

多线性主成分分析和张量分析的 SAR 图像目标识别

宦若虹 陶一凡 陈月 杨鹏 鲍晟霖

(浙江工业大学计算机科学与技术学院, 杭州, 310023)

摘要: 为了提高合成孔径雷达图像目标识别效果, 提出一种基于多线性主成分分析和张量分析的合成孔径雷达图像目标识别方法。该方法首先构建四阶张量训练样本, 利用多线性主成分分析得到多线性投影矩阵; 再通过投影矩阵构建核心张量, 对核心张量进行线性判别分析; 最后对测试样本分类识别。实验中, 将本文提出的多线性主成分分析和张量分析方法在 MSTAR 公共数据库上进行识别实验, 并与主成分分析和二维主成分分析方法进行识别率比较。实验结果表明, 本文方法有效保留了图像的空间结构信息, 提高了目标正确识别率。

关键词: 合成孔径雷达; 目标识别; 多线性主成分分析; 张量分析

中图分类号: TN959.1+7 **文献标志码:** A

SAR Image Target Recognition Based on Multi-linear Principal Component Analysis and Tensor Analysis

Huan Ruohong, Tao Yifan, Chen Yue, Yang Peng, Bao Shenglin

(College of Computer Science and Technology, Zhejiang University of Technology, Hangzhou, 310023, China)

Abstract: For enhancing the target recognition effect of synthetic aperture radar image, a method of synthetic aperture radar image target recognition based on multi-linear principal component analysis and tensor analysis is proposed in this paper. Firstly, a four-order tensor training sample is constructed. Then, multi-linear principal component analysis is used to get the multi-linear projection matrix, and the core tensor is obtained from the multi-linear projection matrix. Finally, linear discriminant analysis is used to train the core tensor and classify the test samples. In the experiments, the proposed multilinear principal component analysis and tensor analysis method in this paper is applied to MSTAR public database for recognition experiments, and compared with principal component analysis and two-dimensional principal component analysis in recognition rate. Experimental results show that the method effectively preserves the image structure information and improves the target recognition rate.

Key words: synthetic aperture radar; target recognition; multi-linear principal component analysis; tensor analysis

引 言

合成孔径雷达(Synthetic aperture radar, SAR)图像目标识别的一般过程为:图像预处理、特征提取

和分类识别。分类识别的前提和关键在于特征提取。合成孔径雷达图像的特征提取方法主要分成两类:一类是在 SAR 图像域的特征提取,常用特征有:峰值、分形维数、阴影和纹理等^[1];另一类是基于数学变换的特征提取:主要是利用数学变换方法将变换域的系数作为图像的特征,常见的方法包括主成分分析、小波变换、离散余弦变换、独立成分分析和线性判决分析等。

主成分分析(Principal component analysis, PCA)也称为离散 K-L 变换,是一种通过特征线性组合的数据降维方法,由于其通过线性变换后产生的新特征正交,变换后的新特征更稳定、能量更集中,使得该方法被广泛应用于 SAR 图像特征提取中^[2-5]。主成分分析面向的数组是向量形式,在降维过程中首先需要将图像数据转化为一维向量,导致特征提取要在高维向量空间中进行,很难准确估计协方差矩阵且维数很大,并且丢失了图像本身的空间结构信息。有学者将 PCA 特征提取和其他特征提取方法相结合来提高识别率和识别速度。李映等^[6]提出一种基于核的奇异值分解(Kernel singular value decomposition,KSVD)与主成分分析相结合的 SAR 图像目标的组合特征提取方法,首先利用核的奇异值分解得到图像非线性的代数特征,然后进一步经过 PCA 变换得到图像的最终分类特征,实验结果表明,该方法不仅有效地提高了目标的正确识别率,而且大大降低了对目标方位的敏感度。贺志国等^[7]从实时性的角度出发,采用 PCA 特征提取和神经网络相结合的 SAR 目标识别方法,实验结果表明,在维持较高识别率的前提下,该类方法具有内存需求少、运行速度快的优点,可用于实时处理。李勇等^[8]应用在 PCA 基础发展起来的二维 PCA(2DPCA)方法进行 SAR 特征提取,该方法对 SAR 图像进行二层小波分解后提取低频子带图像的二维主成分分量作为目标的识别特征,利用支持向量机完成目标分类,取得了不错的识别效果。胡利平等^[9]提出一种两级 2DPCA 的图像特征提取方法,进一步压缩特征维数,减少识别运算量,实验结果表明,该方法能有效降低特征维数,提高识别率,并且对目标方位角具有较强的鲁棒性。尽管上述特征提取方法获得了较高的识别率或者识别速度,但这些方法都不可避免地破坏了样本的空间结构^[10]。多线性主成分分析(Multilinear principal component analysis, MPCA)在 PCA 的基础上直接使用张量的形式提取有效特征,避免了“维数灾难”的同时又具有处理张量数据时保留原始数据空间结构信息的优点^[11-13]。为了克服当前 SAR 图像目标识别中 PCA 特征提取使得图像空间结构信息丢失的问题,进一步提高目标正确识别率,本文提出一种基于多线性主成分分析和张量分析的 SAR 图像目标识别方法,该方法对 SAR 图像构建四阶张量样本,并采用多线性主成分分析提取特征,有效地保留了图像的空间结构信息。

1 多线性主成分分析

多线性主成分分析旨在寻求一组多线性投影矩阵,通过多线性投影矩阵,把原始张量映射到核心张量子空间中,其详细步骤如下^[9]:

(1) 首先对原始张量样本 $\mathbf{X} \in \mathbf{R}^{I_1 \times I_2 \times \dots \times I_N}$ 进行中心化处理,即每个张量样本减去张量样本集的平均值为

$$\bar{\mathbf{X}}_m = \mathbf{X}_m - \bar{\mathbf{X}} \tag{1}$$

$$\bar{\mathbf{X}} = \frac{1}{M} \sum_{m=1}^M \mathbf{X}_m \tag{2}$$

式中: M 为样本数; $\bar{\mathbf{X}}$ 为样本均值; \mathbf{X}_m 为原始样本; $\bar{\mathbf{X}}_m$ 为中心化后的样本。

(2) 初始化协方差矩阵

$$\Phi^{(n)} = \sum_{m=1}^M (\bar{\mathbf{X}}_{m(n)} \bar{\mathbf{X}}_m^{(n)T}) \tag{3}$$

式中: $\mathbf{X}_{m(n)}$ 为张量样本 \mathbf{X}_m 的 n 模展开后的矩阵,对该协方差矩阵进行特征分解,取最大 P^n 个特征值对应的 P^n 个特征向量组成投影矩阵 $\mathbf{U}^{(n)} \in \mathbf{R}^{I_n \times P}$, $n=1,2,\dots,N$ 。

(3) 局部优化

① 利用投影矩阵进行张量子空间映射, 计算

$$\mathbf{S}_m = \bar{\mathbf{X}}_m \times_1 \mathbf{U}^{(1)T} \times_2 \mathbf{U}^{(2)T} \times \dots \times_N \mathbf{U}^{(N)T} \quad (4)$$

式中: $m = 1, 2, \dots, M$; $\times_n, n = 1, 2, \dots, N$ 为 n 模乘积。

② 计算

$$\Psi_{S_i} = \sum_{m=1}^M \|\mathbf{S}_m\|^2 \quad (5)$$

式中 $\|\mathbf{S}_m\|$ 为张量的范数。

③ 循环以下步骤:

a. 对于张量样本的每一阶方向 $n = 1, 2, \dots, N$, 求协方差矩阵 $\Phi^{(n)}$ 的特征分解, 取最大 P^n 个特征值对应的 P^n 个特征向量组成投影矩阵 $\mathbf{U}^{(n)} \in \mathbf{R}^{L \times P}$, $n = 1, 2, \dots, N$, 其中

$$\Phi^{(n)} = \sum_{m=1}^M \bar{\mathbf{X}}_{m(n)} \mathbf{U}_{\Phi^{(n)}} \mathbf{U}_{\Phi^{(n)}}^T \bar{\mathbf{X}}_{m(n)}^T \quad (6)$$

$$\mathbf{U}_{\Phi^{(n)}} = \mathbf{U}^{(n+1)} \otimes \dots \otimes \mathbf{U}^{(N)} \otimes \mathbf{U}^{(1)} \otimes \dots \otimes \mathbf{U}^{(n-1)} \quad (7)$$

式中: \otimes 为矩阵的克罗内克 (Kronecker) 乘积。

b. 计算 \mathbf{S}_m 和 Ψ_{S_i}

$$\mathbf{S}_m = \bar{\mathbf{X}}_m \times_1 \mathbf{U}^{(1)T} \times_2 \mathbf{U}^{(2)T} \times \dots \times_N \mathbf{U}^{(N)T} \quad (8)$$

$$\Psi_{S_i} = \sum_{m=1}^M \|\mathbf{S}_m\|^2 \quad (9)$$

c. 如果 $\Psi_{S_i} - \Psi_{S_{i-1}} < \eta$, 退出循环, 否则回到步骤 a, 其中 η 为自定义的阈值。

(4) 投影计算最终降维后的核心张量

$$\mathbf{S}_m = \bar{\mathbf{X}}_m \times_1 \mathbf{U}^{(1)T} \times_2 \mathbf{U}^{(2)T} \times \dots \times_N \mathbf{U}^{(N)T} \quad (10)$$

2 基于 MPCCA 和张量分析的 SAR 图像目标识别

基于 MPCCA 和张量分析的 SAR 图像目标识别方法, 首先对 SAR 训练图像构建四阶张量训练样本, 用 MPCCA 对训练张量降维, 得到投影矩阵, 然后将原始样本向张量子空间进行映射得到核心张量, 再通过线性判别分析 (Linear discriminant analysis, LDA) 获得分类函数权向量, 最后进行测试样本的分类识别。

2.1 构建四阶张量训练样本

首先对原始的 SAR 图像进行预处理, 将图像统一调整为大小为 128 像素 \times 128 像素的幅度图像 P , 并对幅度数据进行归一化处理, 处理后图像幅度值的均值为 0, 方差为 1, 归一化公式为

$$P = (P - \text{mean}P) / \text{std}P \quad (11)$$

式中: $\text{mean}P$ 为图像幅度数据的均值, $\text{std}P$ 为标准差。

按照图像空间 x 轴、图像空间 y 轴、方位角和样本类别, 构建一个四阶的张量训练样本, 该四阶张量可以表示为 $\mathbf{X}_m \in \mathbf{R}^{I_1 \times I_2 \times I_3 \times I_4}$, I_1, I_2, I_3, I_4 分别代表图像空间 x 轴、图像空间 y 轴、方位角和样本类别四阶张量的维度, 四阶张量构造示意图如图 1 所示。

2.2 多线性主成分分析获得多线性投影矩阵

多线性主成分分析首先对原始的四阶张量训练样本进行中心化, 即每个张量样本减去张量样本集的均值为

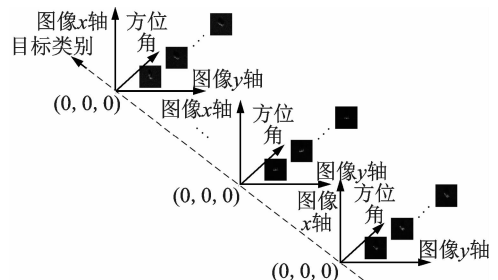


图 1 四阶张量构造示意图

Fig. 1 Construction of four-order tensor

$$\bar{\mathbf{X}}_m = \mathbf{X}_m - \bar{\mathbf{X}} \quad (12)$$

$$\bar{\mathbf{X}} = \frac{1}{M} \sum_{m=1}^M \mathbf{X}_m \quad (13)$$

然后对中心化后的四阶张量样本沿各阶模展开到一组矩阵 $\bar{\mathbf{X}}_{n\text{-MODE}}$, 该过程对组成张量的所有阶按交错次序采样, 在整个采样过程中对不同阶的特征值进行混合交错采样, 从而实现了张量不同阶特征值之间的传递和融合。

最后对四阶张量展开后的矩阵进行多线性主成分分析, 获得各阶上的投影矩阵 $\mathbf{U}^{(n)}, n=1, 2, 3, 4$ 。

2.3 构造核心张量

2.3.1 核心张量的计算

与奇异值分解类似, $\mathbf{U}^{(n)}, n=1, 2, 3, 4$ 可以被看成是一组正交变换基对, 而核心张量 \mathbf{S}_m 是 $\bar{\mathbf{X}}_m$ 在该变换基对上的投影, 中心化后的训练张量样本可以表示为

$$\bar{\mathbf{X}}_m = \mathbf{S}_m \times_1 \mathbf{U}^{(1)} \times_2 \mathbf{U}^{(2)} \times_3 \mathbf{U}^{(3)} \times_4 \mathbf{U}^{(4)} \quad (14)$$

将中心化后的样本通过投影矩阵向核心张量子空间进行映射得到核心张量 \mathbf{S}_m , 表达式为

$$\mathbf{S}_m = \bar{\mathbf{X}}_m \times_1 \mathbf{U}^{(1)\text{T}} \times_2 \mathbf{U}^{(2)\text{T}} \times_3 \mathbf{U}^{(3)\text{T}} \times_4 \mathbf{U}^{(4)\text{T}} \quad (15)$$

\mathbf{S}_m 可以很好地表征中心化后的张量训练样本 $\bar{\mathbf{X}}_m$ 的特性, 从而可以用该核心张量取代原始的张量训练样本进行后续的训练与识别。

2.3.2 核心张量特征的选择

将映射后的核心张量特征转化为一维数组, 计算每一个特征分量的类内离散度和类间离散度以及类间离散度和类内离散度的比值

$$\bar{\mathbf{V}}_k = \frac{1}{M_k} \sum_{m=1}^{M_k} \mathbf{V}_m \quad k=1, 2, \dots, K \quad (16)$$

$$\bar{\mathbf{V}}_A = \frac{1}{K} \sum_{k=1}^K \bar{\mathbf{V}}_k \quad (17)$$

$$S\omega_k = \sum_{m=1}^{M_k} (\mathbf{V}_m - \bar{\mathbf{V}}_k)^2 \quad k=1, 2, \dots, K \quad (18)$$

$$Sb_k = (\bar{\mathbf{V}}_k - \bar{\mathbf{V}}_A)^2 \quad k=1, 2, \dots, K \quad (19)$$

$$R = \frac{\sum_{k=1}^K Sb_k}{\sum_{k=1}^K S\omega_k} \quad (20)$$

式中: K 为类别数; M_k 为每类样本的样本数; \mathbf{V}_m 为当前第 k 类的样本; $\bar{\mathbf{V}}_k$ 为每类样本的均值; $\bar{\mathbf{V}}_A$ 为全体样本的均值; $S\omega_k$ 为每类样本的类内离散度; Sb_k 为每类样本的类间离散度; R 为类间离散度和类内离散度的比值。

对核心张量向量化后特征的每一特征分量按照 R 大小进行降序排序, 选取 R 最大的若干特征分量进行后续的训练和识别, 根据式(21)计算选取的特征分量数占总特征分量数的比例为

$$\text{特征分量比例} = \frac{\text{选取特征分量数}}{\text{总特征分量数}} \quad (21)$$

2.4 线性判别分析

核心张量可表征原始训练样本, 因此可以通过核心张量训练线性判别分类器; 对于 K 类的线性分类问题要寻找 K 个线性判别函数, 每个线性判别函数的求解目的是寻找一个权向量, 使得训练样本 \mathbf{X} 的错分最小, 因而, 这里需要求得 K 个权向量 $\mathbf{W}_k, k=1, 2, \dots, K, K$ 为类别数; 定义误差向量为

$$\mathbf{e}_k = \mathbf{X}\mathbf{W}_k - b_k \quad (22)$$

式中: b_k 为已知的样本类别。

将目标函数定义为平方误差的形式为

$$J(\mathbf{W}_k) = \|\mathbf{e}_k\|^2 = \|\mathbf{X}\mathbf{W}_k - b_k\|^2 \quad (23)$$

\mathbf{W}_k 的优化目标为使得 $J(\mathbf{W}_k)$ 最小, 即求 $J(\mathbf{W}_k)$ 的梯度为 0, 表达式为

$$\nabla J(\mathbf{W}_k) = \sum_{i=1}^M 2(\mathbf{W}_k^T \mathbf{X}_i - b_{k,i}) \mathbf{x}_i = 2\mathbf{X}^T (\mathbf{X}\mathbf{W}_k - b_k) = 0 \quad (24)$$

从而得到权向量为

$$\mathbf{W}_k = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T b_k \quad (25)$$

2.5 测试样本分类

对于给定的测试样本 \mathbf{X}_{test} , 首先将测试样本通过投影矩阵 $\mathbf{U}^{(n)}$, $n=1, 2, 3, 4$ 映射到张量子空间中, 得到测试样本核心张量为

$$\mathbf{S}_{\text{test}} = \mathbf{X}_{\text{test}} \times_1 \mathbf{U}^{(1)T} \times_2 \mathbf{U}^{(2)T} \times_3 \mathbf{U}^{(3)T} \times_4 \mathbf{U}^{(4)T} \quad (26)$$

通过线性判别函数的权向量 \mathbf{W}_k 计算, 即

$$gnd_k(\mathbf{S}_{\text{test}}) = \mathbf{W}_k^T \mathbf{S}_{\text{test}} \quad (27)$$

比较函数值 gnd_k 的大小, 使 gnd_k 最大的线性判别函数权向量所对应的类别则是测试样本的类别。

3 实验结果与分析

3.1 实验数据集

采用 MSTAR 数据集中的实测 SAR 地面静止目标数据来测试本文方法, 并比较 PCA 算法、2DPCA 算法和 MPCA 算法在 SAR 图像特征提取上的性能。MSTAR 是当前 SAR 目标识别性能评估的公开数据库, 该数据库来自于美国国防预研计划署和空军研究实验室 (DARPA/AFRL) 共同资助的运动与静止目标的获取与识别计划。实验中选用 SAR 在俯视角为 17° 和 15° 的 7 类目标图像数据作为目标的训练和测试样本, 该 7 类目标分别为: BTR70_c71, D7, ZSU_23/4, BRDM_2, T72_132, BTR_60 和 2S1。图 2 是 7 类目标在俯视角 17° 及不同方位角 φ 下的 SAR 原始图像, 其训练和测试样本情况见表 1。

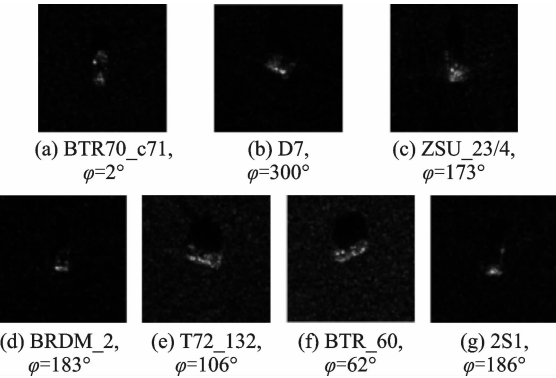


图 2 训练和测试样本原始图像

Fig. 2 Original images for training and testing samples

表 1 训练和测试样例情况

Tab. 1 Sample number of training and testing

类别	训练样本数	测试样本数
BTR70_c71	233	196
D7	299	274
ZSU_23/4	299	274
BRDM_2	298	274
T72_132	232	196
BTR_60	255	195
2S1	299	274
总计	1 915	1 683

3.2 实验结果与分析

本文采用识别率作为 SAR 目标识别效果的衡量指标, 它是正确识别样本数和总样本数的比值。图 3 给出了本文提出的 MPCA 特征提取和 LDA 分类方法 (MPCA+LDA) 选取不同数量的特征分量时, 分

别采用 3 类、5 类和 7 类目标作为训练和测试样本集得到的识别率。图 3 中,特征分量比例从 10% 增加到 100%, 3 条识别率曲线首先随着特征分量比例的增加而增加, 然后随着特征分量比例的进一步增加而趋于稳定。由图 3 可知, 采用 3 类目标进行训练测试, 当特征分量比例为 30% 时, 识别率最高为 96.77%。采用 5 类目标进行训练测试, 当特征分量比例为 90% 时, 识别率最高为 96.46%。采用 7 类目标进行训练测试, 当特征分量比例为 100% 时, 识别率最高为 92.34%。

分别取 3 类、5 类和 7 类目标作为训练和测试样本集时的最高识别率, 得到的混淆矩阵如表 2—4 所示。从表 2—4 可见, BTR70 目标的类间离散度较高, 该类正确分类的几率高, 被误判为其他类别的几率很少; 而 D7 和 ZSU_23/4 的特征相似度较高, 在特征空间中距离很近, 导致这两类被相互误判的概率较高。从表 3 和表 4 中数据可知, BRDM_2, BTR_60 和 2S1 在识别的过程中和其他类别目标都发生了误判的情况, 说明这 3 类在特征空间中分布较为广泛。

将本文提出的 MPCA 特征提取和 LDA 分类方法(MPCA+LDA)得到的识别率与用 PCA 特征提取和 LDA 分类方法(PCA+LDA)以及 2DPCA 特征提取和 LDA 分类方法(2DPCA+LDA)得到的识别率进行比较, 比较结果如表 5—7 所示。由表 5—7 可知, 在分别采用 3 类、5 类和 7 类目标作为训练和测试样本集的 3 组实验中, 本文提出的 MPCA+LDA 方法的平均识别率均要高于 PCA+LDA 和 2DPCA+LDA 方法的识别率, 这是由于本文方法对图像样本构建四阶张量样本, 并采用多线性主成分分析提取特征, 有效地保留了图像空间结构信息。因此, 目标识别率得到了明显的提高。

表 2 3 类目标 MPCA+LDA 识别混淆矩阵
Tab. 2 MPCA + LDA recognition confusion matrix for three classes of targets

类别	BTR70_c71	D7	ZSU_23/4
BTR70_c71	196	0	0
D7	1	265	8
ZSU_23/4	0	15	259

表 3 5 类目标 MPCA+LDA 识别混淆矩阵
Tab. 3 MPCA+LDA recognition confusion matrix for five classes of targets

类别	BTR70_c71	D7	ZSU_23/4	BRDM_2	T72_132
BTR70_c71	195	0	0	0	1
D7	0	264	9	1	0
ZSU_23/4	0	13	261	0	0
BRDM_2	3	2	1	257	11
T72_132	0	0	1	1	194

表 4 7 类目标 MPCA+LDA 识别混淆矩阵

Tab. 4 MPCA+LDA recognition confusion matrix for seven classes of targets

类别	BTR70_c71	D7	ZSU_23/4	BR-DM_2	T72_132	BTR_60	2S1
BTR70_c71	183	0	0	0	2	8	3
D7	0	262	10	2	0	0	0
ZSU_23/4	0	20	254	0	0	0	0
BRDM_2	1	2	0	238	9	0	24
T72_132	0	0	1	0	189	1	5
BTR_60	3	0	2	3	9	174	4
2S1	0	2	4	2	10	2	254




图 3 不同特征分量比例下的识别率
Fig. 3 Recognition rates in different feature component rates

表 5 3 类目标 PCA+LDA, 2DPCA+LDA 和 MPCA+LDA 的识别率

Tab. 5 Recognition rates of PCA+LDA, 2DPCA+LDA and MPCA+LDA for three classes of targets %

类别	PCA+LDA	2DPCA+LDA	MPCA+LDA
BTR70_c71	99.49	100.00	100.00
D7	97.445	97.08	96.72
ZSU_23/4	93.43	93.43	94.53
平均	96.37	96.51	96.77

表 6 5 类目标 PCA+LDA, 2DPCA+LDA 和 MPCA+LDA 的识别率

Tab. 6 Recognition rates of PCA+LDA, 2DPCA+LDA and MPCA+LDA for five classes of targets %

类别	PCA+LDA	2DPCA+LDA	MPCA+LDA
BTR70_c71	97.96	96.93	99.49
D7	94.53	94.53	96.35
ZSU_23/4	93.07	94.53	95.26
BRDM_2	92.34	97.45	93.80
T72_132	96.94	95.92	98.98
平均	94.65	95.80	96.46

表 7 7 类目标 PCA+LDA, 2DPCA+LDA 和 MPCA+LDA 的识别率

Tab. 7 Recognition rates of PCA+LDA, 2DPCA+LDA and MPCA+LDA for seven classes of targets %

类别	PCA+LDA	2DPCA+LDA	MPCA+LDA
BTR70_c71	90.90	85.71	93.37
D7	95.26	95.26	95.62
ZSU_23/4	90.15	90.88	92.70
BRDM_2	79.52	94.53	86.86
T72_132	93.88	91.84	96.43
BTR_60	91.80	88.72	89.23
2S1	92.34	88.69	92.70
平均	90.79	91.09	92.34

将 MPCA+LDA 方法所需的计算时间与 PCA+LDA 方法以及 2DPCA+LDA 方法所需的计算时间进行比较, 比较结果如表 8 所示。由于在实际工程应用中, 训练过程都是离线进行的, 因而本文只对识别单幅 SAR 目标图像所需的计算时间进行比较。由表 8 可见, 尽管 MPCA+LDA 方法的计算时间高于 PCA+LDA 和 2DPCA+LDA 方法, 但 MPCA+LDA 方法的计算时间还是在毫秒级, 完全可满足实际工程应用的实时性需求。

表 8 PCA+LDA, 2DPCA+LDA 和 MPCA+LDA 的计算时间比较

Tab. 8 Comparison of computing time of PCA+LDA, 2DPCA+LDA and MPCA+LDA ms

方法	PCA+LDA	2DPCA+LDA	MPCA+LDA
运行时间	0.013	0.020	0.762

4 结束语

本文对 SAR 图像构建四阶张量训练样本, 并通过多线性主成分分析对 SAR 图像张量样本进行特征提取, 然后对降维后的特征进行线性判别分析, 进行目标的分类识别。实验结果表明, 该方法可有效保留图像的空间结构信息, 较 PCA, 2DPCA 特征提取方法可明显提高 SAR 目标的正确识别率。

参考文献:

- [1] Kreithen D E, Halversen S D, Owirka G J. Discriminating targets from clutter[J]. The Lincoln Laboratory Journal, 1993, 6(1):25-51.
- [2] Shahid N, Perraudin N, Kalofolias V, et al. Fast robust pca on graphs[J]. IEEE Journal of Selected Topics in Signal Processing, 2015, 10(4):740-756.
- [3] Wang Wei, Zhang Baoju, Mu Jiasong. Compressive SAR raw data with principal component analysis[J]. EURASIP Journal

on Wireless Communications and Networking, 2012(1):1-7.

[4] Mishra A K, Motaung T. Application of linear and nonlinear PCA to SAR ATR[C]// 2015 25th International Conference Radioelektronika. [S.l.]: IEEE, 2015:349-354.

[5] 方菲菲, 余稳. 基于 PCA-LDA-SVM 的多普勒雷达车型识别算法[J]. 数据采集与处理, 2012, 27(1):111-116. Fang Feifei, Yu Wen. Vehicle recognition algorithm with Doppler radar based on PCA-LDA-SVM[J]. Journal of Data Acquisition & Processing, 2012, 27(1):111-116.

[6] 李映, 龚红丽, 梁佳熙, 等. 基于 KSVD 和 PCA 的 SAR 图像目标特征提取[J]. 吉林大学学报(工学版), 2010, 40(5):1336-1339. Li Ying, Gong Hongli, Liang Jiayi, et al. SAR image target feature extraction based on KSVD and PCA[J]. Journal of Jilin University, 2010, 40(5):1336-1339.

[7] 王世晔, 贺志国. 基于 PCA 特征的快速 SAR 图像目标识别方法[J]. 国防科技大学学报, 2008, 30(3):136-140. Wang Shixi, He Zhiguo. The fast target recognition approach based on PCA features for SAR images[J]. Journal of National University of Defense Technology, 2008, 30(3):136-140.

[8] 李勇, 王德功, 常硕. 基于小波域 2DPCA 特征提取算法的 SAR 图像识别[J]. 舰船电子工程, 2012, 12:37-39,76. Li Yong, Wang Degong, Chang Shuo. SAR image recognition based on wavelet domain 2DPCA feature extraction algorithm [J]. Ship Electronic Engineering, 2012, 12:37-39,76.

[9] 胡利平, 刘宏伟, 吴顺君. 基于两级 2DPCA 的 SAR 目标特征提取与识别[J]. 电子与信息学报, 2008, 30(7):1722-1726. Hu Liping, Liu Hongwei, Wu Shunjun. SAR target feature extraction and recognition based on two-stage 2DPCA[J]. Journal of Electronics & Information Technology, 2008, 30(7):1722-1726.

[10] Porgès T, Favier G. Automatic target recognition in SAR images using multilinear analysis[C]// The 7th European Radar Conference. [S.l.]: IEEE, 2010: 33-40.

[11] Lu Haiping, Plataniotis K N, Venetsanopoulos A N. MPCa: Multilinear principal component analysis of tensor objects[J]. IEEE Transactions on Neural Networks, 2008, 19(1):18-39.

[12] Lu Haiping, Plataniotis K N, Venetsanopoulos A N. Uncorrelated multilinear discriminant analysis with regularization and aggregation for tensor object recognition[J]. IEEE Transactions on Neural Networks, 2009, 20(1):103-123.

[13] Shi Jiarong, Jiao Licheng, Shang Fanhua. Metric learning for high-dimensional tensor data[J]. Chinese Journal of Electronics, 2011, 20(3):495-498.


作者简介:



宦若虹(1979-),女,博士,副教授,研究方向:视频、图像处理与模式识别, E-mail: huanrh@zjut.edu.cn.



陶一凡(1993-),男,硕士研究生,研究方向:图像处理与模式识别, E-mail: a173981963@163.com.



陈月(1991-),男,硕士研究生,研究方向:机器学习与模式识别, E-mail: 837969469@qq.com.



杨鹏(1990-),男,硕士研究生,研究方向:图像处理与模式识别, E-mail: 1298461580@qq.com.



鲍晨霖(1994-),男,硕士研究生,研究方向:数字图像处理与模式识别, E-mail: 2111612096@zjut.edu.cn.

(编辑:张黄群)