

基于更新分类器的合成孔径雷达图像目标识别

张振中*

武警工程大学装备管理与保障学院, 陕西 西安 710086

摘要 针对合成孔径雷达(SAR)图像目标识别中的分类决策问题,提出了一种基于更新分类器的新识别方法。该方法用卷积神经网络和稀疏表示分类器作为基础分类器对类别未知的样本进行分类,对两种方法的决策结果进行融合,并判定决策结果的可靠性。将类别可靠的测试样本补充到原始训练样本中以更新分类器,从而获得更可靠的识别结果。基于MSTAR数据集的实验结果表明,相比其他方法,本方法的识别准确率更高。

关键词 图像处理;合成孔径雷达;目标识别;卷积神经网络;稀疏表示分类器;更新分类器

中图分类号 TN957

文献标志码 A

doi: 10.3788/LOP202158.1410013

Synthetic Aperture Radar Image Target Recognition Based on Updated Classifier

Zhang Zhenzhong*

College of Equipment Management and Support, Engineering University of PAP, Xi'an, Shaanxi 710086, China

Abstract To address the classification decision problems in synthetic aperture radar (SAR) image target recognition, a new recognition method based on updated classifier is proposed in this paper. The method uses a convolutional neural network and a sparse representation classifier as the basic classifier to classify samples with unknown categories. The decision results of the two methods are fused, and the reliability of the fused decision results is then determined. Subsequently, test samples with reliable categories are added to the original training samples to update the classifier to obtain more reliable recognition results. The experimental results based on the MSTAR data set show that the recognition accuracy of the method is higher than those of the other methods.

Key words image processing; synthetic aperture radar; target recognition; convolutional neural network; sparse representation classifier; updated classifier

OCIS codes 100.3008; 120.0280

1 引言

高分辨率合成孔径雷达(SAR)可为对地观测提供有力支撑,基于SAR图像可以对感兴趣的目标进行检测、识别,从而在军事应用中获得高价值的情报。SAR图像的目标识别问题是传统模式识别技术的具体应用,主要是在训练样本的支持下对待识别测试样本进行分类^[1]。特征提取和分类器的设计

是SAR图像目标识别方法中的两个重要环节,其中,特征提取通过对SAR图像的分析获得具有高鉴别力的特征,从而提升后续分类的整体精度和效率。常用的SAR图像特征包括描述目标几何形状^[2-4]、电磁散射特性^[5-6]和图像像素分布的投影变换特征^[7-9]。分类器基于大量训练样本学习可靠的决策面,进而对测试样本进行分类。常用于SAR图像目标识别的分类器包括最近邻分类^[10]、支持向量机

收稿日期: 2020-09-23; 修回日期: 2020-10-23; 录用日期: 2020-11-14

基金项目: 广东省科学技术委员会基金(cstc2015jcsfA90002)

通信作者: *wjzhangzhenzhong@163.com

(SVM)^[11-12]、稀疏表示分类器 (SRC)^[13-16] 等。此外,多分类器融合也在 SAR 图像目标识别中得到了广泛的应用。近年来,人们研究了大量基于深度学习模型的 SAR 图像目标识别方法,如卷积神经网络 (CNN)^[17-23]。深度学习将特征学习和分类决策集于一体,但这类方法对测试样本的需求量大,在训练样本较少的情况下分类性能较差。不同于光学图像处理领域,SAR 图像的数据资源稀缺,训练可靠的深度学习分类模型困难较大。Ding 等^[20-21]通过样本增强方法构造了更多的可用样本,提升了网络的分类性能。Huang 等^[22-23]通过迁移学习方法及多源图像数据(如光学图像、电磁仿真数据)训练出适用于 SAR 图像目标识别的神经网络。

针对上述问题,本文提出了一种基于更新分类器的 SAR 图像目标识别方法。该方法利用分类过程中类别确认的测试样本对原始分类器的参数进行优化,使分类器获得更强的分类性能。首先,设计初始 CNN 并将其作为 SAR 图像目标识别的主导分类器。然后,用 SRC 作为辅助分类器,与 CNN 一起对待识别样本进行分类。用原始训练样本对 CNN 进行训练,并用这些样本构建 SRC 的全局字典。分别用 CNN 和 SRC 对待识别的测试样本进行分类,并获得相应的决策变量,进而通过加权融合获得最终的决策变量。通过设计的准则判定当前测试样本的类别可信度,并在满足条件的情况下将其加入训练样本,以优化 CNN 的参数,同时扩充 SRC 的全局字典规模。随着类别确认测试样本的不断增多,CNN 和 SRC 的分类性能也得到了不断增强,进一步提升了融合识别结果的可靠性。本方法在 CNN 和 SRC 的分类器决策融合框架下引入了更新机制,充分利用了分类后的测试样本,有效提升了分类器的分类能力。虽然利用决策可靠性准则筛选测试样本可提高网络的分类精度,但仍然存在错误分类的概率。而引入类别错误的测试样本会导致更新分类器的性能下降。因此,基于融合后的概率形式定义决策可靠性指标,用决策可靠性高于预设门限的测试样本更新分类器,以保证分类器更新的有效性。在 MSTAR 数据集上的实验结果表明,相比单一分类器以及传统分类器,本方法使用的决策融合策略在分类精度方面具有明显的优势。

2 基础分类器

2.1 卷积神经网络

CNN 是传统神经网络在二维图像(信号)处理

中的扩展,通过设置多个不同的卷积层对原始数据进行深层次挖掘。各个卷积层均采用多个不同的卷积核提取原始图像中的二维特征,从而获得多层次特征。最终,网络通过端到端的训练学习构建高效的分类框架,实现测试样本的分类。目前,CNN 已经在图像处理领域得到了广泛运用^[17-23],但 CNN 的分类性能与训练样本的规模和覆盖面紧密相关。当训练样本数量较少时,最终训练的网络适应性较差,不能很好地完成 SAR 图像目标的识别任务。

在现有研究的基础上,设计了如图 1 所示的 CNN 结构,共包含 3 个卷积(Conv)层、3 个最大值池化层及 2 个全连接(FC)层。各层标识后的数字为卷积核的个数,@后为卷积核的尺寸。每个卷积层均采用线性整流函数(ReLU)作为激活函数,以增强网络的非线性适应性。在卷积层后设置最大值池化层,以提升网络整体的训练效率。最终通过 2 个 FC 层实现输入数据到类别标签的转换(图 1 以 10 分类目标为例)。网络的末端采用 Softmax 作为基础分类器,通过后验概率形式输出测试样本属于各个类别的可能性。该网络结构的整体复杂度较低,同时有利于提升 SAR 图像的目标识别效率。




图 1 CNN 的结构

Fig. 1 Structure of the CNN

2.2 稀疏表示分类

SRC 将稀疏表示用于模式识别问题,通过已知类别的训练样本对未知输入进行表征,然后根据不

同类别的重构误差判定测试样本的类别^[13-16]。假设 $D=[D^1, \dots, D^C] \in R^{d \times N}$ 为全局字典, 其中, C 为目标种类, d 为字典中样本的维度, N 为总样本数量, $D^i \in R^{d \times N_i}$ ($i=1, \dots, C$) 为第 i 类的 N_i 个训练样本。对于测试样本 y , 其稀疏表示过程为

$$\hat{x} = \operatorname{argmin} \|x\|_0, \text{ s. t. } \|y - Dx\|_2 \leq \epsilon, \quad (1)$$

式中, x 为稀疏系数矢量, ϵ 为误差的上限。目前, 常用于求解稀疏表示问题的算法包括 l_1 范数优化算法和正交匹配追踪 (OMP) 算法等^[13-16]。可根据 \hat{x} 按类别分别计算测试样本的重构误差, 最终判定测试样本所属的类别, 第 i 类样本的重构误差可表示为

$$r_i = \|y - D_i x_i\|_2^2, \quad X_{\text{identity}}(y) = \operatorname{argmin}_i (r_i), \quad (2)$$

式中, x_i 为第 i 类的稀疏系数矢量, X_{identity} 为 y 的所属类别。

相比 CNN, SRC 的分类机制对测试样本的数量依赖性较低, 且 SRC 对于噪声干扰、遮挡等复杂情形具有一定的鲁棒性。因此, CNN 与 SRC 在分类决策上具有一定的互补性, 融合两者的决策结果有利于获得更可靠的识别结果。

3 分类器更新及目标识别方法

3.1 决策准则及分类器的更新

对于 CNN 和 SRC 的分类结果, 采用加权融合方法得到最终的决策变量。CNN 用 Softmax 作为分类器, 其输出的决策变量为后验概率矢量 $[P_1, \dots, P_C]$ 。而 SRC 输出的结果为重构误差矢量 $[r_1, \dots, r_C]$ 。首先, 将 SRC 的决策变量转换成概率变量, 可表示为

$$P_i^S = 1 - \frac{r_i}{\sum_{i=1}^C r_i}. \quad (3)$$

然后, 用经典加权 (同等权值) 算法^[24-25] 将 CNN 的后验概率矢量与 SRC 转换的后验概率矢量进行融合, 可表示为

$$P_i^F = 0.5P_i + 0.5P_i^S, \quad i=1, \dots, C. \quad (4)$$

对于最终得到的决策变量 $[P_1^F, \dots, P_C^F]$, 定义的决策可靠性为

$$R = \min \left[\frac{P_K^F}{\max(P_i^F)} \right], \quad i \neq K, \quad (5)$$

式中, P_K^F 为最大概率值, $R \geq 1$ 。可以发现, R 越大, 表明分类结果越可靠。当决策可靠性高于设置的门限时, 认为当前类别可靠, 并将其加入原始训练样本, 对 CNN 和 SRC 分类器进行更新。反之, 则不更新训练集。

3.2 目标识别流程

通过分析决策可靠性对训练集进行动态更新, 进而获得更可靠的 SRC 和 CNN 分类器, 具体流程如图 2 所示, 关键步骤如下:

- 1) 用原始训练样本对图 1 所示的 CNN 进行训练, 同时构建 SRC 的全局字典;
- 2) 分别用 CNN 和 SRC 对未知类别的测试样本进行分类, 并按照 3.1 节中的准则判定其类别和决策可靠性;
- 3) 若当前测试样本的决策可靠性较高, 则将其加入原始训练样本, 对 CNN 及 SRC 全局字典进行动态更新;
- 4) 对于下一个测试样本, 重复步骤 2) 和步骤 3);
- 5) 对所有测试样本重复步骤 2)~步骤 4), 直至完成所有样本的分类。

随着类别确认的测试样本逐渐增多, CNN 及 SRC 的分类性能也得到了不断增强, 后续测试样本的分类精度也在不断提高。

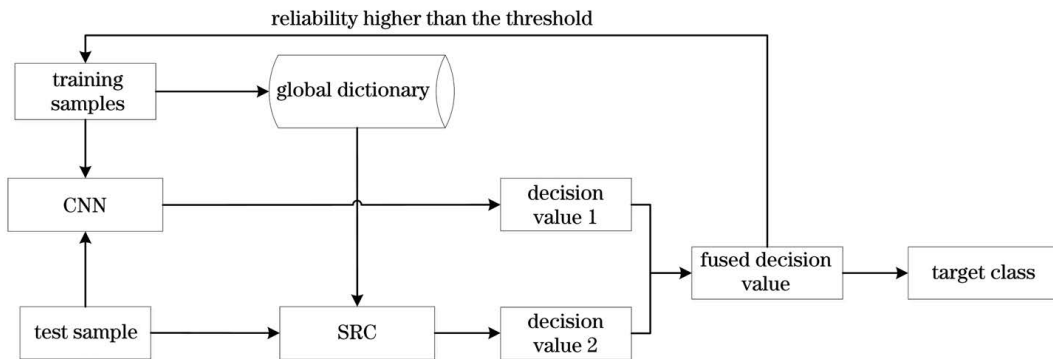


图 2 基于更新分类器的 SAR 图像目标识别流程图

Fig. 2 Flow chart of the SAR image target recognition based on updated classifier

4 实验结果及分析

4.1 数据集简介

MSTAR 数据集是现阶段测试 SAR 图像目标识别方法的代表性数据集,图 3 为包含 10 个类目标的光学和 SAR 图像。其中,各类目标的 SAR 均能囊括全方位角和若干俯仰角,图像分辨率为 $0.3\text{ m} \times 0.3\text{ m}$ 。通过对 MSTAR 数据样本进行灵活分集,可设置多种条件对不同方法进行测试。实

验设置的对比方法包括文献[16]中以 SRC 为基础分类器的方法、文献[17]中基于全卷积神经网络(A-ConvNet)的方法、文献[20]中基于增强数据集的 CNN(Aug-CNN)方法以及文献[12]中基于 SVM 和 SRC 决策融合(SVM+SRC)的方法。首先,在标准操作条件下开展测试,以验证不同方法的基础性能。然后,分别设置若干典型扩展操作条件,以验证不同方法在俯仰角差异、噪声干扰以及少量训练样本条件下的稳健性。




图 3 MSTAR 数据集中的目标图像。(a) BMP2;(b) BTR70;(c) T72;(d) T62;(e) BRDM2;(f) BTR60;(g) ZSU23/4;(h) D7;(i) ZIL131;(j) 2S1

Fig. 3 Target images in the MSTAR data set. (a) BMP2; (b) BTR70; (c) T72; (d) T62; (e) BRDM2; (f) BTR60; (g) ZSU23/4; (h) D7; (i) ZIL131; (j) 2S1

4.2 实验结果

4.2.1 标准操作条件

1) 基础测试

表 1 为 MSTAR 数据集上一种典型的标准操作条件,其中,训练集和测试集分别包含 10 类目标在 17° 和 15° 俯仰角获取的 SAR 图像,两者均覆盖 $0^\circ \sim 360^\circ$ 的方位角,设置的可靠性门限值为 1.4。用本方法对测试样本进行分类,得到的混淆矩阵如图 4 所示。其中,编号 1~10 依次对应表 1 中的 10 类目标。可以发现,本方法对不同类别的分类精度均高于 98%。本方法对 BMP2 和 T72 目标的识别率相对较低,原因是两者的训练集和测试集存在型号差异。此外,由于 BTR60 与 BMP2、T72 目标样本的相似性较高,识别率也相对较低。不同方法在相同条件下对 10 类目标的平均识别率如表 2 所

1	0.985	0	0.010	0	0	0.005	0	0	0	0	
2	0	1.000	0	0	0	0	0	0	0	0	
3	0.005	0	0.990	0	0	0	0.005	0	0	0	
4	0.004	0	0	0.993	0	0	0	0	0	0	
5	0.004	0.004	0	0	0.993	0	0	0	0	0	
6	0.005	0	0.005	0	0	0.990	0	0	0	0	
7	0	0.004	0	0.004	0	0	0.993	0	0	0	
8	0	0	0	0.004	0	0	0	0.996	0	0	
9	0	0	0	0	0	0	0	0	1.000	0	
10	0	0.004	0	0	0.004	0	0	0	0	0.993	
		1	2	3	4	5	6	7	8	9	10

图 4 标准操作条件下的分类结果

Fig. 4 Classification results under standard operating conditions

表 1 标准操作条件的测试场景

Table 1 Test scenarios for standard operating conditions

Class	Training (17°)		Test (15°)	
	Configuration	Number of samples	Configuration	Number of samples
BMP2	9563	233	9563	195
			9566	196
			c21	196
BTR70	-	233	-	196
			132	196
T72	132	232	812	195
			S7	191
			-	273
T62	-	299	-	273
BRDM2	-	298	-	274
BTR60	-	256	-	195
ZSU23/4	-	299	-	274
D7	-	299	-	274
ZIL131	-	299	-	274
2S1	-	299	-	274

表 2 不同方法在标准操作条件下的分类结果

Table 2 Classification results of different methods under standard operating conditions unit: %

Method	Average recognition rate
Ours	99.08
SRC	96.42
A-ConvNet	98.53
Aug-CNN	98.91
SVM+SRC	97.48

示,可以发现,本方法在标准操作条件下的识别性能优于其他对比方法。相比单一采用 SRC 或 CNN 的方法,本方法通过确认类别的测试样本补充训练集,并结合两种方法的分类结果提升分类精度。Aug-CNN 方法虽然通过模拟仿真训练样本提升了传统 CNN 的分类性能,但提升幅度十分有限,且会带来额外的时间消耗。相比融合 SVM 和

SRC 的方法,本方法在融合 CNN 和 SRC 的同时对两个分类器进行动态更新,进一步提升了分类性能。

2) 参数校验

本方法中可靠性门限的选取对最终分类器的更新和识别性能有直接影响,表 3 为不同门限条件下本方法对 10 类目标的平均识别率。可以发现,本方法在不同门限下的平均识别率均高于 98.5%,且在门限相对较低,如为 1.1 时,决策可靠性容易满足要求,可将更多的样本用于分类器更新,但其中部分错误分类样本会导致分类器性能下降,从而降低网络的平均识别率。当门限相对较高,如为 1.7 时,对决策可靠性的要求很高,只有少量测试样本能够用于分类器的更新,使本方法退化为传统的决策融合方法。经对比分析和多次重复实验,实验选取的门限为 1.4,原因是该门限可以有效保证测试样本选取的合理性和分类器更新的可靠性。

表 3 本方法在不同决策可靠性门限下的分类结果

Table 3 Classification results of our method under different decision reliability thresholds unit: %

Threshold	1.1	1.2	1.3	1.4	1.5	1.6	1.7
Average recognition rate	98.62	98.86	99.02	99.08	99.03	98.79	98.54

3) 决策机制分析

本方法结合 CNN 与 SRC 的决策融合策略并通

过准确识别的样本更新两个分类器,最终性能与 CNN 和 SRC 的决策融合效果以及分类器更新的有

效性相关。表 4 为 1 个 BMP2 目标测试样本的决策变量情况,其中,第 1 组和第 2 组决策值分别由 SRC 和 CNN 获得,均为归一化概率的形式,融合后的决策值根据(4)式得到。按最大概率选取原则, SRC 的决策为 T72 目标, CNN 的决策为 BMP2 目标,融

合后的决策为 BMP2 目标。此时, SRC 的决策为错误的。而引入 CNN 的决策融合后可获得正确的识别结果。同理,在部分情形(如噪声干扰)下, SRC 的决策可靠性更强,此时 SRC 可以有效弥补 CNN 的不足,提升最终决策的整体稳健性。

表 4 BMP2 测试样本的决策变量分布

Table 4 Decision variable distribution of BMP2 test sample

Class	1	2	3	4	5	6	7	8	9	10
Decision value 1	0.28	0.05	0.32	0.04	0.10	0.04	0.01	0.06	0.05	0.05
Decision value 2	0.36	0.07	0.18	0.06	0.08	0.07	0.02	0.05	0.07	0.04
Fused decision value	0.32	0.06	0.25	0.05	0.05	0.06	0.02	0.06	0.06	0.05

为验证本方法中更新机制的有效性,从表 1 中的训练样本随机选取一半作为新的训练集,并将测试样本按照测试顺序等分为 4 部分。表 5 为 4 个测试集的平均识别率,可以发现,随着分类器的不断更新,后部分测试子集的识别率不断提高,验证了本方法中更新机制的有效性。此外,实验结果还表明,未引入更新机制条件下, CNN 和 SRC 决策融合条件下对 10 类目标的平均识别率为 73.2%,进一步反映了分类器更新机制的有效性。

表 5 不同测试子集的平均识别率

Table 5 Average recognition rates of different test subsets

Test subset	unit: %				
	Part 1	Part 2	Part 3	Part 4	All
Average recognition rate	69.32	75.45	85.64	89.12	79.86

4.2.2 俯仰角差异

测试样本与训练集之间的俯仰角差异会导致 SAR 图像的特性差异,表 6 为基于 MSTAR 数据集设置的俯仰角差异条件下的训练集和测试集,包含 3 类目标。其中,训练集包含 17°俯仰角的 SAR 图像,训练集包含 30°和 45°俯仰角的 SAR 图像。在 2 个角度下开展实验,得到不同方法的平均识别率如表 7 所示。可以发现,不同方法在 45°俯仰角下的识别性能均明显低于 30°俯仰角,这表明大俯仰角差异会严重影响正确分类决策。而本方法通过对高置信度测试样本的运用以及 CNN 和 SRC 决策的融合,相比采用单一分类器的 A-ConvNet、SRC 以及 Aug-CNN 方法,分类决策的置信度更高,这充分说明了决策融合及动态更新分类器的有效性。相比 SVM+SRC 方法,本方法一方面引入了分类性能更强的 CNN,另一方面利用识别准确的样本对 CNN 和 SRC 进行更新,得到的最终决策结果可靠性更高,

表 6 俯仰角差异的测试条件

Table 6 Test conditions for pitch angle difference

Class	Training		Test	
	Depression	Number of samples	Depression	Number of samples
2S1	17°	299	30°	288
			45°	303
BDRM2	17°	298	30°	287
			45°	303
ZSU23/4	17°	299	30°	288
			45°	303

表 7 不同俯仰角下的测试结果

Table 7 Test results under different pitch angles unit: %

Method	Depression	
	30°	45°
Ours	96.12	72.74
SRC	92.17	64.38
A-ConvNet	94.12	65.93
Aug-CNN	95.38	69.32
SVM+SRC	94.16	66.08

识别性能也更优。

4.2.3 噪声干扰

为测试本方法在噪声干扰条件下的分类性能,以表 1 中标准操作条件下的训练集和测试集为基础,向原始测试样本中添加不同程度的噪声,从而构造不同信噪比(SNR)下的测试集。不同方法在不同 SNR 下的分类结果如图 5 所示,可以发现,本方法在不同 SNR 测试集下均保持了最高的识别率, Aug-CNN 方法的分类性能仅次于本方法,原因是该方法在训练集中加入了模拟生成的噪声样本,提

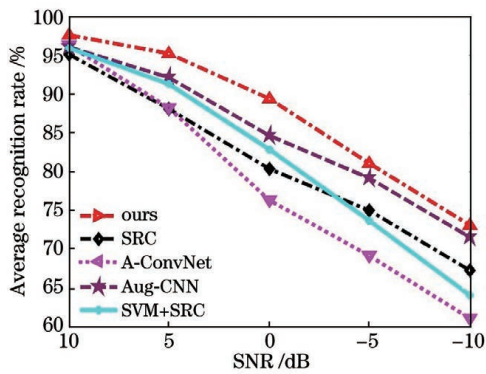


图 5 不同方法在噪声干扰下的分类结果

Fig. 5 Classification results of different methods under noise interference

高了网络对噪声的适应性。A-ConvNet 方法的训练样本均来自高 SNR 的测试集,对噪声干扰尤其是低 SNR 测试样本的分类精度较低。相比 A-ConvNet 方法, SRC 方法和 SVM+SRC 方法对低 SNR 样本的适应能力更强,原因是稀疏表示对于噪声干扰具有一定的鲁棒性。而本方法融合了 CNN 和 SRC 的决策结果,既保持了 SRC 固有的噪声稳健性,也通过动态更新训练样本提高了网络对噪声干扰情形的覆盖能力,最终形成的融合决策对于噪声样本的适应性更强。

4.2.4 少量训练样本

由于 SAR 图像目标识别中可用的训练样本较少,难以覆盖测试样本可能存在的情形(如视角、SNR)。因此,提升识别方法在有限训练样本条件下的稳健性十分重要。以表 1 中的数据为基础,随机抽取原始训练集的 80%, 60%, 40%, 20% 构建新的训练集,然后对原始测试集进行分类,得到不同方法的识别结果如图 6 所示。可以发现,本方法在训练样本较少情况下的分类性能具有明显优势。一方面, CNN 和 SRC 在决策层的融合提升了整体决策

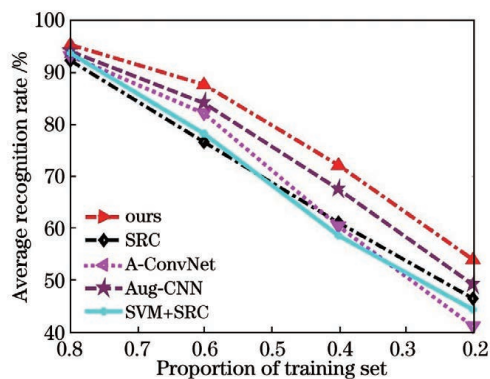


图 6 少量训练样本条件下的结果对比

Fig. 6 Comparison of results under small training samples

的容错性;另一方面,随着确认类别测试样本的不断增多,更新后的 CNN 和 SRC 分类结果也更可靠,而其他对比方法受限于训练样本的规模,整体识别性能均十分有限。

5 结 论

提出了一种基于更新分类器的 SAR 图像目标识别方法,通过对测试样本类别的确认不断更新可用训练样本,从而提升网络的分类性能。用 CNN 和 SRC 作为基础分类器,在更新训练样本的基础上提升独立分类器的分类性能。同时,在决策层对两者进行融合,以获得更可靠的识别结果。基于 MSTAR 数据集的实验结果表明,本方法在标准操作条件、俯仰角差异、噪声干扰和少量训练样本下的分类性能均优于现有分类方法。

参 考 文 献

- [1] El-Darymli K, Gill E W, McGuire P, et al. Automatic target recognition in synthetic aperture radar imagery: a state-of-the-art review [J]. IEEE Access, 2016, 4: 6014-6058.
- [2] Anagnostopoulos G C. SVM-based target recognition from synthetic aperture radar images using target region outline descriptors [J]. Nonlinear Analysis: Theory, Methods & Applications, 2009, 71 (12): e2934-e2939.
- [3] Xie Q, Zhang H. Multi-level SAR image enhancement based on regularization with application to target recognition [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32 (9): 157-162.
谢晴, 张洪. SAR 图像多层次正则化增强及在目标识别中的应用 [J]. 电子测量与仪器学报, 2018, 32 (9): 157-162.
- [4] Papson S, Narayanan R M. Classification via the shadow region in SAR imagery [J]. IEEE Transactions on Aerospace and Electronic Systems, 2012, 48(2): 969-980.
- [5] Ding B Y, Wen G J, Yu L S, et al. Matching of attributed scattering center and its application to synthetic aperture radar automatic target recognition [J]. Journal of Radars, 2017, 6(2): 157-166.
丁柏圆, 文贡坚, 余连生, 等. 属性散射中心匹配及其在 SAR 目标识别中的应用 [J]. 雷达学报, 2017, 6(2): 157-166.
- [6] Ding B Y, Wen G J, Zhong J R, et al. A robust similarity measure for attributed scattering center sets with application to SAR ATR [J]. Neurocomputing,

- 2017, 219: 130-143.
- [7] Liu X W, Lei J C, Wu Y P. Synthetic aperture radar target-recognition method based on bidimensional empirical mode decomposition[J]. *Laser & Optoelectronics Progress*, 2020, 57(4): 041004.
柳小文, 雷军程, 伍雁鹏. 基于二维经验模态分解的合成孔径雷达目标识别方法[J]. *激光与光电子学进展*, 2020, 57(4): 041004.
- [8] Cui Z Y, Cao Z J, Yang J Y, et al. Target recognition in synthetic aperture radar images via non-negative matrix factorization [J]. *IET Radar, Sonar & Navigation*, 2015, 9(9): 1376-1385.
- [9] Dong G G, Kuang G Y, Wang N, et al. SAR target recognition via joint sparse representation of monogenic signal [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2015, 8(7): 3316-3328.
- [10] Hao Y, Bai Y P, Zhang X F. Synthetic aperture radar target recognition based on KNN [J]. *Fire Control & Command Control*, 2018, 43(9): 111-113, 118.
郝岩, 白艳萍, 张校非. 基于 KNN 的合成孔径雷达目标识别[J]. *火力与指挥控制*, 2018, 43(9): 111-113, 118.
- [11] Liu C Q, Chen B, Pan Z H, et al. Research of target recognition technique via simulation SAR and SVM classifier[J]. *Journal of China Academy of Electronics and Information Technology*, 2016, 11(3): 257-262.
刘长清, 陈博, 潘舟浩, 等. 基于仿真 SAR 和 SVM 分类器的目标识别技术研究[J]. *中国电子科学研究院学报*, 2016, 11(3): 257-262.
- [12] Liu H C, Li S T. Decision fusion of sparse representation and support vector machine for SAR image target recognition[J]. *Neurocomputing*, 2013, 113: 97-104.
- [13] Xing X W, Ji K F, Zou H X, et al. Sparse representation based SAR vehicle recognition along with aspect angle[J]. *The Scientific World Journal*, 2014, 2014: 834140.
- [14] Zhang H, Zuo X L, Huang Y. Feature selection based on the correlation of sparse coefficient vectors with application to SAR target recognition[J]. *Laser & Optoelectronics Progress*, 2020, 57(14): 141029.
张虹, 左鑫兰, 黄瑶. 基于稀疏表示系数相关性的特征选择及 SAR 目标识别方法[J]. *激光与光电子学进展*, 2020, 57(14): 141029.
- [15] Zhang X Z, Huang P K. SAR ATR based on Bayesian compressive sensing[J]. *Systems Engineering and Electronics*, 2013, 35(1): 40-44.
张新征, 黄培康. 基于贝叶斯压缩感知的 SAR 目标识别[J]. *系统工程与电子技术*, 2013, 35(1): 40-44.
- [16] Zhang L, Tao Z W, Wang B J. SAR image target recognition using kernel sparse representation based on reconstruction coefficient energy maximization rule[C]//2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), March 20-25, 2016, Shanghai, China. New York: IEEE Press, 2016: 2369-2373.
- [17] Chen S Z, Wang H P, Xu F, et al. Target classification using the deep convolutional networks for SAR images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(8): 4806-4817.
- [18] Du K N, Deng Y K, Wang R, et al. SAR ATR based on displacement- and rotation-insensitive CNN [J]. *Remote Sensing Letters*, 2016, 7(9): 895-904.
- [19] Wagner S A. SAR ATR by a combination of convolutional neural network and support vector machines[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2016, 52(6): 2861-2872.
- [20] Ding J, Chen B, Liu H W, et al. Convolutional neural network with data augmentation for SAR target recognition[J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(3): 364-368.
- [21] Yan Y. Convolutional neural networks based on augmented training samples for synthetic aperture radar target recognition [J]. *Journal of Electronic Imaging*, 2018, 27(2): 023024.
- [22] Huang Z L, Pan Z X, Lei B. Transfer learning with deep convolutional neural network for SAR target classification with limited labeled data [J]. *Remote Sensing*, 2017, 9(9): 907-928.
- [23] Malmgren-Hansen D, Kusk A, Dall J, et al. Improving SAR automatic target recognition models with transfer learning from simulated data[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(9): 1484-1488.
- [24] Huan R H, Pan Y. Target recognition for multi-aspect SAR images with fusion strategies[J]. *Progress in Electromagnetics Research*, 2013, 134: 267-288.
- [25] Zhao P J, Gan K. SAR target recognition based on hierarchical decision fusion of complementary features [J]. *Electronics Optics & Control*, 2018, 25(10): 28-32.
赵鹏举, 甘凯. 基于互补特征层次决策融合的 SAR 目标识别方法[J]. *电光与控制*, 2018, 25(10): 28-32.