

基于代数特征的多光谱图像特征提取方法

刘松涛¹, 常 春¹, 马新星², 王赫男¹

(1. 海军大连舰艇学院信息作战系, 辽宁 大连 116018; 2. 海军航空工程学院控制工程系, 山东 烟台 264001)

摘 要:多光谱图像特征提取的好坏直接关系着目标识别算法的复杂程度,也影响着最终目标识别的性能。研究了一维主成分分析(1DPCA)、二维主成分分析(2DPCA)、一维奇异值分解(1DSVD)和二维奇异值分解(2DSVD)等代数特征提取方法,并用这些方法构成图像识别框架的特征提取部分,通过识别率的大小来验证是否适合于多光谱图像特征提取。实验结果表明:①与可见光图像目标识别相比,PCA和SVD特征更适用于红外图像目标识别;②训练样本分类时,PCA和SVD特征的识别性能改善不明显;③训练样本少时,SVD重构图像、2DSVD和1DPCA特征的识别性能较好。

关键词:多光谱图像;特征提取;主成分分析;奇异值分解

中图分类号:TP391.41 **文献标识码:**A **DOI:**10.3969/j.issn.1001-5078.2013.11.25

Feature extraction method for multi-spectral image based on algebraic feature

LIU Song-tao¹, CHANG Chun¹, MA Xin-xing², WANG He-nan¹

(1. Dept. of Information Operation, Dalian Naval Academy, Dalian 116018, China;

2. Dept. of Control Engineering, Naval Aeronautical and Astronautical University, Yantai 264001, China)

Abstract: The result of feature extraction on multi-spectral image is related to the complex degree of target recognition algorithm directly, and also has deep influence on the performance of target recognition. On the aspect of algebra feature methods, the basic principles of 1DPCA, 2DPCA, 1DSVD, and 2DSVD are studied, then they are used as the feature extraction part of image target recognition algorithm. Whether is suitable for the multispectral image feature extraction is verified through the size of the recognition rate. The experiment results show that, ① the feature of PCA and SVD on infrared image has better recognition results than that of visible image; ② when training samples are classified, the improvement of recognition performance based on the feature of PCA and SVD is not obvious; ③ under the condition of little training sample, the features of SVD reconstructing image, 2DSVD and 1DPCA have good recognition performance.

Key words: multi-spectral image; feature extraction; principal component analysis; singular value decomposition

1 引 言

多光谱(可见光、中波/长波红外)图像中可见光图像分辨率高,目标边缘明显,对比度清晰,但是只能在白天、顺光、能见度好的条件下获取,战场环境的应用概率低于20%。而中波/长波红外图像可全天候获取,目标特征明显,但是目标与背景对比度低,边缘模糊,噪声较大。因此,有必要研究合适的特征提取方法,可以准确地描述可见光和中波/长波

红外图像目标的本质特征,然后通过特征融合技术来提高多光谱图像目标的识别能力。

常见的图像特征包括:灰度特征、几何特征、轮廓特征、代数特征和纹理特征等。在人脸识别领域,

基金项目:国家自然科学基金项目(No. 61303192)资助。

作者简介:刘松涛(1978-),男,博士后,副教授,硕士生导师。主要从事图像处理,成像制导,光电对抗等研究工作。E-mail:navylst@163.com

收稿日期:2013-04-03; **修订日期:**2013-04-23

基于代数特征的人脸识别方法因其计算简单、有效等特性引起了人们的广泛注意,已成为人脸图像特征提取和识别的主流方法之一。所谓代数特征,就是将图像视为一个矩阵,利用各种代数变换或分解来提取图像的代数特征,如特征值、特征向量等。常见的基于代数特征的图像特征提取方法包括:主成分分析(Principal Component Analysis, PCA)^[1]、独立成分分析(Independent Component Analysis, ICA)^[2]、奇异值分解(Singular Value Decomposition, SVD)^[3]、线性判别分析(Linear Discriminant Analysis, LDA)^[4]、非负矩阵分解(Non-negative Matrix Factorization)^[5]等。本文主要关注基于主成分分析和奇异值分解的特征提取方法。PCA 是基于信号的二阶统计特性,借助一个正交变换矩阵,将分量相关的原随机变量转换成分量不相关的新变量,得到数据的低维子空间表示。文献[1]最早应用 PCA 技术,提出了著名的特征脸方法,但传统 PCA 有两个明显的缺点:(1)需要将二维图像矩阵转化为一维图像向量,造成图像向量的维数高,在大尺寸和小样本的情况下,难以精确地求解协方差矩阵;(2)PCA 只利用了图像的全局信息,对人脸表情和光照条件的变化敏感。针对上述不足, Yang 等提出了图像 PCA^[6]和二维 PCA(2DPCA)^[7-8]。与 PCA 相比,2DPCA 不仅能更精确地求解协方差矩阵,而且能大大提高特征提取的速度。但是 2DPCA 提取的特征向量维数还是较高, Kong 等^[9]提出了广义二维主分量分析(G2DPCA)方法,可同时去除图像各行和列像素间的相关性,大大降低了特征维数。普通 2DPCA 中,计算投影矩阵时需要所有的训练样本,如果额外增加了样本,则需要全部重新计算,而实际问题的样本有可能非常多,也有可能是逐渐获取的,文献[10]提出了增量学习的 2DPCA,可以解决计算量大或者重复计算的问题。针对 PCA 仅利用了图像的全局信息,严慧等^[11]综合全局信息和局部信息,将非负约束应用到 2DPCA 中,提高了人脸识别精度。

奇异值固有的稳定性、比例不变性、旋转不变性和降维压缩的特征能有效地反映矩阵特征。Hong 等^[3]首先提出用奇异值分解来提取一组奇异值,作为人脸识别的分类特征,改善了分类性能。随着奇异值分解的成功应用,出现了高阶 SVD^[12]、多分辨率 SVD^[13]、二维 SVD(2DSVD)^[14]、分数(Fractional) SVD^[15]和显著(Dominant) SVD^[16]等用于人脸识别,分数 SVD 主要考虑到大的奇异值对光照和表情变化敏感,应用分数函数来平滑奇异值,而显著 SVD

将每个图像的奇异值谱分为三个子空间,然后正则化重要基的系数,既考虑了每个基的可分辨能力,又避免了分数 SVD 中参数的难以确定。

总之, SVD 直接从图像的灰度矩阵提取特征, PCA 从训练图像集中提取特征,因此, PCA 具备参考图像的统计意义,而 SVD 更能表征参考图像的确定性特征。本文主要是将 PCA、2DPCA、SVD 和 2DSVD 方法用于多光谱图像特征提取,结合训练样本是否分类和奇异值是否重构图像,形成了一系列特征提取方法,并基于多光谱图像进行了分类实验,通过识别率大小来寻找适合于多光谱图像的特征提取方法。

2 基于代数特征的特征提取理论

考虑到 1DPCA 和 1DSVD 理论非常普及,本节仅重点阐述 2DPCA 和 2DSVD 理论。

2.1 二维主成分分析(2DPCA)

2DPCA 方法直接对二维图像矩阵应用主分量分析技术,而不需将图像矩阵转换为矢量^[6-7,17]。该方法的显著特点是计算简便,计算代价小于传统 1DPCA。算法的基本思路为:

将图像矩阵 T 对矢量 u 作投影,可得到矢量 v , 用公式表示为 $Tu = v$, 称 v 为特征矢量。将所有图像均对 u 作投影,可得出各自的特征矢量。规定最优的投影轴 u 应使 $u^T G_i u$ 取极大值,其中 $G_i = \frac{1}{C} \sum_{i=1}^C (T_i - \bar{T})^T (T_i - \bar{T})$, $\bar{T}$ 为所有图像矩阵的均值, C 为图像总数。而求 $u^T G_i u$ 极大值的问题可转化为求 G_i 极大特征值所对应特征向量的问题。

显然,将图像直接投影到矢量,应有两种运算形式,一种是矩阵右乘矢量的形式,称为 I 型 2DPCA,而另一种是矩阵左乘矢量的形式,称为 II 型 2DPCA。这两种方案将原始图像变换到不同的空间,导致 I 型 2DPCA 只保留了图像的同列像素之间的相关信息, II 型 2DPCA 只保留了图像的同行像素之间的相关信息。因此,两种方案对图像具有不同的描述能力。为此,可考虑将 I 型 2DPCA 和 II 型 2DPCA 提取到的特征相结合,充分利用原图像的相关信息。

2DPCA 与 1DPCA 的原理本质上一致,区别在于 1DPCA 需要先将图像拉直成向量再处理,而 2DPCA 直接对二维图像进行处理。在进行图像特征提取时, 1DPCA 与 2DPCA 都需要处理一个协方差阵来获取投影矩阵,但是对于一个 $m \times n$ 的图像, 1DPCA 要处理的是一个 $m \times n$ 阶协方差阵,而

2DPCA 要处理的是一个 m (或 n) 阶协方差阵。

2.2 二维奇异值分解(2DSVD)

2DSVD 是 1DSVD 的延伸^[14], 基于原始图像建立行-行协方差矩阵和列-列协方差矩阵, 然后求取协方差矩阵的特征向量用于图像特征提取。算法的基本思路为:

给定一个图像样本集 $\{T_i\}_{i=1}^C, T_i \in R^{m \times n}$, 定义平均的行-行协方差矩阵 F 和列-列协方差矩阵 G 如下:

$$F = \frac{1}{C} \sum_{i=1}^C (T_i - \bar{T})(T_i - \bar{T})^T \quad (1)$$

$$G = \frac{1}{C} \sum_{i=1}^C (T_i - \bar{T})^T (T_i - \bar{T}) \quad (2)$$

其中, $\bar{T} = \sum_i \frac{T_i}{C}$ 。令 U_r 等于 F 的 r 个主要特征向量, V_s 等于 G 的 s 个主要特征向量, $U_r = (u_1; \dots; u_r)$, $V_s = (v_1; \dots; v_s)$, 则 $\{T_i\}_{i=1}^C$ 的 2DSVD 是 $(U_r, V_s, \{M_i\}_{i=1}^C)$, $M_i = U_r^T T_i V_s$, $U_r \in R^{m \times r}$, $V_s \in R^{n \times s}$, $M_i \in R^{r \times s}$, M_i 是样本 T_i 的特征矩阵。

从上述概念可以知道, 2DSVD 相对于 1DSVD 来说, 没有直接用图像矩阵进行奇异值分解, 而是先求取图像样本集行和列两个方向的协方差矩阵, 然后对这两个方向的协方差矩阵分别进行主成分分析, 最后用降维后的行和列特征向量重构出低维特征矩阵。可见, 2DSVD 充分利用了行列两个方向的图像信息, 比 1DSVD 能更有效地提取原始图像的特征。

3 图像目标识别框架

鉴于本文用识别率来验证特征提取方法的性能, 本节简单介绍图像目标识别框架。主要包括图像预处理、特征提取和决策分类三个过程, 具体如图 1 所示。




图 1 图像目标识别框架

预处理的目的是通过规范化消除由于背景和光照明暗等变化给图像带来的影响。常见的预处理方法有均值化和灰度化^[18]。均值化可以消除图像曝光程度不同造成的灰度值差异, 而针对彩色图像的灰度化有利于多光谱图像之间的统一。

特征提取的目的, 是通过某种变换, 把目标从图

像空间转化到特征空间, 得到所谓的“二次特征”, 比原始图像灰度更有利于分类识别。本文采用奇异值分解和主成分分析两类方法进行一维和二维特征提取。

分类识别是图像识别框架的最终部分。特征量选取后, 需要进行分类器的设计。本文的重点在于特征提取, 故采用简单的最近邻分类器进行分类^[19]。

4 算法实现过程

4.1 一维主成分分析算法

(1) 构造特征子空间。输入一组已知的目标图像作为训练样本集 $\{T_i\}_{i=1}^C, T_i \in R^{m \times n}$, 将图像按行链接在一起构成 N 维向量 $x_k = (x_{k1}, \dots, x_{kN})^T$, $k=1, \dots, C$, 构成原始图像空间。训练样本集的均值向量为: $u = \frac{1}{C} \sum_{k=1}^C x_k$, 协方差矩阵为:

$$S_x = \frac{1}{C} \sum_{k=1}^C (x_k - u)(x_k - u)^T \\ = \frac{1}{C} \sum_{k=1}^C \Phi_k \Phi_k^T = \frac{1}{C} A A^T \quad (3)$$

式中, $A = (\Phi_1, \Phi_2, \dots, \Phi_C)$ 。通常 N 值很大, 直接计算 S_x 的特征值和特征向量难度较大, 当样本个数 C 不多时, 可以先计算 $C \times C$ 维矩阵 $A^T A$ 的特征值 λ_k 和特征向量 V_k , 然后根据奇异值分解定理, $U_k = A V_k \lambda_k^{-1/2}$ 就是 S_x 的特征向量。最后, 选择 p ($p < C$) 个较大特征值对应的特征向量构成特征子空间 $W = (U_1, \dots, U_p)$ 。

(2) 把训练图像和测试图像投影到特征子空间: $y = W^T(x - u)$ 。

(3) 根据最近邻分类器来确定测试图像类别。

4.2 二维主成分分析算法

4.2.1 I 型 2DPCA 和 II 型 2DPCA 算法

两者区别只在于特征提取的方向不同, 仅以 I 型 2DPCA 为例进行说明。算法步骤中仅第一步构造特征子空间和 PCA 算法不同, 具体为: 求取训练集中所有样本的均值, 然后求出行-行协方差矩阵的特征值和特征向量, 并根据前 p 个较大的特征值, 取出对应的特征向量构成特征空间。

4.2.2 I 型和 II 型联合 2DPCA 算法

I 型 2DPCA 的特征矢量第 i 个元素值即为图像第 i 行中所有像素值以投影轴的分量为权重的加权和。而 II 型方案中图像在某一个投影轴上投影所得特征矢量的各元素值分别为原图像各列中像素值

的加权和。这说明两种方案得出的数据是从不同角度对原图像的描述,具有一定的互补性。因此,可将I型方案和II型方案得出的行特征与列特征合并。

4.3 一维奇异值分解算法

本文采用两种方法将一维奇异值分解应用于图像识别,一种是将图像矩阵的奇异值降维后直接作为特征的基本SVD算法,另一种是将降维后的奇异值重构图像作为特征的SVD重构图像算法。

4.3.1 基本SVD算法

(1)构造特征子空间。输入一组已知的目标图像作为训练样本集 $\{T_i\}_{i=1}^C, T_i \in R^{m \times n}$,对每一幅图像的灰度矩阵进行奇异值分解,只取前 p 个较大的奇异值,构成特征矢量,得到一组 p 维矢量 $\lambda_i = (\lambda_{i1}, \dots, \lambda_{ip})^T (i=1, \dots, C)$ 构成目标的特征子空间。

(2)输入测试图像,取前 p 个较大的奇异值构成特征矢量 $\lambda = (\lambda_1, \dots, \lambda_p)^T$ 。

(3)根据最近邻分类器来确定测试图像的类别。

4.3.2 SVD重构图像算法

SVD重构图像算法的步骤与基本SVD算法相同,其区别是,前者将降维后的奇异值重新构成图像,将重构的图像矩阵直接作为特征,而不是直接用奇异值作为分类的特征。重构方法为: $T = U\lambda V^T$,其中 λ 为降维后的 p 维奇异值, U 和 V 分别是原图像中分解出的正交向量。

4.4 二维奇异值分解算法

二维SVD算法的步骤也和基本SVD算法相同,不同之处在于训练样本和测试样本的特征构成,具体为:

(1)从训练集中计算出 U_k 和 V_s ,同时每一个训练图像样本得到一个特征矩阵。

(2)计算每一个测试图像样本的特征矩阵。

5 仿真实验

5.1 实验图像

实验用两组图像进行。第一组是舰船目标红外图像,每类5幅,共15幅,如图2所示。第二组是舰船目标可见光图像,也是每类5幅,共15幅,如图3所示。



图2 舰船目标红外图像




图3 舰船目标可见光图像

需要说明的是,无论是舰船目标红外图像,还是舰船目标可见光图像,原始的15幅模板图像由于反应了不同目标的大小和姿态,模板图像大小并不一致。我们以每15幅图像中最小的图像宽和高为标准,对所有图像都进行了缩放,并将彩色图像转化为灰度图像。

5.2 结果分析

表1和表2反映了本文提到的各种特征提取算法分别对两组图像进行识别的结果,每组实验分为两类,一类是分类识别,一类是不分类识别,最后得出每种算法的识别率。分类识别的含义是对每一个图像类都建立一个特征子空间,然后看未知图像和已知图像类中哪个子空间的距离最近。不分类识别的含义是所有训练图像建立一个特征子空间,没有利用测试数据的类别信息。

表1 舰船目标红外图像识别结果

	分类						
	1DPCA	2DPCA			1DSVD		2DSVD
		行	列	行列	奇异值	重构	
识别率/%	83.3	66.7	83.3	83.3	50	100	66.7
	不分类						
	1DPCA	2DPCA			1DSVD		2DSVD
		行	列	行列	奇异值	重构	
识别率/%	100	83.3	33.3	66.7	50	100	83.3

表2 舰船目标可见光图像识别结果

	分类						
	1DPCA	2DPCA			1DSVD		2DSVD
		行	列	行列	奇异值	重构	
识别率/%	33.3	66.7	83.3	66.7	33.3	66.7	83.3
	不分类						
	1DPCA	2DPCA			1DSVD		2DSVD
		行	列	行列	奇异值	重构	
识别率/%	83.3	66.7	50	44.4	33.3	83.3	66.7

比较实验结果我们可以得到以下结论:

(1)整体上,红外图像的PCA和SVD特征识别效果优于可见光图像的PCA和SVD特征识别效果。可能是由于红外图像特征更加明显,不同图像

之间更容易区别,可见光图像转化为灰度图像后,色彩信息丢失,没能充分体现出可见光图像的优点,所以识别效果稍差,但应该说,无论可见光图像,还是红外图像,识别效果相差不大。如果考虑彩色图像的PCA特征提取,可能识别效果会更好。

(2)无论是可见光图像,还是红外图像,PCA和SVD特征按类识别时识别率并没有明显增加,有时识别率反而会减小。这可能是由于分类后样本数太少导致的,理论上,识别率会有所增加,因为按类提取特征能够大大减小不同类型图像之间的相关度,能够更明显地反映各类图像本身的特征。

(3)无论是可见光图像,还是红外图像,2DPCA的识别效果都没有明显优于1DPCA,甚至还会变差,这主要是由于样本数太少导致的。没有体现出2DPCA在计算效率和识别性能方面的优势。关于2DPCA,分别从图像的行、列以及行列结合三个角度进行特征提取,但是行列结合的识别率没有明显优于行、列中的一种,并且运算量较大,这是因为行列结合这种方法只是将行、列算法中求得特征矩阵的欧式距离简单相加,并没有显示出较好的区分度,所以识别率跟行、列两种算法差别不大。这启发我们如果有更好的行列结合方法,应该是行列结合的识别性能要优于单纯行特征或列特征的识别性能。综合样本数情况考虑,认为1DPCA是比较有效的特征提取方法。

(4)2DSVD的识别率要明显高于1DSVD,这是因为2DSVD利用了图像重构的思想,而不仅仅是像1DSVD那样只利用奇异值作为特征来提取。这个图像重构思想直接用在1DSVD上,识别率提升更明显,对红外图像识别率高达100%。可见,图像重构思想对识别率的提升作用非常明显。故认为SVD图像重构和2DSVD是比较有效的特征提取方法。

6 结 论

本文主要是将1DPCA、2DPCA、1DSVD和2DSVD方法用于多光谱图像特征提取,结合训练样本是否分类和奇异值是否重构图像,形成了一系列特征提取方法,通过实验验证后得出的主要结论有:(1)红外图像的PCA和SVD特征识别效果优于可见光图像的PCA和SVD特征识别效果;(2)无论是可见光图像,还是红外图像,PCA和SVD特征按类识别时识别率改善不明显;(3)SVD图像重构、2DSVD和1DPCA适合于样本少的情况,是比较有效的多光谱图像特征提取方法。研

究过程中还发现了一些其他问题,有待进一步研究,比如:(1)如何选择样本构成训练样本集,使提取出的特征向量能够最充分地表征图像的各种变化;(2)图像代数特征中特征向量各分量在分类中的作用如何确定;(3)单独使用代数特征,由于没有完整的描述目标特性,导致分类效果并没有完全正确,这也启示我们可以继续研究其他图像特征,比如:轮廓特征、纹理特征等,最后将不同目标特征融合,优势互补,从而进一步提高分类识别率。

参考文献:

- [1] Turk M, Pentland A. Eigenfaces for recognition[J]. J. Cognitive Neurosci, 1991, 3(1): 71-96.
- [2] Lennon M, Mercier G, Mouchot M C. Independent component analysis as a tool for the dimensionality reduction and the representation of hyperspectral images[C]//Proceedings of IEEE International Conference on Geoscience and Remote Sensing, Sydney, Australian, 2001: 2893-2895.
- [3] Hong Z Q. Algebraic feature extraction of image for recognition[J]. Pattern Recognition, 1991, 24(3): 211-219.
- [4] Li M, Yuan B. 2D-LDA: A novel statistical linear discriminant analysis for image matrix[J]. Pattern Recognition Letters, 2005, 26(5): 527-532.
- [5] Li Le, Zhang Yujin. A survey on algorithms of non-negative matrix factorization[J]. Acta Electronica Sinica, 2008, 36(4): 737-743. (in Chinese)
李乐, 章毓晋. 非负矩阵分解算法综述[J]. 电子学报, 2008, 36(4): 737-743.
- [6] Yang J, Yang J Y. From image vector to matrix: a straightforward image projection technique-IMPCA vs. PCA[J]. Pattern Recognition, 2002, 35(9): 1997-1999.
- [7] Yang J, Zhang D, Frangi A F, et al. 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.
- [8] Xu Y, Zhang D, Yang J, et al. An approach for directly extracting features from matrix data and its application in face recognition[J]. Neurocomputing, 2008, 71(10): 1857-1865.
- [9] Kong H, Wang L, Teoh E K. Generalized 2D principal component analysis for face image representation and recognition[J]. Neural Networks, 2005, 18(5-6): 585-594.
- [10] Ren C X, Dai D Q. Incremental learning of bidirectional

- principal components for face recognition [J]. Pattern Recognition, 2010, 43(1): 318 – 330.
- [11] Yan Hui, Jin Zhong, Yang Jingyu. Non-negative two-dimensional principal component analysis and its application to face recognition[J]. Pattern Recognition and Artificial Intelligence, 2009, 22(6): 809 – 814. (in Chinese)
严慧, 金忠, 杨静宇. 非负二维主成分分析及在人脸识别中的应用[J]. 模式识别与人工智能, 2009, 22(6): 809 – 814.
- [12] Wang H, Ahuja N. Facial expression decomposition[C]// Proceedings of ICCV, Beijing, China, 2003: 958 – 965.
- [13] Lung S Y. Multi-resolution form of SVD for text-independent speaker recognition[J]. Pattern Recognition, 2002, 35(7): 1637 – 1639.
- [14] Weng X Q, Shen J Y. Classification of multivariate time series using two – dimensional singular value decomposition [J]. Knowledge-Based Systems, 2008, 21(7): 535 – 539.
- [15] Liu J, Chen S, Tan X. Fractional order singular value decomposition representation for face recognition[J]. Pattern Recognition, 2008, 41(1): 378 – 395.
- [16] Lu J W, Zhao Y W. Dominant singular value decomposition representation for face recognition[J]. Signal Processing, 2010, 90(6): 2087 – 2093.
- [17] Xu Yong, Yang Jian, Zhao Yingnan, et al. An approach to image dimension reduction and its application to face omages[J]. Journal of Electronics & Information Technology, 2008, 30(1): 180 – 184. (in Chinese)
徐勇, 杨健, 赵英男, 等. 一种缩减图像维数的方法及其在人脸图像上的应用[J]. 电子与信息学报, 2008, 30(1): 180 – 184.
- [18] Wang Yaonan. Computer image processing and recognition techniques[M]. Beijing: Higher Education Press, 2001. (in Chinese)
王耀南. 计算机图像处理与识别技术[M]. 北京: 高等教育出版社, 2001.
- [19] Bian Zhaoqi, Zhang Xuegong. Pattern recognition[M]. Beijing: Tsinghua University Press, 2000. (in Chinese)
边肇祺, 张学工. 模式识别[M]. 北京: 清华大学出版社, 2000.
-