

基于多重核的稀疏表示分类

陈思宝^{1,2}, 许立仙^{1,2}, 罗 斌^{1,2}

(1. 安徽大学计算机科学与技术学院, 安徽合肥 230601; 2. 安徽省工业图像处理与分析重点实验室, 安徽合肥 230039)

摘 要: 稀疏表示分类(SRC)及核方法在模式识别的很多问题中都得到了成功的运用. 为了提高其分类精度, 提出多重核稀疏表示及其分类(MKSRC)方法. 提出一种快速求解稀疏系数的优化迭代方法并给出了其收敛到全局最优解的证明. 对于多重核的权重给出了两种自动更新方式并进行了分析与比较. 在不同的人脸图像库上的分类实验显示了所提出的多重核稀疏表示分类的优越性.

关键词: 稀疏表示分类 (SRC); 核方法; 多重核; 核权重; 模式识别

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 0372-2112 (2014)09-1807-05

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2014.09.022

Multiple Kernel Sparse Representation-Based Classification

CHEN Si-bao^{1,2}, XU Li-xian^{1,2}, LUO Bin^{1,2}

(1. School of Computer Science and Technology, Anhui University, Hefei, Anhui 230601, China;

2. Key Laboratory for Industrial Image Processing and Analysis of Anhui Province, Hefei, Anhui 230039, China)

Abstract: Sparse representation based classification (SRC) and kernel methods are applied in many pattern recognition problems. In order to improve the classification accuracy, we propose multiple kernel sparse representation based classification (MK-SRC). A fast optimization iteration method to solve sparse coefficients and the associated convergence proof to global optimal solution are given. In order to update the kernel weights of MKSRC, two different updating methods and the associated comparison are given. The experimental results on three face image databases show the superiority of the proposed multiple kernel sparse representation based classification.

Key words: sparse representation based classification (SRC); kernel method; multiple kernel; kernel weight; pattern recognition

1 引言

在分类问题中,最近邻分类器(Nearest Neighbor, NN)和最近子空间分类器(Nearest Subspace, NS)是一种简单的分类器,它们适用于各种问题.支持向量机(Support Vector Machine, SVM)也是一种分类器,但它们都有一些缺点.NN和NS对数据的局部结构非常地敏感,很容易受到噪声的干扰.SVM通常不像其他的分类器如神经网络那样紧凑.幸运的是,Wright等人将稀疏表示引入人脸识别领域,其假定,当测试样本所在类的训练样本足够多时,测试样本可由这些训练样本线性表出,而其它类的训练样本对重构该测试样本的贡献为0,于是通过估计每类的最小误差而对测试样本分类,从而提出了一种基于稀疏表示的人脸识别分类^[1](Sparse Rep-

resentation-based Classification, SRC).SRC比现有的这些方法更能有效地处理如人脸遮挡、光照和表情变化等问题.

最近,随着核技巧在SVM中的成功运用,涌现出很多基于核的方法,如核主成分分析^[2](Kernel Principal Component Analysis, KPCA)、核Fisher判别分析^[3](Kernel Fisher Discriminant Analysis, KFDA)及核直接线性判别分析^[4](Kernel Direct LDA, KDDA).由于最近邻算法的延伸,核最优化方法^[5~7]被提出.通过选择一种合适的核函数,核最近邻算法的实验结果要比传统的最近邻算法好.类似地,单个核SVM被提出,并介绍了各种改进方案,如建立一个稀疏大边缘分类器^[8]和复杂度降低的分类器的增量构建^[9].

众所周知,如果一个合适的核函数被用于一个测

试样本,在高维空间中,更多的近邻都可能属于同一标签类,这样测试样本就可以更准确的由同一类的训练样本线性表示.从而在高维空间中的稀疏表示可以提高识别率和判别性能.因此,一些基于单核的分类算法被相继提出^[10-12].由于不清楚哪种核函数最适合具体的需要,所以结合几种可能的核函数就很有意义.于是产生了多核稀疏分类算法^[13],并且 Huang H. C. 等人将多核方法应用于聚类问题^[14]中,取得了较好的结果.在多重核的使用中,简单地设置相同的权重可能不是最好的.因此,本文提出了一种基于多重核稀疏表示分类(Multiple Kernel Sparse Representation Based Classification, MKSRC),不仅保证了多重核仍然是 Mercer 核,而且着重解决两个问题:第一,在求稀疏解的过程中,采用一种快速简便的迭代方法;第二,考虑并比较两种不同的核权重更新方式.

2 稀疏表示分类(SRC)及核稀疏表示(KSR)

稀疏表示分类(SRC)用训练样本稀疏线性地表示测试样本,并根据类别线性重构残差最小化进行分类.其主要思想为:对给定的训练样本集 $\mathbf{A} = [\mathbf{x}_{1,1}, \dots, \mathbf{x}_{1,n_1}, \dots, \mathbf{x}_{c,1}, \dots, \mathbf{x}_{c,n_c}] \in \mathbb{R}^{d \times n}$ 的每列进行归一化.其次求解最小 l_1 -范数问题: $\hat{\boldsymbol{\alpha}}_1 = \arg \min_{\boldsymbol{\alpha}} \|\boldsymbol{\alpha}\|_1$, 其中 $\boldsymbol{\alpha}$ 满足 $\mathbf{y} = \mathbf{A}\boldsymbol{\alpha}$ 或 $\|\mathbf{y} - \mathbf{A}\boldsymbol{\alpha}\|_2 \leq \varepsilon$, $\varepsilon > 0$ 是一个可选误差.然后对测试样本 \mathbf{y} 计算每一类的残差 $r_i(\mathbf{y}) = \|\mathbf{y} - \mathbf{A}\boldsymbol{\delta}_i(\hat{\boldsymbol{\alpha}}_1)\|_2^2$, $i = 1, 2, \dots, c$, c 为对象类.这里 $\boldsymbol{\delta}_i(\hat{\boldsymbol{\alpha}}_1)$ 是特征函数,其元素选择与 $\hat{\boldsymbol{\alpha}}_1$ 中第 i 类相关的系数.最后对 \mathbf{y} 进行分类: $I(\mathbf{y}) = \arg \min_i r_i(\mathbf{y})$, 这里 $I(\mathbf{y})$ 表示估计 \mathbf{y} 的类别标签.

在核方法中,映射 φ 将原空间中的数据映射到一个高维核特征空间 π 中,其高维空间中的内积 Mercer 核定义为 $k(\mathbf{y}, \mathbf{y}') = \varphi(\mathbf{y})^T \varphi(\mathbf{y}')$. 待分类样本 \mathbf{y} 在空间 π 中的像为 $\varphi(\mathbf{y}) = [\varphi_1(\mathbf{y}), \varphi_2(\mathbf{y}), \dots, \varphi_D(\mathbf{y})]^T$, $\varphi(\mathbf{y}) \in \mathbb{R}^D$. 训练样本集 \mathbf{A} 在空间 π 中的像是 $\varphi(\mathbf{A}) = [\varphi(\mathbf{x}_{1,1}), \varphi(\mathbf{x}_{1,2}), \dots, \varphi(\mathbf{x}_{c,n_c})]$, 记之为 \mathbf{V} . 于是,在空间 π 中,测试样本的像可以由训练样本的像线性表示,即: $\varphi(\mathbf{y}) = \sum_{i=1}^n \alpha_i \varphi(\mathbf{x}_i) = \mathbf{V}\boldsymbol{\alpha}$. 那么核函数中的稀疏求解问题表示为: $\hat{\boldsymbol{\alpha}} = \arg \min_{\boldsymbol{\alpha}} \|\boldsymbol{\alpha}\|_1$, $\boldsymbol{\alpha}$ 满足 $\varphi(\mathbf{y}) = \mathbf{V}\boldsymbol{\alpha}$. 对该式正则化得 $\hat{\boldsymbol{\alpha}} = \arg \min_{\boldsymbol{\alpha}} \|\varphi(\mathbf{y}) - \mathbf{V}\boldsymbol{\alpha}\|_2^2 + \gamma \|\boldsymbol{\alpha}\|_1$, 其中 γ 是一个参数.由于非线性映射 φ 是未知的,故 $\boldsymbol{\alpha}$ 不能直接得出,但由文献[11]知,其等价成式(1):

$$\hat{\boldsymbol{\alpha}} = \arg \min_{\boldsymbol{\alpha}} \boldsymbol{\alpha}^T \mathbf{V}^T \mathbf{V} \boldsymbol{\alpha} - 2\varphi^T(\mathbf{y}) \mathbf{V} \boldsymbol{\alpha} + \gamma \|\boldsymbol{\alpha}\|_1 \quad (1)$$

这样式(1)就可以用二次规划问题的方法来解决.

3 多重核稀疏表示分类(MKSRC)

3.1 多重核的提出

单核 SRC 也许并不是最适合的核,因此希望结合多种可能的核函数.根据文献[15],给定 M 个定义在 $\mathbb{R}^D \times \mathbb{R}^D$ 上的 Mercer 核函数 $k_m(\cdot, \cdot)$, $m = 1, 2, \dots, M$, 构造如下的多重核函数: $k(\mathbf{x}_i, \mathbf{x}_j) = \sum_{m=1}^M w_m k_m(\mathbf{x}_i, \mathbf{x}_j)$, 其中 w_m 是基核 $k_m(\mathbf{x}_i, \mathbf{x}_j)$ 的权重,并且限制权重满足: $\sum_{m=1}^M w_m^2 = 1$, $w_m > 0$. 显然 $k(\mathbf{x}_i, \mathbf{x}_j)$ 也是定义在 $\mathbb{R}^D \times \mathbb{R}^D$ 上的 Mercer 核.令 Φ 是与多重核函数 $k(\cdot, \cdot)$ 有关的非线性映射,则对于样本 \mathbf{x} 和 \mathbf{y} 成立: $\Phi(\mathbf{x})^T \Phi(\mathbf{y}) = k(\mathbf{x}, \mathbf{y})$, $k(\mathbf{x}, \mathbf{y}) = \sum_{m=1}^M w_m k_m(\mathbf{x}, \mathbf{y})$.

映射 Φ 将原空间中的数据映射到高维多重核空间 π 中,即 \mathbf{y} 在空间 π 中的像为 $\Phi(\mathbf{y}) = [\Phi_1(\mathbf{y}), \Phi_2(\mathbf{y}), \dots, \Phi_D(\mathbf{y})]^T$, 这里 $\Phi(\mathbf{y}) \in \mathbb{R}^D$ 是样本 \mathbf{y} 在特征空间 π 中的像, $D \gg d$ 是 π 的维数.训练样本集 \mathbf{A} 在 π 中的像是 $\Phi(\mathbf{A}) = [\Phi(\mathbf{x}_{1,1}), \Phi(\mathbf{x}_{1,2}), \dots, \Phi(\mathbf{x}_{c,n_c})] \in \mathbb{R}^{D \times n}$, 记之为 \mathbf{U} . 于是,在多重核特征空间 π 中,测试样本的像可以由训练样本的像线性表示,即:

$\Phi(\mathbf{y}) = \sum_{i=1}^n \alpha_i \Phi(\mathbf{x}_i) = \mathbf{U}\boldsymbol{\alpha}$. 那么多重核函数中的稀疏系数求解问题即为:

$$\hat{\boldsymbol{\alpha}} = \arg \min_{\boldsymbol{\alpha}} \|\boldsymbol{\alpha}\|_1, \text{ s.t. } \Phi(\mathbf{y}) = \mathbf{U}\boldsymbol{\alpha} \quad (2)$$

对式(2)进行正则化得:

$$\hat{\boldsymbol{\alpha}} = \arg \min_{\boldsymbol{\alpha}} \|\Phi(\mathbf{y}) - \mathbf{U}\boldsymbol{\alpha}\|_2^2 + \lambda \|\boldsymbol{\alpha}\|_1 \quad (3)$$

其中 λ 是权衡重构误差与重构系数稀疏性的参数.由于直接解决式(3)是不实际的.其原因在于:若 π 已知,式(3)的计算复杂度远远大于原优化问题的求解,且其解不稀疏.若 π 未知,又无法获得样本矩阵 \mathbf{U} . 因此,可以将式(3)转换成一个可以运用基于多重核的维数下降方法的最优问题.

3.2 多重核稀疏表示(MKSR)的迭代求解法

记式(3)中目标函数为 $f(\boldsymbol{\alpha})$, 由于 $\|\boldsymbol{\alpha}\|_1$ 是不可微分的,所以欲求 $\boldsymbol{\alpha}$, 式(3)可以化成如下形式:

$$\min f(\boldsymbol{\alpha}) = \|\Phi(\mathbf{y}) - \mathbf{U}\boldsymbol{\alpha}\|_2^2 + \lambda \sum_{i=1}^n |\alpha_i| \quad (4)$$

此时可构造关于 $\boldsymbol{\alpha}$ 的迭代公式来求得解 $\boldsymbol{\alpha}$. 第 t 步 $\boldsymbol{\alpha}$ 为 $\boldsymbol{\alpha}^{(t)} = [\alpha_1^{(t)}, \dots, \alpha_n^{(t)}]$. 由几何算术平均不等式得:

$$\begin{aligned} f(\boldsymbol{\alpha}) &= \|\Phi(\mathbf{y}) - \mathbf{U}\boldsymbol{\alpha}\|_2^2 + \lambda \sum_{i=1}^n |\alpha_i| \\ &\leq \|\Phi(\mathbf{y}) - \mathbf{U}\boldsymbol{\alpha}\|_2^2 + \lambda \sum_{i=1}^n \frac{\alpha_i^2 + (\alpha_i^{(t)})^2}{2|\alpha_i^{(t)}|} \end{aligned}$$

$$\begin{aligned} \text{即 } f(\boldsymbol{\alpha}) &\leq \|\Phi(\mathbf{y}) - \mathbf{U}\boldsymbol{\alpha}\|_2^2 + \frac{\lambda}{2} \boldsymbol{\alpha}^T (\mathbf{M}^{(t)})^{-2} \boldsymbol{\alpha} \\ &\quad + \frac{\lambda}{2} \sum_{i=1}^n \frac{(\alpha_i^{(t)})^2}{|\alpha_i^{(t)}|} \end{aligned} \quad (5)$$

不妨记式(5)中后者为 $g(\boldsymbol{\alpha})$, 其中, $\mathbf{M}^{(t)} = \text{diag}(\sqrt{|\alpha_1^{(t)}|}, \sqrt{|\alpha_2^{(t)}|}, \dots, \sqrt{|\alpha_n^{(t)}|})$, $\text{diag}(\ast)$ 表示把向量转成对角化矩阵. 欲使 $f(\boldsymbol{\alpha})$ 最小, 只需使得 $g(\boldsymbol{\alpha})$ 最小. 对 $g(\boldsymbol{\alpha})$ 关于 $\boldsymbol{\alpha}$ 求偏微分后等于 0, 得 $\boldsymbol{\alpha} = (\mathbf{U}^T \mathbf{U} + \frac{\lambda}{2} (\mathbf{M}^{(t)})^{-2})^{-1} \mathbf{U}^T \Phi(\mathbf{y})$, 即 $\boldsymbol{\alpha} = \mathbf{M}^{(t)} \cdot \left(\mathbf{M}^{(t)} \cdot \mathbf{U}^T \mathbf{U} \cdot \boldsymbol{\alpha} \mathbf{M}^{(t)} + \frac{\lambda}{2} \mathbf{I}_n \right)^{-1} \cdot \mathbf{M}^{(t)} \cdot \mathbf{U}^T \Phi(\mathbf{y})$. 第 $t+1$ 步 $\boldsymbol{\alpha}$ 为 $\boldsymbol{\alpha}^{(t+1)} = [\alpha_1^{(t+1)}, \dots, \alpha_n^{(t+1)}]$, 于是 $\boldsymbol{\alpha}$ 的迭代求解公式为

$$\boldsymbol{\alpha}^{(t+1)} = \mathbf{M}^{(t)} \cdot \left(\mathbf{M}^{(t)} \cdot \mathbf{U}^T \mathbf{U} \cdot \mathbf{M}^{(t)} + \frac{\lambda}{2} \mathbf{I}_n \right)^{-1} \cdot \mathbf{M}^{(t)} \cdot \mathbf{U}^T \Phi(\mathbf{y}), t = 0, 1, 2, \dots \quad (6)$$

记 $\mathbf{K}_{xx}^{(m)} = \begin{bmatrix} k_m(\mathbf{x}_{1,1}, \mathbf{x}_{1,1}) & k_m(\mathbf{x}_{1,1}, \mathbf{x}_{1,2}) & \dots & k_m(\mathbf{x}_{1,1}, \mathbf{x}_{c,n_c}) \\ k_m(\mathbf{x}_{1,2}, \mathbf{x}_{1,1}) & k_m(\mathbf{x}_{1,2}, \mathbf{x}_{1,2}) & \dots & k_m(\mathbf{x}_{1,2}, \mathbf{x}_{c,n_c}) \\ \vdots & \vdots & \ddots & \vdots \\ k_m(\mathbf{x}_{c,n_c}, \mathbf{x}_{1,1}) & k_m(\mathbf{x}_{c,n_c}, \mathbf{x}_{1,2}) & \dots & k_m(\mathbf{x}_{c,n_c}, \mathbf{x}_{c,n_c}) \end{bmatrix}$,
 $\mathbf{K}_{xy}^{(m)} = \begin{bmatrix} k_m(\mathbf{x}_{1,1}, \mathbf{y}) \\ k_m(\mathbf{x}_{1,2}, \mathbf{y}) \\ \dots \\ k_m(\mathbf{x}_{c,n_c}, \mathbf{y}) \end{bmatrix}$, 其中 $m = 1, 2, \dots, M$, 那么可以验证

$$\mathbf{U}^T \mathbf{U} = \sum_{m=1}^M w_m \mathbf{K}_{xx}^{(m)}, \mathbf{U}^T \Phi(\mathbf{y}) = \sum_{m=1}^M w_m \mathbf{K}_{xy}^{(m)}$$
 且它们均为已知量. 因此只要给定一个非零初始值 $\boldsymbol{\alpha}^0$, 就能通过式(6)迭代求得最佳的 $\boldsymbol{\alpha}$ 值. 理论证明, 由于目标函数是凸函数, 因此由迭代式(6)求得的解收敛到问题(4)的唯一全局最优解. 写成定理形式如下:

定理 1 式(4)中的目标函数 $f(\boldsymbol{\alpha})$ 随着式(6)的每一步迭代而单调下降, 并且式(6)中 $\boldsymbol{\alpha}$ 的极限解为 $f(\boldsymbol{\alpha})$ 的全局最优解.

有关该定理的证明方法类似于文献[16]中的证明方法. 由于篇幅有限, 此处省略详细的证明过程.

3.3 多重核 SRC 分类算法及其核权重分析

在 MKSRC 中, 核权重的更新方式对于算法的识别精度至关重要. 基于全面考虑, 本文给出了两种核权重更新方式并进行了比较.

首先给出第一种权重更新方式. 记与第 m 个核函数相关的残差 $r_m = k_m(\mathbf{y}, \mathbf{y}) - 2\boldsymbol{\alpha}^T \mathbf{K}_{xy}^{(m)} + \boldsymbol{\alpha}^T \mathbf{K}_{xx}^{(m)} \boldsymbol{\alpha}$, 显然 $\|\Phi(\mathbf{y}) - \mathbf{U}\boldsymbol{\alpha}\|_2^2 = \sum_{m=1}^M w_m r_m$. 令 $L = \sum_{m=1}^M w_m r_m + \xi \left(\sum_{m=1}^M w_m^2 - 1 \right)$, 对 L 关于 w_m 求导后等于 0 得 $w_m =$

$$-\frac{1}{2\xi} \cdot r_m, \text{ 结合 } \sum_{m=1}^M w_m^2 = 1 \text{ 得第一种核权重更新公式为}$$

$$w_m = r_m / \sqrt{\sum_{m=1}^M r_m^2} \quad (7)$$

然而在多重核特征空间中, 由于初始值设置等原因, 必然会出现一些较大的残差, 而式(7)中权重与残差成正比, 相应地权系数也会比较大, 于是对目标函数的最优化起着抑制作用, 从而必会影响识别精度的提高. 此时, 重点是关注那些较大的残差. 基于此, 本文提出另一种核权重更新方式, 旨在加强权系数对残差的调节作用, 从而提高识别率, 使算法的性能大大提高.

令 $L = \sum_{m=1}^M \frac{w_m}{r_m} + \xi \left(\sum_{m=1}^M w_m^2 - 1 \right)$, 对 L 关于 w_m 求得 $w_m = -\frac{1}{2\xi} \cdot \frac{1}{r_m}$. 结合 $\sum_{m=1}^M w_m^2 = 1$ 可得第二种核权重更新公式为

$$w_m = \frac{1}{r_m} / \sqrt{\sum_{m=1}^M \frac{1}{r_m^2}} \quad (8)$$

采用这种权重更新公式的原理在于, 权重 w_m 与残差 r_m 是成反比的, 即当某些残差较大时, 权系数就相应地较小, 而当某些残差值又较小时, 相应地权系数就会较大, 这样可以促进目标函数的最优化. 第四部分的实验表明采用式(8)的多重核识别率比式(7)的多重核识别率更好.

相应地多重核稀疏表示的算法如下:

算法 1 基于多重核稀疏表示算法 (MKSRC)

输入: 训练样本集 $\mathbf{A} = [\mathbf{x}_{1,1}, \dots, \mathbf{x}_{1,n_1}, \dots, \mathbf{x}_{c,1}, \dots, \mathbf{x}_{c,n_c}] \in \mathbb{R}^{d \times n}$, c 类共 n 个样本, 测试样本 $\mathbf{y} \in \mathbb{R}^d$.

过程: ① 计算初始权重 $w_m = \frac{1}{\sqrt{M}}$ 和 $k(\mathbf{x}_i, \mathbf{x}_j) = \sum_{m=1}^M w_m k_m(\mathbf{x}_i, \mathbf{x}_j)$;
 ② 由式(6)求解问题 $\hat{\boldsymbol{\alpha}} = \arg \min_{\boldsymbol{\alpha}} \{ \|\Phi(\mathbf{y}) - \mathbf{U}\boldsymbol{\alpha}\|_2^2 + \lambda \|\boldsymbol{\alpha}\|_1 \}$ 的系数;
 ③ 根据权重更新式(7)或(8)更新权重;
 ④ 返回到第②步, 直到满足收敛条件时迭代停止.

输出: 稀疏系数 $\hat{\boldsymbol{\alpha}}$ 和核权重 \mathbf{w} .

综上所述, 对于多重核稀疏表示的分类问题, 根据算法 1 求得稀疏系数之后, 计算每一类残差 $r_i(\mathbf{y}) = \|\Phi(\mathbf{y}) - \mathbf{U}\delta_i(\hat{\boldsymbol{\alpha}})\|_2^2$, 然后对测试样本 \mathbf{y} 进行分类: $I(\mathbf{y}) = \arg \min_i r_i(\mathbf{y})$, 这里 $I(\mathbf{y})$ 表示寻找 \mathbf{y} 的类标签. 采用式(7)和(8)的算法分别简记为 MKSRC1 和 MKSRC2.

4 实验结果与分析

在这一部分, 将在不同的人脸数据库上展现多重核稀疏表示的分类性能. 实验中, 三种单核函数分别是线性核、高斯核和多项式核, 多重核是高斯核与多项式核相结合. 实验中将图像规整至 10×10 , 并且同类实验

中的参数均设置一致.

4.1 ORL 人脸数据库

4.1.1 核权重性能分析

对于两种不同核权重的多重核,本文在第 3.3 节进行了理论分析,这里将给出实验论证.该实验是与多重核相关的两种核权重对其目标函数值以及收敛性的影响情况,仅在 ORL 人脸数据库上进行验证. ORL 数据库包括 40 个人共 400 幅图像,每人 10 幅图像有着不同的装饰或表情变化.所有图像都有相同的背景,且都被标准化为 92×112 . 选取每类前 5 个样本作为训练集,余下的作为测试集.目标函数值随迭代次数变化如图 1 所示.从图 1 可看出,目标函数的收敛性仅仅需要几步迭代过程就可以实现,这说明多重核是有效的.同时, MKSR2 的目标函数值比 MKSR1 的目标函数值要低得多,这就是说, MKSR2 较 MKSR1 的性能更优,同时也保证了核权重更新理论分析的可靠性.

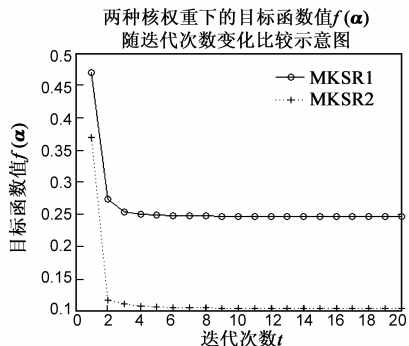


图1 MKSR1和MKSR2对目标函数的收敛性能影响

4.1.2 识别率结果分析

本实验分别选择每类前 4~7 幅图像作为训练集,余下的作为测试集.其实验结果如图 2 所示.




图2 ORL人脸数据库上识别率

图 2 说明,在同等条件下,随着训练样本数量的增多,KSRC 较 SRC 的识别率要高得多, MKSR1 较 SRC 虽有所提高,但其与多项式核是一致的,而 MKSR2 的识别率却是最好的.

4.2 Extended YaleB 人脸数据库

Extended YaleB 人脸数据库包含 38 个人共 2414 幅图片.其中的姿态和光照变化的图像都是在严格控制

的条件下采集的.本文按照文献[17]的方法将 Extended YaleB 库分成 5 个子库,分别为 subfea1、subfea2、subfea3、subfea4 和 subfea5,其中 subfea1 中的图像光照强度正常,而 subfea2、subfea3、subfea4 和 subfea5 的光照强度依次减弱.选择 subfea1 作为训练集,余下的作为测试集.其实验结果如表 1 所示.

表 1 Extended YaleB 人脸数据库上识别率

	SRC	KSRC (Gauss)	KSRC (Polynomial)	MKSRC1	MKSRC2
Subfea2	91.39%	93.6%	93.38%	93.38%	94.7%
Subfea3	75.77%	71.37%	74.23%	74.01%	76.21%
Subfea4	39.39%	47.99%	46.65%	46.65%	48.76%
Subfea5	13.79%	19.22%	17.69%	17.83%	20.33%

由表 1 可得,总体上,核 SRC 较 SRC 的识别率更高, MKSR1 与多项式核识别率基本一致,但 MKSR2 具有更高的识别性能.

4.3 PIE 人脸数据库

PIE 人脸数据库提供了不同姿态、光照、表情条件下 68 位志愿者的 40000 多幅不同的图像,每一幅图像都是在严格控制条件下采集的.本文只在其中一个子集共 17000 幅图像上进行测试,即在数据库中随机提取出 68 个人每人 25 幅图像作为 PIE 子库.实验中选择 PIE 子库中每类前 5, 10, 15, 20 幅图像作为训练集,余下的作为测试集,则该训练集构成的过完备字典的大小分别为 $100 \times 340, 100 \times 680, 100 \times 1020, 100 \times 1360$. 不同训练样本数量下的实验结果如图 3 所示.图 3 表明, MKSR2 的识别性能更高.




图3 PIE人脸数据库上识别率

5 结束语

本文在 SRC 的基础上提出了多重核稀疏表示分类 (MKSR).在处理高维数据上,KSRC 比 SRC 能表现出更好地性能.然而 KSRC 没有充分利用核函数所包含的信息,而本文提出的多重核稀疏表示分类却很好的体现了这一点.多重核在稀疏系数的求解上,采用的是一种简便的迭代求解公式;在核权重上,不仅令其可以自动更新,而且给出了两种不同的核权重更新方式并进行了比较.在包含不同姿态、光照强度、表情的人脸数

数据库上, MKSRC1 和 MKSRC2 较 SRC 的识别率均大大提高, 但 MKSRC2 能表现出最佳的识别性能. 由于核函数参数的选择以及多重核函数中核函数的个数对于识别率影响较大, 因此, 在将来进一步的研究中, 选择合适的核参数将显得至关重要.

参考文献

- [1] J Wright, A Y Yang, A Ganesh, S S Sastry, Yi Ma. Robust face recognition via sparse representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(2): 210 – 227.
- [2] B Scölkopf, A Smola, K R Müller. Nonlinear component analysis as a kernel eigenvalue problem[J]. Neural Computation, 1998, 10(5): 1299 – 1319.
- [3] Sebastian Mika, Gunnar Ratsch, Jason Weston, Bernhard Scholkopf, Klaus-Robert Muller. Fisher discriminant analysis with kernels[A]. Proceedings of the 1999 IEEE Signal Processing Society Workshop on Neural Networks for Signal Processing IX [C]. New York: IEEE Signal Processing Society, 1999. 41 – 48.
- [4] J Lu, K N Plataniotis, A N Venetsanopoulos. Face recognition using kernel direct discriminant analysis algorithms[J]. IEEE Transactions on Neural Networks, 2003, 14(1): 117 – 126.
- [5] Andreas Argyriou, Raphael Hauser, Charles A Micchelli, Massimiliano Pontil. A DC-programming algorithm for kernel selection[A]. William Cohen. Proceedings of the 23rd International Conference on Machine Learning[C]. New York: ACM, 2006. 41 – 48.
- [6] John Shawe-Taylor, Nello Cristianini. Kernel Methods for Pattern Analysis [M]. United Kingdom: Cambridge University Press, 2004. 25 – 45.
- [7] Qiang Wu, Yiming Ying, Ding-Xuan Zhou. Multi-kernel regularized classifiers[J]. Journal of Complexity, 2007, 23(1): 108 – 134.
- [8] M Wu, B Scölkopf, G Balr. A direct method for building sparse kernel learning algorithms[J]. The Journal of Machine Learning Research, 2006, 7(4): 603 – 624.
- [9] Andreas Argyriou, Charles A Micchelli, Massimiliano Pontil. Learning Convex Combinations of Continuously Parameterized Basic Kernels[M]. Berlin Heidelberg: Springer, 2005. 338 – 352.
- [10] Jun Yin, Zhonghua Liu, Zhong Jin, Wankou Yang. Kernel sparse representation based classification[J]. Neurocomputing, 2012, 77(1): 120 – 128.
- [11] Li Zhang, Wei-Da Zhou, Pei-Chann Chang, Jing Liu, Zhe Yan, Ting Wang, Fan-Zhang Li. Kernel sparse representation-based classifier[J]. IEEE Transactions on Signal Processing,

2012, 60(4): 1684 – 1695.

- [12] Shenghua Gao, Ivor Wai-Hung Tsang, Liang-Tien Chia. Sparse representation with kernels[J]. IEEE Transactions on Image Processing, 2013, 22(2): 423 – 434.
- [13] Hao Zheng, Fan Liu, Zhong Jin. Multiple kernel sparse representation based classification[A]. Chen-Lin Liu. Chinese Conference on Pattern Recognition (CCPR) [C]. Berlin Heidelberg: Springer CCIS, 2012. 48 – 55.
- [14] Hsin-Chien Huang, Yung-Yu Chuang, Chu-Song Chen. Multiple kernel fuzzy clustering[J]. IEEE Transactions on Fuzzy Systems, 2012, 20(1): 120 – 134.
- [15] Gert R G Lanckriet, Nello Cristianini, Peter Bartlett, Laurent El Ghaoui, Michael I Jordan. Learning the kernel matrix with semidefinite programming[J]. The Journal of Machine Learning Research, 2004, 5(1): 27 – 72.
- [16] Feiping Nie, Heng Huang, Xiao Cai, Chris Ding. Efficient and robust feature selection via joint $\ell_2, 1$ -norms minimization [A]. Neural Information Processing Systems (NIPS) [C]. Cambridge: MIT Press, 2010. 1813 – 1821.
- [17] Imran Naseem, Roberto Togneri, Mohammed Bennamoun. Linear regression for face recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(11): 2106 – 2112.

作者简介



陈思宝 男, 1979年8月出生于安徽天长, 2000年毕业于安徽大学概率统计专业获理学学士学位, 2003年毕业于安徽大学数理统计专业获理学硕士学位, 2006年毕业于安徽大学计算机应用技术专业获工学博士学位, 2008年从中国科学技术大学信号与信息处理专业博士后出站. 现为安徽大学副教授, 硕士生导师, 目前从事图像处理与模式识别方面的研究.

E-mail: sbchen@ahu.edu.cn



许立仙 女, 1989年7月出生于安徽池州, 2013年毕业于安徽大学数学与应用数学专业获理学学士学位. 现为安徽大学计算机技术专业硕士研究生, 主要从事图像处理与模式识别方面的研究.

E-mail: ahu2009xlx@163.com

罗斌 男, 1963年5月出生于安徽合肥, 现为安徽大学计算机应用技术系博士生导师, 主要从事计算机视觉与模式识别方面的研究.