

基于小波分析和几何特征的人脸识别方法研究

胡占奇, 刘洪玮

(东华大学 信息学院, 上海 201620)

摘要: 在主成分分析法(PCA)和独立成分分析法(ICA)等理论上, 提出一种结合人脸几何特征和独立 Gabor 小波特征分析的人脸识别方法。在对人脸图像进行二维小波分解的基础上, 从人脸图像的下采样 Gabor 小波图像中得到一个 Gabor 小波特征向量并利用 PCA 法降维, 在 ICA 的基础上得到独立 Gabor 小波特征, 并结合人脸面部器官的位置和轮廓及器官距离等所构成的几何特征进行人脸识别。

关键词: 主成分分析法; 独立成分分析法; 几何特征; 独立 Gabor 小波特征; 二维小波分解

中图分类号: TP391.41

文献标识码: A

A research in face recognition based on wavelet analysis and geometric features

HU Zhan Qi, LIU Hong Wei

(Information Institute of Donghua University, Shanghai 201620, China)

Abstract: Based on the theorem of principal component analysis and independent component analysis, an algorithm of human face recognition combined independent Gabor features with face geometric features is proposed. Firstly, decompose the face images with wavelet of two dimensions. Secondly, acquire a Gabor feature vector based on Gabor wavelet downsamples of face images and reduce the vector's dimensions. Based on independent component analysis, acquire independent Gabor features. Finally, obtain the face geometric features such as the position and contour of face apparatus and the distances among them, then make full use of the information obtained from the face geometric features and independent Gabor features to recognize the faces.

Key words: principal component analysis; independent component analysis; geometric feature; independent Gabor feature; wavelet discrete of two dimensions

本文结合 Gabor 小波和 ICA 方法的原因是: (1) 经过 Gabor 小波转换后的人脸图像清楚地显示了局部特征, 多尺度、多方向的选择特性很适合做识别; (2) ICA 方法进一步去除冗余并提取出独立特征, 这些具备独立性的特征有助于随后的分类识别。在 ORL 数据库^[1]上的实验证实, 独立 Gabor 小波特征+几何特征法极大地提高了人脸识别的准确率, 同时降低了特征空间的维数。

1 独立 Gabor 小波特征法

1.1 主成分分析法(PCA)

主成分分析法^[2]是一种降维的数学变换方法, 它把给定的一组相关变量通过正交变换转换成另一组不相关的变量, 这在代数上表现为将原随机向量的协方差矩阵转换为对角矩阵, 在几何上表现为将原坐标系变换成

新的正交坐标系。这些新的变量按照方差依次递减的顺序排列, 在数学变换中保持变量的总方差不变, 使第一变量具有最大的方差, 称为第一主成分, 第二变量的方差次大, 并且和第一变量不相关, 称为第二主成分, 依次类推。PCA 是人脸特征提取的主流方法, 常被用于找到一个关于人脸特征数据的低维表达。在 PCA 的应用中, 二维训练图像必须首先转换为一维向量。假设用于训练的包含有 N 个人脸向量的集合是 $X=[X_1, X_2, \dots, X_N]$, 通过把每一个人脸向量和所有人脸向量的平均向量进行相减所得到的向量集合是 $\Phi=[\Phi_1, \Phi_2, \dots, \Phi_N]$, 训练人脸图像的斜方差矩阵是:

$$S_T = E(\Phi^T \Phi) \quad (1)$$

可以通过式 $|S_T - \lambda I_N| = 0$ 计算矩阵 S_T 的特征向量和特征

值,考虑一个从原始的 n 维空间到 m 维的特征空间的线性转换映射 ($m < n$), 新的特征向量 $z_i \in R^m$ 可以通过如下的线性转换得到:

$$z_i = U \Phi_i \quad (2)$$

PCA 方法就是要通过比较 z 和输入人脸图像的特征向量来进行人脸识别。

1.2 Gabor 小波特征表述

Gabor^[3]小波如下所定义:

$$\psi_{\mu,\nu}(z) = \frac{\|k_{\mu,\nu}\|^2}{\sigma} e^{-\frac{(\|k_{\mu,\nu}\|^2 \|z\|^2 / 2\sigma^2)}{2}} [e^{ik_{\mu,\nu}z} - e^{-(\sigma^2/2)}] \quad (3)$$

μ 和 ν 分别定义了 Gabor 核的方向和尺度, $z=(x, y)$, 小波向量:

$$\kappa_{\mu,\nu} = \kappa_\nu e^{i\phi_\mu} \quad (4)$$

式中, $\kappa_\nu = \kappa_{\max}/f^\nu$, $\phi_\mu = \pi\mu/8$, f 是在频域中核之间的空间系数。

大多数情况下, Gabor 小波有 5 个不同的尺度 $\nu \in \{0, 1, 2, 3, 4\}$ 和 8 个方向 $\mu \in \{0, \dots, 7\}$, 这些 Gabor 小波具备很好的空间局部化和方向可选择特性, 特别适用于图像的分解和表述。当为了分类想得到局部和识别特征时, Gabor 小波对于图像的特征提取是一个很好的选择, 是时域和频域进行局部化分析的最优选择。

Gabor 小波表述一幅图像是通过把图像和如 (3) 式所定义的一族 Gabor 小波进行卷积。假设 $I(x, y)$ 是一幅图像的灰度级, 图像 I 和 Gabor 小波 $\psi_{\mu,\nu}$ 的卷积输出如下:

$$O_{\mu,\nu}(z) = I(z) * \psi_{\mu,\nu}(z) \quad (5)$$

式中, $z=(x, y)$, $*$ 是卷积操作符。应用卷积定理, 可以通过快速傅里叶变换从 (5) 式得到卷积输出 $\mathfrak{F}\{O_{\mu,\nu}(z)\} = \mathfrak{F}\{I(z)\} \mathfrak{F}\{\psi_{\mu,\nu}(z)\}$ 且 $O_{\mu,\nu}(z) = \mathfrak{F}^{-1}\{\mathfrak{F}\{I(z)\} \mathfrak{F}\{\psi_{\mu,\nu}(z)\}\}$, 式中的 \mathfrak{F} 、 \mathfrak{F}^{-1} 分别是傅里叶变换和傅里叶反变换。因为输出 $O_{\mu,\nu}(z)$ ($\mu \in \{0, \dots, 7\}$, $\nu \in \{0, \dots, 4\}$) 包含了不同的局部区域、尺度和方向特征, 把所有这些特征联系起来进而得到一个特征向量 x 。假设每 1 个输出 $O_{\mu,\nu}$ 是 1 个列向量, 则可以通过关联输出的各行(或各列)构成 x 。在关联之前, 首先把每 1 个输出 $O_{\mu,\nu}(z)$ 通过 1 个因子 ρ 进行下采样, 进而降低原始向量空间的维数, 如果 $O_{\mu,\nu}^{(\rho)}$ 表示了一个标准化后的输出(用因子 ρ 进行下采样), 则特征向量 $x^{(\rho)} = (O_{0,0}^{(\rho)}, O_{0,1}^{(\rho)}, \dots, O_{7,4}^{(\rho)})^t$ (t 是转置操作符)。因此特征向量 $x^{(\rho)}$ 包含了所有输出, $O_{\mu,\nu}(z)$ ($\mu \in \{0, \dots, 7\}$, $\nu \in \{0, 1, 2, 3, 4\}$) 可以作为重要的识别信息。

1.3 独立成分分析(ICA)方法

独立成分分析(ICA)是一种新的数据处理方法, 目的在于从未知源信号的观测混合信号中分离(或抽取)相

互统计独立的源信号。将 ICA 用来处理盲源分离问题 BSS(Blind Source Separation)已经引起了广泛关注。标准的独立成分分析需要假设信号的非高斯性, 现实世界中的许多信号(如绝大多数的语音信号和图像信号)是服从非高斯分布的。实际信号的统计特性仅用普通的基于二阶统计量方法是不能反映的, 独立成分分析追求的是信号的高阶统计信息。

标准的(即源信号的个数等于混合信号的个数)无噪声独立成分分析的线性模型的矩阵形式为 $[25, 36, 50, 63, 97, 99, 100]: X=AS_i$, 其中随机向量 $X=(x_1, \dots, x_n)^T$ 表示观测数据或观测信号, 随机向量 $S=(s_1, \dots, s_n)^T$ 表示源信号, 称为独立成分, $A \in R^{n \times n}$ 称为混合矩阵。也可以看作是一个生成模型, 即观测信号 X 是通过源信号混合而生成的。独立成分 S_i 也称为隐含或潜在变量, 也就是说这些独立成分是无法直接观测到的。另一方面, 混合系数矩阵 A 也是未知的。独立成分分析的任务是: 在只知道观测信号 X 的 T 个样本 $x(1), \dots, x(T)$ 、且在源信号 S 和混合矩阵 A 未知的条件下, 假设源信号之间是相互统计独立的, 来求解混合矩阵 A 和源信号 S 。ICA 法寻找一个线性的变换去表达一组随机变量, 是把具有统计独立性的源变量线性组合起来。寻找的规则是把图像之间的共有信息最小化。PCA 法只考虑二阶且把数据的相关性去掉, 而 ICA 法将进一步减小统计的相互依赖性, 减少冗余特征, 表达独立的特征。因此, ICA 法比 PCA 法有更好的数据表述。

1.4 Gabor 小波特征的独立性分析

在 1.2 节中介绍的 Gabor 小波特征向量存在于一个高维空间中, $x^{(\rho)} \in R^N$, N 是向量空间的维数。当要把用于人脸识别的相似性的判断映射到一个低维的空间中去考虑时, PCA 法是一个不错的选择。PCA 方法的一个重要特性是在只用一个包含主成分的子集去表述原始图像时, 是在保证均方误差最小的条件下图像重建的最优选择。根据这个特性, PCA 法的一个重要应用就是降维:

$$y^{(\rho)} = P^t x^{(\rho)} \quad (6)$$

式中, $P=[P_1 P_2 \dots P_n]$ 由 $x^{(\rho)}$ 的协方差矩阵的 n 个主要的特征值所对应的特征向量组成, $n < N$ 且 $P \in R^{N \times n}$, 低维向量 $y^{(\rho)} \in R^n$ 包含原始数据 $x^{(\rho)}$ 的最易区分的特征。PCA 法的输出作为 ICA 方法的输入。

ICA 方法在这里用于得到独立的 Gabor 小波特征。对于一个随机向量, 就是寻找一个使其成分之间的统计依赖性最小化的线性变换。假设 $y \in R^n$ 是一个对应于 PCA 方法的输出的 n 维随机向量, y 的协方差矩阵定义如下:

$$\sum y = E\{[y-E(y)][y-E(y)]^t\}$$

式中, t 为转置操作符, $\sum y \in R^{n \times n}$ 。随机向量 y 的 ICA 就是把协方差矩阵 $\sum y$ 分解为如下形式: $\sum y = FTF^t$, 这里 $\Gamma \in R^{m \times m}$ 是一个对角线的正实矩阵, $F \in R^{n \times m}$ 转换原始随机向量 $y \in R^n$ 为 $z \in R^m, y = Fz$, 新的随机向量 z 的 m 个成分 ($m \leq n$) 是最具独立性的。

假设 $p_z(u)$ 是随机向量 z 的概率密度函数, 向量 z 具有相互独立的成分, 当且仅当其联合概率密度等于其边缘概率密度的乘积:

$$p_z(u) = \prod_{i=1}^m p_{z_i}(u_i) \quad (7)$$

为得到 ICA 法的转换矩阵 F , Comon^[4] 提出了一个衡量随机向量 z 的组成成分独立性的最优准则。该准则计算(7)式左右两边所对应的联合概率密度函数和边缘概率密度函数的相对熵(或相对平均信息量):

$$I(p_z) = \int p_z(u) \log \frac{p_z(u)}{\prod p_{z_i}(u_i)} du \quad (8)$$

(8)式指定了向量 z 的相对平均信息。通过(7)、(8)两式可以得到: 相对平均信息量为零, 当且仅当随机向量 z 具有相互独立的成分。

1.5 建立在独立 Gabor 小波特征基础上的分类设计

在提取特征之后, 进行分类设计。分类方法是在类内协方差矩阵为对角阵的假设下, 定义了一个线性贝叶斯分类器。因为从独立 Gabor 小波特征方法得来的特征具有相互独立的成分, 所以此假设是合理的。需要注意的是此假设是在经 ICA 转换之后。假设 $M_k^0 (k=1, 2, \dots, L)$ 是经过 ICA 转换之后类 ω_k 的训练样本的平均值, 则应用贝叶斯准则进行分类为:

$$\sum_{i=1}^m \frac{(z_i - m_k)^2}{\sigma_i^2} = \min_j \left\{ \sum_{i=1}^m \frac{(z_i - m_j)^2}{\sigma_i^2} \right\} \rightarrow z^{(p)} \in \omega_k \quad (9)$$

式中, z_i 和 $m_k (i=1, \dots, m)$, 分别是 $z^{(p)}$ 和 M_k^0 的组成部分。 σ_i^2 是在一维 ICA 空间对样本的差异进行估计后得到的。

2 几何特征法

2.1 图像的二维小波分解

对人脸图像, 这里采用一维小波对应的滤波器, 分别对二维信号的行和列做滤波并下采样。小波分解是把信号分解成低频 a1 和高频 d1 两部分。在分解中, 低频 a1 中失去的信息由高频 d1 捕获, 在下一层分解中, 又将 a1 分解成低频 a2 和高频 d2 两部分, 低频 a2 中失去的信息由高频 d2 捕获, 如此类推下去, 可以进行更深层次的分解。图 1 显示了一幅人脸图像的二维小波分解^[4]过程, 对如图 1(a)所示的人脸图像进行 1 层小波分解后,

得到如图 1(b)所示 4 个子图像, 对第 1 层小波分解后的子图像 LL(左上角子图)再进行 1 次小波分解, 又可得到如图 1(c)所示原始图像的第 2 层分解图, 依次可进行多层小波分解。其中子图像 LL(左上角子图)反映原图像的低频分量, 为原图像的平滑像; 子图像 LH(右上角子图)反映原图像的水平边缘细节; 子图像 HL(左下角子图)反映原图像的垂直边缘细节; 子图像 HH(右下角子图)反映原图像的斜边缘细节。由于人的丰富表情主要反映在眼睛和嘴巴上, 而且眼睛和嘴巴的水平特征比垂直特征明显, 因此, 水平边缘子图像 LH 刻画了人脸的表情特征; 人脸的轮廓和鼻子的垂直特征比水平特征明显, 它们易受发型和侧脸姿势的影响, 因此垂直边缘子图像 HL 刻画了人脸的姿势; 对于刚体而言, 斜边缘信息最为重要, 因为它代表了图像的整体结构特征, 但人脸是非刚体的, 斜边缘信息受表情和姿势的影响较大, 其稳定性差。适当层次小波变换后的低频子图像刻画了人脸的表情和姿势的不变特征, 有较好的稳定性。由于作 n 次二维小波分解后, 低频子图像的尺寸仅为原图像的 $1/2^n$, 因此能有效地降低图像的维数。由于小波分解的线性化时间取决于图像尺寸, 并且只需要非常少的代码, 所以其计算是非常快的, 这也解决了 PCA 方法由于计算量大而不能满足实时性的问题。图 2 为二维小波变换的方块图。其中的 $f_{LL}(x, y)$ 是原始图像的近似, 而 $f_{LH}(x, y)$ 、 $f_{HL}(x, y)$ 和 $f_{HH}(x, y)$ 分别含有原图像水平、垂直和斜线方向的信息。



(a)人脸图像 (b)1层小波分解 (c)2层小波分解
图1 人脸图像小波分解

2.2 几何特征提取

人脸的轮廓线可以通过邻近像素亮度程度的不同清晰地分离出来。同样, 人脸的各个特征部位也都有各自的不同于邻近区域的亮度值, 故也可以用轮廓线划分出人脸的每一个特征部位, 进而进行特征定位。用 Sobel 算子^[5]进行轮廓线的提取如图 3 所示。在提高识别率的方法中, 眼睛和嘴之间的距离, 被作为一个最基本的几何特征。图 3 显示了在采用 Sobel 算子进行人脸轮廓线的提取图上对眼睛和嘴水平位置的定位。因为能量也是图像的一种属性, 所以可以通过获取人脸各个部位的能量值去表达人脸的特征, 并把它作为人脸特征向量。这里利用人脸图像高频段能量的分析, 构建出人脸几何特征的 3 个关于能量的特征向量。

图 4 显示了根据眼睛、鼻子和嘴的位置进行的人脸

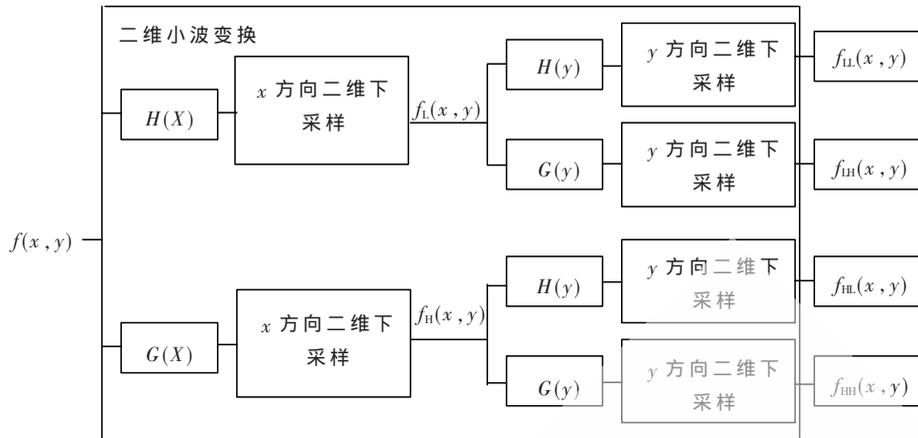


图2 二维小波变换方框图



图3 利用水平方向的投影检测嘴和眼睛的距离

区域划分。眼睛位于人脸的上半部分,包括许多水平方向的成分,子带图像 LH 包含许多水平成分,因此包含许多眼睛的特征;鼻子占据了人脸长度的三分之一,包含许多垂直方向的成分,子带图像 HL 包含许多垂直成分,因此包含许多鼻子的特征;最下方 1/3 区域的人脸轮廓线包含有对角线方向的信息,对应包含斜线方向信息的子带图像 HH。每个子带图像的能量值可由式(10)求解得到:

$$E(X) = \sum_{(i,j) \in X} d^2(i,j) \quad (10)$$

式中, $X \in \{LH_{eye}, HL_{nose}, HH_{chin}, LH_{eye}\}$ 对应人脸图像的上半部分像素点,即子带图像 LH, HL_{nose} 对应中间 1/3 区域的像素点,即子带图像 HL, HH_{chin} 对应人脸下部 1/3 的像素点,即子带图像 HH。 $d^2(i,j)$ 是点 (i,j) 处像素值的平方。

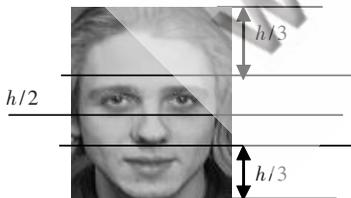


图4 根据眼睛嘴鼻子的位置进行的人脸区域划分

3 实验结果及结论

利用 ORL 数据库的 400 幅图像来评估独立 Gabor 特征+几何特征得到人脸识别效果,从每人的 10 张图像中随机抽取 5 张用于训练,其余 5 张用于测试。图 5 对比了特征脸方法和独立 Gabor 特征方法+几何特征法的

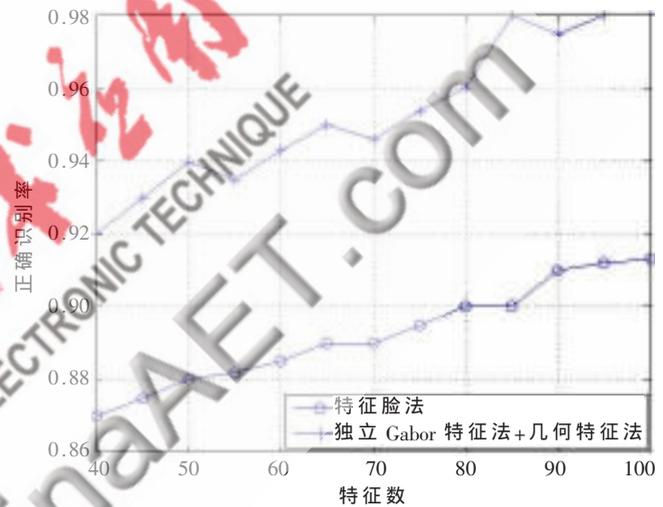


图5 特征脸法和独立 Gabor 特征法+几何特征法的识别效果对比图

识别效果。下一步的研究重点可以放在用更精简的 Gabor 小波特征进行人脸的表述,进而减少用于分类的数据,并进一步提高识别的实时性。

参考文献

- [1] HOPPER A. The ORL face database. AT&T (olivetti) research laboratory cambridge. <http://www.cl.cam.ac.uk/research/dtg/attarchive>, 1992.
- [2] TURK M, PENTLAND A. Eigenfaces for recognition[J]. Cognitive Neurosci, 1991, 3(1): 71-86.
- [3] COMON P. Independent component analysis, a new concept?. Signal Processing, 1994, 36: 287-314.
- [4] VILLASENOR J D, BELLZER B, LIAO J. Wavelet filter evaluation for image compression. IEEE Trans Image Processing, 1995(4):1053-1060.
- [5] GONZALEZ R C, WOODS R E, EDDINS S L. 数字图像处理(MATLAB 版).阮秋琦,等译.北京:电子工业出版社, 2008:287-295.

(收稿日期:2009-04-09)