



小样本雷达辐射源识别的深度学习方法综述

苏丹宁, 曹桂涛, 王燕楠, 王宏, 任赫

引用本文

苏丹宁, 曹桂涛, 王燕楠, 王宏, 任赫. 小样本雷达辐射源识别的深度学习方法综述[J]. 计算机科学, 2022, 49(7): 226-235.

SU Dan-ning, CAO Gui-tao, WANG Yan-nan, WANG Hong, REN He. Survey of Deep Learning for Radar Emitter Identification Based on Small Sample [J]. Computer Science, 2022, 49(7): 226-235.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

一种用于癌症分类的两阶段深度特征选择提取算法

Two-stage Deep Feature Selection Extraction Algorithm for Cancer Classification

计算机科学, 2022, 49(7): 73-78. <https://doi.org/10.11896/jsjkx.210500092>

基于多路径特征提取的实时语义分割方法

Real-time Semantic Segmentation Method Based on Multi-path Feature Extraction

计算机科学, 2022, 49(7): 120-126. <https://doi.org/10.11896/jsjkx.210500157>

中文预训练模型研究进展

Advances in Chinese Pre-training Models

计算机科学, 2022, 49(7): 148-163. <https://doi.org/10.11896/jsjkx.211200018>

基于主动采样的深度鲁棒神经网络学习

Robust Deep Neural Network Learning Based on Active Sampling

计算机科学, 2022, 49(7): 164-169. <https://doi.org/10.11896/jsjkx.210600044>

指静脉识别技术研究综述

Survey on Finger Vein Recognition Research

计算机科学, 2022, 49(6A): 1-11. <https://doi.org/10.11896/jsjkx.210400056>

小样本雷达辐射源识别的深度学习方法综述

苏丹宁¹ 曹桂涛¹ 王燕楠¹ 王 宏² 任 赫²

1 华东师范大学软硬件协同设计技术与应用教育部工程研究中心 上海 200062

2 中国电子科技集团第五十一研究所 上海 201802

(iranus@163.com)

摘要 面对复杂多变的电磁环境与新体制雷达系统,传统的雷达辐射源识别方法已无法满足需求。深度学习模型可有效提取雷达信号的脉内特征,快速准确地对低信噪比、未经分选的雷达辐射源信号进行脉内调制类型识别、型号识别与个体识别。但真实环境中雷达辐射源信号难以收集,无法满足传统的深度学习训练需要,因此小样本雷达辐射源识别是目前研究的热点与难点。文中首先对近年来将基于监督学习的多种经典深度学习方法应用于小样本雷达辐射源识别的研究进行了回顾;其次,介绍了小样本学习在雷达辐射源识别领域的研究进展;最后,基于小样本雷达辐射源识别的研究现状,总结面临的挑战,提出了对未来研究方向的展望。

关键词: 雷达辐射源识别;深度学习;小样本;脉内特征

中图法分类号 TP181

Survey of Deep Learning for Radar Emitter Identification Based on Small Sample

SU Dan-ning¹, CAO Gui-tao¹, WANG Yan-nan¹, WANG Hong² and REN He²

1 East China Normal University MoE Engineering Research Center of SW/HW Co-design Technology and Application, Shanghai 200062, China

2 China Electronics Technology Group Corporation No. 51 Research Institute, Shanghai 201802, China

Abstract Traditional radar emitter identification methods can no longer meet the needs of identifying new-system radar emitters in the complicate and changeable electromagnetic environment. Deep learning methods can effectively extract the intra-pulse features of the unsorting radar emitter signal, quickly and accurately identify the radar intra-pulse modulation type, model type and emitter individual under complex environments such as low signal-to-noise ratio. However, in the reality, radar emitter signal is difficult to collect and cannot satisfy the training needs of traditional deep learning models. Therefore, the small sample radar emitter identification is one of hotspot and difficult questions of current research. Firstly, this paper reviews the research progress and application of various deep learning methods based on supervised learning for radar emitter recognition with small samples in recent years. Secondly, the research progress of radar emitter identification by small sample learning is introduced. Last, according to the current radar emitter identification research, the challenges and outlook for future research are put forward.

Keywords Radar emitter identification, Deep learning, Small sample, Intra-pulse feature

1 引言

随着数字集成电路技术的发展,气象雷达、安防雷达、涵盖海陆空的交通类雷达等民用雷达为人们的生活提供了极大的便利。但是,随着新体制雷达的广泛应用,电磁环境愈发复杂,因此识别雷达辐射源的任务也愈发艰巨。新体制雷达信号中包含着较丰富的脉内特征信息,但是雷达信号复杂多变,往往难以获得大量、高质量的标注样本。深度学习模型具备强大的特征提取与学习能力,能从有限的样本中充分提取特征,因此将深度学习方法引入小样本雷达辐射源识别领域成为了目前学术界和工业界热门的研究方向。

雷达辐射源识别指将接收到的雷达信号进行特征提取等处理,与已有数据库中积累的雷达信号特征进行匹配,以此判别该雷达信号所属辐射源的过程。当前,基于脉内特征的雷达辐射源识别任务主要分为两类。一类是雷达辐射源识别(Specific Emitter Identification, SEI),来自不同雷达辐射源的脉冲信号中隐含无意调制特征,也称为指纹特征^[1],通常为雷达辐射源设备自身具有的固有特征。通过分析雷达信号,提取雷达辐射源设备的指纹特征,从而实现对雷达辐射源的鉴别^[2]。另一类是雷达辐射源信号调制识别,经幅度调制、频率调制、相位调制或混合多种调制方法,人为地在雷达脉冲信号中加入调制特征,该特征也被称为有意调制特征^[3]。早期

到稿日期:2021-06-17 返修日期:2021-10-17

基金项目:国家自然基金科学面上项目(61871186)

This work was supported by the National Natural Science Foundation of China(61871186).

通信作者:曹桂涛(gtcao@sei.ecnu.edu.cn)

进行雷达脉冲分选识别的方法主要有相似系数法、模糊匹配、聚类、支持向量机、专家系统等方法^[4]。

深度学习是基于人工神经网络的机器学习算法,由 Hinton 等^[5]于 2006 年提出。经过数年的发展,各类深度学习算法以强大的特征提取能力、丰富的数据信息表达能力和很强的泛化性,在计算机视觉、自然语言处理、语音识别等多个领域内获得了突破性的进展。在雷达中的目标识别领域,深度学习对于合成孔径雷达图像、高分辨距离图像等已经有成熟的应用。对于雷达辐射源识别任务,可通过深度学习方法在大量的有标注数据集上进行离线训练,针对早期方法无法提取雷达辐射源信号脉内特征的问题,训练出自动、有效的雷达信号特征提取器,免去了繁琐的人工筛选特征,简化了雷达脉冲分选的流程,在线识别不同雷达辐射源,

实现工程上的端到端应用。

对于真实环境中的实测雷达信号数据,由于新体制雷达变化丰富、电磁环境拥挤密集、信号易被干扰且难以捕获等问题,无法收集足量的训练数据;又由于领域的特殊性,缺乏公开的数据集。而深度学习的优势与大数据关系紧密,且模型对数据的需求量会随着模型规模与数据复杂度的增大而增大,不完备的训练数据会将过拟合、欠拟合等问题引入深度学习模型。大多数雷达辐射源识别任务的实验数据为每类雷达辐射源信号为 100~1000 条左右,类别平均为 6~12 类,相比其他领域的公开数据集差之甚远,如图像分类领域包含约 1420 万张图片的 ImageNet 数据集^[6],因此现有的雷达辐射源识别任务面临着小样本的挑战。通用的基于深度学习方法的小样本雷达辐射源识别框架如图 1 所示。

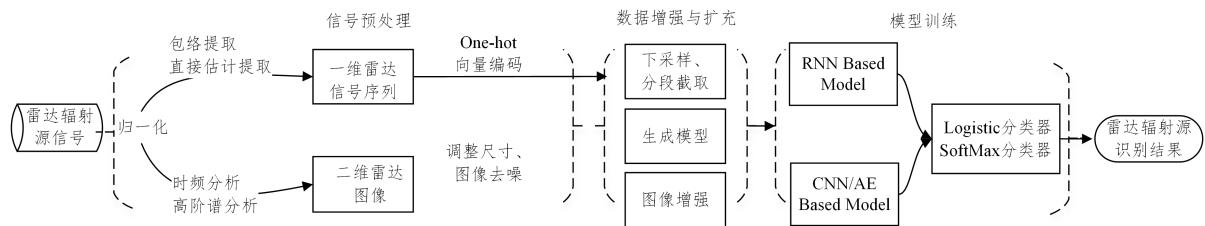


图 1 基于深度学习方法的小样本雷达辐射源识别流程图

Fig. 1 Flow chart of small sample radar emitter identification based on deep learning method

近年来,基于深度学习方法的雷达辐射源识别任务的识别效率、准确度有了大幅提升,并且促进了信号特征分析、电子侦察等领域的发展。由于深度学习领域发展迅速,早期的综述文章^[7-11]未能涵盖各类深度学习方法在雷达辐射源识别方面的应用,本文在上述工作的基础上,从小样本的角度对近年来的雷达辐射源识别任务进行了归纳与整理。本文的主要贡献有:1)介绍了常见的雷达信号特征提取方法,以及小样本条件下的数据增强与数据扩充方法;2)梳理了多种基于监督学习的深度学习方法在雷达辐射源识别领域中的研究与应用;3)探究了小样本学习在雷达信号辐射源识别方面的研究进展;4)对比、总结了各类深度学习方法的效果与优缺点,提出了当前小样本条件下深度学习在雷达辐射源识别领域的应用面临的问题及对未来研究的展望。本文架构如图 2 所示。

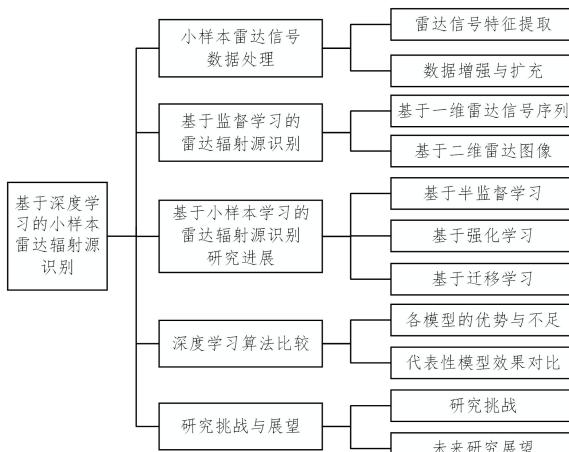


图 2 论文整体架构图

Fig. 2 Overall structure of this paper

2 小样本雷达信号数据处理

当前的雷达辐射源识别研究的数据主要来源于计算机仿真的雷达辐射源调制信号或是从已有的雷达辐射源中采集的,雷达辐射源信号在输入深度神经网络前,需要针对不同的模型进行相应的向量化预处理,并且在小样本条件下,需要对有限的标注数据进行增强、扩充等处理。

2.1 一维雷达信号序列特征提取

通常接收到的雷达信号样本为时域上的一维雷达信号序列,利用深度学习模型的序列建模能力,如通过循环神经网络中的记忆力模块捕获一维连续序列的上下文信息,即雷达信号序列中的时序特征,进行信号特征提取。

2.1.1 包络曲线特征提取

信号包络能呈现出雷达信号个体在变化时的细微时域特征,表现为时间上不同的瞬时信息,如脉冲的上升沿、下降沿与脉宽等^[12]。信号处理中常用的包络提取方法有复调制法、全波整流法、希尔伯特变换法等。由于雷达辐射源信号包络对噪声、多径效应等干扰敏感,需要降噪处理,因此通常配合滤波器应用^[13]。

2.1.2 无意调幅/调频/调相曲线特征提取

脉内的瞬时频率、瞬时相位及瞬时幅度可反映雷达信号的指纹特征,由于其计算量小且易于实现,工程应用中常通过直接估计脉内瞬时幅度、瞬时频率、瞬时相位来提取无意调幅、调频、调相(UAMOP/UFMOP/UPMOP)特征曲线,将这些曲线作为辐射源个体信号特征进行雷达辐射源识别^[14-16]。由于瞬时频率与瞬时相位函数之间成正相关,因此无意调频与无意调相曲线特征往往不同时使用^[17]。通常可以直接求得信号的瞬时幅度、瞬时频率、瞬时相位序列,或利用 Wigner

分布法、小波变换法等,再通过时域加窗平滑或者小波压缩等方式对特征曲线进行降噪处理,以得到更为精确的特征描述。

2.2 二维雷达图像特征提取

为了充分发挥卷积神经网络、自动编码器等深度学习模型在图像特征提取方面的优势,需要在预处理阶段将雷达信号处理为无损且易于卷积计算的数字图像,较普遍的做法是将雷达信号经过时频分析、高阶谱分析^[18]等方法处理为二维雷达图像,同时可使用多种图像处理的方法,如图像尺寸调整、图像滤波去噪、灰度二值化等操作,将二维雷达图像输入卷积神经网络或自动编码器进行特征提取,从而实现分选识别。

2.2.1 时-频特征提取

在数字信号分析中,时间和频率是两个关键的物理量,并且信号的时域与频域密切相关,时频分析方法可从二维时频空间精确描述雷达辐射源个体信号,使得信号个体的时频特征差异最大化,适用于分析非平稳信号。常见的时频分析方法有:1)线性时频分析,如短时傅里叶变换、小波变换等;2)双线性时频分析,如 Wigner-Ville 分布、Choi-Williams 分布等。

短时傅里叶变换的原理是将原始信号加窗,划分为多个小区间,在每一个时间区间内应用傅里叶变换,计算该区间的频率。 $g(t)$ 为窗函数,设雷达辐射源信号为 $s(t)$,连续短时傅里叶变换定义为:

$$STFT_s(t, \omega) = \int_{-\infty}^{+\infty} [s(\tau)g * (\tau-t)]e^{-j2\pi\omega\tau} d\tau \quad (1)$$

小波变换改进了短时傅里叶变换中窗口大小固定的局限,其核心思想为小波基函数,可随频率调节时间窗口,能同时体现信号的时域和频域的局部特性, a 和 b 为尺度因子,小波变换定义为:

$$WT_s(a, b) = a^{-\frac{1}{2}} \int_{-\infty}^{\infty} h^* \left(\frac{t-b}{a} \right) s(t) dt \quad (2)$$

Choi-Williams 分布(Choi-Williams Distribution, CWD)属于 Cohen 类时频分布方法^[19],用于描述能量密度分布,CWD 能准确体现时变频谱特征,适用于非平稳信号,其定义为:

$$CWD_s(t, \omega) = \iint_{-\infty}^{\infty} \sqrt{\frac{\sigma}{4\pi\tau^2}} \exp \left[-\frac{(t-\mu)^2}{4\tau^2/\sigma} \right] \left(\mu + \frac{\tau}{2} \right) x^* \begin{pmatrix} x \\ \mu - \frac{\tau}{2} \end{pmatrix} e^{-j\omega\tau} d\mu d\tau \quad (3)$$

2.2.2 高阶谱特征提取

高于二阶的累积量被称为高阶累积量,其多维傅里叶变换为高阶谱。运用高阶谱的方法,可有效提取信号的谱特征。双谱,也称为三阶累积量的光谱,定义为:

$$B_x(\omega_1, \omega_2) = \sum_{\tau_1=-\infty}^{\infty} \sum_{\tau_2=-\infty}^{\infty} c_{3x}(\tau_1, \tau_2) e^{-j(\omega_1\tau_1 + \omega_2\tau_2)} \quad (4)$$

功率谱与自相关函数基于实数,缺少信号的相位信息,而双谱函数对应复数值,包含信号的相位、幅值双重信息^[20]。并且,双谱是一个具有多重对称性的二维周期函数,可划分成 12 个对称区间,因此只要得到其中一个区间的双谱分布,即可描述出所有区间的双谱。对信号进行双谱估计后得到的是一个三维矩阵,计算量大且复杂度高。为了降低计算复杂性,防止维数爆炸等问题,通常利用对角化、奇异值分解、Walsh 变换等方法对双谱矩阵进行化简。通过双谱分析得到的信号

双谱特征具有尺度缩放不变、时移不变、相位保持等特性^[21],文献[22]证明了双谱分析能有效提取雷达信号的个体特征,并且能在一定程度上抑制高斯噪声、杂波等产生的影响。

2.3 小样本条件下的雷达辐射源数据增强

小样本雷达辐射源信号面临着实测数据不足甚至缺乏的问题,而深度学习模型的训练基于大量有标注的训练样本,故通常需要对雷达辐射源信号数据进行数据增强与数据扩充。

小样本雷达辐射源识别任务中传统的数据增强方法为对信号添加高斯白噪声、多径效应等处理,模拟生成不同干扰条件下的雷达信号。对于一维雷达信号序列,可进行过采样、下采样、分段截取等操作,增加训练集数量与增强模型鲁棒性。对于二维雷达图像,通过维纳滤波器等方式过滤噪声,从而达到数据增强的效果^[23-24]。此外,还可以运用深度生成模型生成接近真实样本分布的辅助样本,主要有生成对抗网络(Generative Adversarial Network, GAN)、变分自动编码器(Variational Auto Encoder, VAE)等。GAN 不仅可以扩充数据集,还可生成新特征,达到特征增强的效果,在标注数据量不足的情况下,利用 GAN 等生成模型可提升模型对新样本的识别能力^[25]。

3 基于监督学习的小样本雷达辐射源识别

3.1 基于一维雷达信号序列特征的雷达辐射源识别

循环神经网络^[26](Recurrent Neural Network, RNN)是一种在层内神经元之间也建立连接的神经网络,其输出与当前时间步的输入和上一时间步的输出有关,能解决训练样本输入为连续序列且序列的长短不一致的问题,常用于时间序列预测、机器翻译、自动驾驶等。然而,RNN 处理信号之间复杂的时空变化的能力相对较弱,因此产生了增加门控机制的长短期记忆网络(Long Short-Term Memory, LSTM)以及 GRU(Gate Recurrent Unit)等^[27]。LSTM 中包含输入门、遗忘门和输出门,它们类似闸门,用于控制神经网络内的信息流动,让神经网络在学到必要的信息后自动遗忘一些旧的信息,以有效地解决训练中梯度消失的问题,并更易于学习到序列中的长期依赖。基本的基于 RNN 模型的结构如图 3 所示。

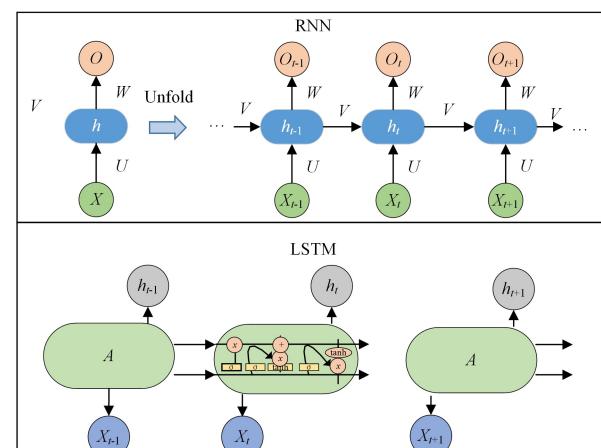


图 3 RNN Based 模型的结构图

Fig. 3 Structure of RNN Based models

循环神经网络模型中的记忆力机制适用于建模一维雷达

信号序列特征,Bagwe 等提出了一种将 LSTM 模型与小波变换相结合的模型,Harr 小波变换对嘈杂环境中的雷达信号进行降噪,LSTM 输出的预测雷达信号序列可被识别,证明了 LSTM 可较好地表达和提取一维雷达信号序列特征^[28]。Zheng 等将双向长短时记忆网络(Bidirectional Long Short-Term Memory,Bi-LSTM)应用于雷达信号脉内调制类型识别,Bi-LSTM 利用两个方向相反的隐藏层连接到同一输出,可以同时捕获时间序列中过去与将来状态的信息,多层的 Bi-LSTM 模型具有了更强的特征学习和表达能力,仅需输入原始的雷达信号采样数据,就可自动提取到区分性较强的特征^[29]。一般来说,一维雷达信号序列中仅包含时域信息,缺少非平稳信号的非线性变化表达。Qin 等采用贝塞尔平滑方法对脉内无意调相特征曲线进行降噪,结合多层适用于提取时间序列特征的 LSTM 和全卷积网络,可以从不同角度提取到无意调相序列的时序特征^[30]。

3.2 基于二维雷达图像特征的雷达辐射源识别

3.2.1 自动编码器

自动编码器^[31](Auto Encoder,AE)神经网络属于无监督学习,学习输入数据的有效表征。自动编码器由编码器和解码器两部分组成,它通过对输入特征 X 按照一定规则及训练算法进行编码,将其原始特征利用低维向量重新表示,自动编码器模型可以实现数据降维、特征提取、数据去噪、图像压缩等功能。针对不同的任务,常用的自动编码器有层级自动编码器(Stack Auto Encoder, SAE)、稀疏自动编码器(Sparse Auto Encoder, sAE)^[32]、降噪自动编码器(Denoising Auto Encoder, DAE)^[33] 和卷积自动编码器(Convolution Auto Encoder, CAE)^[34] 等。几种常用的 AE 基本结构如图 4 所示。

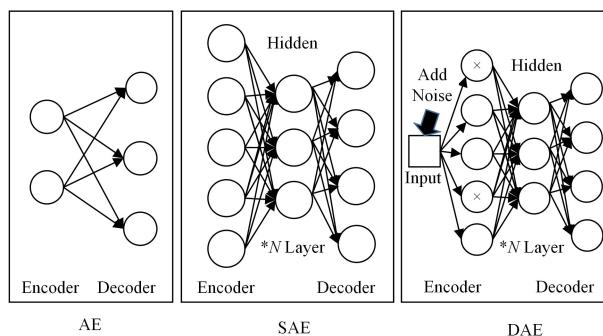


图 4 部分 AE Based 模型的结构图

Fig. 4 Some structure of AE Based models

由于依靠人工经验提取雷达辐射源特征的传统方法有一定的局限性,Zhou 等设计了基于多层自动编码器的雷达辐射源识别算法,该算法智能化地逐层级地提取雷达辐射源的深层特征,且为了减小计算量,利用随机投影与主成分分析的方法进行联合时频降维,证明了深度学习方法可高效准确地完成雷达辐射源自动识别任务^[35]。针对低截获概率(Low Probability of Intercept,LPI)雷达信号特征提取困难的问题,Guo 等和 Zhang 等利用了多层次稀疏自动编码器(Stack Sparse Auto Encoder, sSAE),sSAE 在 SAE 的基础上增加了稀疏惩罚项,可更好地表达训练数据集的统计特征,具有更强的表征学习能力,在低信噪比的环境下取得了更好的识别效果^[36-37]。

变分自动编码器是一种结合了贝叶斯概率图的生成网络,其编码器可输出描述潜在空间不同纬度分布的参数,Gao 等利用 VAE 生成的雷达信号时频图像的隐层变量特征,具有更强的抗噪能力和样本个体特征表达能力^[38]。

自动编码器不仅能有效地提取雷达信号的深层特征,其降噪能力可以增强复杂电磁环境中的雷达辐射源识别能力。降噪自编码器通过在编码器中增加人工噪声,使得模型提取到的数据更鲁棒,实现了去除噪声的效果。Zhou 等结合 DAE 和受限玻尔兹曼机(Stacked Restricted Boltzmann Machines, RBMs),DAE 能有效地将数据映射到高维空间,提高数据的可分性,两层的 RBM 模型从 DAE 的输出中提取深层特征,两者相结合的混合模型能够更好地分层提取输入数据的固有特征,并且抵消输入数据中的噪声^[39]。针对多径信道干扰的问题,Kong 等将 DAE 作为盲均衡器,减轻了多径衰落信道对雷达信号的干扰,利用傅里叶同步压缩变换(Fourier Synchro-squeezing Transform, FSST)表达其相位信息,以更详细地表达雷达信号波形中的细微特征^[40]。

3.2.2 卷积神经网络

传统的神经网络是由神经元连接组成的,随着网络参数的增多,计算复杂度也随之增加。卷积神经网络(Convoluted Neural Networks, CNN)利用卷积计算,能够处理具有清晰网格结构拓扑的数据,并且这样的模型结构能扩展至非常大的规模。卷积神经网络主要包含卷积层、池化层和全连接层。卷积层可有效地提取图像特征;池化层对图像进行下采样,对数据降维,提高了运算速度;全连接层将特征整合,变换维度后输入分类器。随着深度学习理论的进步,卷积神经网络在机器视觉、目标检测等领域的应用发展迅速,结构日益丰富,具有代表性的 CNN 算法有 AlexNet^[41], ZFNet^[42] VG-GNet^[43], GoogLeNet^[44] 和 ResNet^[45] 等。基于 CNN 的基本结构如图 5 所示。

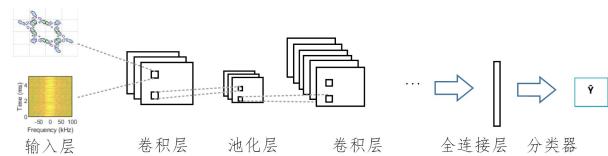


图 5 CNN Based 模型结构图

Fig. 5 Structure of CNN Based models

Wang 等首先将 CNN 用于雷达辐射源识别,用时频分析产生时频图像(Time Frequency Image, TFI),通过图像处理中的滤波器、双线性插值等技术抑制雷达时频图像中的噪声,将 CNN 自动提取的特征直接用于雷达波形识别,取得了良好的识别效果,并且有较强的泛化能力^[23]。Liu 等设计了一个简单的雷达通信系统,论证了与传统的机器学习方法反向传播、支持向量机相比,卷积神经网络在低信噪比条件下具有更强的识别能力^[46]。

基于 TFI-CNN 的雷达辐射源识别框架被广泛应用,并且随着硬件计算能力的提升,卷积神经网络逐渐向更深和更宽的趋势发展。针对相对于图像数据,雷达信号图像种类和样本较少、结构相对简单、在 DCNN 中易过拟合的问题,Li 减小了原始的 VGG-16 的深度,加入了 Dropout 层,相比原始

VGGNet 缩短了训练时间并取得了更好的效果^[47]。Wang 等利用 GoogLeNet 模型的 Inception 结构提取信号特征^[48], Shi 等选用了 ResNet 模型, 其残差模块可以有效解决网络深度增加所引起的梯度消失问题和退化问题^[49]。Si 等和 Cai 等利用以前馈的方式进行层连接的 Dense CNN, 增强了特征传播能力^[50-51]。SENet^[52]通过挤压和激励网络的操作, 能显式地建模特征通道之间的相互依赖关系, Qu 等和 Wei 等利用 SENet, 将雷达信号的时域、频域与时频域各作为一个特征通道输入, SENet 可自动提取信号中相对重要的通道特征, 融合转换后的多域特征进行识别^[53-54]。

除了针对模型的改进, 另一个改进的思路是利用卷积神经网络提取雷达信号的时频图像以外的特征。Wang 等将雷达辐射源中包括上升沿、稳定沿与下降沿的脉冲波形图像作为输入^[55]。Akyon 等提出的 FF-CNN(基于特征融合的卷积神经网络)采用 RSTFT 预处理雷达脉冲, 将数据输入到由两个卷积神经网络组成的组合深度网络结构, 融合网络自动提取的特征, 以区分频率和相位调制信号^[56]。Wang 等将 IQ 分量以双通道的形式输入到卷积神经网络中, 双通道的卷积神经网络构成了多尺度接受场, 其中的深通道与浅通道使用不同大小的滤波器提取不同比例的信号局部特征^[57]。为了增强识别性能, Nguyen 等提出了并行神经网络, 将接收到的雷达脉冲描述字与 IQ 分量以并行的方式输入子网络, 以期将辐射源的指纹特征完全输入模型^[58]。在实际信号环境中, 由于采样点的数量有限, 时频分析的加窗函数的频率特性会引起频谱泄漏, 通过双谱分析可以保留更多有用的频率分布信息。Li 等将能较好地保持频率与其分布信息的振幅双谱图输入改进的 AlexNet^[59]。Gao 等提取雷达辐射源信号的模糊函数切片特征, 将其作为输入, 并采用了三层卷积神经网络, 其识别效果优于 SVM、极限学习机(Extreme Learning Machine, ELM)和基于深度强化学习的深度 Q 网络模型(Depth Q Network, DQN)^[60]。

对于包含多个脉冲的雷达信号图像, 常规的 CNN 无法进行有效识别, 学者们引入了图像识别领域中目标检测的方法, 在时域重叠的脉冲图像中定位某个区域的单个脉冲, 并将其用于雷达辐射源识别。Zheng 等将目标检测中常用的基于区域的卷积神经网络(Faster Region with Convolutional Neural Network, Faster R-CNN)框架用于调制信号的识别与参数提取^[61]。Hoang 等利用单镜头多框检测的通用模型 SSD(Single Shot MultiBox Detector, SSD)或 YOLO(You Only Look Once, YOLO), 在包含几个连续周期的雷达时频图像中对雷达辐射源信号进行定位和分类^[62]。由于信号处理系统会收到不同的接收器有意或无意的干扰, 导致雷达图像中同时存在多种类型的雷达辐射源复合信号, Zhu 等和 Pen 等设计了基于 CNN 的多标签学习框架, 多标签分类器将每个可能的信号调制类型作为候选标签, 对于信号重叠的情况实现信号的分离与识别, 并且复合调制信号识别可对数量有限的信号组合进行训练, 增强模型识别未知信号组合的可扩展性^[63-64]。

3.2.3 集成学习模型

集成学习模型通过协同多个子网络, 提取雷达图像中

不同视角的特征信息, 将各深度学习方法取长补短, 集成使用, 可提升识别性能, 具有广阔的研究前景。Ming 等提出了一种混合分类器, 该分类器包含两个相对独立的子网络, 即卷积神经网络和艾尔曼神经网络^[65]。Kong 等结合 AE 的降噪能力与 CNN 的图像识别能力, 可提升低信噪比环境下的雷达辐射源识别效果^[40, 66-67]。

利用 CNN 提取雷达波形特征时, Wang 等引入 Bi-LSTM 融合两个通道的特征, 能更好地利用时域信号的时间相关性^[57]。Wei 等提出了卷积长短记忆深度神经网络(Convolution Long Short-term Memory Deep Natural Network, CLDNN), 其中 3 个浅层 CNN 分别提取原始信号序列的时域、频域和自相关域的信息, 再将这些信息输入 LSTM 层提取长程特征。该集成神经网络能协同卷积神经网络的局部特征提取能力与循环神经网络的全局序列建模能力, 利用长短时记忆网络建模经卷积神经网络提取到的高维特征的时序特征, 从而增强雷达辐射源识别系统的效果^[24]。Cui 等在 CLDNN 的基础上进行了改进, 选用了参数更少的一维卷积神经网络与能双向提取特征的 Bi-GRU 提取雷达序列的浅层特征, 并结合注意力机制聚焦 DNN 提取的某些重要的深层特征, 进一步加快模型的识别速度^[68]。

4 基于小样本学习的雷达辐射源识别研究进展

第 3 节介绍了雷达辐射源识别研究多为基于监督学习的深度学习方法, 由于在小样本条件的限制下, 深度学习方法面临着泛化能力有限、鲁棒性不足、缺乏反馈机制、对未知雷达辐射源类别识别能力失效等问题, 结合半监督学习、强化学习、迁移学习的思想, 有助于提高小样本条件下深度学习方法对雷达辐射源信号的表达能力和识别能力。

4.1 半监督学习

半监督学习基于大量的未标注数据与少数的标注数据, 服从独立同分布, 将未标注数据与有标注数据有机结合, 让模型从成本较低的未标注数据中充分学习, 其针对现实的小样本雷达辐射源识别任务有良好的应用场景。首先采用深度学习模型通过无监督自学习的方式, 在大量的未标注样本中自动挖掘数据特征, 训练出一个有效的特征提取器, 再将其用于提取小样本的训练数据的特征, 以辅助训练深度学习模型, 该方法也被称为弱监督学习。半监督学习的方法能有效改善无监督学习准确率低的问题, 并且对小样本条件下的监督学习模型易过拟合、鲁棒性不足等问题有所改进。

雷达辐射源识别任务中, 较常见的半监督学习方式是利用自动编码器, 在未标注的雷达信号上自动提取特征并对特征向量进行降维, 配合少量标注的数据进行模型微调。Zhou 等使用层级自动编码器在未标注的雷达信号上训练构造联合时频特征学习模型^[35]。Huang 等利用多层次降噪自动编码器提升模型应对低 SNR 条件下雷达信号失真的情况^[69]。Zhou 等以无监督的方式训练卷积去噪自动编码器(Stack Convolution Denoising Auto Encoder, SCDAE), 再将预训练得到的模型参数用于 CNN 的初始化, 半监督的方式训练得到的 SCDAE 模型通过构造协同特征提取器, 降低了对样本数量的要求^[67]。

4.2 强化学习

强化学习(Reinforcement Learning, RL)的基本思想是模仿人类学习过程中的试错过程,让智能体与环境交互,利用奖励机制让强化学习系统依靠自身的经历进行学习,寻找出最优决策。强化学习的一个广为人知的应用是 DeepMind 的 ALPHAGO^[70],通过结合已有棋局的有监督学习与自玩游戏的强化学习,ALPHAGO 在围棋游戏中胜过了人类。强化学习基于马尔可夫决策过程(Markov Decision Process, MDP),仅通过智能体自身的行为去学习,由环境提供的反馈对产生的动作进行评价,智能体再依据新的环境状态与当前策略作出新的决策。强化学习由于在复杂的非线性系统中具有良好的学习性能,常被应用于任务调度、智能控制、游戏等领域^[71],能在弱监督条件下训练出最佳的识别策略,适用于雷达辐射源识别领域缺少完备数据集的情况。经典的强化学习过程如图 6 所示。

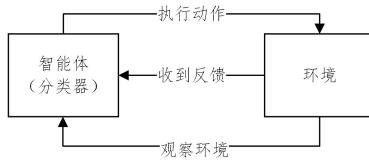


图 6 强化学习过程图

Fig. 6 Process of reinforce learning

深度强化学习决策模型通过模型的分类正确与否得到反馈,因此能利用少量样本实现对识别模进行强化训练。Leng 等将 CNN 提取的辐射源信号包络前沿特征作为输入状态,该输入状态的可选动作即为不同的辐射源类别,多次迭代拟合 Q 值函数,寻找可执行最优先选择动作的分类器^[72]。为了提高脉冲重叠环境下识别系统的成功识别概率,Qu 等利用深度强化学习 Q-Learning 网络自动调整预训练过的 CNN,基于 RNN 架构搭建了多标签分类网络,可对某些特定信号的识别结果进行重新判断,提升了对双分量雷达信号的识别率^[73]。

4.3 迁移学习

迁移学习通过复用现有的知识或模型来解决不相同但相关领域的问题,当训练集和测试集的数据不符合独立同分布条件时,迁移学习可以修正源域与目标域的分布差异,使模型具有更强的泛化性。深度学习网络通过多层矩阵转换和抽象进行特征提取,提取到的特征会从一般性特征过渡到具有类别特定性。一般来说,模型的层数越高,其提取到的特征越具有类别特定性。深度学习模型的拟合能力与健壮性往往无法兼得,雷达信号经不同的传感器接收会带来数值分布上的不同,当训练集与测试集之间的数据分布存在较大差异时,在训练集上训练出的分类器对于测试集的数据的适应性将大幅下降。迁移学习能较好地提高分类器的跨域识别能力,降低了对新领域任务数据集的数量要求与训练复杂度,复用现有知识域的数据,可对新的数据实现快速迁移与应用。迁移学习的策略可以较好地结合弱监督的机器学习,是一个开展小样本条件下未知雷达辐射源识别研究的思路。

真实环境下采集的雷达样本存在特征缺失、信息模糊或畸变等问题,且与数据库中的雷达辐射源特征参数有一定的区别,基于不需要直接估计域分布就能修正域间差异的 BRSD 算法,Li 等利用数据分布结构发现与样本再平衡的

迁移学习方法训练分类器,将具有分布差异的训练集与待识别样本进行基于密度的 DBSCAN 聚类,生成再平衡后的训练样本,提高模型在目标域数据中的泛化能力^[74]。为了增强模型对未知雷达辐射源的识别性能,需要降低模型对先验信息的依赖,Ran 等选用联合分布自适应方法(Joint Distribution Adaptation, JDA)来减小先验知识库与未知雷达信号之间的分布差异。JDA 使用最大均值差异(Maximum Mean Discrepancy, MMD)来估计域之间的分布差异,将少量有标注的源域数据与无标签的目标域数据映射到同一个隐藏空间,用弱分类器 SVM 迭代优化模型,使模型能同时适配两个不同的分布,有效提高了基于现有知识库的算法对未知雷达信号的识别能力^[75]。

迁移学习(Transfer Learning, TL)的另一种应用是在大型数据集上训练源网络,对目标小数据集进行参数传递,重新训练目标网络,适用于解决目标域数据集缺乏的问题。为了解决无源雷达无法在信号空间采样一个完备的数据集的问题,Wang 等运用迁移学习技术中的参数传递,将源域网络参数用于初始化目标域分类器,以提高模型对不同采样率雷达信号的适应性^[57]。Wang 等和 Si 等选用在大规模数据集 ImageNet 上预训练好的卷积神经网络,保存部分预训练的参数,仅需要在雷达信号时频图像的小数据集上微调就可实现迁移^[48,50]。迁移模型参数时,由于目标域数据集有限,深度 CNN 在小数据集上易过拟合,Xiao 等利用微调过的深层 CNN 提取的特征,将其与浅层 CWD 图像纹理特征相融合,解决了过拟合以及浅层 CNN 中图像深度特征不足的问题^[76]。

5 深度学习算法的比较

5.1 深度学习方法优劣势分析

深度学习模型对数据有很强的依赖性,因此常根据样本数据的类型选择相应的模型。一维雷达信号序列中具有更显著的时序上下文相关性,而二维雷达图像中包含更多全局信息与信号的频域变换等信息。对于原始的一维的雷达信号序列,一般选用基于 RNN 的序列模型对其建模,提取雷达信号内包含的长程依赖信息;而对于时频图、高阶谱图等二维雷达图像,则选用 CNN、AE 等模型提取高维特征。不同深度学习模型的优势及局限性如表 1 所列。

表 1 不同深度学习模型的优势及局限性

Table 1 Advantages and limitations of different deep learning models

神经网络	输入	优势	局限
RNN/LSTM Model	一维雷达信号序列	可输入不定长信号,获取时序信息,识别耗时短	参数较多,收敛速度较慢,易过拟合
CNN Model	二维雷达图像	信号特征方式丰富,对信号平移不变性要求低	预处理复杂、耗时,输入长度固定,计算成本高
Auto Encoder Model	二维雷达图像	适用于无标注、不完整信号,可用于降噪、降维	训练时间成本高,识别效果受图像质量影响
Hybrid Model	二维雷达图像、高维特征向量	精度高,融合多种特征,应用前景广阔	模型复杂,训练时间较长

5.2 代表性模型识别性能对比

由于雷达辐射源识别领域缺乏公开数据集和统一评估标准,本文仅选取具有代表性的基于深度学习的雷达辐射源

识别方法进行对比,其主要方法、识别信号类型、预处理方式

及识别准确率等如表 2 所列。

表 2 部分典型基于深度学习的雷达辐射源信号识别工作
Table 2 Some typical radar emitter signal recognition based on deep learning

Related Work	Proposed Time	Method	Signal Type	Preprocessing	Accuracy
Qu et al. ^[66]	2019-08	DCNN, CDAE	LFM, SFM, 2FSK, 4FSK, DLFM, EQFM, MLFM, BPSK, Frank, MP, LFM-BPSK, 2FSK-BPSK.	CTFD TFI	90%(-9 dB) 100%(-7 dB+)
Wei et al. ^[54]	2020-03	CNN, ACSE, SVM	BASK, BFSK, BPSK, CW, SFW	Multidimensional feature matrix	93%(-10 dB)
Si et al. ^[50]	2020-09	CNN, TL	2FSK, 4FSK, BPSK, EQFM, Frank, LFM, NA, SFM	CWD TFI	93.4%(-8 dB) 100%(0 dB+)
Zhou et al. ^[35]	2017-06	RP, PCA, sAE	CP, LFM, NCFM, BPSK, BFSK, QFSK	STFT TFI	88%(-3 dB) 97.1%(0 dB)
Guo et al. ^[36]	2018-04	sSAE	LFM, BPSK, Costas, Frank, T1, T2, T3, T4	CWD TFI	96.4%(-6 dB) 100%(-2 dB+)
Zheng et al. ^[29]	2019-01	Bi-LSTM	CW, LFM, VFM, FSK, BSPK, QPSK	One-dimensional radar sequence	90%(-3 dB) 95%(-1 dB)
Qin et al. ^[30]	2020-05	LSTM-FCN	Signals simulated by radar emitter	Radar sequence	88.57%
Leng et al. ^[72]	2018-12	CNN, RL	Individual radiation source collected by reconnaissance equipment	Radar signal envelope	98.42%
Wei et al. ^[24]	2019-12	CNN, LSTM, DNN	BFSK, BPSK, CW, LFM, NLFM, QPSK	Radar sequence in multi domain	90%(-6 dB) 100%(2 dB+)
Cui et al. ^[68]	2020-09	CLDNN, Attention	BPSK, Costas, Frank, P1, P2, P3, P4	Radar sequence in time domain	69%(-12 dB) 100%(-12 dB)
Qu et al. ^[73]	2020-03	CNN, RNN, RL	LFM, MP, SFM, BPSK, 2FSK, 4FSK, EQFM, Frank	CTFD TFI	94.83%(-6 dB)

6 研究挑战与展望

6.1 研究挑战

尽管利用深度学习使雷达辐射源识别任务的特征提取流程得以简化,识别准确率得到提升,但由于如下挑战,深度学习在雷达辐射源识别领域依然存在一定的局限性。

6.1.1 实测数据缺乏

深度神经网络的训练,往往需要依托大量高质量的标注数据,由于雷达领域的特殊性,雷达的波形设计与分选识别是矛与盾的关系,难以获取到足量有标注的训练数据,当前大多数研究基于仿真数据集进行实验,通常为电脑合成的具有脉内调制特征的雷达信号或来自实验室的电磁频谱环境的具有指纹特征的雷达辐射源个体信号。仿真数据往往长度统一,脉冲完整,受干扰小,与实际环境中的雷达信号差异较大,且实验室设备有限,采集的信号存在时间跨度大、固件老化等问题,易引入设备误差。根据仿真数据训练的分类器,在实际信号上效果欠佳。由于缺少充分的实测数据,因此深度学习算法在雷达辐射源识别任务中存在着适用范围有限且抗干扰性能不足等问题。

6.1.2 小样本识别的泛化能力差

封闭集中训练的网络很难实现对新出现的未知的辐射源信号的正确分类,尽管在实验数据上有了较强的鲁棒性,但通用性随之下降。新型雷达变化形式丰富,雷达信号调制参数和方式多样,未知的雷达辐射源个体将不断出现且样本数量十分有限。目前主流的深度学习模型通常为离线学习,只有完成所有数据的训练后才能用于预测识别,对于新出现的

仅有少量样本甚至零样本的雷达辐射源个体,深度学习模型的识别准确率和稳定性将大幅下降。在小样本条件下,由于样本数量不足、类别不均衡等情况,深度学习模型易出现欠拟合、过拟合、灾难性遗忘等问题。如何提升小样本条件下的深度学习模型的泛化性能仍需展开深入研究。

6.1.3 工程应用受限

在实际应用中,雷达辐射源识别算法往往需要架构在接收信号的硬件设备上,其有限的算力和存储能力,使其在实现实时处理、分选采集到的信号以及完成雷达辐射源识别上面临较大的挑战。信号接收设备在同一时间可能面临成百上千个辐射源的照射,高密度的信号空间使实时地处理、分选、识别雷达辐射源信号的难度增大,并且深度学习算法对设备的运算能力与训练人员有一定的要求。因此,如何构建出端到端并具有扩展能力的雷达辐射源识别平台,高效、精准地辨别接收到的雷达辐射源,分析其工作模式,是雷达辐射源识别系统在工程落地中需要解决的问题。

6.1.4 未来研究展望

综合上述雷达辐射源识别领域面临的挑战,结合军事、工业等的实际应用需求和最新研究进展,本文从以下几个方面对未来的研究提出建议与展望。

(1) 小样本学习方法研究。小样本学习的方法能充分利用基于深度学习的预训练网络与有限的标注数据,增强模型的泛化能力。随着信号采集方法的多样化和存储技术的飞速发展,很容易获得大量无标注信号。因此,将无监督或弱监督的小样本方法的深度学习模型应用于未知辐射源识别是一个重要的研究方向,如将聚类、度量学习这类无监督学习方法与深度学习相结合,实现无标注数据的自动标注与通用浅层

特征提取。Ren 等的研究利用稀疏自动编码器与聚类方法,无监督地学习到雷达信号的关键特征,降低了聚类算法所需要的数据量并提高了精度,证明了深度学习方法在小样本条件下同样具有广阔的应用^[77]。

(2)数据增强与在线学习研究。针对小样本问题,Zhu 等在雷达目标识别中利用时间镜像数据增强与辅助分类生成对抗网络,有效地扩充了数据集,且增强的样本改善了特征空间中原始数据集的覆盖范围^[25]。Zhu 等和 Feng 等提出了在线学习的方法,实时更新模型的分类条件,提升小样本条件下的雷达辐射源识别的准确率与时效性^[78-79]。改进深度学习模型的网络结构,优化训练框架,有利于防止深度神经网络陷入局部最优和过拟合,有利于构建适应小样本条件下泛化能力强的深度学习模型。

(3)工程应用新技术研究。为了保证雷达探测系统的时效性,通常需要在信号接收设备附近完成雷达信号处理与雷达辐射源识别,随着硬件设备计算能力的不断增强,Li 等基于具有并行处理与流水线作业的 FPGA,来实现信号接收机上的信号处理与自动识别功能^[80]。探索边缘计算、模型压缩等技术,尝试将这些改进引入雷达辐射源识别研究中,对于工程应用中实时、准确地识别雷达辐射源信号,具有重要的现实意义。

结束语 目前基于深度学习的小样本雷达信号辐射源识别研究与应用已取得一定成果,本文基于小样本雷达辐射源识别的技术框架,以数据处理、特征提取与分类识别的顺序,归纳与总结了雷达信号特征提取方法、数据增强与扩充方法和多种经典深度学习方法及其应用,并探讨了小样本学习在雷达辐射源识别任务中的研究进展。雷达辐射源识别任务在日益复杂的真实电磁环境中仍面临着标注样本数量少、未知类别的辐射源信号量非常大,且接收到的样本受干扰性强、脉冲重叠、特征缺失等问题,因此亟待对提高深度学习方法的鲁棒性与泛化能力、增强真实环境中小样本雷达辐射源的识别性能展开深入研究。

参 考 文 献

- [1] LANGLEY L E. Specific emitter identification(SEI) and classical parameter fusion technology[C]// Proceedings of WESCON'93. IEEE, 2002.
- [2] ZHANG G Z. Research on Radar Radiator Recognition Technology [D]. Changsha: National University of Defense Technology, 2005.
- [3] MARK A R. Fundamentals of Radar Signal Processing (2nd ed.)[M]// USA: McGraw-Hill Education, 2014: 213-215.
- [4] JORDANOV I, PETROV N. Sets With Incomplete and Missing Data—NN Radar Signal Classification[C]// International Joint Conference on Neural Networks(IJCNN). Beijing, China, 2014: 218-224.
- [5] HINTON G E, OSINDERO S, TEH Y W. A Fast Learning Algorithm for Deep Belief Nets[J]. Neural Computation, 2014, 18(7): 1527-1554.
- [6] RUSSAKOVSKY O, DENG J, SU H, et al. Imagenet large scale visual recognition challenge[J]. International Journal of Computer Vision, 2015, 115(3): 211-252.
- [7] XU H Q, LIU G. Reviews on Radar Emitter Recognition[J]. Shipment Electronic Engineering, 2010, 30(4): 25-27.
- [8] LI M, ZHU W G, CHEN W G. Study of Radar Emitter Identification Based on Machine Learning[J]. Journal of Ordnance Equipment Engineering, 2016, 37(9): 171-175.
- [9] GUO S, WHITE R E, LOW M. A comparison study of radar emitter identification based on signal transients[C]// 2018 IEEE Radar Conference(RadarConf18). IEEE, 2018.
- [10] JIN Q, WANG H Y, MA F F. An Overview of Radar Emitter Classification and Identification Methods[J]. Telecommunications Technology, 2019, 59(3): 360-368.
- [11] MENG L, QU W, CAI K, et al. Overview of Radar Emitter Identification Based on Machine Learning[J]. Journal of Ordnance Equipment Engineering, 2020, 41(10): 16-21.
- [12] ZHANG G Z, HUANG K S, JIANG W L, et al. Emitter feature extract method based on signal envelope[J]. System Engineering and Electronic Technology, 2006(6): 795-797, 936.
- [13] CHOI H I, WILLIAM S. Improved time-frequency representation of multicomponent signals using exponential kernels[J]. Acoustics, Speech and Signal Processing, IEEE Transactions, 1989, 37(6): 862-871.
- [14] KAWALEC A, OWCZAREK R. Specific emitter identification using intrapulse data[C]// Proceedings of 1st European Radar Conference. Amsterdam, Netherlands, 2004: 249-252.
- [15] D'AGOSTINO S, FOGLIA G, PISTOIA D. Specific emitter identification; analysis on real radar signal data [C]// Proceedings of the 6th European Radar Conference. Rome, Italy, 2009: 242-245.
- [16] CONNING M, POTGIETER F. Analysis of measured radar data for specific emitter identification[C]// Proceedings of IEEE Radar Conference. Arlington, VA, USA, 2010: 35-38.
- [17] YE H H, LIU Z, JIANG W L, et al. A Comparison of Unintentional Modulation on Pulse Features with the Consideration of Doppler Effect[J]. Journal of Electronics and Information, 2012, 34(11): 2654-2659.
- [18] FENG Z, LIANG M, CHU F. Recent advances in time-frequency analysis methods for machinery fault diagnosis: A review with application examples[J]. Mechanical Systems & Signal Processing, 2013, 38(1): 165-205.
- [19] COHEN L. Time-Frequency Distribution—A Review[J]. Proceedings of the IEEE, 1989, 77(7): 941-981.
- [20] ZHANG X. On High-order statistical analysis, Modem Signal Processing [M]. Beijing: Tsinghua University Press, 2015: 217-228.
- [21] CAI Z W, LI J D. Individual Recognition of Communication Radiator Based on Bispectrum [J]. Journal of Communications, 2007(2): 75-79.
- [22] CHENG C X, HE M H, ZHU Y Q, et al. Extraction of individual characteristics of radar emitters based on bispectrum analysis[J]. System Engineering and Electronic Technology, 2008 (6): 1046-1049.
- [23] WANG C, WANG J, ZHANG X. Automatic radar waveform recognition based on time-frequency analysis and convolutional

- neural network[C]// IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP). 2017:2437-2441.
- [24] WEI S, QU Q, SU H, et al. Intra-pulse modulation radar signal recognition based on CLDN network[J]. IET Radar, Sonar & Navigation, 2020, 14(6):803-810.
- [25] ZHU K F, WANG X G, LIU Y J. Radar target recognition algorithm based on data augmentation and WACGAN under small sample conditions[J]. Journal of Electronics, 2020, 48(6):1124-1131.
- [26] SAINATH T N, VINYALS O, SENIOR A, et al. Convolutional, Long Short-Term Memory, fully connected Deep Neural Networks[C]// IEEE International Conference on Acoustics. IEEE, 2015.
- [27] HOCHREITER S, SCHMIDHUBER J. Long Short-Term Memory[J]. Neural Computation, 1997, 9(8):1735-1780.
- [28] BAGWE R, KACHHIA J, ERDOGAN A, et al. Automated Radar Signal Analysis Based on Deep Learning[C]// 2020 10th Annual Computing and Communication Workshop and Conference(CCWC). IEEE, 2020.
- [29] ZHENG Y, SHEN Y J, ZHOU Y S. Radar signal intra-pulse modulation recognition based on multi-layer two-way LSTM [J]. Telemetry and remote control, 2019, 40(1):37-45.
- [30] QIN X, HUANG J, WANG J T, et al. Individual Radar Radiator Recognition Based on Unintentional Phase Modulation Characteristics[J]. Journal on Communications, 2020, 41(5):104-111.
- [31] SCHMIDHUBE R, JÜRGE N. Deep Learning in Neural Networks: An Overview[J]. Neural Netw, 2015, 61:85-117.
- [32] BENGIO Y, LAMBLIN P, POPOVICI D, et al. Greedy layer-wise training of deep networks[C]// Advances in Neural Information Processing Systems 19, Proceedings of the Twentieth Annual Conference on Neural Information Processing Systems. Vancouver, British Columbia, Canada, 2006.
- [33] VINCENT P, LAROCHELLE H, BENGIO Y, et al. Extracting and Composing Robust Features with Denoising Autoencoders [C]// Machine Learning, Proceedings of the Twenty-Fifth International Conference(ICML 2008). Helsinki, Finland, 2008.
- [34] MASCI J, MEIER U, CIRESAN D, et al. Stacked Convolutional Auto-Encoders for Hierarchical Feature Extraction[J]. Springer Verlag, 2011(6791):52-59.
- [35] ZHOU Z W, HUANG G M, GAO J, et al. A Deep Learning Radar Radiator Recognition Algorithm[J]. Journal of Xidian University(Natural Science Edition), 2017, 44(3):83-88.
- [36] GUO L M, KOU Y H, CHEN T, et al. Modulation type recognition of radar signal with low probability of interception under low signal-to-noise ratio based on stacked sparse autoencoder [J]. Journal of Electronics and Information, 2018, 40(4):875-881.
- [37] ZHANG M, WANG H, ZHOU K, et al. Low Probability of Intercept Radar Signal Recognition by Staked Autoencoder and SVM[C] // 2018 10th International Conference on Wireless Communications and Signal Processing(WCSP), 2018.
- [38] GAO P C, JIAO S H. Radar radiator individual recognition based on variational autoencoder [J]. Applied Technology, 2020, 47(4):59-65.
- [39] ZHOU Y, WANG X, CHEN Y, et al. Specific Emitter Identification via Bispectrum-Radon Transform and Hybrid Deep Model [J]. Mathematical Problems in Engineering, 2020, 2020 (1): 1-17.
- [40] KONG G, JUNG M, KOIVUNEN V. Waveform Recognition in Multipath Fading using Autoencoder and CNN with Fourier Synchrosqueezing Transform[C] // IEEE International Radar Conference(RADAR). IEEE, 2020:612-617.
- [41] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet Classification with Deep Convolutional Neural Networks[C]// NIPS. Curran Associates Inc. 2012.
- [42] ZEILER M D, FERGUS R. Visualizing and Understanding Convolutional Networks[C]// European Conference on Computer Vision. Springer International Publishing, 2013.
- [43] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional Networks for Large-Scale Image Recognition[J/OL]. <https://arXiv.org/abs/1409.1556>.
- [44] SZEGEDY C, LIU W, JIA Y, et al. Going Deeper with Convolutions[C]// 2015 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). 2015:1-9.
- [45] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). 2016:770-778.
- [46] LIU Z, SHI Y, ZENG Y, et al. Radar Emitter Signal Detection with Time-Frequency Image Processing and Convolutional Neural Network[C]// 2019 IEEE 11th International Conference on Advanced Infocomm Technology(ICAIT). IEEE, 2019.
- [47] LI K. Radar Emitter Identification Based on Improved Convolutional Neural Network[C]// IEEE 3rd Advanced Information Management, Communicates, Electronic and Automation Control Conference(IMCEC). IEEE, 2019.
- [48] WANG G M, CHEN S W, HUANG J, et al. Radar signal sorting and recognition based on transfer deep learning[J]. Computer Science and Applications, 2019, 9(9):18.
- [49] SHI L M, YANG C Z, WU H C. Radar signal recognition method based on deep residual network and triple loss[J]. System Engineering and Electronic Technology, 2020, 42 (11): 2506-2512.
- [50] SI W, WAN C, ZHANG C. Towards an accurate radar waveform recognition algorithm based on dense CNN [J]. Multimedia Tools and Applications, 2021(80):1779-1792.
- [51] CAI J J, LI C, ZHANG H Y. Modulation Recognition of Radar Signal Based on an Improved CNN Model[C]// 2019 IEEE 7th International Conference on Computer Science and Network Technology(ICCSNT). 2019:304-308.
- [52] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]// Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA, 2018: 7132-7141.
- [53] QU Q, WEI S, SU H, et al. Radar Signal Recognition Based on Squeeze-and-Excitation Networks[C]// 2019 IEEE International Conference on Signal, Information and Data Processing (CISIDP). 2019:1-5.
- [54] WEI S, QU Q, WANG M, et al. Automatic Modulation Recognition for Radar Signals via Multi-branch ACSE Networks[J]. IEEE Access, 2020, 8:94923-94935.

- [55] WANG X, HUANG G, MA C, et al. Convolutional neural network applied to specific emitter identification based on pulse waveform images[J]. IET Radar, Sonar & Navigation, 2020, 14(5):728-735.
- [56] AKYON F C, ALP Y K, GOK G, et al. Classification of Intra-Pulse Modulation of Radar Signals by Feature Fusion Based Convolutional Neural Networks[C]// 2018 26th European Signal Processing Conference(EUSIPCO). 2018:2290-2294.
- [57] WANG Q, DU P, YANG J, et al. Transferred deep learning based waveform recognition for cognitive passive radar[J]. Signal Processing, 2019, 155(2):259-267.
- [58] KHANH N, LONG D V, DONG Q T. A Parallel Neural Network-based Scheme for Radar Emitter Recognition[C]// 2020 14th International Conference on Ubiquitous Information Management and Communication(IMCOM). 2020:1-8.
- [59] LI Y, SHAO G, WANG B. Automatic Modulation Classification Based on Bispectrum and CNN[C]// 2019 IEEE 8th Joint International Information Technology and Artificial Intelligence Conference(ITAIC). IEEE, 2019.
- [60] GAO Y Y, ZHANG W B. New Radar Radiation Source Recognition[J]. Chinese Journal of Image and Graphics, 2020, 25(6): 1171-1179.
- [61] ZHENG Y, CHEN Y J, ZHOU Y S. Faster r-cnn realizes modulation recognition and parameter extraction of overlapping radar signals[J]. Telemetry and Remote Control, 2019, 40(3):32-40.
- [62] HOANG L M, KIM M J, KONG S H. Deep Learning Approach to LPI Radar Recognition[C]// 2019 IEEE Radar Conference (RadarConf19). IEEE, 2019.
- [63] ZHU M T, LI Y J, PAN Z S, et al. Automatic modulation recognition of compound signals using a deep multi-label classifier: A case study with radar jamming signals[J/OL]. https://www.researchgate.net/publication/337392227_Automatic_Modulation_Recognition_of_Compound_Signals_using_a_Deep_Multi-Label_Classifier_A_Case_Study_with_Radar_Jamming_Signals.
- [64] PAN Z, WANG S, ZHU M, et al. Automatic Waveform Recognition of Overlapping LPI Radar Signals Based on Multi-Instance Multi-Label Learning[J]. IEEE Signal Processing Letters, 2020, 27:1275-1279.
- [65] MING Z, MING D, LIPENG G, et al. Angel Garrido. Neural Networks for Radar Waveform Recognition[J/OL]. <https://www.docin.com/p-2278363898.html>.
- [66] QU Z, WANG W, HOU C, et al. Radar Signal Intra-Pulse Modulation Recognition Based on Convolutional Denoising Autoencoder and Deep Convolutional Neural Network[J]. IEEE Access, 2019, 7:112339-112347.
- [67] ZHOU Z, HUANG G, CHEN H, et al. Automatic Radar Waveform Recognition Based on Deep Convolutional Denoising Auto-encoders[J]. Circuits Systems & Signal Processing, 2018, 37: 4034-4048.
- [68] CUI B Y, TIAN R L, WANG D F, et al. Radar radiation source recognition based on attention mechanism and improved CLDNN [J]. System Engineering and Electronic Technology, 2021, 43(5):1224-1231.
- [69] HUANG Y K, JIN W D, YU Z B, et al. Radiation source signal recognition based on deep learning and integrated learning[J]. Systems Engineering and Electronic Technology, 2018, 40(11): 33-38.
- [70] SILVER D, HUANG A, MADDISON C J, et al. Mastering the game of Go with deep neural networks and tree search[J]. Nature, 2016, 529(7587):484-489.
- [71] GAO Y, CHEN S F, LU X. Review of Reinforcement Learning Research[J]. Acta Automatica Sinica, 2004(1):86-100.
- [72] LENG P F, XU C Y. A deep reinforcement learning method for individual identification of radar emitters[J]. Acta Armamentarii, 2018, 39(12):134-140.
- [73] QU Z, HOU C, HOU C, et al. Radar Signal Intra-Pulse Modulation Recognition Based on Convolutional Neural Network and Deep Q-Learning Network[J]. IEEE Access, 2020, 8: 49125-49136.
- [74] LI M, ZHU W G. Radar Radiation Source Recognition with Missing Database Samples [J]. Telecommunications Technology, 2017, 57(7):784-788.
- [75] RAN X, ZHU W. Radar emitter identification based on discriminant joint distribution adaptation[C]// 2019 IEEE 3rd Advanced Information Management, Communicates, Electronic and Automation Control Conference(IMCEC). IEEE, 2019.
- [76] XIAO Y, LIU W, GAO L. Radar Signal Recognition Based on Transfer Learning and Feature Fusion[J]. Mobile Networks and Applications, 2020, 25:1563-1571.
- [77] REN K, YE H, GU G, et al. Pulses Classification Based on Sparse Auto-Encoders Neural Networks [J]. IEEE Access, 2019, 7:92651-92660.
- [78] ZHU W, LI M, ZENG C. Research on Online Learning of Radar Emitter Recognition Based on Hull Vector[C]// IEEE Second International Conference on Data Science in Cyberspace. IEEE, 2017.
- [79] FENG Y, CHENG Y, WANG G, et al. Radar Emitter Identification under Transfer Learning and Online Learning[J/OL]. https://www.researchgate.net/publication/338167669_Radar_Emitter_Identification_under_Transfer_Learning_and_Online_Learning.
- [80] LI T, SU S Y, CHEN Z P, et al. A real-time recognition method of radar intra-pulse modulation in EW receiver[J]. Modern Electronic Technology, 2013, 36(21):9-14.



SU Dan-ning, born in 1997, postgraduate. Her main research interests include deep learning, radar emitter identification and so on.



CAO Gui-tao, born in 1970, Ph.D, professor. Her main research interests include artificial intelligence, image analysis and understanding, medical big data processing.