

文章编号: 2095-4980(2023)09-1100-09

面向 ADS-B 信号辐射源个体识别的轻量化模型设计

王艺卉^{1,2}, 闫文君^{*1}, 徐从安^{1,3}, 查浩然⁴, 桂冠⁵, 陈雪梅³, 葛亮⁶

(1. 海军航空大学 信息融合研究所, 山东 烟台 264001; 2. 中国人民解放军 31401 部队, 山东 烟台 264001;
3. 北京理工大学 前沿技术研究院, 北京 100000; 4. 哈尔滨工程大学 信息与通信工程学院, 黑龙江 哈尔滨 150000;
5. 南京邮电大学 信息与通信工程学院, 江苏 南京 210000; 6. 天津市测绘院有限公司, 天津 300000)

摘 要: 针对辐射源个体识别高精度度、轻量化、实时性的现实应用需求, 提出了面向广播式自动相关监测(ADS-B)信号辐射源个体识别的轻量化模型设计方法。根据信号数据特点进行解码处理, 并对不均衡样本进行权重调节, 改善样本质量; 通过分组卷积获取不同维度的细微特征, 与初始特征拼接, 实现多维互补特征融合, 并同步进行提高识别效率。利用 Ghost bottleneck 结构实现网络模型压缩与跨层连接, 在融合多维特征的同时节省计算资源。实验结果表明, 本文算法结构精简, 计算量低, 识别率达到 95.2%, 并在不同容量的样本识别中效果稳定。本文算法较好地平衡了辐射源个体识别精度度、轻量化与高时效的需求。

关键词: 辐射源个体识别; Conv2D 层; Ghost bottleneck 结构; 轻量化设计

中图分类号: TN911.7

文献标志码: A

doi: 10.11805/TKYDA2023077

Design of lightweight model for Specific Emitter Identification of ADS-B signal

WANG Yihui^{1,2}, YAN Wenjun^{*1}, XU Congan^{1,3}, ZHA Haoran⁴, GUI Guan⁵, CHEN Xuemei³, GE Liang⁶

(1. Institute of Information Fusion, Naval Aviation University, Yantai Shandong 264001, China;

2. Unit 31401 of the People's Liberation Army, Yantai Shandong 264001, China;

3. Advanced Technology Research Institute, Beijing Institute of Technology, Beijing 100000, China;

4. School of Information and Communication Engineering, Harbin Engineering University, Harbin Heilongjiang 150000, China;

5. School of Information and Communication Engineering, Nanjing University of Posts and Telecommunications, Nanjing Jiangsu 210000, China;

6. Tianjin Institute of Surveying and Mapping Company Limited, Tianjin 300000, China)

Abstract: Aiming at the practical application requirements of high precision, lightweight and instant for Specific Emitter Identification(SEI), a lightweight model design for radiation source individual recognition of Automatic Dependent Surveillance-Broadcast(ADS-B) signal is proposed in this paper. Firstly, the signal data is decoded according to the characteristics of the signal data, and the weight of the unbalanced sample is adjusted to improve the sample quality. Then, the small features of different dimensions are obtained by grouping convolution and splicing with the initial features to realize multidimensional complementary feature fusion and parallel synchronization to improve the recognition efficiency. Network model compression and cross-layer connection are implemented by using a Ghost bottleneck structure, which tends to save computing resources while integrating multi-dimensional characteristics. The experimental results show that the proposed algorithm has the advantages of simple structure and low computational load, high recognition rate of 95.2%, and a stable recognition effect in different capacity samples. The proposed design better balances the needs of individual identification accuracy, lightweight and efficiency for SEI.

Keywords: Specific Emitter Identification; Conv2D; Ghost bottleneck; design of lightweight model

特定辐射源识别(SEI)是指从接收信号中提取细微差异用于关联单个辐射源的技术^[1]。SEI广泛用于电子情

收稿日期: 2023-03-28; 修回日期: 2023-05-16

基金项目: 国家自然科学基金资助项目(62271499); 电磁空间安全全国重点实验室开放基金资助项目

*通信作者: 闫文君 email:249927911@qq.com

报、预警探测、无线电认知、网络管理、态势监测等领域。传统信号识别算法依赖于先验信息与人工经验，在实际通信场景中受噪声和衰落等因素的影响，辨识精确度与估算误差大，难以满足日益复杂的电磁环境与多维度通信体系的高精确度需求。因此，实现辐射源个体的快速精准识别在军事领域和民用领域都具有重要意义。

近年来，基于深度学习的分类方法已在图像分类与检测、目标检测、分割及跟踪、视频分类、姿态估计等相关领域有较为广泛且成功的应用，其学习能力强，测量精确度高，识别速度快等突出特点，可有效解决先验知识不完备、样本数量不充足、难以满足动态变化实时感知及网络结构轻量化发展等瓶颈问题^[2]。但同时模型性能的优化通常伴随着模型尺寸、计算成本等大幅增长，为实时决策需求和简易端口布设工作带来挑战^[3]。

目前基于深度学习的辐射源个体识别研究主要集中于雷达目标识别、通信信号识别^[4]2 个方面。文献[5]以包络特征作为初级特征，借助深度信念网络挖掘包含个体信息差异的特征，在测试算法识别率的同时，将隐层输出的可分性进行可视化，较好地佐证了理论推断。文献[6]对特征向量之间的距离进行度量与定量分析，将互信息与 K 最近邻算法相结合，实现了基于大数据计算集群的未知雷达辐射源比对检索与识别。文献[7]提出了架构于长-短记忆结构(Long Short-Term Memory, LSTM)的递归神经网络(Recurrent Neural Network, RNN)，实现自动识别硬件特征，在信噪比为-12 dB 的不理想状态下，仍能实现较高的检测精确度；文献[8]提出了一种基于雷达脉冲波形和卷积神经网络(Convolutional Neural Network, CNN)结合的 SEI 方法，通过对全脉冲信号进行建模，提取精细的差异特征，并利用小卷积核神经网络进行监督训练。文献[9]指出少数类样本可能会向分类器中引入无关噪声，因而提出一种结合噪声滤波器的欠采样框架。文献[10]提出一种基于密度的欠采样算法，并将其与 AdaBoost 进行集成，从而保留有效类别。文献[11]为使模型同时适应训练数据和实际应用数据，在网络中加入域分类子网络，使网络能较好地适应不同的目标域，与参数微调方法相比，具备更高的准确率。深层网络更容易提取到语义丰富的深层特征信息，但网络深度加深的同时梯度消失及梯度爆炸的可能性也随之加大，深度残差网络利用跨层级的连接结构使梯度正常回传，可有效避免此问题。

由于内存和计算水平等因素限制，在低算力的移动端和嵌入式设备中实现神经网络架设极具挑战。虽然以上方法分选效果均能实现高效轻量化需求，但不同程度上仍存在内部特征冗余、低维度特征信息损失、大尺寸图像训练速度缓慢等问题。

针对 ADS-B 信号辐射源个体识别任务中网络模型结构复杂，参数量大，样本不均衡等问题，难以满足中、小型航空器设备便携可插拔、感知态势变化实时性的现实需求，本文引入 Ghost bottleneck 轻量级的 CNN 网络模型，以较小代价从原始特征中挖掘更多的细节特征，提升主干分支的特征提取能力，并采用跨层连接的方式，结合多层特征信息，平衡识别效率与精确度，实现面向 ADS-B 信号辐射源个体的精准识别。

1 数据处理

1.1 数据特征

本文就目前应用最为广泛的、亦为国际民航组织推荐的 1 090 MHz S 模式扩展电文数据链进行分析，其最大下行数据长度达 112 位，最大数据率达 1 Mbit/s。典型的报文格式如图 1 所示。

DF (5)	CA (3)	ICAO (24)	ME (56)	PI (24)
-----------	-----------	--------------	------------	------------

Fig.1 Typical packet format of ADS-B
图 1 ADS-B 典型报文格式

民航 ADS-B 消息都必须以下行链路格式 17 开头，对应二进制 10001，处于 1~5 位；6~8 位用作附加标识符，表示通信、飞机在空中位置等应答能力。模式 S 应答器代码通常也称为国际民用航空组织(International Civil Aviation Organization, ICAO)地址或十六进制代码。ICAO 地址以二进制形式从 9 到 32 位定位。唯一的 ICAO 地址被分配给飞机的每个 S 模式应答器，并作为每个飞机的唯一标识符。ME 字段为扩展断续振荡消息域，可承载多种信息，如空中位置信息、地表面位置信息、空中速度信息、飞机标识与类型信息等。PI 字段处于 89~112 位，共 24 bit，用于循环冗余校验码(Cyclic Redundancy Check, CRC)校验，以判断是否存在报文污染现象。

1.2 解码处理

如图 2 所示，一条 ADS-B 消息主要由前导脉冲部分和数据脉冲部分组成。前导脉冲位置在消息的前端，即信号的前 8 μs 时间，为信息头部分，共有 4 个脉冲。采样率为 2 MHz，即 1 μs 可以获取 2 个采样点。从上述检验通过的数据脉冲中，从报头开始取 2×112 个采样点，对 224 个采样点进行脉冲位置调制(Pulse Position Modulation, PPM)解码操作。ADS-B 消息数据块格式采用 PPM 编码，在每一个被传输的脉冲前半部分为 1，后半部分为 0。



Fig.2 ADS-B 1 090 MHz ES pulse signal
图2 ADS-B_1 090 MHz_ES脉冲信号

遍历送入的所有采样点, 首先判断当前点是否为前导脉冲信息头部分, 即从当前点开始往后共 2×8 个采样点, 看当前信号基带幅值是否满足 ADS-B 报文信息头部分的要求。若满足要求, 该采样点即为一条 ADS-B 数据的前导脉冲信息头, 并对第 89 位至第 112 位 PI 字段进行 CRC 校验处理; 若不满足要求, 则对该 16 个采样点进行纠正, 然后再次判断是否符合前导脉冲信息头部分采样点的要求, 进入下一次循环。对后一个采样点进行相同操作, 校验正确后的 ADS-B 消息转换形成 ADS-B 报文, 再进行解简洁位置报告 (Consolidated Position Report, CPR) 码解算, 从而获取明文信息。将解码后的飞机 ID、航班号、经纬度、航速、航向、时间明文作为标签, 与对应的 IQ 数据进行存储。具体流程如图 3 所示。

1.3 数据增强

由于训练数据都属于比较理想的状态, 本文采用 noise-based 方法消除过拟合的影响。在训练集里对每条数据加入均值为 0、方差为 100 的随机高斯噪声, 使其适当偏离原始数据, 形成一条新的报文数据, 与原数据一起作为训练集内容, 在增加数据丰富性的同时提升模型鲁棒性。

1.4 权重调节处理不平衡样本

以实测 50 架飞机的飞行信息为样本, 按类标号 1 至 50, 其数据量如图 4 所示。分析发现每个类别样本数量从 500 至 3 700 不等, 不同类别的样本数量差异较大, 即存在类分布不平衡问题。

对于所有样本, 损失函数为:

$$L = \frac{1}{N} \sum_{i=1}^N l(y_i, \hat{p}_i) \quad (1)$$

式中: N 为类别总量; y_i 为第 i 个样本的真实标签; $\hat{p}_i$ 为模型预测概率。

当样本分布失衡时, 损失函数分布也会随之倾斜, 占据多数的某类样本会占据主导地位, 导致模型倾向于此类样本预测, 对小样本分类能力差; 同时, 少数类样本数量小, 特征无法完整覆盖, 影响分类效果。

针对此问题, 本文采取正负样本的惩罚权重调整方法。将权重调节参数 `class_weight` 改为 `balanced`, 权重自动调整为与输入数据中的类频率成反比, 平衡样本类别权重, 减少小样本部分的片面影响, 更好地呈现全局情况。

2 网络模型

CNN 仿造生物的视知觉机制构建, 可以进行监督学习和非监督学习, 其隐含层内的卷积核参数共享和层间连接的稀疏性, 使卷积神经网络能够以较小的计算量处理输出数据, 生成格点化特征, 对一维信号点学习效果




Fig.3 Data decoding process
图3 数据解码流程




Fig.4 Quantity distribution of training samples
图4 训练样本数量分布情况

稳定。本文识别算法采用具有表征学习能力的 CNN，引入 Conv2D 和串联 Ghost bottleneck 倒残差结构，在实现融合高维度细微和初始特征的同时，实现快速精准识别。

2.1 Conv2D 特征高维细微化

引用 Conv2D 中分组思想，从横向维度提升模型表征能力。如图 5 所示，网络输入为 240×1 的报文数据，经过一次卷积后实现 $240 \times 1 \times 4$ 三维张量。报文根据输入通道数量分为 4 组后，分别进行 Conv1 至 Conv4 不同的卷积操作，实现多维度特征提取，丰富通道信息；同时通道 5 卷积提取输入端信息初始特征，两者拼接后可实现细微特征与高维度特征的融合。为防止卷积层数的陡增导致梯度爆炸，特征拼接后构建修正线性单元(Rectified Linear Unit, ReLU)、批归一化层(Batch Normalization, BN)和平均池化层。




Fig.5 Conv2D packet convolution operation
图 5 Conv2D 分组卷积操作

2.2 Ghost bottleneck 轻量化

在引入 Conv2D 分组卷积关联提取特征后，识别精确度得到了提升，但网络参数与计算量的增加极其影响网络模型的识别速度，故引入 Ghost bottleneck 实现网络模型轻量化。

Ghost bottleneck 轻量化 CNN 网络的机理主要是通过引入 Ghost bottleneck 模块和 SE(Squeeze-and-Excitation)激活函数来降低网络的复杂度，从而实现轻量化的效果。Ghost bottleneck 网络在原始的残差网络中引入了一种新的模块，称为 Ghost bottleneck 模块。该模块包括两部分：一个主干分支和一个辅助分支。其中主干分支包含 1 个卷积层和 1 个批归一化层，而辅助分支只包含 1 个卷积层。在主干分支中，只有一部分通道被保留，其他通道被压缩成较小的通道数。这样可以减少网络中的参数数量和计算量，从而提高网络的轻量化效果。同时，Ghost bottleneck 网络还引入了 SE 激活函数，该激活函数可自适应地调整每个通道的权重，提高网络的表达能力和准确性。

应用在深度学习中的卷积方式主要有 2D 卷积、3D 卷积、 1×1 卷积、反卷积、扩张卷积、空间可分卷积、深度可分卷积、Flattened 卷积、Ghost 卷积等。其中 2D 卷积即普通卷积；3D 卷积不能用于中频数据分析； 1×1 卷积用于调节通道数，增加非线性，实现跨通道信息和减少参数等，其主要作用是数据降维和引入更多非线性；反卷积通常用于 GAN 生成器、自编码、语义分割等模型中，用于执行上采样；扩张卷积是系统性聚合多个比例的信息而不丢失分辨率，其扩张率每层都按照指数层架，不利于网络轻量化；可分卷积使用有局限性，如果使用可分卷积取代普通卷积，有可能限制训练期间搜索可能的内核，导致模型失效；Flattened 卷积能够提供的性能与普通卷积相当，计算成本要低，但将 Flattened 卷积直接用于滤波器，会导致显著的信息丢失；综上，上述卷积对于模型轻量化作用有限甚至无效，因此本文考虑采用对比普通卷积和 Ghost 卷积。

GhostNet 是华为于 2020 年提出的轻量级卷积网络，在实现较高分类和检测性能的同时，创造性地提出 Ghost Module 可以替换经典 CNN 网络中的卷积操作，通过用 Ghost Module 组成的 Ghost bottleneck 替换普通的卷积层，降低计算成本。本文设计的卷积神经网络对文献[12]中提到的 Ghost bottleneck 进行了参考，其突出优势是用线性操作提升与 CNN 特征提取能力正相关的 Ghost 对。

以 Xception 为代表的紧凑型模型设计多采用 pointwise convolution 实现跨通道特征处理，而后采用 depthwise convolution 处理空间信息，但未能充分利用特征映射之间的相关性及冗余性。Ghost bottleneck 由 2 个 Ghost module 组成，其结构如图 6 所示。输入图像的尺寸为 $H \times W \times C$ (高 $\times$ 宽 $\times$ 输入通道数)，卷积核尺寸为 k ，输出图像尺寸为 $H' \times W' \times C'$ (高 $\times$ 宽 $\times$ 输出通道数)。Ghost 卷积通过一个普通的卷积，获得通道数为 m 的特征层，再通过对已经生成的特征层使用深度可分离卷积，Ghost 模块将 identity 与 Ghost Module 中的线性变换并行，线性内核的尺寸为 d ，生成 n 个相似的特征，填充到已生成特征层中，最终获得与以普通卷积输出一致的内在特征图。

如图 7 所示，在 Stride=1 的 Ghost bottleneck 中 Ghost Module 实现特征提取，残差边进行网络优化；Stride=2 的 Ghost bottleneck 在此基础上进行高宽的压缩处理和深度卷积，两者都实现了有效降低计算参数与模型体积压缩，

并提升了识别速度和精确度。




Fig.6 Convolution operation of Ghost Module
图 6 Ghost Module 卷积操作

普通卷积和 Ghost 卷积参数量分别为：

$$P_{\text{conv}} = C \times C' \times k \times k \quad (2)$$

$$P_{\text{Ghost}} = C \times m \times k \times k + m \times n \times d \times d \quad (3)$$

普通卷积和 Ghost 卷积参数量比值为：

$$R_{\text{CG}} = \frac{C \times C' \times k \times k}{C \times m \times k \times k + m \times n \times d \times d} \approx \frac{C'}{m} \quad (4)$$

普通卷积和 Ghost 卷积计算量分别为：

$$G_{\text{conv}} = C \times k \times k \times C' \times H' \times W' \quad (5)$$

$$G_{\text{Ghost}} = H' \times W' \times C \times k \times k \times m + H' \times W' \times d \times d \times n \quad (6)$$

普通卷积和 Ghost 卷积计算量比值为：

$$R_G = \frac{C \times k \times k \times C' \times H' \times W'}{H' \times W' \times C \times k \times k \times m + H' \times W' \times d \times d \times n} \approx \frac{C'}{m} \quad (7)$$




Fig.7 Convolution operation of Ghost bottleneck
图 7 Ghost bottleneck 卷积操作

通过分析发现，普通卷积与 Ghost 卷积的参数量和计算量之比均为 C' 与 m 的比值。通过 Ghost 卷积生成的特征图通道数 m 比普通卷积少，则 Ghost 卷积的参数量和计算量相较于普通卷积更少。

2.3 主干网络

针对辐射源个体识别任务，本文采用传统的 CNN 结构与含有跨层连接的 Conv2D 和 Ghost bottleneck 实现多维特征融合，如图 8 所示。主要包括普通卷积层、批规范层、池化层、Conv2D 层、Ghost bottleneck 结构层、全连接层。




Fig.8 Lightweight model design for individual recognition of radiation sources
图 8 面向辐射源个体识别的轻量化模型设计

为避免前向计算的该 batch 数据误差累积回传，解决神经网络中梯度消失的问题，使用批规范层(BatchNorm 层)加速神经网络收敛过程，同时提高训练过程中的稳定性。具体而言，就是把每层神经网络任意神经元输入值的分布强行限制到均值为 0，方差为 1 的标准正态分布。其数学表达式为：

$$\mu_B \leftarrow \frac{1}{m} \sum_{i=1}^m x_i \quad (8)$$

$$\sigma_B^2 \leftarrow \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \quad (9)$$

$$\hat{x}_i = \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}} \quad (10)$$

式中： m 代表 batch； μ_B 和 σ_B^2 为批处理数据的均值及方差； x_i 为第 i 个样本； ε 为防止分母为零的微小常数。通过计算式(8)~(10)，实现原本随机分布的样本 x_i 到正态分布的数据 $\hat{x}_i$ 的转化。

通过设置 dropout 参数，在前向传播过程中让某个神经元的激活值以一定的概率 p (伯努利分布) 停止工作，使其不会参与前向传播与反向回传，模型不会过分依赖某些局部特征而泛化性更强，有效实现模型融合并避免过拟合。

损失函数是对网络模型定量分析的表征，损失函数输出越小，表明网络学习到的规律愈加贴合数据的内含规律。经过前向传播计算 Loss，根据其值进行反向推导，并进行相关参数的调整，神经网络模型训练得以实现。本文采用交叉熵损失函数对网络参数进行方向性调整。

交叉熵能够衡量一个随机变量中 2 个不同概率分布的差异程度，在机器学习中表示为真实概率分布 y_{ji} 与预测概率分布 $\hat{y}_{ji}$ 。对一个 batch 单标签 n 分类任务的交叉熵，则损失函数的计算方法为：

$$Loss = -\frac{1}{B} \sum_{j=1}^B \sum_{i=1}^n y_{ji} \log \hat{y}_{ji} \quad (11)$$

式中 B 为 batchsize。

交叉熵函数计算的每个类别概率可以反映分类模型实际输出的概率分布和预期概率分布的差距。

3 实验过程与结果分析

3.1 实验环境及网络参数设置

本文采用 USRP 210 软件无线电设备采集系统接收的 1 090 MHz ADS-B S 模式响应信号，可在 70 MHz~6 GHz 范围内提供连续的频率覆盖。IQ 数据中心频率为 1 090 MHz，带宽为 2 M，采样频率为 2 MHz，接收增益为 80 dB，信号采集场景如图 9 所示。在航班密集程度不同的时间段及地点累积采集 ADS-B 射频信号后，进行抗混叠滤波和步进增益，将信号解调到中频；通过 AD 转换器进行数字信号处理得到 IQ 数据，并进行 1.2 节中所述的解码处理得到纯净报文数据；合并为真实的 16 位 IQ 数据后取模，得到基带幅值数据作为样本。根据采集地点选取样本，形成 2 个数据集作为主干网络输入，分别为北京某地区采集的类别数量(飞机数量)为 232，总样本量为 39 294；青岛某地区采集类别数量为 50，总样本量为 98 862，分别记为 BJdata 和 QDdata，每个类别样本以其 ICAO 航班识别号为标记，训练集与测试集按 7:3 比例划分。图 10 为部分接收的 ADS-B 信号样本的波形。



Fig.9 Signal acquisition scenario
图9 信号采集场景




Fig.10 Waveform of the received partial ADS-B signal sample
图10 部分接收的 ADS-B 信号样本波形

网络模型的设计与训练过程采用 Pycharm 软件完成，使用的模型为基于 TensorFlow 的 keras 框架，硬件配置为 Intel(R) Core(TM)i9-9900K CPU，主频 3.6 GHz，运行内存 16 GB。输入数据尺寸统一为 240×1 格式，模型训练过程采用 Adam 优化器进行权值优化，每次迭代样本数为 64，训练次数设置为 30，学习率为 0.01。

3.2 评价标准

将识别准确率(accuracy)、参数量和计算量作为评价指标进行性能评价。若样本总数为 n ，ICAO 航班号为 m 的样本数量为 nm ，分选算法将 ICAO 航班号为 j 的样本分选为 k 样本的数量为 $n^k(j, k=1, 2, \dots, N)$ ，则将类型为 j 的样

本分类为类型为 k 的概率为:

$$P_{jk} = \frac{n^{jk}}{n^j} \quad (12)$$

当 j 和 k 相等时, 表示预测正确。则信号分选的准确率可表示为:

$$P_k = \frac{n^{kk}}{n^{m^k}} \quad (13)$$

参数量和计算量一般能够反映模型对所承载设备的性能要求, 一般来说, 参数量较小的模型对设备的内存、计算能力要求更低, 更易于实时反馈。

3.3 实验结果分析

基于训练集与测试集的划分, 分别以 BJdata 和 QDdata 为训练样本对网络模型进行训练。从图 11 中可以看出, 模型的训练损失率随迭代次数都趋于下降, 分别达到 0.361 9 和 0.258 2; 训练正确率随之上升, 分别达到 0.892 7 和 0.925 7, 说明此轻型神经网络同时适用于类别数量为 50~200 区间内的辐射源个体识别。




Fig.11 Changes in accuracy and loss during training process

图 11 训练过程中 accuracy 和 loss 变化情况

3.3.1 有效性验证

为验证采用 noise-based 数据增强的有效性, 在训练集里对每条数据添加/不添加均值为 0、方差为 100 的随机高斯噪声, 据此处理的 2 组 BJdata 和 QDdata 分别作对比实验。2 组对比实验训练机器学习模型时, 训练数据的误差度与正确率如图 12 所示。




Fig.12 Training performance with or without adding random noise in different datasets

图 12 有无添加随机噪声在不同数据中的训练表现

从图 12 中可以看出, 训练过程中的误差度与正确率随着随机高斯噪声的加入明显更快进入, 并最终达到更好的训练效果。在 BJdata 样本种类 4.64 倍于 QDdata, 但样本数量 0.397 倍于 QDdata 的情况下, 训练模型的效果明显提高; 相反, 在样本数量充足的情况下, 采用 noise-based 数据增强反而降低了训练模型的特征提取能力。因

此，考虑单个样本数量在不同情况下是否进行数据增强是未来改善算法性能的关键之一。

3.3.2 与其他识别算法比较

为进一步说明此基于轻量级神经网络的无线电信号识别的性能优势，从模型参数量、浮点计算量、识别准确率 3 个角度将本文算法与现有典型算法的复杂度进行对比。由表 1 可知，本文模型的参数量和计算量明显低于 ResNet50、DenseNet121、MobileNetV2、EfficientNet，这是因为本文算法对设备内存要求更低，易于嵌入，迁移便捷程度更高，在新的应用场景下会更快地完成训练。在 ADS-B 信号个体识别性能上，本文算法比 ResNet50、DenseNet121 略低，但比另外 2 种网络高。在性能相差不大情况下，本文更加考虑轻量化的影响。

表 1 网络模型复杂度比较
Table1 Comparison of network model complexity

module	parameter quantity	floating-point computation	recognition accuracy/%
ResNet50	25.5×10 ⁶	3.8×10 ⁹	95.5
DenseNet121	8.0×10 ⁶	2.9×10 ⁹	95.7
MobileNetV2	3.4×10 ⁶	0.3×10 ⁹	93.4
EfficientNet	5.3×10 ⁶	0.4×10 ⁹	92.8
proposed method	2.3×10 ⁶	0.2×10 ⁹	95.2

3.3.3 算法鲁棒性分析

深度学习模型的识别性能一定程度上受训练样本容量的影响，为分析不同样本数量下本文算法的识别准确率，对样本类别同为 50，训练样本数量分别为 7 321、33 154 和 80 543 的数据集进行算法性能仿真，分别为训练集 1、2、3。

由表 2 可知，在样本容量差距较大的情况下，本文算法能保持较好的识别性能，且在训练集 1 中，各类训练样本数量均值为 146.42 的情况下仍能保持优异的识别性能，从而验证了本文算法的鲁棒性和对辐射源个体识别的表征能力。考虑到实际应用场景中非合作辐射源个体的高质量样本采集与标注难度，本文对少量样本识别效果的稳定性更具有实际应用意义。

表 2 不同样本数下模型识别准确率比较
Table2 Comparison of recognition accuracies with different sample sizes

training set	number of training samples	recognition accuracy/%
1	7 321	95
2	33 154	96
3	80 534	93

4 结论

针对辐射源个体识别受限于识别精确度、模型规模、计算复杂度不平衡发展的问题，本文结合高维细微特征和初始低维特征融合的分组卷积思路与跨层连接的 Ghost bottleneck 结构，实现多维度特征融合。实验结果表明，与较为经典的识别算法相比，本文面向辐射源个体识别的轻量化模型较好地平衡了识别精确度、计算复杂度与模型规模，为实际应用场景中的低算力设备部署提供了可能。

参考文献：

[1] XING Yuexiu, HU Aiqun, ZHANG Junqing, et al. Design of a robust radio-frequency fingerprint identification scheme for multimode LFM radar[J]. IEEE Internet of Things Journal, 2020,7(10):10581–10593.

[2] 魏溪含,涂铭,张修鹏. 深度学习与图像识别:原理与实践[M]. 北京:机械工业出版社, 2019. (WEI Xihan,TU Ming,ZHANG Xiupeng. Deep learning and image recognition:principle and practice[M]. Beijing:China Machine Press, 2019.)

[3] 李登峰,高明,叶文韬. 结合轻量级特征提取网络的舰船目标检测算法[J/OL]. 计算机工程与应用, 2022:1–10. (LI Dengfeng, GAO Ming, YE Wentao. Ship target detection algorithm combined with lightweight feature extraction network[J/OL]. Computer Engineering and Applications, 2022:1–10.)

[4] LIU Mingwei, DOHERTY J F. Nonlinearity estimation for specific emitter identification in multipath channels[J]. IEEE Transactions on Information Forensics and Security, 2011,6(3):1076–1085.

[5] 徐宇恒,程嗣怡,董晓璇,等. 基于 DBN 特征提取的雷达辐射源个体识别[J]. 空军工程大学学报(自然科学版), 2019,20(6):91–96,108. (XU Yuheng,CHENG Siyi,DONG Xiaoxuan, et al. Radar specific emitter identification based on DBN feature extraction[J]. Journal of Air Force Engineering University(Natural Science Edition), 2019,20(6):91–96,108.)

- [6] 冯蕴天,王国良,韩慧,等. 面向电磁大数据的未知雷达辐射源智能识别[J]. 太赫兹科学与电子信息学报, 2021,19(4):589–595. (FENG Yuntian,WANG Guoliang,HAN Hui,et al. Intelligent recognition of unknown radar emitters for electromagnetic big data[J]. Journal of Terahertz Science and Electronic Information Technology, 2021,19(4):589–595.) doi:10.11805/TKYDA2021146.
- [7] 秦鑫,黄洁,王建涛,等. 基于无意调相特性的雷达辐射源个体识别[J]. 通信学报, 2020,41(5):104–111. (QIN Xin,HUANG Jie,WANG Jiantao,et al. Radar emitter identification based on unintentional phase modulation on pulse characteristic[J]. Journal on Communications, 2020,41(5):104–111.) doi:10.11959/j.issn.1000–436x.2020084.
- [8] CHEN Peibo, GUO Yulan, LI Gang, et al. Discriminative adversarial networks for specific emitter identification[J]. Electronics Letters, 2020,56(9):438–441.
- [9] KANG Qi, CHEN Xiaoshuang, LI Sisi, et al. A noise-filtered under-sampling scheme for imbalanced classification[J]. IEEE Transactions on Cybernetics, 2017,47(12):4263–4274.
- [10] HOU Yun, LI Li, LI Bailin, et al. An anti-noise ensemble algorithm for imbalance classification[J]. Intelligent Data Analysis, 2019,23(6):1205–1217.
- [11] 谭凯文,张立民,闫文君,等. 面向非均衡类别的半监督辐射源识别方法[J]. 雷达学报, 2022,11(4):713–727. (TAN Kaiwen, ZHANG Limin, YAN Wenjun, et al. A semi-supervised emitter identification method for imbalanced category[J]. Journal of Radars, 2022,11(4):713–727.)
- [12] HAN Kai, WANG Yunhe, TIAN Qi, et al. GhostNet: more features from cheap operations[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Seattle, WA, USA: IEEE, 2020:1577–1586.

作者简介:

王艺卉(1992–), 女, 在读硕士研究生, 主要研究方向为辐射源个体识别.email:249927911@qq.com.

闫文君(1986–), 男, 博士, 副教授, 主要研究方向为空时分组码检测、智能信号处理.

徐从安(1987–), 男, 博士, 副教授, 主要研究方向为遥感图像智能处理、多目标跟踪.

查浩然(1996–), 男, 在读博士研究生, 主要研究方向为深度学习、信号分析识别、软件无线电技术.

桂冠(1982–), 男, 博士, 教授, 博士生导师, 主要研究方向为智能信号处理、无限功率传输和物理层安全技术.

陈雪梅(1978–), 女, 博士, 副教授, 主要研究方向为智能车辆决策、驾驶行为分析.

葛亮(1983–), 男, 博士, 高级工程师, 主要研究方向为测绘与遥感.