

# 带判别性局部结构约束的多分辨率字典学习算法及人脸识别研究

曾淑英<sup>1</sup>, 汤红忠<sup>1,2\*</sup>, 邓仕俊<sup>2</sup>, 张东波<sup>2</sup>

<sup>1</sup>湘潭大学自动化与电子信息学院, 湖南 湘潭 411105;

<sup>2</sup>智能信息处理与应用湖南省重点实验室, 湖南 衡阳 421002

**摘要** 字典学习是图像表示的一种有效手段且在图像识别任务中具有出色的表现。大部分传统字典学习算法在高分辨率人脸图像识别中存在不同分辨率下字典判别性不强的问题。为了解决这一问题,提出一种新的带判别性局部结构约束的多分辨率字典学习算法。首先,通过分析字典原子与轮廓向量之间的一一对应关系,采用字典原子的局部几何结构,分别构造了轮廓向量的类内局部约束项与类间局部约束项;然后将这两个约束项统一在同一个正则项中,并将其增加到字典学习目标函数中进行联合优化,从而实现判别性局部几何结构的编码。该算法促使类内编码系数保持相似的局部一致性,而且能有效提高类间编码系数的局部结构的差异性。最后,在多个多分辨率人脸图像数据集上验证了本文算法的有效性,实验结果表明,与同类字典学习算法相比,本文学习的多分辨率字典能保持训练样本中的判别性局部结构,在不同分辨率的人脸图像上获得了更好的识别性能。

**关键词** 机器视觉; 字典学习; 判别性局部结构约束; 多分辨率字典; 人脸识别

中图分类号 TP391.41

文献标志码 A

doi: 10.3788/LOP202158.1415008

## Multi-Resolution Dictionary Learning Algorithm with Discriminative Locality Constraints for Face Recognition

Zeng Shuying<sup>1</sup>, Tang Hongzhong<sup>1,2\*</sup>, Deng Shijun<sup>2</sup>, Zhang Dongbo<sup>2</sup>

<sup>1</sup> College of Automation and Electronic Information, Xiangtan University, Xiangtan, Hunan 411105, China;

<sup>2</sup> Hunan Provincial Key Laboratory of Intelligent Information Processing and Application, Hengyang, Hunan 421002, China

**Abstract** Although dictionary learning has shown to be a powerful tool for image representation and has achieved satisfactory results in various image recognition tasks. Most traditional dictionary learning algorithms have been restricted to multi-resolution face recognition tasks mainly due to the poor discriminability of the dictionary. To solve this problem, we propose a novel multi-resolution dictionary learning algorithm with discriminative locality constraints (MDL DLC) in this paper. Based on the one-to-one mapping between each dictionary atom and the corresponding profile vector, we design two local constraints on profile vectors, referred to as intra-class and inter-class local constraints, by utilizing the local geometric structure of the dictionary atoms. Meanwhile, the two constraints are formulated into a unified regularization term and incorporated into the objective function of the dictionary learning model to optimize for encoding the discriminative locality of input data jointly. The proposed MDL DLC algorithm encourages high intra-class local consistency and inter-class local separation in the code space of multi-resolution images. Finally, extensive experiments conducted on different multi-resolution face image datasets demonstrate the effectiveness of the proposed MDL DLC algorithm. The results show that the proposed MDL DLC

收稿日期: 2020-08-03; 修回日期: 2020-09-20; 录用日期: 2020-09-30

基金项目: 国家自然科学基金区域创新发展联合基金(U19A2083)、湖南省战略性新兴产业科技攻关与重大成果转化项目(2019GK4007)、湖南省自然科学基金(2020JJ4588, 2020JJ4090)

通信作者: \*diandiant@126.com

algorithm can learn the multi-resolution dictionaries with discriminative locality, preserving and achieving promising recognition performance compared with other state-of-the-art dictionary learning algorithms.

**Key words** machine vision; dictionary learning; discriminative locality constraints; multi-resolution dictionary; face recognition

**OCIS codes** 150.1135; 100.5010; 100.3008

## 1 引言

人脸自动识别是根据人脸图像特征来识别或判别人的身份,是一种极其有效的生物识别技术,已广泛应用于人机交互、智能视觉导航与安全安防等领域。近十几年来,智能手机与视频监控技术的普及,为人脸识别技术现场应用提供了海量有价值的数据库,人脸识别技术也取得了突破性进展,但多数工作仍然集中于限定条件下采集的单分辨率图像<sup>[1-2]</sup>。然而实际场景中,光照条件、有无遮挡物以及成像设备中数字变焦或者光学变焦的功能差异,使得同一个人或场景存在不同分辨率的多个图像。多分辨率图像中人脸轮廓与细节特征有较大的差异,如人脸表情变化、姿态平移、噪声强弱等,部分关键的分类特征有可能只出现在某些分辨率的人脸图像中,这些因素极大地影响了传统人脸识别算法的精度与泛化性能。因此,研究如何提高多分辨率人脸识别的性能是该领域中急需解决的问题之一,且具有极大的应用价值与行业需求。

图像稀疏表示作为一种新兴且有效的表示方法,已广泛应用于人脸图像识别<sup>[3]</sup>、人体行为识别<sup>[4]</sup>与高光谱图像分类识别<sup>[5]</sup>等相关领域。Wright等<sup>[6]</sup>认为同一人脸图像可以表示为若干训练图像的线性组合,并首次提出基于稀疏表示的人脸识别方法,获得了令人满意的性能。至此,基于稀疏表示及字典学习的人脸识别方法也迅速获得国内学者的广泛关注。其中,如何通过学习获得判别性强的稀疏表示系数是人脸识别算法性能提升的关键问题。文献<sup>[7-10]</sup>针对这一问题,提出了不同的解决方案。Zhang等<sup>[7]</sup>提出了判别性KSVD(D-KSVD)字典学习算法,该算法在文献<sup>[6]</sup>的基础上增加了线性分类器学习,采用K-SVD方法同时优化学习字典与分类器参数。进一步地,Jiang等<sup>[8]</sup>提出了类标一致性KSVD(LC-KSVD)字典学习算法,通过对字典原子引入类标信息,利用类标一致性原则构建了学习字典的正则项。Yang等<sup>[9]</sup>基于Fisher准则提出一种判别性字典学习(FDDL)算法,同时优化了稀疏表示系数的类内相似性与类间差异性。Gu等<sup>[10]</sup>提出一种投影字典对学习(DPL)算法,该算法同时学习

了合成字典和解析字典,并通过解析字典的投影保证了表示系数的判别性。上述工作均通过不同的策略优化了编码系数的判别性能,提升了人脸识别算法性能。

在实际应用中,在不同分辨率下同一个人的多幅人脸图像可能存在于同一个高维空间中的低维子流形上<sup>[11]</sup>。为了利用这种潜在的流形结构,文献<sup>[12-13]</sup>提出了局部结构保持策略,若训练样本具有一定的局部几何结构,在进行特征编码后,这种结构也将保持在编码系数中。基于此,Wang等<sup>[12]</sup>提出了局部约束线性编码(LLC)算法,该算法通过引入样本特征与原子之间的相似性来保持编码系数的局部结构,从而确保相似样本的编码系数也相似。在此基础上,Min等<sup>[13]</sup>提出了拉普拉斯正则化局部约束编码(LpLLC)算法,该算法基于训练样本构造拉普拉斯矩阵来描述样本的局部结构,利用拉普拉斯正则项来实现局部结构保持这一目的。类似地,文献<sup>[14]</sup>提出了一种局部感知的判别性字典学习(LSDDL)算法,该算法在字典学习中引入编码系数的局部保持正则项,有效地提高了人脸识别精度。Li等<sup>[15]</sup>提出了局部约束与类标嵌入的字典学习(LCLE-DL)算法,该算法基于字典原子的局部几何结构构造了轮廓向量约束项,其目的是保证相似字典原子具有相似的轮廓向量。近期,文献<sup>[16]</sup>提出了一种自表达局部结构自适应双字典学习(SLaDPL)算法,该算法引入了两个非相干局部约束的正则项,并将稀疏编码和显著性特征提取集成在一个模型中,促使相似样本的编码系数具有较高的相似性,以此提高算法的识别性能。

近些年来,深度学习方法在大数据样本下显现出非常强的特征提取能力,在自然图像分类中取得了巨大的进展。近期也涌现出基于深度学习的人脸识别方法,如Deepface<sup>[17]</sup>、DeepID<sup>[18]</sup>等。基于深度学习的工作大多利用卷积神经网络获取人脸图像的深度特征,然后再用Softmax函数进行识别。为了获得人脸图像的深度特征,往往需要大量的训练样本、复杂的网络结构与较长的训练时间,然而对于数量较少的数据样本而言,传统方法具有与深度学习算法相当的性能且计算效率更高。

上述基于字典学习与深度学习的人脸识别工作,虽然均取得了令人满意的性能,但大多是针对限制条件下采集的单分辨率人脸图像,故将上述方法直接用于解决实际问题时,无法达到理想的识别精度且泛化性能大大下降。因此,2019年 Luo 等<sup>[19]</sup>提出了多分辨率字典学习(MRD L)算法,在不同分辨率人脸图像中分别学习相应的字典,并基于不同分辨率下的表示系数构造分类器,实现了多分辨率人脸识别。此外,Zhang 等<sup>[20]</sup>基于样本扩展策略提出一种多分辨率字典学习(SEMRDL)算法,该算法利用多重表征理论生成虚拟样本来增加训练样本的数量,解决了因样本数量小而导致的学习字典鲁棒性弱的问题。然而,上述多分辨率人脸识别算法在字典学习过程中主要以优化不同分辨率下字典的重构性能为目标,故学习字典对多分辨率图像具有很好的重构性能。但是受不同多分辨率的影响,忽略了在多个分辨率下图像局部结构的类内相似性与类间差异性,同时人脸图像的类内特征差异可能大于类间特征差异,较好的重构特征并不一定是最优的分类特征,这大大影响了算法的性能。

不同分辨率下人脸图像的光照、表情与姿态都存在较大的差异,图像轮廓与细节变化、噪声的强弱都会引起学习字典的判别性与泛化性能有较大的衰减。从另一角度来说,高分辨率人脸图像中包含更

多低级特征与细节信息,低分辨率人脸图像则包含了更多语义特征与全局信息,有时某一分辨率下图像中丢失的关键信息会出现在另一分辨率图像中。学习不同分辨率下的判别性字典,挖掘不同分辨率图像特征之间的互补信息,填补细节信息与语义信息的特征差距,将利于提高多分辨率人脸图像识别性能。

基于上述分析,本文提出一种带判别性局部结构约束的字典学习(MDL DLC)算法,并将其应用于多分辨率人脸识别,其主要目的是解决多分辨率人脸图像识别中学习字典判别性不强的问题。该算法利用不同分辨率图像的特征互补性,首先在不同分辨率下的人脸图像中分别学习相应的字典,然后,基于不同分辨率字典的类内原子与类间原子,分别构造相应的类内局部约束项与类间局部约束项,并将两者统一在同一个正则项中联合优化,从而确保局部几何结构的编码,有效地学习带判别性的局部结构,最终提高了多分辨率人脸图像的识别性能。

## 2 相关工作

### 2.1 多分辨率字典学习算法

2019年,Luo 等<sup>[19]</sup>提出了一种多分辨率字典学习(MRD L)算法,其目标函数定义为

$$\langle \mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_k, \mathbf{X} \rangle = \underset{\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_k, \mathbf{X}}{\operatorname{argmin}} (\|\mathbf{Y}_1 - \mathbf{D}_1 \mathbf{X}\|_F^2 + \|\mathbf{Y}_2 - \mathbf{D}_2 \mathbf{X}\|_F^2 + \dots + \|\mathbf{Y}_k - \mathbf{D}_k \mathbf{X}\|_F^2 + \beta \|\mathbf{X}\|_F^2), \quad (1)$$

式中:  $[\mathbf{Y}_1, \mathbf{Y}_2, \dots, \mathbf{Y}_i, \dots, \mathbf{Y}_k]$  表示训练样本集,共含  $k$  个不同分辨率下  $k$  个样本子集;  $\mathbf{Y}_i = [y_i^{(1)}, y_i^{(2)}, \dots, y_i^{(s)}, \dots, y_i^{(p)}] \in \mathbb{R}^{n \times p}$  表示第  $i$  个分辨率下的样本子集,训练样本个数为  $p$ ,  $y_i^{(s)}$  表示第  $i$  个分辨率下的第  $s$  个训练样本;  $[\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_i, \dots, \mathbf{D}_k]$  表示  $k$  个不同分辨率下的字典,  $\mathbf{D}_i = [d_i^{(1)}, d_i^{(2)}, \dots, d_i^{(j)}, \dots, d_i^{(m)}] \in \mathbb{R}^{n \times m}$  表示第  $i$  个分辨率下的字典,  $d_i^{(j)}$  表示第  $i$  个分辨率下字典中第  $j$  个字典原子;  $\mathbf{X} = [x^{(1)}, x^{(2)}, \dots, x^{(s)}, \dots, x^{(p)}] \in \mathbb{R}^{m \times p}$  表示  $p$  个训练样本的编码系数,  $x^{(s)}$  是第  $s$  个训练样本  $y_i^{(s)}$  的编码系数;  $\beta$  为编码系数惩罚参数。其中,前面  $k$  项表示  $k$  个分辨率下的误差重构项,最后一项为编码系数约束正则项。文献<sup>[19]</sup>中作者认为,图像分辨率虽然存在一定的差异,但对于分类识别来说,学习的图像特征不会因为分辨率不同而存在差异,故需假设不同分辨率下同一个人的脸

图像表示系数尽可能保持一致,即  $\mathbf{Y}_i = \mathbf{D}_i \mathbf{X}$ 。由(1)式可知,MRDL 算法虽在不同分辨率的训练样本中学习了多分辨率字典,但其目标函数仍然主要关注不同分辨率下学习字典的重构性能,故学习字典对多分辨率图像具有很好的重构性能。但是该算法仍然存在以下两个方面的问题:1)对于人脸识别而言,最适合的重构特征并不一定最有利于识别任务;2)受多分辨率的影响,人脸图像的类内特征差异可能大于类间特征差异,若仅仅设定不同分辨率下图像的编码系数完全相同,则编码时可能会出现一定程度的混淆。针对上述问题,本文提出一种 MDL DLC 算法,该算法能够有效提升多分辨率下学习字典的判别性能,如图 1 所示。

### 2.2 字典原子与轮廓向量

在多分辨率字典学习中,不同分辨率下训练样本可表示为不同分辨率下字典中原子的线性组合



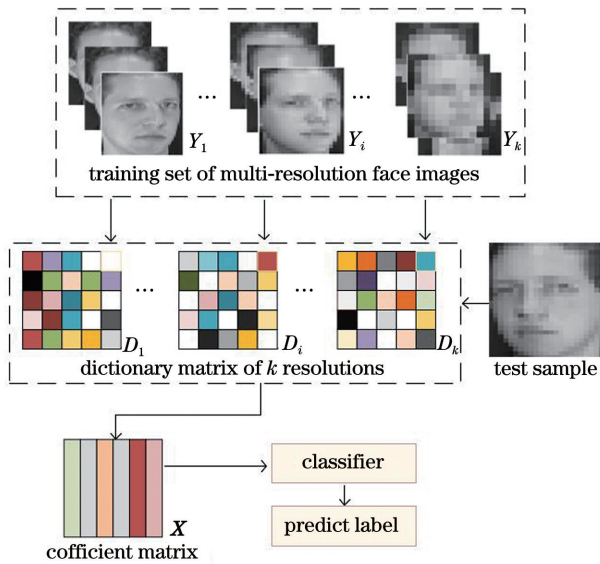


图 1 MDL DLC 算法流程图

Fig. 1 MDL DLC algorithm flow chart

$Y_i = D_i X$ , 其中,  $D_i (i = 1, 2, \dots, k)$  为第  $i$  个分辨率下的字典, 字典中的列向量  $d_i^{(j)} (j = 1, 2, \dots, m)$  则称为字典原子。文献[21]将编码系数矩阵  $X$  的行向量定义为字典原子的轮廓向量  $\hat{x}^{(j)} (j = 1, 2, \dots, m)$ , 与字典原子一一对应, 它可以衡量字典原子  $d_i^{(j)}$  重构所有训练样本的贡献度, 如图 2 所示。




图 2 字典原子与轮廓向量的对应关系

Fig. 2 Correspondence between dictionary atom and profile vector

### 3 带判别性局部结构约束的多分辨率字典学习算法

诸多相关工作都证明训练样本中潜在的局部结构可以用来提升算法的分类性能。LLC 算法<sup>[12]</sup>利用训练样本与原子之间的距离来约束编码系数的平滑性, 以确保相似样本具有相似的编码系数, 如图 3(a)所示。LCLE-DL 算法<sup>[15]</sup>则直接采用字典原子构造拉普拉斯矩阵, 实现局部结构的编码, 但编码的局部结构不具备判别性, 如图 3(b)所示。与上述两类算法的不同在于: 本文提出的 MDL DLC 算法是基于不同分辨率字典下的类内原子与类间原子, 更进一步地编码了局部结构的类内相似性与类间差

异性, 从而获得带判别性的局部结构, 如图 3(c)所示。




图 3 LLC, LCLE-DL 及 MDL DLC 算法的对比分析。

(a) LLC 算法; (b) LCLE-DL 算法; (c) 本文提出的 MDL DLC 算法

Fig. 3 Comparative analysis of LLC, LCLE-DL and MDL DLC algorithms. (a) LLC algorithm; (b) LCLE-DL algorithm; (c) proposed MDL DLC algorithm

#### 3.1 基于同类字典原子构造类内局部约束项

$d_i^{(a)}$  与  $d_i^{(b)}$  ( $a, b \in [1, 2, \dots, m]$ ) 分别表示第  $i$  个分辨率下字典  $D_i$  中第  $a$  个与第  $b$  个原子的坐标,  $l_i^{(a)}$  与  $l_i^{(b)}$  分别表示原子  $d_i^{(a)}$  与  $d_i^{(b)}$  的类标, 若  $l_i^{(a)} = l_i^{(b)}$  时, 说明原子  $d_i^{(a)}$  与  $d_i^{(b)}$  属于同一类。本文基于同类字典原子的局部几何结构, 构造轮廓向量的类内局部约束项, 即

$$\min \frac{1}{2} \sum_{a=1}^m \sum_{b=1}^m (\hat{x}^{(a)} - \hat{x}^{(b)})^2 \omega_{ab}, \quad (2)$$

其中,  $\hat{x}^{(a)}$  与  $\hat{x}^{(b)}$  分别表示  $d_i^{(a)}$  与  $d_i^{(b)}$  对应的轮廓向量,  $\omega_{ab}$  为权值矩阵元, 表达式为

$$\omega_{ab} = \begin{cases} \|d_i^{(a)} - d_i^{(b)}\|, & d_i^{(b)} \notin \text{KNN}(d_i^{(a)}) \\ \exp\left(-\frac{\|d_i^{(a)} - d_i^{(b)}\|}{\sigma}\right), & d_i^{(b)} \in \text{KNN}(d_i^{(a)}) \end{cases}, \quad (3)$$

式中  $\text{KNN}(\cdot)$  为  $k$  近邻, 代表一个样本附近的  $k$  个最近 (即特征空间中最邻近) 样本。由 (3) 式可知, 若两个原子的相似程度低, 则  $\omega_{ab}$  值较大, 优化 (2) 式可以确保  $\hat{x}^{(a)}$  与  $\hat{x}^{(b)}$  保持较高的相似性。反之, 若两个原子相似程度高, 则  $\|d_i^{(a)} - d_i^{(b)}\|$  值较小。由于同类原子编码系数需尽可能接近, 故设置  $\exp\left(-\frac{\|d_i^{(a)} - d_i^{(b)}\|}{\sigma}\right)$  使  $\omega_{ab}$  保持一个较大值, 以此方式来保证  $\hat{x}^{(a)}$  与  $\hat{x}^{(b)}$  具有较高的相似性。由此可知, 在多分辨率字典中,  $\omega_{ab}$  能控制同类原子对应的轮廓向量的类内相似性。

#### 3.2 基于非同类字典原子构造类间局部约束项

若  $l_i^{(a)} \neq l_i^{(b)}$  时, 说明原子  $d_i^{(a)}$  与  $d_i^{(b)}$  属于不同类别的字典原子。本节基于非同类字典原子的局部几何结构, 构造轮廓向量的类间局部约束项, 即

$$\min \frac{1}{2} \sum_{a=1}^m \sum_{b=1}^m (\hat{\mathbf{x}}^{(a)} - \hat{\mathbf{x}}^{(b)})^2 v_{ab}, \quad (4)$$

$$v_{ab} = \begin{cases} 0, & \|\mathbf{d}_i^{(a)} - \mathbf{d}_i^{(b)}\| \geq \theta \\ \max(\|\mathbf{d}_i^{(a)} - \mathbf{d}_i^{(b)}\| - \theta, -\|\mathbf{d}_i^{(a)} - \mathbf{d}_i^{(b)}\|), & \|\mathbf{d}_i^{(a)} - \mathbf{d}_i^{(b)}\| < \theta \end{cases}, \quad (5)$$

其中,  $\theta$  表示  $\mathbf{d}_i^{(a)}$  与  $\mathbf{d}_i^{(b)}$  分别对应的不同类别字典的中心距离。若  $\|\mathbf{d}_i^{(a)} - \mathbf{d}_i^{(b)}\| \geq \theta$ , 说明两个原子之间的距离大于两个类别的中心距离, 无需约束  $\hat{\mathbf{x}}^{(a)}$  与  $\hat{\mathbf{x}}^{(b)}$  之间的距离, 即  $v_{ab} = 0$ 。反之, 若  $\|\mathbf{d}_i^{(a)} - \mathbf{d}_i^{(b)}\| < \theta$ , 说明两个原子之间的距离小于两个类别中心的距离, 利用  $(\|\mathbf{d}_i^{(a)} - \mathbf{d}_i^{(b)}\| - \theta, -\|\mathbf{d}_i^{(a)} - \mathbf{d}_i^{(b)}\|)$  中的较大数促使  $\hat{\mathbf{x}}^{(a)}$  与  $\hat{\mathbf{x}}^{(b)}$  保持较大差异, 以避免不同类别的轮廓向量出现相似度高的现象。

结合(2)式和(4)式, 将构造的类内局部约束项与类间局部约束项统一在同一正则项中, 表达式为

$$\min \frac{1}{2} \sum_{a=1}^m \sum_{b=1}^m \left[ \eta_{a,b} (\hat{\mathbf{x}}^{(a)} - \hat{\mathbf{x}}^{(b)})^2 \omega_{ab} + (1 - \eta_{a,b}) (\hat{\mathbf{x}}^{(a)} - \hat{\mathbf{x}}^{(b)})^2 v_{ab} \right], \quad (6)$$

其中,  $\eta_{a,b} = \begin{cases} 1, & \text{if } l_i^{(a)} \neq l_i^{(b)} \\ 0, & \text{else} \end{cases}$ , (6)式可重新写为

$$\min \frac{1}{2} \sum_{a=1}^m \sum_{b=1}^m S_{a,b} (\hat{\mathbf{x}}^{(a)} - \hat{\mathbf{x}}^{(b)})^2, \quad (7)$$

其中,  $S_{a,b} = \begin{cases} \omega_{ab}, & \text{if } l_i^{(a)} \neq l_i^{(b)} \\ v_{ab}, & \text{else} \end{cases}$ ,  $S_{a,b}$  构成的矩阵定义为  $\mathbf{S} \in \mathbb{R}^{m \times m}$ 。

基于(7)式, 构造拉普拉斯矩阵, 表达式为

$$\mathbf{L}_S = \mathbf{P} - \mathbf{S}, \quad \mathbf{P} = \text{diag}(p_1, p_2, \dots, p_m), \quad (8)$$

$$p_a = \sum_{b=1}^m S_{a,b},$$

将(7)式转化为矩阵形式, 可表示为

$$\min \text{tr}(\mathbf{X}^T \mathbf{L}_S \mathbf{X}), \quad (9)$$

式中  $\text{diag}(\cdot)$  和  $\text{tr}(\cdot)$  分别表示对角矩阵和矩阵的迹。

### 3.3 MDL DLC 模型构建

针对面向多分辨率图像的字典学习方法存在不同分辨率下字典判别性不强的问题, 本研究结合字典原子的局部几何结构与类标信息, 提出一种 MDL DLC 算法。该算法联合优化了编码系数局部结构的类内相似性与类间差异性, 其模型定义如下:

$$\langle \mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_k, \mathbf{X} \rangle = \underset{\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_k, \mathbf{X}}{\text{argmin}} \left[ \|\mathbf{Y}_1 - \mathbf{D}_1 \mathbf{X}\|_F^2 + \|\mathbf{Y}_2 - \mathbf{D}_2 \mathbf{X}\|_F^2 + \dots + \|\mathbf{Y}_k - \mathbf{D}_k \mathbf{X}\|_F^2 + \beta \|\mathbf{X}\|_F^2 + \alpha \cdot \text{tr}(\mathbf{X}^T \mathbf{L}_S \mathbf{X}) \right], \quad (10)$$

式中  $\alpha$  为局部约束项惩罚参数。

由(10)式可知, 本文所提模型与 MRDL 算法<sup>[19]</sup>的不同之处在于: 基于多分辨率字典的类内原子与类间原子, 分别构造了轮廓向量的类内局部约束项与类间局部约束项, 并将两个约束项统一在同一个正则项中进行了联合优化。优化(10)式不仅可以实现样本局部结构的编码, 而且能促使同类样本具有相似的局部几何结构, 非同类样本具有不同的局部几何结构, 从而保持判别性局部

结构, 极大地提升不同分辨率下学习字典的判别性能。

### 3.4 模型优化

(10)式是一个组合优化问题, 本研究采用交替迭代方法进行求解, 其具体步骤如下:

1) 更新拉普拉斯矩阵  $\mathbf{L}_S$ 。固定字典  $\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_k$ , 利用(8)式更新  $\mathbf{L}_S$ 。

2) 更新编码系数  $\mathbf{X}$ 。固定拉普拉斯矩阵  $\mathbf{L}_S$  与字典  $\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_k$ , 则(10)式可转化为

$$\mathbf{X}^* = \underset{\mathbf{X}}{\text{argmin}} \left[ \|\mathbf{Y}_1 - \mathbf{D}_1 \mathbf{X}\|_F^2 + \|\mathbf{Y}_2 - \mathbf{D}_2 \mathbf{X}\|_F^2 + \dots + \|\mathbf{Y}_k - \mathbf{D}_k \mathbf{X}\|_F^2 + \beta \|\mathbf{X}\|_F^2 + \alpha \cdot \text{tr}(\mathbf{X}^T \mathbf{L}_S \mathbf{X}) \right], \quad (11)$$

基于梯度下降法<sup>[22]</sup>可获得(11)式的闭式解, 即

$$\mathbf{X}^* = (\mathbf{D}_1^T \mathbf{Y}_1 + \mathbf{D}_2^T \mathbf{Y}_2 + \dots + \mathbf{D}_k^T \mathbf{Y}_k) (\mathbf{D}_1^T \mathbf{D}_1 + \mathbf{D}_2^T \mathbf{D}_2 + \dots + \mathbf{D}_k^T \mathbf{D}_k + \beta \mathbf{I} + \alpha \mathbf{L}_S)^{-1}. \quad (12)$$

3) 更新字典  $\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_k$ 。固定拉普拉斯矩阵  $\mathbf{L}_S$  与编码系数  $\mathbf{X}$ , (10)式可转化为

$$\langle \mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_k \rangle = \underset{\mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_k}{\text{argmin}} (\|\mathbf{Y}_1 - \mathbf{D}_1 \mathbf{X}\|_F^2 + \|\mathbf{Y}_2 - \mathbf{D}_2 \mathbf{X}\|_F^2 + \dots + \|\mathbf{Y}_k - \mathbf{D}_k \mathbf{X}\|_F^2), \quad (13)$$

同样地,利用梯度下降法求解,(13)式的闭式解可定义为

$$D_i = Y_i X^T (X X^T)^{-1}. \quad (14)$$

因此,MDL DLC 算法的优化求解步骤即训练  $Y = [Y_1, Y_2, \dots, Y_i, \dots, Y_k] \in \mathbb{R}^{n \times k p}$ , 设置参数  $\alpha, \beta$  和迭代次数  $T$ , 根据(8)式迭代优化拉普拉斯矩阵  $L_s$ , 根据(12)式迭代优化编码系数  $X$ , 根据(14)式迭代优化学习字典  $D_i$ , 直至收敛, 输出  $D = [D_1, \dots, D_i, \dots, D_k], X$ .

### 3.5 多分辨率人脸图像识别方法

基于学习的多分辨率字典  $D_1, D_2, \dots, D_k$ , 对测试的人脸图像进行编码, 并利用编码系数进行识别, 其步骤如下:

1) 给定一个测试样本  $y$ , 分别计算它在  $k$  个分辨率学习字典  $D_k$  下的编码系数:

$$\begin{cases} x^{\text{test}_1} = (D_1^T D_1)^{-1} D_1^T y, \\ x^{\text{test}_2} = (D_2^T D_2)^{-1} D_2^T y, \\ \vdots \\ x^{\text{test}_k} = (D_k^T D_k)^{-1} D_k^T y \end{cases}, \quad (15)$$

其中,  $x^{\text{test}_1}, x^{\text{test}_2}, \dots, x^{\text{test}_k}$  是测试样本  $y$  分别在多分辨率学习字典  $D_1, D_2, \dots, D_k$  下对应的编码系数。

2) 计算测试样本  $y$  的编码系数与每一个训练样本的编码系数之间的距离:

$$d_s = \|x^{\text{test}_1} - x^{(1)}\| + \|x^{\text{test}_2} - x^{(2)}\| + \dots + \|x^{\text{test}_k} - x^{(s)}\|, \quad (16)$$

其中,  $x^{(s)}$  是编码系数矩阵  $X$  中的第  $s$  列, 表示第  $s$  个训练样本在不同多分辨率学习字典下的编码系数。

3) 对测试图像  $y$  进行分类: 若测试样本  $y$  与第  $s$  个训练样本的编码系数  $x^{(s)}$  距离较近, 则将  $y$  定义为第  $s$  个训练样本相应的类别, 即识别函数的表达式为

$$R = \underset{s}{\operatorname{argmin}} \{d_s\}, s = 1, 2, \dots, N. \quad (17)$$

式中  $N$  为矩阵列数。

## 4 实验结果及分析

为验证 MDL DLC 算法的性能, 本文在 ORL<sup>[23]</sup> 数据集、Extended Yale B<sup>[24]</sup> 数据集、AR<sup>[25]</sup> 数据集和 PIE<sup>[26]</sup> 数据集上进行实验, 并将其与 D-KSVD<sup>[7]</sup>、LC-KSVD1<sup>[8]</sup>、LC-KSVD2<sup>[8]</sup>、LCLE-DL<sup>[15]</sup>、SLatDPL<sup>[16]</sup>、MRDL<sup>[19]</sup>、ResNet<sup>[27]</sup> 算法进行对比分析。同时, 在每个数据集上分别进行 10 次实验, 取 10 次识别率的平均值作为最终结果。

### 4.1 ORL 数据集及实验结果

ORL 数据集共包含 400 张人脸图像, 分别来自 40 个人, 每个人 10 张人脸图像。每幅图像的初始尺寸为 56 pixel × 46 pixel, 采用文献[28]的金字塔分解方法, 分别构造了分辨率为 28 pixel × 23 pixel 和 14 pixel × 12 pixel 的人脸图像。三种不同分辨率的人脸图像如图 4 所示, 在三种不同分辨率下, 人脸图像的面部表情(睁眼/闭眼, 微笑/无微笑)、面部




图 4 ORL 数据集中三种不同分辨率的人脸图像。(a) 56 pixel × 46 pixel; (b) 28 pixel × 23 pixel; (c) 14 pixel × 12 pixel  
Fig. 4 Face images with different resolutions from the ORL database. (a) 56 pixel × 46 pixel; (b) 28 pixel × 23 pixel; (c) 14 pixel × 12 pixel

细节(戴眼镜/不戴眼镜)、清晰程度与光线条件不同,即使同类图像之间也呈现出相当大的差异。

本研究将 ORL 数据集以 1:1 比例分为训练集与测试集。表 1 给出了不同算法在 ORL 数据集上的识别结果。从表 1 可以看出,在 ORL 数据集上,本文提出的 MDL DLC 算法优于 MRDL 算法

表 1 不同算法在 ORL 数据集上的识别率

Table 1 Recognition rates of different algorithms on the ORL database unit: %

Algorithm	Recognition rate
D-KSVD	86.10±2.63
LCKSVD1	86.52±1.73
LCKSVD2	87.10±2.23
LCLE-DL	90.42±1.56
SLatDPL	90.80±1.04
MRDL	91.75±1.25
ResNet	84.00±1.24
<b>MDL DLC</b>	<b>94.62±0.81</b>

2.87 个百分点,较 D-KSVD、LC-KSVD1、LC-KSVD2、LCLE-DL、SLatDPL、ResNet 算法分别提升了约 8.52 个百分点、8.1 个百分点、7.52 个百分点、4.2 个百分点、3.82 个百分点、10.62 个百分点。

#### 4.2 Extended Yale B 数据集及实验结果

Extended Yale B 数据集是在不同光照条件下拍摄的人脸图像,共有 2414 张,分别来自 38 个人,即每人有 64 张人脸图像。三种不同分辨率分别为 64 pixel×64 pixel、32 pixel×32 pixel、16 pixel×16 pixel,如图 5 所示。

同样地,将 Extended Yale B 数据集以 1:1 比例分为训练集与测试集。表 2 给出了不同算法在具有多个分辨率的 Extended Yale B 数据集上的识别结果,从表 2 可以看出,在 Extended Yale B 数据集上本文提出的 MDL DLC 算法优于 MRDL 算法 3.74 个百分点,较 D-KSVD、LC-KSVD1、LC-KSVD2、LCLE-DL、SLatDPL、ResNet 算法分别提升了约 19.06 个百分点、18.47 个百分点、16.1 个百分点、20.73 个百分点、4.9 个百分点、5.12 个百分点。




图 5 Extended Yale B 数据集中三种不同分辨率的人脸图像。(a) 64 pixel×64 pixel;(b) 32 pixel×32 pixel;(c) 16 pixel×16 pixel

Fig. 5 Face images with different resolutions from the Extended Yale B database. (a) 64 pixel×64 pixel; (b) 32 pixel×32 pixel; (c) 16 pixel×16 pixel

#### 4.3 AR 数据集及实验结果

AR 数据集来自 126 个人,每个人有 26 张人脸图像,这些图像在光照条件、面部表情方面存在不同程度的差异。本节使用该数据库的一个子集,其中包括 120 个人,总共 3120 张图像。三种不同的分辨

率分别为 50 pixel×40 pixel、25 pixel×20 pixel、12 pixel×10 pixel,如图 6 所示。

在 AR 数据集中随机选择 13 张图像作为训练样本,剩下的图像作为测试样本,表 3 为不同算法在多个分辨率 AR 数据集上的识别结果。从表 3 可以



表 2 不同算法在 Extended Yale B 数据集上的识别率

Table 2 Recognition rates of different algorithms on the Extended Yale B database unit: %

Algorithm	Recognition rate
D-KSVD	72.54±1.38
LCKSVD1	73.13±1.24
LCKSVD2	75.50±1.36
LCLE-DL	70.87±1.27
SLatDPL	86.70±1.26
MRDL	87.86±1.43
ResNet	86.48±1.25
<b>MDL DLC</b>	<b>91.60±0.90</b>

表 3 不同算法在 AR 数据集上的识别率

Table 3 Recognition rates of different algorithms on the AR database unit: %

Algorithm	Recognition rate
D-KSVD	66.17±1.23
LCKSVD1	74.73±1.25
LCKSVD2	75.60±1.30
LCLE-DL	71.21±1.23
SLatDPL	84.47±1.45
MRDL	82.36±1.52
ResNet	85.63±1.23
<b>MDL DLC</b>	<b>85.39±1.12</b>




图 6 AR 数据集中三种不同分辨率的人脸图像。(a) 50 pixel×40 pixel;(b) 25 pixel×20 pixel;(c) 12 pixel×10 pixel

Fig. 6 Face images with different resolutions from the AR database. (a) 50 pixel×40 pixel; (b) 25 pixel×20 pixel;

(c) 12 pixel×10 pixel

看出,在 AR 数据集上本文提出的 MDL DLC 算法优于 MRDL 算法 3.03 个百分点,低于 ResNet 算法约 0.24 个百分点,较 D-KSVD、LC-KSVD1、LC-KSVD2、LCLE-DL、SLatDPL 算法分别提升了约 18.21 个百分点、9.65 个百分点、8.78 个百分点、13.17 个百分点、0.92 个百分点。

#### 4.4 PIE 数据集及实验结果

PIE 数据集来自 68 个人,包含 13 种不同姿势、43 种不同的光照条件,以及 4 种不同面部表情下的人脸图像。本节选择第 5 种姿势下不同的面部图像,每个人共有 49 张图像,总共包括 3332 张人脸图像。三种不同分辨率同样分别为 64 pixel×64 pixel、32 pixel×32 pixel、16 pixel×16 pixel,如

图 7 所示。

在 PIE 数据集中随机选择 25 张图像作为训练样本,剩下的图像作为测试样本,表 4 为不同算法在多个分辨率 PIE 数据集上的识别结果。从表 4 可以看出,在 PIE 数据集上本文提出的 MDL DLC 算法优于 MRDL 算法 1.67 个百分点,较 D-KSVD、LC-KSVD1、LC-KSVD2、LCLE-DL、SLatDPL、ResNet 算法分别提升了约 34.85 个百分点、31.44 个百分点、30.96 个百分点、12.94 个百分点、5.59 个百分点、28.16 个百分点。

#### 4.5 实验结果分析

在多个分辨率人脸图像数据集上,将本文提出的 MDL DLC 算法与 D-KSVD、LC-KSVD1、LC-



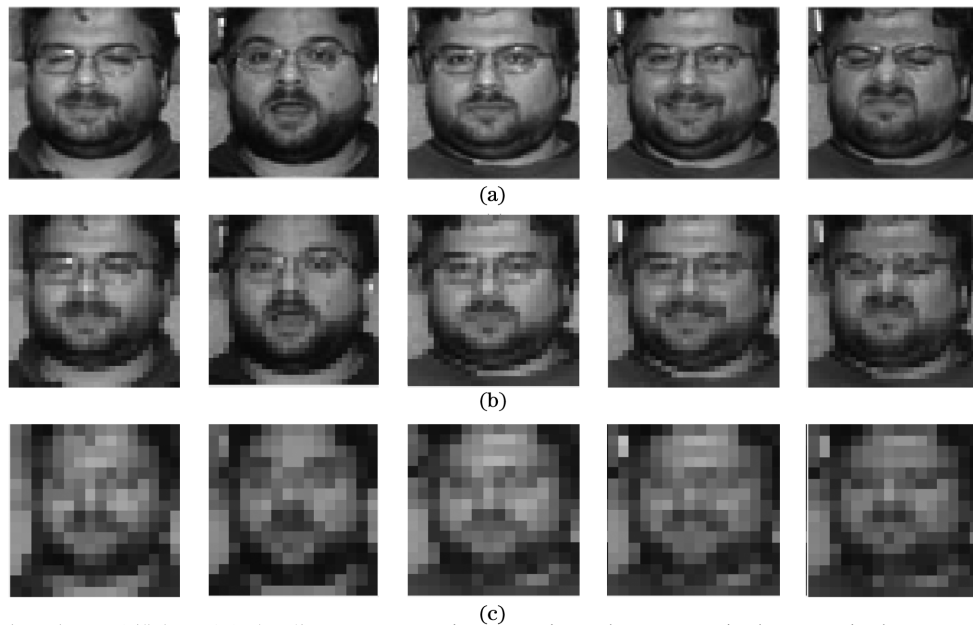


图 7 PIE 数据集中三种不同分辨率的人脸图像。(a) 64 pixel×64 pixel;(b) 32 pixel×32 pixel;(c) 16 pixel×16 pixel

Fig. 7 Face images with different resolutions from PIE database. (a) 64 pixel×64 pixel; (b) 32 pixel×32 pixel;

(c) 16 pixel×16 pixel

表 4 不同算法在 PIE 数据集上的识别率

Table 4 Recognition rates of different algorithms on the PIE database unit: %

Algorithm	Recognition rate
D-KSVD	62.31±0.98
LCKSVD1	65.72±0.90
LCKSVD2	66.20±0.75
LCLE-DL	84.22±0.56
SLatDPL	91.57±0.58
MRDL	95.49±0.45
ResNet	69.00±0.74
<b>MDL DLC</b>	<b>97.16±0.36</b>

KSVD2、LCLE-DL、SLatDPL、MRDL、ResNet 算法进行对比,不同算法在 ORL、Extended Yale B、AR、PIE 数据集上的结果如表 1~4 所示。由 4 个表中结果可知,本文算法在这 4 个多分辨率人脸图像数据集上均获得了较好的识别率。其中 D-KSVD、LC-KSVD1、LC-KSVD2、LCLE-DL、SLatDPL、MRDL、ResNet 算法均为面向单分辨率图像设计的字典学习算法,若将其直接应用于多分辨率人脸图像识别,算法性能将大幅下降。MRDL 算法针对每个分辨率学习了不同的字典,故在多分辨率人脸图像上取得了较好的识别率。与 MRDL 算法相比,本文提出的 MDL DLC 算法面向多分辨图像学习

了判别性更强的字典,取得了最高识别率。其关键在于:MDL DLC 算法基于多分辨率字典的类内原子与类间原子,分别构造了相应的类内局部约束项与类间局部约束项,并将两个约束项统一在同一个框架中进行联合优化,从而确保局部几何结构的编码;有效地优化了编码系数局部结构的类内相似性与类间差异性,从而保持判别性局部结构。该算法极大地提升了不同分辨率下学习字典的判别性能。

#### 4.6 实验参数分析

##### 4.6.1 正则化参数 $\alpha, \beta$ 的影响

与 MRDL 算法相比,本文提出的 MDL DLC 算法中增加了类内局部约束项与类间局部约束项。为得到不同数据集的最优参数,将参数  $\alpha, \beta$  取值范围设置为  $[10^{-2}, 10^{-6}]$ ,步长设置为  $10^{-1}$ 。对某一个参数进行调整时,另一个参数保持不变,最后得到每个数据集所对应的最优参数组合。图 8 给出了 ORL、Extended Yale B、AR 与 PIE 数据集上随着  $\alpha, \beta$  变化,MDL DLC 算法的识别结果。由图 8 可知: $\alpha=10^{-6}, \beta=10^{-2}$  时,本文算法在 ORL 数据集获得最优的识别结果; $\alpha=10^{-5}, \beta=10^{-3}$  时,本文算法在 Extended Yale B 数据集获得最优的识别结果; $\alpha=10^{-3}, \beta=10^{-3}$  时,本文算法 AR 数据集获得最优的识别结果; $\alpha=10^{-3}, \beta=10^{-4}$  时,本文算法在 PIE 数据集获得最优的识别结果。




图 8 参数  $\alpha, \beta$  对不同数据集的影响。(a) ORL 数据集; (b) Extended Yale B 数据集; (c) AR 数据集; (d) PIE 数据集  
 Fig. 8 Effect of parameter selection of  $\alpha$  and  $\beta$  on the different datasets. (a) ORL database; (b) Extended Yale B database; (c) AR database; (d) PIE database

4.6.2 字典原子数目对识别性能的影响

字典原子数目大小会影响 MDLDC 算法的性能,原子数目过大会导致训练时间过长、计算冗余度的影响。由图 9 可知,在 ORL 数据集上字典原子数目设置为 120 时,本文算法可获得最高的识别精度,在 Extended Yale B 数据集上字典原子数目设置为 418 时,本文算法可获得最高的识别精度,在

高,原子数目过小会极大地影响判别性字典的特征学习能力。图 9 给出了 ORL、Extended Yale B、AR 与 PIE 数据集上不同的字典原子数目对识别性能 AR 数据集上字典原子数目设置为 240 时,本文算法可获得最高的识别精度,在 PIE 数据集上字典原子数目设置为 204 时,本文算法可获得最高的识别精度。

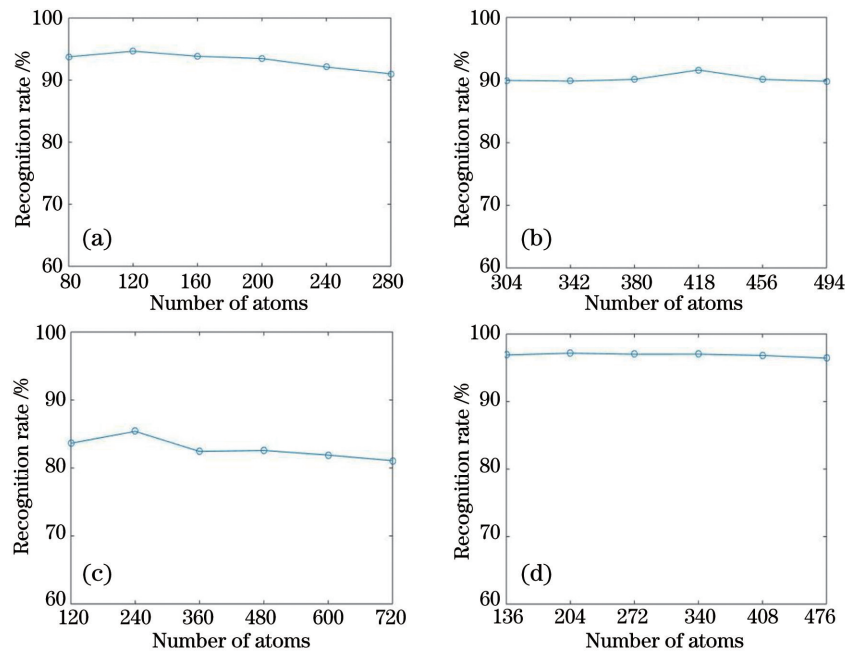


图 9 字典原子数目对不同数据集的影响。(a) ORL 数据集; (b) Extended Yale B 数据集; (c) AR 数据集; (d) PIE 数据集  
 Fig. 9 Effect of number of atoms on the different datasets. (a) ORL database; (b) Extended Yale B database; (c) AR database; (d) PIE database

#### 4.7 复杂度分析

在提出的 MDL DLC 算法中,利用交替迭代优化多分辨率字典  $D_i$ ,并对编码系数  $X$  进行求解,其中  $Y_i \in \mathbb{R}^{n \times p}$ ,  $D_i \in \mathbb{R}^{n \times m}$ ,  $X \in \mathbb{R}^{m \times p}$ 。算法中矩阵的加减和数乘的复杂度可忽略不计,主要考虑矩阵相乘和矩阵求逆的复杂度。因此,每次更新  $X$  时,算法复杂度为  $O(m^3 + mnp + m^2 p)$ ,更新  $D_i$  时所需的算法复杂度为  $O(m^3 + mnp)$ 。

## 5 结 论

针对多分辨率人脸图像识别问题,提出了一种带判别性局部结构约束的多分辨率字典学习算法。该算法结合字典原子的局部几何结构与类标信息,分别构造轮廓向量的类内局部约束项与类间局部约束项,然后将二者统一在同一个正则项中,并进一步增加到字典学习目标函数中进行联合优化,实现了判别性局部结构的编码。这不仅能有效地保证相似样本具有相似的编码系数,更能促使同类样本的编码系数保持相似的局部几何结构,同时使非同类样本的编码系数的局部几何结构差异程度较高。在多个不同多分辨率人脸数据集上的实验结果表明,与同类型字典学习算法相比,本文学习的多分辨率字典具有更强的判别能力,在多分辨率人脸图像上获得了更好的识别性能。

### 参 考 文 献

- [1] Cheng C, Da F P, Wang C X, et al. Pose invariant face recognition using maximum Gabor similarity based on Lucas-Kanade algorithm [J]. Acta Optica Sinica, 2019, 39(7): 0715005.  
程超, 达飞鹏, 王辰星, 等. 基于 Lucas-Kanade 算法的最大 Gabor 相似度大姿态人脸识别 [J]. 光学学报, 2019, 39(7): 0715005.
- [2] Liu F, Li M J, Hu J W, et al. Expression recognition based on low pixel face images [J]. Laser & Optoelectronics Progress, 2020, 57(10): 101008.  
刘芾, 李茂军, 胡建文, 等. 基于低像素人脸图像的表情识别 [J]. 激光与光电子学进展, 2020, 57(10): 101008.
- [3] Chen Y F, Su J B. Sparse embedded dictionary learning on face recognition [J]. Pattern Recognition, 2017, 64: 51-59.
- [4] Cai J X, Feng G C, Tang X, et al. Human action recognition by leaning pose dictionary [J]. Acta Optica Sinica, 2014, 34(12): 1215002.  
蔡加欣, 冯国灿, 汤鑫, 等. 基于姿势字典学习的人
- 体行为识别 [J]. 光学学报, 2014, 34(12): 1215002.
- [5] Li F Y, Huo H T, Li J, et al. Hyperspectral image classification via multiple-feature-based improved sparse representation [J]. Acta Optica Sinica, 2019, 39(5): 0528004.  
李非燕, 霍宏涛, 李静, 等. 基于多特征和改进稀疏表示的高光谱图像分类 [J]. 光学学报, 2019, 39(5): 0528004.
- [6] 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.
- [7] Zhang Q, Li B X. Discriminative K-SVD for dictionary learning in face recognition [C] // 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, June 13-18, 2010, San Francisco, CA, USA. New York: IEEE Press, 2010: 2691-2698.
- [8] Jiang Z L, Lin Z, Davis L S. Label consistent K-SVD: learning a discriminative dictionary for recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(11): 2651-2664.
- [9] Yang M, Zhang L, Feng X C, et al. Fisher discrimination dictionary learning for sparse representation [C] // 2011 International Conference on Computer Vision, November 6-13, 2011, Barcelona, Spain. New York: IEEE Press, 2011: 543-550.
- [10] Gu S, Zhang L, Zuo W, et al. Projective dictionary pair learning for pattern classification [C] // Advances in Neural Information Processing Systems, December 8-13, 2014, Montreal. Canada: Neural Information Processing Systems Foundation, 2014: 793-801.
- [11] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation [J]. Neural Computation, 2003, 15(6): 1373-1396.
- [12] Yu K, Zhang T, Gong Y. Nonlinear learning using local coordinate coding [C] // Advances in Neural Information Processing Systems, December 7-10, 2009, Vancouver, British Columbia. Canada: Neural Information Processing Systems Foundation, 2009: 2223-2231.
- [13] Min H Q, Liang M J, Luo R H, et al. Laplacian regularized locality-constrained coding for image classification [J]. Neurocomputing, 2016, 171: 1486-1495.
- [14] Guo J, Guo Y Q, Li Y, et al. Locality sensitive discriminative dictionary learning [C] // 2015 IEEE International Conference on Image Processing (ICIP), September 27-30, 2015, Quebec City, QC, Canada. New York: IEEE Press, 2015: 1558-1562.

- [15] Li Z M, Lai Z H, Xu Y, et al. A locality-constrained and label embedding dictionary learning algorithm for image classification[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(2): 278-293.
- [16] Zhang Z, Sun Y L, Wang Y, et al. Twin-incoherent self-expressive locality-adaptive latent dictionary pair learning for classification[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 32(3): 947-961.
- [17] Taigman Y, Yang M, Ranzato M, et al. DeepFace: closing the gap to human-level performance in face verification[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE Press, 2014: 1701-1708.
- [18] Sun Y, Wang X G, Tang X O. Deep learning face representation from predicting 10,000 classes[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE Press, 2014: 1891-1898.
- [19] Luo X L, Xu Y, Yang J. Multi-resolution dictionary learning for face recognition[J]. *Pattern Recognition*, 2019, 93: 283-292.
- [20] Zhang Y J, Zheng S J, Zhang X X, et al. Multi-resolution dictionary learning method based on sample expansion and its application in face recognition[J]. *Signal, Image and Video Processing*, 2021, 15(2): 307-313.
- [21] Sadeghi M, Babaie Z M, Jutten C. Learning overcomplete dictionaries based on atom-by-atom updating[J]. *IEEE Transactions on Signal Processing*, 2014, 62(4): 883-891.
- [22] Bottou L. Large-scale machine learning with stochastic gradient descent[C]//Proceedings of COMPSTAT 2010, August 22-27, 2010, Paris, France. [S.l.]: Physica-Verlag HD, 2010: 177-186.
- [23] Samaria F S, Harter A C. Parameterisation of a stochastic model for human face identification[C]//Proceedings of 1994 IEEE Workshop on Applications of Computer Vision, December 5-7, 1994, Sarasota, FL, USA. New York: IEEE Press, 1994: 138-142.
- [24] Georghiadis A S, Belhumeur P N, Kriegman D J. 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.
- [25] Martinez A, Benavente R. The AR face database [R]. Barcelona: Barcelona Computer Vision Center (CVC) Technical, 1998: 24.
- [26] Sim T, Baker S, Bsat M. The CMU pose, illumination, and expression (PIE) database [J]. *Proceedings of Fifth IEEE International Conference on Automatic Face Gesture Recognition*, 2002: 53-58.
- [27] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [28] Adelson E H, Anderson C H, Bergen J R. Pyramid methods in image processing [J]. *RCA Engineer*, 1984, 29(6): 33-41.