

## 张量子空间降维的边缘图像匹配

肖传民<sup>1,2</sup>, 史泽林<sup>1</sup>, 刘云鹏<sup>1</sup>

(1. 中国科学院沈阳自动化研究所, 辽宁 沈阳 110016;  
2. 中国科学院大学, 北京 100049)

**摘要:** 针对传统基于向量子空间降维的图像匹配算法易丢失像素间邻域关系和计算量大的问题, 提出一种基于张量子空间降维的边缘图像匹配算法。通过双边投影变换提取边缘图像的张量子空间, 在降低特征空间维数的同时保持边缘特征之间的邻域关系, 同时采用边缘膨胀后的互相关度量模板与实时图的相似性。标准人脸数据库和红外实时图像的匹配实验结果表明: 该算法在匹配时间、匹配正确率、匹配精度 3 方面较传统基于向量子空间的匹配算法有显著的性能提高, 并且对杂波和部分遮挡有较强的适应性。

**关键词:** 图像匹配; 张量子空间降维; 边缘特征; 相似性度量

**中图分类号:** V19 **文献标志码:** A **文章编号:** 1007-2276(2015)11-3488-06

## Image matching algorithm based on tensor subspace dimensionality reduction

Xiao Chuanmin<sup>1,2</sup>, Shi Zelin<sup>1</sup>, Liu Yunpeng<sup>1</sup>

(1. Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China;  
2. University of Chinese Academy of Sciences, Beijing 100049, China)

**Abstract:** An image matching algorithm based on tensor subspace dimensionality reduction was proposed to the questions of easily losing relationships between pixels and intensively computational problems using traditional vector subspace methods. The algorithm extracts tensor subspace by employing two-sided projection transformation in edge images, reducing dimension of feature space and preserving the relationships between edge pixels. The algorithm measured the similarity between template and real-time image by calculating the correlation of dilated binary images. Experimental results on the standard face database and real IR images show that the new algorithm can improve the computational efficiency remarkably, and has a higher matching rate and matching precision than traditional vector subspace methods. The proposed algorithm can also be applied in cluttering and partially occluded circumstances.

**Key words:** image matching; tensor subspace dimensionality reduction; edge feature; similarity measurement;

收稿日期: 2015-03-14; 修订日期: 2015-04-18

基金项目: 中国科学院光电信息处理重点实验室基金(Y2F4060401)

作者简介: 肖传民(1978-), 男, 博士生, 主要从事自动目标识别技术研究工作。Email: xiaochuanmin@sia.cn

导师简介: 史泽林(1965-), 男, 研究员, 博士生导师, 主要从事精确制导、图像处理等研究工作。Email: zlshi@sia.cn

## 0 引言

图像匹配是计算机视觉及图像处理中的一个重要研究方向,在自动目标识别与跟踪任务中具有重要的应用价值。图像匹配方法主要分为基于灰度的方法和基于特征的方法<sup>[1]</sup>。基于灰度的匹配方法,受光照影响较大,对灰度变化和遮挡比较敏感,并且处理的信息量大;基于特征的匹配方法能够在一定程度上避免上述缺点。现有的基于模板的图像匹配方法对几何形变非常敏感,通常需要利用大量的模板进行匹配,计算量大。由于不同模板之间的畸变不是很大,故可以利用子空间近似的方法,利用特征分解得到模板集合的特征子空间。然后利用特征子空间近似表示模板集合,当特征子空间的维数远小于模板数量时,可以大大提高匹配的速度<sup>[2]</sup>。

但是传统基于特征子空间降维的图像匹配方法在提取图像中的稳定特征建立特征空间时,降维算法多是基于向量的<sup>[2]</sup>。利用向量表示数据有很大的局限性,它破坏了数据的结构,丢失了一些相邻像素间的隐含关系,增加了运算复杂度;第二,在利用某种判决准则计算模板与实时图相似性时,常用的差方和 SSD 准则由于对杂波和遮挡比较敏感,所以匹配效率较低。

为了解决以上问题,研究学者们开始用高阶张量来描述对象,将传统的基于向量的降维算法推广到张量空间中<sup>[3-6]</sup>。为了从张量样本的内在的流形结构中提取有判别特征,Wang 等提出了判别张量子空间分析(Discriminant tensorsubspace analysis, DTSA)算法<sup>[3]</sup>。他们还把一个彩色的人脸图像看作是一个三阶的张量并提出一个基于判别张量的彩色空间(Tensor discriminant color space)模型<sup>[4]</sup>,并用于人脸识别。唐科威等将向量空间中的洛仑兹投影判别法推广到张量空间中,提出张量洛仑兹投影判别法(张量 LDP),人脸数据和纹理数据识别实验验证了该算法的有效性<sup>[5]</sup>。赵永强等充分利用红外多光谱图像的空间和光谱结构,提出了一个 Gabor 张量匹配滤波模型,有效地提高了多光谱图像红外目标的辨识能力<sup>[6]</sup>。

对于前视红外景象匹配自动目标识别,模板图像是从下视可见光图像生成,而实时图像是红外前

视图图像,同一场景的实时图像与模板图像表现出完全不同的灰度特征。然而,边缘轮廓特征是可见光和红外图之间的共有特征,基于边缘的匹配算法是解决可见光和红外图像间匹配问题的首选。

针对以上分析,文中提出一种基于张量子空间降维的边缘图像匹配方法。与现有张量子空间降维方法不同的是,文中通过张量子空间分析提取边缘图像中的有效特征,降低特征空间的维数,提高计算效率,实验结果验证了所提出算法的有效性。

## 1 张量子空间降维

### 1.1 张量基础

张量是矢量和矩阵概念的推广。标量是零阶张量,矢量是一阶张量,矩阵是二阶张量,而三阶张量好比“立方矩阵”,更高阶的矩阵无法用图形表达,也超出了人们的直观想象空间,三阶及以上张量被称为高阶张量。图 1 给出了一个三阶张量的示意图。




图 1 三阶张量

Fig.1 Third order tensor

假设  $X \in R^{I_1 \times \dots \times I_N}$  表示一  $N$  阶张量,当  $N=1$  时,  $X \in R^I$  表示向量;当  $N=2$  时,  $X \in R^{I_1 \times I_2}$  表示矩阵。张量的  $d$  阶矩阵展开是将张量  $X \in R^{I_1 \times I_2 \times \dots \times I_N}$  在第  $d$  ( $d=1, 2, \dots, N$ ) 维上展开成矩阵  $R_d \in R^{I_d \times M_d}$  的过程,其中  $M_d = I_1 \times I_2 \times \dots \times I_{d-1} \times I_{d+1} \times \dots \times I_N$ 。张量  $X \in R^{I_1 \times I_2 \times \dots \times I_d \times \dots \times I_N}$  与矩阵  $U \in R^{J \times I_d}$  的  $d$  阶乘积表示为:

$$T = X_d \times U \in R^{I_1 \times \dots \times I_{d-1} \times J \times I_{d+1} \times \dots \times I_N} \quad (1)$$

### 1.2 张量子空间降维

对于给定的  $N$  个训练样本表示为:

$$X = \{X_1^1, X_2^1, \dots, X_{N_1}^1, X_1^2, X_2^2, \dots, X_{N_2}^2, \dots, X_1^c, X_2^c, \dots, X_{N_c}^c\} \quad (2)$$

式中:  $X_i^c \in R^{I_1 \times I_2}$  为第  $c$  类数据中的第  $i$  个样本;  $C$  为

样本类别总数;  $N_c$  为第  $c$  类数据的训练样本数, 且满足  $N=N_1+N_2+\dots+N_c$ 。对于传统向量空间降维方法中, 数据  $X_i$  首先要转成向量形式  $x_i \in R^{n \times 1}$ , 其中  $n=I_1 \times I_2$ ,  $I_1$  和  $I_2$  分别表示样本数据的宽和高, 则训练样本集合表达为:

$$X = \{x_1^1, x_2^1, \dots, x_{N_1}^1, x_1^2, x_2^2, \dots, x_{N_2}^2, \dots, x_1^c, x_2^c, \dots, x_{N_c}^c\} \quad (3)$$

相应的子空间变换即寻找最佳的投影矩阵  $U \in R^{n \times L_1}$ , 将原数据投影到子空间:

$$Y_i = U^T X_i \quad (4)$$

使得投影后的特征数据  $Y_i \in R^{L_1 \times 1}$  具有最佳的类别识别能力, 同时达到降维的目的。主成分分析(PCA)是一种典型的基于向量空间降维的方法, 其投影矩阵由数据协方差矩阵前  $k$  个最大特征值对应的特征向量组成。

张量子空间(TensorPCA)降维是基于传统 PCA 方法的扩展。TensorPCA 则试图将数据投影到方差最大的张量子空间中, 以保证重构误差最小。对于训练集中的样本  $X_i \in R^{I_1 \times I_2}$ , 无需转化成向量表示, 而作为一个二阶张量表示。则相应的张量子空间变换即寻找最佳的投影张量  $U \in R^{I_1 \times L_1}$  和  $V \in R^{I_2 \times L_2}$ , 将原数据投影至张量子空间:

$$Y_i = U^T X_i V \quad (5)$$

使投影后的数据  $Y_i \in R^{L_1 \times L_2}$  具有最佳的类别识别能力, 其中  $L_1 < I_1$  和  $L_2 < I_2$  是降维后的空间维数。两个投影矩阵  $U$  和  $V$  的最佳解是通过计算  $Y$  和  $X$  之间的最小重构误差得到<sup>[10]</sup>。参考文献[7]的算法在训练样本数量较多时会产生高维的协方差矩阵。文中参照参考文献[7]迭代过程做了改进, 计算两个投影矩阵的具体迭代过程如下。

算法: TensorPCA

输入: 样本集合  $X = \{X_i | X_i \in R^{I_1 \times I_2}, i=1, 2, \dots, n\}$ ,

最大迭代次数:  $T$

输出: 投影矩阵  $U_{(t)} \in R^{I_1 \times L_1}$  和  $V_{(t)} \in R^{I_2 \times L_2}$

初始化:  $t=1$  时,  $U_{(t)}$  和  $V_{(t)}$  分别为  $I_1 \times L_1$  和  $I_2 \times L_2$  的单位矩阵。

迭代:

for  $t=1$  to  $T$

1.  $Y_i = U_{(t)}^T X_i$ ;

2. 计算  $Y$  的均值矩阵:  $E_Y = \frac{1}{n} \sum_{i=1}^n Y_i$ ;

3. 计算  $Y$  的协方差矩阵:

$$C_Y = \frac{1}{n} \sum_{i=1}^n (Y_i - E_Y)^T (Y_i - E_Y)$$

4. 计算  $C_Y$  的特征值和特征向量:

$$C_Y V_{(t)} = \Lambda V_{(t)}$$

其中  $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_m)$  为  $C_Y$

前  $m$  个最大特征值组成的对角阵;

5.  $Z_i = X_i \times V_{(t)}$ ;

6. 计算  $Z$  的均值矩阵:  $E_Z = \frac{1}{n} \sum_{i=1}^n Z_i$ ;

7. 计算  $Z$  的协方差矩阵:

$$C_Z = \frac{1}{n} \sum_{i=1}^n (Z_i - E_Z)^T (Z_i - E_Z)$$

8. 计算  $C_Z$  的特征值和特征向量:

$$C_Z U_{(t)} = \Lambda U_{(t)}$$

其中  $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_l)$  为  $C_Z$  前  $l$  个最大特征值组成的对角阵;

}

循环迭代的次数可以实验确定。

## 2 基于张量子空间降维的边缘图像匹配

### 2.1 边缘特征相似性度量

边缘检测<sup>[8-10]</sup>是图像特征提取的基础, 是图像分析的一个重要内容, 在计算机视觉系统的初级处理中具有关键作用。Canny 算子具有很好的边缘检测性能和很好的抗噪性能, 因而得到了广泛应用。文中目标匹配处理基于图像边缘特征, 首先采用 Canny 算子对待处理图像进行边缘特征检测。

为了增加算法的鲁棒性, 给定二值边缘图像  $I_m$  和  $I_n$ , 对图像  $I$  进行  $d$  个像素的边缘膨胀得到  $I^d$ 。边缘粗化后的图像  $I_m$  和  $I_n$  之间的相似性度量可以通过以下边缘互相关度量计算:

$$\Phi_d(I_m, I_n) = \frac{x_m^T x_n}{\|x_m\|^2} \quad (6)$$

式中:  $x_m$  和  $x_n$  都是二维张量,  $\|x_m\|^2$  则表示  $I_m$  自身边缘点的数目。对于通过张量子空间降维后的特征相似性度量可表示为:

$$\Phi_d(Y_m, Y_n) = \frac{Y_m^T Y_n}{\|Y_m\|^2} \quad (7)$$

### 2.2 匹配算法描述

(1) 首先对模板集合图像和待匹配图像分别进行边缘检测;

(2) 根据模板的二值边缘图构造特征张量矩阵。 $I_1, I_2, \dots, I_N$  为模板的二值图,  $X_1, X_2, \dots, X_N$  为它们对应的二维张量矩阵, 通过算法 1 计算模板集合的张量子空间投影矩阵  $U \in R^{l_1 \times l_1}$  和  $V \in R^{l_2 \times l_2}$ 。并用投影矩阵将训练样本投影到张量子空间  $Y_i = U^T X_i V$ 。

(3) 遍历整个实时边缘图像, 对于每个待匹配图像, 首先对其二值边缘图进行  $d$  个像素的膨胀, 得到其张量表示为  $Test^d$ , 用投影矩阵将其投影到张量子空间。

(4) 根据公式(7)计算模板集合与实时图像之间的相似度量, 给出匹配识别结果。

## 3 实验分析

### 3.1 实验参数设置

为了验证该算法的有效性, 用文中基于张量子空间降维的边缘匹配方法 (TensorM) 与传统基于向量空间降维的边缘匹配算法 (VectorM) 进行比较。算法用 Matlab 语言编写, 在处理器为 Intel i5-2400 3.1 GHz、内存为 3GB 的微机上完成。

在算法 1 中,  $m$  和  $l$  代表张量子空间的大小。子空间大小一般难以确定, 这里使用占有  $\Lambda$  中的所有特征值之和百分比 (testQ) 的前  $p$  个特征值来确定张量子空间的大小。算法最大循环迭代次数选为 2。

为了确定 testQ, 首先采用 ORL 人脸数据库对所提出的算法进行仿真实验。ORL 数据库包含 40 个人的人脸图像, 每人 10 张, 图像大小均为  $112 \times 92$ 。用留一交叉法<sup>[11]</sup>来识别测试, 即每次随机从 400 幅图像中选择 1 幅作为测试样本, 另外 399 幅作为训练样本集。训练集张量的大小为  $112 \times 92 \times 399$ 。重复进行 1000 次识别实验, 图 2 给出了不同 testQ 下的识别结果。从图中可以看出, 保留太多或太少的特征所能达到的识别率都不是最优。文中所提出的 TensorM 算法在 testQ=0.6 的情况下达到最优识别率 97.3%, VectorM 算法在 testQ=0.7 的情况下达到最优识别率 91.5%, 且 TensorM 算法明显优于 VectorM 算法。

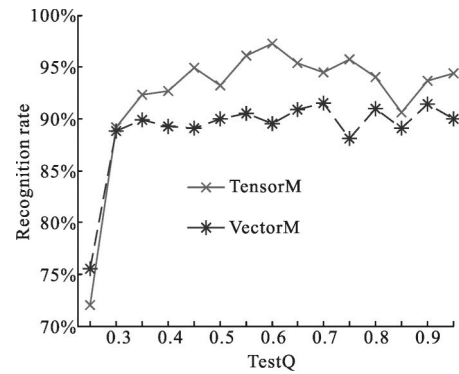


图 2 不同 testQ 对应的识别率

Fig. 2 Different testQ corresponding recognition rate


### 3.2 红外实时图匹配结果

文中采用一组高速交通枢纽的红外图像实时图像序列进行图像匹配仿真实验。实验用的图像序列包含 300 帧图像, 每帧图像大小为  $512 \times 256$ 。对于每一帧图像根据航向角、俯仰角、横滚角不同参数的变化得到模板共 224 个。图 3 为其中一帧图像对应的部分模板图像集合。模板图像的大小为  $206 \times 100$ , 因此模板张量描述为  $T^{206 \times 100 \times 224}$ 。




(a) 部分模板

(a) Partial template



(b) 红外实时图

(b) Infrared real-time image



(c) 实时图边缘图像

(c) Real-time edge image

图 3 实验用部分模板和实时图像

Fig. 3 Template of experiment and real-time image

实验一: 算法匹配快速性验证

将文中所提出的 TensorM 算法与 VectorM 算法<sup>[12]</sup>

和传统的模板匹配算法(TemplateM)进行比较进行了实验对比。传统的模板匹配方法是把所有的参考模板和待匹配图像一一进行匹配。实验用模板和实时图像如图 3 所示。实验中 TensorM 算法的 testQ=0.6, VectorM 算法的 testQ=0.7。表 1 给出了算法的匹配时间性能比较,表中数据是完成 1 个位置处的匹配所用的平均时间,整幅图像的有效匹配范围为  $500 \times 250$ 。此外离线计算模板集合张量子空间的时间是 1.569 7 s,实时图边缘提取时间是 0.24 s。模板张量降维后的子空间的大小为  $T^{13 \times 11 \times 224}$ 。图 4 给出了匹配结果。

表 1 算法快速性验证的实验结果

Tab.1 Experimental result of algorithm rapidity verification

| Template quantity | TemplateM<br>matching time/s | VectorM<br>matching time/s | TensorM<br>matching time/s |
|-------------------|------------------------------|----------------------------|----------------------------|
| 112               | 0.070 31                     | 0.047 55                   | 0.009 4                    |
| 224               | 0.116 2                      | 0.054 41                   | 0.015 72                   |




图 4 匹配结果

Fig.4 Matching result

由表 1 还可以看出:随着模板数量的增多,基于子空间的算法增长时间不多。文中 TensorM 算法的快速性表现的尤为突出。此算法会随着模板量的增加,较传统模板匹配方法节省更多的匹配时间,速度优于基于向量子空间的图像匹配算法。

#### 实验二:算法匹配性能验证

在实时图像中加入 0.05 椒盐噪声,进行了 100 次匹配识别实验,实验结果如表 2 所示。由表 2 可知,文中方法在匹配正确率和匹配精度上与传统模板匹配方法几乎一致,较基于向量子空间降维的匹配算法有较大的性能提高。

表 2 算法性能比较

Tab.2 Algorithm performance comparison

| Performance comparison          | TemplateM | VectorM | TensorM |
|---------------------------------|-----------|---------|---------|
| Matching accuracy               | 98%       | 66%     | 96%     |
| Average matching accuracy/pixel | 0.723 8   | 1.218 5 | 0.813 4 |

### 3.3 算法抗杂波和遮挡干扰验证

实验设计为对场景中的目标进行匹配。选取目标的 32 幅图像进行特征提取, TensorM 算法的 testQ=0.6, 并利用文中算法进行匹配。模板为  $128 \times 128$  像素的图像,模板张量的大小为  $T^{128 \times 128 \times 32}$ ,模板张量降维后的子空间的大小为  $T^{25 \times 19 \times 32}$ ,场景图为  $512 \times 512$  像素的图像,图 5 为匹配结果。图 5(a)为原始图像经 Canny 算子边缘检测后的匹配结果,图 5(b)在原始图像中加入 0.05 椒盐噪声后的匹配结果,图 5(c)在图像中目标有部分遮挡情况下的匹配结果,图 5(d)在图像中目标同时有杂波和部分遮挡情况下的匹配结果。




图 5 算法抗杂波和干扰的实验结果

Fig.5 Algorithm anti-clutter and partial occlusion interference

由图 5 可知,在图像中有杂波和部分遮挡情况下,或者图像中同时存在杂波和部分遮挡情况,文中算法都能够给出正确的匹配结果。由此,验证了文中算法有较强的抑制杂波和部分遮挡的能力。

## 4 结论

文中针对传统基于向量子空间降维的匹配算法匹配效率低和对噪声、遮挡敏感的不足,提出一种基于张量子空间降维的边缘图像匹配方法。张量子空间分析能够很好地提取图像中有效特征,而不破坏数据结构,并能降低特征空间的维数,从而提高匹配效率;边缘粗化后的互相关度量本身对噪声不敏感的特点,提高了匹配的鲁棒性,对杂波和噪声较严重的情况都有很好的抑制效果。实验表明,这种基于张

量子空间降维的边缘图像匹配方法, 在提高匹配精度和计算效率的同时, 有效提高了算法对杂波和遮挡的适应性。实现文中算法的实时工程应用将是后续工作的重点方向。

#### 参考文献:

- [1] Qiao Xiangchen, Zao Zhuang. Research on the algorithm of image matching based on improvedSIFT [C]//International Conference on Information Technology for Manufacturing Systems, 2014, 686: 348–353.
- [2] He X, Yan S, Hu Y, et al. Face recognition using Laplacianfaces [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27(3): 328–340.
- [3] Wang Sujing, Zhou Chunguang, Zhang Na, et al. Face recognition using second-order discriminant tensor subspace analysis[J]. *Neurocomputing*, 2011, 74(12): 2142–2156.
- [4] Wang Sujing, Yang Jian, Zhang Na, et al. Tensor discriminant color space for face recognition[J]. *IEEE transactions on Image Processing*, 2011, 20(9): 2490–2501.
- [5] Tang Kewei, Liu Risheng, Du Hui, et al. Reduction method based on tensor and lorentzian geometry[J]. *Acta Automatica Sinica*, 2011, 37(9): 1151–1156. (in Chinese)  
唐科威, 刘日升, 杜慧, 等. 一种基于张量和洛仑兹几何的降维方法[J]. 自动化学报, 2011, 37(9): 1151–1156.
- [6] Zhao Yongqiang, Zhang Guohua, Jie Feiran, et al. Multi-band infrared targets discrimination based on tensor filters [J]. *Infrared and Laser Engineering*, 2011, 40(10): 1862–1865. (in Chinese)  
赵永强, 张国华, 揭裴然, 等. 基于张量滤波器的多波段红外目标辨识[J]. 红外与激光工程, 2011, 40(10): 1862–1865.
- [7] Tao Dacheng, Li Xuelong, Wu Xindong, et al. General tensor discriminant analysis and gabor features for gait recognition [J]. *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 2007, 29(10): 1700–1715.
- [8] Xiao Chuanmin, Shi Zelin, Xia Renbo, et al. A edge detection algorithm based on visual saliency [J]. *Information and Control*, 2014, 43(1): 9–13. (in Chinese)  
肖传民, 史泽林, 夏仁波, 等. 一种基于视觉显著性的图像边缘检测算法[J]. 信息与控制, 2014, 43(1): 9–13.
- [9] Chen Enqing, Wang Jianbo, Qi Lin, et al. A novel multiscale edge detection approach based on nonsubsampling contourlet transform and edge tracking[J]. *Mathematical Problems in Engineering*, 2015, 2015: 504725.
- [10] Zhang H L, Ravat D, Maragoni Y R. Edge detection of potential-field sources using normalized anisotropy variance [J]. *Society of Exploration Geophysicists*, 2014, 79 (3): 43–53.
- [11] Cawley G C, Talbot N L C. Preventing over-fitting during model selection via Bayesian regularization of the hyper-parameters[J]. *Journal of Machine Learning Research*, 2007, 8(4): 841–861.