DOI:10.20079/j.issn.1001-893x.220427007

引用格式:李汪华,张贞凯. 一种基于集成卷积神经网络的 SAR 图像目标识别算法[J]. 电讯技术, 2023, 63(12): 1918-1924. [LI W H, ZHANG Z K. A SAR image target recognition algorithm based on ensemble convolutional neural network[J]. Telecommunication Engineering, 2023, 63(12): 1918-1924.]

一种基于集成卷积神经网络的 SAR 图像目标识别算法*

李汪华,张贞凯

(江苏科技大学海洋学院,江苏镇江 212100)

摘 要:针对合成孔径雷达(Synthetic Aperture Radar, SAR)图像目标识别问题,提出了一种基于集成 卷积神经网络(Convolutional Neural Network, CNN)的 SAR 图像目标识别方法。首先对原始数据集 进行数据增强的预处理操作,以扩充训练样本;接着通过重采样的方法从训练样本中获取不同的训 练子集,并在训练各基分类器时引入 Dropout 和 Padding 操作,有效增强了网络泛化能力;然后采用 Adadelta 算法与 Nesterov 动量法结合的思想来优化网络,提高了网络的收敛速度和识别精度;最后 采用相对多数投票法对基分类器的分类结果进行集成。在 MSTAR 数据集上进行的实验结果表明, 集成后的模型识别准确率达到 99.30%,识别性能优于单个卷积神经网络,具有较强的泛化能力和 较好的稳健性。

关键词:雷达目标识别;合成孔径雷达(SAR);卷积神经网络(CNN);Ada_Nesterov 动量法;网络集成

开放科学(资源服务)标识码(OSID):



中图分类号:TN957.52 文献标志码:A 文章编号:1001-893X(2023)12-1918-07

A SAR Image Target Recognition Algorithm Based on Ensemble Convolutional Neural Network

LI Wanghua, ZHANG Zhenkai

(Ocean College, Jiangsu University of Science and Technology, Zhenjiang 212100, China)

Abstract: For the problem of target recognition in synthetic aperture radar(SAR) image target recognition, a method of SAR image target recognition based on the ensemble convolutional neural network (CNN) is proposed. Firstly, the data-enhanced preprocessing operation of the original data set is performed to expand the training samples. Secondly, different training subsets are obtained from the training samples by resampling, and Dropout and Padding operations are introduced when training each base classifier, which effectively enhances the network generalization ability. Then the idea of combining the Adadelta algorithm and the Nesterov momentum algorithm is used to optimize the network, which improves the convergence speed and recognition accuracy of the network. Finally, the relative majority voting method is used to combine the classification results of base classifier. Experiment results on the MSTAR dataset show that the recognition accuracy of the ensemble model reaches 99. 30%, and the recognition performance is better than that of a single CNN, with strong generalization ability and good robustness.

Key words: radar target recognition; synthetic aperture radar(SAR); convolutional neural network(CNN); Ada_Nesterov momentum algorithm; network ensemble

^{*} 收稿日期:2022-04-27;修回日期:2022-06-07 基金项目:国家自然科学基金资助项目(61871203) 通信作者:张贞凯

0 引 言

合成孔径雷达(Synthetic Aperture Radar, SAR)^[1]是一种主动式微波传感器,因其具有全天 时、全天候、高分辨成像等特点,已被广泛应用在现 代军事和国防安全等众多领域中。自动目标识别 (Automatic Target Recognition, ATR)^[2]技术致力于 从传感器信号中提取信息和实现目标类别鉴定,也 是实现 SAR 图像解译的重要组成部分。在早期的 SAR ATR 研究中,常用的是基于模板的方法和基于 模型的方法^[3]。但由于分类准确率十分依赖于构 建的特征库或模型库,所以此类方法鲁棒性不强,泛 化能力差。

近年来,随着人工智能技术的快速发展,将深度 学习应用到 SAR ATR 领域,已经成为了 SAR 图像 目标识别技术研究的热点。由于卷积神经网络 (Convolutional Neural Network, CNN)具有独特的特 征提取方式,因而具有了强大的模式捕获能力,在 SAR 图像目标识别任务中已经取得了一定的成功。 文献[4]提出了将 CNN 和卷积自编码器相结合的 识别方法,大幅降低了算法的时间复杂度且没有降 低识别精度。文献[5]提出了将 CNN 和支持向量 机(Support Vector Machine, SVM)结合的 SAR 图像 目标识别方法,具有较准确的识别率和较好的鲁 棒性。

然而,现有的基于 CNN 的目标识别方法在网络 结构优化设计上还存在一些不足,例如:文献[6]提 出了一种基于多特征聚合的 CNN 网络架构,虽然能 够在数据量较少时获得较好的识别精度,但是特征 提取步骤繁琐,耗时长;文献[7]为了减少自由参 量,使用稀疏连接层代替全连接层设计了一款全 CNN 算法,既减少了训练数据的规模,又提高了识 别精度,但该网络结构的噪声鲁棒性较差,泛化能力 较弱;文献[8]采用并联的卷积神经网络以不同的 尺度同步提取图像特征,能从多方面刻画目标并提 高分类精度,但由于数据量较少,易出现过拟合 现象。

为了弥补网络结构优化过程中存在的一些不 足,并进一步提高 SAR 图像目标识别的识别准确率 和收敛速度,本文提出了一种将改进的卷积神经网 络进行集成的 SAR 图像目标识别方法。为解决 SAR 图像样本不足的问题,对 SAR 图像进行了数据 增强的操作。为解决模型泛化能力不足的问题,在 改进的 CNN 中引入了 Dropout^[9]和 Padding 操作。 为减少各 CNN 网络带来的偏差,提高分类器的泛化 能力,通过利用 Bagging 方法对各改进 CNN 的初步 的分类结果进行集成决策。为提高网络的训练速度 与收敛精度,采用 Ada_Nesterov 动量法对网络进行 优化。实验结果验证了本文所提算法的有效性。

1 SAR 图像特征提取

1.1 SAR 图像预处理

与光学图像相比,SAR 图像存在明显的相干斑 噪声,因此需要进行适当处理以降低其对识别性能 的影响。

本文在 TensorFlow 平台上对数据集进行预处 理。首先采用图像旋转、缩放等几种途径进行数据 增强^[10],获得了更多的训练样本;然后通过对增强 的图像进行裁剪得到了输入大小为 128×128 的目 标切片图像,除以 255.0,使图像灰度等级位于[0, 1]之间。这些操作不仅减弱了相干噪声的影响,而 且提高了模型的泛化能力。此外,为了提高网络训 练效率,对输入数据进行批处理,批大小设置为 32。

1.2 集成学习

集成学习算法是目前比较流行的机器学习算法 之一,一般是先通过某种集成学习算法产生若干个 基分类器,再通过某种集成策略对其结合以完成分 类识别,能够实现优势互补^[11]。

本文采用的集成学习方法是 Bagging 算法^[12], 它的思想是从训练集中进行有放回重采样来获得每 个基分类器所需要的子训练集,对所有基分类器预 测的结果基于某种结合策略产生最终的预测结果。 本文采用的集成策略是相对多数投票法^[13],它是分 类问题中最常用的一种结合策略。个体分类器的输 出类型包含类标签和类概率两种,以类标签为基础 的投票被称作"硬投票",以类概率为基础的投票被 称作"软投票"。一般情况下,以类概率为基础的集 成结合效果更优。Bagging 算法原理图如图 1 所示。



1.3 CNN 基本原理

CNN^[14] 是一种特殊的多层前馈神经网络,具有强大的特征学习与特征表达能力,主要包括输入层、卷积层、激活层、池化层、全连接层和输出层。

卷积层主要用来提取图像特征。激活层是把卷 积层的结果做非线性映射,使得神经网络可以逼近 任何非线性函数,赋予了网络非线性的性质,从而可 避免线性模型表达不够的问题。常用的激活函数有 Sigmoid 函数、Tanh 函数、ReLu 函数等,其中 ReLu 函数可以避免梯度消失的问题且能有效缓解过拟合 问题,因此被广泛应用。池化层主要是对卷积层输 出的特征图进行特征选择和信息过滤。通过卷积、 非线性和池化等操作,CNN 可以从低级特征中分层 挖掘出高级特征,从而获得更好的分类识别学习能 力。最终通过若干个全连接层完成分类识别任务。

CNN 的前向传播是把上一层的输出用作当前 层的输入,它的主要作用是对输入图像进行逐层特 征提取,如式(1)和式(2)所示:

$$\boldsymbol{z}_{j}^{l} = \sum_{i} \boldsymbol{w}_{ij}^{l} * \boldsymbol{a}_{i}^{l-1} + \boldsymbol{b}_{j}^{l}, \qquad (1)$$

$$\boldsymbol{a}_{j}^{l} = f(\boldsymbol{z}_{j}^{l})_{\circ} \tag{2}$$

式(1)中: z_i^l 表示第l层中第j个特征图的输入加权 和; $w_{ij}^l \in \mathbb{R}^2$ 表示第l-1层的第i个特征图与第l层 第j个特征图的卷积核; * 表示卷积运算符号; b_j^l 表 示第l层的第j个特征图的偏置项。式(2)中: $a_j^l \in \mathbb{R}^2$ 表示第l层的第j个特征图; $f(\cdot)$ 表示激活 函数。

本文激活函数选用 ReLu 函数,如式(3) 所示:

ReLu=max($0, z_j^l(x, y)$)。 (3) 池化操作选用最大池化,如式(4)所示:

 $\boldsymbol{a}_{j}^{l}(x,y) = \max_{0 \le u < p_{1}, 0 \le v < p_{2}} \boldsymbol{a}_{j}^{l}(x+u,y+v) \quad (4)$

式中: p1 和 p2 是池化窗口的大小。

Dropout 的思想是在网络训练时按照一定概率 随机失活部分神经元,它可以有效减少相邻神经元 之间的依赖性。采用 Dropout 后的网络计算公式如 (5)~(8) 所示:

$$\mathbf{r}_{j}^{l-1} \sim \operatorname{Bernoulli}(p)$$
, (5)

$$\tilde{a}_{j}^{l} = r^{l-1} * a_{j}^{l-1},$$
 (6)

$$\sum_{i=1}^{l} \sum_{j=1}^{P_{l-1}} \boldsymbol{w}_{ij}^{l} * \tilde{\boldsymbol{a}}_{i}^{l} + \boldsymbol{b}_{i}^{l}, \qquad (7)$$

$$\boldsymbol{a}^{l} = f(\boldsymbol{z}^{l}) \tag{8}$$

式中:Bernoulli 函数作用是生成 r 向量,即随机生成 $-\gamma[0,1]$ 向量;p 为 Dropout 概率。

2 基于集成 CNN 的 SAR 图像目标识别算法

本文提出的基于集成 CNN 的 SAR 图像目标识 别算法的流程框图如图 2 所示。首先对输入的原始 SAR 图像数据进行数据增强以达到扩充训练数据 集的目的,然后通过有放回的重采样操作从训练集 中获得能够输入到各基分类器中的子数据集,接着 根据 Bagging 方法将 4 个结构不同的卷积神经网络 集成,最后基于相对多数投票法进行投票表决,得到 目标识别结果。



图 2 基于投票法的集成网络模型流程框图

2.1 基于改进 CNN 的基分类器构建

本文设计了 4 个 10 层的 CNN 架构并分别对其 改进,引入 Dropout 和 Padding 操作,同时采用 Ada_ Nesterov 动量法作为最小化损失函数的优化算法, 以此组成一个 Multi-CNN。将构建的 4 个改进 CNN 分别命名为 CNN1、CNN2、CNN3、CNN4,其中 CNN1 模型设计如表 1 所示。

层数	类型	核尺寸	步长	输出特征大小	激活函数	Dropout	Padding
1	输入层			128×128×1			
2	卷积层	8×8	2	64×64×128	Relu		same
3	池化层	2×2	2	32×32×128			
4	卷积层	5×5	1	32×32×64	Relu		same
5	池化层	3×3	1	30×30×64			
6	卷积层	3×3	1	30×30×64	Relu		same
7	卷积层	3×3	1	30×30×64	Relu		same
8	卷积层	3×3	1	30×30×32	Relu		same
9	池化层	2×2	2	15×15×32			
10	全连接层			1×512		0.5	
11	全连接层			1×256		0.5	
12	输出层			1×10	Softmax		

表 1 基分类器 CNN1 网络结构

在 CNN1 的基础上,通过改变卷积核的尺寸和数目,构建了 CNN2、CNN3 和 CNN4 网络模型。 CNN2 是将 CNN1 中第6 层中卷积核尺寸改为 5×5, 其他参数不变。CNN3 是将 CNN1 中第4,6,7 层中 卷积核数目分别改为 96,96,48,其他参数不变。 CNN4 是将 CNN1 中第4,6,7 层卷积核数目分别改 为 96,64,64,其他参数不变。

2.2 基于 Ada_Nesterov 动量法的基分类器训练

网络训练的目标是得到最小化损失函数,因此 在神经网络的训练过程中,需要使用优化算法来最 小化损失函数。本文采用的损失函数为交叉熵损失 函数,如式(9)所示:

$$\boldsymbol{L}(\boldsymbol{w},\boldsymbol{b}) = -\sum_{i=1}^{N} y_{i} \ln P(y_{i} | \boldsymbol{z}^{L}; \boldsymbol{w}, \boldsymbol{b}) \quad (9)$$

式中: z^{L} 是 Softmax 层的输入,由上一个全连接层计 算得到;N为类别数。

Adadelta 算法具有自适应学习率的功能,它是 对 AgaGrad 算法的一种改进,主要解决了 AgaGrad 算法在训练后期学习率很小和参数更新时参数不一 致的问题^[15]。Nesterov 动量法^[16]虽然能很好地改 进梯度下降方向,但是其所有参数都具有一样的学 习率,并且需要人为设定。因此,本文在计算 Nesterov 动量法的梯度下降时引入 Adadelta 算法的 自适应学习率策略,使其同时具有自适应学习率和 梯度下降方向准确的能力。本文从两个方面改进参 数更新方式,有效避免了陷入局部最优解的问题,提 高了网络收敛精度。该算法的更新规则如下:

Require:常数 ϵ ,动量因子 ρ ,衰减系数 α

Require:初始化变量 θ ,初始化参数 $E[\Delta \theta^2]_0 = 0$

For t=1:T,循环:

训练样本中采用得到的 m 个小批次样本 $\{x^{(1)} \cdots x^{(m)}\}$, 对应目标为 $y^{(i)}$

计算指数衰减均值: $E[\Delta\theta^2]_t = \rho E[\Delta\theta^2]_{t-1} + (1-\rho)\Delta\theta_t^2$ 求均方根:RMS[$\Delta\theta$]_t = $\sqrt{E[\Delta\theta^2]_t + \epsilon}$ 计算学习率: $\eta = RMS[\Delta\theta]_{t-1}$ 计算 θ 更 新: $\Delta\theta = \rho [\Delta\theta]_{t-1} - RMS [\Delta\theta]_{t-1} \nabla_{\theta}$ $\left(\frac{1}{m}\sum_{i=1}^m L(f(x^{(i)};\theta), y^{(i)})\right)$, 在 Nesterov 动 量 法 中 引 入 Adadelta 算法的学习率

应用更新:θ←θ+Δθ End For

2.3 基于相对多数投票法的基分类器集成

为了得到最终的目标分类结果,在各基分类器 训练完成后,需要对所有分类器预测结果进行相对 多数投票。

设训练样本集为 D,经过重采样操作后得到的

子训练集为 D_i ,训练得到的基分类器为 h_i ,其中t= 1,2,…, T_o 样本x的实际输出为 $h_i(x)$,类别集合 为 $\{c_1, c_2, ..., c_N\}$,类别 c_j 的实际输出为 $h_i^j(x)$ 。相 对多数投票法如式(10)所示:

$$H(x) = c_{\operatorname{argmax} \sum_{j,i=1}^{T} h_{i}^{j}(x)} \circ$$
(10)
式中:T 为基分类器个数。

3 实验结果与分析

3.1 实验设置

为了验证本文所提出方法的有效性,采用了由 美国 DAPRA 发布的 MSTAR 公开数据集^[17]进行性 能评估与验证。该数据集包括 BMP2、2S1、BTR70、 BTR60、BRDM2、T72、T62、ZIL131、D7、ZSU23/4 等 10 类地面军事目标。在本文中,选用标准操作条件 (Standard Operation Condition, SOC)下 SAR 图像进 行训练和测试,将17°俯仰角下的图像作为训练样 本,15°俯仰角下的图像作为测试样本。SOC 下训练 与测试目标的类别和数目如表 2 所示。在 SOC 条 件下对 10 类地面军事目标进行分类识别,分类评价 指标^[18]选择总体分类精度(Overall Accuracy, OA) 和平均分类精度(Average Accuracy, AA), 网络的稳 健性选用平均分类精度标准差(Standard Deviation, STD)作为评价指标。所有实验均在配置为 Intel(R) Core (TM) i5 - 6500CPU @ 3.20 GHz, 4.0 GB RAM, NVIDIA GeForce GTX1060 GPU 的计算机上完成。

表 2 SOC 下训练与测试目标类别与数目

目标类型	目标名称	训练样本 (17°俯仰角)	测试样本 (15°俯仰角)
BMP2	步兵战车	233	195
BRDM2	装甲侦察车	298	274
BTR70	装甲运输车	233	196
BTR60	装甲运兵车	256	195
T72	主战坦克	232	196
281	自行榴弹炮	299	274
D7	推土机	299	274
T62	大型坦克	299	273
ZIL131	普通卡车	299	274
ZSU23/4	自行高射炮	299	274

3.2 实验结果

3.2.1 实验 1: Padding 操作对各基分类器网络性 能的影响

为了验证在各基分类器中引入 Padding 操作对

各基分类器网络性能的影响,做了对照实验,结果如 表3所示。

表 3 是否使用 Padding 操作对各基分类器网络性能的影响

基分类器	有无 Padding 操作	AA/%	OA/%
CNN1	有	98.93	98.70
CININI	无	98.47	98.12
CNNO	有	98.68	98.35
CNN2	无	98.05	97.89
CNN2	有	98.87	98.75
CNN3	无	98.36	98.14
CNN4	有	98.85	98.57
UNN4	无	98.37	98.05

由表 3 可以看出,在各基分类器中引入 Padding 操作后,各基分类器的平均分类精度与总体分类精 度都有 0.5% 左右的提高。这是因为引入 Padding 操作后减少了边缘信息的丢失,进而提取到了更多 的图像特征,有效抑制了过拟合。出于综合考量,在 设计本文集成网络时,各基分类器中均使用 Padding 操作。

3.2.2 实验 2: Dropout 操作对网络性能的影响

为了验证 Dropout 操作对网络性能的影响,在 各基分类器都引入 Padding 操作的情况下,分别在 Dropout 概率为0,0.3,0.5和0.7时进行实验,结果 如表4和表5所示。

表 4 不同 Dropout 概率对各基分类器 AA 的影响

Dropout	AA/%			
概率	CNN1	CNN2	CNN3	CNN4
0.0	98.93	98.68	98.87	98.85
0.3	99.02	98.75	98.90	99.01
0.5	99.13	99.03	99.07	99.05
0.7	97.04	96.98	97.53	97.41

私了 不同 Diopout 晚午对百座万天宙 UA 的影响	表 5	不同 Dropout	概率对各基分类器	OA 的影响
-------------------------------	-----	------------	----------	--------

Dropout	OA/%					
概率	CNN1	CNN2	CNN3	CNN4		
0.0	98.70	98.35	98.75	98.57		
0.3	98.92	98.45	98.80	98.73		
0.5	99.03	98.83	98.94	98.90		
0.7	96.85	96.32	97.27	96.54		

由表4和表5可以看出,随着 Dropout 概率的增加,各基分类器的平均分类精度与总体分类精度均 是先增加后减小,这也意味着并不是 Dropout 概率 越大越好。当Dropout 概率为0.5时,各基分类器的 识别率最高且效果最好。这是因为当Dropout 概率 为0.5时,Dropout 随机生成的网络结构最多。故本 文在设计集成网络时,各基分类器中Dropout 概率

3.2.3 实验3:基分类器的有效性验证

均设置为 0.5。

为了验证所构建的基分类器的有效性,本文使 用每种基分类器重复进行 5 次实验,分别得到了各 基分类器在 SOC 下的分类识别性能,如表 6 所示。

表 6	各种基分类器在 SOC 下的识别性能			
基分类器	AA/%	OA/%	STD	
CNN1	99.13	99.03	0.63	
CNN2	99.03	98.83	0.65	
CNN3	99.07	98.94	0.57	
CNN4	99.05	98.90	0.61	

由表 6 可以看出,不同的基分类器均有较好的 识别效果,并且分类器之间的分类识别性能相差不 大。而且,经过反复试验发现,通过对超参数的调 整,很难在准确率上再有明显提升。但是,各基分类 器的平均分类精度标准差均在 0.60 左右,这意味着 单个网络的稳健性不足,即存在偏向性。

实验过程当中各基分类器的训练及测试损失曲 线图如图 3~6 所示。







由图 3~6 可以看出,网络在训练前期损失均有 快速下降,大概在 epoch 为 20 次时开始收敛,且在 训练后期损失值波动较小,网络收敛效果较好。

3.2.4 实验4:相对多数投票集成实验

用训练好的基分类器对测试样本进行预测,然 后分别以"硬投票"和"软投票"方式对已经训练好 的基分类器进行相对多数投票集成,每种投票方式 进行5次实验,集成结果如表7所示。

投票方式	AA/%	STD	OA/%
硬投票	99.21	0.34	99.05
软投票	99.30	0.27	99.15

± 7	12 1 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
天 /	和对多数投票集放主运运车
101	山川少奴以示未成大型山小

由表 7 可以看出,利用相对多数投票法将各基 分类器分类结果集成以后的分类精度会有一定的提 升。与各个基分类器相比,"硬投票"方式的平均分 类精度与总体分类精度均可以提高大约 0.15%, "软投票"方式的平均分类精度与总体分类精度均 可以提高大约 0.23%。从表 7 实验结果可以看出, 集成后的平均分类精度的标准差比各个基分类器的 均小。由此可见,集成网络的分类识别性能优于单 个卷积神经网络识别性能,并且集成后的网络降低 了各基分类器的标准差。

3.2.5 实验 5:SOC 下的识别性能比较

在 MSTAR 的 SOC 下采集的 10 类目标上,与现 有的其他 SAR 图像目标识别方法进行对比,每种方 法重复进行 5 次实验。文献[19]、文献[6]及文献 [8]中的方法分别记为迁移 VGG16、MFCNNs、并联 CNN,不同方法的对比结果如表 8 所示。

表 8 几种方法在 SOC 下的识别性能比较

实验方法	AA/%	STD	训练时间 (包括特征提取)
迁移 VGG ^[19]	94.40	0.58	几小时
MFCNNs ^[6]	95.52	0.56	几小时至几天
并联 CNN ^[8]	99.10	0.47	几小时
集成网络	99.30	0.27	1 h 左右

由表 8 可以看出,本文所提方法的平均分类精 度最高,相比迁移 VGG16、MFCNNs 和并联 CNN 的 平均分类精度分别提高了 4.9%, 3.78% 和 0.2%。 虽然本文方法对于并联 CNN 方法平均分类精度提 高不明显,但是本文算法的训练时间更短。另外,从 表 8 的实验结果可以看出,相较于几种对比方法,本 文所提方法平均分类精度的标准差最小。由此可 见,本文提出的集成卷积神经网络可以获得稳健且 最优的分类识别性能。

4 结 论

本文采用集成卷积神经网络作为 SAR 图像目标识别的网络架构,通过将各个基分类器的识别结果进行集成决策,可以明显地提高整个网络的识别能力和稳健能力。为了优化所提出的网络,引入了Dropout和 Padding 操作,并采用 Ada_Nesterov 动量法作为优化算法,有效抑制了网络的过拟合,提高了网络收敛精度。在 MSTAR 数据集 SOC 下的 10 类目标的实验结果表明,所提方法的平均分类精度达到了 99.30%,标准差仅有 0.27,有效抑制了过拟合,网络性能较好。

参考文献:

- [1] MOREIRA A, PRATS-IRAOLA P, YOUNIS M, et al. A tutorial on synthetic aperture radar[J]. IEEE Geoscience and Remote Sensing Magazine, 2013, 1(1):6-43.
- [2] 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.

- [3] 冯博迪,杨海涛,李高源,等. 神经网络在 SAR 图像目标识别中的研究综述[J]. 兵器装备工程学报,2021, 42(10):15-22.
- [4] HOUSSEINI A, TOUMI A, KHENCHAF A. Deep learning for target recognition from SAR images [C]//Proceedings of 2017 Seminar on Detection Systems Architectures and Technologies. Algiers: IEEE, 2017:1–5.
- [5] 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.
- [6] CHO J H, CHAN G P. Multiple feature aggregation using convolutional neural networks for SAR image-based automatic target recognition [J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(12):1882-1886.
- [7] 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.
- [8] 李清,魏雪云.基于并联卷积神经网络的 SAR 图像目标识别[J].电波科学学报,2020,35(3):364-371.
- [9] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: a simple way to prevent neural networks from overfitting [J]. The Journal of Machine Learning Research, 2014, 15(1):1929-1958.
- [10] 许强,李伟,Pierre Loumbi. 深度卷积神经网络在 SAR 自动目标识别领域的应用综述[J]. 电讯技术,2018, 58(1):106-112.
- [11] 周志华,陈世福.神经网络集成[J]. 计算机学报,

2002,25(1):1-8.

- [12] 孙艺聪,田润澜,刘冲,等.基于 Bagging-CNN 雷达信号分类方法[J]. 兵器装备工程学报,2021,42(5):191-195.
- [13] 樊利恒,吕俊伟,邓江生.基于分类器集成的高光谱 遥感图像分类方法[J].光学学报,2014(9):91-101.
- [14] 田壮壮,占荣辉,胡杰民,等. 基于卷积神经网络的 SAR 图像目标识别研究[J]. 雷达学报,2016,5(3): 320-325.
- [15] 贾熹滨,史佳帅. Ada_Nesterov 动量法[J]. 计算机科 学与应用,2019,9(2):351-358.
- [16] SUTSKEVER I, MARTENS J, DAHL G, et al. On the importance of initialization and momentum in deep learning [C]//Proceedings of 2013 International Conference on Machine Learning. Atlanta: IEEE, 2013: 1139-1147.
- [17] 贺丰收,何友,刘准钆,等.卷积神经网络在雷达自动 目标识别中的研究进展[J].电子与信息学报,2020, 42(1):119-131.
- [18] 谷雨,徐英.基于随机卷积特征和集成超限学习机的快速 SAR 目标识别[J].光电工程,2018,45(1):1-10.
- [19] 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.

作者简介:

李汪华 男,1997 年生于安徽安庆,2021 年获学士学位,现为硕士研究生,主要研究方向为雷达信号与信息处理。

张贞凯 男,1982年生于江苏徐州,2013年获博士学

位,现为教授,主要研究方向为雷达信号处理、深度学习等。