

改进残差网络结合迁移学习的 SAR 目标识别

崔亚楠¹, 吴建平^{1,2,3}, 朱辰龙¹, 闫相如¹

(1. 云南大学 信息学院, 云南 昆明 650504;

2. 云南省电子计算中心, 云南 昆明 650223;

3. 云南省高校数字媒体技术重点实验室, 云南 昆明 650223)

摘要:合成孔径雷达(SAR)图像的目标识别对地面和海面目标获取具有重大意义。实现 SAR 图像目标自动解释, 提高图像目标识别的准确率成为 SAR 图像研究的热点问题。为准确获取 SAR 图像中的目标信息, 解决深度神经网络训练小样本 SAR 图像过程中细节特征丢失严重, 网络易出现过拟合等问题, 该研究提出一种基于 RCF(ResNet101-CBAM-FPN)神经网络模型来提取 SAR 图像特征。将 ResNet101 作为主干网络模型用于特征提取, 在主干网络模型中加入卷积注意力模块引导神经网络有针对性地提取 SAR 图像关键特征信息。然后结合特征金字塔网络, 实现神经网络高层特征与底层特征融合, 丰富特征信息。最后融合迁移学习思想, 通过数据相对充足的仿真 SAR 图像对 RCF 网络模型进行预训练。将预训练获取的模型参数迁移至目标网络, 作为目标网络的初始化参数, 并使用目标网络对 SAR 图像进行迭代训练。实验结果表明, 该方法能有效提升小样本数据 SAR 图像的识别精度, 在 MSTAR 数据集上达到 99.60% 的识别率。

关键词: ResNet101; 迁移学习; 合成孔径雷达; 卷积注意力模块; 特征金字塔网络

中图分类号: TP753

文献标识码: A

文章编号: 1673-629X(2022)05-0001-06

doi: 10.3969/j.issn.1673-629X.2022.05.001

SAR Target Recognition of Improved Residual Network Combined with Transfer Learning

CUI Ya-nan¹, WU Jian-ping^{1,2,3}, ZHU Chen-long¹, YAN Xiang-ru¹

(1. School of Information Science & Engineering, Yunnan University, Kunming 650504, China;

2. Yunnan Provincial Electronic Computing Center, Kunming 650223, China;

3. Digital Media Technology Key Laboratory of Universities and Colleges in Yunnan Province,
Kunming 650223, China)

Abstract: The target recognition of synthetic aperture radar (SAR) images is of great significance to the acquisition of military targets on the ground and sea. Realizing the automatic interpretation of SAR image targets and improving the accuracy of image target recognition have become a hot issue in SAR image research. To accurately obtain the target information in the SAR image, and solve the problem of serious loss of detailed features in the process of deep neural network training small sample SAR images, and the network is prone to over-fitting, we propose a neural network model based on RCF (ResNet101-CBAM-FPN) to extract SAR image features. ResNet101 is used as the backbone network model for feature extraction, and the convolutional attention module is added to the backbone network model to guide the neural network to be targeted for extraction of key feature information of SAR images. Then, combined the feature pyramid network, the fusion of high-level features and low-level features of neural network is realized to enrich feature information. Finally, the ideas of transfer learning is fused. The RCF network model is pre-trained by simulating SAR images with relatively sufficient data. The model parameters obtained by pre-training are transferred to the target network as the initialization parameters of the target network, and the target network is used to iteratively train the SAR image. The experiment shows that the proposed method can effectively improve the recognition accuracy of SAR images with small sample data, and achieve a high recognition rate of 99.60% on the MSTAR data set.

Key words: ResNet101; transfer learning; synthetic aperture radar; convolutional block attention module; feature pyramid network

收稿日期: 2021-05-31

修回日期: 2021-10-08

基金项目: 云南省重大科技专项计划项目(202002AD080001); 云南省科技厅应用基础研究计划重点项目(2019FA044)

作者简介: 崔亚楠(1997-), 男, 硕士研究生, 研究方向为图像处理、AI 技术; 通信作者: 吴建平(1965-), 男, 高级工程师, 硕士, 研究方向为多媒体、信息化技术。

0 引言

合成孔径雷达 (synthetic aperture radar, SAR) 是一种与红外光、可见光等传统光学成像系统截然不同的主动微波成像雷达系统。基于多平台协同工作的 SAR 具有全天候, 全天时, 不受环境因素影响等诸多独特优势。目前, 随着 SAR 系统成像技术的发展, 在情报搜集、目标侦察等方面具有重大意义。高效、准确的 SAR 图像目标自动识别成为当前研究热点。

早期对 SAR 图像目标识别分类的研究重心在于特征的提取和分类器的设计。如汪洪桥等人^[1]运用多邻域正交基实现对 SAR 图像的多级滤波采样, 获取 SAR 多级 Gauss 差分图像的空间尺度并应用于 SAR 图像特征的提取。然后运用多尺度核的支持向量机 (SVM) 模型对不同层级的图像特征进行多尺度核函数映射, 最后进行合成, 实现 SAR 图像目标的识别分类; Liu Haicang 等人^[2]提出一种基于稀疏表示融合支持向量机决策的方法。利用 FSR-C 分类器对图像进行分类检测, 并通过检测 SR 系数中非零元素的位置对 SAR 图像目标进行识别分类。利用 SVM-C 提取图像的 PCA 特征。最后融合 FSR-C 和 SVM-C 提取的特征实现 SAR 图像目标的分类; 吴天宝等人^[3]基于 SVM 和稀疏表示分类 (SRC) 级联决策融合的方法, 首先运用 SVM 对图像进行分类, 获取图像的后验概率, 然后通过门限判决方法得到置信度较高的类别图像, 最后利用 SRC 对 SAR 图像进行分类, 并结合 SVM 和 SRC 的决策值实现 SAR 图像目标识别分类。近几年, 深度学习^[4]的出现使得图像识别研究取得突破性的进展。AlexNet^[5]、VGG^[6]、GoogleNet^[7]、ResNet^[8] 等神经网络模型相继出现, 并在 ImageNet 大赛中展露锋芒。因此, 深度学习的方法必然被引入到 SAR 图像目标识别分类的研究中。

在深度学习研究中, 胡显等人^[9]提出一种基于 SAR 图像识别的 CMNet 网络模型。该模型运用较小的卷积核设计四个卷积池化层完成特征提取, 利用 Softmax 损失与中心损失共同监督网络训练, 以此来提高网络模型的泛化能力, 提高 SAR 图像识别的准确率。但面对场景复杂的 SAR 图像, 浅层神经网络学习能力有限, 泛化能力较差, 对 SAR 图像识别率提高有限。该文前期实验将迁移学习与 Inception-Resnet-v2 网络模型相结合, 通过迁移预训练仿真 SAR 图像的网络参数作为目标网络的初始参数, 然后使用 Inception-Resnet-v2 目标网络对 SAR 图像进行训练, 实现目标图像特征的提取。最后, 通过 Softmax 分类器对 SAR 图像进行识别分类。该方法选用网络层次较深的 Inception-Resnet-v2 模型对 SAR 图像进行训练, 以便获取更深层次的图像特征。并利用迁移学习提高模型

泛化能力, 解决小样本问题。该方法相比文献[9], 网络学习能力得到加强, 对 SAR 图像识别率有明显提高。但深层网络训练更加注重图像的语义信息, 训练过程中图像细节特征丢失严重, 对提高 SAR 图像识别的准确率有一定的影响。任硕良等人^[10]将迁移学习与 VGG16 网络模型相结合, 通过迁移 VGG16 网络的预训练模型完成目标图像特征的提取。该文选用 VGG16 深层神经网络, 训练过程中仍然存在图像细节丢失的问题。

针对以上 SAR 图像识别的深度学习方法所存在的问题, 研究并提出一种基于迁移学习改进 ResNet101 下 SAR 图像识别研究方法。其思路是: 采用 ResNet101 卷积神经网络^[8]作为网络总体框架, 并针对小样本 SAR 图像在深层卷积神经网络训练中细节特征丢失严重的问题, 将卷积注意力模块 (CBAM)^[11]、特征金字塔网络 (FPN)^[12]与 ResNet101 神经网络相结合, 构成 RCF (ResNet101-CBAM-FPN) 神经网络模型, 以充分提取 SAR 图像的特征。针对卷积神经网络训练小样本数据集出现过拟合的问题, 利用仿真 SAR 图像数据集对 RCF 神经网络模型进行预训练, 得到相应的网络结构参数。将得到的网络结构参数迁移至目标 RCF 网络模型上, 再对 SAR 图像数据进行训练。该文在前期研究实验的基础上, 将深层神经网络与 FPN 结合, 并在网络中引入 CBAM, 一定程度上增强了网络对图像关键特征的学习, 减少了深度神经网络训练小样本图像细节特征的丢失。实验结果表明, 该算法相较以往研究方法具有更佳的识别效果, 进一步提高了 SAR 识别的应用价值。

1 理论基础

1.1 卷积神经网络

卷积神经网络是深度学习中具有层次模型的监督学习神经网络, 核心结构包含卷积层、池化层以及全连接层。卷积神经网络利用卷积层和池化层, 实现特征提取。与传统机器学习相比, 卷积神经网络在训练过程中可自动提取目标特征。同时, 模型参数量很大程度得到减少, 模型泛化能力得到提高。

卷积核作为卷积层的核心部分, 通过神经元进行矩阵变换计算, 将特征信息传递至下一层, 实现特征提取。通常神经网络模型中会存在多种尺度的卷积核, 多种尺度的卷积核逐一进行特征提取才能充分提取特征信息。其卷积过程如下所示:

$$Y_j^l = f(\sum_{i \in N_j} X_i^{l-1} \times M_{ij}^l + b_j^l) \quad (1)$$

式中, Y_j^l 表示 l 层的 j 个特征图; M 表示卷积核; b 表示偏置项; f 表示激活函数实现特征信息的非线性激活。

当卷积层完成特征提取后,会将提取的特征信息传输到池化层,进一步缩减来自卷积层的特征矩阵,优化对特征信息的提取。同时能有效降低特征维度,减少网络模型的运算量。

全连接层作为卷积神经网络的核心结构,相当于神经网络的“分类器”。全连接层通过对模型学习到的特征信息进行加权求和,并与样本空间中的标签数据进行映射,进而对学习到的特征信息加以区分。

1.2 卷积注意力模块

卷积注意力模块(CBAM)^[11]在2018ECCV会议上被Woo等人提出。CBAM由通道注意力(channel attention)和空间注意力(spatial attention)联合构成,是一种轻量级模块。其中,通道注意力模块注重全局信息,通过分析每条通道之间的相互关系,确定每个特征通道的重要程度,再对每个通道获取的特征信息进行重要程度划分,以获取目标图像的显著特征。

假定 F 为通道注意力输入的特征图,则该模块权重系数 $M_c(F)$ 表达如下:

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) = \sigma(W_1(W_0(F_{\text{avg}}^c)) + W_1(W_0(F_{\text{max}}^c))) \quad (2)$$

其中, $W_0 \in R^{C/r \times C}$, $W_1 \in R^{C \times C/r}$, F_{avg}^c 表示通道注意力的全局平均池化特征, F_{max}^c 表示通道注意力的全局最大池化特征, σ 为激活函数, C/r 为隐层神经元个数, C 为输出神经元个数。

空间注意力模块注重局部信息,通过分析上下文信息的相互关系,确定特征对应空间位置信息的重要程度,以获取目标图像的显著特征。

假定 F 为通道注意力输入的特征图,则该模块权重系数 $M_s(F)$ 表达如下:

$$M_s(F) = \sigma(f^{7 \times 7}([\text{AvgPool}(F); \text{MaxPool}(F)])) = \sigma(f^{7 \times 7}([F_{\text{avg}}^s; F_{\text{max}}^s])) \quad (3)$$

其中, F_{avg}^s 表示空间注意力的全局平均池化特征, F_{max}^s 表示空间注意力的全局最大池化特征, $f^{7 \times 7}$ 表示卷积核大小为 7×7 的卷积层, σ 为激活函数。

CBAM首先将给定的特征图 $F \in R^{C \times H \times W}$ 与通道注意力模块的权重 $M_c(F)$ 相乘得到通道优化的特征图 F' ,再将通道特征图 F' 作为空间注意力的输入与空间注意力模块的权重 $M_s(F)$ 相乘得到优化的空间位置信息特征图。CBMA实现过程可表示为:

$$F' = M_c(F) \otimes F \quad (4)$$

$$F'' = M_s(F') \otimes F' \quad (5)$$

1.3 特征金字塔网络

对于卷积神经网络,浅层网络更注重细节特征,深

层网络更注重语义信息。通过深层语义信息可以更准确检测目标,因此传统网络模型通常利用最后一层卷积特征图实现检测。其缺点是只关注特征图的最后一层,而忽略了其他层所包含的细节特征。特征金字塔网络(FPN)作为一种端到端的网络^[12],能够将含有丰富语义的高层特征传递至底层,实现低分辨率的高层特征与高分辨率的底层特征相融合,使得网络每一层都具有丰富的特征信息。特征金字塔结构以损失少量的运算效率为代价,能够有效提升目标识别的准确率,更有利于小样本实现目标检测。

2 相关工作准备

2.1 SAR 图像去噪

由于SAR成像系统受到相干辐射的影响,导致生成的图像存在较大的相干斑噪声,后期对SAR图像的处理、解释具有严重干扰,一定程度增加了卷积神经网络训练的难度,不利于卷积神经网络性能的最大化利用。因此,该文预先采用增强的Lee滤波算法^[13]对SAR图像进行滤波去噪,尽可能减少噪声对神经网络模型学习过程的影响,确保网络性能达到最佳。

2.2 SAR 图像仿真

仿真SAR图像通过电磁散射模型与场景模型获取SAR图像扫频数据,再结合时频变换与成像算法得到^[14]。利用射线追踪方法获取地面与目标场景的空间几何关系,初步建立3D仿真SAR场景模型。利用粗糙面散射理论等技术实现真实场景粗糙特性的建模。利用射线弹跳法等方法建立地面及目标场景的电磁散射模型,获取SAR图像目标的扫频数据。最后通过时频变换与成像技术得到仿真SAR目标图像。

以往的SAR图像识别研究都采用ImageNet数据集进行迁移训练,但ImageNet数据集中的图像特征与SAR图像特征相似度不高,训练出来的网络参数不太适合作为训练SAR图像网络模型的初始化参数。仿真SAR图像与MSTAR数据集提供的SAR图像相比,特征相似度高,相干斑噪声小,相比ImageNet图像更适合作为预训练样本。仿真SAR图像与真实SAR图像对比如图1所示。

3 SAR 图像目标识别模型

3.1 结合卷积注意力的残差网络模块

卷积注意力模块在通道和空间上对图像重要特征进行筛选,使得引入CBAM的网络模型能够更加准确提取目标的主要特征。该文将CBAM应用到残差网络中,在ResNet101网络的残差节点分别加入四个卷积注意力模块,对各残差模块学习到的图像特征进行分析,通过对特征图分配不同的权重,引导网络在训练

过程中有针对性地提取目标图像上关键的特征信息,从而提高网络模型对 SAR 图像目标的特征表达能力。结合 CBAM 的残差网络模型如图 2 所示。




图 1 SAR 图像与仿真 SAR 图像对比




图 3 RCF 网络总体结构

至底层,实现高层特征与底层特征的融合,最大程度上保留图像的细节特征。最终将融合的特征通过全局平均池化 (AVG pooling) 操作输入到全连接层。同时,在全连接层之前加入 Dropout 层防止过拟合,有利于提升网络模型的泛化能力。

3.3 迁移学习模型

迁移学习是一种利用某一领域现存的知识或在该领域学习到的经验对相关领域存在的问题进行求解的机器学习方法^[15]。传统机器学习需要大量数据训练,得到性能良好的模型,迁移学习能有效解决神经网络对训练样本需求量大的缺陷,对于提升小样本数据图像分类识别的准确率有较大贡献。实现的模型迁移过程如图 4 所示。

4 实验设置与结果分析

4.1 实验数据

选用的 MSTAR 数据集相对完整,并且数据集建模时充分考虑了目标形态变化以及影响目标的不确定

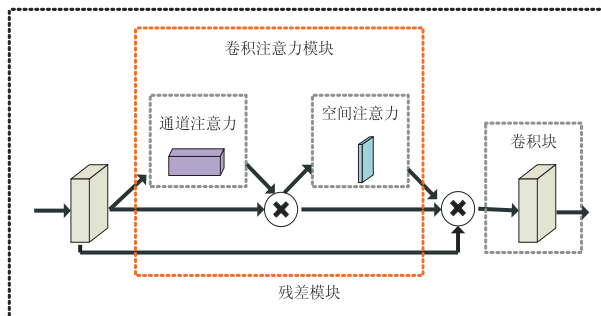


图 2 融合 CBAM 的残差模块

3.2 RCF 神经网络

使用 ResNet101 网络模型作为 RCF 网络的主干部分,网络总体框架如图 3 所示。与 ResNet101 网络不同,RCF 网络模型在主干 ResNet101 网络的中间层加入了四个 CBAM 模块,从而提升网络对图像重要特征的学习能力。结合特征金字塔网络,RCF 网络在每个 CBAM 模块后,将上一层学习到的图像特征经过 1×1 的卷积块提取,通过上采样方法将高层特征传递

因素。该数据集包含两种方向角下十种目标图像,共计 5 172 张 SAR 图像。实验将两个方位角下的同类目标图像打乱,并在每类中随机抽取 80% 作为训练集,剩余的 20% 作为测试集,具体如表 1 所示。

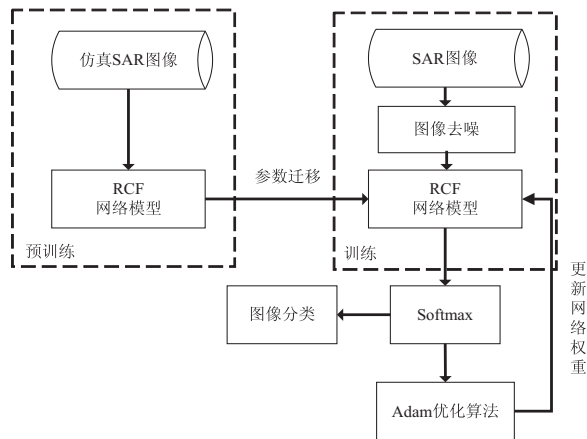


图 4 迁移学习模型

预训练过程使用 SAR 仿真数据集^[16],该仿真数据集包含多个同场景下的七种 SAR 目标图像,共计

21 168幅仿真 SAR 图像。

4.2 实验结果

训练输入大小为 224×224 的图片;dropout 值设置为 0.8;batchsize 值设置为 12;学习率设置为 0.000 1;训练共计迭代 10 340 次。MSTAR 十类目标图像识别

率如表 2 混淆矩阵所示。其中,2S1、BTR70、D7、T72、ZIL131、ZSU23 这六种类别的 SAR 目标图像都取得 100% 的识别率。最终,十类 SAR 目标图像的平均识别率达到 99.60%。

表 1 SAR 实验数据

类别	2S1	BMP2	BRDM2	BTR70	BTR60	D7	T62	T72	ZIL131	ZSU23
17°方向角	299	232	298	233	256	299	299	232	299	299
15°方向角	274	196	274	196	195	274	273	196	196	274
训练数据	458	342	458	343	361	458	458	342	458	458
测试数据	115	86	114	86	90	115	114	86	115	115

表 2 MSTAR 十类目标图像识别结果

类别	2S1	BMP2	BRDM2	BTR70	BTR60	D7	T62	T72	ZIL131	ZSU23	识别率/%
2S1	115	0	0	0	0	0	0	0	0	0	100
BMP2	0	85	1	0	0	0	0	0	0	0	98.84
BRDM2	0	1	113	0	0	0	0	0	0	0	99.12
BTR70	0	0	0	86	0	0	0	0	0	0	100
BTR60	0	0	0	1	89	0	0	0	0	0	98.89
D7	0	0	0	0	0	115	0	0	0	0	100
T62	0	0	0	0	0	0	113	1	0	0	99.12
T72	0	0	0	0	0	0	0	86	0	0	100
ZIL131	0	0	0	0	0	0	0	0	115	0	100
ZSU23	0	0	0	0	0	0	0	0	0	115	100
平均识别率/%											99.60

4.3 对比实验设置与结果分析

为验证该算法的有效性,在原有实验基础上预先设置两组对比实验。

(1)实验一:ResNet101 网络模型迁移实验。

选用 ResNet101 网络替换 RCF 网络模型,并实现文中迁移学习训练。训练集和验证集的获取方式、输入图像的大小、dropout 值、batchsize 大小、学习率与文中实验相同。最终在 MSTAR 数据集上仅实现了 96.43% 的识别率。

该实验验证了构造的 RCF 网络模型能够更有效地提取图像的特征。不仅能够减少图像细节特征的消失,而且能够使模型更加专注于重要特征的学习,提高模型的学习能力。

(2)实验二:ImageNet 数据集预训练 RCF 网络。

选取 ImageNet 数据集对 RCF 网络进行预训练。再利用迁移学习方法,将预训练模型的网络参数作为目标训练网络初始化参数,并完成目标网络对 MSTAR 图像目标的训练。该实验仅替换掉原预训练过程使用的数据集,实验参数与文中实验选取的参数

保持一致。最终在 MSTAR 数据集图像识别上获得 98.81% 的准确率,仍低于文中方法。

该实验证明仿真 SAR 图像与 SAR 图像具有更高的特征相似度,使用仿真 SAR 图像对网络模型进行预训练,在有效抑制网络过拟合的同时很大程度上提升了模型的泛化能力。

SAR 图像识别准确率以及训练误差对比如图 5、图 6 所示。




图 5 SAR 识别准确率对比




图 6 SAR 训练误差对比

为进一步验证文中方法的有效性,将其与其他方法的 SAR 图像识别效果进行对比,结果如表 3 所示。

表 3 不同方法下 SAR 图像识别率对比

来源	方法	识别率/%
对比实验一	ResNet101 网络模型	96.43
对比实验二	ImageNet 数据集预训练	98.81
文献[9]	CMNet 模型	99.30
文献[10]	迁移 VGG16	94.40
文中方法	迁移 RCF 模型	99.60

5 结束语

在不扩充 SAR 训练样本(小样本)的前提下,提出 RCF 神经网络模型。RCF 以 ResNet101 网络作为主干网,并在主干网的中间层加入了四个 CBAM 模块,增强网络模型对 SAR 图像关键特征的学习,从而提升网络模型对 SAR 图像识别的准确率。同时,为了解决网络过深而导致 SAR 图像细节特征严重丢失的问题,引入了 FPN 网络,实现图像高层特征与底层特征融合,丰富图像特征信息,提升分类器对小样本识别分类能力。其中,使用了 RCF 网络模型先对仿真 SAR 图像进行预训练,将预训练得到的网络参数作为 RCF 网络模型的初始化参数训练 SAR 图像,有效解决深度网络训练小样本数据集易导致过拟合的问题。最终在测试集上获得 99.60% 的识别率,验证了该改进方法具有较好的有效性及可行性。

该方法相较于现有深度神经网络方法,有效解决了深层神经网络训练小样本 SAR 图像细节特征丢失严重的技术问题,为 SAR 图像目标的识别研究和进一步应用提供理论和技术参考。

参考文献:

[1] 汪洪桥,孙富春,蔡艳宁,等. 基于局部多分辨特征的 SAR 图像自动目标识别[J]. 清华大学学报:自然科学版,2011,51(8):1049-1054.

[2] LIU Haicang, LI Shutao. Decision fusion of sparse representation and support vector machine for SAR image target recognition[J]. Neurocomputing, 2013, 113:97-104.

[3] 吴天宝,夏靖波,黄玉燕. 基于 SVM 和 SRC 级联决策融合的 SAR 图像目标识别方法[J]. 河南理工大学学报:自然科学版,2020,39(4):118-124.

[4] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7):1527-1554.

[5] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks[C]//Proceedings of the 25th international conference on neural information processing systems. Lake Tahoe, Nevada: Curran Associates Inc, 2012:1097-1105.

[6] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv:1409.1556, 2014.

[7] SZEGEDY C, LIU Wei, JIA Yangqing, et al. Going deeper with convolutions[C]//2015 IEEE conference on computer vision and pattern recognition (CVPR). Boston, MA: IEEE, 2015:1-9.

[8] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//IEEE conference on computer vision & pattern recognition. Las Vegas, NV: IEEE, 2016:770-778.

[9] 胡显,姚群力,侯冰倩,等. 基于卷积神经网络的合成孔径雷达图像目标识别[J]. 科学技术与工程, 2019, 19(21):228-232.

[10] 任硕良,索继东,佟禹. 卷积神经网络结合迁移学习的 SAR 目标识别[J]. 电光与控制, 2020, 27(10):37-41.

[11] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]//Proceedings of the European conference on computer vision (ECCV). Munich, Germany: Springer International Publishing, 2018:3-19.

[12] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//Proceedings of the 2017 IEEE conference on computer vision and pattern recognition. Piscataway: IEEE, 2016:770-778.

[13] 李文辉. 基于深度学习的 SAR 图像目标识别[D]. 成都:电子科技大学, 2018.

[14] 董纯柱,胡利平,朱国庆,等. 地面车辆目标高质量 SAR 图像快速仿真方法[J]. 雷达学报, 2015, 4(3):351-360.

[15] PAN S J, YANG Qiang. A survey on transfer learning[J]. IEEE Transactions on Knowledge & Data Engineering, 2010, 22(10):1345-1359.

[16] ANDERS K, ADILI A, JØRGENSEN D. Synthetic SAR image generation using sensor, terrain and target models[C]//Eusar: European conference on synthetic aperture radar. Hamburg, Germany: VDE Press, 2016:405-409.