DOI:10.3969/j.issn.1672-2337.2024.05.003

基于自适应阈值卷积网络的抗干扰雷达目标识别

王佳豪',陈澍元',赵书敏²,蒋忠进¹

(1. 东南大学毫米波全国重点实验室, 江苏南京 210096;

2. 中国空空导弹研究院空基信息感知与融合全国重点实验室, 河南洛阳 471009)

摘 要:本文提出了一种自适应阈值卷积网络(ATCN),基于HRRP数据进行抗干扰雷达目标识别。ATCN 中的核心模块是自适应阈值卷积单元(ATCU),该模块能准确高效地完成对HRRP数据的特征提取。在ATCU 中,采用自适应阈值函数充当激活函数,自动调整阈值以面对不同信干比的数据;利用多个不同尺度的卷积核来 捕获HRRP数据中的区域差异特征;引入通道注意力机制和残差连接优化网络结构。本文进行了大量的抗干扰 目标识别实验,实验结果表明,相比于所选择的3种对比网络,本文的ATCN 网络能在不同干扰类型和不同信干 比下提供更优的平均识别率和更好的指标稳定性,且具有更少的网络模型参数量和浮点运算次数,具备轻量化 和高效的特点。

关键词: 雷达自动目标识别; 高分辨距离像; 压制性干扰; 自适应阈值卷积单元

中图分类号:TN957.51 文献标志码:A 文章编号:1672-2337(2024)05-0487-08

引用格式:王佳豪,陈澍元,赵书敏,等.基于自适应阈值卷积网络的抗干扰雷达目标识别[J].雷达科学与技术,2024,22(5):487-494.

WANG Jiahao, CHEN Shuyuan, ZHAO Shumin, et al. Target Recognition for Anti - Interference Radar Based on Adaptive Threshold Convolution Network[J]. Radar Science and Technology, 2024, 22(5):487-494.

Target Recognition for Anti-Interference Radar Based on Adaptive Threshold Convolution Network

WANG Jiahao¹, CHEN Shuyuan¹, ZHAO Shumin², JIANG Zhongjin¹

(1. State Key Laboratory of Millimeter Waves, Southeast University, Nanjing 210096, China;

2. National Key Laboratory of Air-based Information Perception and Fusion, China Airborne Missile Academy, Luoyang 471009, China)

Abstract: This paper proposes an adaptive threshold convolutional network (ATCN) for anti-interference radar target recognition based on HRRP data. The core module in ATCN is the adaptive threshold convolutional unit (ATCU), which enables the accurate and efficient feature extraction from HRRP data. In ATCU, an adaptive threshold function is employed as the activation function to automatically adjust the threshold for different signal-to-interference ratios. Multiple convolutional kernels of different scales are used to capture regional difference features in HRRP data. The channel attention mechanism and residual connection are introduced to optimize the network structure. Extensive experiments on anti-interference target recognition are conducted in this study. The experimental results demonstrate that compared with the three selected comparison networks, the proposed ATCN provides better average recognition rate and better index stability under different interference types and signal-to-interference ratios. Furthermore, the ATCN network has fewer model parameters and floating-point operations, demonstrating its lightweight and efficient characteristics.

Key words: radar automatic target recognition (RATR); high resolution range profile (HRRP); suppression interference; adaptive threshold convolution unit (ATCU)

0 引 言

雷达高分辨距离像(High Resolution Range Pro-

file, HRRP)是目标散射点的子回波沿雷达视线方向上的叠加,它包含着目标的大量结构信息。相比于二维雷达图像, HRRP具有获取、存储和计算

收稿日期: 2024-03-12; 修回日期: 2024-04-11

基金项目:国家自然科学基金资助项目(No.61890544, 91748106)

的便利性^[1]。随着机器学习的发展,越来越多的 研究人员在雷达自动目标识别(Radar Automatic Target Recognition, RATR)领域中采用深度学习算 法,并取得了一定的成果。然而,在实际应用中, 雷达探测往往处于复杂的电磁环境中,且目标通 常是非合作的,目标回波会受到各种干扰信号的 影响,这给RATR带来了巨大的挑战^[2]。

近年来,在目标识别领域使用的深度学习网 络模型多采用复合结构,将多种网络结构相结合。 例如,文献[3]将自编码器与卷积神经网络(Convolutional Neural Network, CNN)相结合,利用自编码 器进行特征提取,并利用CNN进行分类决策,充分 发挥深度网络结构的复杂函数表示能力。文献 [4]提出了一种端到端的多输入卷积门控递归单 元神经网络,利用门控单元提取目标的时域和频 域特征,从而获得 HRRP 序列的多域时间依赖特 征。文献[5]提出了基于注意机制的堆叠 CNN-Bi-RNN模型,将动态调整层、CNN和挤压激励块嵌入 到堆叠双向RNN中,更有效地提取和利用雷达回 波信号的特征。文献[6]使用CNN提取目标特征, 设计了基于混合核函数的最大均值差异损失函 数,结合深度适配网络进行HRRP目标识别。文献 [7]采用CNN和双向长短期记忆网络分别提取总 体包络特征和时间特征,然后通过挤压激励块处 理并行特征以增强关键信息。文献[8]结合多尺 度特征提取和注意力机制,设计了基于注意力的 多尺度残差特征提取模块。文献[9]提出了基于 一维金字塔卷积神经网络PyDSC的识别方法,使 用金字塔卷积提取不同尺度的局部特征,并引入 深度可分离卷积降低参数量。

上述网络模型大多假设数据集为干净的回波 样本。但在实际应用中,回波信号往往伴随着各 种不同的干扰。因此,文献[10]引入了一种噪声 鲁棒识别算法,通过估计噪声的方差来更新高斯 训练模型,并引入相关信息和序列处理,以提高识 别率和鲁棒性。文献[11]提出了一种集成了去噪 和识别的网络IDR-Net,将去噪模块与识别模块相 结合,实现端到端训练,提高了低信噪比条件下的 识别性能。上述研究主要将高斯白噪声或瑞利噪 声直接添加到目标原始HRRP数据中,无法准确模 拟实际情况中压制干扰和欺骗干扰等复杂干扰的 影响。

为了更真实地模拟带有干扰的目标回波信 号,本文合成了3种典型的压制干扰信号,并按照 不同信干比添加到目标原始HRRP数据中,得到抗 干扰目标识别的研究数据。本文还提出了一种基 于自适应阈值卷积单元(Adaptive Threshold Convolution Unit, ATCU)的卷积神经网络,此处称之为自 适应阈值卷积网络(Adaptive Threshold Convolution Network, ATCN)。该ATCN网络的核心模块即 为ATCU,用于实现准确高效的特征提取。在AT-CU中,采用自适应阈值函数充当激活函数,自动调 整阈值以面对不同信干比的数据;利用多个不同 尺度的卷积核来捕获HRRP数据中的区域差异特 征;引入通道注意力机制和残差连接优化网络结 构。经过数值实验测试,本文提出的ATCN网络在 识别准确率和抗干扰稳健性方面表现出很好的 性能。

1 雷达干扰仿真及HRRP数据合成

雷达干扰的主要目的是通过散射或辐射电磁 信号来扰乱敌方雷达的探测,使其无法获取雷达 目标的准确信息^[12]。本次研究以有源压制干扰为 例,探究所提出的网络ATCN的抗干扰目标识别 性能。

有源压制干扰通过发射强干扰功率的噪声或 类噪声信号,降低雷达接收机的信噪比,使得雷达 难以发现并检测目标。常见的有源压制干扰包括 噪声调幅干扰、噪声调频干扰和噪声调相干扰等。

以下3个广义平稳随机过程分别表示噪声调 幅、噪声调频和噪声调相干扰:

$$\begin{cases} J_{a}(t) = \left[U_{0} + U_{n}(t) \right] \cos\left(\omega t + \varphi\right) \\ J_{f}(t) = U_{f} \cos\left[\omega t + 2\pi K_{FM} \int_{0}^{t} u(t') dt' + \varphi\right] (1) \\ J_{p}(t) = U_{p} \cos\left[\omega t + K_{PM} u(t) + \varphi\right] \end{cases}$$

式中, ω 为信号的中心频率, φ 为[0,2 π]上的均匀 分布。对于噪声调幅干扰 $J_a(t)$, $U_n(t)$ 为在区间 [$-U_0$, ∞]的零均值的广义平稳随机过程, U_0 为常 数;对于噪声调频干扰 $J_f(t)$ 和噪声调相干扰 $J_p(t)$, $U_f 和 U_p$ 为幅度常数, K_{FM} 为调频斜率,u(t)为调制 噪声且是一个零均值的广义平稳随机过程, K_{PM}为常数。

在实际的雷达探测中,雷达通过发射宽频带 信号,接收到目标的回波信号,并通过脉冲压缩技 术获取目标的高分辨率距离像HRRP。

本文使用频域电磁仿真软件生成目标 HRRP, 软件模拟了发射脉冲信号的宽带频谱,并通过计 算获得目标在不同频率下的散射场数据,从而得 到宽带散射谱。然后通过傅里叶逆变换,把宽带 散射谱转换成目标的 HRRP。

本文使用程序仿真生成干扰信号,并将干扰 信号与原始HRRP数据进行叠加,以获得带有干扰 的HRRP实验数据。图1为噪声调频干扰、原始 HRRP以及带干扰的HRRP的示例图像。



2 基于ATCN的目标识别方法

2.1 自适应阈值函数

文献[13]将软阈值函数作为一种新颖的非线 性激活函数嵌入到深度学习网络模型中,实现雷 达信号识别。但使用软阈值函数作为激活函数存 在一定的问题,即其非线性特性太弱。软阈值函 数的表达式为f(x) = sgn(x)max[(|x| - th),0],其中 $sgn(\cdot)$ 为符号函数,th为大于0的阈值。当阈值 th接近0时,软阈值函数退化为f(x) = x这一线性 函数,这与激活函数是为了引入非线性特性这一 初衷相违背。

为此,本文参考激活函数Leaky-ReLU设计了 如下自适应阈值激活函数:

$$g(x) = \begin{cases} x - th, & x > th \\ 0, & -th < x \le th \\ \alpha(x + th), & x \le -th \end{cases}$$
(2)

式中:th为自适应阈值,可通过网络学习;α为常数,在此处设为0.01。自适应阈值函数的导函数为 1或0或α,这样可以有效防止梯度消失和梯度爆 炸问题。

此自适应阈值函数有以下优点:首先,其有着 自适应的阈值,能够实现滤波去噪功能,降低干扰 信号对目标识别的影响;其次,与传统激活函数 ReLU相比,其*x* < 0并未全部归零,从而避免了神 经元死亡无法复活的问题;最后,与文献[13]中使 用的软阈值激活函数相比,其非线性特征更明显, 更适合作为激活函数。

2.2 多尺度卷积层

不同大小的卷积核对于同一输入图像提取的 特征信息会有所差异。通常情况下,大尺寸的卷 积核更能关注到图像的全局信息,能够捕捉到目 标的显著性和大尺度上下文信息,同时也能关注 相邻数据之间的联系。相反,小尺寸的卷积核更 适合突出图像细节,能够更精确地定位目标边界 的小尺度特征。

因此,将不同尺寸的卷积核结合起来使用可 以提取图像更丰富的特征。这种多尺度卷积的思 想在目标识别领域取得了显著的研究进展,如通 过改进残差网络中的瓶颈层提出的 Res2Net^[14]和 Google 提出的 Inception 系列网络^[15]等。

本文使用如图2所示改进的多尺度卷积。使 用不同尺寸的卷积核来构造卷积层,从左到右,核 尺寸逐渐增大,深度逐渐减小。对于大卷积核,它 们会更多地关注数据整体特征。对于每个卷积 核,同时作用于所有输入通道数据,得到输出通道 的特征映射,将各卷积核得到的特征映射线性相 加,从而得到最终的特征数据。



假设输入的特征长度为*W*_{in},已知卷积输出长度*W*_{au}的计算公式为

$$W_{\text{out}} = \frac{W_{\text{in}} + P - F + 1}{S} \tag{3}$$

式中,P为补零数,F为卷积核大小,S为步长。为 了使得输出通道的特征映射能够在通道维度上线 性叠加,则需保证不同大小卷积输出长度W_{out}一 致。本文设置步长S = 1,所以只需设置特定的补 零数P。

通过使用不同尺寸的卷积核,网络能够同时 关注数据上下文信息和数据的细节特征。通过融 合不同尺度的特征信息,网络能够得到更好的特 征表示。

2.3 通道注意力机制和残差连接

随着注意力机制在深度学习领域广泛且成功 的应用,更多的研究人员提出了新的注意力机制, 包括邻里注意^[16]、快速注意力机制^[17]等。

本文参考Hu等人提出的通道注意力机制块^[18], 并修改使其适用于本文的一维卷积网络,如图3 所示。



图3 通道注意力机制模块

假设输入数据为 $x_{in} \in \mathbb{R}^{L \times C}$,即输入一维数据长度 为L,且有C个通道。传统网络中各通道相互独立,无 法利用该通道之外的上下文信息。为此,可将全局空 间信息压缩到通道描述符中,即通过全局池化层得 到通道统计信息向量 $V_{cs} = [V_{cs}(1), V_{cs}(2), \dots, V_{cs}(i)],$ V_{cs} 的计算公式如下:

$$\boldsymbol{V}_{\rm cs}(i) = \frac{1}{L} \sum_{l=1}^{L} \boldsymbol{x}_{\rm in}(i,l)$$
(4)

式中x_{in}(i,l)表示x_{in}第i个通道的第l个元素。

为了捕获与通道相关的依赖信息,将池化后的结果通过两个全连接层。计算公式如下:

$$\boldsymbol{Y}_{se} = \boldsymbol{\sigma} \left(\boldsymbol{W}_{2} \cdot \mathbf{h} \left(\boldsymbol{W}_{1} \cdot \boldsymbol{V}_{cs} \right) \right) \tag{5}$$

式中, $\mathbf{W}_1 \in \mathbb{R}^{\frac{c}{r} \times c}$ 表示第一个全连接层的权值矩阵, $\mathbf{W}_2 \in \mathbb{R}^{c \times \frac{c}{r}}$ 表示第二个全连接层的权值矩阵, $\sigma(\cdot)$ 为 Sigmoid 激活函数, h(·)为 ReLU 激活函数。 为了降低复杂度, 在全连接层 1 中采用了倍率为r 的降维操作, 即将通道数变为 $\frac{C}{r}$, 然后在全连接层 2 中恢复通道数为C, 方便后续运算。最后,将得到 的通道注意力权值乘到原始数据中, 即

 $F_{ca} = Y_{se} \otimes x_{in}$ (6) 式中,运算 ⊗表示 x_{in} 中的每个元素都乘以 Y_{se} 中对 应通道权重。

通道注意力通过调整各通道的权重,提高对 特征的感知,使模型能够自适应地学习每个通道 的重要性,减少无关信息的干扰,提高模型的泛化 能力和鲁棒性。

随着网络深度的增加,数据尺寸逐渐减小,数 据信息缺失,网络可学习到的特征变少,从而导致 网络更难训练,出现过拟合、梯度消失和梯度爆炸 等问题。为了解决这个问题,本文中的卷积网络 使用了残差连接^[19]。残差连接可简单地用公式 y = F(x) + x表示,其中x表示上一层的输出, $F(\cdot)$ 表示本层网络对应的变换,则y就是残差输出。

2.4 自适应阈值卷积单元和网络整体框架

本文设计的特征提取单元,即自适应阈值卷 积单元(ATCU),作为自适应阈值卷积网络 (ATCN)的核心,其结构如图4所示。ATCU首先使 用3个不同尺寸(1、3和5)的卷积核进行多尺度的 特征提取。通过批归一化层对特征进行归一化处 理,以稳定梯度传播、缓解过拟合问题。采用自适 应阈值函数实现抗干扰特征提取,增加数据的非 线性能力。在此基础上,引入通道注意力机制层 对特征进行加权处理,自适应地学习通道之间的 特征重要性。ATCU还采用了残差连接来保护原 始特征的完整性并增强网络性能。通过将原始特 征直接与经过处理的特征相加,可以提供额外的 路径,使得信息更充分地传递。此外,ATCU可以 设置不进行数据下采样,从而避免因为网络过深 导致特征图尺寸过小,限制特征提取的问题。



图4 自适应阈值卷积单元ATCU

本文设计的自适应阈值卷积网络(ATCN)结 构如图5所示。首先,输入的HRRP数据会经过若干 个堆叠的ATCU进行特征提取。然后,批归一化层对 提取到的特征数据进行归一化处理,同时ReLU激 活函数引入非线性变换,这两层能增强模型表达 能力并防止模型过拟合。接着,特征数据会经过 一个全局平均池化层,该层能减少后面全连接层 的权重数量,从而减少网络的参数量。最后,将处 理好的数据展平为一维向量输入到全连接层中, 得到HRRP的分类标签。



图5 自适应阈值卷积网络ATCN

3 实验与分析

3.1 数据集

本文使用课题组自主研发的高频电磁仿真代

码对10个1:1军用飞机3D模型进行电磁仿真,得 到HRRP研究数据,飞机模型如图6所示,飞机的 尺寸参数见表1。生成每个HRRP的扫频参数设 置如下:中心频率为10 GHz,带宽为0.5 GHz,频率 采样次数为128。生成HRRP视角范围:俯仰角范 围为60°~120°,采样步长为1°,方位角范围为0°~ 180°,采样步长为1°,所以每个目标均生成HRRP 数目为61×181=11 041。将其中的10 000个样本 划分为训练集,1041个样本划分为测试集。



(g) F/A-18



(j) Su-47

图6 10种飞机3D模型示意图

为了研究网络模型在抗干扰识别方面的性 能,本文使用MATLAB仿真得到了3种类型的压制 型干扰信号:噪声调频干扰、噪声调幅干扰和噪声 调相干扰,并设置了[0 dB,5 dB,10 dB,15 dB,20 dB,25 dB,30 dB,35 dB,40 dB]一共9个信干比的 实验条件。参考本文第2节中的回波合成方法,将

表1	10种飞机目标的尺寸参数		m
飞机名称	机长	翼展	机高
A-10	16.26	17.53	4.47
E-2	17.60	24.56	5.58
EA-6	18.24	16.15	4.95
EF-2000	15.96	10.95	5.28
F-15	19.45	13.05	5.65
F-16	15.09	9.45	5.09
F/A-18	17.07	11.43	4.66
MiG-29	17.37	11.40	4.73
SR-71	32.74	16.94	5.64
Su-47	22.20	15.20	6.30

压制干扰添加到所有的HRRP原始数据中。对于 每个HRRP数据,干扰都是独立生成的,并具有一 定的随机性。

3.2 实验设置

实验计算机搭载的 CPU 为 Intel(R) Core(TM) i7-10700, GPU 为 NVIDIA GeForce RTX 3060。深 度学习平台为 Pytorch 1.13.1。

实验按照表2设置ATCN网络的参数,整个网络包含8个特征提取单元ATCU,其中4个ATCU进行下采样,另外4个不进行下采样,且相互间隔。 ATCU的第一个参数表示输出通道数,第二个参数 表示是否下采样。最后输出尺寸为10代表一共有 10个类别。

编号	输出尺寸	ATCN
1	1×128	Input
2	8×64	ATCU(8, Y)
3	8×64	ATCU(8,N)
4	16×32	ATCU(16, Y)
5	16×32	ATCU(16,N)
6	32×16	ATCU(32, Y)
7	32×16	ATCU(32,N)
8	64×8	ATCU(32, Y)
9	64×8	ATCU(32,N)
10	64	批归一化,ReLU,全局池化
11	10	全连接层

表2 ATCN网络参数设置

3.3 实验结果与分析

1) 平均识别率的对比

本文分别使用噪声调频干扰、噪声调幅干扰

和噪声调相干扰与原始HRRP数据叠加,得到对应 于不同干扰类型和不同信干比的研究数据。并选 取了 CNN-3(3 层的常规 CNN)、VGG-10(10 层的 VGG)和PyDSC 三种网络模型与ATCN 网络进行对 比实验,比较各种网络的平均识别率。不同干扰 类型下平均识别率随信干比的变化曲线如图 7 所示。



图 7 不同网络的平均识别率对比

通过对比可知,本文提出的ATCN 网络在不同 干扰类型下的平均识别率均优于其他几种网络。 相比于采用堆叠卷积层的网络,如CNN-3和VGG-10,本文的ATCN 网络的平均识别率明显提升。分 析可知,传统卷积网络会随着层数加深和最大池 化层的使用导致数据变得过短,从而使得特征信 息的丢失。相比之下,本文的ATCN 网络采用了多 尺度卷积层,在同一层中能够提取目标更多的特 征信息。

与同样利用多尺度卷积的PyDSC相比,本文的ATCN网络的平均识别率也有提升。通过分析网络结构,可以得出以下几点原因:首先,自适应

阈值函数的使用能降低干扰对特征提取的影响; 其次,本文的ATCN网络更深,相较于PyDSC的6 个特征提取单元,ATCN使用了8个特征提取单元; 最后,本文的ATCN网络引入了通道注意力机制, 使得网络能够在通道之间传递特征信息,提高了 特征的利用率。

此外,观察图像可以发现,本文的ATCN网络 的识别率曲线相对平稳,而其他几种网络的平均 识别率曲线均有着或多或少的波动。这说明本文 的网络在识别不同信干比的HRRP时具有更好的 稳定性。

2) 网络模型复杂度的对比

本文对比了4种网络的结构复杂度,结果如表 3所示。可以观察到,本文提出的ATCN网络的参数量明显少于其他网络,浮点运算次数FLOPs远 小于VGG-10,但略大于PyDSC和CNN-3。

表3 4种网络的结构复杂度对比

模型	参数量	FLOPs
CNN-3	140.33K	221.90M
VGG-10	695.13K	1 044.64M
PyDSC	142.09K	386.53M
ATCN	83.16K	451.80M

分析可知,多尺度卷积层的使用会导致模型 参数减少,但略微增加了计算量。网络的深度增 加了,较小的计算量的增加是可以接受的。通过 这样的设计,本文的ATCN网络在复杂度和识别性 能之间取得了一个平衡。较少的参数量使得网络 更加轻量化,适用于资源受限的场景。尽管计算 量略有增加,但仍然保持在合理的范围内。

3) 消融实验

为了更好地了解ATCU中不同结构模块对 ATCN网络识别率的影响,本文进行了消融实验, 删除或修改部分ATCU结构模块,并测试平均识别 率的下降值,结果如表4所示。

编号	修改项	识别率下降值
1	修改激活函数	0.93%
2	删除通道注意力机制	0.84%
3	修改卷积核数目	0.75%
4	删除残差连接	0.45%

修改项1:修改ATCU中的自适应阈值函数为

常规ReLU激活函数,结果显示平均识别率下降了 0.93%。这说明自适应阈值函数能够在不同信干 比下自动调整阈值大小,减小干扰对目标识别的 影响。

修改项2:删除ATCU中的通道注意力机制层, 结果显示平均识别率下降了0.84%。这说明通道 注意力机制能够使网络更加关注对识别有用的通 道特征,并实现不同通道间的特征融合,有助于最 终的目标识别。

修改项3:删除ATCU中的2个卷积核,仅留下 尺寸为3的1个卷积核,结果显示平均识别率下降 了0.75%。这表明多尺度卷积能够提取更多的目 标特征信息,使得网络能够更全面地分析目标并 进行分类。

修改项4:删除ATCU中的残差连接,结果显示 平均识别率下降了0.45%。因为残差连接能够明 显改善特征消失的问题。

4 结束语

本文提出了一种基于自适应阈值卷积单元 ATCU的卷积神经网络ATCN,并基于带有压制类 干扰的HRRP数据进行目标识别。相较于传统卷 积神经网络,本文的ATCN网络使用自适应阈值函 数,面对不同信干比的HRRP数据会自动调整阈 值,降低干扰对目标特征提取的影响;采用了多尺 度卷积层,融合了不同尺度下的特征信息;同时结 合通道注意力机制,增强通道间特征信息的交互; 使用残差连接改善梯度消失的问题。

本文进行了大量的抗干扰目标识别实验,实验结果表明,相比于另外3种对比网络,本文的ATCN网络能在不同干扰类型和不同信干比下提供更优的平均识别率和更好的指标稳定性,且具有更少的网络模型参数量和浮点运算次数,具备轻量化和高效的特点。

参考文献:

- [1]保铮,邢孟道,王彤.雷达成像技术[M].北京:电子工业 出版社,2019.
- [2] 张永顺,童宁宁,赵国庆.雷达电子战原理[M].北京:国 防工业出版社,2020.
- [3] KONG Yameng, FENG Dejun, ZHANG Jiang. Radar

HRRP Target Recognition Based on Composite Deep Networks [C]// 2022 International Applied Computational Electromagnetics Society Symposium, Xuzhou, China: IEEE, 2022:1-5.

- [4] ZENG Zhiqiang, SUN Jinping, HAN Zhu, et al. Radar HRRP Target Recognition Method Based on Multi-Input Convolutional Gated Recurrent Unit with Cascaded Feature Fusion [J]. IEEE Geoscience and Remote Sensing Letters, 2022, 19:1-5.
- [5] PAN Mian, LIU Ailin, YU Yanzhen, et al. Radar HRRP Target Recognition Model Based on a Stacked CNN-Bi-RNN with Attention Mechanism [J]. IEEE Trans on Geoscience and Remote Sensing, 2022, 60:1-14.
- [6] 王国帅,汪文英,魏耀,等.基于混合核深度适配网络的HRRP目标识别[J].雷达科学与技术,2020,18(6):618-624.
- [7] WU Lingang, HU Shengliang, XU Jianghu, et al. Ship HRRP Target Recognition Against Decoy Jamming Based on CNN-BiLSTM-SE Model[J]. IET Radar, Sonar & Navigation, 2024, 18(2):361-378.
- [8] 陈禾,张心怡,李灿,等.基于多尺度注意力CNN的SAR 遥感目标识别[J].雷达科学与技术,2021,19(5):517-525.
- [9] HE Jiaxing, WANG Xiaodan, SONG Yafei, et al. A Multi-Scale Radar HRRP Target Recognition Method Based on Pyramid Depthwise Separable Convolution Network [C]// 2022 7th International Conference on Image, Vision and Computing, Xi'an, China: IEEE, 2022:579-585.
- [10] SU Keyu, GONG Lin, WANG Guanyong, et al. Noise-Robust Radar HRRP Target Sequential Recognition Based on Correlative Scattering Centers [J]. IEEE Geoscience and Remote Sensing Letters, 2023, 20:1-5.
- [11] LIU Xiaodan, WANG Li, BAI Xueru. End-to-End Radar HRRP Target Recognition Based on Integrated Denoising and Recognition Network[J]. Remote Sensing, 2022, 14(20):5254-5271.
- [12] 赵国庆. 雷达对抗原理[M]. 西安: 西安电子科技大学 出版社, 2015.
- [13] PAN Jifei, ZHANG Shengli, XIA Lingsi, et al. Embedding Soft Thresholding Function into Deep Learning

Models for Noisy Radar Emitter Signal Recognition [J]. Electronics, 2022, 11(14):2142-2154.

- [14] GAO Shanghua, CHENG Mingming, ZHAO Kai, et al. Res2net: A New Multi-Scale Backbone Architecture [J].
 IEEE Trans on Pattern Analysis and Machine Intelligence, 2019, 43(2):652-662.
- [15] SZEGEDY C, LIU Wei, JIA Yangqing, et al. Going Deeper with Convolutions [C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, Boston, MA, USA: IEEE, 2015:1-9.
- [16] HASSANI A, WALTON S, LI Jiachen, et al. Neighborhood Attention Transformer [C]// 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Vancouver, BC, Canada:IEEE, 2023:6185-6194.
- [17] WAZIR S, FRAZ M M. HistoSeg: Quick Attention with Multi-Loss Function for Multi-Structure Segmentation in Digital Histology Images [C]// 2022 12th International Conference on Pattern Recognition Systems, Saint-Etienne, France:IEEE, 2022:1-7.
- [18] HU Jie, SHEN Li, SUN Gang. Squeeze-and-Excitation Networks[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA: IEEE, 2018:7132-7141.
- [19] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep Residual Learning for Image Recognition [C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA: IEEE, 2016:770-778.

作者简介:

王佳豪 男,硕士研究生,主要研究方向为基于深度 学习的抗干扰雷达目标识别。

陈澍元 男,硕士研究生,主要研究方向为基于深度 学习的图像目标检测和图像分割。

赵书敏 男,研究员,主要研究方向为雷达信号处理、时间调制相控阵列的分析与综合。

蒋忠进 男,博士,副教授,主要研究方向为雷达目标 电磁散射特性、抗干扰目标识别、高分辨雷达成像、SAR图 像自动解译。