

基于雷达 RCS 数据的空间目标识别算法研究^{*}

张 裕¹ 李建鑫¹ 朱勇建² 马 腾¹

(1.上海应用技术大学计算机科学与信息工程学院 上海 201418; 2.深圳技术大学工程物理学院 深圳 518118)

摘 要: 近年来,深度学习在雷达目标识别领域取得了突破性进展,但基于雷达散射截面数据的深度学习目标识别算法研究相对甚少。此外,空间目标雷达信号容易受噪声影响,导致目标识别准确率低。本文提出了一种端到端的时频特征融合神经网络 TFF-Net 用于实现基于 RCS 序列数据的空间目标识别。首先使用时频分析方法将 RCS 序列数据转化为二维时频数据来降低噪声干扰,其次使用 TFF-Net 提取时频数据的深层特征。TFF-Net 先利用卷积神经网络捕获目标空间特征,接着采用双向长短时记忆网络来建模时序信息,再通过时间注意力网络自适应地关注时频数据中重要的序列。最后,在空间目标数据集上进行了算法对比实验。结果表明,所提出算法的空间目标识别精度达到 95.8%,明显高于当前一些主流雷达目标识别算法,且在低信噪比情况下分类精度也优于其他算法,具有更好的噪声鲁棒性。

关键词: 空间目标识别;雷达散射截面;时频分析;神经网络

中图分类号: TN957.52 **文献标识码:** A **国家标准学科分类代码:** 510.40

Research on space object recognition algorithm based on radar RCS data

Zhang Yu¹ Li Jianxin¹ Zhu Yongjian² Ma Teng¹

(1. School of Computer Science and Information Engineering, Shanghai Institute of Technology, Shanghai 201418, China;

2. The College of Engineering Physics, Shenzhen Technology University, Shenzhen 518118, China)

Abstract: In recent years, deep learning has achieved breakthrough progress in radar target recognition. However, research on deep learning target recognition algorithms based on radar cross-section (RCS) data is relatively scarce. Additionally, space target radar signals are easily affected by noise, resulting in low target recognition accuracy. This paper proposes an end-to-end Time-Frequency Feature Fusion Neural Network (TFF-Net) for space target recognition based on RCS sequence data. First, time-frequency analysis methods are used to convert the RCS sequence data into two-dimensional time-frequency data to reduce noise interference. Then, TFF-Net is used to extract deep features from the time-frequency data. TFF-Net first uses a convolutional neural network to capture spatial features of the targets, then employs a bidirectional long short-term memory network to model temporal information, and finally applies a temporal attention network to adaptively focus on important sequences in the time-frequency data. Comparative experiments were conducted on a space target dataset. The results show that the proposed algorithm achieves a space target recognition accuracy of 95.8%, significantly higher than several current mainstream radar target recognition algorithms. Furthermore, the classification accuracy under low signal-to-noise ratio conditions is also superior to other algorithms, demonstrating better noise robustness.

Keywords: radar target recognition; radar cross section; time frequency analysis; neural networks

0 引 言

在当今信息化战争的背景下,雷达空间物体智能识别技术备受关注^[1]。雷达识别通过雷达系统探测和辨识空间中的物体,这对对战场态势感知、目标跟踪和战术决策至关

重要^[2-3]。典型的空间目标识别技术根据信息来源可以分为宽带雷达和窄带雷达。宽带雷达包括高分辨率距离像 (high resolution range profile, HRRP) 数据和合成孔径雷达数据,窄带雷达则包括微多普勒数据和雷达散射截面序列 (radar cross section, RCS) 数据^[4-17]。相比于宽带雷达,

窄带雷达通过牺牲部分细节特征来实现更远的探测距离,尤其是 RCS 序列数据,RCS 反映了目标对雷达信号的散射能力,是衡量目标散射特征的基本参数。通过分析 RCS 序列特征,可以获取目标的外形和表面材料的电磁特性,这对于识别空中目标和评估其隐身性能具有重要意义^[4]。

学者普遍通过研究不同的特征提取和分析方法来实现精准的空间目标识别。如文献[5-6]束长勇等人通过分析微多普勒谱的差异,利用人工提取的特征来完成对锥体目标微动形式的分类。文献[9-11]通过提取 RCS 序列的统计特征如均值、方差等,使用传统分类器实现目标识别。文献[12-16]通过对空间目标的 RCS 序列进行小波变换,傅里叶变换等时频分析方法提取 RCS 序列数据的时频特征,并采用 SVM 等机器学习方法对空间目标进行分类。RCS 数据预处理方法可以分为两类,其中统计特征的计算相对简单且高效,但仅考虑统计特征会导致信息丢失,无法充分反映目标的复杂性,因而目标识别效果不理想。时频分析可以揭示 RCS 数据中的周期性和频率特征,但由于时频特征的复杂性,需要借助深层次网络架构来提取 RCS 序列的潜在特征。然而,这些特征提取方法需要基于先验知识来构造特征,然后将构造的特征送入分类器实现分类,但是基于人工构造的方法首先不能减少噪声干扰,此外,也不能提取 RCS 序列数据中的隐含特征。

近年来,深度学习被广泛用于雷达空间目标识别领域,因为它具备自动特征学习以及有效建模非线性关系等特点,从而显著提升了目标识别性能^[17-26]。在文献[17-19]针对传统目标识别方法中人工特征提取难以捕捉深层次特征的问题,将 BP 神经网络以及卷积神经网络(convolutional neural network, CNN)应用于 RCS 数据的雷达目标识别,充分提取 RCS 序列数据的空间特征,同时在实验数据上展现出了出色的目标识别性能。文献[20]考虑到 RCS 数据中包含的时序信息,采用双向门控循环单元网络对船舶目标进行分类。文献[21-26]首先利用 CNN 提取 HRRP 序列数据的空间特征,然后将这些特征输入到长短时记忆网络(long short-term memory, LSTM)中进行时间序列建

模,进而捕捉 HRRP 序列的深层次的时频特征。上述文献通过构建合适的深度神经网络实现雷达目标识别,其识别效果显著优于传统分类器。然而,由于实测 RCS 易受环境影响且存在较多噪声,加之相关 RCS 数据集的较少,目前,构建适用于提取 RCS 序列数据特征并进行目标识别的深度神经网络的研究仍然较为欠缺。

针对 RCS 序列数据容易受到噪声干扰以及人工构造方法难以提取其深层次特征的问题,本文提出了一种 RCS 序列数据预处理方法,采用傅里叶-对数综合变换得到雷达信号的二维时频数据,减小了原始噪声和杂波的影响,然后提出一种雷达空间目标识别模型 TFF-Net 自动提取时频数据中的深层特征并实现目标识别。

1 雷达信号预处理

在雷达目标识别领域,若直接将雷达的 RCS 序列数据输入至深度神经网络进行特征提取,目标识别效果比较差。原因在于 RCS 时域信号的信息中有较多噪声,并且信息量不足以应对复杂识别任务。因此需要对 RCS 数据进行合适的预处理。小波变换和傅里叶变换等依赖于时频特征分析的主流方法能够揭示复杂的频域信息,从而显著提升目标识别性能。

时频分析能将原始的一维 RCS 数据转换为二维时频表示,这种多维表示可以更清晰地揭示信号中的频率成分。同时在频域中,噪声往往表现为高频成分,而有用的信号则集中在特定的频率范围内。图 1 展示了对原始雷达 RCS 序列数据进行时频分析的流程,可以看出时频分析后可以更容易地识别并过滤掉非目标相关的高频噪声,从而清晰地突出有用信号。

如图 1、2 为两类不同的目标时频分析流程图,对原始数据中水平和垂直的极化宽带 RCS 序列数据进行了可视化,显示了 401 个采样频点,其散射中心在不同俯仰角和方位角下的散射强度,不同颜色代表了目标各个位置对雷达信号不同的散射强度,如图 1(a)、图 2(a)可以观察到散射强度在时间域上局部特征分布比较离散,不能够充分体现目标的特征。




图 1 类别 1 时频分析流程图

考虑到傅里叶变换(short time fourier transform, STFT)可以将不同目标的频域特征分开,使细微差异更加明显,同时可以将干扰从频谱中分离出来,本文对原始 RCS 序列数据进行了傅里叶变换,从而获得目标的时频信息。傅里叶变换公式如下:

$$X(f) = \int_{-\infty}^{\infty} x(t) e^{-j2\pi ft} dt \quad (1)$$

式中: $X(f)$ 表示频域信号,是一个复数值, $x(t)$ 包括振幅和相位信息,表示输入的时域信号, f 是频率。

经过傅里叶变换后得到频域特征,如图 1(b)、图 2(b)




图 2 类别 2 时频分析流程图

展示了频域上目标散射点的振幅强度,经过傅里叶变换后两类目标已经具有明显的可以区分的特征,两类目标在特定的频率下散射强度有明显区别,但是信号的振幅分布范围明显扩大,所以使用对数变换将高幅度信号进行压缩,同时将低幅度信号放大,不仅可以降低背景噪声,还可以增强信号的动态范围。对数变换具体公式如下:

$$T(f) = \log(1 + \sqrt{|fft-Eh|^2 + |fft-Ev|^2}) \quad (2)$$

式中: $fft-Eh$ 为经过傅里叶变换后的水平宽带雷达数据, $fft-Ev$ 为经过傅里叶变换后的垂直宽带雷达数据, $T(f)$ 为经过对数变换后的时频信号。

如图 1(c)、图 2(c) 所示,经过对数变换处理(logarithmic transform, LOGT)后的时频特征表现出更加紧凑和清晰的频域特性,同时实现了振幅范围的有效压缩。与图 1(b)相比,这些特征更加突出,有利于不同目标的区分。图 1(c)中的每一列数据代表目标特定位置频域中的反射强度,可以被视为一个独立的特征。这些特征将被用作输入,送入后续的网络模型中,以便提取更深层次的特征信息。本文的数据预处理方法不仅减少了原始数

据中的噪声对 TFF-Net 的影响,也增强了 TFF-Net 对复杂信号特征的识别能力。

2 本文模型

图 3 为本文提出 TFF-Net 空间目标识别网络模型,主要包含 3 部分:空间特征提取模块(spatial feature extraction module, SFEM),时间序列特征提取模块(temporal feature extraction module, TFEM)以及目标识别模块。TFF-Net 模型首先使用卷积神经网络提取目标的空间信息,经过多轮卷积和池化操作逐渐抽取出更高层次的空间特征。随后 TFEM 模块中双向长短期记忆网络(bidirectional long short-term memory, BiLSTM)用于对 SFEM 输出的特征进行建模,以捕捉时频信号中的时序关系,并引入时间注意力网络(temporal attention network, TAN)对 BiLSTM 的输出进行加权求和,关注时频数据中重要的序列。最终将提取的关键特征送入识别模块,通过全连接层,应用 Softmax 函数获得目标识别的最终结果。

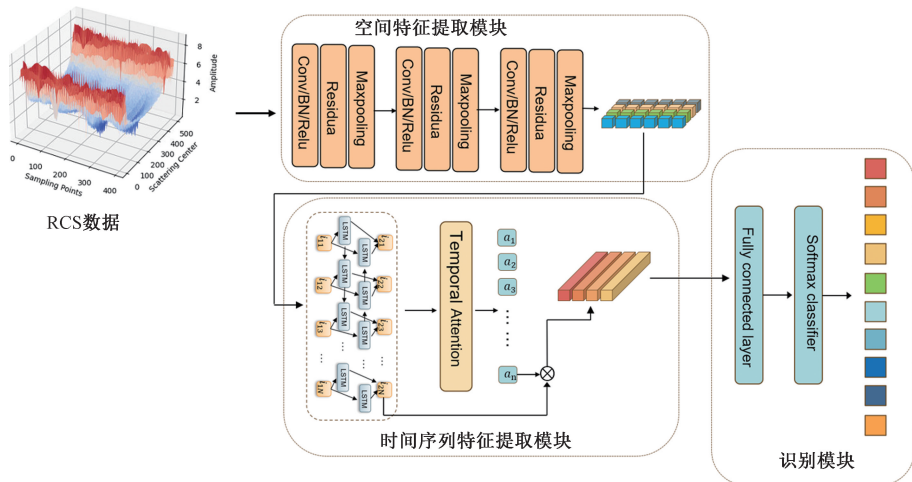


图 3 雷达目标识别网络结构

2.1 空间特征提取模块

为进一步提取输入时频数据的潜在特征,挖掘时频图数据的局部空间特征以及特征之间的关联性,引入卷积神经网络对输入数据进行处理。本文设计的空间特征提取模块由 3 个卷积模块组成,卷积模块的网络结构如图 4 所示,通过多层卷积和池化操作对频域特征有效提取。




图 4 卷积模块网络结构

图 4 中的一维卷积层,用于捕捉输入数据的局部空间特征。通过堆叠多个卷积层,可以提取到深层的隐藏特征。卷积运算的数学公式如下:

$$(\mathbf{Y} \cdot \mathbf{W})(i) = \sum_{k=1}^K \sum_{j=1}^J \sum_{l=1}^L \mathbf{X} \cdot \mathbf{W}(j, l) \quad (3)$$

式中: \mathbf{Y} 是卷积特征输出图, \mathbf{X} 是输入数据, \mathbf{W} 是卷积核, k 是输入数据的通道数, j 是卷积核的高度, l 是卷积核的宽度, i 是输出特征图的索引。

为了防止训练过程中出现梯度爆炸,卷积模块中加入了残差连接。残差连接允许网络直接学习输入和输出之间的残差,从而更有效地传播梯度并提高模型的训练效果。残差块的公式如下:

$$\mathbf{F}(\mathbf{X}) = \text{RELU}(\text{Conv1D}(\mathbf{X})) + \mathbf{X} \quad (4)$$

式中: \mathbf{X} 代表输入, $\mathbf{F}(\mathbf{X})$ 代表输出。

最后通过池化层进一步降低特征图的空间维度,这有助于减少计算量并提高模型的泛化能力,具体地,池化操作通过对邻近像素进行汇总来减小特征图的尺寸,从而提炼出更加鲁棒的特征,并减少对特定位置的依赖。池化层的数学公式如下:

$$\mathbf{Y}(i) = \max(\mathbf{X}(2i), \mathbf{X}(2i+1)) \quad (5)$$

式中: $\mathbf{Y}(i)$ 是池化层的输出, $\mathbf{X}(2i)$ 和 $\mathbf{X}(2i+1)$ 是输入中相邻的两个元素。

2.2 时间序列特征提取模块

空间特征提取模块获得时频数据的空间特征,考虑到雷达 RCS 数据为时序数据,通过分析时序数据可以更准确地理解信号的时序特征,因此设计了一个时间序列特征提取模块,该模块利用 BiLSTM 和 TAN 捕捉信号随时间变化的动态特性以及相邻时间信号之间的关联。

1) 双向长短时记忆网络

BiLSTM 可以有效捕获时间序列数据中的长期依赖关系。与传统的 LSTM 相比, BiLSTM 通过在正向和反向两个方向处理序列,能够综合考虑过去和未来的信息,为理解雷达信号的时间特性提供更全面的序列信息。BiLSTM 具体网络结构如图 5 所示。




图 5 双向长短时记忆网络

图 5 中将卷积层输出的特征输入 BiLSTM 挖掘数据之间的时序关系。BiLSTM 能够同时考虑正向和反向的

上下文信息,从而更全面地理解序列中的依赖关系。正向和反向长短时记忆网络分别计算每个时间步的隐藏状态向量,并将这些向量在特征维度上拼接起来。其中前向隐藏状态通过前向长短时记忆网络的门控制计算得到,具体公式如下:

$$\mathbf{i}_t^f = \sigma(\mathbf{W}_{xi}^f \mathbf{x}_t + \mathbf{W}_{hi}^f \mathbf{h}_{t-1}^f + \mathbf{W}_{ci}^f \mathbf{c}_{t-1}^f + \mathbf{b}_i^f) \quad (6)$$

式中: \mathbf{x}_t 是当前时刻的输入, \mathbf{h}_{t-1}^f 是前一时刻的隐藏状态, \mathbf{c}_{t-1}^f 是前一时刻的记忆单元状态, $\mathbf{W}_{xi}^f, \mathbf{W}_{hi}^f, \mathbf{W}_{ci}^f$ 是权重矩阵, \mathbf{b}_i^f 是偏差, σ 是 sigmoid 激活函数。

$$\mathbf{f}_t^f = \sigma(\mathbf{W}_{xf}^f \mathbf{x}_t + \mathbf{W}_{hf}^f \mathbf{h}_{t-1}^f + \mathbf{W}_{cf}^f \mathbf{c}_{t-1}^f + \mathbf{b}_f^f) \quad (7)$$

$$\mathbf{m} = \tanh(\mathbf{W}_{xm}^f \mathbf{x}_t + \mathbf{W}_{hm}^f \mathbf{h}_{t-1}^f + \mathbf{b}_m^f) \quad (8)$$

$$\mathbf{c}_t^f = \mathbf{f}_t^f \odot \mathbf{c}_{t-1}^f + \mathbf{i}_t^f \odot \mathbf{m} \quad (9)$$

$$\mathbf{o}_t^f = \sigma(\mathbf{W}_{xo}^f \mathbf{x}_t + \mathbf{W}_{ho}^f \mathbf{h}_{t-1}^f + \mathbf{W}_{co}^f \mathbf{c}_{t-1}^f + \mathbf{b}_o^f) \quad (10)$$

$$\mathbf{h}_t^f = \mathbf{o}_t^f \odot \tanh(\mathbf{c}_t^f) \quad (11)$$

式中: \mathbf{i}_t^f 是输入门的输出, \mathbf{f}_t^f 是遗忘门的输出, \mathbf{c}_t^f 是记忆单元的更新, \mathbf{o}_t^f 是输出单元的输出, \mathbf{h}_t^f 是前向隐藏状态, \odot 表示逐元素乘法, \tanh 表示双曲正切激活函数。

2) 时间注意力机制

BiLSTM 虽能捕捉 RCS 序列数据的长期依赖关系,但难以区分各时间点的重要性,会对所有时间点赋予相同的权重。因此对 BiLSTM 输出的每个 RCS 序列的时间步使用线性变换计算其注意力分数,然后用 Softmax 函数对注意力分数进行归一化并得到每个时间步的权重,权重用于加权 BiLSTM 输出的时序特征,将关键信息突出,最后将 BiLSTM 输出与对应的时间注意力权重相乘,得到最终加权输出结果。时间注意力使模型能够自适应地关注 RCS 序列中不同时间步的关键内容,提高特征提取的效率和准确性。

时间注意力机制的原理如图 6 所示, \mathbf{x}^k 为 BiLSTM 输出的每个 RCS 序列的时间经过线性变换后得到其权重 \mathbf{a}^k 。计算过程公式如下:

$$\mathbf{v}^k = f(\mathbf{W}_a \mathbf{x}^k + \mathbf{b}) \quad (12)$$

$$\mathbf{a}_i^k = \frac{\exp(\mathbf{v}_i^k)}{\sum_{i=1}^D \exp(\mathbf{v}_i^k)} \quad (13)$$

$$\mathbf{x}'_k = \mathbf{a}^k \times \mathbf{x}^k \quad (14)$$

式中: i 为对应的时间步, \mathbf{v}^k 为时序注意力权重向量, \mathbf{a}^k 为权重, \mathbf{W}_a 为权重向量, f 为激活函数, \mathbf{b} 为偏置向量。




图 6 时间注意力机制

2.3 识别模块

识别模块将时间序列特征提取模块输出的特征映射

到最终的分类结果,由两个部分构成:全连接层和 Softmax 函数。全连接层通过权重矩阵和偏置向量将多维特征转换为与目标类别数相对应的维度。数学表达式如下:

$$\boldsymbol{F} = \sigma(\boldsymbol{W}\boldsymbol{X} + \boldsymbol{b}) \tag{15}$$

式中: \boldsymbol{F} 表示全连接层的输出, \boldsymbol{W} 是权重矩阵, \boldsymbol{X} 为输入特征, \boldsymbol{b} 为偏置项, σ 是激活函数。

Softmax 函数在识别模块中将全连接层的输出转换为概率,每个类别的输出值为模型预测该类别的概率。数学表达式如下:

$$P_i = \frac{e^{S_i}}{\sum_{j=1}^N e^{S_j}} \tag{16}$$

式中: P_i 表示第 i 个类别的概率, S_i 是对应类别的输出, N 是类别总数。

3 实验结果与分析

3.1 数据集

本研究使用“第十八届挑战杯”提供的空间目标数据集进行实验验证,其中 RCS 数据的频段范围为 8~10 GHz,总计 401 个采样频点,采样频点之间的间隔为 0.005 GHz,一共采集了 10 类不同目标的雷达回波数据,每个数据块包含了以下 5 个变量:频率、 E_h 、 E_v 、俯仰角和方位角。 E_h 和 E_v 是两种不同极化宽带 RCS 数据。后续训练时按照 9 : 1 比例划分训练集和测试集,评价指标选择目标识别准确率和混淆矩阵。模型训练使用的软件环境环境为 Ubuntu 20.04, Python 3.7, Pytorch 1.12.1, CUDA 11.4,硬件环境为 Inter (R) Xeon (R) W-1270PCPU @ 3.80 GHz, NVIDIA GeForce RTX 3090。

如图 7 所示,展示了一个具体 RCS 序列数据,将 E_h 和 E_v 相位叠加后的经过预处理的 RCS 时序数据,数据包含 401 个采样频点,每个采样频点包括 512 个不同的角度,图 7 中所展示的不同颜色代表了目标各个位置对雷达信号不同的散射强度。

3.2 数据预处理策略对比实验

为了验证不同的数据预处理方法对目标识别准确率的影响,实验将训练和测试的数据块按照 9 : 1 比例划分,




图 7 雷达采集的 RCS 数据

使用目前主流雷达识别算法 DeepConvLSTM^[24] 验证 5 种不同的数据预处理方式,考虑到 RCS 数据中包含的丰富的频域特征,目前最新数据预处理方法有,傅里叶变换,小波变换,梅林变换,小波包分解等。其中傅里叶变换适用于平稳信号,小波变换适用于非平稳信号但计算复杂度较高,梅林变换和小波包分解在处理非线性和非平稳信号方面有优势但实现复杂。本文最终采用在傅里叶变换基础上进行对数变换的方法,有效提取频域特征并平滑信号。针对本文具体的 RCS 数据集,考虑到包含不同的极化 RCS 数据,即 E_h 和 E_v ,首先需要对其进行相位叠加,然后将本文方法与分别使用傅里叶变换,小波变换,梅林变换,小波包分解的方法进行对比。

如表 1 所示,本文方法在目标识别准确率方面表现优异。与傅里叶变换、小波变换、梅林变换和小波包分解相比,本文方法在大多数类别中的识别准确率更高,尤其在类别 2、3、4 和 6 上表现尤为突出,达到了 100% 的准确率。平均准确率为 86.00%,显著高于其他预处理方法,表明本文方法在整体识别效果上具有显著优势。此外,本文方法在各类别中的表现较为稳定,未出现极端低值,说明其不同目标类别中的鲁棒性较强。这表明,本文通过对傅里叶变换后进行对数变换,能够有效提取频域特征并平滑信号,减少噪声干扰,显著提升目标识别的准确率和稳定性。

表 1 不同数据预处理方式下目标识别的准确率

预处理方式	准确率/%										平均
	类别 1	类别 2	类别 3	类别 4	类别 5	类别 6	类别 7	类别 8	类别 9	类别 10	准确率/%
傅里叶变换 ^[13]	70.00	98.00	98.00	98.00	76.00	96.00	62.00	88.00	80.00	58.00	82.40
小波变换 ^[12]	72.00	98.00	98.00	98.00	72.00	94.00	60.00	86.00	72.00	56.00	80.60
梅林变换 ^[16]	70.00	96.00	98.00	98.00	70.00	92.00	58.00	80.00	70.00	52.00	78.40
小波包分解 ^[14]	70.00	96.00	98.00	98.00	74.00	94.00	60.00	84.00	70.00	56.00	80.00
本文方法	84.00	100	100	100	78.00	100	74.00	88.00	74.00	62.00	86.00

3.3 网络模型对比实验

为了验证所设计的深度融合网络识别效果的准确性,本文研究基于 RCS 数据的目标识别与其他 5 种主流雷达目标识别模型进行比较分析。

传统的基于 RCS 序列数据的识别大多采用 SVM,目前已有的基于 RCS 序列数据的网络模型包括 BP 神经网络、CNN 以及双向门控循环单元网络等。然而,这些网络在挖掘 RCS 序列的空间特征及时序关系方面仍显不足。本文借鉴了已有的基于 HRRP 序列数据的研究,其中 CNN、ConvLSTM 与 DeepConvLSTM 以及 ConvBiLSTM 已取得了显著效果。基于 RCS 序列数据的研究逐步引入

了更复杂的网络结构,因此本文模型在 ConvBiLSTM 基础上,结合了时间注意力机制,对不同时间步赋予不同的重要程度,从而进一步提升目标识别性能。

对比模型中,传统的 SVM 分类器采用了 RBF 核函数,并设置正则化参数 C 为 1.0。另外 5 种深度学习目标识别模型的网络结构组成如表 2 所示。其中,表 2 中的对号表示该网络组成包含对应模块。Conv32 为通道数为 32 的卷积层,Conv64 为通道数为 64 的卷积层,Conv128 为通道数为 128 的卷积层,LSTM 为长短时记忆网络层,BiLSTM 为双向长短时记忆网络层,MaxPool1d 为一维最大池化层,FC 为全连接层,Softmax 层将输出转为概率分布。

表 2 五种网络结构的组成要素

网络模型	Conv32	Conv64	Conv128	LSTM	BiLSTM	MaxPool1d	Attention	FC	Softmax
CNN ^[19]	✓	✓	✓			✓		✓	✓
ConvLSTM ^[23]	✓			✓		✓		✓	✓
DeepConvLSTM ^[24]	✓	✓	✓	✓		✓		✓	✓
ConvBiLSTM ^[26]	✓	✓	✓		✓	✓		✓	✓
TFF-Net	✓	✓	✓		✓	✓	✓	✓	✓

为验证不同的模型对目标识别的影响,实验将训练和测试的数据块按照 9 : 1 比例划分,5 种算法使用相同的代码框架搭建,均采用本文提出的数据预处理方法,使用不同的卷积神经网络提取时频数据特征,构建不同的时序模型提取时序特征,并使用全连接层实现目标识别。除了网络架构外所有其他参数保持一致,每个模型训练 200 个 epoch,学习率为 0.001。每个模型保存 loss 值最低的权重

文件,用于测试模型的识别效果。

如表 3 所示,不同模型识别效果有明显差异,SVM 识别效果最差,平均准确率为 41.20%,主流雷达识别算法最高达到 90.40%,而本文所提出的 TFF-Net 目标识别平均准确率达到 95.80%,针对目标“类别 5”,“类别 7”,“类别 9”,“类别 10”本文模型识别的准确率显著高于其他主流雷达识别算法。

表 3 不同网络模型对每类目标识别的准确率

网络模型	准确率/%										平均准
	类别 1	类别 2	类别 3	类别 4	类别 5	类别 6	类别 7	类别 8	类别 9	类别 10	确率/%
SVM ^[14]	44.00	24.00	48.00	48.00	38.00	54.00	40.00	46.00	36.00	34.00	41.20
CNN ^[19]	80.00	98.00	100	98.00	48.00	94.00	42.00	76.00	56.00	48.00	74.00
ConvLSTM ^[23]	70.00	98.00	100	100	74.00	100	60.00	80.00	82.00	68.00	83.20
DeepConvLSTM ^[24]	84.00	100	100	100	78.00	100	74.00	88.00	74.00	62.00	86.00
ConvBiLSTM ^[26]	100	100	100	100	76.00	100	68.00	90.00	86.00	84.00	90.40
TFF-Net	98.00	100	100	100	92.00	100	92.00	96.00	84.00	96.00	95.80

如图 8(a)所示,使用传统 SVM 模型的识别雷达 RCS 数据的效果较差。图 8(b)~(e)所示的混淆矩阵表明,在应用常规雷达目标识别算法时,类别 5 与 10 及类别 7 与 9 之间易发生误识别,同时目前主流的雷达识别算法,对容易混淆的目标有较低的识别准确率。如图 8(f)所示本文的模型可以准确的识别相似的目标。这种显著的差异表明,使用本文的模型可以捕捉到相似目标的细微差异,用于实现准确的目标识别。

实验表明,传统 SVM 识别效果和深度神经网络有较大差距,CNN、ConvLSTM 与 DeepConvLSTM 虽然在空间

特征提取上表现出色,但难以捕捉深层次的时序特征。ConvBiLSTM 虽然能结合空间和时间特征,但无法自适应地关注不同时间步的关键内容,容易忽略时频数据中的重要信息。本文的 TFF-Net 模型为主流雷达识别模型 ConvBiLSTM 基础上融合时间注意力模块,使模型能够自适应地关注 RCS 序列中不同时间步的关键内容,从而显著提高特征提取的效率和准确性。

在实际雷达场景中,由于环境噪声、天气等因素的影响,雷达回波信号会受到不同程度的干扰和噪声,导致信号的质量下降,因此在测试集中加入不同比例的噪声来模




图 8 不同模型的混淆矩阵

拟实际的复杂场景,使用 CNN、ConvLSTM、DeepConvLSTM、ConvBiLSTM 与 TFF-Net 模型来进行测试,具体加入高斯噪声的公式为:

$$\text{SNR} = 10 \times \lg\left(\frac{\overline{P_x}}{P_{\text{Noise}}}\right) \quad (17)$$

式中: $\overline{P_x}$ 和 P_{Noise} 分别表示目标和噪声的平均功率。

如图 9 所示,所有模型的目标识别准确率随着噪声水平的增高而降低,但是本文所提出的模型在不同比例噪声

下识别准确率均高于其他 4 个模型,并且在信噪比为 1 dB 时 CNN 目标识别平均精度只有 20%,本文模型可以达到 45%,在信噪比为 10 dB 时 TFF-Net 目标识别平均精度达到 70%,在信噪比大于 20 dB 时 TFF-Net 识别精度在 80% 以上。实验结果表明, TFF-Net 在有噪声的测试集上也可以取得满意的识别性能,进一步验证本文模型具有一定的抗噪性。

4 结 论

本文为应对噪声干扰和传统人工特征提取方法在空间目标识别中的局限性,首先对雷达 RCS 数据进行数据预处理,通过傅里叶-对数变换将 RCS 数据转换为时频数据以降低噪声影响,然后提出了基于 TFF-NET 目标识别算法,使用 SFEM 模块挖掘时频图深层特征,TFEM 模块捕捉关键的时序特征,最后通过识别模块实现精准的目标分类。该算法在准确率上超越了当前主流的雷达识别算法,并且在低信噪比环境下表现优异的识别性能。未来的研究将探索轻量化的网络模型,在保证较高目标识别准确度的同时提升识别效率。

参考文献

- [1] 金宇锋,陶重彝. 基于 Transformer 的融合信息增强 3D 目标检测算法[J]. 仪器仪表学报, 2023, 44(12): 297-306.
- [2] 刘永超,刘秀文,谢兴涛,等. 基于激光雷达的港口环境海面目标检测[J]. 电子测量技术, 2023, 46(6): 153-158.
- [3] 王丽黎,刘庆,杜忠红. 用于雷达隐身设备的低 RCS 超宽带 Vivaldi 天线[J]. 电子测量与仪器学报, 2022, 36(3): 122-129.
- [4] CHEN J, XU S, CHEN Z. Convolutional neural network for classifying space target of the same shape by using RCS time series[J]. IET Radar, Sonar & Navigation, 2018, 12(11): 1268-1275.
- [5] 束长勇,张生俊,黄沛霖,等. 基于微多普勒的空间锥体目标微动分类[J]. 北京航空航天大学学报, 2017, 43(7): 1387-1394.
- [6] 关永胜,左群声,刘宏伟. 基于微多普勒特征的空间锥体目标识别[J]. 电波科学学报, 2011, 26(2): 209-215.
- [7] 詹武平,郑永煌,王金霞. 基于深度神经网络模型的雷达目标识别[J]. 现代雷达, 2018, 40(1): 16-19.
- [8] 金胜,高梅国,王洋. 基于 RCS 的空间目标识别技术[J]. 现代雷达, 2010, 32(6): 59-62.
- [9] 黎鑫,夏晓云,张玉石,等. 海面背景下弱目标 RCS 估计及特性分析[J]. 系统工程与电子技术, 2023, 45(2): 424-430.
- [10] 李雄. 基于窄带 RCS 数据的空间目标识别[D]. 成都:

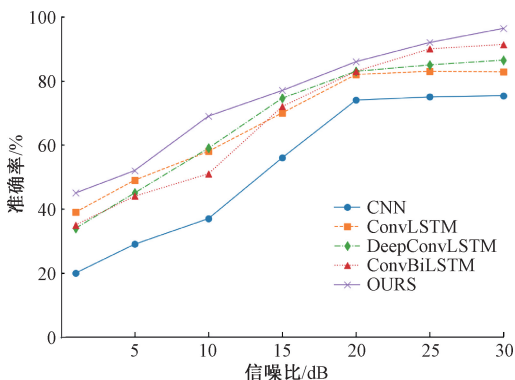


图 9 不同信噪比下不同算法识别的准确率

- 电子科技大学, 2020.
- [11] 李鑫. 基于 RCS 序列的雷达目标特征辨识方法研究[D]. 北京: 北京交通大学, 2019.
- [12] HU K J, LI H Y, XU S F, et al. Nonlinear signal classification based on wavelet transform and deep belief network[J]. Journal of Physics: Conference Series, 2021, 1948(1): 012029-012034.
- [13] 潘美艳, 蔡兴雨, 薛健. 基于时频谱图和 CNN 的雷达空中目标识别方法[J]. 火控雷达技术, 2023, 52(4): 16-22.
- [14] 于兴伟, 张学文, 侯鑫宇, 等. 基于窄带 RCS 数据的低速旋转空间目标识别研究[J]. 现代雷达, 2022, 44(7): 75-81.
- [15] 胡盟霄, 来嘉哲, 徐灿. 一种空间目标 RCS 序列的姿态异常检测方法[J]. 中国空间科学技术, 2019, 39(6): 72-79.
- [16] 占洪涛, 郭亮, 詹武平, 等. 基于 RCS 置信度分析的雷达目标识别[J]. 微型电脑应用, 2022, 38(7): 35-37, 47.
- [17] 袁俊英. 基于动态 RCS 的雷达目标识别研究[D]. 哈尔滨: 哈尔滨理工大学, 2021.
- [18] 高伟智, 杨伟, 蔡宇峰, 等. 基于卷积神经网络的舰船近场 RCS 雷达识别方法研究[C]. 中国电子学会, 2023.
- [19] QUAN D, TANG Z, WANG X, et al. LPI radar signal recognition based on dual-channel CNN and feature fusion[J]. Symmetry, 2022, 14(3): 570.
- [20] CHEN Y, LUO N. A ship radar cross section recognition method based on Bi-directional gated recurrent unit net [C]. 2023 IEEE 11th Joint International Information Technology and Artificial Intelligence Conference(ITAIC), IEEE, 2023.
- [21] LIN C L, CHEN T P, FAN K C, et al. Radar high-resolution range profile ship recognition using two-channel convolutional neural networks concatenated with bidirectional long short-term memory [J]. Remote Sensing, 2021, 13(7): 1259.
- [22] SI W, WAN C, DENG Z. An efficient deep convolutional neural network with features fusion for radar signal recognition[J]. Multimedia Tools and Applications, 2023, 82(2): 2871-2885.
- [23] BAIRD Z, MCDONALD M K, RAJAN S, et al. A cnn-lstm network for augmenting target detection in real maritime wide area surveillance radar data[J]. IEEE Access, 2020, 8: 179281-179294.
- [24] 卢中原. 基于雷达高分辨距离像的舰船目标识别方法[D]. 烟台: 烟台大学, 2023.
- [25] ZHANG Y P, ZHANG L, KANG L, et al. Space target classification with corrupted HRRP sequences based on temporal-spatial feature aggregation network[J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61(6): 1-18.
- [26] PAN M, LIU A, YU Y, et al. Radar HRRP target recognition model based on a stacked CNN-Bi-RNN with attention mechanism[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 60(4): 1-14.

作者简介

张裕, 讲师, 硕士生导师, 主要研究方向为智能网联汽车感知与决策规划。

E-mail: yuzhang@sit.edu.cn

李建鑫, 硕士研究生, 主要研究方向为目标检测与识别。

E-mail: xin13103359962@163.com

朱勇建, 教授, 硕士生导师, 主要研究方向为自动驾驶感知与路径规划。

E-mail: zhuyongjian_hn@163.com

马腾, 硕士研究生, 主要研究方向为深度学习、目标检测。

E-mail: mt1425@163.com