

快速局部协同表示分类器及其在人脸识别中的应用

陈长伟^{1,2} 周晓峰¹

1 河海大学计算机与信息学院 南京 210098

2 南京晓庄学院信息工程学院 南京 211171

摘要 针对协同表示分类器(CRC)计算时间复杂度较高的问题,利用重构系数的大小与样本标签之间的正相关性,提出了局部快速协同表示器并用于人脸识别。首先使用最小二乘法求解 L2 范数约束下的线性回归问题;然后对重构系数进行筛选,舍弃对分类不利的负重构系数;最后抛弃原 CRC 算法中的样本重构环节,转而使用最大相似性准则确定测试样本所属分类。该方法利用样本的局部相似性,使识别率得到了一定的提升。同时该方法无需样本重构,求解复杂度大幅度降低。在 AR 和 CMU PIE 数据集上的实验结果表明,所提方法的时间复杂度极大程度优于 CRC,且在各种光照、表情、角度等状态下其识别率均高于现有其他相关算法。

关键词 人脸识别;线性回归;协同表示;流形学习

中图分类号 TP183

Fast Local Collaborative Representation Based Classifier and Its Applications in Face Recognition

CHEN Chang-wei^{1,2} and ZHOU Xiao-feng¹

1 College of Computer and Information, Hohai University, Nanjing 210098, China

2 College of Information and Engineering, Nanjing Xiaozhuang University, Nanjing 211171, China

Abstract To solve the problem of high computational time complexity of collaborative representation based classification method (CRC), this paper proposes a local fast collaborative representation based classifier for face recognition by using the positive correlation between the reconstruction coefficient and sample labels. Firstly, the least square method is used to solve the linear regression problem with a L2 norm constraint, and then the negative reconstruction coefficients which are unsuitable for classification are discarded. Finally, the maximum similarity criterion instead of the reconstruction criterion in CRC is adopted to determine the label of the test sample. The proposed method can receive better performance by taking local similarity into account, and consumes much less time without sample reconstruction than CRC. The experimental results on AR and CMU PIE datasets demonstrate that the proposed method consumes much less time than CRC, and can achieve better recognition accuracy than some state-of-the-art methods with varying illuminations, expressions and angles in facial images.

Keywords Face recognition, Linear regression, Collaborative representation, Manifold learning

1 引言

人脸识别^[1-3]是利用人脸特征信息对人进行身份识别的一种识别方法,可分为 3 个步骤:人脸检测、特征提取、人脸分类,其中分类器的设计是人脸识别的最后一个环节,它的好坏直接决定了人脸识别的效果。

早期的分类器以提高准确率为目标,如经典的最近邻分类器(Nearest Neighbor Classifier, NNC)^[4]、最小距离分类器(Minimum Distance Classifier, MDC)^[5]、K 近邻分类器(K-Nearest Neighbor Classifier, KNNC)^[6]、基于局部均值的最近邻分类器(Local Mean based Nearest Neighbor Classifier,

LM-NNC)^[7]等,这些分类器的思想非常直观,主要以样本距离作为主要判别原则,识别率相对较低。

2008 年, Wright 等提出了稀疏表示分类器(Sparse Representation based Classification, SRC)^[8], SRC 首次将信号分解理论引入人脸识别领域,将人脸识别问题转化为求解 L1 范数最小化问题,在处理光照、表情、遮挡等情况时表现出很强的鲁棒性,识别率有了大幅度的提升,人脸识别自此进入新时期。然而识别率的提高是以时间复杂度近百倍的增加作为代价的,在样本维度较大时,此类算法更加耗时,限制了人脸识别在现实领域的应用。人脸分类器的研究不仅需要提高准确率,降低复杂度同样重要^[9]。2010 年, Naseem 等提出了线

到稿日期:2020-08-24 返修日期:2020-10-31

基金项目:国家自然科学基金(11101216);南京晓庄学院校级科研项目(2019NXY25)

This work was supported by the National Natural Science Foundation of China(11101216) and University Level Scientific Research Project of Nanjing Xiaozhuang University(2019NXY25).

通信作者:陈长伟(chenchangwei2008@sina.com)

性回归分类器 (Linear Regression for Face Recognition, LRC)^[10], LRC 优化了 SRC 算法中求解 L1 范数最小化问题的部分, 使用最小二乘法计算重构系数, 使得算法的时间复杂度下降了一个数量级。Zhang 等分析了稀疏表示算法的运作机理, 发现样本间的协同性才是影响算法性能的关键因素, 并提出了协同表示分类 (Collaborative Representation Classification, CRC)^[11] 算法, 该方法放宽了数据的稀疏性, 使用计算量较小的 L2 范数代替原有的 L1 范数求解特征表示系数, 大大降低了分类器的时间复杂度。

为了提升稀疏、协同表示类算法的识别率, 同时进一步降低时间复杂度, 本文对多种稀疏^[12-15]、协同^[16-18]表示类算法进行了分析, 找出了影响分类器性能的 3 个关键环节: 1) 如何构建字典; 2) 如何求解重构系数^[19-20]; 3) 如何基于重构系数进行分类。对于如何构建字典, 本文在 3.1 节进行了详细分析; 对于如何求解重构系数, 已有多位研究者提出了优秀的方法, 本文使用较为常见的最小二乘法求解; 如何基于重构系数进行分类是本文的核心内容, 将细分为两个问题进行讨论: 1) 如何降低时间复杂度; 2) 如何提高分类器识别率。针对以上两个核心问题, 本文提出了快速局部协同表示分类器 (Fast Local Collaborative Representation based Classifier, FLCRC), FLCRC 在 CRC 的基础上对稀疏系数进行筛选, 使用局部样本的协同性质应对噪声影响并提高识别率, 提出了使用 L2 范数直接作用于重构系数并以最大化参与度作为类别决策准则, 用来代替原有 CRC 分类器中残差最小化的评判标准, 大幅降低了算法的时间复杂度。本文在多个人脸数据库上对所提算法与其他算法进行实验, 验证了本文算法在识别率与时间复杂度方面的优越性。

2 协同表示分类器

假设共有 n 幅人脸图像, 每幅图像的分辨率为 $w \times h$, 这 n 幅图像来自 C 个类别, 每类有 m 幅图像。对这 n 幅图像进行矩阵向量化操作, 可得到 n 幅人脸图像, 训练集样本为 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n]$, 其中, $\mathbf{x}_i \in \mathbf{R}^D$, $D = w \times h$ 。

设待识别样本表示为 $\mathbf{Y}_{\text{test}}$, 则 $\mathbf{Y}_{\text{test}}$ 可表示为训练样本的线性组合:

$$\mathbf{Y}_{\text{test}} = \mathbf{X}\mathbf{w} \quad (1)$$

其中, $\mathbf{w} = [\omega_{1,1}, \omega_{1,2}, \dots, \omega_{2,1}, \dots, \omega_{c,m}]^T \in \mathbf{R}^{c \times m}$ 为线性重构系数向量, $\omega_{a,b}$ 表示第 a 类第 b 个样本对重构 $\mathbf{Y}_{\text{test}}$ 的贡献度。

利用最小二乘法求解重构系数 $\mathbf{w}$:

$$\mathbf{w} = (\mathbf{X}^T \mathbf{X} + \lambda \mathbf{I})^{-1} \mathbf{X}^T \mathbf{Y}_{\text{test}} \quad (2)$$

根据重构系数重建每类样本, 其中, $\mathbf{w}_i$ 表示第 i 类样本对应的重构系数:

$$\hat{\mathbf{y}}_i = \mathbf{X}\mathbf{w}_i, i = 1, 2, \dots, C \quad (3)$$

$$\hat{\mathbf{y}}_i = \mathbf{X}_i (\mathbf{X}_i^T \mathbf{X}_i)^{-1} \mathbf{X}_i^T \mathbf{Y}_{\text{test}} \quad (4)$$

计算重建样本与测试样本残差并除以 $\mathbf{w}_i$ 的 L2 范数:

$$d_i(\mathbf{y}) = \frac{\|\mathbf{Y}_{\text{test}} - \hat{\mathbf{y}}_i\|_2}{\|\mathbf{w}_i\|_2}, i = 1, 2, \dots, C \quad (5)$$

根据最小误差原则, 确定测试样本所属分类:

$$\min_i d_i(\mathbf{Y}_{\text{test}}), i = 1, 2, \dots, C \quad (6)$$

3 快速局部协同表示分类器

3.1 动机

基于字典学习的分类器都是以字典信号的稀疏分解理论为基础, 使用训练集图片作为原子构建字典, 将测试样本表示为各原子的线性组合, 再根据最小误差 (如 SRC, LRC, CRC) 或最大相似性 (如 MRC^[21]) 原则确定样本所属分类。通常情况下, 人脸识别中单一类别人脸是小样本问题, 如 AR 人脸数据库^[22] 每类样本仅为 26 张, Extended Yale B^[23-24] 数据库仅为 64 张, 远远小于样本的维度数, 即使选取每类所有样本也只能构建欠完备字典, 这就限制了稀疏表示的能力, 从而导致重构误差增大, 影响了算法性能。

人脸图像之间具有很大的相似度, 不同类别的图像也能在不同程度上协助表达测试样本。以 AR 人脸数据集中第 1 类中的 1 个样本作为测试样本, 在不同数据集大小下, 以前 i 个类别全部样本构建字典进行稀疏表示, 并计算重构误差, 如图 1 所示。在训练样本受限的情况下引入其他类别的样本进行补充, 可以显著减少重构误差, 提高稀疏表示能力, 从而改善分类器的分类性能。CRC 将全部样本作为字典, 通过构建完备字典, 大大提高了稀疏表示能力。在完成测试样本的稀疏表示并求得稀疏系数向量之后, 测试样本将会由若干个来自不同类别的样本线性组合而成, 继续进行样本重构并通过残差确定测试样本的最终类别。




图 1 不同数据集大小下的重构误差

Fig. 1 Reconstruction errors under different data set sizes

残差衡量的是测试样本与重建样本之间的差异, 即两样本差的 L2 范数。d 维空间中的某点 $\mathbf{x} = (\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(d)})^T \in \mathbf{R}^d$ 的 L^p 范数定义为:

$$\|\mathbf{x}\|_p = \left(\sum_{i=1}^d (\mathbf{x}^{(i)})^p \right)^{\frac{1}{p}} \quad (7)$$

则对于任意 $K > 0$, 如果 $\lim_{d \rightarrow \infty} \frac{\text{var}(\|\mathbf{x}\|_p^k)}{E(\|\mathbf{x}\|_p^k)^2} = 0$, 那么 $\lim_{d \rightarrow \infty} P \left(\frac{\max(\|\mathbf{x}\|_p) - \min(\|\mathbf{x}\|_p)}{\min(\|\mathbf{x}\|_p)} < \epsilon \right) = 1$ 。

该推论证明, 随着样本维度的增加, 各样本之间范数的相对差异越来越小, 在维度趋向于无穷时样本间的范数相等, 这就是著名的“维度灾难”问题^[25]。人脸图片是典型的高维度数据, 在 CRC 算法中 p 取值为 2, 即求样本间的欧氏距离, 随着样本维度的增加, 通过欧氏距离衡量的样本间残差逐渐不准确。虽然有相当多学者提出了很多优秀的降维方法来应对这种“维度灾难”, 如经典的 PCA^[26], LDA^[27], LPP^[28] 等算法, 可以将高维的数据降低到任意维度, 但过低的维度也会导致

大量特征的损失,降低分类器的性能。使用降维的方法无法完全避免“维数灾难”的影响,为此需要使用一种新的评价方法来规避高维空间欧氏距离效果下降的问题。稀疏系数向量表示的是字典中各个原子在表示测试样本时参与的权重,某个原子对应的系数越大则说明此原子在参与表示时越重要,与测试样本相似度更高。抛弃 CRC 中以最小残差作为判断标准,转而使用最大相似性原则作为最终类别的判断标准,就可以有效避免“维数灾难”问题。

人脸图像之间的相似性也是造成分类器产生错误的主要原因。例如,字典由 4 个原子构成,样本 a_1, a_2 来自 X_i 类别,对应的重构系数为 w_{a_1}, w_{a_2} , 样本 b_1, b_2 来自 X_j 类别,对应的重构系数为 w_{b_1}, w_{b_2} , 测试样本 Y_{test} 来自分类 X_i , 在某种情况下,可能出现 b_1 取得了最大的重构系数 w_{b_1} , 而 w_{b_2} 的重构系数较小,与此同时 w_{a_1} 和 w_{a_2} 均略小于 w_{b_1} 的情况,此时根据最大相似原则将测试样本确定为 X_j 则会造成误判。此时虽然 $\max(w) = w_{b_1}$, 但 $w_{a_1} + w_{a_2} > w_{b_1} + w_{b_2}$, 这说明在参与表示的原子中 X_i 类原子贡献了更多的成分,以整类样本的参与程度作为衡量标准可以提高算法的性能。反之,若 $w_{a_1} + w_{a_2} \approx w_{b_1} + w_{b_2}$, 每类样本的参与程度相当,则认为具有较大系数的原子在参与稀疏表示时占主体地位,更有可能与测试样本处于同一子空间内。文献[11]对稀疏表示类算法能较好地重建样本的内在原因进行了详尽的分析,证明了影响信号重建的并不是 L1 范数对目标函数的稀疏性约束,而是样本间的协同性。因此在确定测试样本的所属分类时,要综合考虑每类样本的参与程度,即利用样本间的协同性,同时强化较大系数所占的权重、弱化较小系数所占的权重。此外流形学观点认为,样本的相似性质更多地集中在与其近邻的若干个样本中,而不是整个样本集中^[29-31],舍弃与测试样本较远的样本可以更好地利用同类样本子空间的相似性质,提高分类器对噪声的容忍程度。基于以上研究,本文提出了基于快速局部协同表示的人脸分类器,具体地,先对重构系数进行预处理,仅保留稀疏表示中产生正面影响的系数,即舍弃负值系数,巧妙利用 L2 范数,在考虑每类样本参与程度(协同性)的同时优化了各系数的权重,有效降低了训练样本中噪声的影响,使分类器更具鲁棒性。由于仅需要对数据量极小的重构系数求 L2 范数,无需对样本进行重构,因此其时间复杂度相对 CRC 算法大幅度降低。

3.2 快速局部协同表示分类器

待识别样本 Y_{test} 可表示为全体训练样本 X 的线性组合:

$$Y_{\text{test}} = Xw \quad (8)$$

其中, $w = [w_{1,1}, w_{1,2}, \dots, w_{2,1}, \dots, w_{c,m}]^T \in R^n$ 为线性重构系数向量, $w_{a,b}$ 表示第 a 类第 b 个样本对重构 Y_{test} 的贡献度。

使用最小二乘法求解重构系数 w , 其中 $I \in R^{C \times C}$ 是单位矩阵, $\lambda > 0$ 是可调节参数。

$$w = (X^T X + \lambda I)^{-1} X^T Y_{\text{test}} \quad (9)$$

将 $w_{a,b}$ 中小于 0 的系数置为 0:

$$w_{a,b} = \{0 \mid \text{if } w_{a,b}(i) < 0, a = 1, 2, \dots, C, b = 1, 2, \dots, m\} \quad (10)$$

求 w 所代表样本每一类别的 L2 范数, 其中 w_i 表示第 i 类样本对应的重构系数:

$$S_a = \|w_i\|_2, (i = 1, 2, \dots, C) \quad (11)$$

3.3 快速局部协同表示分类算法步骤

根据前文所述,快速局部协同表示分类 FLCRC 算法的流程如算法 1 所示。

算法 1 FLCRC 算法

输入: 包含 C 类样本的训练样本集 $X = [X_1, X_2, \dots, X_C]$, 每类样本包含 m 个样本, 第 i 类样本表示为 $X_i = [X_{i,1}, X_{i,2}, \dots, X_{i,m}]$, 测试样本 y , 可调节参数 λ

输出: 根据最大相似原则, 确定测试样本所属分类: $\max_a S_a(Y_{\text{test}})$ ($a = 1, 2, \dots, C$)

- Step 1 使用最小二乘法求解重构系数 $w = (X^T X + \lambda I)^{-1} X^T Y_{\text{test}}$;
- Step 2 将 w 中小于 0 的系数置为 0:
 $w_{a,b} = \{0 \mid \text{if } w_{a,b}(i) < 0, a = 1, 2, \dots, C, b = 1, 2, \dots, m\}$;
- Step 3 求 w 所代表样本每一类别的 L2 范数: $S_a = \|w_i\|_2, (i = 1, 2, \dots, C)$;
- Step 4 将样本 y 分类到具有最大 L2 范数的类 S : $S = \max_a S_a(y), (a = 1, 2, \dots, n)$;
- Step 5 根据样本在低维空间的表示利用分类器进行分类。

4 实验结果与分析

为了评估所提算法的性能,本节在 AR 和 CMU PIE 人脸库^[32]上设计了 3 组实验;同时在 Extended Yale B 人脸库和 FERET^[33]人脸库上各设计了 1 组实验,用于验证所提方法的时间复杂度。参与对比的算法有 NNC, SRC, LRC, MRC, CRC。所有实验方法使用 MATLAB 2020a 实现,部分使用多线程以及 GPU 加速。CPU 为 AMD R7 2700 3.2GHz, GPU 为 NVIDIA RTX2080TI, 内存为 32GB。

4.1 AR 人脸数据集实验

AR 人脸数据库包含 126 位志愿者,每人 26 幅图像,包含不同的表情、光照、角度、遮挡等情况。数据集中的样本分为两个部分,前后各 13 张,样本表情、光照等条件相同,间隔 14 天采集,共计 3 276 张。实验中采用经过预处理且不含遮挡的图像,共包括样本 120 类,每类样本 14 个,共计 1 680 个样本。所有图片样本均为下采样至 50×45 像素的灰度图片。AR 人脸数据库上某一类样本的 14 幅图像如图 2 所示。



图 2 AR 数据库上某人的 14 幅图像

Fig. 2 14 images of one person on AR database

在 AR 库上,实验中选取每类人脸样本的前 l ($l = 4, 5, 6$) 个样本作为训练样本,其余样本作为测试样本。所有算法执行前均经过 PCA 降维处理,投影维数从 100 到 450,间隔为 50。SRC 算法中稀疏约束 $\epsilon = 0.001$, CRC 与 FLCRC 中参数 $\lambda = 0.02$ 。图 3—图 5 为 AR 库上在训练集大小为 4, 5, 6 (每类样本选取 4, 5, 6 个) 时,在不同投影维数下各个方法的性能。表 1 为 AR 库上训练样本数分别为 4, 5, 6 时,各算法的最佳识别率。




图 3 在 AR 库上当训练样本数为 4 时各算法最佳识别率的比较
Fig. 3 Comparison of the best recognition rate of each algorithm when number of training samples is 4 on AR database




图 4 在 AR 库上当训练样本数为 5 时各算法最佳识别率的比较
Fig. 4 Comparison of the best recognition rate of each algorithm when number of training samples is 5 on AR database




图 5 在 AR 库上当训练样本数为 6 时各算法最佳识别率的比较
Fig. 5 Comparison of the best recognition rate of each algorithm when number of training samples is 6 on AR database

表 1 AR 库上各算法的最高识别率

	database					
	NNC	SRC	LRC	MRC	CRC	FLCRC
$l=4$	46.08	60.92	51.17	56.00	67.17	67.58
$l=5$	48.52	72.41	53.80	59.35	78.70	79.17
$l=6$	54.48	78.85	69.79	60.52	84.58	84.69

由图 3—图 5 可以看出,在不同训练集下,随着投影维数增加,FLCRC 始终保持在略高于原始算法的水平,远高于其余稀疏表示类算法,且提升较为稳定,对表情变化明显的样本具有较强的鲁棒性。

4.2 CMU PIE 人脸数据集 C27 实验

CMU PIE 人脸数据集包含 68 位志愿者在不同表情、光照、拍摄角度等情况下的共计 51 368 个样本,其中包含 5 个接近正脸角度的子数据集(C05,C07,C09,C27,C29)。本文选取 C27 进行实验,C27 包含 24 个类别,每类 68 张,共计 1 632 个样本,所有图片样本均为下采样至 64 * 64 像素的灰度图片。CMU PIE 人脸数据库 C27 中某一类样本的 49 幅图像如图 6 所示。



图 6 CMU PIE 数据库 C27 上某人的 49 幅图像
Fig. 6 49 images of one person on CMU PIE C27 database

在 CMU PIE 库 C27 上,选取每类人脸样本的前 $l(l=4, 5, 6)$ 个样本作为训练样本,其余样本作为测试样本。所有算法执行前均经过 PCA 降维处理,投影维数从 80 增加到 240,间隔为 20,SRC 算法中稀疏约束 $\epsilon=0.001$,CRC 与 FLCRC 中参数 $\lambda=0.02$ 。图 7—图 9 为 CMU PIE 库上在训练集大小为 4,5,6 时不同投影维数下各个方法的性能。表 2 为 CMU PIE 库上训练样本数分别为 4,5,6(每类样本选取 4,5,6 个)时,各算法的最佳识别率。




图 7 在 PIE 库 C27 上当训练样本数为 4 时各算法最佳识别率的比较
Fig. 7 Comparison of the best recognition rate of each algorithm when number of training samples is 4 on PIE C27 database




图 8 在 CMU PIE 库 C27 上当训练样本数为 5 时各算法最佳识别率的比较

Fig. 8 Comparison of the best recognition rate of each algorithm when number of training samples is 5 on CMU PIE C27 database




图 9 在 PIE 库 C27 上当训练样本数为 6 时各算法最佳识别率的比较
Fig. 9 Comparison of the best recognition rate of each algorithm when number of training samples is 6 on PIE C27 database

表 2 CMU PIE 数据库 C27 上各方法最高的识别率

CMU PIE C27 database						
<i>l</i>	NNC	SRC	LRC	MRC	CRC	FLCRC
<i>l</i> =4	39.12	70.75	42.91	51.76	77.19	77.58
<i>l</i> =5	40.47	73.70	50.64	51.54	80.15	80.41
<i>l</i> =6	42.00	77.19	52.39	48.84	83.14	83.38

此实验中面对明暗变化较为明显的图片,FLCRC 表现出了较强的鲁棒性,从表 2 可以发现,所提算法在各种数据集下均取得了最好的性能。

4.3 CMU PIE 人脸数据集 C05 实验

本节选取 C05 进行实验,C05 包含 24 个类别,每类 68 张,共计 1632 个样本,所有图片样本均为下采样至 64 * 64 像素的灰度图片。CMU PIE 数据库 C05 上某一类样本的 49 幅图像如图 10 所示。



图 10 CMU PIE 数据库 C05 上某人的 49 幅图像
Fig. 10 49 images of one person on the CMU PIE C05 database

实验中选取每类人脸样本的前 $l(l=4,5,6)$ 个样本作为训练样本,其余样本作为测试样本。所有算法执行前均经过 PCA 降维处理,投影维数从 80 增加到 240,间隔为 20,SRC 算法中稀疏约束 $\epsilon=0.001$,CRC 与 FLCRC 中参数 $\lambda=0.09$ 。图 11—图 13 为 CMU PIE 库上在训练集大小为 4,5,6(每类样本选取 4,5,6 个)时不同投影维数下各个方法的性能。表 3 为 PIE C05 库上训练样本数分别为 4,5,6 时,各算法的最佳识别率。




图 11 PIE 库 C05 上训练样本数为 4 时各算法最佳识别率的比较
Fig. 11 Comparison of the best recognition rate of each algorithm when number of training samples is 4 on PIE C05 database




图 12 PIE 库 C05 上训练样本数为 5 时各算法最佳识别率的比较
Fig. 12 Comparison of the best recognition rate of each algorithm when number of training samples is 5 on PIE C05 database




图 13 PIE 库 C05 上训练样本数为 6 时各算法最佳识别率的比较
Fig. 13 Comparison of the best recognition rate of each algorithm when number of training samples is 6 on PIE C05 database

表 3 CMU PIE 数据库 C05 上各方法最高的识别率

CMU PIE C05 database						
<i>l</i>	NNC	SRC	LRC	MRC	CRC	FLCRC
<i>l</i> =4	57.78	75.81	65.88	48.95	83.66	83.69
<i>l</i> =5	58.39	79.78	70.19	47.93	86.30	86.60
<i>l</i> =6	58.52	82.80	70.86	46.14	89.40	89.57

此实验中面对明暗变化强烈且有一定偏转角度的人脸图片,FLCRC 依旧取得了最高的识别率,且仍然小幅度领先于原算法。

4.4 时间复杂度与参数的选择

在 Extended Yale B 数据库上进行实验,验证投影维数对各算法时间复杂度的影响;在 FERET 数据库上进行实验,验证数据集大小对各算法时间复杂度的影响。算法时间复杂度计量时仅包含算法本身的计算时间,不包含图像预处理以及降维所消耗的时间,其中,SRC 算法中稀疏约束 $\epsilon=0.001$,CRC 和 FLCRC 算法中 $\lambda=0.02$, $P=(X^T X + \lambda I)^{-1} X^T$ 独立于测试样本仅计算 1 次耗时。

Extended Yale B 数据库包含 38 个人,共有 2414 幅图像。本实验使用下采样至 96 * 84 的灰度图像,实验中训练集大小和测试集大小为 1:1,测试 PCA 降维到不同维数情况下各算法的时间复杂度。图 14 给出了各算法处理每个样本所消耗的平均时间,其中 SRC 算法由于时间复杂度较其余算法过高,在次坐标轴显示。图 15 给出了 FLCRC 和其原算法在时间复杂度上的对比。表 4 列出了 FLCRC 与原算法的耗时对比。Multiple 列表示原 CRC 算法相比 FLCRC 耗时的倍数。




图 14 Extended Yale B 库上各算法处理每个样本所消耗的平均时间
Fig. 14 Average time consumed by each sample in each algorithm on the Extended Yale B database




图 15 Extended Yale B 库上 FLCRC 与其余算法耗时的对比

Fig. 15 Time consuming of FLCRC compared with other algorithms on Extended Yale B database

表 4 在 Extended Yale B 库上的耗时对比

Table 4 Time consuming comparison on Extended Yale B database

(单位: 10^{-7} s)

components	CRC	FLCRC	Multiple
50	142.37	9.77	14.58
100	179.38	10.79	16.62
150	251.34	11.31	22.23
200	267.78	11.31	23.68
250	331.52	11.82	28.04
300	383.94	11.82	32.48
350	418.38	11.82	35.39
400	470.29	11.82	39.78
450	521.69	11.82	44.13
500	584.91	11.82	49.48

FERET 数据库包含 200 个志愿者,每人 7 幅图像,共计 1 400 个样本。本实验下采样至 80×80 。实验中 PCA 投影维数统一为 200,测试不同训练集下各算法的时间复杂度,训练集大小取值为 $l(l=2,3,4,5,6)$ 。图 16 给出了各算法处理每个样本所消耗的平均时间。图 17 给出了 FLCRC 及其原算法的耗时对比。表 5 列出了 FLCRC 与原算法的耗时对比。




图 16 FERET 库上各算法处理每个样本所消耗的平均时间

Fig. 16 Average time consumed by each sample in each algorithm on the FERET database




图 17 FERET 库上 FLCRC 及其原算法的耗时

Fig. 17 Time consuming of FLCRC compared with other algorithms on the FERET database

表 5 在 FERET 库上的耗时对比

Table 5 Time consuming comparison on the FERET database

(单位: 10^{-6} s)

l	$l=2$	$l=3$	$l=4$	$l=5$	$l=6$
CRC	133.25	137.81	142.29	150.62	158.13
FLCRC	1.50	1.85	2.08	2.50	3.13
Multiple	80.83	73.50	68.30	60.25	50.60

图 18 为 FLCRC 选取不同参数 λ 时在 AR,CMU PIE 数据集 C27 下的识别率,其中 AR 与 CMUPIE 数据集中训练集大小均为 10,投影维数均为 300。




图 18 FLCRC 算法中 λ 取值与识别率的关系

Fig. 18 Relationship between λ and recognition rate in FLCRC algorithm

4.5 实验结果分析

根据实验结果,可以得到如下结论:

(1)通过图 3—图 5、图 7—图 9、图 11—图 13 可以发现,在不同数据集、不同降维维度下,FLCRC 的识别率均大幅度领先于其余稀疏、协同表示类算法,与原 CRC 算法相比也有小幅度的提升。这主要是由于 FLCRC 采用了局部协同的思想,舍弃了部分子空间中相对较远的样本,更好地利用了同类样本子空间的相似性质,使 FLCRC 对噪声具有更强的鲁棒性,在面对光照、表情、角度变化的样本时表现出更高的识别率。

(2)FLCRC 算法中,可调节参数 λ 的取值对最终的结果起到至关重要的作用。使用最小二乘法对训练样本构建的字典求解稀疏系数的过程就是通过最小化误差的平方来寻找数据的最佳函数拟合,即求解满足 $\min \|\mathbf{Y}_{\text{test}} - \mathbf{X}\mathbf{w}\|_2^2$ 时的 $\mathbf{w}$,添加 $\lambda \|\mathbf{w}\|_2^2$ 作为 L2 正则化的约束项,可以使最小二乘估计更好地适用于训练样本以外的样本,有效避免了过拟合问题。

(3)从表 4、表 5 可以看出,FLCRC 的求解速度非常快,单测试样本的最快求解时间可以达到 10^{-7} s 的水平,相对于原 CRC 算法缩小到几十分之一。图 14 中,随着保留投影维数从 50 增长到 500,扩大了 10 倍,所有算法的时间复杂度都有不同程度的增加,其中 SRC 算法的耗时增长最为明显,耗时增加了近 40 倍;原 CRC 算法耗时的提升也较为明显,为 4 倍;本文提出的 FLCRC 算法在保留投影维数增长 10 倍的情况下,时间复杂度仅增加了 21%。可以预见,面对高维度样本时,FLCRC 将在时间复杂度上表现出更大的优越性。图 16 中随着训练集取值的增大,FLCRC 算法对于单个样本耗时的增加比例略高于其余各算法,这是由于 FLCRC 中对稀疏系数的预处理及 L2 范数求解占据了大部分的时间,随着训练集大小的增加,稀疏系数的数量随之成比例增加,造成耗

时增长率过快,但消耗时间的绝对值大幅度领先于其余算法。

(4)FLCRC 较 CRC 在时间复杂度上以极大的优势领先,这是由于 FLCRC 算法对 CRC 算法中的样本重构环节进行了调整,以计算量极小的局部重构系数的 L2 范数求解,代替了 CRC 算法中耗时巨大的样本重构及残差计算环节。

(5)参数 λ 的选择对算法的识别率具有至关重要的作用,因为不同的 λ 取值会影响到稀疏表示中线性重构系数的分布,不合适的 λ 取值会使错误类别的重构系数异常偏大,无法反映样本的分布信息,导致识别率下降;合理的 λ 取值可以更好地调节重构系数的分布,使识别率得到提升。如本文算法在 AR 数据集上 λ 取 0.02 时获得最佳识别率,在 CMU PIE 数据集上 λ 取 0.02 时获得最佳识别率。

结束语 SRC 算法以全部训练集样本构建字典,将人脸识别问题转化为 L1 范数最小化问题,使人脸识别具有较好的鲁棒性;LRC 在 SRC 的基础上使用类内样本构建字典,大幅度减少 SRC 耗时;CRC 算法以 SRC 算法为基础,突出了协同性的重要作用,使用 L2 范数放宽了 SRC 算法中对稀疏性的要求,进一步降低了时间复杂度。本文分析了多种稀疏、协同表示类算法的优缺点,在 CRC 的基础上提出了 FLCRC,利用局部样本重构系数的 L2 范数取代 CRC 算法中的样本重构和残差计算,大幅度降低了时间复杂度,同时,准确率也得到了提升。实验中发现参数 λ 的选取对算法性能的影响较大,不同实验中使算法达到最佳性能的取值暂无依据可循;另一方面 FLCRC 算法相对于原 CRC 算法识别率提升有限,如何降低参数调优的难度以及进一步提升算法识别率是后续研究和优化的方向。

参 考 文 献

[1] JAYARAMAN U, GUPTA P, GUPTA S, et al. Recent Development in Face Recognition[J]. Neurocomputing, 2020, 408: 231-245.

[2] CHENG E J, CHOU K P, RAJORA S T, et al. Deep Sparse Representation Classifier for Facial Recognition and Detection System[J]. Pattern Recognition Letters, 2019, 125: 71-77.

[3] MOKHAYERI F, GRANGER E. A paired sparse representation model for robust face recognition from a single sample[J/OL]. <http://arXiv.org/abs/1910.02192>.

[4] COVER T, HART P. Nearest Neighbor Pattern Classification [J]. IEEE Transactions on Information Theory, 2003, 13 (1): 21-27.

[5] GONZALEZ R C, WOODS R E. Digital Image Processing[M]. Addison Wesley, 1997.

[6] DUDA R O, HART P E, STORK D G. Pattern Classification (2nd Edn.) [M]. Wiley, 2000.

[7] MITANI Y, HAMAMOTO Y. A Local Mean based Nonparametric Classifier[J]. Pattern Recognition Letters, 2006, 27(10): 1151-1159.

[8] WRIGHT J, YANG A Y, GANESH A, et al. Robust Face Recognition via Sparse Representation[J]. IEEE Transactions on

Pattern Analysis and Machine Intelligence, 2008, 31 (2): 210-227.

[9] SONG X N, HU G S, LUO J H, et al. Fast SRC using Quadratic Optimisation in Downsized Coefficient Solution Subspace[J]. Signal Processing, 2019, 161: 101-110.

[10] NASEEM I, TOGNERI R, BENNAMOUN M. Linear Regression for Face Recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(11): 2106-2112.

[11] ZHANG L, YANG M, FENG X C. Sparse Representation or Collaborative Representation: Which helps Face Recognition? [C]// International Conference on Computer Vision, 2012.

[12] YANG A Y, ZHOU Z, GANESH A, et al. Fast L1-Minimization Algorithms for Robust Face Recognition[J]. IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society, 2010, 22(8): 3234-3246.

[13] BERNHARD S, JOHN P, THOMAS H. Sparse Representation for Signal Classification[C]// International Conference on Neural Information Processing Systems, 2016.

[14] 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.

[15] GAO S H, TSANGI W H, CHIA L T. Kernel Sparse Representation for Image Classification and Face Recognition[C]// European Conference on Computer Vision, 2010.

[16] WANG B, LI W F, POH N, et al. Kernel collaborative representation-based classifier for face recognition [C]// IEEE International Conference on Acoustics, Speech and Signal Processing, 2013: 2877-2881.

[17] WANG D, LU H, YANG M. Kernel collaborative face recognition[J]. Pattern Recognition, 2015, 48(10): 3025-3037.

[18] VO D M, LEE S W. Robust face recognition via hierarchical collaborative representation[J]. Information Sciences, 2017, 432: 332-346.

[19] DONOHO D. For Most Large Underdetermined Systems of Linear Equations the Minimal L1-Norm Solution is also the Sparsest Solution[J]. Communications on Pure and Applied Mathematics, 2006, 59(6): 797-829.

[20] TROPP J A, WRIGHT S J. Computational methods for sparse solution of linear inverse problems[C]// Proceedings of IEEE, Special Issue on Applications of Compressive Sensing & Sparse Representation, 2010: 948-958.

[21] XU J, YANG J. Mean Representation based Classifier with its Applications[J]. Electronics Letters, 2011, 47(18): 1024-1026.

[22] MARTINEZ A M, BENAVENTE R. The AR face database [R]. CVC Technical Report # 24, 1998.

[23] GEORGHIADES A, BELHUMEUR P, KRIEGMAN D. From Few to Many: Illumination Cone Models for Face Recognition under Variable Lighting and Pose[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23 (6): 643-660.

[24] LEE K, HO J, KRIEGMAN D. Acquiring Linear Subspaces for Face Recognition under Variable Lighting[J]. IEEE Transactions

on Pattern Analysis and Machine Intelligence, 2005, 27(5): 684-698.

[25] JUAN L,MARTÍNEZ F,ZULIMA F. The curse of dimensionality in inverse problems[J/OL]. Journal of Computational and Applied Mathematics, 2020, <https://doi.org/10.1016/j.cam.2019.112571>.

[26] TURK M,PENTLAND A. Eigenfaces for recognition[J]. J Cogn Neurosci, 1991, 3(1): 71-86.

[27] BLEI D M,NG A Y,JORDAN M I. Latent Dirichlet Allocation [J]. Machine Learning Research Archive, 2003, 3: 993-1022.

[28] HE X F. Locality Preserving Projections[J]. Advances in Neural Information Processing Systems, 2003, 16(1): 186-197.

[29] HUANG P,YANG Z,CHEN C. Fuzzy Local Discriminant Embedding for Image Feature Extraction [J]. Comput. Electr. Eng., 2015, 46: 231-240.

[30] HUANG L,MA Y Q,LIU X L. A General Non-Parametric Active Learning Framework for Classification on Multiple Manifolds[J]. Pattern Recognition Letters, 2020, 130: 250-258.

[31] MENG Y,SHANG R,JIAO L,et al. Feature Selection Based Dual-graph Sparse Non-negative Matrix Factorization for Local Discriminative Clustering[J]. Neurocomputing, 2018, 290(17): 87-99.

[32] GROSS R,MATTHEWS I,COHN J,et al. Multi-PIE[J]. Image and Vision Computing, 2010, 28(5): 807-813.

[33] PHILLIPS P J,WECHSLER H,HUANG J S,et al. The FERET Database and Evaluation Procedure for Face-Recognition Algorithms [J]. Image and Vision Computing, 1998, 16(5): 295-306.

CHEN Chang-wei, born in 1975, Ph.D, associate professor, is a member of China Computer Federation. His main research interests include image processing and pattern recognition, etc.