

doi:10.11835/j.issn.1000-582X.2020.11.003

特征空间中的拓展稀疏人脸识别

张泓¹, 范自柱¹, 王松¹, 李争名²

(1.华东交通大学理学院,南昌 330013;2.广东技术师范大学工业实训中心,广州 510665)

摘要: 基于稀疏表示分类(SRC, sparse representation for classification)是近年来模式识别领域中备受关注的一个研究热点。当每类训练样本较少时,SRC 的识别效果往往不理想。为解决此问题,人们提出了拓展的稀疏表示分类算法。它引入了训练样本的类内变量矩阵,来补充每类训练样本信息。但是,该方法很难获取普遍存在于复杂数据如图像中的非线性信息。为此,提出了特征空间中的拓展稀疏人脸识别算法。该算法将样本集非线性映射到新的特征空间中,计算每个训练样本在表示测试样本时所做的贡献。根据贡献大小,给每个训练样本赋予一定的权重。同时,利用类内变量矩阵,共同表示测试样本。实验表明所提出的算法优于其它经典稀疏表示分类算法。

关键词: 人脸识别;拓展的稀疏表示识别;特征空间;模式识别;稀疏分类表示

中图分类号:TP391.4

文献标志码:A

文章编号:1000-582X(2020)11-021-08

Extended sparse representation for face recognition in feature space

ZHANG Hong¹, FAN Zizhu¹, WANG Song¹, LI Zhengming²

(1.School of Basic Science, East China Jiaotong University, Nanchang 330013, P. R. China;
2.Industrial Training Center, Guangdong Polytechnic Normal University, Guangzhou 510665, P. R. China)

Abstract: Sparse representation for classification (SRC) has attracted much attention in the field of pattern recognition in recent years. If each class has few training samples, SRC usually cannot achieve the desirable recognition performance. To address the above problem, extended sparse representation for classification (ESRC) is proposed, which uses the intraclass variant matrix to supplement the training sample information. Nevertheless, ESRC can hardly capture the nonlinear information in complex data such as images. An extended sparse representation in a feature space for classification algorithm was proposed, in which the original data were mapped into a new high dimensional space through a nonlinear mapping to evaluate the contribution of each training sample in the representation of test sample, and each sample was given a certain weight according to the contribution. Then, the proposed algorithm used the weighted training samples combining the intraclass variant matrix to represent the test samples. Experiments show that the proposed algorithm is superior to other typical sparse representation for classification algorithms.

Keywords: face recognition; extended sparse representation for classification (ESRC); feature space; pattern recognition; sparse representation for classification (SRC)

收稿日期:2020-09-03

基金项目:国家自然科学基金资助项目(61991401;61673097;61702117);江西省自然科学基金重点资助项目(20192ACBL20010)。

Supported by National Natural Science Foundation of China(61991401;61673097;61702117)and Key Project of Jiangxi Natural Science Foundation(20192ACBL20010).

作者简介:张泓(1996—),男,硕士,主要从事图像处理和模式识别方向研究,(E-mail)zhanghong9625@qq.com。

通讯作者:范自柱,男,博士,教授,主要从事模式识别与机器学习方向研究,(E-mail)zzfan3@163.com。

压缩感知理论是近年来信号处理领域的一个研究热点^[1-2],它的提出为模式识别和计算机视觉等诸多领域提供了一个新的研究方向。在模式识别领域中,自从 J. Wright 首次将压缩感知理论核心内容之一的稀疏表示应用于人脸识别^[3-4],即面向分类的稀疏表示算法(SRC, sparse representation for classification),该方法受到广泛关注^[5-10]。SRC 方法在不少情况下可以取得较好的分类或识别效果,尤其是在处理有噪声与遮挡的人脸图像时,若每一类训练样本比较充分,SRC 算法的分类效果往往优于最近邻分类器结合 Fisherfaces 和 Laplacianfaces^[11]等特征抽取方法的分类效果^[12-14]。

然而,在不少应用场合,训练样本很难获取。它们的数目很小,甚至每类只有一个训练样本,这样的数据集为“少样本”数据集。此时,SRC 算法的分类效果往往不理想,主要原因是每类数据的训练样本过少,往往不能充分成为与该类训练样本对应的子空间。为解决少样本问题,Deng 等^[15]人提出了拓展的稀疏人脸识别算法(ESRC, extended sparse representation for classification),该方法目的是处理 SRC 算法中所遇到的少样本问题。但 ESRC 也很难获取高维数据中有利用来分类的非线性信息,为解决这个问题,拟采用一非线性映射将原始输入空间中的数据映射到一高维甚至无穷维的特征空间中。这样,一方面可以从复杂数据集中获取有利于分类的非线性信息^[16]。另一方面,把原始输入空间中的数据映射到高维特征空间,避免不同类的样本向量分布于同一方向上^[17],使得对样本的线性表示模型变得更简单有效,提高识别效果。

从经典的 SRC 的表示模型可知,每个训练样本在表示测试样本时所做的贡献不一样。实际上,那些离测试样本越近的训练样本对测试样本的贡献会越大^[18-19]。因此,在表示测试样本的过程中,可以将距离测试样本近的训练样本赋予较大的权值,其他训练样本赋予较小的权值,以去除表示测试样本时的干扰因素。为能更好解决上述稀疏表示中的少样本问题,提出特征空间中的核加权拓展稀疏人脸识别算法(KWESRC, kernel weighted extended sparse representation for classification)。在 KWESRC 中,首先,利用一种非线性映射^[20],将这些样本数据非线性映射到高维的特征空间中。它可以通过指定合适的核函数及其参数实现。再利用某一距离度量如高斯核距离^[21]计算训练样本的权重,给每个训练样本加权。然后,运用所有的加权训练样本和类内变量矩阵表示测试样本,通过解决 l_1 范数的最小化问题^[5]求得测试样本的稀疏表示系数。最后,通过计算每个类别训练样本表示测试样本的 l_2 范数误差,将测试样本分类到误差最小的类别中。实验表明提出的 KWESRC 算法的分类效果优于其他经典的 SRC 算法。

1 ESRC 算法

Deng 等人提出的 ESRC 算法^[15],假设有来自 C 类的训练样本集 $\mathbf{X} = [X_1, X_2, \dots, X_C] \in R^{m \times n}$ 与测试样本 $y \in R^m$ 。第 i ($i=1, \dots, C$) 类的训练样本为 $\mathbf{X}_i = [x_{i1}, x_{i2}, \dots, x_{in_i}]$,其类中心为

$$D_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \mathbf{x}_{ij}, \quad (1)$$

其中, n_i 为第 i 类中训练样本个数。由此,再给出类内变量子矩阵如下: $\mathbf{D}_i^* = [x_{i1}^*, x_{i2}^*, \dots, x_{in_i}^*]$, 其中, $x_{ij}^* = x_{ij} - D_i$ ($j=1, 2, \dots, n_i$)。这些矩阵构成类内变量矩阵: $\mathbf{D}^* = [\mathbf{D}_1^*, \mathbf{D}_2^*, \dots, \mathbf{D}_C^*]$ 。用所有的训练样本与上述类内变量矩阵共同线性表示测试样本,可得如下式子

$$y = \mathbf{X}\boldsymbol{\theta} + \mathbf{D}^* \boldsymbol{\omega} + \xi, \quad (2)$$

其中: ξ 为噪声或表示误差; $\boldsymbol{\theta}$ 和 $\boldsymbol{\omega}$ 为 y 的稀疏表示系数,具体如下, $\boldsymbol{\theta} = [\theta_{11}, \dots, \theta_{1n_1}, \dots, \theta_{C1}, \dots, \theta_{Cn_C}]$, $\boldsymbol{\omega} = [\omega_{11}, \dots, \omega_{1n_1}, \dots, \omega_{C1}, \dots, \omega_{Cn_C}]$ ($\boldsymbol{\theta}, \boldsymbol{\omega} \in R^n$)。通过解决 l_1 范数的最小化问题求得稀疏表示系数如下

$$\begin{bmatrix} \hat{\boldsymbol{\theta}} \\ \hat{\boldsymbol{\omega}} \end{bmatrix} = \arg \min \left\| \begin{bmatrix} \boldsymbol{\theta} \\ \boldsymbol{\omega} \end{bmatrix} \right\|_1, \text{ s.t. } \| y - \mathbf{X}\boldsymbol{\theta} - \mathbf{D}^* \boldsymbol{\omega} \|_2 \leq \delta, \quad (3)$$

式中, $\hat{\boldsymbol{\theta}}, \hat{\boldsymbol{\omega}} \in R^n$ 。求得稀疏表示系数后,就可以利用此系数计算每类训练样本表示测试样本的误差,将测试样本分到对应最小表示误差的类中。

2 KWESRC 算法

对于少样本问题,ESRC 算法通过引入类内变量矩阵,组成每类训练样本所对应的子空间,再用训练样

本集与由它计算得到的类内变量矩阵共同表示单个测试样本, 取得一定效果。但是, ESRC 算法不能有效获取复杂数据集中的有利于分类的非线性信息。同时, 也很难解决不同类的样本向量分布于同一向量方向的问题。为了能够有效获取这样的非线性信息, 采用一非线性映射, 将数据变换到高维的特征空间。在这一新的空间中, 给出 KWESRC 算法, 具体如下。

对来自 C 类的训练样本集 $\mathbf{X} = [X_1, X_2, \dots, X_C] \in R^{m \times n}$ 与测试样本 $y \in R^m$ 来说, 可利用非线性映射 φ 将这些样本映射到高维甚至无穷维的特征空间中。在新的特征空间中, 新训练样本集为 $\varphi(\mathbf{X}) = [\varphi(X_1), \varphi(X_2), \dots, \varphi(X_C)] \in R^{M \times n}$, $\varphi(X_i) = [\varphi(x_{i1}), \varphi(x_{i2}), \dots, \varphi(x_{in_i})]$,

$\varphi(y) \in R^M$ 其中 $i=1, \dots, C$, $\sum_{i=1}^C n_i = n$ 。第 i 类训练样本的均值为

$$\varphi(\mathbf{D}_i) = \frac{1}{n_i} \sum_{j=1}^{n_i} \varphi(x_{ij}), \quad (4)$$

其中 $i=1, \dots, C, j=1, \dots, n_i$ 。第 i 类的类内变量子矩阵可表示为

$$\varphi(\mathbf{D}_i^*) = [\varphi(x_{i1}^*), \varphi(x_{i2}^*), \dots, \varphi(x_{in_i}^*)], \quad (5)$$

其中: $\varphi(x_{ij}^*) = \varphi(x_{ij}) - \varphi(\mathbf{D}_i)$ ($j=1, 2, \dots, n_i$)。即类内变量矩阵可表示为

$$\varphi(\mathbf{D}^*) = [\varphi(\mathbf{D}_1^*), \varphi(\mathbf{D}_2^*), \dots, \varphi(\mathbf{D}_C^*)]. \quad (6)$$

用所有的训练样本与类内变量矩阵共同线性表示测试样本, 即

$$\varphi(y) = \varphi(\mathbf{X})\alpha + \varphi(\mathbf{D}^*)\beta' + \eta, \quad (7)$$

其中, η 表示噪声或误差; α, β 为 $\varphi(y)$ 的稀疏表示系数如下, $\alpha = [a_{11}, \dots, a_{1n_1}, \dots, a_{C1}, \dots, a_{Cn_C}]$, $\beta = [b_{11}, \dots, b_{1n_1}, \dots, b_{C1}, \dots, b_{Cn_C}]$ 。然后通过解决 l_1 范数的最小化问题求得稀疏表示系数, 如下式

$$\begin{bmatrix} \alpha \\ \beta \end{bmatrix} = \arg \min \left\| \begin{bmatrix} \alpha \\ \beta \end{bmatrix} \right\|_1, \text{s.t. } \|\varphi(y) - \varphi(\mathbf{X})\alpha - \varphi(\mathbf{D}^*)\beta\|_2 \leq \epsilon, \quad (8)$$

式中的 $\alpha, \alpha, \beta, \beta \in R^n$ 。然后, 利用经典 KPCA 算法, 得到训练样本的投影轴, 并对高维的训练样本数据与类内变量数据进行降维处理。若将每个样本向量降至 p 维, 则有变换矩阵 \mathbf{U} 如下

$$\mathbf{U}_h = \sum_{i=1}^C \sum_{j=1}^{n_i} v_{hij} \varphi(x_{ij}) = \varphi(\mathbf{X})v_h, \quad (h=1, \dots, p), \quad (9)$$

$$\begin{aligned} \mathbf{U} &= [\mathbf{U}_1, \dots, \mathbf{U}_h, \dots, \mathbf{U}_p] = \varphi(\mathbf{X})\mathbf{V}, \\ &= [\varphi(\mathbf{X})v_1, \dots, \varphi(\mathbf{X})v_h, \dots, \varphi(\mathbf{X})v_p], \end{aligned} \quad (10)$$

其中, \mathbf{U}_h 为训练样本的投影轴, $v_h = (v_{h11}, \dots, v_{h1n_1}, \dots, v_{hC1}, \dots, v_{hCn_C})^\top$ 为变换系数向量 $\mathbf{V} = [v_1, \dots, v_h, \dots, v_p]$, ($h=1, \dots, p$)。在特征空间中, 对于任意的 2 个训练样本 $\varphi(x_1), \varphi(x_2)$, 可定义核函数为 $k(x_1, x_2) = (\varphi(x_1))^\top \varphi(x_2)$ 。将样本数据降至 P 维, 则有

$$\begin{aligned} &\|\mathbf{U}^\top(\varphi(y) - \varphi(\mathbf{X})\alpha - \varphi(\mathbf{D}^*)\beta)\|_2 = \\ &\|(\varphi(\mathbf{X})\mathbf{V})^\top(\varphi(y) - \varphi(\mathbf{X})\alpha - \varphi(\mathbf{D}^*)\beta)\|_2 = \\ &\|(\mathbf{V}^\top \varphi^\top(\mathbf{X}))(\varphi(y) - \varphi(\mathbf{X})\alpha - \varphi(\mathbf{D}^*)\beta)\|_2 = \\ &\|\mathbf{V}^\top(k(\cdot, y) - \mathbf{K}\alpha - \mathbf{G}\beta)\|_2 = \\ &\left\| \mathbf{V}^\top k(\cdot, y) - (\mathbf{V}^\top \mathbf{K} - \mathbf{V}^\top \mathbf{G}) \begin{pmatrix} \alpha \\ \beta \end{pmatrix} \right\|_2, \end{aligned} \quad (11)$$

其中, $k(\cdot, y) = (\varphi(\mathbf{X}))^\top \varphi(y) = [k(x_{11}, y), \dots, k(x_{Cn_C}, y)]$,

$$\mathbf{G} = \begin{pmatrix} (\varphi(x_{11}))^\top \varphi(x_{11}^*) & \cdots & (\varphi(x_{11}))^\top \varphi(x_{Cn_C}^*) \\ \vdots & \ddots & \vdots \\ (\varphi(x_{Cn_C}))^\top \varphi(x_{11}^*) & \cdots & (\varphi(x_{Cn_C}))^\top \varphi(x_{Cn_C}^*) \end{pmatrix} = \begin{pmatrix} k(x_{11}, x_{11}^*) & \cdots & k(x_{11}, x_{Cn_C}^*) \\ \vdots & \ddots & \vdots \\ k(x_{Cn_C}, x_{11}^*) & \cdots & k(x_{Cn_C}, x_{Cn_C}^*) \end{pmatrix},$$

$$\begin{aligned} \mathbf{K} &= \begin{pmatrix} (\varphi(x_{11}))^\top \varphi(x_{11}) & \cdots & (\varphi(x_{11}))^\top \varphi(x_{Cn_C}) \\ \vdots & \ddots & \vdots \\ (\varphi(x_{Cn_C}))^\top \varphi(x_{11}) & \cdots & (\varphi(x_{Cn_C}))^\top \varphi(x_{Cn_C}) \end{pmatrix} = \begin{pmatrix} k(x_{11}, x_{11}) & \cdots & k(x_{11}, x_{Cn_C}) \\ \vdots & \ddots & \vdots \\ k(x_{Cn_C}, x_{11}) & \cdots & k(x_{Cn_C}, x_{Cn_C}) \end{pmatrix} \\ &= (K_{11}, \dots, K_{ij}, \dots, K_{Cn_C}). \end{aligned}$$

上面矩阵 \mathbf{K} 的每一列定义如下

$$\mathbf{K}_{ij} = (k(x_{11}, x_{ij}), \dots, k(x_{1n_1}, x_{ij}), \dots, k(x_{C1}, x_{ij}), \dots, k(x_{Cn_C}, x_{ij}))^\top, (i=1, \dots, C, j=1, \dots, n_i)。$$

此时,在特征空间中,该训练样本利用定义的核函数可计算得到每一个训练样本的特征向量,矩阵 \mathbf{K} 的每一列定义为该训练样本的特征向量。然后,可衡量训练样本特征在表达测试样本特征时所做的贡献。具体地,计算单个测试样本 $\mathbf{k}(\cdot, y)$ 与 $\mathbf{K}_{ij} (i=1, \dots, C, j=1, \dots, n_i)$ 之间的高斯核距离,用所计算的距离对 \mathbf{K}_{ij} 进行加权处理。所用的高斯核距离可表示为

$$d_g(\mathbf{K}_{ij}, \mathbf{k}(\cdot, y)) = \exp(-\|\mathbf{K}_{ij} - \mathbf{k}(\cdot, y)\|^2 / 2\sigma^2), \quad (12)$$

其中 σ 表示高斯核宽度,在实验部分将给出参数 σ 的计算方法。对 \mathbf{K} 的每一列特征向量加权后的新训练样本特征集 \mathbf{K}' 为

$$\begin{aligned} \mathbf{K}' &= \begin{pmatrix} k'(x_{11}, x_{11}) & \cdots & k'(x_{11}, x_{Cn_C}) \\ \vdots & \ddots & \vdots \\ k'(x_{Cn_C}, x_{11}) & \cdots & k'(x_{Cn_C}, x_{Cn_C}) \end{pmatrix} = (\mathbf{K}'(1), \dots, \mathbf{K}'(i), \dots, \mathbf{K}'(C)) \\ &= (\mathbf{K}'_{11}, \dots, \mathbf{K}'_{Cn_C}), \end{aligned} \quad (13)$$

其中, $\mathbf{K}'_{ij} = d_g(\mathbf{K}_{ij}, \mathbf{k}(\cdot, y)) * \mathbf{K}_{ij}, (i=1, \dots, C, j=1, \dots, n_i)$ 。同时, 加权的训练样本特征集 \mathbf{K}' 的类内变量矩阵为 \mathbf{G}' , 即 \mathbf{G}' 可表示为

$$\begin{aligned} \mathbf{G}' &= \begin{pmatrix} k'(x_{11}, x_{11}^*) & \cdots & k'(x_{11}, x_{Cn_C}^*) \\ \vdots & \ddots & \vdots \\ k'(x_{Cn_C}, x_{11}^*) & \cdots & k'(x_{Cn_C}, x_{Cn_C}^*) \end{pmatrix} = [\mathbf{G}'(1), \dots, \mathbf{G}'(i), \dots, \mathbf{G}'(C)] \\ &= [\mathbf{K}'_{11} - l_1, \dots, \mathbf{K}'_{1n_1} - l_1, \dots, \mathbf{K}'_{C1} - l_C, \dots, \mathbf{K}'_{Cn_C} - l_C] \in R^{M \times n}, \end{aligned} \quad (14)$$

其中, $l_i (i=1, 2, \dots, C)$ 表示第 i 类对应的训练样本特征向量 $\mathbf{K}'(i) = (\mathbf{K}'_{i1}, \dots, \mathbf{K}'_{in_i})$ 的均值。即 $l_i = \sum_{b=1}^{n_i} \mathbf{K}'_{ib} / n_i$ 。在特征空间中,用所有的加权训练样本特征和类内变量矩阵来线性表示测试样本,并将每个样本特征数据降至 p 维。因此,可将式(8)改为

$$\begin{bmatrix} \alpha_1 \\ \beta_1 \end{bmatrix} = \arg \min \left\| \begin{bmatrix} \alpha_1 \\ \beta_1 \end{bmatrix} \right\|_1, \text{s.t.} \left\| \mathbf{V}^\top \mathbf{k}(\cdot, y) - (\mathbf{V}^\top \mathbf{K}' - \mathbf{V}^\top \mathbf{G}') \begin{pmatrix} \alpha_1 \\ \beta_1 \end{pmatrix} \right\|_2 \leq \epsilon, \quad (15)$$

其中 $\mathbf{V} = [v_1, \dots, v_p]$ 。即求得此式的稀疏表示系数 α_1, β_1 。然后计算每一类对应的误差大小,将测试样本分到误差最小的类别中。该类别误差可表示为

$$r_i(y) = \left\| \mathbf{V}^\top \mathbf{k}(\cdot, y) - (\mathbf{V}^\top \mathbf{K}' - \mathbf{V}^\top \mathbf{G}') \begin{pmatrix} \delta_i(\alpha_1) \\ \beta_1 \end{pmatrix} \right\|_2, \quad (16)$$

其中 $i=1, 2, \dots, C$, 其中新向量 $\delta_i(\alpha_1) \in R^M$ 中的非零项是 α_1 中的仅属于第 i 类的非零项。具体地, KWESRC 算法过程如下。

KWESRC 算法

1) 输入: 对于给定的测试样本 $y \in R^m$, 训练样本的矩阵 $\mathbf{X} = [X^1, X^2, \dots, X^C] \in R^{m \times n}$, 将其非线性映射到特征空间中, 即新样本集为 $\varphi(\mathbf{X}) = [\varphi(X_1), \varphi(X_2), \dots, \varphi(X_C)] \in R^{M \times n}$, $\varphi(y) \in R^M$, 误差 $\epsilon > 0$ 。

2) 利用高斯核函数计算得到每个样本的特征向量, 即组成了训练样本特征矩阵 \mathbf{K} 与测试样本特征 $\mathbf{k}(\cdot, y)$ 。

3) 利用高斯核距离给每一个训练样本特征向量加权, 即产生加权后的新的训练样本特征矩阵 \mathbf{K}' , 并求出 \mathbf{K}' 的类内变量矩阵 \mathbf{G}' 。

4) 通过解决式(15)的 l_1 范数最小化问题求得稀疏表示系数, 并利用式(16)来分类测试样本。

3 实验

在 3 个经典的 GT, AR 和 Extended Yale B (EYB) 人脸数据集上验证提出的 KWESRC 算法的识别效

果。KWESRC 算法将与传统的 SRC 算法^[3]、协同表示分类算法(CRC)^[4]、ESRC 算法作比较, 来验证所提出的算法识别效果。实验中的式(12)表示高斯核距离, 其中的参数 σ 为高斯核宽度, 其值为原始输入空间中的全部训练样本平均欧式距离的 $1e-3$ 倍。式(15)中的误差 ϵ 设置为 0.01。

3.1 GT 人脸数据上的实验

第一个实验将在 GT(georgia tech)人脸数据集上进行。GT 数据集共有 50 个人的 750 幅图像, 每人有不同姿态, 表情, 光照等各种条件下的人脸图像。图 1 为此人脸数据集的部分图像示例。实验中所有的图像都被转换成为具有 256 等级的灰度图像, 且被裁剪成大小为 60×50 像素的图像。随机将每类样本分为 2 类, 一部分作为训练样本, 剩余的作为测试样本。选定的每类训练样本的数量分别为 2 和 3, 即组成 2 个训练子集。每个算法随机运行 10 次。

实验中, 运用经典的 PCA 算法将 SRC、CRC、ESRC 与 KED^[6]算法中人脸图像降维至不同的维数。图 2 和 3 直观地给出了每类不同训练样本数目 N 下的各种算法的识别效果, 可以看到随着 PCA 维度的增高, 算法的识别精度也随之增高。从图 2 和 3 可知, 提出的 KWESRC 算法优于其它 3 种算法的识别结果。



图 1 GT 人脸数据集的部分图像

Fig. 1 Some images of the GT face data set

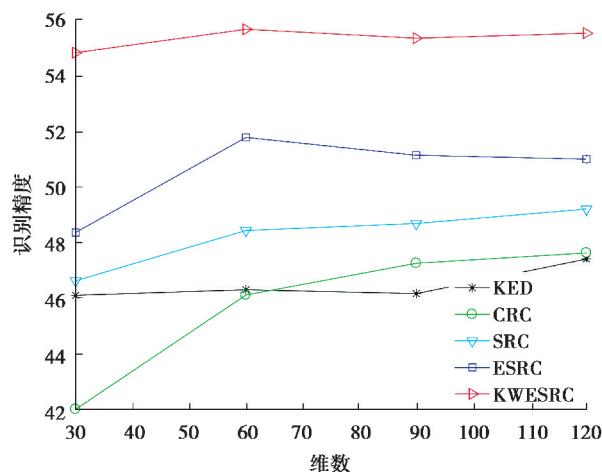


图 2 GT 数据库上的各种算法的分类效果($N=2$)

Fig. 2 Classification effect of various algorithms on the GT database ($N=2$)

3.2 AR 人脸数据上的实验

在 AR 人脸数据集上做第二个实验。AR 数据集包含 120 个人(类)的 4 000 多幅人脸图像。采用每人不同动作, 表情, 光照变量条件下的 26 幅人脸图像。图 4 为此人脸数据集的部分图像。实验中所有的图像都被转换成为具有 256 等级的灰度图像, 且被裁剪成大小为 20×25 像素的图像。同样, 随机将每类的样本分为 2 类, 一部分作为训练样本, 剩余的作为测试样本。选定的每类训练样本的数量分别为 2 和 3, 也组成 2 个训练子集。同样, 每个算法随机运行 10 次。

此实验中, 同样运用经典的 PCA 算法将 SRC、CRC、ESRC 与 KED 算法中的人脸图像数据降维至不同的维数。表 1 和 2 给出了每类不同训练样本数目 N 下的各种算法的识别效果。从表 1, 2 中可知, 所提算法优于其它 4 种算法的识别结果, 并且 PCA 维度设置的越高, 识别精度越高。

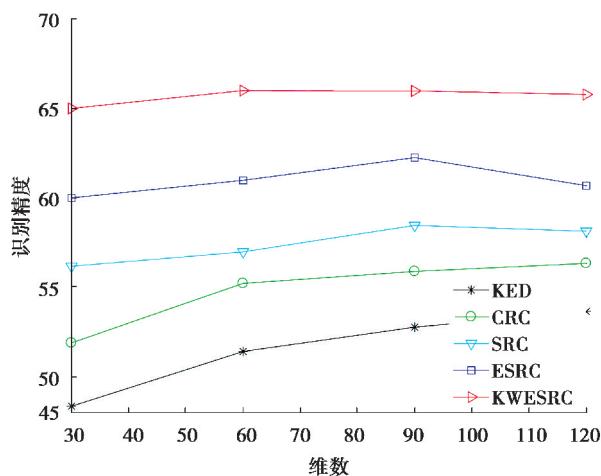
图 3 GT 数据库上的各种算法的分类效果 ($N=3$)Fig. 3 Classification effect of various algorithms on the GT database ($N=3$)

图 4 AR 人脸数据集的部分图像

Fig. 4 Some images of AR Face Data Set

表 1 AR 数据库上的分类精度(平均分类精度±均方差)(%) ($N=2$)Table 1 Classification accuracy on AR database (average classification accuracy±mean square deviation) (%) ($N=2$)

算法	40 维	80 维	120 维	160 维
SRC	56.25 ± 1.51	63.20 ± 1.32	67.56 ± 1.05	65.99 ± 1.38
CRC	58.48 ± 1.64	67.68 ± 1.31	69.01 ± 1.17	68.23 ± 1.24
ESRC	62.69 ± 1.24	68.98 ± 1.35	70.51 ± 1.35	70.93 ± 1.43
KED	50.59 ± 1.88	63.39 ± 1.42	66.67 ± 1.28	67.71 ± 1.09
KWESRC	64.48 ± 0.87	73.14 ± 1.20	76.00 ± 1.18	76.53 ± 1.10

表 2 人脸库 AR 上的分类精度(平均分类精度±均方差)(%) ($N=3$)Table 2 Classification accuracy on AR database (average classification accuracy±mean variance) (%) ($N=3$)

算法	40 维	80 维	120 维	160 维
SRC	65.28 ± 1.10	72.74 ± 1.19	77.27 ± 0.94	75.72 ± 0.91
CRC	66.71 ± 0.72	76.04 ± 0.87	77.96 ± 0.82	77.96 ± 0.96
ESRC	72.53 ± 0.99	79.76 ± 0.94	81.25 ± 1.20	81.94 ± 0.91
KED	57.29 ± 1.28	72.48 ± 0.99	76.65 ± 0.88	78.08 ± 0.81
KWESRC	74.00 ± 0.74	82.09 ± 1.01	84.24 ± 1.07	85.32 ± 0.91

3.3 EYB 人脸数据上的实验

第三个实验是在人脸数据库 Extended Yale B(EYB)上实现的。EYB 人脸数据库由 38 个人脸图像构

成, 总计有 2 414 幅不同光照条件下的正面人脸图像, 每幅人脸图像被裁剪成 40×35 大小。下图是该人脸库的一些示例图像。同前面的 2 个实验一样, 随机将每类的样本分为两类, 一部分作为训练样本, 剩余的作为测试样本。选定的每类训练样本的数量分别为 3, 4 和 5, 组成 3 个训练子集。每个算法也随机运行 10 次。

实验中, 运用经典的 PCA 算法将所有的人脸图像数据降至 100 维。图 6 给出了每种算法的识别精度。从此图中可以看出, 同前面 2 个实验结果一致, 提出的算法具有最高的识别精度。算法取得理想识别效果的原因主要在于, 一方面是利用非线性映射将数据样本从原始输入空间变换到高维特征空间, 从理论上使得样本类别之间的边界线性可分。另一方面, 考虑了每个样本在表示测试样本的重要程度。给对表示测试样本中贡献大的训练样本赋予较大的权重, 进一步增强它们表示测试样本的能力。



图 5 EYB 人脸库的部分图像

Fig. 5 Some images of the EYB face database

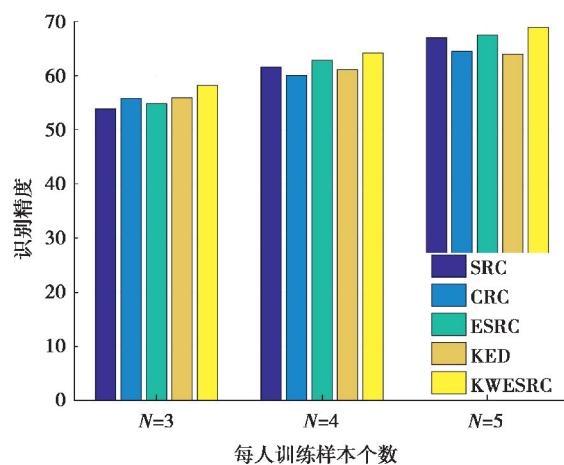


图 6 EYB 人脸库上的各种算法的分类效果

Fig. 6 Classification effect of various algorithms on EYB face database

4 结束语

所提出的特征空间中的 KWESRC 算法可更好处理经典的 SRC 算法中经常遇到的少样本问题, 且有效避免不同类的样本向量分布于同一向量方向的问题。它首先利用一种非线性映射将原来线性不可分数据映射到高维特征空间中, 利用高斯核函数求得新样本的特征。然后, 考虑不同的训练样本在表示测试样本时所起的作用, 即对训练样本进行加权处理, 用所求得新样本的类内变量来弥补少样本问题所造成的类内信息缺失。最后用加权的训练样本和类内变量矩阵来线性表示测试样本。实验证明, KWESRC 算法的识别精度高于经典的 SRC 和 ESRC 算法的识别精度, 具有较好的应用前景。

参考文献:

- [1] Lu L N, Hu X L, Chen S H, et al. Face recognition based on weighted wavelet transform and compressed sensing[C]// 2016 8th International Conference on Wireless Communications & Signal Processing (WCSP). Piscataway, NJ: IEEE, 2016: 1-5.
- [2] Zhou T Y, Shen F Z, Meng Q Y, et al. Towards real-time through-obstacle imaging based on compressed sensing for sparse objects[J]. IET Microwaves, Antennas & Propagation, 2019, 13(13): 2290-2296.
- [3] Wright J, Yang A Y, Ganesh A, et al. Robust face recognition via sparse representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210-227.

- [4] Zhang L, Yang M, Feng X C. Sparse representation or collaborative representation: Which helps face recognition? [C]// 2011 International Conference on Computer Vision. Piscataway, NJ: IEEE, 2011: 471-478.
- [5] Yang J, Zhang L, Xu Y, et al. Beyond sparsity: The role of L1-optimizer in pattern classification [J]. Pattern Recognition, 2012, 45(3): 1104-1118.
- [6] Huang K K, Dai D Q, Ren C X, et al. Learning kernel extended dictionary for face recognition[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(5): 1082-1094.
- [7] Wu M H, Li S R, Hu J G. Extended class-wise sparse representation for face recognition [C] // 2017 3rd IEEE International Conference on Computer and Communications (ICCC). Piscataway, NJ: IEEE, 2017: 1611-1615.
- [8] Fan Z Z, Zhang D, Wang X, et al. Virtual dictionary based kernel sparse representation for face recognition[J]. Pattern Recognition, 2018, 76: 1-13.
- [9] Fan Z Z, Wei C. Fast kernel sparse representation based classification for undersampling problem in face recognition[J]. Multimedia Tools and Applications, 2020, 79(11/12): 7319-7337.
- [10] Xu Y, Zhong Z F, Yang J, et al. A new discriminative sparse representation method for robust face recognition via $\$l_2\$$ regularization[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(10): 2233-2242.
- [11] Singh R R, Khandelwal R K, Chavan M. Face recognition using orthogonal locality preserving projections[C] // 2016 International Conference on Signal Processing, Communication, Power and Embedded System (SCOPES). Piscataway, NJ: IEEE, 2016: 1323-1328.
- [12] Miazonza J F, Hua Q, Wang L. Face recognition using laplacianfaces and artificial neural network[J]. Applied Mechanics and Materials, 2015, 734: 633-636.
- [13] Chen S B, Ding C H Q, Luo B. Linear regression based projections for dimensionality reduction[J]. Information Sciences, 2018, 467: 74-86.
- [14] Xu X Y, Li S, Liu L. Face recognition based on multi-level histogram sequence center-symmetric local binary pattern and fisherface[C] // 2017 IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC). Piscataway, NJ: IEEE, 2017: 448-451.
- [15] Deng W H, Hu J N, Guo J. Extended SRC: Undersampled face recognition via intra-class variant dictionary[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(9): 1864-1870.
- [16] Cheng E J, Chou K P, Rajora S, et al. Deep sparse representation classifier for facial recognition and detection system[J]. Pattern Recognition Letters, 2019, 125: 71-77.
- [17] Esmaeilzehi A, Abrishami M H. Nonparametric kernel sparse representation-based classifier[J]. Pattern Recognition Letters, 2017, 89: 46-52.
- [18] Liu X G, Lu L Y, Shen Z X, et al. A novel face recognition algorithm via weighted kernel sparse representation[J]. Future Generation Computer Systems, 2018, 80: 653-663.
- [19] Fan Z Z, Ni M, Zhu Q, et al. Weighted sparse representation for face recognition[J]. Neurocomputing, 2015, 151: 304-309.
- [20] Fan Z Z, Wang J H, Xu B G, et al. An efficient KPCA algorithm based on feature correlation evaluation[J]. Neural Computing and Applications, 2014, 24(7/8): 1795-1806.
- [21] Fu L J, Chen D Y, Lin K Z, et al. An improved SRC method based on virtual samples for face recognition[J]. Journal of Modern Optics, 2018, 65(13): 1565-1576.

(编辑 候 湘)