

# 自适应加权特征字典与联合稀疏相结合的遥感目标检测

王 威 陈俊伍 王 新

(长沙理工大学计算机与通信工程学院综合交通运输大数据智能处理湖南省重点实验室 长沙 410114)

**摘 要** 随着分辨率的提高,遥感图像空间包含的有用信息越来越丰富,这使得遥感数据的处理变得更加复杂,容易发生维数灾难并影响识别效果。针对这一情况,提出一种自适应加权特征字典与联合稀疏相结合的遥感图像目标检测方法(GJ-SRC)。首先将训练图像和待测图像进行 Gabor 变换以提取特征图像。然后计算各个特征值在进行稀疏表示时的贡献权重,通过自适应方法构造特征字典,使字典具有更强的判别能力。最后,提取每一类图像的公共特征和单个图像的私有特征构成联合字典,并利用测试图像稀疏表示进行目标检测识别。为了避免 Gabor 变换产生的维数灾难,在处理过程中采用 PCA 方法对特征字典进行降维,以降低计算成本。实验表明,与现有的 SRC 方法和遥感目标检测方法等相比,所提方法具有较好的检测效果。

**关键词** 遥感目标,稀疏表示,Gabor 变换,联合稀疏

中图分类号 TP391 文献标识码 A DOI 10.11896/j.issn.1002-137X.2018.10.051

## Remote Sensing Targets Detection Based on Adaptive Weighting Feature Dictionaries and Joint Sparse

WANG Wei CHEN Jun-wu WANG Xin

(Hunan Provincial Key Laboratory of Intelligent Processing of Big Data on Transportation, School of Computer and Communication Engineering, Changsha University of Science & Technology, Changsha 410114, China)

**Abstract** With the improvement of resolution, more and more useful information is contained in remote sensing images, which makes the processing of remote sensing data become more complex, and it is easy to cause the curse of dimensionality and the poor recognition effect. In view of this situation, a remote sensing targets detection approach (GJ-SRC) based on adaptive weighting feature dictionaries and joint sparse was proposed. Firstly, the Gabor transform is used to extract the features from the training images and the testing images. Then, the contribution weights of each eigenvalue in sparse representation are calculated, and the feature dictionary is constructed by the adaptive method, which makes the dictionary more discriminative. Finally, the common features of each category and the private features of a single image are extracted to form a joint dictionary, and the sparse representation of the test image is used for target recognition. In order to avoid the curse of dimensionality caused by the Gabor transform, the PCA method is used to reduce the dimension of the feature dictionary in order to reduce the computational cost. Experiments show that this method has better detection effect compared with the existing SRC method and remote sensing target detection method.

**Keywords** Remote sensing target, Sparse representation, Gabor transform, Joint sparse

近年来,随着我国航天事业的迅速发展,利用遥感图像来检测和识别重要目标已经被广泛应用于各行各业,对遥感图像进行精确的鲁棒分类识别成为目标识别与目标检测研究领域中的热点和挑战<sup>[1]</sup>。特别是近年来兴起的稀疏表示与压缩感知等算法,为遥感图像分析提供了更好的技术支持。

稀疏表示作为计算机视觉研究领域中的一个重要的信号和图像表示模型,受到了国内外学者的高度关注<sup>[2]</sup>。随着获取遥感数据技术的发展,对遥感数据处理的要求变得越来越高。原始的基于稀疏表示的遥感图像目标检测并没有考虑图像中的结构信息,其识别效率与识别速率略显不足。

Jia 等人使用 3-D Gabor 变换提取图像特征,利用特征向量较强的图像分类判别能力进行高光谱图像分类<sup>[3]</sup>。Cui 等人采用多尺度稀疏表示对高光谱图像进行分类识别与检测<sup>[4]</sup>,并将自适应加权分配方案融入到分类框架中,利用多尺度信息结合自适应权重分配使高光谱图像分类具有更高的分类精度。针对遥感图像中的飞机目标检测问题,Wu 等人利用相似度测度对遥感飞机目标进行检测,将类型识别问题转化为重建问题,采用拼图匹配追踪算法来解决重建问题<sup>[4]</sup>。Jiang 等人提出了一种新的时频分析方法,利用稀疏恢复理论和正交匹配追踪法对飞机遥感目标进行检测<sup>[5]</sup>。上述研究虽

到稿日期:2017-08-05 返修日期:2017-12-13 本文受国防 973 基金项目(613XXX0301),湖南省教育厅科研课题(17C0043)资助。

王 威(1974—),男,博士,教授,主要研究方向为智能信息处理,E-mail:wangwei@csust.edu.cn(通信作者);陈俊伍(1991—),男,硕士生,主要研究方向为智能信息处理,E-mail:will\_chenjw@163.com;王 新(1976—),女,讲师,主要研究方向为智能信息处理。

然在一定程度上提高了普通图像稀疏求解进行识别的效率,但并未针对飞机遥感图像,讨论其复杂的结构信息和提取向量时的数据高维数问题。另外,在稀疏求解中,选择具有高判别能力的原子、构造高效且简洁的图像字典也尤为重要。

本文针对飞机遥感图像由于图像数据丰富导致的特征提取困难、维数灾难、识别鲁棒性较差等问题,利用 Gabor 变换在不同尺度和方向上提取遥感图像的特征向量,自适应分配特征向量作为原子在稀疏表示中的贡献能力。然后采用 PCA 进行降维,结合联合稀疏模型,在稀疏表示的基础上进行遥感图像目标检测识别。

## 1 稀疏表示模型

稀疏表示分类方法(Sparse Representation-based Classifier, SRC)是在稀疏表示的基础上提出的一个全新的分类识别框架,目前在目标识别领域获得了广泛关注。在 SRC 系统中,所有训练样本的每一幅图像转化为列向量(即原子),所有的列向量组成字典。假设有  $k$  类训练样本,每类有  $n$  个训练样本,把每一幅样本的维数  $m = l \times w$  转换为一个列向量  $y \in R^m$ ,则第  $i$  类的训练样本可组成矩阵  $A_i = [y_{i,1}, y_{i,2}, \dots, y_{i,n}] \in R^{m \times n}$ ,其中,  $y_{i,n}$  表示第  $i$  类样本中的第  $n$  个样本。整个训练字典可以表示为  $A = [A_1, A_2, \dots, A_k] \in R^{m \times (n \cdot k)}$ ,则测试信号在字典  $A$  的稀疏表示模型为:

$$y = Ax + z \quad (1)$$

其中,  $y \in R^m$  表示测试样本向量,  $A$  为训练样本字典,  $x \in R^{n \cdot k}$  为测试向量  $y$  在字典  $A$  下求得的稀疏系数,  $x$  中只有很少一部分非零元素,  $z \in R^{m \times 1}$  为此模型的噪声项<sup>[6]</sup>。

$x$  中的稀疏系数表示字典不同原子对测试样本的不同贡献,  $x$  越稀疏,则字典中不同类别的原子的贡献越小,同类别的原子贡献越大。因此需要求出最稀疏的  $x$ :

$$\hat{x}_0 = \arg \min \|x\|_1 \quad (2)$$

$$\text{s. t. } \|y - Ax\|_2 \leq \epsilon$$

令  $\hat{\delta}(x_0)$  是与  $\hat{x}_0$  有相同维数的类别选择向量,表示  $\hat{x}_0$  中

与第  $i$  类对应的非零元素,即  $\hat{\delta}(x_0) = [0, \dots, 0, x_i, 0, \dots, 0]^T$ ,则测试样本利用稀疏系数可以表示为  $y_i = A\hat{\delta}_i + n$ ,然后根据重构误差最小判定准则把  $y$  归类为  $\|y - y_i\|_2$  最小的一类,即:

$$\text{class}(y) = \arg \min \|y - A\hat{\delta}_i\|_2, i = 1, 2, \dots, k \quad (3)$$

## 2 Gabor 小波变换特征提取

Gabor 小波在频域和空域均具有很好的局部性,能充分描述图像纹理,在图像处理中得到了广泛应用,特别是在提取局部特征方面效果显著。二维 Gabor 函数为<sup>[7]</sup>:

$$\phi_{u,v}(m,n) = \frac{k^2}{\sigma^2} \exp\left(-\frac{k^2(m+n)^2}{2\sigma^2}\right) \cdot [\exp(ik \cdot \left(\frac{m}{n}\right)) - \exp\left(-\frac{\sigma^2}{2}\right)] \quad (4)$$

其中,  $k = k_v(\cos \theta, \sin \theta)^T$ ,  $\theta = \frac{\pi u}{8}$ ,  $\theta$  体现滤波器的方向选择

性;  $k_v = k_{\max}/f^v$ ,  $k_{\max}$  是最大频率。  $(m, n)$  为图像空间坐标;  $u$  和  $v$  分别为 Gabor 小波的方向和尺度;  $\sigma$  为高斯函数的半径,它规定了二维 Gabor 小波的尺寸大小;  $i$  为复数算子。文献[8]表明采用 5 个尺度 ( $v = 0, 1, 2, 3, 4$ ) 和 8 个方向 ( $u = 0, 1, 2, 3, 4, 5, 6, 7$ ) 的效果最好。图像  $I(m, n)$  的 Gabor 小波变换是图像与不同尺度方向的 Gabor 滤波器作卷积,即:

$$F_{u,v}(m,n) = I(m,n) \otimes \psi_{u,v}(m,n) \quad (5)$$

其中,  $F_{u,v}(m,n)$  为图像  $I(m,n)$  卷积后的 Gabor 特征。

## 3 联合稀疏理论

联合稀疏模型(Joint Sparse Model, JSM)最开始提出出来是为了能够对多个相关信号进行有效的编码<sup>[9]</sup>。在 JSM 模型中,由于信号之间的相关性,可以把一类信号当作一个信号集,其中每个信号都能够在某个变换基下稀疏表示为公共特征和私有特征<sup>[10]</sup>。其中,公共特征即为该类别下信号集所有信号的公共部分,私有特征即为各个信号独有的特征部分。显然,公共特征和私有特征都能够同一个变换基下稀疏表示。即某一类图像可以表示为如下形式:

$$y_{i,j} = z_i^j + z_{i,j}^j, j \in \{1, 2, 3, \dots, J\} \quad (6)$$

把一幅图像转换成一维列向量  $y \in R^m$ , 假设所有图像可以分为  $K$  个不同类别, 每个类别有  $J$  个训练图像, 则其中一个类别的图像可以表示为:

$$y_i = [y_{i,1}, y_{i,2}, \dots, y_{i,J}]^T \quad (7)$$

根据 JSM 模型, 第  $i$  类第  $j$  个图像可以表示为:

$$y_{i,j} = z_i^j + z_{i,j}^j \quad (8)$$

其中,  $z_i^j$  表示第  $i$  类图像的公共特征,  $z_{i,j}^j$  表示第  $i$  类第  $j$  个图像的私有特征。如果有一正交矩阵(如 DCT 基)为  $\Psi \in R^{N \times N}$ , 同时训练样本可以在该变换基上稀疏表示为  $\theta_{i,j} = \Psi y_{i,j}$ , 将式(6)代入  $\theta_{i,j} = \Psi z_i^j + \Psi z_{i,j}^j$  中, 则可以得到  $\theta_{i,j}$  是  $y_{i,j}$  在稀疏基上的稀疏表示:

$$\theta_{i,j} = \theta_i^j + \theta_{i,j}^j \quad (9)$$

其中,  $\theta_i^j$  是在变换基上公共特征  $z_i^j$  的稀疏表示,  $\theta_{i,j}^j$  是私有特征  $z_{i,j}^j$  在变换基上的稀疏表示。因此两边同时乘以  $\Psi^T$  可以表示为  $\Psi^T \theta_{i,j} = \Psi^T \theta_i^j + \Psi^T \theta_{i,j}^j$ , 即:

$$y_{i,j} = \Psi^T \theta_i^j + \Psi^T \theta_{i,j}^j \quad (10)$$

由此可以得到第  $i$  类图像的联合表示为:

$$\begin{bmatrix} y_{i,1} \\ y_{i,2} \\ \vdots \\ y_{i,J} \end{bmatrix} = \begin{bmatrix} \Psi^T & \Psi^T & 0 & 0 & 0 & 0 \\ \Psi^T & 0 & \Psi^T & & & \\ \vdots & & & \Psi^T & & \\ \vdots & & & & \Psi^T & \\ \Psi^T & 0 & 0 & 0 & 0 & \Psi^T \end{bmatrix} \begin{bmatrix} \theta_i^j \\ \theta_{i,1}^j \\ \theta_{i,2}^j \\ \vdots \\ \theta_{i,J}^j \end{bmatrix} \quad (11)$$

将式(11)简化, 则字典中某一类图像可以表示为:

$$y_i = \bar{\Psi} W_i \quad (12)$$

其中,  $\bar{\Psi}$  是一个由两个矩阵组成的过完备字典, 表示为  $\bar{\Psi} = [A, B]$ , 其中  $A = [\Psi^T \Psi^T \dots \Psi^T]^T$ ,  $B = \text{diag}(A)$ ,  $W_i = [\theta_i^j, \theta_{i,1}^j, \theta_{i,2}^j \dots \theta_{i,J}^j]^T$ 。由于字典的冗余性, 可以通过求解下式的最优化问题来求得稀疏解, 即:

$$W_i = \arg \min \| W_i \|_1 \quad (13)$$

$$\text{s. t. } y_i = \Psi W_i$$

在得到一类字典的稀疏解后,通过求其逆变换就可以得到第  $i$  类字典在  $\Psi$  域上的公共特征和私有特征,即:

$$\begin{bmatrix} z_i^c \\ z_{i,1}^p \\ z_{i,2}^p \\ \vdots \\ z_{i,J}^p \end{bmatrix} = \begin{bmatrix} \Psi^T & & & \\ & \Psi^T & & \\ & & \Psi^T & \\ & & & \ddots \\ & & & & \Psi^T \end{bmatrix} \begin{bmatrix} \theta_i^c \\ \theta_{i,1}^p \\ \theta_{i,2}^p \\ \vdots \\ \theta_{i,J}^p \end{bmatrix} \quad (14)$$

通过式(14)可以分别求出一类图像公共特征和私有特征。我们将一类图像的私有特征求和<sup>[11]</sup>,即:

$$z_i^A = \sum_{j=1}^J z_{i,j}^p, j=1,2,\dots,J \quad (15)$$

因此,对于一类图像,只需保存其共有特征  $z_i^c$  和私有特征之和  $z_i^A$  即可。

#### 4 自适应加权 Gabor 特征字典和联合稀疏相结合的遥感图像目标检测

针对遥感图像包含数据丰富、图像较大、计算复杂、识别率较低等情况,本文基于自适应加权 Gabor 特征字典和联合稀疏表示方法(GJ-SRC)对遥感目标进行检测识别。将图像预处理后,采用 Gabor 变换对训练样本和待测样本提取特征图像,并计算各个特征向量在进行稀疏表示时的贡献权值,自适应地构造新的特征字典。同时,针对 Gabor 变换提取的特征维数较大的问题,采用 PCA 方法降维。然后应用联合稀疏模型得到每一类图像的公共特征和私有特征,构成联合字典,使字典蕴含更好的目标信息,提高稀疏表示的检测率,增强字典和重构误差在特征层面上的判别能力。本文算法的框架如图 1 所示。

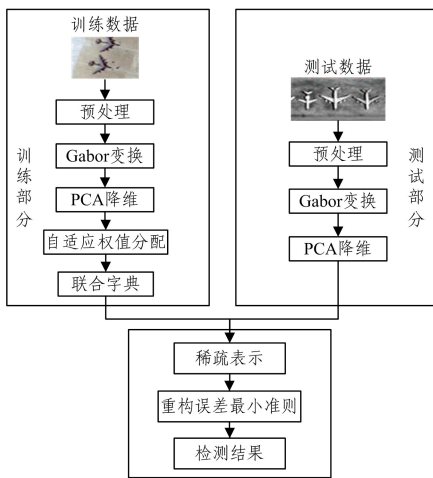


图 1 本文算法框架图

Fig. 1 Framework diagram of this algorithm

##### 4.1 Gabor 特征向量自适应加权重构方法

图像特征向量作为稀疏表示字典中的原子,在求解稀疏解时,主要体现对测试图像的不同贡献。因此,如果能够使原子的贡献能力更加明显,那么识别效果会更理想。对于每一个特征向量,本文用其标准差或方差来衡量该样本的波动大

小,其标准差或方差越大,说明样本数据波动越大,包含的信息也就越突出<sup>[1]</sup>。在构建联合字典时,将每一类图像的私有部分组合在一起,不同样本含有的目标信息并不相同,样本方差越大,说明目标信息越多。因此,可以考虑增加有用信息在字典中的权重,减少含有目标信息较少的样本的权重,以提高特征字典的判别能力。因此,在利用 Gabor 小波变换求得一幅图像的特征向量  $F = [F_1, F_2, \dots, F_n]^T$  后,本文对其做如下改变:

$$F' = [F_1' = \frac{|F_1 - \bar{F}|}{F} F_1, F_2' = \frac{|F_2 - \bar{F}|}{F} F_2, \dots, F_n' = \frac{|F_n - \bar{F}|}{F} F_n]^T \quad (16)$$

其中,  $\bar{F} = \frac{F_1 + F_2 + \dots + F_n}{n}$ 。最后用改变后的特征向量作为图像向量  $y$  来进行联合稀疏表示。由于式(16)是自适应地对每一个样本向量元素进行加权重构,在一定程度上增加了样本向量的标准差或方差,从而使得由样本向量作为原子构成的特征字典包含更多的识别信息,对提升检测效率有较好的效果<sup>[12]</sup>。由于上述方法获得的向量维度较高,需要进行降维。本文采用 PCA 算法降维,以有效地压缩数据,减少冗余。

对特征向量进行自适应加权重构后,即可得到对稀疏表示贡献更加突出的特征字典。

##### 4.2 稀疏检测步骤

在 JSM 模型下,需要提取每一类图像的公共特征和私有特征,不同于 JSM 模型仅将私有特征求和,本文利用共有特征和私有特征组合成联合字典  $D$ ,在此基础上求解测试图像与自适应联合字典的稀疏解,并对其进行目标识别检测。其主要步骤如下。

1)对遥感图像进行图像预处理,然后采用 Gabor 小波变换提取特征向量。

2)对特征向量进行自适应加权重构,得到特征字典,并利用 PCA 技术对特征字典进行降维。

3)对每一类图像提取共有特征和私有特征,将每一类图像的共有特征组成矩阵  $A$ ,将私有特征组成矩阵  $B$ ,则联合字典  $D$  表示为:

$$D = [A, B] = [z_1^c, z_2^c, \dots, z_k^c, z_{1,1}^p, \dots, z_{1,J}^p, z_{2,1}^p, \dots, z_{2,J}^p, \dots, z_{k,1}^p, \dots, z_{k,J}^p] \quad (17)$$

4)将测试图像  $y$  在联合字典  $D$  上进行稀疏表示,求出稀疏解系数:

$$\bar{\theta} = \arg \min \| \theta \|_1 \quad (18)$$

$$\text{s. t. } y = D\theta$$

5)计算重构误差,差值最小的一类则为待测样本所属类别:

$$i = \arg \min \| y - D\delta_i(\bar{\theta}) \|_2 \quad (19)$$

#### 5 实验分析

为了验证本文 GJ-SRC 算法的有效性,参考文献[4]所使用的数据集,利用 Google Earth 7.1.5 选取遥感飞机图像数

据集进行实验,图像来自 QuickBird 商业卫星和 LANDSAT-7 卫星。实验采用不同拍摄时间和地点的图像作为数据集。实验所使用的计算机配置为 Inter Corei5 3.30CPU 和 8GB 内存,采用 Matlab 2014a 进行仿真。

为了突出遥感图像中的飞机目标,削弱干扰信息,实验首先对遥感图像进行预处理,主要是图像灰度化、图像去噪增强以及主要目标图像获取。

图像灰度化采取加权平均法对遥感图像进行灰度处理,根据  $R, G, B$  三分量对不同权值进行加权平均:

$$gray = w_R * R + w_G * G + w_B * B \quad (20)$$

其中,  $gray$  为灰度值,  $w_R, w_G, w_B$  3 个灰度系数分别取 0.30, 0.59, 0.11<sup>[13]</sup>, 使用加权法灰度化的结果如图 2 所示。




图 2 加权法灰度化的结果图

Fig. 2 Images after weighted grayscale

在图像去噪增强方面,采用  $3 \times 3$  中值滤波方法滤除干扰信息,突出有用信息,如图 3 所示。



图 3 灰度图像滤波后的结果图

Fig. 3 Grayscaled image after filtering

在处理后的遥感图像中,选取 10 类遥感飞机图像作为数据集,每类 40 幅目标图像。所获得的 10 类飞机机型对应的图像如图 4 所示。




图 4 目标图像示例图

Fig. 4 Examples of target images

通过选取训练样本将各个机型图像构建成联合字典,将剩余图像作为测试图像进行稀疏求解。利用稀疏重构图像,从联合字典中检测出当前目标的所属类别。图 5(a)为原图,

图 5(b)为稀疏重构后的检测图像。从图中可以看出,检测出的目标形态比较完整。



图 5 A-10 目标图像的原图和检测图

Fig. 5 Original image and recognized image of A-10 target image

实验将 Gabor-SRC 算法<sup>[1]</sup>、Gabor-JSM 算法<sup>[11]</sup>和本文提出的 GJ-SRC 算法进行对比。每一类随机选取 6 幅图像作为训练样本,其余作为测试样本,分别用 3 种方法做 10 次实验取平均值,实验结果如图 6 所示。




图 6 3 种方法的目标检测率

Fig. 6 Target detection rate of three methods

由图 6 可以看出,在相同维数下,本文算法的分类识别率要优于其他两种方法。在上述实验的基础上,针对遥感图像维数较大的情况,我们采用 PCA 降维技术对图像进行降维,之后再对其进行对比分析。每类图像选取 10 张作为训练样本,取不同维数对 3 种算法做 10 次实验并取平均值,实验结果如表 1 所列。

表 1 不同维数对应 3 种算法的检测率

Table 1 Detection rate of three algorithms with different dimensions (单位:%)

维数	Gabor-SRC	Gabor-JSM	GJ-SRC
100	91.88	92.58	93.24
200	92.86	94.02	94.98
300	93.55	94.58	95.45
400	94.86	95.89	96.66

由表 1 可以看到,本文方法在图像处于不同维数的情况下,对目标的检测率依然是最高的。这也证明了 GJ-SRC 算法可以在确保一定识别率的前提下降低特征维数,从而减少数据量,减轻数据传输负担。

为了验证 GJ-SRC 算法的时间效率,将训练图像分别设定为 8 幅和 10 幅进行实验仿真。统计每种方法的检测时间,结果如表 2 所列。

表 2 不同训练样本数下 3 种算法的检测时间

Table 2 Detection time of three algorithm with different training samples (单位:s)

训练样本数	Gabor-SRC	Gabor-JSM	GJ-SRC
8	96.3	97.52	98.63
10	100.76	104.12	106.31

由表 2 可知,由于 Gabor 小波变换和特征向量自适应重构等步骤,GJ-SRC 算法的运算时间有所增加,但是相差不大。

为了验证 GJ-SRC 算法在遥感飞机目标检测上的有效性,选取 DG-SRC<sup>[3]</sup>,RE-SRC<sup>[4]</sup>,TF-SRC<sup>[5]</sup> 3 种飞机遥感图像目标检测算法进行对比。在每一类中随机选取 10 幅图像作为训练样本,其余作为测试样本,分别用 4 种方法做 10 次实验,取平均值,得到图 7 所示的实验结果。




图 7 4 种方法的目标检测率

Fig. 7 Target detection rate of four methods

从图 7 可以看出,GJ-SRC 算法依然有比较出色的检测效率,目标检测率优于其他 3 种算法。同样地,为了验证 GJ-SRC 算法在低维空间的有效性,采用 PCA 对训练样本图像进行不同维度的降维,并进行比较实验,从而得到表 3 结果。

表 3 不同维数对应 4 种算法的检测率

Table 3 Detection rate of four algorithms with different dimensions (单位:%)

维数	DG-SRC	RE-SRC	TF-SRC	GJ-SRC
100	93.28	93.01	92.59	94.22
200	94.46	93.82	93.42	95.23
300	95.55	94.79	94.48	95.88
400	96.24	95.78	95.26	96.90

由表 3 可知,相对于其他 3 种算法,GJ-SRC 算法在不同维数情况下的检测效率最高。同时将这 4 种算法的训练样本数分别设置为 8 和 10,剩余样本做测试样本,统计 4 种算法的检测时间,结果如表 4 所列。

表 4 不同训练样本数下 4 种算法的检测时间

Table 4 Detection time of four algorithms with different training samples (单位:s)

训练样本数	DG-SRC	RE-SRC	TF-SRC	GJ-SRC
8	95.42	95.43	92.43	98.63
10	97.33	96.25	93.76	106.31

由表 4 可知,其他 3 种算法在字典构建上比 GJ-SRC 算法简单,所需时间相对较短。

综合上述实验结果可知,本文算法在几种飞机遥感图像的目标检测中具有最好的检测率,虽然检测时间略有劣势,但相对来说其综合性能仍然是最优的。

**结束语** 本文针对遥感图像维数较大、检测困难等情况,提出了一种 GJ-SRC 目标检测方法。该方法首先进行特征提取,并对特征向量进行自适应加权重构,然后增加原子对稀疏求解的贡献,同时利用 PCA 降低向量维数,减少计算量。

在构建联合稀疏模型时,我们针对训练样本的每一类图像,结合联合稀疏模型提取出公共特征和私有特征,从而构建联合字典,使字典具有更强的判别能力,最后通过稀疏表示进

行类别判定。与传统的稀疏表示的 SRC 方法以及联合稀疏模型 B-JSM 方法相比,本文提出的 GJ-SRC 方法的检测率更高。与最近提出的几种飞机遥感图像目标检测方法相比,GJ-SRC 依然具有更优的综合表现。同时,由于自适应特征向量和联合字典的构建,算法的检测时间有所增加。

## 参考文献

- [1] CUI M, PRASAD S. Multiscale sparse representation classification for robust hyperspectral image analysis[C]// IEEE Global Conference on Signal and Information Processing. IEEE, 2013: 969-972.
- [2] YANG B, LI S T. Multifocus image fusion and restoration with sparse representation[J]. IEEE Transactions on Information Theory Instrumentation and Measurement, 2010, 59(4): 884-892.
- [3] JIA S, SHEN L, LI Q. Gabor Feature-Based Collaborative Representation for Hyperspectral Imagery Classification[J]. IEEE Transactions on Geoscience & Remote Sensing, 2015, 53(2): 1118-1129.
- [4] WU Q C, SUN H, SUN X, et al. Aircraft Recognition in High-Resolution Optical Satellite Remote Sensing Images[J]. IEEE Geoscience & Remote Sensing Letters, 2015, 12(1): 112-116.
- [5] JIANG Y, XIA R, XU J, et al. Multiple aircraft formation identification using OMP-based time-frequency analysis and hough transform[C]// IET International Radar Conference 2016. 2016.
- [6] WRIGHT J, YANG A Y, SASTRY S S, et al. Robust Face Recognition via Sparse Representation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2008, 31(2): 210-227.
- [7] LIN K Z, XU Y, ZHONG Y. Using 2D Gabor values and kernel fisher discriminant analysis for face recognition[C]// Proceedings of the 2nd International Conference on Information Science and Engineering. 2010: 7624-7627.
- [8] WANG C X, LIU Y, LI Z Y. Algorithm research of face image gender classification based on 2-D Gabor wavelet transform and SVM[C]// Proceedings of the International Symposium on Computer Science and Computational Technology. Los Alamitos: IEEE Computer Society Press, 2008, 1: 312-315.
- [9] CANDES E J, ROMBERG J. Quantitative Robust Uncertainty Principles and Optimally Sparse Decompositions[J]. Foundations of Computational Mathematics, 2006, 6(2): 227-254.
- [10] WEN Y, XIANG Y, FU Y. A joint classification approach via sparse representation for face recognition[C]// International Conference on Signal Processing. IEEE, 2015: 1387-1391.
- [11] NAGESH P, LI B. A compressive sensing approach for expression-invariant face recognition[C]// Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on. IEEE, 2015: 1518-1525.
- [12] CHEN J, HUANG L, GAO C, et al. Study on Gender Recognition Based on Gabor Wavelet Weighted Combination Feature[J]. Journal of Computer-Assisted Design and Graphics, 2015, 27(9): 1767-1774.
- [13] LIU H, HOU X. The Precise Location Algorithm of License Plate Based on Gray Image[C]// 2012 International Conference on Computer Science and Service System. 2012: 65-67.