

结合多分辨率表示和复数域 CNN 的 SAR 图像目标识别方法

乔良才*

徐州工程学院信息工程学院(大数据学院), 江苏 徐州 221018

摘要 为了提高合成孔径雷达(SAR)图像目标的识别性能,将多分辨率表示与复数域卷积神经网络(CNN)联合使用。首先通过对原始 SAR 图像的时频域进行处理,获得其多分辨率表示图像;然后采用复数域 CNN 分别对原始 SAR 图像及其多分辨率表示图像进行分类;接着对分类结果进行线性加权融合,根据融合结果对测试样本类别进行判决;最后基于 MSTAR 数据集对所提方法在标准和扩展的操作条件下进行实验。实验结果表明,所提方法具有有效性及稳健性。

关键词 图像处理;合成孔径雷达;目标识别;多分辨率表示;复数域 CNN;线性加权融合

中图分类号 TN957

文献标志码 A

doi: 10.3788/LOP57.241007

SAR Image Target Recognition Method Combining Multi-Resolution Representation and Complex Domain CNN

Qiao Liangcai*

School of Information Engineering (College of Big Data), Xuzhou University of Technology, Xuzhou, Jiangsu 221018, China

Abstract To improve the recognition performance of synthetic aperture radar (SAR) image targets, multi-resolution representation and a complex domain convolutional neural network (CNN) are used in combination. Initially, the original SAR image is processed in time and frequency domain to obtain its multi-resolution representation image. Then, the complex domain CNN is used to classify the original image and its multi-resolution representation image. The classification results are weighted using a linearly weighted fusion scheme, and the test sample classification is evaluated according to the fusion result. Finally, the proposed method is tested under standard and extended operating conditions based on the MSTAR data set. The experimental results show that the proposed method is both effective and robust.

Key words image processing; synthetic aperture radar; target identification; multi-resolution representation; complex domain CNN; linear weighting fusion

OCIS codes 100.3008; 120.0280

1 引言

随着合成孔径雷达(SAR)数据获取及解译能力的不断提高,SAR 图像目标识别技术在军民领域具有重要意义^[1-5]。SAR 图像目标识别技术在军事领域中的应用十分广泛,主要通过匹配待识别样本与明确类别训练样本之间的信息来达到鉴别分类的

目的^[6]。SAR 图像目标识别多采用特征提取和分类决策两个阶段来获得识别结果,其中特征提取阶段通过图像处理和分解等来获得低维度和区分性强的特征矢量,处理和分解依据有外形尺寸^[7-9]、像素分布^[10-13]及散射机理^[14-15]等,分类决策阶段通过决策面等判决机制来获得输入样本的类别,判决机制有最近邻^[16]、支持向量机(SVM)^[17-18]和稀疏表示

收稿日期:2020-05-14;修回日期:2020-05-31;录用日期:2020-06-04

基金项目:江苏省现代教育技术研究 2017 年度课题(55518)

*E-mail: qiaolc@xzit.edu.cn

(SRC)^[18-19]等。近年来,随着深度学习技术的不断进步,以卷积神经网络(CNN)为代表的深度模型在SAR图像目标识别方面得以成功运用^[20-22],该模型使用的是光学图像处理领域的最新成果,通过运用新模型来提升SAR图像目标识别的性能。事实上,与一般光学图像的像素值不同,SAR图像的像素值为复数,其可以体现图像的幅度和相位信息。采用一般的CNN并不能充分利用图像中的信息,为此文献[23-24]采用了复数域CNN的SAR图像目标识别方法对图像进行分析处理并验证其处理效果。

本文提出结合多分辨率表示和复数域CNN的SAR图像目标识别方法。对于原始的SAR图像,首先进行多分辨率处理以构造多个不同分辨率的图像,其与原始图像相同,均为复数图像并包含幅度和相位信息。文献[25-27]设计了基于多分辨率表示的SAR目标识别方法,并验证该方法的性能优势。在此基础上,采用复数域CNN对各个分辨率的图像进行训练学习,从而获得相应的分类网络。对于待识别样本,构造图像的多分辨率表示,并运用对应的复数域CNN对其进行分类,从而获得相应的概率分布矢量。接着,基于线性加权融合对不同分辨率的图像进行融合处理,从而获得最终的概率分布矢量。基于最大概率的原则即可判定测试样本的所属类别,相比于直接对原始图像进行复数域CNN分类,本文综合应用多分辨率表示可以有效起到互

补的作用,从而提升整体决策的稳健性。最后,在MSTAR数据集上验证所提方法的有效性。

2 多分辨率表示

对于较大的带宽和合成孔径,SAR可以实现距离和方位的二维高分辨成像。使用SAR目标图像可以有效实现目标几何形状、时频域特性分析以及散射中心分布等特征的提取,进而服务于图像解译。文献[25-27]在设计多分辨率表示的SAR图像目标识别方法时,提出了基于原始SAR图像的多分辨率表示构造算法。图1为多分辨率表示算法的基本流程和关键步骤。从图1可以看到,首先采用二维快速傅里叶逆变换(2D IFFT)将原始图像从空域变换到频域;然后根据预设的分辨率从原始的频域数据中分离出相应的频域数据;最后采用二维快速傅里叶变换(2D FFT)将分离的频域数据变换到图像域,从而获得预设分辨率的SAR图像。相比于原始图像,低分辨率SAR目标图像的细节信息相对模糊,但其整体结构特性依然可以保持,因此定性判断多分辨率表示的图像可以为目标特性的分析提供更多的可用信息。与原始图像相同,构造的多分辨率表示图像依然是复数域图像,其包含幅度和相位信息,因此联合采用多分辨率表示算法可以更为有效地考察目标图像的时频特性。




图1 多分辨率表示算法的流程图

Fig. 1 Flow chart of multi-resolution representation algorithm

图2为MSTAR数据集中的SAR图像目标(分辨率为0.3m)及其构造得到的多分辨率表示图




图2 不同分辨率下的SAR图像目标。(a)原始图像;
(b) 0.4 m; (c) 0.5 m; (d) 0.6 m

Fig. 2 SAR image targets under different resolutions.
(a) Original image; (b) 0.4 m; (c) 0.5 m; (d) 0.6 m

像,分辨率分别为0.4,0.5,0.6m。从图2可以看到,在较低分辨率的条件下,目标区域的特征仍较为明显,说明多分辨率表示算法能够在目标的整体特征分析过程中起到支撑的作用,综合运用多分辨率表示图像有利于提升分类识别的精度。

3 复数域CNN

复数域CNN是传统的实数域CNN的扩展,其具备直接处理复数矩阵和图像的能力^[23-24]。与传统的实数域CNN相比,复数域CNN的关键在于网络的权重参数求解。

3.1 前向传播

卷积操作的过程中,第 l 层的输出特征图 \mathbf{a}^l

通过权重 \mathbf{W}^{l+1} 并结合偏差 \mathbf{b}^{l+1} 来获得中间输出特征图 \mathbf{z}^{l+1} , 进而使用复数域非线性激活函数 σ

来获得复数域特征图 \mathbf{a}^{l+1} 。复数域的卷积表达式为

$$\mathbf{a}^{l+1} = \sigma [\operatorname{Re}(\mathbf{z}^{l+1})] + j\sigma [\operatorname{Im}(\mathbf{z}^{l+1})] = \sigma [\operatorname{Re}(\mathbf{W}^{l+1} * \mathbf{a}^l + \mathbf{b}^{l+1})] + j\sigma [\operatorname{Im}(\mathbf{W}^{l+1} * \mathbf{a}^l + \mathbf{b}^{l+1})], \quad (1)$$

$$\begin{aligned} \mathbf{z}_i^{l+1} &= \sum_{k=1}^K [\operatorname{Re}(\mathbf{w}_{ik}^{l+1}) * \operatorname{Re}(\mathbf{a}_k^l) - \operatorname{Im}(\mathbf{w}_{ik}^{l+1}) * \operatorname{Im}(\mathbf{a}_k^l)] + \\ &j \sum_{k=1}^K [\operatorname{Re}(\mathbf{w}_{ik}^{l+1}) * \operatorname{Im}(\mathbf{a}_k^l) + \operatorname{Im}(\mathbf{w}_{ik}^{l+1}) * \operatorname{Re}(\mathbf{a}_k^l)] + \mathbf{b}_i^{l+1}, \end{aligned} \quad (2)$$

式中: j 为虚数单位; $*$ 为卷积操作符号; Re 和 Im 分别为对应复数的实部和虚部; \mathbf{a}_k^l 为第 l 层、第 k 个输出特征图; \mathbf{z}_i^{l+1} 为第 $l+1$ 层、第 i 个中间输出特

征图; \mathbf{w}_{ik}^{l+1} 为 \mathbf{a}_k^l 与 \mathbf{z}_i^{l+1} 之间的卷积核; \mathbf{b}_i^{l+1} 为第 $l+1$ 层、第 i 个中间输出特征图的偏差。

全连接层的输出表达式为

$$\mathbf{a}^L = \sigma [\operatorname{Re}(\mathbf{z}^L)] + j\sigma [\operatorname{Im}(\mathbf{z}^L)], \quad (3)$$

$$\mathbf{z}^L = \mathbf{W}^L \mathbf{a}^{L-1} + \mathbf{b}^L = \mathbf{W}^L \sigma(\mathbf{z}^{L-1}) = \operatorname{Re}(\mathbf{W}^L) \sigma [\operatorname{Re}(\mathbf{z}^{L-1})] + \operatorname{Re}(\mathbf{b}^L) + j \{ \operatorname{Im}(\mathbf{W}^L) \sigma [\operatorname{Im}(\mathbf{z}^{L-1})] \} + \operatorname{Im}(\mathbf{b}^L), \quad (4)$$

式中: L 为复数域 CNN 的输出层数。

3.2 后向传播

复数域 CNN 后向传播算法的原理与传统的后

向传播算法一致。定义误差函数 J 来描述网络输出与类别标签之间的差异, 表达式为

$$J = \frac{1}{2} \left\| \mathbf{a}^L - \mathbf{y} \right\|_2^2 = \frac{1}{2} \left\| [\operatorname{Re}(\mathbf{a}^L) - \operatorname{Re}(\mathbf{y})] - j [\operatorname{Im}(\mathbf{a}^L) - \operatorname{Im}(\mathbf{y})] \right\|_2^2, \quad (5)$$

式中: \mathbf{y} 为类别标签。迭代更新的求解公式为

$$\mathbf{W}_{t+1}^{l+1} = \mathbf{W}_t^{l+1} - \alpha \frac{\partial J_t}{\partial \mathbf{W}_t^{l+1}}, \quad (6)$$

$$\mathbf{b}_{t+1}^{l+1} = \mathbf{b}_t^{l+1} - \alpha \frac{\partial J_t}{\partial \mathbf{b}_t^{l+1}}, \quad (7)$$

式中: α 为学习率; t 为迭代次数。定义的误差项为

$$\boldsymbol{\delta}^{l+1} = \frac{\partial J}{\partial \operatorname{Re}(\mathbf{z}^{l+1})} + j \frac{\partial J}{\partial \operatorname{Im}(\mathbf{z}^{l+1})}, \boldsymbol{\delta}^{l+1} \in \mathbf{C}. \quad (8)$$

根据(8)式可以获得输出层的误差项 $\boldsymbol{\delta}^L$, 表达式为

$$\begin{aligned} \boldsymbol{\delta}^L &= \operatorname{Re}(\mathbf{a}^L - \mathbf{y}) \boldsymbol{\sigma}' \operatorname{Re}(\mathbf{z}^L) + \\ &j [\operatorname{Im}(\mathbf{a}^L - \mathbf{y}) \boldsymbol{\sigma}' \operatorname{Im}(\mathbf{z}^L)], \end{aligned} \quad (9)$$

式中: $\boldsymbol{\sigma}'$ 为协方差矩阵。对于输出层的前一个隐藏层, 其误差项 $\boldsymbol{\delta}^{L-1}$ 为

$$\boldsymbol{\delta}^{L-1} = (\mathbf{W}^L)^* \boldsymbol{\delta}^L \odot \boldsymbol{\sigma}'(\mathbf{z}^{L-1}), \quad (10)$$

式中: $(\cdot)^*$ 为复共轭转置; \odot 为 Hadamard 积。

全连接层的权重更新为

$$\frac{\partial J}{\partial \mathbf{W}^L} = \boldsymbol{\delta}^L (\mathbf{a}^{L-1})^*. \quad (11)$$

将第 a 层卷积层的误差项 $\boldsymbol{\delta}_k^a$ 与池化因子 β 相关联, 获得的 $\boldsymbol{\delta}_k^a$ 为

$$\begin{aligned} \operatorname{Re}(\boldsymbol{\delta}_k^a) &= \beta_i^{a+1} \{ \operatorname{Re} [u_{\text{up}}(\boldsymbol{\delta}_i^{a+1})] + \\ &\operatorname{Im} [u_{\text{up}}(\boldsymbol{\delta}_i^{a+1})] \} \sigma(\mathbf{z}_k^a), \end{aligned} \quad (12)$$

$$\begin{aligned} \operatorname{Im}(\boldsymbol{\delta}_k^a) &= \beta_i^{a+1} \{ \operatorname{Im} [u_{\text{up}}(\boldsymbol{\delta}_i^{a+1})] - \\ &\operatorname{Re} [u_{\text{up}}(\boldsymbol{\delta}_i^{a+1})] \} \sigma(\mathbf{z}_k^a), \end{aligned} \quad (13)$$

$$\boldsymbol{\delta}_k^a = \operatorname{Re}(\boldsymbol{\delta}_k^a) + j \operatorname{Im}(\boldsymbol{\delta}_k^a), \quad (14)$$

式中: $u_{\text{up}}(\cdot)$ 为上采样操作。使 $u_{\text{up}}(\boldsymbol{\delta}_i^{a+1})$ 与 $\boldsymbol{\delta}_k^a$ 具有相同的尺寸, 则卷积层的权重更新为

$$\frac{\partial J}{\partial \mathbf{W}^a} = \overline{\mathbf{a}^{a-1}} * \boldsymbol{\delta}^a, \quad (15)$$

式中: $\overline{(\cdot)}$ 为取复共轭。

根据(1)~(15)式的推导过程, 设计的复数域 CNN 结构如图 3 所示, 其中 ReLU 为线性整流函数。从图 3 可以看到, 将 MSTAR 数据集中的 10 类目标识别图像作为背景并设计复数域 CNN, 该网络包含三个卷积层、三个池化层(采用最大值池化操作进行处理)以及两个全连接层。对原始训练集进行构造以得到不同分辨率的图像, 并使用网络对其进行训练, 从而获得相应的分类模型。对不同分辨率的图像采用对应的网络进行分类, 通过 Softmax 来获得相应的概率分布矢量。Softmax 是一种基于概率理论的多类别分类器, 通常在网络的最后一层获得 M 个后验概率 p_m ($m = 1, 2, \dots, M$), 其中 M 为参数识别的目标类别总数, p_m 为当前输入图像




图3 获得标签分布的流程示意图

Fig. 3 Flow chart of obtaining label distribution

属于第 m 类的后验概率,基本计算公式为

$$p_m = \frac{\exp(V_m)}{\sum_{m=1}^M \exp(V_m)}, \quad (16)$$

式中: V_m 为第 m 个输出的前一层输入元素。

图4为基于原始分辨率MSTAR图像的网络训练过程收敛曲线。从图4可以看到,迭代约2000次后,曲线趋于收敛。图5为所提网络的部分中间过程输出的特征图。从图5可以看到,网络学习得到的特征图与原始图像具有较高的关联性,说明该网络能够保留目标图像的各种特性。




图4 网络训练过程的收敛曲线

Fig. 4 Convergence curve of network training process




图5 所提网络输出的特征图。(a)输入图像;(b)第一卷积层

Fig. 5 Feature maps of proposed network output. (a) Input image; (b) first convolutional layer

3.3 识别算法及流程

对4个不同分辨率的输出概率分布矢量采用线性加权融合的形式进行融合,分辨率为0.3,0.4,0.5,0.6 m所对应的概率矢量分别为 $r_1(m)$, $r_2(m)$, $r_3(m)$, $r_4(m)$,其线性加权的过程为

$$r_f(m) = w_1 * r_1(m) + w_2 * r_2(m) + w_3 * r_3(m) + w_4 * r_4(m), \quad (17)$$

式中: w_1 , w_2 , w_3 和 w_4 为权值。从图1可以看到,不同分变率图像所包含的鉴别力信息仍然是有所区别的,分辨率越高,则分类的可用价值相对更大。为此,经验性设置 $w_1 = 0.4$, $w_2 = 0.3$, $w_3 = 0.2$ 和 $w_4 = 0.1$ 并代入后续的融合处理过程中,最终根据融合后的概率矢量来判定测试样本的类别。

通过结合多分辨率表示和复数域CNN设计的目标识别流程如图6所示,具体步骤如下。

1)构造原始训练样本集的多分辨率表示,分别为0.3,0.4,0.5,0.6 m并独立构成训练集。

2)采用复数域CNN分别对各个分辨率下的训练集进行学习以获得不同的分类网络。

3)对于待识别的测试样本,采用相同的算法来构造其多分辨率表示。

4)对于对应分辨率的测试样本,采用相应的复数域CNN对其进行分类以输出概率分布矢量。

5)基于线性加权融合对4个不同分辨率的概率分布矢量进行加权融合,从而获得最终的概率分布矢量。

6)比较不同类别的后验概率,具有最大值者即为测试样本。

以图5的输入图像为例,对所提方法的主要过程进行定量描述。不同分辨率的图像训练得到的后验概率矢量分别为 $[0.51 \ 0.07 \ 0.12 \ 0.02 \ 0.06 \ 0.05 \ 0.100 \ 0.030 \ 0.020 \ 0.02]$, $[0.480 \ 0.100 \ 0.080 \ 0.040 \ 0.05$

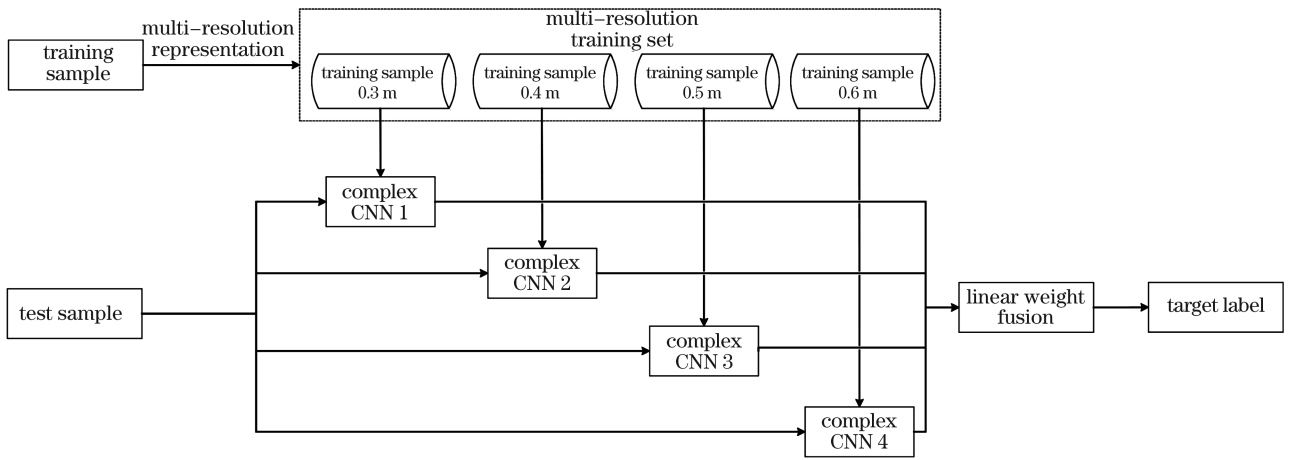


图 6 结合多分辨率表示与复数域 CNN 的 SAR 图像目标识别流程示意图

Fig. 6 Flow chart of SAR image target recognition process combining multi-resolution representation and complex domain CNN

0.07 0.06 0.04 0.02 0.06]、[0.45 0.07 0.12 0.06 0.09 0.03 0.01 0.08 0.05 0.04]和[0.50 0.06 0.09 0.04 0.07 0.05 0.02 0.04 0.06 0.07]。采用(17)式融合后得到的最终概率矢量为[0.49 0.08 0.11 0.04 0.06 0.05 0.06 0.04 0.03 0.04]。根据最大后验概率原则,判定当前输入图像的类别为 BMP2。

4 实验与结果

4.1 实验准备

基于 MSTAR 数据集开展实验,对其中包含的 10 类地面车辆 SAR 图像进行识别,待识别目标图像如图 7 所示。对 SAR 图像均通过 X 波段机载 SAR 进行成像,原始距离及方位的分辨率均为 0.3 m。对于每一类 SAR 图像,其可以有效覆盖 $0^{\circ}\sim 360^{\circ}$ 范围内的方位角以及典型俯仰角(15° 和 17°

等)。基于 MSTAR 数据集可以设置多种实验场景,覆盖标准以及扩展的操作条件。其中标准的操作条件通常是对全部的 10 类目标图像进行分类,扩展操作条件中的目标类别相对较少,但测试样本与训练样本之间存在较大差异,典型的有型号差异、俯仰角差异和噪声干扰等。因此,基于 MSTAR 数据集可以有效对所提方法的有效性和稳健性进行验证。

实验过程中将所提方法与已有的同类方法进行对比,包括文献[25,27]中基于多分辨率表示的方法,分别记为多分辨率 1(MR 1)和多分辨率 2(MR 2),文献[20]中基于实数全卷积神经网络的方法,记为 CNN,文献[23]中基于复数域 CNN 的方法,记为复数域 CNN(CCNN)。与文献[23]方法不同,所提方法并不是直接对原始图像进行训练和分类,而是综合应用多分辨率表示。后续实验分别在标准以及扩展的操作条件下进行比较和验证。



图 7 待识别的目标示意图。(a) BMP2; (b) BRT70; (c) T72; (d) T62; (e) BRDM2; (f) BTR60; (g) ZSU23/4; (h) D7; (i) ZIL131; (j) 2S1

Fig. 7 Schematic of target to be identified. (a) BMP2; (b) BRT70; (c) T72; (d) T62; (e) BRDM2; (f) BTR60; (g) ZSU23/4; (h) D7; (i) ZIL131; (j) 2S1

4.2 结果与分析

4.2.1 标准的操作条件

标准的操作条件下,训练样本和测试样本的图像数量如表 1 所示,训练样本和测试样本分别是在 17°和 15°的俯仰角下获得。标准的操作条件下,采用所提方法对 10 类目标进行识别,结果如图 8 所示。从图 8 可以看到,对角线元素为不同目标图像的分类精度,即正确识别数目占总数的比例,分类精度均优于 99%,说明所提方法具有有效性。表 2 为所有方法的平均识别率。从表 2 可以看到,所有方法的平均识别率均能够保持在 98%以上。与其他方法相比,所提方法的识别效果优势明显,说明其可以更有效地利用多分辨率表示图像的幅度及相位信息。与 CNN 方法和 CCNN 方法相比,所提方法正是因为综合应用多分辨率表示算法,所以可进一步提升最终的识别性能。与传统的 CNN 相比,所提方法可以取得更高的识别率。实验结果表明,在标准的操作条件下,所提方法在识别性能方面具有优势,并且在分类方面具有有效性。

表 1 标准的操作条件下训练和测试样本的图像数量
Table 1 Number of images for training and test samples under standard operating conditions

| Class | Training set | Test set |
|---------|------------------------|------------------------|
| | (depression angle 17°) | (depression angle 15°) |
| BMP2 | 233 | 195 |
| BTR70 | 233 | 196 |
| T72 | 232 | 196 |
| T62 | 299 | 273 |
| BRDM2 | 298 | 274 |
| BTR60 | 256 | 195 |
| ZSU23/4 | 299 | 274 |
| D7 | 299 | 274 |
| ZIL131 | 299 | 274 |
| 2S1 | 299 | 274 |




图 8 在标准的操作条件下 10 类目标的识别结果

Fig. 8 Identification results of 10 categories of targets under standard operating conditions

表 2 不同方法在标准的操作条件下的平均识别率

Table 2 Average recognition rates of different methods under standard operating conditions

| Method | Average recognition rate/% |
|-----------------|----------------------------|
| Proposed method | 99.42 |
| MR 1 | 98.78 |
| MR 2 | 99.02 |
| CNN | 99.08 |
| CCNN | 99.16 |

4.2.2 型号识别问题

型号识别问题指测试样本的目标型号与训练样本存在较大差异,其是 SAR 图像识别问题中的典型扩展操作条件之一。表 3 为训练样本和测试样本中的图像数量。其中 BMP2 和 T72 两类目标的测试样本的型号与训练样本完全不同(型号在样本数目后的括号内注明)。对各类方法在当前的条件下进行测试,统计其平均识别率,结果如表 4 所示。从表 4 可以看到,对比于标准的操作条件,型号差异会导致各类方法的识别性能降低;CNN 方法的平均识别率下降最为显著,所提方法对型号识别问题可以取得最高的平均识别率,说明其具有更强的稳健性。通过综合应用多分辨率表示算法,所提方法可以更有效地观察目标图像的细节信息,从而获得型号差异条件下的稳健特征。

表 3 型号识别问题的训练和测试样本的图像数量

Table 3 Number of images for training and test samples in model identification problems

| Class | Training set | Test set |
|-------|------------------------|------------------------|
| | (depression angle 17°) | (depression angle 15°) |
| BMP2 | 233 (Sn_9563) | 196 (Sn_9566) |
| | | 196 (Sn_c21) |
| BTR70 | 233 (Sn_c71) | 196 (Sn_c71) |
| T72 | 232 (Sn_132) | 195 (Sn_812) |
| | | 191 (Sn_s7) |

表 4 不同方法在型号识别问题中的平均识别率

Table 4 Average recognition rates of different methods under model recognition problem

| Method | Average recognition rate /% |
|-----------------|-----------------------------|
| Proposed method | 98.92 |
| MR 1 | 97.64 |
| MR 2 | 98.08 |
| CNN | 97.26 |
| CCNN | 98.23 |

4.2.3 俯仰角识别问题

俯仰角识别问题指测试样本的俯仰角和训练样本存在较大差异,其是 SAR 图像识别问题中的代表性扩展操作条件之一。在 17° 俯仰角下对三类 SAR 图像目标进行训练学习,在 30° 和 45° 的俯仰角下对两组测试集进行测试,结果如表 5 所示。表 6 为所有方法的平均识别率。从表 6 可以看到,在 45° 的俯仰角下,各类方法的平均识别率下降十分显著,主要是由大俯仰角差异导致测试样本和训练样本之间的差异显著。对比可见,所提方法在两个角度下的平均识别率均高于其他方法,说明其对俯仰角识别问题具有稳健性。采用所提方法来观察各个分辨率图像的幅度和相位特性,能够更有效地获得俯仰角变化稳健的特征,从而提升最终的识别性能。

表 5 俯仰角识别问题的训练与测试样本的图像数量
Table 5 Number of images for training and test samples in pitch angle recognition problem

| Sample | Depression angle | 2S1 | BDRM2 | ZSU23/4 |
|--------------|------------------|-----|-------|---------|
| Training set | 17° | 299 | 298 | 299 |
| Test set | 30° | 288 | 287 | 288 |
| | 45° | 303 | 303 | 303 |

表 6 不同方法在俯仰角识别问题下的平均识别率
Table 6 Average recognition rates of different methods under pitch angle recognition problem

| Method | Average recognition rate/% | |
|-----------------|----------------------------|------------|
| | 30° | 45° |
| Proposed method | 98.56 | 73.62 |
| MR 1 | 97.54 | 69.56 |
| MR 2 | 97.82 | 71.08 |
| CNN | 97.43 | 67.92 |
| CCNN | 98.02 | 72.02 |

4.2.4 随机噪声识别问题

SAR 图像中存在较为严重的相干斑噪声,尤其在非合作的条件下获得的噪声水平较高。实验按照文献[20]的方法向表 1 的测试样本中添加不同比例的随机噪声,进而测试不同方法在随机噪声干扰的条件下的识别性能。图 9 为各类方法在噪声水平为 5%、10%、15% 和 20% 的平均识别率。从图 9 可以看到,随机噪声对各类方法的识别性能都有着十分显著的影响,而所提方法在各个噪声的水平下均可以取得最高的识别率,说明其对随机噪声的干扰具

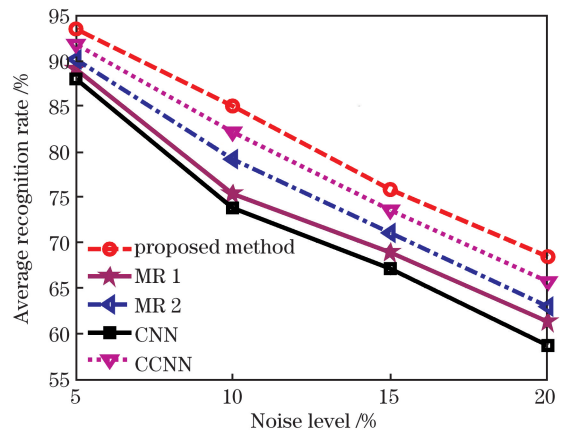


图 9 不同方法在随机噪声识别问题下的对比曲线
Fig. 9 Comparison curves of different methods under random noise identification problem

有稳健性。采用所提方法来观察多分辨率表示图像的幅度和相位信息,可以更有效地获得对噪声稳健的分类特征,从而提高所提方法的识别稳健性。

5 结 论

提出结合多分辨率表示和复数域 CNN 的 SAR 图像目标识别方法。构造多分辨率的 SAR 图像来描述目标层次化的特性,对每个层次的复数图像分别采用复数域 CNN 进行训练和分类,可以获得 SAR 图像的幅度和相位信息。基于线性加权算法对各个分辨率图像的分类结果进行联合分析并判定目标类别。依托 MSTAR 数据集开展标准操作条件、型号识别、俯仰角识别以及随机噪声识别问题的实验。实验结果表明,相比于现有几类方法,所提方法具有更强的有效性和稳健性。

参 考 文 献

- [1] Li L R, Xu X, Dong H, et al. Gaussian mixture model and classification of polarimetric features for SAR images[J]. Acta Optica Sinica, 2019, 39(1): 0128002.
李璐茹, 徐新, 董浩, 等. SAR 影像极化特征的混合高斯模型与分类[J]. 光学学报, 2019, 39(1): 0128002.
- [2] Hu T, Li W H, Qin X X. Semantic segmentation of polarimetric synthetic aperture radar images based on multi-layer deep feature fusion[J]. Chinese Journal of Lasers, 2019, 46(2): 0210001.
胡涛, 李卫华, 秦先祥. 基于多层深度特征融合的极化合成孔径雷达图像语义分割[J]. 中国激光, 2019, 46(2): 0210001.

- [3] Su Q, Yang J Y, Wang Y P. Synthetic aperture radar image change detection based on intuitionistic fuzzy C-core mean clustering algorithm[J]. *Laser & Optoelectronics Progress*, 2019, 56(19): 192805.
宿强, 杨景玉, 王阳萍. 基于直觉模糊C核均值聚类算法的合成孔径雷达图像变化检测[J]. *激光与光电子学进展*, 2019, 56(19): 192805.
- [4] Li Y Y, Wu H, Chang X L, et al. Multi-view stereo positioning error analysis based on spaceborne optics and SAR images[J]. *Acta Optica Sinica*, 2018, 38(5): 0528003.
李莹莹, 吴昊, 常学立, 等. 基于星载光学和SAR影像的多视立体定位误差分析[J]. *光学学报*, 2018, 38(5): 0528003.
- [5] Zhan Y J, Dai T D, Huang J J, et al. Synthetic aperture radar image filtering based on clustering three-dimensional block-matching [J]. *Laser & Optoelectronics Progress*, 2018, 55(4): 041004.
詹云军, 代腾达, 黄解军, 等. 基于聚类三维块匹配的合成孔径雷达影像滤波算法[J]. *激光与光电子学进展*, 2018, 55(4): 041004.
- [6] 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.
- [7] 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.
- [8] 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.
- [9] 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.
- [10] Mishra A K, Motaung T. Application of linear and nonlinear PCA to SAR ATR [C] // 2015 25th International Conference Radioelektronika (RADIOELEKTRONIKA), April 21-22, 2015, Pardubice, Czech Republic. New York: IEEE, 2015: 15236296.
- [11] Cui Z Y, Feng J L, Cao Z J, et al. Target recognition in synthetic aperture radar images via non-negative matrix factorisation [J]. *IET Radar, Sonar & Navigation*, 2015, 9(9): 1376-1385.
- [12] 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.
- [13] 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.
- [14] 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.
- [15] Liu Y. Target recognition of SAR images based on multi-level matching of attributed scattering centers [J]. *Journal of Electronic Measurement and Instrumentation*, 2019, 33(11): 192-198.
刘阳. 基于属性散射中心多层次匹配的SAR目标识别方法[J]. *电子测量与仪器学报*, 2019, 33(11): 192-198.
- [16] 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.
- [17] 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.
- [18] 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.
- [19] Han P, Wang H. Research on the synthetic aperture rader target recognition based on KPCA and sparse representation [J]. *Journal of Signal Processing*, 2013, 29(12): 1696-1701.
韩萍, 王欢. 结合 KPCA 和稀疏表示的 SAR 目标识别方法研究 [J]. *信号处理*, 2013, 29(12): 1696-1701.
- [20] 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.
- [21] 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.
- [22] 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.
- [23] Hua Q L, Huang B, Chen X F, et al. Ship target recognition algorithms based on complex domain CNN [J]. *Command Information System and Technology*, 2019, 10(6): 71-75.
化青龙, 黄斌, 陈雪峰, 等. 基于复数域 CNN 的舰船目标识别算法 [J]. *指挥信息系统与技术*, 2019, 10(6): 71-75.
- [24] Zhang Z M, Wang H P, Xu F, et al. Complex-valued convolutional neural network and its application in polarimetric SAR image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(12): 7177-7188.
- [25] Ding B Y, Wen G J. Target recognition of SAR images based on multi-resolution representation [J]. *Remote Sensing Letters*, 2017, 8(11): 1006-1014.
- [26] Zhang Z Y. Joint classification of multiresolution representations with discrimination analysis for SAR ATR [J]. *Journal of Electronic Imaging*, 2018, 27(4): 043030.
- [27] Cai D R, Zhang T. SAR target recognition based on joint use of multi-resolution representations [J]. *Journal of Electronic Measurement and Instrumentation*, 2018, 32(12): 71-77.
蔡德饶, 张婷. 联合多分辨表示的 SAR 图像目标识别方法 [J]. *电子测量与仪器学报*, 2018, 32(12): 71-77.