

# 核二维最大间距准则\*

姜伟<sup>1</sup>, 程洋洋<sup>1</sup>, 杨炳儒<sup>2</sup>

(1. 辽宁师范大学 数学学院, 辽宁 大连 116029; 2. 北京科技大学 计算机与通信工程学院, 北京 100083)

**摘要:** 研究了核理论和二维矩阵表示的非线性特征提取方法。在对向量和矩阵表示最大间距准则进行分析基础上,提出了一种核二维最大间距准则的非线性判别方法。该算法是对二维最大间距准则的核化推广,不但有效利用了图像的空间结构信息,而且分别在两个特征空间提取判别特征。在 ORL 和 Extended Yale-B 人脸数据库上的实验表明了该算法的有效性。

**关键词:** 核函数; 判别分析; 特征提取; 矩阵表示

**中图分类号:** TP391.41      **文献标志码:** A      **文章编号:** 1001-3695(2012)12-4767-03

**doi:**10.3969/j.issn.1001-3695.2012.12.096

## Kernel two dimensional maximum margin criterion

JIANG Wei<sup>1</sup>, CHENG Yang-yang<sup>1</sup>, YANG Bing-ru<sup>2</sup>

(1. School of Mathematics, Liaoning Normal University, Dalian Liaoning 116029, China; 2. School of Computer & Communication Engineering, University of Science & Technology Beijing, Beijing 100083, China)

**Abstract:** This paper studied the kernel theory and two dimensional matrix representation for nonlinear feature extraction method. Based on the analysis of maximum marginal criterion of vector and matrix representation, it proposed a nonlinear discriminant analysis method called kernel two dimensional maximum margin criterion (KTDDMM) to extract nonlinear features. It was an extension to kernelization of two dimensional maximum marginal criterion (TDDMM), which not only effectively utilized the underlying spatial structure of images, but also extracted the discriminating information in two kernel subspaces respectively. Experiments on ORL and Extended Yale-B face recognition databases demonstrate the effectiveness of the proposed method.

**Key words:** kernel function; discriminant analysis; feature extraction; matrix representation

## 0 引言

线性判别分析(linear discriminant analysis, LDA)<sup>[1]</sup>为监督降维算法,目的是寻求投影方向,使得数据映射到低维空间后,各类内样本尽可能紧凑,类间样本尽可能分开。然而,LDA 算法存在两大缺点:一个是小样本(small sample size, SSS)<sup>[2]</sup>问题;另一个是 LDA 面临着秩限制<sup>[3]</sup>问题,即对于  $c$  类问题最多只能提取  $c-1$  个最优鉴别向量。鉴于此,Li 等人<sup>[4]</sup>提出最大间距准则(maximum margin criterion, MMC),并且用核方法推广到非线性情形。

LDA 和 MMC 算法都是基于数据一维向量表示,在图像处理应用中,数据内在模式是由矩阵表示,需要将矩阵按照一定规则重新组合成一维向量形式。二维矩阵向量化,破坏了像素之间空间结构关系,损失重要空间结构信息;向量化后维数过高,导致小样本问题和高计算代价。为了克服向量表示缺点,许多学者在这方面做了卓有成效的工作。Yang 等人<sup>[5]</sup>首先将矩阵表示推广到 PCA 算法中,该方法思想是直接使用图像矩阵计算协方差,求得协方差最大投影方向。Xiong 等人<sup>[6]</sup>和 Yang 等人<sup>[7]</sup>分别提出了二维 Fisher 线性判别分析(two-dimensional Fisher linear discriminant analysis, 2DFDA)和二维线性判别分析(two-dimensional linear discriminant analysis, 2DLDA)方法。实践证明,这些方法较基于向量表示的方法性能更好,但是其算法

都是采用单边矩阵投影,所提炼出特征维数依然比较高。鉴于此,Ye 等人<sup>[8]</sup>和 He 等人<sup>[9]</sup>分别提出二维线性判别分析(2DLDA)和量子空间分析(tensor subspace analysis, TSA)方法。它们把特征抽取过程看做是在一定准则下寻找两个正交投影矩阵,使得样本矩阵映射到低维矩阵空间中。由于算法采用 Fisher 准则,通过迭代广义特征分解来寻求最优解,因此,该方法并不能保证收敛到最优解。针对这个问题,Gu 等人<sup>[10]</sup>提出二维最大间距准则解决了这一问题,其算法直接利用图像矩阵类间方差矩阵和类内方差矩阵,并且保证算法收敛性。该算法收敛很快,这使算法更加稳定和有效,而且 2DMMC 拥有 MMC 算法的所有优点。

2DMMC 直接利用二维人脸图像矩阵实现降维,但它是全局线性方法,无法揭示数据非线性几何结构。在输入空间数据特征之间存在复杂关系情况下,线性方法不能捕获数据非线性特征,此时核方法<sup>[11]</sup>意义得以彰显。本文提出的方法是将核函数直接作用于图像矩阵。首先,图像矩阵经 SVD 分解为两个正交矩阵与一个对角矩阵的乘积,即  $X=UAV^T$ 。左边正交矩阵代表原矩阵行信息,而右边正交矩阵代表原矩阵列信息;然后,通过两个核函数将两个正交矩阵列向量从原始非线性空间映射到一个更高维甚至是无限维特征空间;最后,两个核矩阵通过优化更新过程学习得到。本文提出的算法具有以下优点:a)充分利用了数据空间结构信息;b)双核代替单核,从多角度全面刻画数据

收稿日期: 2012-04-26; 修回日期: 2012-05-30      基金项目: 国家自然科学基金资助项目(61175048)

作者简介:姜伟(1969-),男,辽宁大连人,副教授,博士研究生,主要研究方向为机器学习、模式识别(swxwjw@yahoo.com.cn);程洋洋(1987-),女,硕士研究生,主要研究方向为机器学习、模式识别;杨炳儒(1943-),男,教授,博导,主要研究方向为知识工程、数据挖掘、人工智能。

的几何结构,算法更具鲁棒性;c)KTDMMC 保证算法收敛性。

### 1 最大间距准则和二维最大间距准则

#### 1.1 最大间距准则

MMC 准则目的是寻找一个最优鉴别矢量集,将样本数据投影到这些方向上,使得映射后的类间散度矩阵和类内散度矩阵的差最大。设有  $C$  个模式类,共  $N$  个样本,第  $i$  类有  $n_i$  个样本。训练样本集  $X = \{x_j^{(i)}\} (i = 1, 2, \dots, C; j = 1, 2, \dots, n_i), x_j^{(i)}$  表示第  $i$  类的第  $j$  个样本,设第  $i$  类均值和总体均值分别为  $m_i$  和  $m$ 。

$$m_i = \frac{1}{n_i} \sum_{j=1}^{n_i} x_j^{(i)}$$

$$m = \frac{1}{N} \sum_{i=1}^c n_i m_i \quad (1)$$

最大间距准则(MMC)目标函数定义如下:

$$\max \operatorname{tr}(W^T(S_b - S_w)W)$$

s. t.  $W^T W = I$  (2)

其中: $S_b$  为样本类间散度矩阵, $S_w$  为类内散度矩阵,即

$$S_b = \sum_{i=1}^c n_i (m_i - m)(m_i - m)^T$$

$$S_w = \sum_{i=1}^c \sum_{j=1}^{n_i} (x_j^{(i)} - m_i)(x_j^{(i)} - m_i)^T \quad (3)$$

通过解广义特征方程求 MMC 算法最优投影矩阵  $W$ ,即

$$(S_b - S_w)w_i = \lambda_i w_i$$

其中: $\lambda_i$  为  $S_b - S_w$  的特征值, $w_i$  为  $\lambda_i$  对应的特征向量。选取  $(S_b - S_w)$  的前  $d$  个最大的特征值对应的特征向量  $w_1, w_2, \dots, w_d$  作为投影方向,可得最优投影矩阵为

$$W = [w_1, w_2, \dots, w_d]$$

由于 MMC 方法无须求  $S_w^{-1}$ , $S_w$  是否可逆对求最终判别矢量没有任何影响,不存在小样本问题。

#### 1.2 二维最大间距准则

2DMMC 是将向量表示最大间距准则推广到矩阵表示中,寻找两个正交投影矩阵,使得样本矩阵映射到低维矩阵空间中,同类样本之间更加紧凑,不同类样本之间更加远离。假设样本集  $X_i \in R^{m \times n} (i = 1, \dots, N), X_i$  的类标签  $l_i \in \{1, 2, \dots, c\}, c$  是样本的类数, $\pi_i$  是样本属于第  $i$  类样本的索引集, $n_i$  是第  $i$  类样本个数。 $\bar{X}^{(i)} = \frac{1}{n_i} \sum_{j \in \pi_i} X_j^{(i)}$  为第  $i$  类样本均值, $\bar{X} = \frac{1}{N} \sum_{i=1}^c \sum_{j \in \pi_i} X_j^{(i)}$  是所有样本均值矩阵, $X_j^{(i)}$  表示第  $i$  类第  $j$  个样本。

2DMMC 算法是寻找两个变换矩阵  $L \in R^{m \times m'}, R \in R^{n \times n'}$ ,将图像矩阵  $X_i$  映射为  $Y_i \in R^{m' \times n'} (i = 1, \dots, N)$ ,使得  $Y_i = L^T X_i R$ 。2DMMC 准则函数定义如下:

$$\max \operatorname{tr}(S_B - S_W)$$

s. t.  $L^T L = I, R^T R = I$  (4)

其中:

$$S_W = \sum_{i=1}^c \sum_{j=1}^{n_i} \|L^T X_j^{(i)} R - L^T \bar{X}^{(i)} R\|_F^2$$

$$S_B = \sum_{i=1}^c n_i \|L^T \bar{X}^{(i)} R - L^T \bar{X} R\|_F^2 \quad (5)$$

目标函数是一个多变量二次优化问题,没有闭式解,因此需采用迭代法来求映射矩阵  $L$  和  $R$ 。

### 2 双核二维最大间距准则

在 KTDMMC 中,将图像矩阵  $X$  映射到特征空间,相当于

首先将  $X$  经 SVD 分解为两个正交矩阵  $U$  和  $V$ ,然后通过核映射将  $U$  和  $V$  矩阵列向量映射到高维特征空间中,描述如下:

$$X = USV^T$$

$$\Phi(X) = \Phi_1(U) S \Phi_2(V)^T \quad (6)$$

其中: $\Phi_1(U) = \Phi_1(U(:, 1)), \dots, \Phi_1(U(:, m)), \Phi_2(V) = \Phi_2(V(:, 1)), \dots, \Phi_2(V(:, n)), U(:, k)$  表示矩阵  $U$  的第  $k$  列。KTDMMC 准则函数定义如下:

$$\max \operatorname{tr}(S_B^{\Phi} - S_W^{\Phi}) \quad (7)$$

其中: $S_W^{\Phi} = \sum_{i=1}^c \sum_{j=1}^{n_i} \|U_L^T \Phi_1(U_j^{(i)}) S_j^{(i)} \Phi_2(V_j^{(i)})^T V_R - U_L^T \Phi_1(\bar{U}^{(i)}) S^{(i)} \Phi_2(\bar{V}^{(i)})^T V_R\|_F^2, S_B^{\Phi} = \sum_{i=1}^c n_i \|U_L^T \Phi_1(\bar{U}^{(i)}) S^{(i)} \Phi_2(\bar{V}^{(i)})^T V_R - U_L^T \Phi_1(\bar{U}) S \Phi_2(\bar{V})^T V_R\|_F^2$

如果把  $U_L$  和  $V_R$  看做是所有训练样本经奇异值分解后所得到的  $U$  和  $V$  列向量所张成的空间中,共有  $mN$  和  $nN$  个样本张成核空间  $K_U$  和  $K_V$ ,导致之后优化算法时间复杂太高。本文采用把  $U_L$  和  $V_R$  分别看做是类中心  $\bar{X}^{(i)}$  经奇异值分解后得到  $\bar{U}^{(i)}$  和  $\bar{V}^{(i)}$  列向量所张成的空间中,存在系数  $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_{mc}]^T$  和  $\beta = [\beta_1, \beta_2, \dots, \beta_{nc}]^T$ ,使得

$$U_L = [[\Phi_1(\bar{U}^{(1)}(:, 1)), \Phi_1(\bar{U}^{(1)}(:, 2)), \dots, \Phi_1(\bar{U}^{(1)}(:, m))], \dots, [\Phi_1(\bar{U}^{(c)}(:, 1)), \Phi_1(\bar{U}^{(c)}(:, 2)), \dots, \Phi_1(\bar{U}^{(c)}(:, m))]] \alpha$$

$$V_R = [[\Phi_2(\bar{V}^{(1)}(:, 1)), \Phi_2(\bar{V}^{(1)}(:, 2)), \dots, \Phi_2(\bar{V}^{(1)}(:, n))], \dots, [\Phi_2(\bar{V}^{(c)}(:, 1)), \Phi_2(\bar{V}^{(c)}(:, 2)), \dots, \Phi_2(\bar{V}^{(c)}(:, n))]] \beta$$

其中: $\bar{U}^{(i)}$  和  $\bar{V}^{(i)}$  是  $\bar{X}^{(i)}$  奇异值分解结果。将  $\Phi(U_j^{(i)}(:, k))$  投影到  $U_L$  上,可以得到  $U_L^T \Phi(U_j^{(i)}(:, k))$  为

$$U_L^T \Phi(U_j^{(i)}(:, k)) = \alpha^T \begin{bmatrix} \Phi_1(\bar{U}^{(1)}(:, 1))^T \\ \Phi_1(\bar{U}^{(1)}(:, 2))^T \\ \vdots \\ \Phi_1(\bar{U}^{(c)}(:, m))^T \end{bmatrix} \Phi_1(U_j^{(i)}(:, k)) = \alpha^T [K_j^{(i)}(:, k)]_U$$

其中: $[K_j^{(i)}(:, k)]_U$  表示第  $i$  类第  $j$  个样本的第  $k$  列核向量。定义  $L^T \Phi(U_j^{(i)}) = \alpha^T [K_j^{(i)}]_U, [K_j^{(i)}]_U = [[K_j^{(i)}(:, 1)]_U, \dots, [K_j^{(i)}(:, m)]_U]$ ,称  $[K_j^{(i)}]_U$  为  $X_j^{(i)}$  左核矩阵,大小为  $mc$  行  $m$  列。将  $\Phi(V_j^{(i)}(:, k))^T$  投影到  $V_R$  上,可以得到  $\Phi(V_j^{(i)}(:, k))^T V_R = \Phi_2(V_j^{(i)}(:, k))^T [\Phi_2(\bar{V}^{(1)}(:, 1)), \dots, \Phi_2(\bar{V}^{(c)}(:, n))] \beta = [K_j^{(i)}(:, k)]_V \beta$

其中: $[K_j^{(i)}(:, k)]_V$  为第  $i$  类第  $j$  个样本的第  $k$  行核向量。定义  $\Phi(\bar{V}_j^{(i)}) V_R = [K_j^{(i)}]_V \beta$ ,其中  $[K_j^{(i)}]_V = [[K_j^{(i)}(:, 1)]_V, \dots, [K_j^{(i)}(:, n)]_V]^T$ ,称  $[K_j^{(i)}]_V$  为  $X_j^{(i)}$  的右核矩阵,大小为  $n$  行  $nc$  列。 $X_j^{(i)}$  核矩阵定义如下:

$$K_j^{(i)} = [K_j^{(i)}]_U S_j^{(i)} [K_j^{(i)}]_V \quad (8)$$

同理可得类均值  $\bar{X}^{(i)}$  和总体均值  $\bar{X}$  的核矩阵分别为

$$K^{(i)} = [K^{(i)}]_U S^{(i)} [K^{(i)}]_V$$

$$K = [K]_U S [K]_V$$

根据以上定义,重写 KTDMMC 准则函数为

$$\max \operatorname{tr}(S_B^{\Phi} - S_W^{\Phi}) \quad (9)$$

其中:

$$S_W^{\Phi} = \sum_{i=1}^c \sum_{j=1}^{n_i} \|\alpha^T K_j^{(i)} \beta - \alpha^T K^{(i)} \beta\|_F^2 \quad (10)$$

$$S_B^{\Phi} = \sum_{i=1}^c n_i \|\alpha^T K^{(i)} \beta - \alpha^T K \beta\|_F^2 \quad (11)$$

优化式(9)可得到  $\alpha$  和  $\beta$ , 由于低维空间是多维的, 用下式表示

$$A = [\alpha_1, \alpha_2, \dots, \alpha_m]$$

$$B = [\beta_1, \beta_2, \dots, \beta_n]$$

重写式(10)和(11):

$$S_W^{\phi} = \sum_{i=1}^c \sum_{j=1}^{n_i} \|A^T K_j^{(i)} B - A^T \bar{K}^{(i)} B\|_F^2 \quad (12)$$

$$S_B^{\phi} = \sum_{i=1}^c n_i \|A^T \bar{K}^{(i)} B - A^T \bar{K} B\|_F^2 \quad (13)$$

### 3 迭代过程

目标函数是一个多变量二次函数, 没有闭式解 (close-form solution), 因此需用迭代法求解目标函数。其核心思想是固定  $B$ , 求出一个最优矩阵  $A$ , 然后固定  $A$ , 求出一个最优  $B$ , 不停迭代, 可以得到一个局部最优解。在给定  $B$  情况下, 根据 Frobenius 范数与迹之间的关系,  $\|u\|^2 = \text{trace}(uu^T)$ , 则目标函数变换为如下形式:

$$\text{argmax } A^T (S_B^{\phi} - S_W^{\phi}) A \quad (14)$$

其中:

$$S_B^{\phi} = \sum_{i=1}^c n_i (\bar{K}^{(i)} - \bar{K}) B B^T (\bar{K}^{(i)} - \bar{K})^T$$

$$S_W^{\phi} = \sum_{i=1}^c \sum_{j=1}^{n_i} (K_j^{(i)} - \bar{K}^{(i)}) B B^T (K_j^{(i)} - \bar{K}^{(i)})^T$$

优化式(14)可以通过解如下广义特征值问题, 即

$$S_B^{\phi} A = \lambda S_W^{\phi} A \quad (15)$$

在给定  $A$  时, 由  $\|u\|^2 = \text{trace}(u^T u)$ , 则目标函数变换为如下形式:

$$\text{argmax } B^T (S_B^A - S_W^A) B \quad (16)$$

其中:

$$S_B^A = \sum_{i=1}^c n_i (\bar{K}^{(i)} - \bar{K})^T A A^T (\bar{K}^{(i)} - \bar{K})$$

$$S_W^A = \sum_{i=1}^c \sum_{j=1}^{n_i} (K_j^{(i)} - \bar{K}^{(i)})^T A A^T (K_j^{(i)} - \bar{K}^{(i)})$$

优化式(16)通过解如下广义特征值问题:

$$S_B^A B = \lambda S_W^A B \quad (17)$$

对于新数据元素  $X_{\text{new}} \in \mathbb{R}^{m \times n}$ , 首先进行 SVD 分解, 即

$$X_{\text{new}} = U_{\text{new}} S_{\text{new}} V_{\text{new}} \quad (18)$$

则相应低维表示  $Y_{\text{new}}$  为

$$Y_{\text{new}} = L^T \Phi_1(U_{\text{new}}) S_{\text{new}} \Phi_2(V_{\text{new}})^T R =$$

$$A^T K_{\text{new}}^U S_{\text{new}} K_{\text{new}}^V B$$

$$K_{\text{new}}^U = L^T \Phi_1(U_{\text{new}}) =$$

$$\begin{bmatrix} \Phi(U^{(1)}(:, 1))^T \\ \Phi(U^{(1)}(:, 2))^T \\ \vdots \\ \Phi(U^{(c)}(:, m))^T \end{bmatrix} \Phi(U_{\text{new}})$$

$$K_{\text{new}}^V = \Phi_2(V_{\text{new}})^T R =$$

$$\Phi_2(V_{\text{new}})^T [\Phi_2(V^{(1)}(:, 1)), \dots, \Phi_2(V^{(c)}(:, n))]$$

得到样本低维表示之后, 使用最近邻分类器对样本进行分类。

### 4 实验

实验采用了 ORL 和 Extended YaleB 人脸数据库。在实验中, 所有人脸图像都经过了标准化处理, 即首先标定出人脸图像中两眼的位置, 并在该位置将图像对齐, 然后剪切出图像中

的面部区域。实验中是通过 KTDMMC 算法与已有的 2DMMC 和 2DFDA 算法在 ORL 和 Extended YaleB 人脸数据库中的识别率对比来验证 KTDMMC 算法的有效性。

#### 4.1 ORL 人脸库数据

ORL 数据库中共有 40 个人脸的面部图像, 每个人 10 种不同的姿态, 每幅像素为  $92 \times 112$ , 即为  $92 \times 112$  的矩阵; 人脸姿态有相当程度的变化, 深度旋转和平面旋转可达到  $20^\circ$ , 人脸的尺度也有 10% 的变化。

本实验在 ORL 人脸数据库中选取 200 幅图作为训练集 (即每人 5 幅图), 其他作为测试集。考虑到运算复杂度和存储空间的限制, 将每张图像进行标准化处理, 统一缩放成  $64 \times 64$ 。因此左核矩阵大小为  $12800 \times 64$ , 右核矩阵的大小为  $12800 \times 64$ , 最后的核矩阵的大小为  $12800 \times 12800$ 。

实验采用 Gaussian 核, 参数  $\delta = 0.22$ , 如图 1 所示, 给出了 KTDMMC、2DMMC 以及 2DFDA 算法在 ORL 人脸数据库上识别率随特征维数变化的曲线。通过图 1 的曲线可以看出, 在 ORL 人脸数据库, KTDMMC 算法有更好的识别率, 并且在特征空间维数  $d \geq 12$  时, 其识别率高达 100%, 高于其他算法。

#### 4.2 Extended Yale-B 人脸数据库

此数据集包括 38 个人的 2 414 幅正面人脸图像, 其中每人大约 64 幅。这些图像均在实验室控制光照的条件下拍摄。在下面的实验中, 将每张图像统一缩放成分辨率为  $32 \times 32$ , 并将像素灰度值归一化到单位区间。

实验中选取 75 幅图作为训练集 (即选取 15 人, 每人 5 幅图), 其他作为测试图像。考虑到运算复杂度和存储空间的限制, 将每张图像进行标准化处理, 统一缩放成  $32 \times 32$ , 因此左核矩阵的大小为  $2400 \times 32$ , 右核矩阵的大小为  $2400 \times 32$ , 最后的核矩阵的大小为  $2400 \times 2400$ , 实验结果如图 2 所示。其中采用的核是 Gaussian 核, 参数  $\delta = 0.22$ 。图 2 给出了 KTDMMC、2DMMC、以及 2DFDA 算法在 Extended Yale-B 人脸数据库上识别率随特征维数变化的曲线。通过图 2 曲线可以看出, 在 Extended Yale-B 人脸数据库, KTDMMC 算法有更好的识别率, 并且当特征维数选择 8 时达到了最高的识别率 96%。

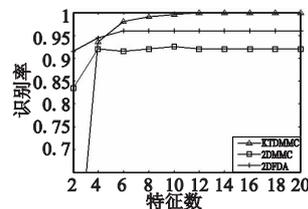


图1 三种算法在ORL人脸数据库上识别率随特征维数变化的曲线

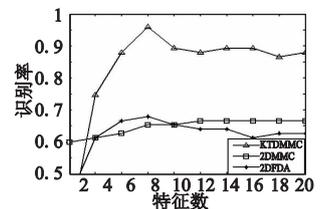


图2 三种算法在YaleB人脸数据库上识别率随特征维数变化的曲线

### 5 结束语

本文提出了一种基于矩阵表示的非线性方法 KTDMMC, 传统核方法只用一个核空间来决定最终识别结果, 而在 KTDMMC 中, 两个核空间同时决定最终识别结果。KTDMMC 最大问题是算法时间复杂性很高, 主要由于核空间是所有样本类矩阵经奇异值分解后所得到  $U$  和  $V$  列向量所张成的, 并且算法需在两个特征空间计算特征矩阵, 导致后面的优化操作计算复杂度高。一个可能的解决方法是找到一种直接基于矩阵表示的核分析方法。

是由于事件 2 比较复杂,其他算法很容易将一个与事件 2 相似的事件误判为一个事件 2 的实例(由于复杂事件比较容易被截断);对于事件 4,针对小船长时间停留情况,SDG 方法也可以得到很好的准确率。如图 4(b)所示,对于事件 5,本文方法的召回率比较高,原因是事件 5 时间间隔较短,SDG 方法可以更好地区分简短事件的子事件与其他干扰子事件。所以 SDG 方法用于事件检测能得到较好的准确率和召回率,能够有效地解决复杂视频事件的检测问题。

#### 4 结束语

本文提出了一种基于超图模型的视频复杂事件建模及检测方法。该方法首先检测出视频中的运动对象并对其进行分类和跟踪,从而提取出对象的运动轨迹;然后通过分析对象的运动轨迹,检测出视频中的所有子事件并构建子事件时序关系图。基于子事件时序关系图,对于训练视频,通过自动构建训练视频中各类子事件间的依赖关系图来建立复杂事件的模型;而对于测试视频,依次利用每一个子事件依赖关系图来构建子事件超图,并通过谱超图聚类分析来检测相应的事件。采用 SDG 来对复杂事件建模不仅能很好地捕捉同一种事件中各个子事件之间可能出现的时序关系变化,而且能有效地描述各个子事件之间不同大小的时序条件依赖关系。不仅如此,SDG 还可以用于多主体事件的建模,且用它来对事件建模时对事件的长度没有限制。因而通过对子事件超图的谱聚类分析,不仅可以检测出多主体事件,而且还可以检测出任意长度的事件。实验结果表明,SDG 方法具有更高的准确率和召回率,能更加有效地适应复杂视频事件的检测。

#### 参考文献:

- [1] HAKEEM A, SHAH M. Learning, detection and representation of multi-agent events in videos[J]. *Artificial Intelligence*, 2007, 171(8-9): 586-605.
- [2] BADLER N. Temporal scene analysis: conceptual description of object movements, University of Toronto Technical Report No. 80[R].

- 1975.
- [3] AYERS D, SHAH M. Monitoring human behavior from video taken in an office environment[J]. *Image and Vision Computing*, 2001, 19(12): 833-846.
- [4] 徐杨,吴成东,陈东岳. 基于视频图像的交通事件自动检测算法综述[J]. *计算机应用研究*, 2011, 28(4): 1206-1210.
- [5] XIN Lun, TAN Tie-niu. Semi-supervised learning on semantic manifold for event analysis in dynamic scenes[C]//Proc of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington DC: IEEE Computer Society, 2007: 18-23.
- [6] 刘卫宁,曾恒,孙隼华,等. 基于视频检测技术的交通拥挤判别模型[J]. *计算机应用研究*, 2010, 27(8): 3006-3008.
- [7] ZHANG Zhang, HUANG Kai-qi, TAN Tie-niu, et al. Trajectory series analysis based event rule induction for visual surveillance[C]//Proc of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington DC: IEEE Computer Society, 2007: 1-8.
- [8] ZHONG Hua, SHI Jian-bo, VISONTAI M. Detecting unusual activity in video[C]//Proc of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. 2004: 819-826.
- [9] RAO Cen, YILMAZ A, SHAH M. View-invariant representation and recognition of actions[J]. *International Journal of Computer Vision*, 2002, 50(2): 203-226.
- [10] JU Shi-guang, CHEN Xiao-jun, XU Guang-hua. An improved mixture Gaussian models to detect moving object under real-time complex background[C]//Proc of International Conference on Cyberworlds. 2008: 730-734.
- [11] SHI Jian-bo, MALIK J. Normalized cuts and image segmentation[J]. *IEEE Trans of Pattern Analysis and Machine Intelligence*, 2000, 22(8): 888-905.
- [12] BERGE C. Graph and hypergraph[M]. Amsterdam: North-Holland, 1973: 528.
- [13] 黄汝激. 超网络的有向超树分析法[J]. *电子科学学报*, 1987, 19(3): 244-255.
- [14] ALLEN J F, FERGUSON G. Actions and events in interval temporal logic[J]. *Journal of Logic Computation*, 1994, 14(5): 531-579.

(上接第 4769 页)

#### 参考文献:

- [1] JI Shui-wang, YE Jie-ping. Generalized linear discriminant analysis: a unified framework and efficient model selection[J]. *IEEE Trans on Neural Networks*, 2008, 19(10): 1768-1782.
- [2] CHEN Li-fen, LIAO H Y M, KO M T, et al. A new LDA-based face recognition system which can solve the small sample size problem[J]. *Pattern Recognition*, 2000, 33(10): 1713-1726.
- [3] CHEN Song-can, LI Dao-hong. Modified linear discriminant analysis[J]. *Pattern Recognition*, 2005, 38(3): 441-443.
- [4] LI Hai-feng, JIANG Tao, ZHANG Ke-shu. Efficient and robust feature extraction by maximum margin criterion[C]//Advances in Neural Information Processing Systems. 2003: 157-165.
- [5] YANG Jian, ZHANG D, FRANGI A F. Two dimensional PCA: a new approach to appearance-based face representation and recognition[J]. *IEEE Trans on Pattern Analysis and Machine Intelligence*, 2004, 26(1): 131-137.

- [6] XIONG Hui-lin, SWAMY M N, AHMAD M O. Two-dimensional FLD for face recognition[J]. *Pattern Recognition*, 2005, 38(7): 1121-1124.
- [7] YANG Jian, ZHANG D, YONG Xu, et al. Two-dimensional discriminant transform for face recognition[J]. *Pattern Recognition*, 2005, 38(7): 1125-1129.
- [8] YE Jie-ping, JANARDAN R, LI Qi. Two-dimensional linear discriminant analysis[C]//Advances in Neural Information Processing Systems. 2004: 1569-1576.
- [9] HE Xiao-fei, CAI Deng, NIYOGI P. Tensor subspace analysis[C]//Advances in Neural Information Processing Systems. 2005.
- [10] GU Quan-quan, ZHONG Jie. Two dimensional maximum margin criterion[C]//Proc of IEEE International Conference on Acoustics, Speech and Signal Processing. 2009.
- [11] YAN Shui-cheng, XU Dong, ZHANG Lei, et al. Coupled kernel-based subspace learning[C]//Proc of IEEE Computer Society Conference on Computer Vision and Pattern Recognition. 2005: 645-650.