

基于 KPCA 的非线性 ASM 定位方法研究

徐 涛^{1,2}, 孙 彤^{1,2}

(1 中国民航大学 计算机科学与技术学院, 天津 300300; 2 中国民航信息技术科研基地, 天津 300300)

摘 要: 针对主动形状模型(Active Shape Model, ASM)中的建模方法——主分量分析(Principal Component Analysis, PCA)存在容易忽略像素间非线性关系等弱点, 对基于 ASM 的图像中目标物体定位技术进行了非线性化的研究探索. 通过引入核理论, 提出了一种基于核主分量分析(Kernel PCA, KPCA)的非线性 ASM 定位方法, 并运用多维空间距离关系原理解决了 KPCA 方法无法重构原空间图像模型的难题. 实验证明, 此方法能够有效地实现二维图像中的目标物体定位.

关键词: 目标定位; 非线性 ASM; PCA; KPCA

中图分类号: TP391. 41

文献标识码: A

文章编号: 1000-7180(2010)12-0113-04

Object Localization of Nonlinear Active Shape Model Based on Kernel PCA

XU Tao^{1,2}, SUN Tong^{1,2}

(1 College of Computer Science and Technology, Civil Aviation University of China, Tianjin 300300, China;

2 Information Technology Research Base, Civil Aviation Administration of China, Tianjin 300300, China)

Abstract: In this paper, we address the problem of principal component analysis technique which is the modeling method of active shape model. Since the principal component analysis usually ignores nonlinear relativity among a large number of pixels, kernel method is combined to research object localization. A nonlinear active shape model based on kernel principal component analysis is presented in this paper. The proposed method reconstructs the pre-image in input space through the idea in multidimensional scaling. The validity of this method is demonstrated by the results of preliminary experiments.

Key words: object localization; nonlinear ASM; PCA; KPCA

1 引言

目标的准确定位对于目标的识别以及图像的理解与分析起着非常重要的作用. 在过去的几十年中, 基于统计学的可变形模型对目标物体定位的研究取得了巨大的成功.

文献[1]提出了主动轮廓模型(Active Contour Model), 又被称作 Snake 模型^[1]. 主动形状模型(Active Shape Model, ASM)是 Snake 模型的发展与改进, 由于引入模型的先验知识提高了定位的精确性与鲁棒性, 能够有效地实现医学图像的目标定

位^[2], 而在 ASM 模型中加入纹理模型的主动表现模型(Active Appearance Model, AAM)取得了较好的定位效果^[3]. 由于 ASM 先验模型建立在对训练样本集进行主分量分析(Principal Component Analysis, PCA)的基础上, 且 PCA 作为一种线性方法势必会丢失样本集的非线性特征^[4]. 因此, 如果原始数据存在复杂的非线性关系, 相比主分量分析而言, 非线性主分量分析更适合用作特征抽取方法^[5]. 文中针对传统 ASM 定位方法的这些局限和不足, 对其进行了非线性化的研究探索, 通过引入核方法, 提出了一种基于 KPCA 的非线性 ASM 定位方法.

收稿日期: 2009-11-04; **修回日期:** 2010-01-22

基金项目: 国家“八六三”计划项目(2006AA12A106)

2 基于 KPCA 的非线性 ASM 定位方法

非线性 ASM 定位方法以目标物体的轮廓作为训练样本构造模型. 首先通过人机交互方式标定目标轮廓的特征点, 使之形成训练样本集, 并用点分布模型(PDM)^[2]进行描述. 运用 KPCA 方法提取训练集的特征, 进一步构造样本的先验模型. 先验模型建立后, 利用色调模型在目标图像中搜索特征点的最佳位置, 同时根据搜索结果调整先验模型的参数, 使模型与目标物体实际轮廓逐步逼近, 从而达到准确定位目标的目的.

2.1 构造训练样本集

在二维图像中, 目标物体的轮廓可以用特征点集合描述. 用于描述轮廓的点一般选在能表示目标物体轮廓特征的地方, 如拐角点、T-形连接处等, 同时在轮廓特征点之间, 用等间距采样的方式选取另外若干中间点, 共同构成目标轮廓的特征点集合. 例如: 由 n 个特征点构成的目标轮廓可表示为 $2n$ 维向量 $X = (x_1, y_1, x_2, y_2, \dots, x_n, y_n)^T$.

所有用于训练的图像按上述方法进行轮廓特征点的提取, 得到训练样本集 Ω , 即 $\Omega = \{X_1, X_2, \dots, X_L\}$.

2.2 基于 KPCA 的先验模型的建立

2.2.1 KPCA

PCA 基于数据间的线性关系处理数据, 对于非线性情况, 处理效果并不理想. 因此, KPCA 等一系列非线性方法应运而生. KPCA 方法借鉴支持向量机(Support Vector Machines, SVM)的核方法思想, 将线性的 PCA 扩展到非线性情形. 其思想可描述为: 通过一个非线性函数 Φ 将输入空间映射到更高维的特征空间中, 然后在此高维空间中使用 PCA 方法提取数据特征. 由图 1 可以看出, 非线性可分的输入空间通过函数 Φ 映射到特征空间后, 变成了一个线性可分的问题.




图 1 核映射示意图

KPCA 方法甚至无需知道非线性映射函数 Φ 的具体形式, 仅通过一个满足 Mercer 条件的核函数即可完成特征提取的计算. 常用的核函数有: 线性核

函数、多项式核函数、高斯径向基函数核函数等. 本文采用在模式识别领域广泛应用的高斯径向基函数为核函数.

将轮廓特征点组成的训练样本集作为输入空间数据, 即矩阵 $\Omega = \{X_1, X_2, \dots, X_L\}$, $X_k \in R^N$ ($k = 1, \dots, L$; $N = 2 \times n$). 假设输入空间 R^N 到高维特征空间 F 的映射函数为 Φ , 并且特征空间中数据满足“中心化”条件, 即: $\sum_{i=1}^L \Phi(X_i) = 0$.

假设协方差矩阵 $C = \frac{1}{L} \sum_{i=1}^L \Phi(X_i) \Phi(X_i)^T$ 的特征值 $\lambda \geq 0$ 与特征向量 $V \in F \setminus \{0\}$, 即:

$$\lambda \langle \Phi(X_k) \cdot V \rangle = \langle \Phi(X_k) \cdot C V \rangle$$

$$k = 1, 2, \dots, L \quad (1)$$

根据核理论, 存在一组系数 $\alpha_1, \dots, \alpha_L$, 使得:

$$V = \sum_{i=1}^L \alpha_i \Phi(X_i) \quad (2)$$

定义一个由高斯核函数 $k(x, y) = \exp(-\|x - y\|^2/c)$ 计算得出的 $L \times L$ 维核矩阵 K , 满足 $K_{ij} = (\Phi(X_i) \cdot \Phi(X_j)) = (k(X_i, X_j))$. 于是, 可得式(1)的等价式:

$$L \lambda \alpha = K \alpha \quad (3)$$

其中, $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_L)^T$.

设 K 的特征值为 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L$, 相应的特征向量为 $\alpha^1, \alpha^2, \dots, \alpha^L$, 特征空间中的特征向量 V 可用式(2)求得, 并通过 $\lambda_k (\alpha^k \cdot \alpha^k) = 1$ 进行规范化. 将前 t 个特征值对应的特征向量(一般前 t 个特征值占目标物体形变总量的比例不小于 0.98)组成一个特征子空间, 则 $\Phi(X)$ 在子空间中的投影可表示为: $P\Phi(X) = \sum_{i=1}^t \beta_i V_i$. 其中, $\beta_i = \Phi(X)^T V_i = \sum_{j=1}^L \alpha_j^i k(X, X_j)$ 表示 $\Phi(X)$ 在第 i 个特征向量上的投影.

2.2.2 先验模型的建立

不同于基于 PCA 建立先验模型的方法, KPCA 方法不能直接重构出原图像. 从 KPCA 的原理可以看到, 非线性的特征向量提取对输入空间到特征空间的映射函数是不关心的. 在提取非线性特征方面, 这不失为一个行之有效的方法, 但是因为不知道映射函数 Φ 的具体形式, 故不可能由反函数来重构出原输入空间图像, 因此, 需借助一种近似的方法来进行重构. 目前比较流行的方法有固定点迭代法(Fixed Point Iteration)^[6]和基于多维空间距离关系^[7]的重构方法. 文中采用第二种方法建立先验模型.

由于多维空间存在着距离关系, 因此可将特征空间与输入空间联系起来, 在计算出特征空间中样

本与样本间的欧氏距离后,将其转化为输入空间中样本间的距离关系.如图2所示,输入空间的样本,在特征空间中映射为 $\Phi(X)$,经主分量分析之后它在特征子空间投影为 $P\Phi(X)$,输入空间的图像重构过程则可通过 $P\Phi(X)$ 与周围样本的空间距离转化实现.




图2 基于多维空间距离关系

假设初始模型为 X ,它与任意一个样本 X_i 在特征空间中的欧氏距离为:

$$\tilde{d}^2(P\Phi(X), \Phi(X_i)) = \|P\Phi(X)\|^2 + \|\Phi(X_i)\|^2 - 2P\Phi(X)^T\Phi(X_i) \quad (4)$$

不同的核函数对应的多维空间之间的距离关系不同,对于高斯核函数,输入空间中任意两样本的欧氏距离 d_{ij}^2 与相应的特征空间中的样本距离 $\tilde{d}_{ij}^2$ 存在如下关系:

$$d_{ij}^2 = -c \log\left(\frac{1}{2}(K_{ii} + K_{jj} - \tilde{d}_{ij}^2)\right) \quad (5)$$

研究表明,与重构的原图像距离越大的样本,在计算中的贡献越小^[8].因此,在实际计算过程中,只要选取前 n 个与 $\Phi(x)$ 距离最近的样本进行估算即可.

将选取的 n 个相邻样本 $\{X_1, \dots, X_n\} \in R^N$ 中心化并进行PCA,得到可以表征其主要特征的特征向量组 $U = [e_1, \dots, e_q]$,以及每个样本 X_i 投影到特征向量 e_j 上的投影向量 z_i 组成的 $q \times n$ 维矩阵 $Z = [z_1, \dots, z_n]$.另外,计算出平方距离 $\|z_i\|^2$ 组成的 n 维向量 $d_0^2 = [\|z_1\|^2, \dots, \|z_n\|^2]^T$.

于是,先验模型 $\hat{X}$ 表述为:

$$\hat{X} = U\hat{z} + X \quad (6)$$

其中, $\hat{z} = -(ZZ^T)^{-1}Z(d^2 - d_0^2)/2$, d^2 为式(5)得到的输入空间样本间距离.

2.3 基于先验模型的目标定位

选取一幅测试图像,将初始模型 X 置于该测试图像中,每一次迭代过程获得从KPCA空间中重构出的模型,并改变其位置和形状,进而产生新的模型实例 Y ,最终完成模型与测试图像轮廓的匹配.迭代实现过程为:

Step1: 选取初始模型,通常取 $X = \bar{X}$.

Step2: 沿当前模型 X 的每个特征点周围搜索,

寻找各特征点 (x_i, y_i) 的最佳匹配点 (x'_i, y'_i) ,如图3所示.




图3 模型点的搜索

Step3: 将最佳匹配点 (x'_i, y'_i) 构成的样本映射到KPCA空间进行重构,利用式(6)构造新的先验模型,在对其进行位置和形状的相似性变换之后,构成模型实例 Y ,设为新的当前模型 X .

Step4: 重复 Step2、Step3 直至模型不再发生明显变化.

在上述迭代过程中,Step2 将搜索区域选定为每个特征点沿当前模型轮廓的法线方向.由于文中针对彩色图像中目标物体进行定位,并且色调(Hue)包含了颜色空间中绝大多数信息,所以在对彩色图像的目标定位时采用基于轮廓的色调匹配方法调整改变轮廓形状,使之逐渐向物体逼近.

基于轮廓的色调匹配法首先对训练样本的每一个轮廓特征点沿轮廓法线方向进行色调采样,假设对于第 i 个特征点 (x_i, y_i) ,在其两侧沿法线方向各取 k 个点,这 $2k+1$ 个点的色调值构成向量 h_i .对每一个训练样本中同一位置的轮廓特征点都进行这种处理,得到一个向量集 $\{h_i\}$.一般而言, h_i 满足高斯分布, $\{h_i\}$ 的均值记为 $\bar{h}$,协方差记为 Σ_h .对于每一个特征点,用同样的方法进行色调采样与分析,从而构成目标轮廓的色调统计模型.

考虑一个待测试的轮廓特征点 p ,沿法线方向得到其色调向量 h_p ,定义如下的匹配函数:

$$f(h_p) = (h_p - \bar{h})^T \Sigma_h^{-1} (h_p - \bar{h}) \quad (7)$$

实际上, $f(h_p)$ 是向量 h_p 与向量均值 $\bar{h}$ 之间的Mahalanobis距离,它线性依赖于 h_p 的概率对数值,于是,求 h_p 的最大概率分布问题就转化为求 $f(h_p)$ 的最小值问题.

在搜索过程中,对于每一个当前位置的轮廓特征点 (x_j, y_j) ,沿搜索方向在其两侧各取 m 个点($m > k$),从这 $2m+1$ 个点中每次取 $2k+1$ 个点的色调与色调模型进行比较,从 $2(m-k)+1$ 个位置中找出最佳匹配位置,也就是使 $f(h_p)$ 最小,并向该方向移动规定的步长.所有特征点都经过这样的移动后,将其映射到KPCA空间进行特征提取并生成重构

图像,作为新的模型实例,使模型与目标轮廓逼近.

3 实验及结果

文中以一组手部照片(共 44 幅)作为实验图像,选取其中 40 幅作为训练图像,4 幅作为测试图像检验模型匹配的正确性.

在 40 幅训练图像中,从拇指一侧的手腕处开始标注轮廓特征点,按顺时针方向依次标注共 85 个轮廓特征点,用点分布模型 PDM 构造先验模型,并对每个边界点取 $k=4$ 进行色调统计模型的训练. 高斯核函数的参数 c 取值为 55 000. 表 1 计算了 KPCA 方法提取的特征值,取前 5 个特征值满足 $\sum_{i=1}^5 \lambda_i \geq 0.98$.

表 1 采用 KPCA 方法提取的特征值

特征值	所占比例	比例累计
12.7020	48.63	48.63
5.9895	22.93	71.56
4.7269	18.10	89.66
2.1700	08.31	97.97
0.0699	00.27	98.24
0.0375	00.14	98.38
0.0353	00.13	98.51
0.0307	00.12	98.63

在搜索迭代过程中,沿模型轮廓特征点搜索方向取 $m=14$ 进行色调匹配,经过若干次迭代后,运用基于 KPCA 的非线性 ASM 目标定位方法使得模型能够与目标轮廓较好吻合,达到了定位的目的.

4 结束语

文中讨论了一种将传统线性 ASM 目标定位扩展至非线性领域的新方法. 以 KPCA 方法提取数据特征,有效地解决了 PCA 方法容易忽略像素间高阶非线性因素的问题. 与基于 PCA 的建模方法不同,基于 KPCA 的建模具有更大的难度. 高阶映射函数的未知导致重构模型只能采用一种近似的方法,文

中采用的多维空间距离关系的方法很好地解决了这一难题. 实验表明,与传统的基于 PCA 的线性 ASM 定位方法相比,基于 KPCA 的非线性 ASM 定位方法能够更加有效地实现目标的轮廓定位.

参考文献:

[1] Cootes T F, Hill A, Taylor C J, et al. The use of active shape models for locating structures in medical images [J]. Image and Vision Computing, 1994, 12(6): 355—366.

[2] Xu Tao, Cai Yuxin. Localization of object (spine) in medical image using active shape models[J]. Transactions of Nanjing University of Aeronautics and Astronautics, 2003, 20(2): 211—217.

[3] Xi Pengcheng, Xu Tao, Zhao Zheng. Knowledge—based active appearance model applied in medical image localization[C]// Proceedings of the IEEE International Conference on Mechatronics and Automation (ICMA 2005). China, Luoyang, 2005: 637—642.

[4] Koschan A, Kang S, Paik J, et al. Color active shape models for tracking non—rigid objects[J]. Pattern Recognition Letters, 2003, 24(11): 1751—1765.

[5] 顾梅,徐涛. 基于 ASM 的彩色视频中运动物体的定位 [J]. 计算机应用, 2007, 27(1): 234—236.

[6] 范玉华,马建伟. 多模型 ASM 及其在人脸面部特征点定位中的应用[J]. 微电子学与计算机, 2008, 25(6): 105—107.

[7] Mika S, Scholkopf B, Smola A, et al. Kernel PCA and De—noising in feature spaces[C]// Proceedings of the 1998 Conference on Advances in Neural Information Processing Systems. USA: Colorado, 1999: 536—542.

[8] Kwok J T, Tsang I W. The Pre—Image problem in kernel methods [J]. IEEE Transactions on Neural Networks, 2004, 15(6): 1517—1525.

作者简介:

徐 涛 男, (1962—), 教授. 研究方向为图像处理与人工智能、软件体系结构.

孙 彤 女, (1982—), 硕士研究生. 研究方向为图像处理与分析.