

文章编号 1004-924X(2008)08-1471-07

基于有监督核局部线性嵌入的面部表情识别

黄 鸿, 李见为, 冯海亮

(重庆大学 光电技术及系统教育部重点实验室, 重庆 400030)

摘要:提出了一种新的有监督核局部线性嵌入算法(SKLE),并将算法应用于面部表情识别中。该算法通过非线性核映射将人脸图像样本投影到高维核空间,然后将人脸图像局部流形的结构信息和样本的类别信息有效地结合进行维数约简,提取低维鉴别流形特征用于表情分类。SKLE算法不仅能发现嵌入了高维人脸图像空间的低维表情子流形,增强了局部类间的联系,而且对新样本有较好的泛化性。基于JAFFE面部表情库的实验结果表明,该方法能很好地实现维数约简,达到最高识别率(100%)所需的鉴别维数仅为二维,有效地提高了面部表情识别的性能。

关键词:流形学习;核技巧;局部线性嵌入;有监督学习;面部表情识别

中图分类号:TP391.41 文献标识码:A

Facial expression recognition based on supervised kernel local linear embedding

HUANG Hong, LI Jian-wei, FENG Hai-liang

(Key Laboratory of Opto-electronic Technology & System of the Ministry of Education, Chongqing University, Chongqing 400030, China)

Abstract: A novel supervised kernel local linear embedding (SKLE) method is introduced to facial expression recognition, which maps face images to a high dimensional kernel space through nonlinear kernel mapping, then fuses prior class-label information and nonlinear facial expression submanifold of real face images to extract discriminative features for expression classification. SKLE can not only gain a perfect approximation of facial expression manifold, and enhance local within-class relations, but also can do well on the new samples. The experimental results on JAFFE database show that the proposed method can achieve the highest recognition rate (100%) using only 2D embedding feature vectors, which improves face expression classification performance effectively.

Key words: manifold learning; kernel trick; Local Linear Embedding (LLE); supervised learning; facial expression recognition

1 引言

人脸是人类最重要的生物特征之一,它反映了很多重要的人口统计信息,如表情、性别和种族等。面部表情识别是计算机自动表情识别的简称,指利用计算机对人脸的表情信息进行特征提取,按照人的认识和思维方式加以归类和理解,进而从人脸信息中去分析理解人的情绪,如快乐、惊奇、愤怒、恐惧、厌恶、悲伤等^[1-3],是模式识别、计算机视觉等相关领域的研究热点课题。面部表情识别技术具有广泛的用途,主要包括:智能人机接口、人工智能、情感机器人、网络教育、汽车辅助驾驶等。

面部表情识别是个极富挑战的课题,涉及多学科的发展,如心理学、计算机视觉、模式识别、认知科学等。目前,面部表情识别算法大致可以分为两类:基于表观的方法(Appearance-based Methods)、基于几何特征的方法(Geometric Feature-based Methods)^[4-5]。其中基于表观的方法将整个人脸区域作为识别系统的输入,不依赖于人脸的先验知识和参考模型,一直以来都是面部表情识别的研究热点。

维数约简是基于表观方法中的一个重要环节,其主要目标是在获得最优、最显著特征的同时丢弃无关或次要的信息,减小数据的维数以降低分类系统的复杂性^[6-7]。维数约简可以分为线性和非线性两类,线性方法主要有主成分分析(Principal Component Analysis, PCA)、Fisher 判别分析(Fisher Discrimination Analysis, FDA)等,但是它们对非线性结构的数据就无能为力了。随着核方法的成功应用,出现了如 KPCA(Kernel PCA)、KFDA(Kernel FDA)等方法,并将其引入生物特征识别领域^[8]。近年来,有科学家提出人脸图像很可能位于一个低维的非线性子流形上,可以将高维输入数据点映射到一个全局低维坐标系,既能够降低数据维数、减少运算,又能很好地保留各类人脸样本的拓扑结构,其中具有代表性的流形学习方法有等距映射(Isometric Feature Mapping, ISOMAP)^[9]、局部线性嵌入(Local Linear Embedding, LLE)^[10]和拉普拉斯本征映射(Laplacian Eigenmaps, LE)^[11]等。但这些算法都算是属于无监督学习方法,未能充分利用样

本类别信息,因而并不适合分类,而且这些方法都是批处理模式,不能直接取新样本的特征,致使其不能直接对新样本进行分类,从而限制了流形学习算法的应用。Oleg 等提出了监督局部线性嵌入算法(Supervised LLE, SLLE)^[12],将在保留人脸局部流形结构的同时引入样本类别信息,将 LLE 扩展成为有监督的流形学习方法,取得了不错的分类效果,但是 SLLE 算法依然不能有效地解决新样本的问题。

本文提出了一种新的有监督的核局部线性嵌入算法(Supervised Kernel Local Linear Embedding, SKLLE)。该算法通过非线性核映射将人脸样本投影到高维核空间,然后将人脸表情的局部流形结构信息和样本的类别信息有效地结合进行维数约简,提取低维鉴别表情流形特征用于分类。实验结果表明该算法具有非常好的识别效果。

2 算法介绍

2.1 局部线性嵌入(LLE)

LLE^[10]算法的目的在于对在高维欧氏空间 \mathbf{R}^D 中的高维数据集 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N\}$, 将这些样本映射到一个低维空间 $\mathbf{R}^d (d \ll D)$ 中, 得到 \mathbf{X} 的低维嵌入为 $\mathbf{Y} = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N\}$ 。LLE 的主要思想是认为流形上每一个局部邻域内的任意一点都可以描述为邻域内其他点的线性表示。通过最小化这种线性表示的误差,可建立如下模型

$$J_{\text{LLE}} = \operatorname{argmin} \sum_{i=1}^n \left\| \mathbf{y}_i - \sum_{j=1}^k \omega_{ij} \mathbf{y}_j \right\|^2, \quad (1)$$

约束条件为: $\sum_{i=1}^n \mathbf{y}_i = 0, \mathbf{Y}^T \mathbf{Y} = \mathbf{I}$ 。利用 Lagrange 乘法,该模型可以转化为方程

$$\mathbf{M}\mathbf{Y} = \lambda\mathbf{Y}, \quad (2)$$

的特征值求解问题,式中 $\mathbf{M} = (\mathbf{I} - \mathbf{W})^T (\mathbf{I} - \mathbf{W})$ 。

从上述算法可知,利用线性重构的局部对称性质,LLE 能够学习非线性流形的全局结构,比如从人脸和文本图像中学习到有意义的特征等。本文对 75 幅表情图像进行 LLE 嵌入实验,图像分辨率为 64 pixel \times 64 pixel,近邻 $k=12$,其二维嵌入如图 1 所示,从图 1 可以看出,LLE 算法能够有效地学习人脸表情的流形结构,充分反映面部表情从高兴到悲伤和从惊奇到愤怒的变化过程。




图 1 投影到二维嵌入空间的数据点和对应的人脸表情图像

Fig. 1 Projecting data points in two-dimensional embedded space and corresponding images

2.2 监督局部线性嵌入(SLLE)

针对 LLE 未能利用样本类别信息的缺点, Dick 等提出了一种有监督的 LLE 算法, 即 SLLE^[12]。传统的 LLE 算法在第一步时根据样本点间的欧氏距离来寻找 k 个近邻点, 而 SLLE 在处理这一步时, 增加了样本点的类别信息。SLLE 的其余步骤同 LLE 算法是一致的。

SLLE 算法在计算点与点之间的距离时, 采用如下公式:

$$D' = D + \alpha \max(D)\Delta, \quad (3)$$

式中, D' 是计算后的距离; D 定义为样本之间的距离; $\max(D)$ 是表示类与类之间的最大距离; Δ 取 0 或者 1, 当两点属于同类时, Δ 取为 0, 否则取 1; α 是控制点集之间的距离参数, 是一个经验参数, 当 $\alpha=0$ 时, SLLE 和 LLE 算法相同。

2.3 监督核局部线性嵌入(SKLLLE)

根据 Mercer Kernel 理论, 核方法的思想能应用于 N 维点乘空间中由两点之间点乘形成的算法中, 于是出现了如 KPCA、KFDA 等核方法的成功应用, 并将其引入人脸识别中, 取得不错的识别效果, 而且在识别的泛化能力等方面具备优势^[13]。本文将核方法的思想引入 LLE 算法中, 并结合类别信息, 提出了有监督的核局部线性嵌入算法(SKLLLE)。

SKLLLE 算法的主要思想是在核空间使用结合样本类别信息的欧式距离来计算样本点的近邻点, 而不是像传统的 LLE 算法在原始数据空间中计算。SKLLLE 算法的具体步骤如下:

(1) 采用非线性映射函数 φ 将数据 X 映射到

高维特征空间 $F: \Phi(\mathbf{X}) = [(\varphi(\mathbf{x}_1), \varphi(\mathbf{x}_2), \dots, \varphi(\mathbf{x}_n))]$, 计算核空间中样本点 $\varphi(\mathbf{x}_i)$ 和 $\varphi(\mathbf{x}_j)$ 之间的距离, 距离定义如下:

$$d[\varphi(\mathbf{x}_i), \varphi(\mathbf{x}_j)] = \text{dist}[\varphi(\mathbf{x}_i), \varphi(\mathbf{x}_j)] = \sqrt{[\|\varphi(\mathbf{x}_i) - \varphi(\mathbf{x}_j)\|^2]}. \quad (4)$$

通过采用核技巧(Kernel Trick)直接计算距离

$$d[\varphi(\mathbf{x}_i), \varphi(\mathbf{x}_j)] = \sqrt{K_{ii} - 2K_{ij} + K_{jj}}, \quad (5)$$

式中, $K_{ij} = K(\mathbf{x}_i, \mathbf{x}_j) = \varphi(\mathbf{x}_i) \cdot \varphi(\mathbf{x}_j) = \varphi(\mathbf{x}_i)' \varphi(\mathbf{x}_j)$, K 为 Mercer 核。常用的 Mercer 核有以下三种:

$$\textcircled{1} \text{ 线性核: } K(\mathbf{u}, \mathbf{v}) = \mathbf{u} \cdot \mathbf{v} = \sum_{i=1}^d \mathbf{u}_i \cdot \mathbf{v}_i;$$

$\textcircled{2}$ 多项式核: $K(\mathbf{u}, \mathbf{v}) = (\mathbf{u} \cdot \mathbf{v} + r)^d$, 其中 d 为多项式度参数, r 为偏移量;

$$\textcircled{3} \text{ 高斯核: } K(\mathbf{u}, \mathbf{v}) = \exp(-\|\mathbf{u} - \mathbf{v}\|^2 / 2\sigma^2),$$

(2) 结合类别信息, 将距离公式改进为:

$$D[\varphi(\mathbf{x}_i), \varphi(\mathbf{x}_j)] = \begin{cases} \sqrt{1 - \exp[-d^2(\mathbf{x}_i, \mathbf{x}_j)/\beta]} & y_i = y_j \\ \sqrt{\exp[d^2(\mathbf{x}_i, \mathbf{x}_j)/\beta]} & y_i \neq y_j \end{cases}, \quad (6)$$

式中, y_i 和 y_j 表示 \mathbf{x}_i 和 \mathbf{x}_j 所属类别, 参数 β 用于防止在 $d[\varphi(\mathbf{x}_i), \varphi(\mathbf{x}_j)]$ 较大时 $D[\varphi(\mathbf{x}_i), \varphi(\mathbf{x}_j)]$ 增长过快。 $D[\varphi(\mathbf{x}_i), \varphi(\mathbf{x}_j)]$ 函数曲线如图 2 所示。




图 2 $D(\varphi(\mathbf{x}_i), \varphi(\mathbf{x}_j))$ 函数的曲线图

Fig. 2 Curve of $D(\varphi(\mathbf{x}_i), \varphi(\mathbf{x}_j))$ functions

从图 2 可知, 当欧式距离 $d(\varphi(\mathbf{x}_i), \varphi(\mathbf{x}_j))$ 相同时, 类内距离 < 1 , 类间距离 > 1 , 算法保证了类间距离比类内距离大, 因而 SKLLLE 适用于此类面部表情识别的模式分类问题。通过 $D(\varphi(\mathbf{x}_i), \varphi(\mathbf{x}_j))$ 计算每个点的 k 近邻。

(3) 通过 $\varphi(\mathbf{x}_i)$ 的近邻点计算 $\varphi(\mathbf{x}_i)$ 的线性重构的权值 W_{ij} , 使得

$$\min \varepsilon(W) = \sum_j \|\varphi(\mathbf{x}_i) - \sum_j w_{ij} \varphi(\mathbf{x}_j)\|^2, \quad (7)$$

式中, W_{ij} 是 $\varphi(\mathbf{x}_i)$ 与近邻点 $\varphi(\mathbf{x}_j)$ 之间的权值, 且满足: $\sum W_{ij} = 1$, W_{ij} 可以通过以下方法进行计算: 首先计算 $\varphi(\mathbf{x}_i)$ 的近邻协方差矩阵 C

$$C_{jk} = (\varphi(\mathbf{x}_i) - \varphi(\mathbf{x}_j))(\varphi(\mathbf{x}_i) - \varphi(\mathbf{x}_k)), \quad (8)$$

而后可以通过求解线性方程 $\sum CW=1$ 来求解 W_{ij} 。

(4) 通过稀疏矩阵 $M_{ij} = \delta_{ij} - w_{ij} - w_{ji} + \sum_k w_{ki} w_{kj}$ 来求解式(2)的特征向量。从而可以计算由 W_{ij} 最优重构的低维嵌入向量 \mathbf{y}_i 。

SKLLE 算法在有新样本 $t \in \mathbf{R}^D$ 时, 无需对样本重新训练, 可使用核技巧来得到新样本的低

维嵌入, 如下式所示

$$\mathbf{y}_j = \sum_{i=1}^N \mathbf{V}_{ij} k(\mathbf{x}_i, t), \quad (9)$$

式中 \mathbf{V}_{ij} 为式(2)中得到的特征向量, \mathbf{y}_j 为 \mathbf{Y} 的第 j 个元素。从式(9)可知, 进行新样本的低维嵌入时, 样本的类别信息将不会被使用。本文对 Swiss-roll 数据集进行试验, 验证 SKLLE 算法能否有效的获得新样本的低维嵌入, 如图 3 所示, 其中已填充的正方形表示新样本(20 个), 选择线性核, $k=12$ 。

图 3 中点(●)代表直接使用 SKLLE 进行低维嵌入后的数据, 填充正方形(■)代表使用本文方法对新样本进行嵌入的数据, 可以得知, SKLLE 方法可以有效的学习非线性流形的全局结构, 并且对新样本点有较好的嵌入效果。

在使用 SKLLE 将人脸图像特征映射到低维鉴别空间中后, 便可使用分类器进行分类。本文使用基于欧式距离的最近邻分类器进行分类。

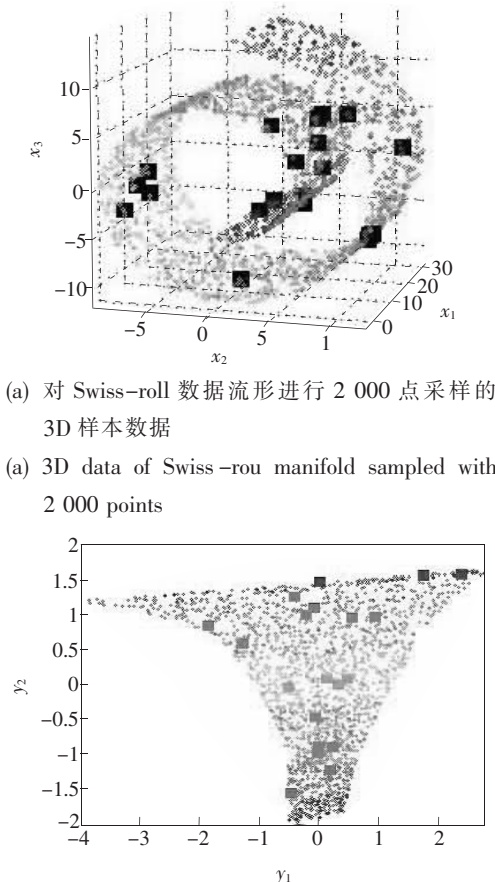
3 实验结果及分析

本文在 JAFFE 人脸表情库(简称 JAFFE 库)^[14]上对本文方法(SKLLE)与 PCA、KPCA、LLE、SLLE 等方法进行比较。JAFFE 库包含 10 个日本女生的 213 张人脸表情图像, 分辨率为 $256 \text{ pixel} \times 256 \text{ pixel}$, 灰度级为 256, 基本都是正面人脸图像, 每个人每种表情图像为 2~3 个。库中包括惊奇、恐惧、厌恶、愤怒、快乐、悲伤、中性(无表情)等 7 种基本表情, 这些图像充分反映了人脸的表情变化。在预处理阶段, 首先对其进行裁剪, 只包含人脸的表情部分, 将其分辨率调整为 $130 \text{ pixel} \times 150 \text{ pixel}$, 对其进行 1/4 的下采样, 达到 $65 \text{ pixel} \times 75 \text{ pixel}$ 的分辨率, 最后进行均值为 0 和方差为 1 的规格化。图 4 为 JAFFE 人脸表情库经过预处理后的图像示例。



图 4 JAFFE 人脸表情库的人脸图像示例。从左到右依次为: 愤怒、厌恶、恐惧、高兴、中性、悲伤、惊奇。

Fig. 4 Examples of seven images in JAFFE: anger, disgust, fear, happy, neutral, sadness and surprise (from left to right).



(a) 对 Swiss-roll 数据流形进行 2 000 点采样的 3D 样本数据
(a) 3D data of Swiss-roll manifold sampled with 2 000 points

(b) 使用 SKLLE 进行低维嵌入和新样本嵌入后的结果
(b) Result of low dimension embedded and new samples embedded with SKLLE algorithm

图 3 SKLLE 算法在 Swiss-roll 数据集上的泛化性实验
Fig. 3 SKLLE generalization on Swiss-roll dataset

在实验中与 LLE 相关的算法中用到的参数近邻 $k=12$, KPCA 和 SKLLE 方法中的核函数选择高斯核, 高斯核参数 $\sigma=1$ 。使用各种算法对预处理后的人脸表情图像进行维数约简, 再用最近邻分类器对嵌入的子流形特征进行分类。为了尽可能减少分类器对算法的影响, 对每个算法进行 10 次实验, 取其平均值。因 LLE 和 SLLE 算法不能直接对新样本进行学习, 得到低维嵌入坐标, 本文先使用这 5 种算法直接对所有样本进行训练来进行学习得到低维嵌入坐标, 然后分类比较各种算法的性能。在 JAFFE 库中, 每种表情约 30 幅图像, 在实验中, 每类每次随机选择 15 个样本, 共 105 个样本作为训练集, 其余 108 个作为测试集。图 5 为各种算法在 JAFFE 库中不同嵌入维数下的识别结果, 其对应的最高识别率和相应的鉴别维数由表 1 给出。

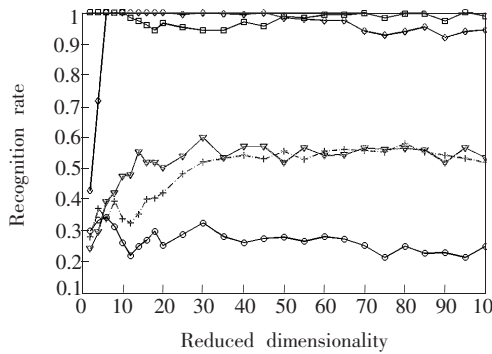


图 5 不同算法在 JAFFE 表情库的识别率与鉴别维数的关系

Fig. 5 Relation of recognition rate and reduced dimensionality at different methods

表 1 不同算法在 JAFFE 表情库的最高识别率及鉴别维数关系

Tab.1 Relation of the highest recognition accuracy and reduced dimensionality at different methods on JAFFE database

算法	PCA	KPCA	LLE	SLLE	SKLLE
最高识别率	67.62%	40%	63.81%	100%	100%
维数	55	24	65	6	2

从图 5 中总体识别结果来看, 不考虑鉴别性能的方法如 PCA 方法和 LLE 方法获得的识别曲线很相似, 都能尽可能地减少每一类的重建误差, 随着鉴别矢量数量的增加, 重建误差会越来越小,

识别率也会逐步上升, 但是由于没有考虑类别信息, 识别率的上升会有明显的极限, 所以识别效果不是非常理想。而 SLLE 与 SKLLE 方法在考虑类别重建的同时, 通过强调类之间的差异来突出鉴别性能, 因此能很快地达到最高的识别率, 但是随着鉴别矢量数目的增加, 会存在类似于"过拟合"的现象, 识别率有所下降, 但是要远优于非监督的维数约简方法。KPCA 方法由于其本身固有的不能得到一个可表示的子空间的缺点, 识别效果较差, 但是 SKLLE 方法有效地克服了此缺点, 它利用核技巧将样本映射到高维核空间, 而后通过 LLE 的思想得到样本的低维嵌入子流形, 所以识别效果很好。

从维数约简的目的来看, 在表 1 中相对其他算法, 基于监督流形学习的方法达到最高识别率所需要的鉴别维数要明显少于其他方法, 这更有利于维数约简。

为了检验各种方法的实时性, 本文对各种算法的运算时间进行了对比, 使用的计算机配置为: 英特尔赛扬 1.7 G 的 CPU, 512 M 的 DDR 内存。嵌入特征维数 $d=2$, 其他参数设置不变, 每种方法实验结果为 10 次实验的平均值。各种算法的运行时间如表 2 所示。

表 2 各种算法的运行时间比较

Tab.2 Runtime comparison at different methods

算法	PCA	KPCA	LLE	SLLE	SKLLE
运行时间	1.452 1	0.440 6	1.592 5	1.642 4	0.230 3

从表 2 可得知, 由于采用了核技巧, 基于核的维数约简方法的计算时间反而有所下降, 具有更好的实时性。

针对 SKLLE 的泛化性能进行实验, 本文分别对每种表情选择 5、15、25 个样本直接使用 SKLLE 方法得到低维嵌入特征矢量, 其余使用公式(9)来进行嵌入, 然后再使用最近邻分类器进行分类, 每次进行 10 次实验, 取其平均值。相关的参数为: 近邻 $k=12$, 高斯核 $\sigma=1$, 嵌入维数 $d=2$ 。具体结果如表 3 所示。

SKLLE 算法中, 使用不同的新样本数进行嵌入分类实验, 尽管识别率有所下降, 但是依然有相对较好的识别性能, 这充分说明 SKLLE 算法对新

表 3 SKLLE 算法在不同样本数目下的平均识别率比较
Tab. 3 Performance comparison of SKLLE method under different samples

样本数	5	15	25
识别率	82.5%	87.67%	92.43%

样本具有较好的泛化性。

4 结 论

本文在对局部线性嵌入算法(LLE)进行分析后,提出了一种基于核方法的监督局部线性嵌入

算法(SKLLE),并将该算法应用于人脸表情识别中。该算法不仅将人脸表情的局部流形结构信息和样本类别信息有效的结合从而进行维数约简,提取低维鉴别流形特征,而利用核技巧直接提取新样本的特征,对新样本也有较好的泛化性。在 JAFFE 库上的实验结果表明:该算法能很好的实现维数约简,达到最高识别率(100%)所需的鉴别维数仅为二维,可以有效地提高面部表情识别的性能。因 JAFFE 库的图像背景都比较简单,如何有效地提高复杂条件下人脸表情识别的正确率和效率,以及将算法向种族、年龄等群体特征识别进行扩展有待于进一步研究。

参考文献:

- [1] 崔洁,冯晓毅. 基于粗略到精细分类的面部表情识别方法[J]. 计算机工程, 2007, 33(5):168-172.
CUI J, FENG X Y. Method of facial expression recognition based on coarse-to-fine classification [J]. *Computer Engineering*, 2007, 33(5):168-172(in Chinese).
- [2] 梁毅雄,龚卫国,潘英俊,等. 基于奇异值分解的人脸识别方法[J]. 光学 精密工程, 2004, 12(5):543-549.
LIANG Y X, GONG W G, PANG Y J, et al.. Singular value decomposition-based approach for face recognition [J]. *Opt. Precision Eng.*, 2004, 12(5): 543-549. (in Chinese)
- [3] EKMAN P. *Emotion in the Human Face* [M]. Cambridge:Cambridge University Press, 1982.
- [4] TORSTEN W, GROSS H M. Classification of face images for gender, age, facial expression, and identity[C]. *Proc. Int. Conf. on Artificial Neural Networks (ICANN'05)*, Springer Verlag, LNCS 3696, 2005:569-574.
- [5] 刘晓旻,谭华春,章毓晋. 人脸表情识别研究的新进展[J]. 中国图象图形学报, 2006, 11(10):1359-1368.
LIU X M, TAN H CH, ZHANG Y J. New research advances in facial expression recognition [J]. *J. Image and Graphics*, 2006, 11(10):1359-1368. (in Chinese)
- [6] 刘晓旻,章毓晋. 基于 Gabor 直方图特征和 MVBoost 的人脸表情识别[J]. 计算机研究与发展, 2007, 44(7):1089-1096.
LIU X M, ZHANG Y J. Facial expression recognition based on Gabor histogram feature and MVBoost [J]. *J. Computer Research and Development*, 2007, 44(7):1089-1096. (in Chinese)
- [7] 李粉兰,徐可欣. 一种应用于人脸正面图像的眼睛自动定位算法[J]. 光学 精密工程, 2006, 14(2):320-326.
LI F L, XU K X. An algorithm applied in frontal-view face images for automatically localizing eyes [J]. *Opt. Precision Eng.*, 2006, 14(2):320-326. (in Chinese)
- [8] 李粉兰,唐文彦,段海峰,等. 分数次幂多项式核函数在核直接判别式分析中的应用[J]. 光学 精密工程, 2007, 15(9):1410-1414.
LI F L, TANG W Y, DUAN H F, et al.. Application of fractional power polynomial kernel function to kernel direct discriminant analysis [J]. *Opt. Precision Eng.*, 2007, 15(9):1410-1414. (in Chinese)
- [9] ROWEIS S T, SAUL L K. Nonlinear dimensionality reduction by locally linear embedding [J]. *Science*, 2000, 290(5500):2323-2326.
- [10] TENENBAUM J B, SILVA V D, LANGFORD J C. A global geometric framework for nonlinear dimensionality reduction [J]. *Science*, 2000, 290(5500):2319-2323.
- [11] BELKIN M, NIYOGI P. Laplacian eigenmaps and spectral techniques for embedding and clustering [C]. *In Advances in Neural Information Processing Systems*, Cambridge, MA, USA: The MIT Press, 2002, 14:585-591.
- [12] OKUN O, KOUROPTOVA O. Supervised locally linear embedding algorithm [C]. *Proc. of the Tenth Finnish*

Artificial Intelligence Conference, Finland; FAIC, 2002;50-61.

- [13] YANG J, FRANGI A F, YANG J Y, *et al.*. KPCA plus LDA: a complete kernel fisher discriminant framework for feature extraction and recognition [J]. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 2005, 27 (2):230-244.
- [14] JAFFE facial expression database [OL]. <http://www.irc.atr.jp/~mlyons/jaffe.html>.

作者简介:黄鸿(1980-),男,湖南新宁人,博士,主要研究方向为图像处理、模式识别、流形学习、生物特征识别等。E-mail:hhuang.cqu@gmail.com

李见为(1947-),男,陕西西安人,教授,博士生导师,主要研究方向为图像处理、模式识别、地理信息系统(GIS)等。E-mail:jwli@cqu.edu.cn

冯海亮(1962-),男,副教授,主要研究方向为应用数学、黎曼流形、图像处理、人脸识别等。

● 下期预告

基于 Q 值选取的太阳同步回归轨道设计算法

曲宏松^{1,2},张 叶^{1,2},金 光¹

(1. 中国科学院 长春光学精密机械与物理研究所,吉林 长春 130033;

2. 中国科学院 研究生院,北京 100039)

由于太阳同步回归轨道既可以满足光照条件的要求,又可以满足时间分辨力的要求,所以成为对地观测航天器首选轨道之一。由于 Q 值是将太阳同步轨道和回归轨道联系起来的桥梁,所以 Q 值在设计太阳同步回归轨道中起着举足轻重的作用,是太阳同步回归轨道设计时最先考虑的参数。通过对太阳同步轨道和回归轨道特性的分析,可以建立 Q 值与太阳同步回归轨道参数之间的数学关系,此关系是设计太阳同步回归轨道的依据。通过对轨道回归特性的分析,引入了设计太阳同步回归轨道 Q 值的方法。最后,结合某航天任务的具体指标,利用 Q 值选取算法,在 500~510 km 轨道高度范围内选取了一条轨道高度为 502.59 km 的轨道。该轨道的回归周期为 21 d,平均重访周期为 5 d,是 500~510 km 轨道高度范围内重访特性最优的太阳同步回归轨道。基于 Q 值选取的轨道设计算法从理论上找到了太阳同步轨道设计中的关键,为复杂的轨道设计工作提供了一个可靠而易行的方法。