

文章编号:1671-9352(2007)09-096-05

利用小波变换提高基于 KPCA 方法的人脸识别性能

杨绍华¹, 林盘², 潘晨¹

(1. 宁夏大学 数学计算机学院, 宁夏 银川 750021;

2. 福建师范大学 软件学院, 福建 福州 350007)

摘要: 基于核主成分分析(KPCA)的人脸识别算法能够提取非线性图像特征,在小样本训练条件下有较好性能.然而并非所有非线性特征对识别都有利,过多的不相关特征可能会降低识别性能.针对图像信息冗余的特点,预先对图像进行小波变换,通过消除对识别无关的细节信息,不仅提高了KPCA方法的识别精度,而且降低了该算法对计算机硬件的要求.同时,为了抑制KPCA对光照等变化的较高敏感性,还提出一种对图像灰度进行衰减的预处理策略.基于ORL数据库的实验表明,综合上述措施的系统比传统方法具有更快的训练速度和更高的识别精度.

关键词: 人脸识别;小波变换;核主成分分析

中图分类号: TP391 **文献标志码:** A

Performance improvement of face recognition based on kernel principal component analysis using wavelet transform

YANG Shao-hua¹, LIN Pan², PAN Chen¹

(1. School of Mathematics and Computer Science, Ningxia University, Yinchuan 750021, Ningxia, China;

2. Software College, Fujian Normal University, Fuzhou 350007, Fujian, China)

Abstract: The algorithm of face recognition based on kernel principal component analysis(KPCA) can abstract nonlinear features of image and can get better performance under less sample training conditions. Not all nonlinear features are beneficial to the recognition. The superabundant unrelated features may reduce the recognition performance. The image was transformed by wavelet transformation for its redundancy, which not only has improved the accuracy of recognition but has reduced the demand for computer hardware of the algorithm. A pretreatment strategy that can reduce image gradation was developed in order to restrain upper sensitivity of KPCA to the change of illumination. The experimental results based on ORL-DATABASE show that the above-mentioned algorithm allows faster training speed and higher accuracy of recognition than traditional ones.

Key words: face recognition; wavelet transform; kernel principal component analysis

0 引言

在模式识别领域,人脸识别一直是一个重要的研究课题,并且具有广阔的应用前景.人脸识别是典型的高维数据分类问题,在人脸识别中通常要考

虑2个重要的问题,即提取什么样的特征有利于分类器的分类和如何避免或降低高维的运算.利用子空间技术可以大大降低数据的特征维数,节省存储和计算资源.迄今已经出现许多有效的方法,主成分分析(principal component analysis, PCA)是最重要的技术之一.1991年Turk和Pentland提出了

收稿日期:2007-04-26

基金项目:国家自然科学基金资助项目(60663003);福建省教育厅K类资助项目(2006F5024);宁夏自然科学基金资助项目(NZ0610)

作者简介:杨绍华(1978-),男,助教,硕士,研究方向:图形图像与多媒体技术. Email: yang_shh@nxu.edu.cn

Eigenfaces^[1]方法用于人脸识别. 特征脸方法的一个重要优点是保留了图像大部分能量, 提取的特征在协方差意义下是最优的. Belhumer 对特征脸方法进行了有效改进提出了 Fisherface 方法^[2], 对于光照具有较好的鲁棒性. 然而这 2 种方法在人脸识别时都需将人脸图像向量化表示, 这样不仅丢失了图像的结构信息还造成了高维的数据运算. YANG 提出了一种具有统计不相关性的图像投影鉴别分析方法, 并命名为 2DPCA^[3,4]. 2DPCA 方法克服了 PCA 向量化表示图像的缺陷, 提高了识别精度和效率. Scholkopf 等人提出了核主成分分析(KPCA), 并应用于人脸识别^[5,6], 实验结果表明 KPCA 能够抽取有利于人脸识别的非线性特征, 有着比主成分分析更好的识别效果.

KPCA 是一种重要的非线性子空间方法, 它能够通过空间映射技术提取非线性的信号(本文为图像)特征, 一般认为其性能优于线性的 PCA 和 ICA 方法^[7]. 然而在 KPCA 方法应用时, 存在一些问题. 如:(1)KPCA 的核空间映射通常是一个高维的运算过程, 对计算机的硬件性能有较高的要求;(2)KPCA 同 PCA 算法一样, 都是一种从信号整体特征考虑的特征提取算法, 这样的算法对影响信号整体特征的干扰和变化敏感, 如光照变化;(3)KPCA 提取的特征对识别目的而言并没有直接的关系, 并非所有提取的特征对识别都有利, 过多的不相关特征可能会降低识别性能. 对于图像来说, 由于人的感观和物理仪器都有一定的分辨率, 对低于一定尺度的信号细节是无法认识的, 但对于所有尺度信号进行研究也是没有必要的^[8].

众所周知, 小波变换是一种有效的多分辨率方法. 通过对图像的高低通滤波可以将图像分解为对应不同尺度的近似分量(低频分量)和细节分量(高频分量), 这样的方法有助于我们针对有意义的某种尺度信号的研究. 比如 Nastar 等^[9]研究了人脸外观变化与小波频谱变化之间的关系, 指出人脸的光照、少许遮罩、旋转扭曲和面部表情只影响图像中高频部分, 人脸图像的低频部分仍然保持稳定.

本文通过对训练样本预先进行小波分解, 提取其低频分量图作为原始图像的近似, 并利用简单的指数衰减技术减少光照等非线性因素对分类器的影响. 实验结果表明, 本文提出的算法不但能降低训练样本的维数减少计算机的计算量并在识别率上优于 PCA, 2DPCA 等线性方法, 也优于没有经过小波处理的 KPCA + KNN 方法.

1 小波变换原理

小波变换是一种时间窗和频率窗都可改变的时频分析方法, 在时频域都具有很强的表征信号局部特征的能力.

设函数 $f(t)$ 是平方可积函数, 即 $f(t) \in L^2(R)$, 则连续小波变换的定义为:

$$w_f(a, b) = \int_{-\infty}^{+\infty} f(t) \Psi_{a,b}(t) dt = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) dt. \quad (1)$$

其中 $a > 0$ 是尺度因子, b 是定位参数, 函数 $\Psi_{a,b}(t)$ 称为小波或母小波.

离散小波是对连续小波的尺度和位移按照 2 的幂次进行离散化得到的, 相应的离散小波变换定义为

$$\langle f, \Psi_{m,n} \rangle = a_0^{-\frac{m}{2}} \int_{-\infty}^{+\infty} f(t) \Psi_{m,n}(t) dt = a_0^{-\frac{m}{2}} \int_{-\infty}^{+\infty} f(t) \Psi(a_0^{-m}t - nb_0) dt. \quad (2)$$

在计算机中利用金字塔算法^[10]实现小波变换. 图 1 是一个小波分解示意图, 图中左面图像是原始图像, 中间是小波 2 层分解示意图, 右图是 2 层分解后的低频分量图.




图 1 小波分解示意图

Fig.1 Decomposing process of wavelet

2 基于核方法的特征提取

许多利用机器学习的数据分析任务中, 都需要对数据进行合适的表示或描述. 一个有效的数据表示能够使数据的内在结构更清晰、减少数据的维数, 以利于进一步计算. PCA, NMF 等方法都是线性的, 虽然得到广泛应用, 但是它们不能揭示数据中隐藏的非线性结构. 除此以外, 线性方法只能处理具有属性值的数据, 在很多应用中我们可能不知道数据的属性值, 而只知道相互关系(相似或不相似). 线

性方法无法直接应用于这样的场合^[11].

KPCA(核主成分分析)的基本思想是通过一个非线性映射,把输入数据映射到一个高维的特征空间,在特征空间上进行线性主成分分析.设输入数据 x_k 被映射为 $\Phi(x_k)$,假设它们已经被中心化即满足条件:

$$\sum_{k=1}^N \Phi(x_k) = 0. \quad (3)$$

其中, k 是 N 个输入训练样本, $\Phi(x_k)$ 是变换后的训练样本. 映射后训练样本的协方差矩阵 C 为:

$$C = \frac{1}{N} \sum_{j=1}^N \Phi(x_j) \Phi(x_j)^T. \quad (4)$$

求解该协方差的特征方程:

$$\lambda V = CV. \quad (5)$$

根据再生核理论,特征向量 V 一定位于由 $\Phi(x_1) \cdots \Phi(x_N)$ 张成的空间内,即 V 可以由 $\Phi(x_1), \cdots, \Phi(x_N)$ 的线性组合:

$$V = \alpha_i \sum_{i=1}^N \Phi(x_i). \quad (6)$$

其中 $\alpha_1 \cdots \alpha_N$ 为常数. 定义一个 $N \times N$ 的矩阵 K :

$$K_{ij} = \Phi(x_i)^T \Phi(x_j). \quad (7)$$

K 称为核矩阵,将式(4),(6),(7)代入式(5)得:

$$K\alpha = N\lambda\alpha. \quad (8)$$

这样求解式(5)的特征向量 V 的问题就转换为求解式(8)中特征向量 α ,由式(7)得知,核矩阵 K 是对称的、半正定方阵,其具有非负的特征向量,通过求解特征方程(8)得到一组非零特征值 λ_j 以及对应满足归一化条件: $\lambda_j(\alpha^j, \alpha^j) = 1$ 的特征向量 $\alpha^j (j = 1, \cdots, N)$ 根据式(6)得到特征空间上的投影主分量 $V_j (j = 1, \cdots, N)$.

设 x 是测试样本,那么 x 在投影主分量上的投影为:

$$(V_j)^T \Phi(x) = \sum_{i=1}^N \alpha_i^j \Phi(x_i)^T \Phi(x) = \sum_{i=1}^N \alpha_i^j K(x_i, x). \quad (9)$$

于是将 R^f 空间的 PCA 问题转换为 R^f 空间的内积问题,在求解过程中只要知道 $K(x_i, x)$ 的表达式即可, $K(x_i, x)$ 称为核函数,核函数的选择必须满足 Mercer 定理,常用的核函数有

(1) 线性函数: $K(x_i, x) = x \cdot x_i$;

(2) 多项式核函数:

$$K(x_i, x) = [(x \cdot x_i) + 1]^d, \quad d = 1, 2, \cdots;$$

(3) Sigmoid 核函数:

$$K(x_i, x) = \tanh[v(x \cdot x_i) + c];$$

(4) 高斯径向基函数:

$$K(x_i, x) = \exp(-q \|x - x_i\|^2).$$

这样就降低了计算的复杂度,同样可以取核矩阵 K 的最大的 k 个特征值所对应的特征向量组成 R^f 空间上 k 个非线性主成分.

3 指数衰减的预处理方法

KPCA 是一种提取全局特征的方法,此类算法对光照条件变化敏感.为了抑制光照影响,对样本图像做了简单的重映射(幂次变换)处理,也就是对训练样本矩阵中的元素作一个指数衰减即

$$h = h^\alpha. \quad (0 < \alpha \leq 1) \quad (10)$$

其中 h 表示图像的像素灰度值, α 表示衰减因子,类似于图像显示时的伽马校正.通过适当增加暗区的对比度,稍微提高整体图像亮度,抑制亮度较高时光照变化的幅度见图2和图3,从而提高识别精度.如图2所示,采用该算法无论训练样本多少都能提高识别正确率.实验中,当指数取 $a = 0.4$ 时,识别的效果最佳.在后续的实验,将这种方式作为预处理手段处理人脸图像.




图2 指数衰减示意图

Fig.2 Sketch map of the exponential decay




图3 指数衰减因子对识别率的影响

Fig.3 Comparison based on different exponential decay factors

4 算法描述

本文提出的算法如图4所示,详细描述如下:

第一步,读取训练样本,选取指数衰减因子 $\alpha = 0.4$ 对图像灰度进行指数衰减.

第二步,对经过指数衰减处理的样本进行小波分解,选用的小波基函数是 Daubechies 基中的 db4,分解层数为3层,得到的小波系数是相互独立的,也就得到了原始训练样本的一系列不同的特征.最后选择小波变换后的 LL 部分作为原始图像的近似,这样原始分辨率为 112×92 的图像变换为 14×12 的低频近似分量图像,在其中保留了原始图像的大部分能量,用于人脸识别的特征提取,有效地降低了训练样本的维数.

第三步,利用 KPCA 方法对训练样本数据集进行核映射,核函数选择的是多项式函数,得到训练样本集在核空间的投影基矩阵.训练样本集在投影基矩阵上进行投影,构成训练样本空间.

第四步,对测试样本进行第一步和第二步的预处理,然后在第三步中的投影基矩阵上进行投影,构成测试样本空间.

第五步,KNN 作为分类器进行分类,并自动计算算法识别率和识别时间,输出结果.

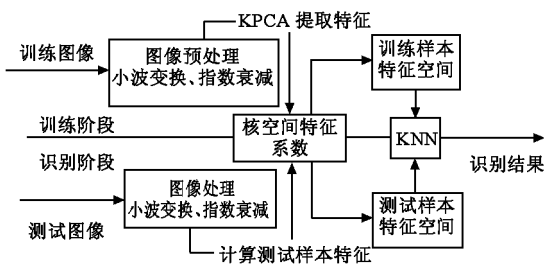


图4 本文算法流程图
Fig.4 The sketch map of algorithm

5 实验结果

5.1 实验环境

本文实验是在 Intel Core™ Duo processor T5500 1.66 GHz, 内存 512 M, Windows xp sp2 机器上利用 Matlab 7.0 编程实现的. 使用 ORL 人脸数据库作为数据集, ORL 标准人脸库(英国剑桥大学 Olivetti Research Laboratory 提供的识别用脸库)有 40 个人的 人脸图像, 每人有 10 幅 112×92 像素的人脸图像, 256 级灰度. 其中人的脸部表情和脸部细节有着不同程度的变化, 如笑或不笑, 眼睛睁或闭, 戴或不戴眼镜等; 人脸姿态也有相当程度的变化, 深度旋转和平面旋转可达 20° ; 人脸的尺度也有多达 10% 的变化.

5.2 实验结果与分析

实验 1 预处理手段对识别性能的影响. 实验选择 ORL 人脸数据库每人前 5 幅图像进行训练, 剩下 5 幅进行测试, 这样训练样本集和测试样本集的样本数均为 200. 为了实验的方便性, 选择多项式核函数的次数 $d = 1$. 实验分别比较了 KPCA + KNN, ED(指数衰减) + KPCA + KNN, WT(小波变换) + KPCA + KNN 和同时采用指数衰减 + 小波变换的 KPCA + KNN 算法(本文改进方法)的识别性能, 表 1 给出了上述 4 种算法达到最优识别率时的主分量数, 识别率、训练时间、测试时间和单个样本识别时间, 其中单个样本识别时间 = (识别时间 + 测试时间)/200.

实验 2 单样本训练情况下, 各算法的识别性能比较. 人脸识别是典型的小样本训练识别问题, 为了说明本文算法的有效性, 选择每人的第 1 幅图像作为训练样本, 剩下的 9 幅进行测试. 比较了线性方法 PCA, 2DPCA 和非线性方法 KPCA + KNN, KPCA + SVM 及本文方法的识别率. 结果如表 2 所示.

表 1 不同算法识别性能比较

Table 1 Comparison of recognition performance based on different methods

序号	算法名称	主分量数	正确率/%	训练时间/s	测试时间/s	单个样本识别时间/s
1	KPCA + KNN	34	87.00	12.92	8.26	0.106
2	ED + KPCA + KNN	32	92.50	13.03	9.02	0.110
3	WT + KPCA + KNN	34	89.00	4.13	7.55	0.058
4	ED + WT + KPCA + KNN	36	95.00	4.12	7.80	0.059

表 2 各种算法最优识别率比较

Table 2 Comparison of top performance

算法名称	PCA	2DPCA	KPCA + KNN	KPCA + SVM	WT + KPCA + KNN
识别率/%	68.61	70.56	72.78	76.39	79.17

从表 1 可以看出,采用指数衰减的方法 2 和 4 能够有效克服 KPCA 算法对光照变化的敏感,算法识别率明显高于没有采用指数衰减的方法 1 和 3;引入小波变换预处理后,除去了干扰分类器分类的一些非线性因素,识别率也有近 2% 的提高,另外即使识别过程中离散小波分解增加了系统开销,但在单个样本识别时间上,引入小波分解的方法 3 和 4 均低于没有使用小波分解的方法 1 和 2.

表 2 显示在单样本训练情况下,本文算法识别率可达 79.17%,优于线性的 PCA,2DPCA 方法以及

表 3 核参数对识别算法性能的影响

Table 3 Comparison based on the different reference of kernel function

核参数 d	KPCA + KNN		KPCA + SVM		Wt + KPCA + KNN	
	识别率/%	识别时间/s	识别率/%	识别时间/s	识别率/%	识别时间/s
1	82.81	21.22	84.06	112.33	86.88	11.06
2	84.06	21.75	86.56	116.17	81.87	11.41
3	83.44	21.38	85.94	112.95	80.31	11.52
4	81.87	20.86	86.25	112.05	78.13	11.54
5	81.56	21.14	84.69	114.25	75.31	11.17

从表 3 的结果中看到:(1)总体随着多项式次数 d 的增加识别率反而下降,如 $d = 4, 5$ 时的识别率是低于 $d = 2, 3$ 时的,这说明不是多项式次数越高对识别就越有利,过复杂的多项式函数反而会降低识别性能.(2)前 2 种方法在 $d = 2$ (非线性情况)下达到最优识别率,这是因为非线性情况下 KPCA 提取到更多有利于分类器分类的非线性特征;而本文方法在 $d = 1$ (线性情况下)达到最优识别率, $d \geq 2$ 的非线性情况反而识别率有所下降.这是因为小波分解过程中低频子图 LL 部分是人脸的平滑像,人脸的姿态、角度、表情特征集中在其它部分,如 LH 描述了人脸的姿态.在小波分解的过程中选择 LL 部分作为人脸的近似,已经很大程度上减少了光照、角度等非线性因素对分类器的影响,当 $d \geq 2$ 时通过非线性方法的特征提取反而带入了不利于 KNN 分类的无关非线性特征,所以本文算法在 $d \geq 2$ 的识别性能不如 $d = 1$ 的线性情况.(3)识别时间上,无论 d 如何变化本文算法的识别时间均明显低于前 2 种方法,识别时间是 KPCA + KNN 的一半,是 KPCA + SVM 的近十分之一.

实验 4 不同训练样本训练情况下,各算法的识别性能比较

图 5 给出了不同训练样本情况下,线性方法 PCA, 2DPCA, 非线性方法 KPCA + KNN 和本文提出的预处理 + KPCA + KNN 4 种方法的识别率比较,由图 5 可清楚地看到在少数样本训练情况下,本文提出的方法在识别率上明显优于其它 3 种方法.图 6 比较了没有经过小波预处理的 KPCA + KNN 方法和

非线性的 KPCA + KNN, KPCA + SVM 方法.在实际应用中,取得大量训练样本的代价巨大,因此具有小样本训练时的较高性能无疑具有重要的意义,从这个角度而言,本文方法具有较好的实用价值.

实验 3 核函数参数对识别率的影响

实验中选择 ORL 每人前 2 幅图像训练,剩下样本进行测试,主分量数选择 40,且均使用了指数衰减的预处理.比较了多项式次数 d 从 1 到 5 的变化中对 KPCA + KNN, KPCA + SVM 和本文方法的识别性能影响,表 3 给出了实验结果.

本文方法的识别时间,从结果来看本文提出的方法在识别时间上明显少于 KPCA + KNN 方法.所以认为在 KPCA 方法中使用指数衰减和小波变换的预处理手段不但能够克服光照变化对算法的影响,除去干扰分类器分类的一些非线性因素,有效提高识别精度,还能有效降低数据维数,减少算法对计算机硬件的要求,提高识别效率.




图 5 各种算法识别性能比较

Fig.5 Comparison of four methods




图 6 识别时间比较

Fig.6 Comparison of running time

(上接第100页)

5 结束语

本文通过小波变换对训练样本图像进行了预处理,有效地降低了训练样本的维数,并结合指数衰减因子作用于图像,很大程度上克服了光照等非线性因素对分类的影响,提取到了更有利于分类的特征.实验结果表明本文算法能够取得优于PCA,2DPCA和KPCA+KNN方法的识别性能.同时也看到指数衰减因子需要实验方法确定,小波分解过程中基函数和分解层数的选择对识别率有着不同程度的影响,如何在算法中自适应地选择这些参数将是进一步研究的问题之一;另外文中实验部分SVM分类器在小样本训练情况下表现出了良好的分类特性,能否通过本文提出的预处理方法进一步提高KPCA+SVM算法的性能也将是下一步将要进行的工作.

参考文献:

- [1] TURK M, PENTLAND A. Eigenfaces for recognition[J]. Journal of Cognitive Neuroscience, 1991, 3(1):71-86.
- [2] Peter N Belhumeur, Joao P Hespanha, David J Kriegman. Eigenfaces vs fisherfaces: Recognition using class specific linear projection[J]. IEEE Trans on Pattern Anal Machine Intell, 1997, 19(7):711-720
- [3] 杨健,杨静宇.具有统计不相关性的图像投影鉴别分析及人脸识别[J].计算机研究与发展,2003,40(3):447-452.
- [4] YANG J, ZHANG D, YANG J Y. Two-dimensional PCA: A new approach to appearance-based face representation and recognition[J]. IEEE Trans. on Pattern Anal Machine Intell, 2004, 26(1):131-137.
- [5] SCH ÖLKOPF B, MIKA S, BURGESS C, et al. Input space vs feature space in kernel-based method[J]. IEEE Trans Neural Networks, 1999(10):1000-1017.
- [6] SCH ÖLKOPF B, SMOLA A, ROBERT MULLER K. Nonlinear component analysis as a kernel eigenvalue problem[J]. Neural computer, 1998(10):1299-1319.
- [7] MOGHADDAM B. Principal manifolds and probabilistic subspaces for visual recognition[J]. IEEE Tran On Pattern Analysis and Machine Intelligence, 2002, 24(6):780-788.
- [8] 郝文化. MATLAB图形图像处理应用教程[M].北京:中国水利水电出版社,2004.
- [9] NASTAR C, AYACHE N. Frequency-based non-rigid motion analysis[J]. IEEE Trans Pattern Anal Machine Intell, 1996, 18(11):1067-1079.
- [10] MALLAT S. A theory for multiresolution signal decomposition: The wavelet representation[J]. IEEE Trans Pattern Anal Mach intell, 1989, 11(7):674-693.
- [11] ZHANG D Q, CHEN S C, ZHOU Z H. Non-negative matrix factorization on kernels[C]// Proceedings of the 9th pacific rim international conference on artificial intelligence (PRICAI'06). Guilin, China: LNAI 4099, 2006:404-412.

(编辑:孙培芹)