近似表示集合.在核空间的潜在字典学习模型中,需要被学习的有潜在字典: $D=[d_1, d_2, \dots, d_N]$ 和潜在矩阵 $\mathcal{W}=[\mathcal{W}c_1, \mathcal{W}c_2, \dots, \mathcal{W}c_M]$,其中, N 是字典中原子的个数, \mathcal{W} 中的第 j 列 $\mathcal{W}c_j$ 表示核空间中的第 j 类样本与字典 D 中原子的关系,稀疏系数矩阵 $A=[A_1, A_2, \dots, A_M]$,其中, A_j 为第 j 类样本子集的近似表示 $Z(X_j)$ 在字典 D 上的稀疏系数矩阵.对于第 j 类样本,学习到的字典 D 和第 j 类潜在向量 $\mathcal{W}c_j$ 可以很好地表示第 j 类的训练样本 $Z(X_j)$,即 $Z(X_j) \approx D \text{diag}(\mathcal{W}c_j) A_j$,核空间的潜在字典学习模型^[28]为

$$\left. \begin{aligned} \min_{A, D, \mathcal{W}} \sum_{j=1}^M \|Z(X_j) - D \text{diag}(\mathcal{W}c_j) A_j\|_2^2 + \lambda_1 \|A_j\|_1 + \lambda_2 \|A_j - M_j\|_F^2 + \lambda_3 \sum_{j=1}^M \sum_{l \neq j} \sum_{n=1}^N \sum_{r \neq n} \mathcal{W}c_{j,r} (d_r^T, d_n)^2 \mathcal{W}c_{l,n} \\ \text{s.t. } \mathcal{W}c_{j,r} \geq 0, \forall j, r; \sum_r \mathcal{W}c_{j,r} = \delta, \forall r \end{aligned} \right\} \quad (10)$$

公式(10)里的 δ 是一个常量,为了平衡不同类的潜在向量 $\mathcal{W}c_j$ 表达数据的能力.对于不同类的潜在向量,潜在向量中值的和应该相等,即 $\sum_r \mathcal{W}c_{j,r} = \sum_n \mathcal{W}c_{l,n} = \delta, \forall j \neq l$. M_j 是与 A_j 相同尺寸的矩阵, M_j 中的每一列是矩阵 A_j 的平均向量.公式的第2项为稀疏系数惩罚项,第3项是稀疏系数判别项,第4项为字典原子的不相关项.学习得到的潜在字典和潜在向量之间的关系是相辅相成的,且核空间潜在稀疏表示模型也依赖潜在字典和潜在向量才能实现分类的任务.

2.3 核空间潜在字典学习

在公式(10)的目标函数中,需要学习的有潜在字典、潜在向量和训练样本在潜在字典上的稀疏系数.对于该优化问题,使用 ADMM(alternating direction method of multipliers)算法,首先固定潜在向量,学习潜在字典和潜在稀疏系数,公式(10)的潜在字典学习模型可以重新写为

$$\min_{A, D} \sum_{j=1}^M \|Z(X_j) - D \text{diag}(\mathcal{W}c_j) A_j\|_2^2 + \lambda_1 \|A_j\|_1 + \lambda_2 \|A_j - M_j\|_F^2 + \lambda_3 \sum_{j=1}^M \sum_{l \neq j} \sum_{n=1}^N \sum_{r \neq n} \mathcal{W}c_{j,r} (d_r^T, d_n)^2 \mathcal{W}c_{l,n} \quad (11)$$

对于该优化问题,使用 ADMM 算法对公式(11)中的字典 D 和稀疏系数 A 进行迭代更新.当字典 D 固定时,逐类求解稀疏系数,第 j 类样本稀疏系数的优化问题为

$$\min_{A_j} \|Z(X_j) - D \text{diag}(\mathcal{W}c_j) A_j\|_2^2 + \lambda_1 \|A_j\|_1 + \lambda_2 \|A_j - M_j\|_F^2 \quad (12)$$

公式(12)的优化问题可以像文献[28]中那样使用 IPM(iterative projection method)^[28,36]求解.当稀疏系数固定时,我们重新定义潜在稀疏系数 $L=[L_1, L_2, \dots, L_M]$,其中, $L_j = \text{diag}(\mathcal{W}c_j) A_j$.字典更新模型为

$$\min_D \|Z(X) - DL\|_F^2 + \lambda_3 \sum_{j=1}^M \sum_{l \neq j} \sum_{n=1}^N \sum_{r \neq n} \mathcal{W}c_{j,r} (d_r^T, d_n)^2 \mathcal{W}c_{l,n} \quad (13)$$

公式(13)是为了更新核空间中的潜在字典 D .令 $\Gamma = LL^T, A = Z(X)L^T$,若要更新核空间潜在字典 D 中的第 n 个原子,公式(13)可以重写为^[28]

$$\min_{d_n} \|D^T D \Gamma - 2D^T A\|_F^2 + 2\lambda_3 \sum_{r \neq n} (d_r^T d_n)^2 \sum_{j=1}^M \sum_{l \neq j} \mathcal{W}c_{j,r} \mathcal{W}c_{l,n} \quad (14)$$

该问题是一个收敛问题,基于文献[37]提出的字典更新方法,公式(14)的解为

$$u = (\Gamma_{n,n} I + 2\lambda_3 I_Q)^{-1} (A_n - D \Gamma_n - 2\lambda_3 Q D_n) \quad (15)$$

$$d_n = u / \|u\|_2 \quad (16)$$

公式(15)中的 I 为单位矩阵, $Q = \sum_{r \neq n} d_n d_r^T \sum_{j=1}^M \sum_{l \neq j} \mathcal{W}c_{j,r} \mathcal{W}c_{l,n}$, I_Q 是一个对角矩阵,且对角元素与 Q 的对角元素相同; $\Gamma_{n,n}$ 是 Γ 的第 n 行 n 列元素; A_n, Γ_n 和 D_n 是 A, Γ 和 D 的第 n 个列向量.公式(16)是字典原子的归一化操作.利用公式(15)和公式(16)对字典中的原子进行逐一更新,通过迭代更新得到核空间的潜在字典 D .

2.4 核空间潜在矩阵学习

对于公式(10)中核空间潜在向量的优化问题^[28],使用 ADMM 方法,固定潜在字典和潜在稀疏系数,更新潜在向量.潜在矩阵中,每一类的潜在向量都有约束条件,第 j 类的潜在向量的约束为 $\sum_r \mathcal{W}c_{j,r} = \delta$,所以在更新潜在矩阵时,需要逐类更新潜在向量,并将更新的潜在向量合并得到最终的潜在矩阵.优化第 j 类潜在向量的目标函数^[28]为

$$\left. \begin{aligned} \min_{\mathcal{W}c_j} \sum_{j=1}^M \|Z(X_j) - D \text{diag}(\mathcal{W}c_j) A_j\|_2^2 + 2\lambda_3 \sum_{n=1}^N \mathcal{W}c_{j,n} \sum_{r \neq n} (d_r^T, d_n)^2 \sum_{l \neq j}^M \mathcal{W}c_{l,r} \\ \text{s.t. } \mathcal{W}c_{j,r} \geq 0, \forall j, r; \sum_r \mathcal{W}c_{j,r} = \delta, \forall r \end{aligned} \right\} \quad (17)$$

公式(17)是一个受限二次规划问题.令 $A_j(n)$ 表示稀疏系数矩阵 A_j 的第 n 行; $B = [B_1, B_2, \dots, B_M]^T$, 其中, $B_n = \sum_{r \neq n} (d_r^T, d_n)^2 \sum_{l \neq j}^M \mathcal{W}c_{l,r}$; $a = \text{vec}(Z(X_j))$ 表示将矩阵 $Z(X_j)$ 展开成列向量; $R_n = d_n A_j(n)$ 和 $R = [\text{vec}(R_1), \text{vec}(R_2), \dots, \text{vec}(R_N)]$. 公式(17)可以被简化^[28,36]为

$$\left. \begin{aligned} \min_{\mathcal{W}c_j} \|a - R \mathcal{W}c_j\|_F^2 + 2\lambda_3 B^T \mathcal{W}c_j \\ \text{s.t. } \mathcal{W}c_{j,r} \geq 0, \forall j, r; \sum_r \mathcal{W}c_{j,r} = \delta, \forall r \end{aligned} \right\} \quad (18)$$

基于 IPM^[28,36] 框架,公式(18)的优化问题可以通过迭代更新求解.其中,第 j 类的潜在向量的第 $t+1$ 次迭代的结果 $\mathcal{W}c_j^{t+1}$ 为^[28,36]

$$T_0 = \mathcal{W}c_j^t - (R^T (R \mathcal{W}c_j^t - a) + \lambda_3 B) / \sigma \quad (19)$$

$$T_1 = T_0 - \left(\sum_n T_{0,n} - \delta \right) / N \quad (20)$$

$$T_2 = \max(T_1, 0) \quad (21)$$

$$\mathcal{W}c_j^{t+1} = T_2 / \sum_n T_{2,n} \cdot \delta \quad (22)$$

公式(19)中的 σ 为 IPM 算法^[28,36] 的步长, \max 为取大操作,且当 T_1 为负数时, $T_2 = 0$. 公式(22)得到了第 $t+1$ 次迭代的第 j 类潜在向量.算法 1 是核空间潜在字典和潜在矩阵学习的详细步骤.

算法 1. 核空间潜在字典和潜在矩阵学习.

输入:

- 初始化的潜在矩阵 W , 字典学习时的迭代次数;
- 训练样本集 $X = \{X_1, X_2, \dots, X_M\}$, 其中, $X_j = \{X_{j,1}, X_{j,2}, \dots, X_{j,m}\}$ 为第 j 类样本的子集.

输出:

- 更新后的潜在矩阵;
 - 核空间的潜在字典.
- 1) 使用 Nyström 方法求得样本在核空间的近似表示;
 - 2) 学习潜在字典(循环至收敛):
 - 使用公式(12)逐类更新稀疏系数;
 - 使用公式(13)更新潜在字典;
 - 3) 使用公式(17)逐类更新潜在矩阵中的潜在向量;
 - 4) 如果公式(10)中目标函数的值足够小或者迭代次数达到,输出潜在字典和潜在矩阵;否则返回第 2)步.

通过核空间训练样本的近似表示,我们学习到了核空间的潜在字典和潜在矩阵.在核空间潜在在稀疏表示模型中,核映射 ϕ 没有具体的形式,为了得到解析解,将公式(6)和公式(7)中带 ϕ 的项通过核技巧转换成公式(9)中核内积 $K(Y, D)$ 和 $K(D, D)$ 的形式,以求得对于不同类潜在向量的稀疏系数及重构误差.在我们的方法中,由于使用核空间的近似表示求得了字典 D 和潜在矩阵 \mathcal{W} ,且核空间是高维的线性空间,所以可用测试样本的近似表示 $Z(Y)$ 和学习到的字典 D 的内积去近似的表示公式(9)中的 K ,即 $K(Y, D) \cong D^T Z(Y)$,用学习到的字典 D 中原子的内积去

近似表示公式(9)中的 K ,即 $K(D,D)\cong D^T D$.算法 2 给出了基于 SPD 流形潜在稀疏表示分类算法的详细步骤.

算法 2. 基于 SPD 流形潜在稀疏表示分类算法.

输入:

- 训练样本集 $X=\{X_1,X_2,\dots,X_M\}$,其中, $X_j=\{X_{j,1},X_{j,2},\dots,X_{j,m}\}$ 为第 j 类样本的子集;
- 测试样本 $Y \in S_n^+$.

输出:测试样本 $Y \in S_n^+$ 的类别.

- 1) 利用算法 1 学习核空间的潜在字典和潜在矩阵;
- 2) 使用公式(6)和公式(9)计算测试样本在不同类潜在向量条件下的稀疏系数;
- 3) 使用公式(7)和公式(9)计算测试样本对于不同类样本的重构误差;
- 4) 将样本归为重构误差最小的一类.

3 实验结果与分析

为了验证我们的方法的有效性,我们在 5 个基准数据集上进行测试,他们分别应用于纹理识别、病毒细胞识别、材质识别、人脸识别和对象分类.这 5 个数据集分别是 Brodatz 纹理数据集^[16,17]、Virus 病毒细胞基准数据集^[28]、UIUCM 基准数据集^[38]、YouTube Celebrities(YTC)基准数据集^[8]和 ETH-80 基准数据集^[39],其中,后两个数据集常被用于基于图像集的分类任务中.在每个数据集上,我们分别做了 10 次迭代实验,取 10 次实验识别率的平均值和标准差作为最终的结果.

在 5 个数据集上,我们与已有的一些在 SPD 流形上使用稀疏表示的分类算法作对比,例如 Rie_SR+Rie_DL^[17]、LE_SR+LE_DL^[21]和 Ker_DLSR(LogEK)^[27].同时,在这 5 个数据集上,我们共同对比了以下几种方法.

- (1) Frob_SR+Frob_DL^[17]:将 SPD 矩阵视为欧氏空间的点,用字典原子的线性组合来重构样本,并用矩阵的 F 范数^[15]来度量重构样本的误差.
- (2) CDL-LDA(covariance discriminant learning)^[8]:该方法是通过黎曼核将 SPD 矩阵映射到核空间,然后利用 LDA(linear discriminant analysis)方法进行学习和分类.

对于 Brodatz,Virus 和 UIUCM 这 3 个数据集,我们还与文献[40]中给出的 3 种纹理识别的方法做对比,它们分别是:

- 1) COV-SVM:该方法将对象建模成 SPD 矩阵,并用 SVM 分类器进行分类.
- 2) Gau-SVM:该方法将对象建模成高斯模型,并用 SVM 分类器进行分类.
- 3) RoG-SVM:RoG 是文献[40]提出一种样本描述模型,该方法将样本建模成 RoG 模型^[40],并用 SVM 分类器进行分类.

对于上述的 SVM 方法,我们使用 LIBSVM 工具包^[41]实现“one vs all”分类器,该工具包中的参数“-c -p”与文献[40]中一致,分别设为 4 和 10^{-5} ,其余参数保持工具包的默认设置.

对于 YTC 和 ETH-80 这两个图像集的数据集,我们与一些经典的基于图像集的分类算法进行对比,它们是:

- 1) PML(projection metric learning)^[42]:该算法首先将图像集建模为 Grassmann 流形上的点,然后通过学习得到一个正交的投影矩阵,使得投影空间的样本具有较大的类间散度和较小的类内散度.
- 2) GDA(Grassmann discriminant analysis)^[43]:该算法与 PML 一样首先将图像集建模为 Grassmann 流形上的点,然后将 Grassmann 流形嵌入到一个高维的希尔伯特空间,再通过 Fisher 判别准则去学习一个映射,从而使得原始的流形被映射到一个维度较低同时鉴别性更好的空间.
- 3) SPDML(SPD manifold leaning)^[6,7]:该方法首先将样本建模为 SPD 矩阵,然后通过学习得到一个投影矩阵,使得原始的 SPD 流形被投影到一个维度更低且更具有判别性的空间.

如第 2.1 节所述,潜在矩阵 $W=[W_{r_1},W_{r_2},\dots,W_{r_N}]$,潜在向量 W_{r_i} 表示第 i 个字典原子与样本类别之间的关系.在潜在字典的初始化过程中,我们通过直接从训练样本中抽取样本作为字典的原子,假设潜在向量中只有一个非 0 元素(例如等于 1)来初始化潜在向量 W_{r_i} ,若 $W_{r_i,j}=1$,那么字典中的第 i 个原子应用第 j 类样本中随机抽取来

初始化潜在字典.在所有的实验中,通过交叉验证来确定公式(10)中的 λ_1, λ_2 和 λ_3 的值.由于本文的实验和文献[27]的方法都是基于 Log-Euclidean 黎曼核,为了实验数据具有公正性,本文给出的这两个方法的实验数据,都是基于 LEM 度量的指数核^[27]所得出的实验结果.根据文献[33]中的描述,Nyström 方法的算法复杂度为 $O(rmn)$,这里的 r 为矩阵的秩, m 为采样样本的数量.潜在字典学习和潜在向量的复杂度为 $O(jn^2)$, j 为字典学习时的迭代次数;潜在稀疏表示模型的算法复杂度为 $O(n^2)$,因此,算法的整体复杂度为 $O((j+1)n^2)$.

3.1 图像分类

Brodatz 是一个纹理数据库^[16,17],在该数据集中包含 112 张纹理图片,选择前 20 张纹理图片作为该实验的样本集.在实验中,将每张图片的尺寸调整为 500×500 ,并将每张图片分成大小相等的 25 个方块,每个块的尺寸为 100×100 ,其中每张图片中,任意选择 10 块用作训练样本,剩下的 15 块用作测试样本.为了使得每个块可以用协方差描述表示,对块中的每个像素点的提取一个 5 维的特征描述.

$$F_{Brodatz}(x,y)=[x,y,I,abs(I_x),abs(I_y)] \quad (23)$$

公式(23)中,前 2 维的特征是该像素点在该图片块中的横、纵坐标,后面 3 维的特征分别是该像素点的灰度值、 x 轴和 y 轴方向的梯度.最后,每个图像块被描述为一个 5×5 的协方差矩阵.在该数据集上,通过交叉验证得: $\lambda_1=0.05, \lambda_2=0.5$ 和 $\lambda_3=0.05$.表 2 给出了各个算法在 Brodatz 数据集上的平均结果.

Virus 病毒数据集^[33]包含 15 个类别的病毒细胞图片,每个类别包含 100 张图片,每张图片的尺寸为 41×41 ,共 1 500 张图片.在每一类样本中,我们将 100 张样本随机分成 10 份,从每份中随机选择 8 张图片作为训练样本,剩下的 2 张作为测试样本.为了可以使用协方差矩阵描述图片样本,我们用 Gabor 滤波^[23,27]为每个像素点提取特征值.

$$F_{Virus}(x,y)=[G_{0,0}(x,y),\dots,G_{0,7}(x,y),\dots,G_{4,7}(x,y)] \quad (24)$$

公式(24)为每个像素点提取了 40 维(5 尺度,8 方向)的特征值,最后得到的协方差矩阵的维度是 40×40 .在该数据集上,通过交叉验证得: $\lambda_1=0.05, \lambda_2=0.01$ 和 $\lambda_3=0.01$.表 2 给出了各个算法在 Virus 数据集上的平均结果.

Table 2 Average results of algorithms on Brodatz, Virus and UIUCM datasets

表 2 各算法在 Brodatz, Virus 和 UIUCM 数据集上的平均结果

算法	Brodatz	Virus	UIUCM
COV-SVM ^[37]	65.23±2.14	51.00±7.71	23.70±2.40
Gau-SVM ^[37]	71.73±1.95	52.00±9.58	26.02±2.16
RoG-SVM ^[37]	73.07±1.96	59.33±8.72	28.98±2.83
CDL-LDA ^[8]	79.30±1.60	59.67±6.93	43.15±4.39
Frob_SR+Frob_DL ^[17]	70.67±1.98	54.00±7.83	42.41±5.25
LE_SR+LE_DL ^[21]	78.20±1.64	55.67±7.04	45.46±4.06
Ker_SR+Random_DL ^[27]	88.44±1.26	56.33±6.37	37.04±3.57
Proposed	90.22±1.07	62.67±7.83	47.69±3.06

UIUCM 数据集包含 18 个类别的材质图片,每个类包含 12 张样本图片,每张图片的尺寸大小不唯一.在每类样本中,我们随机抽取 6 张样本用于训练,剩余的 6 张样本用测试.为了使得每个样本可以用协方差描述表示,先将彩色图片转换为灰度图,对其中每个像素点提取 45 维的特征描述.

$$F_{UIUCM}(x,y)=[x,y,I,abs(I_x),abs(I_y),G_{0,0}(x,y),\dots,G_{0,7}(x,y),\dots,G_{4,7}(x,y)] \quad (25)$$

公式(25)中的特征为公式(23)和公式(24)特征的组合,最后得到的协方差矩阵维度为 45×45 .在该数据集上,通过交叉验证得: $\lambda_1=0.005, \lambda_2=0.5$ 和 $\lambda_3=0.5$.表 2 给出了各种算法在 UIUCM 数据集上的平均结果.

3.2 图像集分类

相比于单幅图像,图像集包含了更多的有效信息,例如光照、姿态和遮挡等.最近,基于图像集的分类问题在计算机视觉和模式识别领域获得了广泛的关注.所以,为了验证我们方法的泛化性,本文也将我们的方法应用于图像集的分类任务,分别在 ETH-80 和 YTC 两个数据集上与一些经典的基于图像集的分类算法作对比.

ETH-80 数据集^[36]中含有 8 个类别,每个类别有 10 个图像集,每个图像集中有 41 张从不同角度拍摄的照片.

我们把每个图片的尺寸调整为 20×20 , 并且在每一类图像集中, 任意选 5 个图像集用作训练, 剩下的用作测试. 在该数据集上, 通过交叉验证得: $\lambda_1=0.05, \lambda_2=0.001$ 和 $\lambda_3=0.001$. 表 3 为各算法在 ETH-80 上的平均结果.

Table 3 Average results of algorithms on ETH-80 dataset

表 3 各算法在 ETH-80 数据集上的平均结果

算法	ETH-80
PML ^[38]	90.00±3.07
GDA ^[39]	93.25±4.80
SPDML ^[6,7]	90.50±3.87
CDL-LDA ^[8]	93.75±3.43
Frob_SR+Frob_DL ^[17]	93.25±4.45
Rie_SR+Rie_DL ^[17]	88.75±4.60
LE_SR+LE_DL ^[21]	95.12±4.17
Ker_SR+Random_DL ^[27]	94.88±4.17
Proposed	96.00±3.75

YouTube Celebrities(YTC)数据集^[8]包含 47 个类, 由于每一类的对象所包含的图像集的个数不一样, 所以我们从每一类图像中随机抽取图像制作成 9 个图像集, 任选 3 个图像集作训练, 剩下的 6 个图像集用作测试, 图像集中每个图片的尺寸调整为 20×20 . 在该数据集上, 通过交叉验证得: $\lambda_1=0.05, \lambda_2=0.05$ 和 $\lambda_3=0.005$. 表 4 为各算法在 YTC 上的平均结果.

Table 4 Average results of algorithms on YTC dataset

表 4 各算法在 YTC 数据集上的平均结果

算法	YTC
PML ^[38]	67.62±3.32
GDA ^[39]	65.78±3.34
SPDML ^[6,7]	61.57±3.43
CDL-LDA ^[8]	68.72±2.96
Frob_SR+Frob_DL ^[17]	63.16±2.72
Rie_SR+ Random_DL ^[16]	47.45±7.17
LE_SR+LE_DL ^[21]	74.68±2.71
Ker_SR+Random_DL ^[27]	72.55±2.77
Proposed	78.12±2.56

3.3 实验分析

上述表中的实验结果通过我们在每个数据集上经过 10 次迭代实验获得, 其中, 有个别稀疏表示方法中的字典原子是从样本中随机抽取得到的, 而不是通过学习得到, 我们称这种字典为 Random_DL. 通过所得 10 次实验结果的均值和标准差作为最终的结果, 从这 3 个表中的数据来看, 在 5 个基准数据集上, 我们提出的方法在分类正确率上都是最好的. 在已有的将稀疏表示应用于 SPD 流行上样本的分类算法中, 方法 LE_SR+LE_DL^[21]和 Ker_SR+Random_DL^[27]也可以获得相对较好的效果. 这两种方法都不是直接在 SPD 流形上进行分类的任务, 而是通过映射函数分别将 SPD 流形嵌入到切空间和核空间中, 然后再进行稀疏表示和样本分类. 文献[37]中的 3 种方法——COV-SVM, Gau-SVM 和 RoG-SVM 之间的识别率的差距并不大, 但由于 Gau-SVM 方法在对样本建模时考虑了平均值信息, 所以 Gau-SVM 的识别率要比 COV-SVM 高出一. 方法 RoG-SVM 在对样本建模时使用了更加鲁棒的描述方法, 所以 RoG-SVM 的识别率要比 Gau-SVM 高出一. 综上, 在这 3 个方法中, 方法 RoG-SVM 可以得到较高的识别率. 在表 2 的实验数据中, 确实是 RoG-SVM 的识别率高于 Gau-SVM, Gau-SVM 的识别率高于 COV-SVM. 在 Brodatz 数据集上, 除了方法 Ker_SR+Random_DL 以外^[27], 我们的方法的优势非常明显, 识别率可以达到 90.22%, 同时具有最小的标准差 1.07. 这说明在该数据集上, 我们的方法不仅具有较好的识别效果, 还具有很强的鲁棒性. 在 Virus 数据集上, 我们的方法具有最高的识别率 62.67%, 但是我们的方法的标准差并不是最小的, 但 7.83 的标准差在所有的方中也是相对较小的, 说明我们的方法在该数据上的鲁棒性仍然可以得到保证. 在 UIUCM 数据集, 所有方法的识别率普遍偏低, 但是我们的方法获得了最好的识别率, 且标准差较小.

在 ETH-80 数据集上,我们的方法标准差为 3.75,仅次于 PML^[38].但是我们方法的识别率为 96.00%,远高于 PML 的 90.00%.其中,方法 LE_SR+LE_DL^[21]和 Ker_SR+Random_DL^[27]的识别率和标准差都仅次于我们的方法.在 YTC 数据集上,除了方法 Ker_SR+Random_DL^[27]和 Ker_SR+Random_DL^[27],我们的方法的优势非常明显,识别率可以达到 78.12%,同时具有最小的标准差 2.56.综上,我们的方法在 5 个数据集上具有最好的识别率以及相对较好的鲁棒性.

4 总结与展望

用 SPD 矩阵描述图像或者图像集具有较强的鲁棒性,且由 SPD 矩阵所张成的 SPD 流形是一个非线性的黎曼空间.本文充分考虑 SPD 流形的黎曼度量和几何性质,提出了基于 SPD 流形潜在稀疏表示分类算法.首先,将 SPD 流形嵌入到核空间,且在核空间字典学习过程中学习一个潜在矩阵,灵活联系核空间中字典原子和类别之间的信息,提出了核空间潜在稀疏表示分类模型.但核空间的样本没有明确的形式,给核空间的字典的更新带来了不便,我们使用 Nyström 方法获得核空间训练样本的向量表示去学习更新核空间的潜在字典和潜在矩阵.至此,我们将欧氏空间分类算法与黎曼流形结合起来,实现 SPD 流形上样本的分类任务.接下来,如何在 SPD 流形上更新字典,将是我们下一步的研究重点.

References:

- [1] Wright J, Yang AY, Ganesh A, Sastry SS, Ma Y. Robust face recognition via sparse representation. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2009,31(2):210–227. [doi: 10.1109/TPAMI.2008.79]
- [2] Zhang L, Yang M, Feng X. Sparse representation or collaborative representation: Which helps face recognition? In: *Proc. of the 2011 IEEE Int'l Conf. on Computer Vision (ICCV)*. IEEE, 2011. 471–478. [doi: 10.1109/ICCV.2011.6126277]
- [3] Yang M, Zhang L. Gabor feature based sparse representation for face recognition with Gabor occlusion dictionary. In: *Proc. of the European Conf. on Computer Vision*. Berlin, Heidelberg: Springer-Verlag, 2010. 448–461. [doi: 10.1007/978-3-642-15567-3_33]
- [4] Chen Z, Wu XJ, Yin HF, Kittler J. Robust low-rank recovery with a distance-measure structure for face recognition. In: *Proc. of the Pacific Rim Int'l Conf. on Artificial Intelligence*. Cham: Springer-Verlag, 2018. 464–472. [doi: 10.1007/978-3-319-97310-4_53]
- [5] Aharon M, Elad M, Bruckstein A. K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation. *IEEE Trans. on Signal Processing*, 2006,54(11):4311–4322. [doi: 10.1109/TSP.2006.881199]
- [6] Harandi MT, Salzmann M, Hartley R. From manifold to manifold: Geometry-aware dimensionality reduction for SPD matrices. In: *Proc. of the European Conf. on Computer Vision*. Cham: Springer-Verlag, 2014. 17–32. [doi: 10.1007/978-3-319-10605-2_2]
- [7] Harandi M, Salzmann M, Hartley R. Dimensionality reduction on SPD manifolds: The emergence of geometry-aware methods. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2018,40(1):48–62. [doi: 10.1109/TPAMI.2017.2655048]
- [8] Wang R, Guo H, Davis LS, Dai Q. Covariance discriminative learning: A natural and efficient approach to image set classification. In: *Proc. of the 2012 IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*. IEEE, 2012. 2496–2503. [doi: 10.1109/CVPR.2012.6247965]
- [9] Feng F, Wu XJ, Xu T. Object tracking with kernel correlation filters based on mean shift. In: *Proc. of the 2017 Int'l Smart Cities Conf. (ISC2)*. IEEE, 2017. 1–7. [doi: 10.1109/ISC2.2017.8090863]
- [10] Ren J, Wu X. Sparse coding for symmetric positive definite matrices with application to image set classification. In: *Proc. of the Int'l Conf. on Intelligent Science and Big Data Engineering*. Cham: Springer-Verlag, 2015. 637–646. [doi: 10.1007/978-3-319-23989-7_64]
- [11] Sivalingam R, Boley D, Morellas V, Papanikolopoulos N. Tensor sparse coding for region covariances. In: *Proc. of the European Conf. on Computer Vision*. Berlin, Heidelberg: Springer-Verlag, 2010. 722–735. [doi: 10.1007/978-3-642-15561-1_52]
- [12] Sivalingam R, Boley D, Morellas V, Papanikolopoulos N. Tensor sparse coding for positive definite matrices. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 2014,36(3):592–605. [doi: 10.1109/TPAMI.2013.143]
- [13] Sivalingam R, Boley D, Morellas V, Papanikolopoulos N. Positive definite dictionary learning for region covariances. In: *Proc. of the 2011 IEEE Int'l Conf. on Computer Vision (ICCV)*. IEEE, 2011. 1013–1019. [doi: 10.1109/ICCV.2011.6126346]

- [14] Sivalingam R, Boley D, Morellas V, Papanikolopoulos N. Tensor dictionary learning for positive definite matrices. *IEEE Trans. on Image Processing*, 2015,24(11):4592–4601. [doi: 10.1109/TIP.2015.2440766]
- [15] Sra S, Chierian A. Generalized dictionary learning for symmetric positive definite matrices with application to nearest neighbor retrieval. In: *Proc. of the Machine Learning and Knowledge Discovery in Databases*. 2011. 318–332. [doi: 10.1007/978-3-642-23808-6_21]
- [16] Chierian A, Sra S. Riemannian sparse coding for positive definite matrices. In: *Proc. of the European Conf. on Computer Vision*. Cham: Springer-Verlag, 2014. 299–314. [doi: 10.1007/978-3-319-10578-9_20]
- [17] Chierian A, Sra S. Riemannian dictionary learning and sparse coding for positive definite matrices. *IEEE Trans. on Neural Networks and Learning Systems*, 2017,28(12):2859–2871. [doi: 10.1109/TNNLS.2016.2601307]
- [18] Pennec X, Fillard P, Ayache N. A Riemannian framework for tensor computing. *Int'l Journal of Computer Vision*, 2006,66(1): 41–66. [doi: 10.1007/s11263-005-3222-z]
- [19] Quang MH, San Biagio M, Murino V. Log-Hilbert-Schmidt metric between positive definite operators on Hilbert spaces. In: *Proc. of the Advances in Neural Information Processing Systems*. 2014. 388–396.
- [20] Faraki M, Harandi MT, Porikli F. Image set classification by symmetric positive semi-definite matrices. In: *Proc. of the 2016 IEEE Winter Conf. on Applications of Computer Vision (WACV)*. IEEE, 2016. 1–8. [doi: 10.1109/WACV.2016.7477621]
- [21] Guo K, Ishwar P, Konrad J. Action recognition using sparse representation on covariance manifolds of optical flow. In: *Proc. of the 2010 7th IEEE Int'l Conf. on Advanced Video and Signal Based Surveillance (AVSS)*. IEEE, 2010. 188–195. [doi: 10.1109/AVSS.2010.71]
- [22] Arsigny V, Fillard P, Pennec X, *et al.* Log-Euclidean metrics for fast and simple calculus on diffusion tensors. *Magnetic Resonance in Medicine*, 2006,56(2):411–421. [doi: 10.1002/mrm.20965]
- [23] Harandi MT, Sanderson C, Hartley R, *et al.* Sparse coding and dictionary learning for symmetric positive definite matrices: A kernel approach. In: *Proc. of the Computer Vision (ECCV 2012)*. Berlin, Heidelberg: Springer-Verlag, 2012. 216–229. [doi: 10.1007/978-3-642-33709-3_16]
- [24] Sra S. Positive definite matrices and the S-divergence. *Proc. of the American Mathematical Society*, 2016,144(7):2787–2797. [doi: 10.1090/proc/12953]
- [25] Cichocki A, Cruces S, Amari S. Log-determinant divergences revisited: Alpha-beta and gamma log-det divergences. *Entropy*, 2015, 17(5):2988–3034. [doi: 10.3390/e17052988]
- [26] Harandi MT, Hartley R, Lovell B, Sanderson C. Sparse coding on symmetric positive definite manifolds using Bregman divergences. *IEEE Trans. on Neural Networks and Learning Systems*, 2016,27(6):1294–1306. [doi: 10.1109/TNNLS.2014.2387383]
- [27] Li P, Wang Q, Zuo W, Zhang L. Log-Euclidean kernels for sparse representation and dictionary learning. In: *Proc. of the IEEE Int'l Conf. on Computer Vision*. 2013. 1601–1608. [doi: 10.1109/ICCV.2013.202]
- [28] Yang M, Dai D, Shen L, *et al.* Latent dictionary learning for sparse representation based classification. In: *Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition*. 2014. 4138–4145. [doi: 10.1109/CVPR.2014.527]
- [29] Ren JY, Wu XJ. Vectorial approximations of infinite-dimensional covariance descriptors for image classification. *Computational Visual Media*, 2017,3(4):379–385. [doi: 10.1007/s41095-017-0094-4]
- [30] Faraki M, Harandi MT, Porikli F. Approximate infinite-dimensional region covariance descriptors for image classification. In: *Proc. of the 2015 IEEE Int'l Conf. on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2015. 1364–1368. [doi: 10.1109/ICASSP.2015.7178193]
- [31] Harandi M, Salzmann M. Riemannian coding and dictionary learning: Kernels to the rescue. In: *Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition*. 2015. 3926–3935. [doi: 10.1109/CVPR.2015.7299018]
- [32] Yang T, Li Y F, Mahdavi M, Jin R, Zhou ZH. Nyström method vs random Fourier features: A theoretical and empirical comparison. In: *Proc. of the Advances in Neural Information Processing Systems*. 2012. 476–484.
- [33] Kumar S, Mohri M, Talwalkar A. Sampling methods for the Nyström method. *The Journal of Machine Learning Research*, 2012, 13(1):981–1006.

- [34] Elad M. Sparse and redundant representation modeling—What next? *IEEE Signal Processing Letters*, 2012,19(12):922–928. [doi: 10.1109/LSP.2012.2224655]
- [35] Grant M, Boyd S, Ye Y. CVX: Matlab software for disciplined convex programming. 2009. <http://cvxr.com/cvx/>
- [36] Rosasco L, Verri A, Santoro M, *et al.* Iterative projection methods for structured sparsity regularization. Technical Report, MIT-CSAIL-TR-2009-050CBCL-282, 2009. <http://hdl.handle.net/1721.1/49428>
- [37] Mairal J, Bach F, Ponce J, *et al.* Online learning for matrix factorization and sparse coding. *Journal of Machine Learning Research*, 2010,11(1):19–60. [doi: 10.1145/1756006.1756008]
- [38] Liao Z, Rock J, Wang Y, Forsyth D. Non-parametric filtering for geometric detail extraction and material representation. In: Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition. 2013. 963–970. [doi: 10.1109/CVPR.2013.129]
- [39] Huang Z, Wang R, Shan S, Li X, Chen X. Log-Euclidean metric learning on symmetric positive definite manifold with application to image set classification. In: Proc. of the Int'l Conf. on Machine Learning. 2015. 720–729.
- [40] Wang Q, Li P, Zuo W, Zhang L. RAID-G: Robust estimation of approximate infinite dimensional Gaussian with application to material recognition. In: Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition. 2016. 4433–4441. [doi: 10.1109/CVPR.2016.480]
- [41] Chang CC, Lin CJ. LIBSVM: A library for support vector machines. *ACM Trans. on Intelligent Systems and Technology (TIST)*, 2011,2(3):1–27. [doi: 10.1145/1961189.1961199]
- [42] Huang Z, Wang R, Shan S, Chen X. Projection metric learning on Grassmann manifold with application to video based face recognition. In: Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition. 2015. 140–149. [doi: 10.1109/CVPR.2015.7298609]
- [43] Hamm J, Lee DD. Grassmann discriminant analysis: A unifying view on subspace-based learning. In: Proc. of the 25th Int'l Conf. on Machine Learning. ACM, 2008. 376–383. [doi: 10.1145/1390156.1390204]



陈凯旋(1993—),男,硕士,主要研究领域为模式识别,计算机视觉,黎曼流形学习.



吴小俊(1967—),男,博士,教授,博士生导师,CCF专业会员,主要研究领域为模式识别,计算机视觉,模糊系统,神经网络,智能系统.