

基于 Gabor 多通道加权优化与稀疏表征的人脸识别方法

杨清山 郭成安* 金明录

(大连理工大学信息与通信工程学院 大连 116023)

摘要: 稀疏表征理论在模式识别中的应用引起广泛的关注。在用稀疏表征方法研究人脸识别问题中, 为了使得表征系数矢量具有更为显著的稀疏性, 该文提出一种 Gabor 稀疏表征分类(Gabor Sparse Representation Classification, GSRC)算法, 该算法利用 Gabor 局部特征构造字典, 增强算法对外界环境变化的鲁棒性。GSRC 算法对所有的 Gabor 特征同等对待, 通过进一步考虑不同 Gabor 特征对识别的不同贡献, 该文提出了一种加权多通道 Gabor 稀疏表征分类(WMC-GSRC)算法, 该算法通过引入 Gabor 多通道模型, 提取不同通道的 Gabor 特征分别构造字典和稀疏表征分类器, 在决策级执行分类器的加权融合得到识别结果。通过在 ORL, AR 和 FERET 人脸库上的实验结果验证了该文算法的有效性。

关键词: 人脸识别; 稀疏表征; Gabor 局部特征; 字典; 分类器融合

中图分类号: TP391.41

文献标识码: A

文章编号: 1009-5896(2011)07-1618-07

DOI: 10.3724/SP.J.1146.2010.01280

Face Recognition Based on Gabor Multi-channel Weighted Optimization and Sparse Representation

Yang Qing-shan Guo Cheng-an Jin Ming-lu

(School of Information and Communication Engineering, Dalian University of Technology, Dalian 116023, China)

Abstract: Very recently, the sparse representation theory in pattern recognition arouses widespread concern. In this paper, the sparse representation-based face recognition algorithms are studied. In order to make the representation coefficient vector sparser, a Gabor Sparse Representation Classification (GSRC) algorithm is presented, which uses the Gabor local feature to construct dictionary to enhance the robustness for the external environment changes. GSRC algorithm equally treats all the Gabor features, while in consideration that different Gabor features distinctively contribute to the face recognition task, a Weighted Multi-Channel Gabor Sparse Representation Classification (WMC-GSRC) algorithm is further proposed. By introducing the Gabor multi-channel model, WMC-GSRC algorithm extracts Gabor features in different channels to construct dictionaries and sparse representation classifiers, and obtains the final classification result by performing the weighting fusion of classifiers. Experimental results given in the paper on the ORL, AR and FERET face databases show the feasibility and effectiveness of the proposed methods.

Key words: Face recognition; Sparse representation; Gabor local feature; Dictionary; Classifier fusion

1 引言

最近, 稀疏表征理论在机器学习中的应用引起了广泛的研究兴趣, 例如 Wright 等人^[1]提出了一种基于稀疏表征的人脸识别方法。在该方法中, 作者应用了 Eigenface, Randomface 及 Fisherface 等基于整体的特征提取方法提取人脸图像的特征并构造字典, 在训练样本足够多的条件下得出只要特征的维数足够大, 稀疏表征分类器对特征类型不敏感这一结论。然而当训练样本数较少时, 特征的选择将变得更加重要。基于整体的特征由于易受光照、表情、

姿态等因素的影响而产生复杂的变形^[2], 这通常导致待测图像与同类训练图像之间的线性相关性遭到破坏, 因此在对待测图像进行稀疏编码时, 所得到的表征系数矢量中非零元素将可能对应多个类别的训练图像, 显然不利于正确的分类。考虑到 Gabor 局部特征对光照、表情、姿态等具有更强的鲁棒性^[2], 本文引入 Gabor 局部特征构造字典, 提出一种 Gabor 稀疏表征分类(Gabor Sparse Representation Classification, GSRC)算法。该算法和文献[1]中的稀疏表征分类(Sparse Representation Classification, SRC)算法相比, 在稀疏编码阶段, 表征系数矢量具有更为显著的稀疏性, 从而有利于提高识别率。

GSRC 算法在特征提取阶段, 首先采用 5 个不

2010-11-19 收到, 2011-04-06 改回

国家自然科学基金(60871046)资助课题

*通信作者: 郭成安 cguo@dlut.edu.cn

同尺度和 8 个不同方向的 Gabor 核函数对人脸图像进行 2 维滤波处理^[3], 然后将滤波结果的幅值部分串接起来构成一个特征矢量, 在串接过程中, 对不同 Gabor 核函数与人脸图像的滤波结果同等对待。对于图像的 Gabor 滤波处理, 文献[4]通过实验表明, 不同尺度和方向的 Gabor 核函数所提取的特征具有不同的识别性能。本文在 GSRC 算法的基础上, 通过进一步考虑不同 Gabor 特征对识别任务的不同贡献, 提出了一种加权多通道 Gabor 稀疏表征分类 (Weighted Multi-Channel Gabor Sparse Representation Classification, WMC-GSRC) 算法。WMC-GSRC 算法首先对 Gabor 滤波器组进行划分, 并将每个分组看作一个独立通道, 对每个通道, 利用该通道上 Gabor 滤波器所提取的 Gabor 特征分别构造字典和稀疏表征分类器。在决策级融合时, 根据不同通道的特征在分类鉴别能力上的不同, 采用加权融合策略, 给鉴别力较强的通道赋予较大的权值, 而对鉴别力较弱的通道则赋予较小的权值, 以此来优化组合。与 GSRC 算法相比, WMC-GSRC 算法对不同的 Gabor 特征进行了区分对待, 对其中鉴别力强的特征进行强化, 同时也弱化了那些对识别贡献并不显著的特征, 因此 WMC-GSRC 算法可能进一步提高识别率。

本文后面的内容安排如下: 第 2 节给出多通道 Gabor 特征的提取方法。第 3 节详细阐述基于 Gabor 多通道加权优化与稀疏表征的人脸识别方法。第 4 节给出在 ORL, AR 和 FERET 人脸库上的实验结果, 分析验证本文方法的有效性。第 5 节对全文进行总结。

2 多通道 Gabor 特征提取

对人脸图像进行 Gabor 滤波处理, 不仅能够增强人脸中的一些关键特征, 并且对图像的局部形变具有较好的鲁棒性, 因此在人脸识别中得到了成功的应用。本文使用的 Gabor 滤波器如式(1)所示^[4]。

$$\psi_{\mu,v}(z) = \frac{\|k_{\mu,v}\|^2}{\sigma^2} e^{-\frac{\|k_{\mu,v}\|^2 \|z\|^2}{2\sigma^2}} [e^{jk_{\mu,v} \cdot z} - e^{-\sigma^2/2}] \quad (1)$$

其中 $z = (x, y)$; $\|\cdot\|$ 表示范数运算; $k_{\mu,v} = k_v e^{j\phi_\mu}$, $k_v = k_{\max}/f^v$, $\phi_\mu = \pi\mu/8$, $\sigma = 2\pi$, $k_{\max} = \pi/2$, $f = \sqrt{2}$, μ 和 v 分别表示 Gabor 滤波器的方向和尺度。本文采用 5 个尺度 ($v = 0, 1, \dots, 4$), 8 个方向 ($\mu = 0, 1, \dots, 7$) 的 Gabor 滤波器组对人脸图像进行滤波处理。令 $I(x, y)$ 表示人脸灰度图像, 对其做 Gabor 滤波处理即为下面的卷积运算:

$$G_{\mu,v}(x, y) = I(x, y) * \psi_{\mu,v}(z) \quad (2)$$

由式(2)构成的 2 维 Gabor 滤波, 对应不同的 v 和 μ

共有 40 组不同的滤波处理结果, 将这 40 组滤波结果的幅值串接在一起构成一个特征矢量 $g_{C,C}$ 得

$$g_{C,C} = \underset{v=0}{\overset{4}{C}} \underset{\mu=0}{\overset{7}{C}} |G_{\mu,v}(x, y)| \quad (3)$$

其中“C”表示串接运算符^[4]。

在上述的 Gabor 特征表示方法中, 对每组滤波结果是等同对待的, 而在实际中, 各组滤波结果对识别任务往往具有不同的贡献, 因此应该加以区分对待。本文借鉴文献[5]提出的多通道划分思想, 采用如下两种方案提取多通道 Gabor 特征: 方案 1 将属于同一尺度下不同方向的 Gabor 滤波器归为一组, 这样得到 5 个尺度通道, 其中尺度 v 所对应通道的 Gabor 特征矢量由式(4)表示:

$$g_{C,v} = \underset{\mu=0}{\overset{7}{C}} |G_{\mu,v}(x, y)|, \quad v = 0, 1, \dots, 4 \quad (4)$$

方案 2 将同一方向下不同尺度的 Gabor 滤波器归为一组, 可得到 8 个方向通道, 其中方向 μ 所对应通道的 Gabor 特征矢量由式(5)表示:

$$g_{\mu,C} = \underset{v=0}{\overset{4}{C}} |G_{\mu,v}(x, y)|, \quad \mu = 0, 1, \dots, 7 \quad (5)$$

通过提取多通道 Gabor 特征, 并根据各通道 Gabor 特征鉴别能力的强弱对其加以区别对待, 以挖掘不同通道的鉴别潜力, 可能获得更好的识别效果。

3 基于 Gabor 多通道加权优化与稀疏表征的人脸识别

3.1 基于 Gabor 特征的人脸图像稀疏表征方法

在引言中提到, 基于稀疏表征的人脸识别方法 (SRC)^[1]采用基于整体的特征构造字典, 在每类训练样本数较少的情况下, 对待测图像进行稀疏编码, 所求出的非零表征系数将可能对应多个类别, 因此不利于正确分类。鉴于 Gabor 局部特征对光照、表情、姿态以及局部形变等变化条件具有更好的鲁棒性, 因此本文将 Gabor 局部特征应用到稀疏表征方法中, 提出一种 GSRC 算法。该算法首先提取人脸图像的高维 Gabor 特征, 然后对高维 Gabor 特征进行维数约简并利用降维后的特征构造字典, 在稀疏编码阶段, 通过增强表征系数的稀疏性以改善原 SRC 算法的性能。对于维数约减, 本文采用一种常用的子空间学习方法, 即 NLDA (Null space LDA)^[6]方法对高维 Gabor 特征进行降维处理。由于人脸图像的高维 Gabor 特征通常只是分布在高维空间中的一块区域, 即它们通常存在于一个更加低维的子空间上, 采用子空间方法降维, 其实质是寻找嵌入在高维 Gabor 特征空间中的低维子空间, 因此维数约简过程并不会破坏高维 Gabor 特征之间的内在结构

而导致扭曲变形。通过 Gabor 滤波处理,在一定程度上消除了光照、表情及姿态等因素的影响,并且维数约简过程保留了高维 Gabor 特征之间的内在几何结构,因此低维特征同样具有高维 Gabor 特征的鲁棒性。

对于人脸识别问题,一般是使用带有标号的包括 k 个类别, n 幅人脸图像的训练样本集合作为参考标准,在此基础上通过分类匹配算法判定一个新的测试样本所属的类别。现设给定这样一个训练样本集合,以 $n_i (i = 1, 2, \dots, k)$ 表示第 i 类的样本个数, $\psi_{i,j}$ 表示第 i 类第 j 个样本的 Gabor 特征矢量 $\mathbf{g}_{C,C}$, $\Psi = [\psi_{1,1}, \psi_{1,2}, \dots, \psi_{1,n_1}, \dots, \psi_{k,1}, \psi_{k,2}, \dots, \psi_{k,n_k}]$ 表示全部训练样本特征矩阵。假设第 i 类全部训练样本的特征构成一个子空间,则属于该类的某个测试样本 y , 其 Gabor 特征矢量 ψ_y 可以由这个子空间中的训练样本特征通过线性来近似地表示和重构^[1], 即

$$\psi_y \approx x_{i,1}\psi_{i,1} + x_{i,2}\psi_{i,2} + \dots + x_{i,n_i}\psi_{i,n_i} \quad (6)$$

其中 $x_{i,j} \in \mathbf{R}, j = 1, 2, \dots, n_i$ 。在全部训练样本下, ψ_y 可改写成式(7)的形式

$$\begin{aligned} \psi_y \approx \Psi \mathbf{x} = & 0 \cdot \psi_{1,1} + \dots + 0 \cdot \psi_{1,n_1} + \dots + x_{i,1}\psi_{i,1} \\ & + x_{i,2}\psi_{i,2} + \dots + x_{i,n_i}\psi_{i,n_i} + \dots + 0 \cdot \psi_{k,1} + \dots \\ & + 0 \cdot \psi_{k,n_k} \end{aligned} \quad (7)$$

其中 $\mathbf{x} = [0, \dots, 0, x_{i,1}, x_{i,2}, \dots, x_{i,n_i}, 0, \dots, 0]^T \in \mathbf{R}^n$ 表示训练样本特征矩阵 Ψ 对 ψ_y 的表征系数矢量。显然这种表示是稀疏的,新样本 y 只与第 i 类的训练样本强相关,即第 i 类的训练样本对应的表征系数较大,其它训练样本对应的表征系数较小或等于零。

为了计算稀疏表征系数 \mathbf{x} , 需要求解如下的最小 l^0 范数问题^[7]:

$$\hat{\mathbf{x}}_0 = \arg \min \|\mathbf{x}\|_0, \text{ s.t. } \Psi \mathbf{x} = \psi_y \quad (8)$$

最小 l^0 范数优化是一个 NP-hard 问题,难以直接求解。Donoho 等人^[8]指出,如果 \mathbf{x} 足够稀疏,通过求解如下的凸优化问题可正确恢复稀疏矢量 \mathbf{x} :

$$\hat{\mathbf{x}}_1 = \arg \min \|\mathbf{x}\|_1, \text{ s.t. } \Psi \mathbf{x} = \psi_y \quad (9)$$

由于 $\psi_{i,j}$ 的维数很高,为了计算的有效性,可首先产生一个变换矩阵 Φ , 将高维 Gabor 特征投影到低维观测空间中,然后在观测空间中去求解如下的最小 l^1 范数问题:

$$\hat{\mathbf{x}}_1 = \arg \min \|\mathbf{x}\|_1, \text{ s.t. } \Phi \Psi \mathbf{x} = \Phi \psi_y \quad (10)$$

本文采用 Homotopy 算法求解由式(10)所示的最小 l^1 范数问题^[9]。Homotopy 算法已经成功地应用在基于稀疏表征的人脸识别中^[10], 不仅获得了较高的识别精度,同时运算速度也很快。

在求得了稀疏表征矢量 $\hat{\mathbf{x}}_1$ 后,按照文献[1]的分类准则,采用下述方法进行图像分类:

$$i = \arg \min_j \|\Phi \psi_y - \Phi \Psi \delta_j(\hat{\mathbf{x}}_1)\|_2 \quad (11)$$

其中 $\delta_j(\hat{\mathbf{x}}_1)$ 表示只保留 $\hat{\mathbf{x}}_1$ 中对应第 j 类训练样本的表征系数,而将其它的系数置 0。

3.2 基于多通道 Gabor 特征与稀疏表征的人脸识别算法

3.1 节中的 Gabor 稀疏表征分类(GSRC)算法对不同尺度和方向的 Gabor 滤波器所提取的特征是等同对待的。Amin 等人^[4]通过实验表明,不同尺度和方向的 Gabor 特征鉴别力存在差异,因此在建模过程中对不同的 Gabor 特征应该加以区别对待,体现出不同 Gabor 特征对识别任务的不同贡献。基于这种考虑,本文采用如下解决方案:首先采用第 2 节中给出的多通道划分方案,对所有不同尺度和方向的 Gabor 特征进行分组构造多个特征通道,并且在每个通道上都设计稀疏表征分类器,然后利用各通道的 Gabor 特征计算出一组能够反映各通道鉴别能力强弱的权值系数,最后通过对多分类器进行加权融合得到最终的识别结果。采用上述方案,对于那些鉴别力较强的通道,由于具有较大的权值,因此在分类器融合过程中的作用得到加强。反之,对那些鉴别力较弱的通道,由于其对应的权值较小,因此在分类器融合过程中的作用得到弱化。本文将上述描述的方法称为加权多通道 Gabor 稀疏表征分类(WMC-GSRC)方法。该方法和 GSRC 方法相比,根据不同通道的 Gabor 特征对识别的贡献差异进行了加权优化,因此有望提高识别率。

下面具体阐述 WMC-GSRC 算法:给定一个包含 k 个类别 $\omega_i (i = 1, 2, \dots, k)$, n 幅人脸图像的训练样本集合,令 $n_i (i = 1, 2, \dots, k)$ 表示第 i 类的训练样本数, $\psi_{i,j,m}$ 表示第 i 类第 j 个样本在 $m (1 \leq m \leq M)$ 通道上的 Gabor 特征矢量, d 表示 Gabor 特征矢量的长度, $\psi_{i,j,m}(q)$ 表示 Gabor 特征矢量第 q 个元素的 Gabor 特征值(标量),其中 $q \in \{1, 2, \dots, d\}$ 。前面提到不同通道的 Gabor 特征鉴别能力存在差异,因此对不同通道赋予不同的权值以反映各个通道对识别的不同重要性,将对识别产生积极影响。本文利用 Fisher 线性判别分析的优化思想,分别计算训练样本集在各个通道的类内方差 $\sigma_{W,m}^2(q)$ 与类间方差 $\sigma_{B,m}^2(q)$, 对于那些类间方差与类内方差比值越大的通道,说明其 Gabor 特征判别能力越强,因此应该赋予这些通道更大的权值。 $\sigma_{W,m}^2(q)$ 和 $\sigma_{B,m}^2(q)$ 的定义如下^[11]:

$$\begin{aligned} \sigma_{W,m}^2(q) = & \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} [\psi_{i,j,m}(q) - \mu_{i,m}(q)]^2, \\ & q \in \{1, 2, \dots, d\} \end{aligned} \quad (12)$$

$$\sigma_{B,m}^2(q) = \frac{1}{n} \sum_{i=1}^k n_i [\mu_{i,m}(q) - \mu_m(q)]^2, \quad q \in \{1, 2, \dots, d\} \quad (13)$$

其中 $\mu_{i,m}(q) = \frac{1}{n_i} \sum_{j=1}^{n_i} \psi_{i,j,m}(q)$ 表示第 i 类训练样本 Gabor 特征值 $\psi_{i,j,m}(q)$ 的均值, $\mu_m(q) = (1/n) \cdot \sum_{i=1}^k \sum_{j=1}^{n_i} \psi_{i,j,m}(q)$ 表示全部训练样本 Gabor 特征值 $\psi_{i,j,m}(q)$ 的均值。在得到 $\sigma_{W,m}^2(q)$ 和 $\sigma_{B,m}^2(q)$ 之后, 再定义方差比率参数 $\gamma_m^2(q)$ 为

$$\gamma_m^2(q) = \sigma_{B,m}^2(q) / \sigma_{W,m}^2(q), \quad q \in \{1, 2, \dots, d\} \quad (14)$$

对所有 q 求平均, 得到 $\gamma_m^2(q)$ 的样本均值 $\bar{\gamma}_m$ 为

$$\bar{\gamma}_m = \frac{1}{d} \sum_{q=1}^d \gamma_m^2(q) \quad (15)$$

在此基础之上, 定义通道的权值系数 w_m 为

$$w_m = \bar{\gamma}_m / \sum_{i=1}^M \bar{\gamma}_i \quad (16)$$

于是可根据 w_m 来衡量 m 通道上 Gabor 特征的鉴别力, w_m 越大意味着第 m 通道特征的鉴别力越强。

鉴于单个 Gabor 特征通道只提取了整个人脸纹理特征的一部分, 而不同通道提取的特征之间具有互补关系, 因此还应该融合各个通道的鉴别信息以改善识别性能。本文的 WMC-GSRC 算法通过利用不同通道的 Gabor 特征分别构造字典和稀疏表征分类器, 得到多个字典和分类器。为了进一步融合不同通道的鉴别信息, 采用多分类器融合方案。对于第 m 个通道, 令 $\tilde{\Phi}_m$ 表示利用全部训练样本 Gabor 特征构造的字典, $\tilde{\psi}_{y,m}$ 表示待测样本 y 的 Gabor 特征, \hat{x}_m 表示稀疏表征系数, r_m^i 为利用第 i 类训练样本所对应的稀疏表征系数对待测样本 y 进行重构得到的重构残差:

$$r_m^i = \|\tilde{\psi}_{y,m} - \tilde{\Phi}_m \delta_i(\hat{x}_m)\|_2, \quad i = 1, 2, \dots, k \quad (17)$$

再定义基于重构残差的后验概率函数的估值 $\hat{P}_m(\omega_i | y)$ 为

$$\hat{P}_m(\omega_i | y) = \frac{(1/r_m^i)^2}{\sum_{j=1}^k (1/r_m^j)^2} \quad (18)$$

进而提出采用下面的加权优化准则对测试样本 y 进行分类。

$$j = \arg \max_i \sum_{m=1}^M w_m \cdot \hat{P}_m(\omega_i | y) \quad (19)$$

由此, 本文给出 WMC-GSRC 算法的详细步骤:

(1) 将 40 个 Gabor 滤波器划分成 M 组, 构成 M 个通道 ($M \in \{5, 8\}$), 按第 2 节所述方法在第 m 个 ($1 \leq m \leq M$) 通道上, 提取训练样本集的 Gabor 特征, 并按 3.1 节所述方法构造特征矩阵 $\Psi_m = [\psi_{1,1,m}, \dots, \psi_{1,n_1,m}, \dots, \psi_{k,1,m}, \dots, \psi_{k,n_k,m}]$, 通过 NLDA^[6] 方法求

得变换矩阵 Φ 对 Ψ_m 进行维数约简, 构造字典 $\tilde{\Phi}_m$, 其中 $\tilde{\Phi}_m = \Phi \Psi_m$;

(2) 按式(12)–式(16)计算各通道的权值系数 w_m , $m = 1, \dots, M$;

(3) 采用与步骤(1)同样的算法提取待测样本 y 在 m 通道的 Gabor 特征矢量 $\psi_{y,m}$ 并对其进行压缩变换得 $\tilde{\psi}_{y,m} = \Phi \psi_{y,m}$;

(4) 采用 Homotopy 算法对如下的最小 l^1 范数问题进行求解, 求得稀疏表征系数矢量 \hat{x}_m : $\hat{x}_m = \arg \min_{\mathbf{x}_m} \|\mathbf{x}_m\|_1$, s.t. $\|\tilde{\Phi}_m \mathbf{x}_m - \tilde{\psi}_{y,m}\|_2 \leq \varepsilon$, 其中 $m = 1, 2, \dots, M$, ε 表示预定的误差能量的上限值;

(5) 按式(17)计算重构残差 r_m^i , 并根据式(18)计算后验概率估值 $\hat{P}_m(\omega_i | y)$;

(6) 采用由式(19)定义的加权融合准则, 将待测样本 y 判为类别 j 。

4 实验结果举例与分析

本节将通过在 ORL, AR 和 FERET 3 个人脸库上进行实验来考核 GSRC 和 WMC-GSRC 算法的分类识别性能。首先选择训练样本数相对较多的 AR 库对文中算法进行实验。然后在 ORL 库上, 考查训练样本数不同时各算法识别率的变化规律。最后针对训练样本数较少条件下的姿态偏转问题, 选择 FERET 库进行实验。

4.1 AR 库上的实验结果

对于 WMC-GSRC 算法, 为了说明 $\bar{\gamma}_m$ 参数定义的合理性, 实验中考察了各通道字典的 $\bar{\gamma}_m$ 值与对应通道识别率之间的关系。此外 WMC-GSRC 算法在执行分类器融合时, 可以采用不同的融合规则, 因此实验中也考察了不同融合规则对识别率的影响。在前面提到采用 Gabor 局部特征构造字典, 可能会使得表征系数更具稀疏性, 因此在实验中对此也加以考核。

为了和文献[1]中方法的识别率进行对比, 本文按照文献[1]中的同样方法选择 AR 库中的 50 个男性和 50 个女性对象进行实验。对每个对象, 选择其中第 1 阶段采集的 7 幅图像用于训练, 第 2 阶段的 7 幅图像用于识别。实验中, AR 库的人脸图像被裁剪到 64×80 大小。对于 WMC-GSRC 算法, 分别取 5 个尺度通道(W5C-GSRC)和 8 个方向通道(W8C-GSRC)进行实验。表 1 给出的结果是以 W8C-GSRC 算法为例, 在不同方向通道上字典的 $\bar{\gamma}_m$ 值与识别率之间的对应关系, 其中识别率是应用最近邻(NN)分类器进行分类得到的结果。从表 1 中可以看出, 识别率越高的方向通道, 其对应的 $\bar{\gamma}_m$ 值越大, 因此 $\bar{\gamma}_m$ 值能够正确反映不同通道 Gabor 特

表 1 不同方向通道上字典的 $\bar{\gamma}_m$ 值与识别率之间的对应关系

方向通道	0	1	2	3	4	5	6	7
$\bar{\gamma}_m$ 值	0.416	0.4120	0.3812	0.2969	0.2172	0.3289	0.3757	0.4258
识别率	0.8986	0.8886	0.8357	0.7886	0.7229	0.8086	0.8357	0.9057

征鉴别力的强弱。

在采用 WMC-GSRC 算法进行分类器加权融合时, 有不同的融合规则可供选择, 本实验中除了采用由式(19)所示的和规则外, 还分别采用了积规则、投票规则及中值规则来进行分类器的融合。表 2 给出了在 W8C-GSRC 算法中采用不同融合规则时的识别率。从表 2 可知, 基于和规则的融合方法识别效果最好, 而基于投票规则的融合方法识别效果较差。由于各通道之间的鉴别信息存在互补关系, 因此采用和规则比投票规则可以得到更好的识别效果。

表 2 采用不同融合规则对方向通道进行融合时的识别率

融合规则	和规则	积规则	投票规则	中值规则
识别率	0.9886	0.9871	0.9771	0.9857

为了考查本文算法的有效性, 在实验中还分别实现了 SRC 算法^[1], LGBPHS 算法^[12], Gabor+NLDA+NN 算法及 Gabor+NLDA+SVM 算法, 在同样的数据集上进行实验并对实验结果进行比较。对于 WMC-GSRC 算法, 为了考查加权融合的效果, 同时也给出没有进行加权融合时的识别结果。表 3 给出了 AR 库上各算法识别率的对比结果。根据表 3 的实验结果, 我们得到如下结论: (1) 本文的 GSRC 与 WMC-GSRC 算法的识别率优于文献[1]中的 Random+SRC 算法; (2) WMC-GSRC 算法(包括 W5C-GSRC 和 W8C-GSRC)优于没有进行加权融合的 MC-GSRC 算法(包括 5C-GSRC 和 8C-GSRC); (3) W8C-GSRC 算法优于 W5C-GSRC 算法, 这说明方向通道比尺度通道的鉴别力更强。由于采用 8 个方向通道时识别效果更好, 因此在后续实验中仅给出 W8C-GSRC 算法的识别率。

为了进一步分析 GSRC 算法和 Random+SRC 算法各自的稀疏表征特性, 图 1 给出了两种算法表征系数和重构残差的实验结果。从图中可以看出, 两种算法都能将待测样本正确地识别为类别 1。从图 1(a)和图 1(c)可知, Random+SRC 算法求得的表征系数矢量中含有多个较大的元素, 并且不全对应类别 1。而对于 GSRC 算法, 其表征系数矢量中只有一个较大的元素, 并且对应正确的类别。因此 GSRC 算法能够得到更加稀疏的表征系数, 并且这

表 3 AR 库上各种算法识别率的比较

算法	识别率(%)
Random+SRC	94.7
LGBPHS	96.71
Gabor+NLDA+NN	93.71
Gabor+NLDA+SVM	95.14
GSRC	97.29
5C-GSRC	98.14
8C-GSRC	98.71
W5C-GSRC	98.29
W8C-GSRC	98.86

种稀疏性有利于正确的识别。从图 1(b)和图 1(d)可知, 每个类别的训练样本对测试样本进行重构都得到重构残差, 因此共有 100 组重构残差, 分别计算这 100 组重构残差中对应于不同类别的两个最小残差之间的比值, 对 Random+SRC 算法其比值为 2.39; 而对于 GSRC 算法其比值为 4.25, 显然比值越大, 样本被错分的概率越小, 这说明 GSRC 算法的鲁棒性更好。

4.2 ORL 库上的实验结果

对于 ORL 人脸库, 主要考察当每类训练样本数发生变化时各算法识别率的变化情况。ORL 人脸数据库包括 40 个人, 每人 10 幅人脸图像, 实验中每幅图像被裁剪到 64×64 大小。根据每个类别训练样本数的不同, 一共进行 4 组实验, 对于每组实验, 都以 20 次随机实验的平均识别率作为最终的识别率。表 4 所示为各种算法识别率的对比结果, 从表中可知, 随着训练样本数的增加, SRC, GSRC 以及 W8C-GSRC 算法的识别率呈上升的趋势。当每类的训练样本数从 2 增加到 5 时, GSRC 相对 NLDA+SRC 的识别率分别提高了 7.34%, 6.14%, 4.64% 和 4.52%。此外, W8C-GSRC 算法相对 GSRC 算法, 识别率也分别提高了 1.33%, 0.91%, 0.4% 和 0.32%。该实验结果表明利用 Gabor 局部特征构造字典, 显著地提高了识别率。而且还可以发现当训练样本数越少时, GSRC 算法相对于 NLDA+SRC 算法的改进程度越大。W8C-GSRC 算法由于对不同方向通道的 Gabor 特征加以区别对待, 根据不同通道的特征对识别的贡献大小进行加权优化, 因此能够使识别率得到进一步提高。

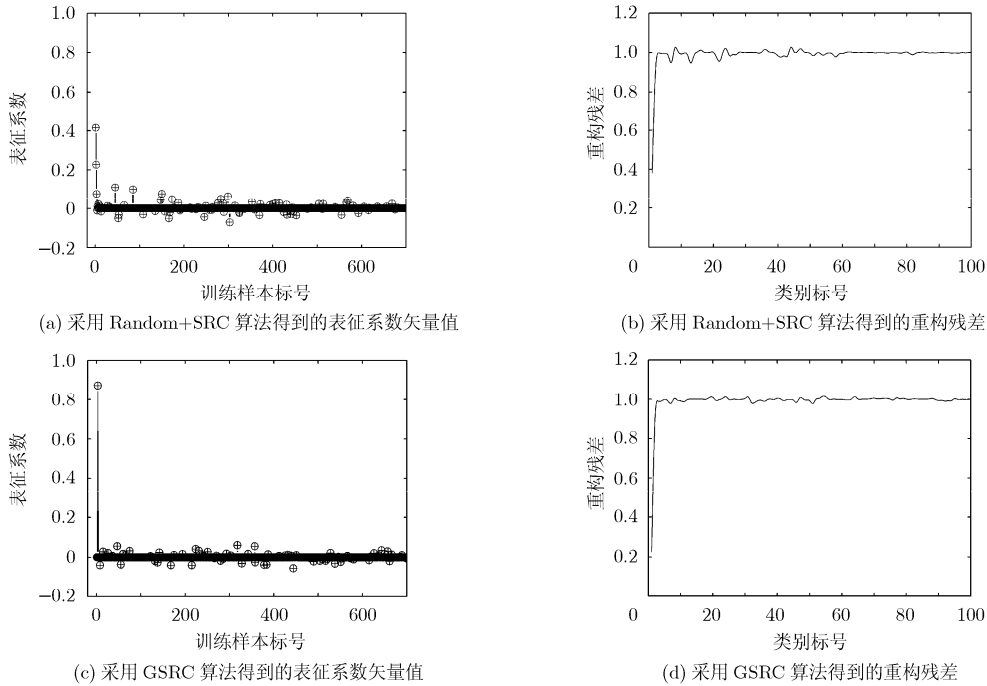


图 1 利用 Random+SRC 与 GSRC 算法对 AR 库类别 1 中同一测试样本进行稀疏编码时，表征系数及重构残差的对比结果

表 4 ORL 库上各种算法识别率(%)的比较

算法	每类的训练样本数			
	2	3	4	5
NLDA+SRC	83.33	90.43	93.71	95.78
LGBPHS	91.07	94.39	97.48	97.82
Gabor+NLDA+NN	87.86	95.42	97.71	98.65
Gabor+NLDA+SVM	88.36	95.68	97.83	98.78
GSRC	90.67	96.57	98.35	99.2
SC-GSRC	91.22	97.09	98.58	99.38
WSC-GSRC	92	97.48	98.75	99.52

4.3 FERET 库上的实验结果

本实验针对每个类别训练样本数较少条件下且存在姿态偏转的问题，探讨 SRC, GSRC 及 WMC-GSRC 算法的识别性能。本文选择 FERET 库的一个姿态子库作为实验数据，该姿态子库由 200 个人的 1400 幅图像组成，对于每个人，选择其标号为‘ba’, ‘bj’, ‘bk’, ‘bg’, ‘bf’, ‘be’, ‘bd’的 7 幅图像，其中‘ba’表示原型图像，‘bj’表示表情变化的图像，‘bk’表示光照变化的图像，‘bg’, ‘bf’, ‘be’, ‘bd’分别表示偏转角度为 -25° , -15° , $+15^\circ$, $+25^\circ$ 的图像。实验中每幅图像被裁剪到 80×80 大小。

针对不同的姿态偏转角度，我们分别构造训练集和测试集。对于姿态角为 0° 的情况，标号为‘ba’, ‘bj’的图像用来构造训练集，标号为‘bk’的图像用来构造测试集。对于姿态偏转的情况，选择标号为‘ba’, ‘bj’, ‘bk’的图像作为训练集，标号为‘bg’, ‘bf’, ‘be’,

‘bd’的图像分别用来构造测试集。表 5 给出了 FERET 库上各种算法识别率的对比结果。当姿态角从 -25° 变化到 $+25^\circ$ 时，GSRC 算法相对 Random+SRC 算法的识别率分别提高了 32.5%, 25.5%, 22.5%, 36.5%和 24%。这说明利用对姿态变化鲁棒性更好的 Gabor 局部特征构造字典，显著地提高了识别率。从表中结果也可以看出，WSC-GSRC 算法的识别率总是高于 GSRC 算法，这再次表明通过区别对待不同的 Gabor 特征，考虑不同 Gabor 特征对识别任务的不同贡献进行加权优化，能够进一步改善识别性能。

4.4 算法时间复杂性

本节中，通过实验来考查各算法的时间复杂性。表 6 所示为各算法识别一幅人脸图像所需的 CPU 时间(对于 ORL 库，选择每人的 5 幅图像作为训练集)，实验所用平台为：Intel Core(TM)2 Duo CPU，主

表 5 FERET 库上各种算法识别率(%)的比较

算法	测试集				
	bg	bf	bk	be	bd
Random+SRC	22.5	68	73	47.5	21.5
LGBPHS	24.5	86	94	72	27
Gabor+NLDA+NN	47	92.5	94	81	41
Gabor+NLDA+SVM	50.5	93	94.5	81.5	41.5
GSRC	55	93.5	95.5	84	45.5
SC-GSRC	56	94.5	96	85	49
WSC-GSRC	56.5	95.5	96.5	86.5	49.5

表6 各算法CPU时间的比较

算法	识别时间(s)		
	ORL库	AR库	FERET库'bf'测试集
Random+SRC	0.03	0.38	0.09
LGBPHS	1.64	3.04	3.43
Gabor+NLDA+NN	0.28	0.29	0.30
Gabor+NLDA+SVM	0.28	0.29	0.30
GSRC	0.30	0.44	0.32
W5C-GSRC	0.36	0.68	0.43
W8C-GSRC	0.40	1.12	0.52

频 2.2G, 3G 内存, Matlab R2007b。以规模相对较大的 AR 库为例, GSRC 算法识别一副图像所需的 CPU 时间为 0.44 s, 而对于 Gabor+NLDA+NN 和 Gabor+NLDA+SVM 算法, CPU 时间为 0.29 s, 这说明稀疏表征分类器和 NN(最近邻分类器)及 SVM(支持向量机)分类器相比, 消耗了更多的 CPU 时间。同时我们也看到, 对于 W5C-GSRC 及 W8C-GSRC 算法, 识别时间分别为 0.68 s 和 1.12 s, 因此通过对不同通道的 Gabor 特征分别进行稀疏表征, 增加了算法的复杂性, 从而消耗了更多的 CPU 时间。然而应该指出的是, 尽管 W8C-GSRC 算法具有相对较高的计算复杂度, 但其在 ORL, AR 及 FERET 人脸数据库上识别一副图像所需的 CPU 时间仅为 0.4 s, 1.12 s 及 0.52 s, 因此能够满足实时性需求。

5 结束语

本文基于稀疏表征的人脸识别方法, 在字典构造阶段, 采用 Gabor 局部特征构造字典, 提出了一种 Gabor 稀疏表征分类算法—GSRC 算法。鉴于 GSRC 算法对所有的 Gabor 特征进行等同对待, 通过进一步考虑不同通道的 Gabor 特征对识别任务的贡献不同, 提出了 WMC-GSRC 算法, 该算法通过引入 Gabor 多通道模型, 提取不同通道的 Gabor 特征分别构造字典和稀疏表征分类器, 在决策级进行加权优化得到最终的识别结果。

本文在 ORL, AR 和 FERET 3 个人脸数据库上进行了大量的仿真实验, 通过实验结果得到如下结论: (1)本文提出的 GSRC 与 WMC-GSRC 算法一致地优于 SRC 算法, 并且当训练样本数越少时, GSRC 和 WMC-GSRC 算法相对 SRC 算法的改进越明显, 因此本文的算法对于处理训练样本数较少时的识别问题更加有效; (2)对于姿态偏转问题, GSRC 和 WMC-GSRC 算法在 FERET 人脸库上的识别率相对 SRC 算法提高了 20 个百分点以上, 说明本文的算法在解决姿态偏转问题时更具鲁棒性; (3)对于没有进行加权融合的 MC-GSRC 算法, 其识别率优于 GSRC 算法, 这说明在稀疏表征框架下,

采用多通道 Gabor 特征构造多字典、多分类器的方案优于采用单字典、单分类器的方案; (4)WMC-GSRC 算法的性能一致地优于 MC-GSRC 算法, 这说明采用加权优化融合策略有利于提高识别率。

参考文献

- [1] Wright J, Yang A, and Ganesh A, *et al.* Robust face recognition via sparse representation [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2009, 31(2): 210-227.
- [2] Su Y, Shan S G, and Chen X L, *et al.* Hierarchical ensemble of global and local classifiers for face recognition[J]. *IEEE Transactions on Image Processing*, 2009, 18(8): 1885-1896.
- [3] Shen L L and Bai L. A review on Gabor wavelets for face recognition [J]. *Pattern Analysis and Application*, 2006, 9(2): 273-292.
- [4] Amin M A and Yan H. An empirical study on the characteristics of Gabor representations for face recognition [J]. *International Journal of Pattern Recognition and Artificial Intelligence*, 2009, 23(3): 401-431.
- [5] Wang L, Li Y P, and Wang C B, *et al.* 2D Gaborface representation method for face recognition with ensemble and multichannel model [J]. *Image and Vision Computing*, 2008, 26(6): 820-828.
- [6] Huang R, Liu Q, and Lu H, *et al.* Solving the small size problem of LDA [C]. *International Conference on Pattern Recognition*, Quebec, Canada, Aug. 11-15, 2002, 3: 29-32.
- [7] Candès E J, Romberg J, and Tao T. Robust uncertainty principles: exact reconstruction from highly incomplete frequency information [J]. *IEEE Transactions on Information Theory*, 2006, 52(2): 489-509.
- [8] Donoho D L. For most large underdetermined systems of linear equations the minimal l_1 -norm solution is also the sparsest solution [J]. *Communications on Pure and Applied Mathematics*, 2006, 59(6): 797-829.
- [9] Yang A, Sastry S, Ganesh A, and Ma Y. Fast l_1 -minimization algorithms and an application in robust face recognition: a review [C]. *International Conference on Image Processing*, Hong Kong, Sep. 26-29, 2010: 1849-1852.
- [10] Donoho D L and Tsaig Y. Fast solution of l_1 -norm minimization problems when the solution may be sparse [R]. *Technical Report*, Institute for Computational and Mathematical Engineering, Stanford University, 2006.
- [11] Du S and Ward R K. Improved face representation by nonuniform multilevel selection of Gabor convolution features [J]. *IEEE Transactions on System, Man, and Cybernetics-Part B: Cybernetics*, 2009, 39(6): 1408-1419.
- [12] Yang Q S and Guo C A. Parallel face recognition approach based on LGBPHS with homogeneous PC cluster [J]. *Journal of Information & Computational Science*, 2010, 7(3): 637-648.

杨清山: 男, 1985 年生, 博士生, 研究方向为数字图像处理与识别、并行计算。

郭成安: 男, 1955 年生, 教授, 博士生导师, 研究方向为数字信号处理、数字图像处理与识别、智能信息处理技术。

金明录: 男, 1958 年生, 教授, 博士生导师, 研究方向为现代通信技术、集成电路设计、压缩感知技术。