

基于监督拉普拉斯特征映射算法的人脸识别

沈杰¹, 嵇春梅², 王正群³, 王明辉¹, 钱亚芹¹

- (1. 盐城工学院 现代教育技术中心, 江苏 盐城 224051;
2. 盐城工业职业技术学院 机电工程学院, 江苏 盐城 224005;
3. 扬州大学 信息工程学院, 江苏 扬州 225009)

摘要: 为了提高人脸识别算法的识别率, 提出了一种基于局部奇异值分解(Local Singular Value Decomposition, LSVD)和监督拉普拉斯特征映射(Supervised Laplacian Eigenmap, SLE)的人脸图像识别方法。由于奇异值向量具有良好的稳定性、转置不变性等特点, 首先利用局部奇异值分解方法从人脸图像中提取特征向量; 然后采用监督拉普拉斯特征映射算法对已获取的人脸特征进行维数约简。在Yale和ORL人脸库上的实验结果表明, 该算法能有效地提高人脸识别的性能。

关键词: 人脸识别; 流形学习; 局部奇异值分解; 监督拉普拉斯特征映射

中图分类号: TP391.4

文献标识码: A

文章编号: 1671-5322(2016)04-0016-05

人脸识别技术是模式识别领域的一个热门研究课题。人脸识别在非侵犯性、并发性、操作性、隐蔽性等方面比其他识别方法如指纹识别、虹膜识别、语音识别都有着明显的优势, 在智能领域有着良好的应用前景。人脸识别方法的效果往往取决于研究人员对人脸脸部特征的抽取。特征抽取的主要目标是通过优化的特征提取算法获取最重要的、具有典型特征的信息, 从而实现数据的维数约简, 提高识别系统的准确率和效率。

子空间分析方法是研究人员进行特征提取的一种常用手段, 具有计算复杂度小、描述能力强以及分离效果好等特点, 其代表性的算法有主成分分析(Principal Component Analysis, PCA)和线性判别分析(Linear Discriminant Analysis, LDA)^[1]。为了有效提取人脸的非线性特征, 核方法被成功应用于人脸识别领域, 出现了核主成分分析^[2](Kernel Principal Component Analysis, KPCA)、核Fisher判别^[3](Kernel Fisher Discriminant, KFD)等非线性特征提取算法。基于核函数的方法能够较好地提取数据的全局结构特征, 但往往忽略了数据的局部结构特征。随后出现了一种称为流形

学习(Manifold Learning, ML)的方法, 为研究者分析处理图像提供了一个新的方向^[4]。

首次引入术语“Manifold Learning”的是《Science》2000年发表的3篇论文^[5-7], 文章深入地探讨了流形学习方法并给出了相关算法, 此后越来越多的研究者开始关注流形学习方法。流形学习的最终目的是发现隐藏在低维采样数据中的低维流形结构, 以实现维数约简或数据可视化, 从而提取出易于识别的特征。由于流形学习算法能较好地保持训练集原始数据的拓扑结构不发生变化, 有效地解决高维数据和非线性数据处理时出现的诸多问题, 因此, 当数据集在高维空间呈现高度扭曲时, 流形学习算法能够很好地发现嵌入在数据集中的非线性结构, 并恢复其内在在局部结构。

作为流形学习方法的2种典型算法——局部线性嵌入^[7](Locally Linear Embedding, LLE)和拉普拉斯特征映射^[8](Laplacian Eigenmap, LE), 在有效实现降维的同时都存在一个共同的缺陷, 即忽视了数据样本类别的相关信息, 而且又都是在非监督情况下学习的。

针对传统流形学习算法非监督学习的缺陷,

收稿日期: 2016-06-23

基金项目: 国家自然科学基金面上项目(61402395); 江苏省文化科研项目(15YB38); 江苏省现代教育技术研究课题(47937)

作者简介: 沈杰(1974—), 男, 江苏盐城人, 讲师, 硕士, 主要研究方向为人工智能与模式识别。

本文提出了一种基于局部奇异值分解^[9] (Local Singular Value Decomposition, LSVD) 和监督拉普拉斯特征映射^[10] (Supervised Laplacian Eigenmap, SLE) 的人脸图像识别方法。LSVD 方法将人脸图像分割为多个采样窗口并计算其局部奇异值向量,可以有效地增加识别特征量,更好地反映人脸局部特征的个体差异;SLE 算法在运行过程中增加了样本的标签信息,很好地弥补了 LE 算法非监督学习的缺陷。运用本文 LSVD + SLE 算法与 LE 算法对 Yale 和 ORL 人脸库进行识别测试,验证了本文 LSVD + SLE 算法所获取的识别率远高于 LE 算法。

1 局部奇异值分解 (LSVD)

奇异值分解 (Singular Value Decomposition, SVD) 为抽取图像的代数特征提供了新的途径,它应用广泛,是数据压缩、信号处理的常用方法。若矩阵 $A_{m \times n}$ 代表一幅图像,使用奇异值对矩阵进行分解

$$A = U\Sigma V^T \quad (1)$$

其中: Σ 是一个对角矩阵, $\Sigma = \text{diag}(\lambda_1, \lambda_2, \dots)$, U 和 V 是 2 个单位正交的矩阵。

如果 A 只有 k 个非零奇异值,则

$$A = \sum_{i=1}^k \lambda_i u_i v_i^T \quad (2)$$

其中 u_i 和 v_i 是 U 和 V 的各个列。记 $S_{n \times 1} = (\lambda_1, \lambda_2, \dots, \lambda_k, 0, \dots, 0)^T$ 为矩阵 A 的奇异值向量。

洪子泉^[11] 最早将奇异值分解应用于人脸识别,并取得了较好的效果。随着研究的深入,奇异值分解方法得到了进一步的发展和补充,但它们都是对整幅人脸图像进行奇异值分解,其缺陷是无法获得人脸识别所需的足够信息。本文采用 LSVD 的方法来提取人脸特征^[9],按照一定规则将人脸图像分割成多个采样窗口,然后取它们的局部奇异值向量,让其构成识别特征向量,这样可以更合理、更充分地挖掘图像的原始信息,很好地解决了前人取整幅图像的奇异值向量带来信息量不足的问题。

一幅标准人脸图像的分割策略如图 1 所示,每个采样窗口产生一组局部奇异值向量,各组向量按照采样窗口在人脸图像中的位置,由上至下、由左至右进行排列,生成一幅人脸图像的特征值序列。由于 Yale 和 ORL 人脸库中的人脸图像尺

寸不同,在后续实验部分对 Yale 库中的人脸图像进行垂直方向 10 等份、水平方向 8 等份,对 ORL 库中的人脸图像进行垂直方向 8 等份、水平方向 4 等份。另外本文算法中局部奇异值向量的后几个值都比较小,接近于零,故本文对每个采样窗口的局部奇异值向量仅取其前 6 位。



图 1 人脸分割策略

Fig. 1 Strategy of face segmentation

2 拉普拉斯特征映射算法 (LE)

LE 算法是由 Belkin 和 Niyogi 于 2003 年提出的一种基于局部的流形学习算法^[8],它的基本思想是用拉普拉斯算子来表示流形的局部特征。假设高维空间 R^D 中有一组样本数据集 $X = \{x_1, x_2, \dots, x_N\}$, $x_i \in R^D$,通过映射: $f: R^D \rightarrow R^d$ ($d \ll D$),得到其在低维嵌入空间 R^d 上的映射数据集 $Y = \{y_1, y_2, \dots, y_N\}$, $y_i \in R^d$, ($d \ll D$)。

LE 算法的具体步骤如下^[12]:

步骤 1: 邻域的确定。对高维数据集中的每个样本点 x_i , 计算其近邻数据点 (常用方法有 K 近邻法或 ε 邻域方法)。

步骤 2: 根据邻域关系构造权值矩阵 W 。样本点间的权值计算,有 2 种方法:

简约法: 如果 x_i 和 x_j 互为近邻点,则两点之间的权值 $w_{ij} = 1$, 否则 $w_{ij} = 0$ 。

热核函数法: 若 x_i 和 x_j 属于邻域关系,那么这两个样本点间的权值可通过热核函数来描述

$$w_{ij} = e^{-\frac{\|x_i - x_j\|^2}{t}} \quad (3)$$

否则 $w_{ij} = 0$ 。

本文在计算权值矩阵 W 时,选用的是热核函数法。

步骤 3: 计算映射结果。在 LE 算法中目标函

数为:

$$\min \sum_{i,j} (y_i - y_j)^2 w_{ij} \quad (4)$$

可用广义特征值求解的方法来实现低维映射结果的计算,如下式:

$$LY = \lambda DY \quad (5)$$

其中, D 为对角矩阵, $D_{ii} = \sum_j w_{ij}$, $L = D - W$ 为拉普拉斯矩阵。

设 $\lambda_1 \cdots \lambda_d$ 为式(5)求解的最小的前 d 个非零特征值,则其所对应的特征向量就是高维数据的低维嵌入结果。

3 监督拉普拉斯特征映射算法(SLE)

为了克服 LE 算法非监督学习方法的缺陷,张建波等^[10]提出了一种有监督的拉普拉斯特征映射(SLE)算法,即在计算距离矩阵的时候引入样本的标签信息,使得样本邻域的构造更为准确、合理。

$$D(x_i, x_j) = \begin{cases} \sqrt{1 - \exp(-d^2(x_i, x_j)/\beta)} & (c_i = c_j) \\ \sqrt{\exp(d^2(x_i, x_j)/\beta)} & (c_i \neq c_j) \end{cases} \quad (6)$$

其中: c_i, c_j 表示样本 x_i, x_j 的类别; $d(x_i, x_j)$ 表示样本 x_i, x_j 的欧氏距离; 参数 β 可以防止 $d(x_i, x_j)$ 取值较大时 $D(x_i, x_j)$ 增长过快,能有效地实现对噪声的抑制。

SLE 算法和 LE 算法的区别主要在于步骤 1, 即邻域的构造方法不尽相同, 二者的其它步骤基本相同。SLE 算法在算法运行过程中增加了样本的标签信息, 通过带标签的样本重新计算距离矩阵, 将不同类别的标签样本有效进行了分离, 同时取得了很好的降维效果。

针对人脸识别问题, 本文引入 LSVD 方法来提取人脸特征, 然后采用 SLE 算法对已获取的人脸特征进行维数约简。由于考虑了样本的类别信息, LSVD + SLE 算法可以获得更优化且适合分类识别的人脸识别特征, 有效地提高了人脸识别的性能。

4 实验结果及分析

在 Yale 和 ORL 人脸库对 LE 算法和 LSVD + SLE 算法的识别性能、相关参数的选择进行了测试及分析(取多次重复实验的平均值), 其中 Yale 人脸库存储了 15 个人(人均 11 幅)不同光照、表情姿态各异的正面人脸图像, 每人随机取 5 幅进

行训练, 剩余 6 幅进行测试; ORL 人脸库存储了 40 个人(人均 10 幅)均匀光照条件下不同表情姿态的正面人脸图像, 每人随机取 5 幅进行训练, 剩余 5 幅进行测试。

2 种算法中参数 k 值(邻域数目)的变化对识别率产生的影响如图 2 ~ 图 3 所示。由图 2 可见, Yale 人脸库上, 当 $k = 4$ 或 $k = 8$ 时, LE 算法获得最高识别率; 当 $k = 6$ 或 $k = 8$ 时, LSVD + SLE 算法获得最高识别率。由图 3 可见, ORL 人脸库上, 当 $k = 4$ 时, LE 算法获得最高识别率; 当 $k = 6$ 或 $k = 8$ 时, LSVD + SLE 算法获得最高识别率。

显然参数 k 值对算法的识别率有着一定的影响, 从图 2 和图 3 可见, 当 k 值在一定区间范围内逐渐增大时识别率会相应有所提高; 当 k 值继续增大且超过某一临界值之后, 识别率逐渐成下降趋势, 最终处于稳定。另综合图 2、图 3 可见, 当 k 值恒定时, LSVD + SLE 算法识别效果远优于 LE 算法。

通过此轮实验可以确定 LE 算法与 LSVD + SLE 算法中参数 k 的取值, 后续实验环节, Yale 和 ORL 人脸库上, LE 算法邻域数目 k 取值为 4, LSVD + SLE 算法邻域数目 k 取值为 6。

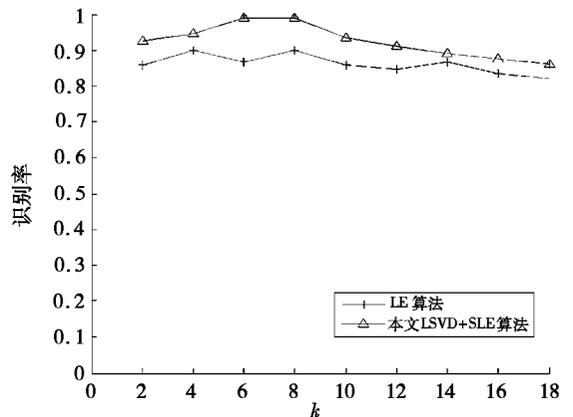


图 2 k 值变化对识别率的影响(Yale 人脸库)
Fig. 2 Influence of the change of k value on recognition rate (face database of Yale)

2 种算法中参数 d 值(特征维数)的变化对识别率产生的影响如图 4 ~ 图 5 所示。由图 4 可见, Yale 人脸库上, 当 $d = 40$ 时, LE 算法获得最高识别率(90%); 当 $d = 15$ 或 $d = 20$ 时, LSVD + SLE 算法获得最高识别率(99%)。由图 5 可见, ORL 人脸库上, 当 $d = 40$ 时, LE 算法获得最高识别率(91.5%); 当 $d = 30$ 或 $d = 35$ 时, LSVD +

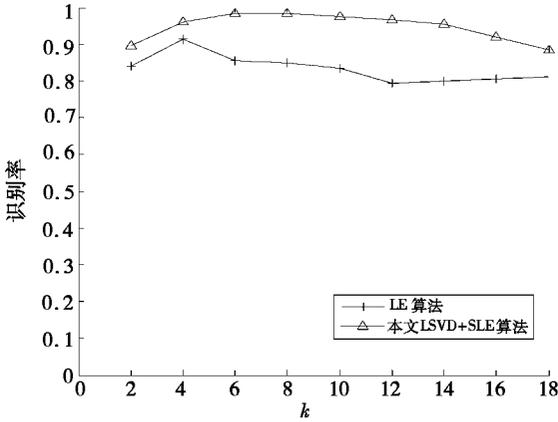


图 3 k 值变化对识别率的影响 (ORL 人脸库)

Fig. 3 Influence of the change of k value on recognition rate (face database of ORL)

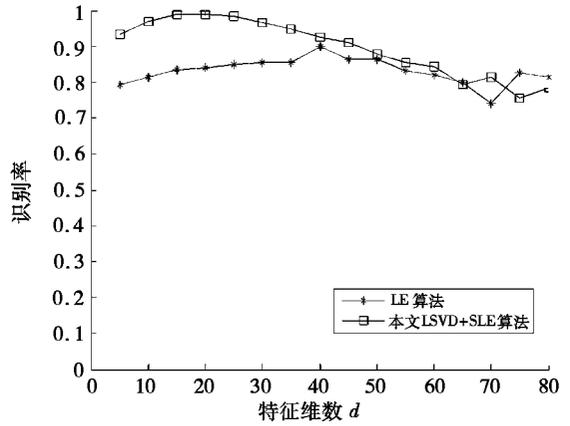


图 4 d 值变化对识别率的影响 (Yale 人脸库)

Fig. 4 Influence of the change of d value on recognition rate (face database of Yale)

SLE 算法获得最高识别率 (98.5%)。

显然,参数 d 值对算法的识别率有着明显的影响,从图 4 和图 5 可见,当 d 值从低值区间逐渐增大时识别率会逐渐提高 (ORL 人脸库 LE 算法有波动,但整体呈上升趋势),中途识别率会出现峰值;当 d 值继续增大且超过某一临界值之后,识别率逐渐回落 (有小幅波动) 并趋向于稳定。另综合图 4、图 5 可见,当 d 值恒定时,LSVD + SLE 算法的识别效果远优于 LE 算法。

识别率和分类识别时间是衡量一个算法性能优劣的 2 个重要指标,本文对上述 2 种算法的平均识别率和分类识别时间 (基于 Yale 和 ORL 人脸库) 进行了比较,如表 1 所示。由表 1 可见, Yale 和 ORL 人脸库上,LSVD + SLE 算法获取的识别率分别是 99% 和 98.5%,远远高于 LE 算法; LSVD + SLE 算法对一幅测试图像的分类识别时间分别是 6.5 ms 和 7.2 ms,基本控制在 8 ms 以内,与 LE 算法大致持平。

LSVD 方法提取人脸特征,可以更充分地挖掘人脸图像的原始信息,增加有效识别特征量; SLE 算法引入样本的标签信息重新计算距离矩

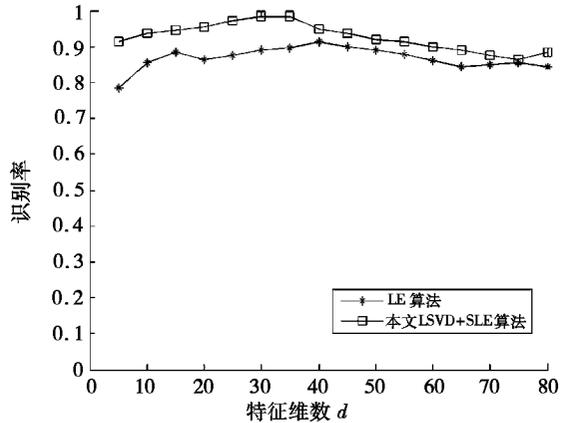


图 5 d 值变化对识别率的影响 (ORL 人脸库)

Fig. 5 Influence of the change of d value on recognition rate (face database of ORL)

阵,可以获取比 LE 算法更为准确的样本邻域,故而 LSVD + SLE 算法可以比 LE 算法获取更好的识别效果。实验结果进一步证明了 LSVD + SLE 算法实时性好,以较小的代价有效地提高了人脸识别算法的识别率。

表 1 两算法的平均识别率及分类识别时间比较 (Yale 和 ORL 人脸库)

Table 1 Comparison between the average recognition rate and classification recognition time of two algorithms (face database of Yale and ORL)

算法名称	Yale 人脸库		ORL 人脸库	
	识别率/%	识别时间/ms	识别率/%	识别时间/ms
LE	90.0	6.0	91.5	7.1
LSVD + SLE	99.0	6.5	98.5	7.2

5 结论

本文在拉普拉斯特征映射(LE)算法分析的基础上提出了一种基于局部奇异值分解(LSVD)和监督拉普拉斯特征映射(SLE)的人脸图像识别方法。首先利用 LSVD 方法将人脸图像分割为多个采样窗口并计算其局部奇异值向量;然后针对 LE 算法非监督学习的缺陷对其进行改进,采用

SLE 算法对已获取的人脸特征进行维数约简。由于考虑了样本的类别信息,本文 LSVD + SLE 算法可以获得良好的降维效果并有效地实现样本分离。

在 Yale 和 ORL 人脸库上的实验结果表明,本文提出的 LSVD + SLE 算法在降维效果和识别率方面都表现出众;从试验的角度看,本文算法有效地提高了人脸识别的性能,满足现代工程应用的技术性能要求。

参考文献:

[1] 袁正海. 人脸识别系统及关键技术研究[D]. 南京:南京邮电大学,2013.

[2] KIM K I, JUNG K, HANG J K. Face recognition using kernel principal component analysis[J]. IEEE Signal Processing Letters, 2002,9(2):40-42.

[3] YANG J, FRANGI A F, YANG J Y. A new kernel Fisher discriminant algorithm with application to face recognition[J]. Neurocomputing, 2004,56:415-421.

[4] 黄璞. 基于流形学习的特征提取与人脸识别研究[D]. 南京:南京理工大学,2014.

[5] SEUNG H S, LEE D D. The manifold ways of perception[J]. Science, 2000,290(5 500):2 268-2 269.

[6] TENENBAUM J B, DE SILVA V, LANGFORD J C. A global geometric framework for nonlinear dimensionality reduction [J]. Science, 2000, 290(5 500):2 319-2 323.

[7] ROWEIS S T, SAUL L K. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000,290(5 500):2 323-2 326.

[8] BELKIN M, NIYOI P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. Neural Computation, 2003,15(6):1 373-1 396.

[9] 沈杰. 一种基于局部奇异值分解和最近邻决策规则的人脸识别方法[J]. 盐城工学院学报(自然科学版),2009,22(3):51-54.

[10] 张建波,朱敏琛. 基于监督学习的核拉普拉斯特征映射分类方法[J]. 福州大学学报(自然科学版),2011,39(1):49-53.

[11] HONG Z Q. Algebraic feature extraction of image for recognition[J]. Pattern Recognition, 1991,24(3):211-219.

[12] 王建中. 基于流形学习的数据降维方法及其在人脸识别中的应用[D]. 长春:东北师范大学,2010.

Face Recognition Based on Supervised Laplacian Eigenmap Algorithm

SHEN Jie¹, JI Chunmei², WANG Zhengqun³, WANG Minghui¹, QIAN Yaqin¹

(1. Modern Educational Technology Center, Yancheng Institute of Technology, Yancheng Jiangsu 224051, China;
 2. College of Mechanical and Electrical Engineering, Yancheng Vocational Institute of Industry Technology, Yancheng Jiangsu 224005, China;
 3. College of Information Engineering, Yangzhou University, Yangzhou Jiangsu 225009, China

Abstract: Because of the characteristics such as good stability and transpose invariance of singular value vector, feature vectors are extracted from face image by using local singular value decomposition method firstly. Then dimensionality reduction is applied on facial features which have been acquired by supervised laplacian eigenmap algorithm. Experimental results on Yale and ORL face database show that the proposed algorithm can effectively improve the performance of face recognition.

Keywords: face recognition; manifold learning; local singular value decomposition; supervised laplacian eigenmap

(责任编辑:李华云)