

# 基于卷积双向长短时记忆网络的雷达辐射源信号识别

普运伟<sup>1,2\*</sup>, 刘涛涛<sup>1</sup>, 吴海潇<sup>1</sup>, 郭江<sup>1</sup>

<sup>1</sup>昆明理工大学信息工程与自动化学院, 云南 昆明 650500;

<sup>2</sup>昆明理工大学计算中心, 云南 昆明 650500

**摘要** 雷达辐射源信号识别在实际战场中是对敌制胜的重要手段。为解决人工提取的雷达辐射源信号特征参数不完备、时效性低等问题,基于模糊函数在表征信号内在结构上的独特作用,提出一种结合模糊函数主脊坐标变换的卷积双向长短时记忆网络的识别方法。首先,为放大不同信号间的差异,采用数学思维将主脊切面转换为极坐标域的几何图像,以此作为神经网络的输入;其次,设计卷积神经网络来挖掘二维时频图的特征信息;最后,搭建双向长短时记忆网络对提取到的特征进行分类识别。仿真实验结果表明,所提方法在信噪比为 0 dB 以上均能保持 100% 的准确率,即使信噪比为 -6 dB 时,识别率仍可达 93.58% 以上,同时也有效缩短了信号分类时间。结果验证了所提方法不仅能提取信号的隐藏抽象特征,还具备良好的时效性和抗噪性。

**关键词** 雷达辐射源信号识别; 模糊函数主脊; 卷积神经网络; 双向长短时记忆网络

中图分类号 TN974

文献标志码 A

DOI: 10.3788/LOP202259.2228007

## Radar Emitter Signal Recognition Based on Convolutional Bidirectional Long- and Short-Term Memory Network

Pu Yunwei<sup>1,2\*</sup>, Liu Taotao<sup>1</sup>, Wu Haixiao<sup>1</sup>, Guo Jiang<sup>1</sup>

<sup>1</sup>Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, Yunnan, China;

<sup>2</sup>Computer Center, Kunming University of Science and Technology, Kunming 650500, Yunnan, China

**Abstract** Radar emitter signal recognition is an important means to defeat the enemy on the actual battlefield. To solve the problems of incomplete characteristic parameters and low timeliness of an artificial extraction's radar emitter signal, based on the unique role of the ambiguity function in characterizing the internal structure of the signal, this study proposes a recognition method for convolutional bidirectional long- and short-term memory network combined with the transformation of the main ridge coordinate of the ambiguity function. First, to amplify the difference between different signals, the main ridge section was mathematically converted into a geometric image in the polar coordinate domain, which was used as the input of a neural network. Second, a convolutional neural network was designed to excavate the feature information of a two-dimensional time-frequency map. Finally, a bidirectional long- and short-term memory network was built to classify and recognize the extracted features. Simulation results show that the proposed method maintains 100% accuracy even when the signal-to-noise ratio is above 0 dB, the recognition rate reaches above 93.58% even at -6 dB, and the signal classification time is effectively shortened. Furthermore, the proposed method extracts the hidden abstract features of the signal and produces good timeliness and antinoise performances.

**Key words** radar emitter signal recognition; main ridge of ambiguity function; convolutional neural network; bidirectional long- and short-term memory network

收稿日期: 2021-08-16; 修回日期: 2021-09-14; 录用日期: 2021-09-16

基金项目: 国家自然科学基金(61561028)

通信作者: \*puyunwei@126.com

## 1 引言

雷达辐射源信号(RES)分选识别是电子对抗领域的关键环节,其技术水平和雷达对抗系统水平紧密相关。然而随着电子对抗中电磁环境日趋复杂,加之所部署的各种复杂体制雷达越来越多,仅依靠到达时间(TOA)、载波频率(RF)、到达方向(DOA)、脉冲幅度(PA)和脉冲宽度(PW)这五个经典参数的分选方法已经无法满足实际战场的需要。另一方面,随着对辐射源信号先验信息认知的增强,利用新型学习算法对雷达辐射源信号进行分选识别具有重大意义。为此,寻找新的分选识别特征参数已成为亟需解决的问题。

近年来,国内外许多专家学者对提取雷达信号的时频域特征进行了重点研究,如时频特征<sup>[1]</sup>、双谱特征<sup>[2]</sup>等,并取得了一定的分选效果。但人工提取特征存在耗时长且需要研究者具有较高的知识储备等问题,因此基于深度学习(DL)的雷达辐射源信号识别不失为一种可行的方案。深度学习广泛运用于模式识别<sup>[3]</sup>、图像处理<sup>[4]</sup>等领域,通过多层神经网络的非线性映射的堆叠来提取数据更抽象更深层次的特征<sup>[5]</sup>。其中,卷积神经网络(CNN)和循环神经网络(RNN)因强大的学习能力在众多领域已得到成熟的应用。文献[6]利用残差神经网络提取雷达信号的深层特征,同时加入了三元组损失函数,模型的准确率和扩展性都得到了较大提升。文献[7]对维度不一致的特征采用了新的编码方法,并通过一维CNN对处理后的等长新特征进行学习并分类识别,结果表明该方法在识别率、抗噪性能上都有所提升。文献[8]利用RNN的变体——长短时记忆(LSTM)神经网络,实现了心电信号的阻塞睡眠呼吸暂停检测并取得了较好的识别结果。文献[9]通过结合CNN和LSTM对心电信号心律失常进行分类,在准确率和分类时间上都有所提高。文献[10]通过双向长短时记忆(Bi\_LSTM)网络直接对雷达辐射源的原始信号进行特征提取和分类识别,分类效果较好并提高了鲁棒性。因此,本文在这些文献的基础上,采用CNN和Bi\_LSTM两种神经网络结合的方式对雷达辐射源信号进行分类识别。该模型同时兼顾了识别精度和识别效率,能提取信号的深层抽象特征,避免了人工提取特征时描述不完备的局限,同时有效降低了工程计算量和网络训练难度,提高了计算速度,模型的普适泛化性得到加强。

同时,文献[11]指出,模糊函数(AF)提供了对信号结构信息较为完整的描述,包含了信号丰富的时频域信息。而模糊函数主脊(AFMR)作为模糊能量最聚集的部分,其分布信息体现了AF分布特性,因此对AFMR进行研究有助于RES分选识别。文献[11]通过穷举法搜索AFMR并提取其旋转角、原点矩以及中心矩特征,该方法在一定程度上描述了模糊能量分布

特性且抗噪性能良好,但运算量大、耗费时间长,不适用于实际战场中雷达信号的复杂环境。文献[12]将笛卡尔坐标系中的AFMR转换到极坐标域以形成封闭的几何图像,然后提取该图像的似圆度、致密度和均面积作为特征向量,该方法在时效性和分选识别率上均有较大提高,验证了AFMR极坐标变换的可行性。但该方法只能提取信号的表面信息,无法充分反映信号内在深层次特征,导致在低信噪比下分选结果不理想。

针对传统方法无法反映信号内在深层特征、低信噪比下分类结果不理想等问题,本文在文献[11-12]的基础上,提出一种基于CNN\_Bi\_LSTM和AFMR极坐标变换的雷达信号识别方法。所提方法首先采用CNN提取AFMR极坐标域二维时频图的深层特征,然后通过Bi\_LSTM网络学习卷积运算提取到的深层特征,最后利用全连接层和Softmax分类器对雷达信号进行分类识别。仿真结果表明,所提方法在识别率、时效性上均优于传统的雷达信号识别方法。

## 2 理论基础

### 2.1 AFMR提取

任意窄带雷达辐射源信号 $s(t)$ 的AF<sup>[11]</sup>可以定义为

$$\chi_s(\tau, \xi) = \int_{-\infty}^{+\infty} s(t + \frac{\tau}{2}) s^*(t - \frac{\tau}{2}) e^{-j2\pi\xi t} dt, \quad (1)$$

式中: $\chi_s(\tau, \xi)$ 为AF; $\tau$ 为时延; $\xi$ 为频移; $s^*(t)$ 是 $s(t)$ 的共轭。AF提供了一个信号及其自身经时延和频移后所得信号间的相似性度量,反映了信号本身内在结构上的特性。

AF在零点处有最大值,所以过原点至少会有一条模糊能量的主要分布带,即为AFMR。Akay等定义了AF和分数自相关运算关系<sup>[13]</sup>:

$$[C^\alpha(s, s)](\rho) = \chi_s(\rho \cos \alpha, \rho \sin \alpha), \quad (2)$$

式中: $C^\alpha$ 是旋转角为 $\alpha$ 的分数域 $u_\alpha$ 上的分数自相关算子; $\rho$ 为 $u_\alpha$ 域的径向距离。式(2)表明,旋转角为 $\alpha$ 的分数域的自相关等价于该分数域上AF的径向切面。所以,通过分数傅里叶变换的快速离散方法,便可计算AF任意过原点的径向切面。文献[10]构建了检测测量:

$$D_{RS}(\alpha) = \frac{\int [C^\alpha(s, s)](\rho) d\rho}{\int |s(t)| dt}, \quad |\alpha| < \pi/2, \quad (3)$$

式中:分母是归一化系数,目的是减小噪声和信号能量对 $D_{RS}(\alpha)$ 的影响, $D_{RS}(\alpha)$ 的最大值即为AFMR。为保证搜索的准确性,采用穷举法对AF切片进行搜索,6类雷达信号在信噪比为20 dB和0 dB下的AFMR切面如图1所示。

图1中,6类雷达信号分别为常规信号(CON)、线性调频信号(LFM)、二相编码(BPSK)、四相编码

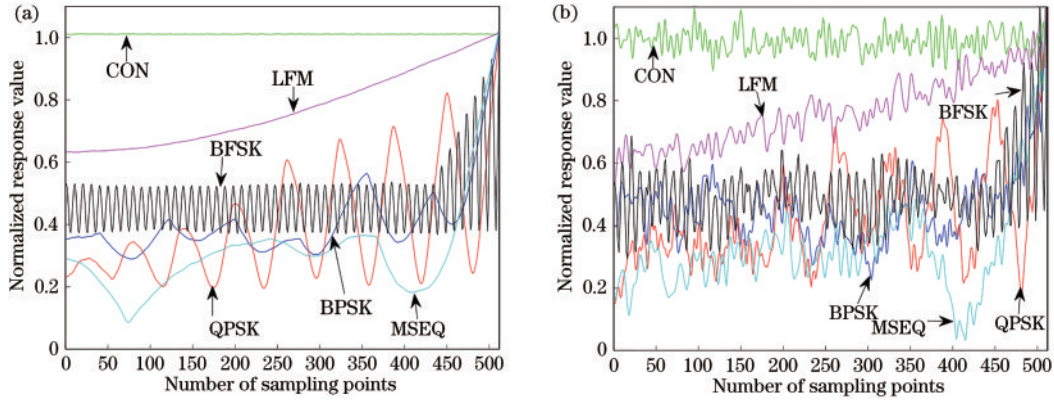


图 1 6类雷达信号的主脊切面对比。(a) 20 dB; (b) 0 dB

Fig. 1 Comparison of main ridge sections of six radar signals. (a) 20 dB; (b) 0 dB

(QPSK)、M 伪随机序列 (MSEQ) 以及二频编码 (BFSK)。从图 1 可以看出: CON、LFM 以及 BFSK 能明显区别于其他三类信号; BPSK、QPSK 和 MSEQ 则发生了混叠, 这是因为该三种信号都为非线性调制信号, 其中 BPSK 和 QPSK 仅仅只是相位调制的阶数不同, 频域上差异不显著, 所以两者的 AFMR 交叠更为严重。

## 2.2 AFMR 极坐标变换

为了解决上述问题, 从坐标转换的角度出发, 将笛卡尔坐标系的原图映射到极坐标系当中, 转换后的 AFMR 为一个封闭的二维图像。坐标转换公式为

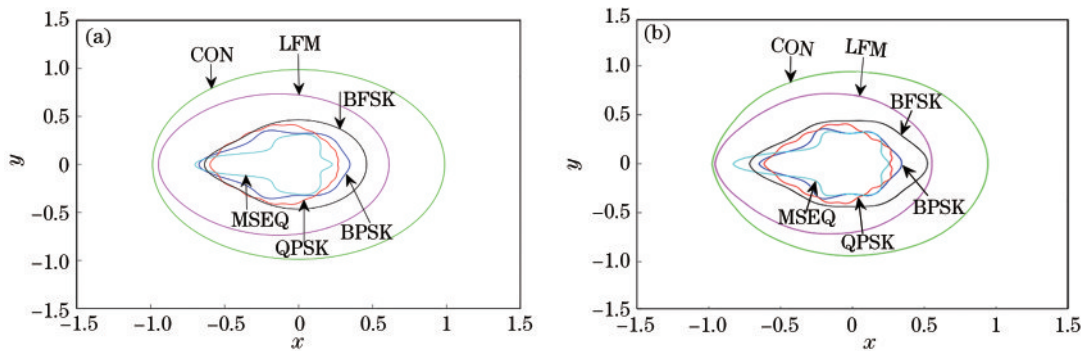


图 2 6类信号的极坐标 AFMR 切面对比。(a) 20 dB; (b) 0 dB

Fig. 2 Polar coordinate AFMR face ratio of six types of signals. (a) 20 dB; (b) 0 dB

## 3 基于 CNN\_Bi\_LSTM 的极坐标 AFMR 切面识别方法

### 3.1 卷积神经网络

卷积神经网络由纽约大学的 LeCun 等<sup>[14]</sup>提出, 本质是通过多个卷积核来提取模型输入的深层次抽象特征, 具体结构如图 3 所示。

CNN 通过卷积操作处理前一个神经元的参数, 以此来降低网络复杂度。卷积核以一定的步长在特征图上移动来获取图片的特征, 然后传递给激活函数, 激活

$$\begin{cases} x_{u_a} = C_{MRS}(u_a) \cos(2\pi \cdot u_a) \\ y_{u_a} = C_{MRS}(u_a) \sin(2\pi \cdot u_a) \end{cases} \quad (4)$$

式中:  $u_a$  为主脊切面所在分数域;  $C_{MRS}(u_a)$  表示 AFMR。令  $u_a$  为转换角度,  $C_{MRS}(u_a)$  为半径。然而转换的二维图像有许多毛刺与突起, 为了不影响图像的形状, 采用两次 80 点滑动平均方法对图形进行降噪处理。图 2 为 6 类信号在信噪比为 20 dB 和 0 dB 环境下的极坐标 AFMR 图像。

由图 2 可以看出, 6 类信号的形状、大小有明显区别, 即使图像有所交叠, 但 CNN 具有强大的学习和提取图像深层抽象特征的能力, 因此采用 AFMR 极坐标时频图作为 CNN 输入的想法是可行的。

函数将新得到的特征传递给下一层, 基本公式为

$$\mathbf{x}_i^j = f\left(\sum_{i \in M_j} \mathbf{x}_i^{(j-1)} * \boldsymbol{\omega}_{il}^j + \mathbf{b}_i^j\right), \quad (5)$$

式中:  $\mathbf{x}$  为输入和输出层;  $i, l$  为位置顺序;  $j$  是当前卷积层对应层数;  $\boldsymbol{\omega}$  为权值矩阵;  $\mathbf{b}$  为偏置;  $f(\cdot)$  是激活函数;  $M_j$  为第  $j$  层的特征图个数。

为了进一步加快运算速度, 降低参数数量, 在卷积层后引入池化层, 从而对卷积后的特征向量进行降维, 计算公式为

$$\mathbf{x}_i = \text{down}(\mathbf{x}_{i-1}), \quad (6)$$

式中:  $\mathbf{x}_{i-1}$  为池化前的特征量;  $\mathbf{x}_i$  为池化后的特征量;






图3 CNN的基本结构

Fig. 3 Basic structure of CNN

down(·)为池化函数。常用的池化方法有平均池化和最大池化,由于平均池化能避免过拟合和提高鲁棒性,故所提方法采用平均池化对特征分布进行降维。

### 3.2 长短时记忆网络

LSTM是RNN的一类变体,由输入层、隐藏层和输出层组成。同RNN相比,LSTM解决了RNN中存在的梯度消散和长期记忆的问题,结构如图4所示。




图4 LSTM网络结构

Fig. 4 LSTM network structure

LSTM的核心概念在于细胞状态(Cell State)和“门”结构。它由输入门、遗忘门和输出门构成, $t$ 时刻状态下的计算过程为

$$\begin{cases} f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \\ C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \\ o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ h_t = o_t * \tanh(C_t) \end{cases} \quad (7)$$

式中: $f_t$ 、 $i_t$ 、 $o_t$ 分别表示三个门的计算结果; $x_t$ 、 $h_t$ 为输入和输出; $\tilde{C}_t$ 为临时细胞状态, $C_t$ 为当前时刻细胞状态; $W_f$ 、 $W_i$ 和 $W_o$ 分别表示对应门的权值矩阵; $b_f$ 、 $b_i$ 和 $b_o$ 表示其对应的偏置项; $W_c$ 为临时细胞状态的权值矩阵, $b_c$ 为其偏置; $\sigma$ 和 $\tanh$ 为激活函数。

### 3.3 双向长短时记忆网络

双向长短时记忆网络是一个双向的循环神经网络,由前向LSTM和后向LSTM组合而成。与常规LSTM相比,其结合了输入序列在前向和后向两个方向的信息,模型的输出由这两个LSTM层的输出通过相加或取平均值等方式所决定,具体结构如图5所示。




图5 Bi\_LSTM网络结构

Fig. 5 Bi\_LSTM network structure

### 3.4 卷积双向长短时记忆网络

CNN能提取信号频域特征且特征可变能力强,Bi\_LSTM可以提取信号时域特征且能突出信号的时序性,模型深度是挖掘隐藏抽象特征和提高模型泛化性的关键所在。因此,为了克服CNN和Bi\_LSTM结合时模型泛化能力不强、维度不一致以及过拟合等问题,对所有的极坐标图像进行灰度化处理,得到维度为 $300 \times 300 \times 1$ 的统一格式,并搭建四层卷积层将图像降维成 $15 \times 15 \times 1$ ,进行多次实验调整参数;同时为匹配Bi\_LSTM层的输入维度,将CNN表达能力和可分辨能力强的输出特征处理成 $2 \times 1350$ 的特征向量,并输入到Bi\_LSTM中,以此来进行分类识别。通过CNN\_Bi\_LSTM学习AFMR极坐标二维时频特征分布并对信号进行分类识别的算法流程如图6所示。

## 4 实验结果与分析

首先采用Matlab生成CON、LFM、BPSK、QPSK、MSEQ和BFSK六类典型雷达辐射源信号。

1	The experimental platform: Matlab2019
2	Initial change;
3	Emitter: radar emitter to be classified
4	Num: number of signals generated by each radar emitter
5	SNR: signal-to-noise ratio
6	$n$ : signal length
7	$M$ : signal resampling length
8	for all Emitter do
9	for all SNR do
10	for all Num do
11	discrete signals: $s(n)$ ;
12	resample $s(n)$ because of $M/n$ ;
13	find the AFMR polar coordinate diagram according to section 1.1;
14	using 80-point average filtering twice to reduce the noise of the AFMR polar graph;
15	grayed out, resampled to [300 300 1] and saved;
16	end for
17	end for
18	end for
19	Experimental platform: Python3.6 and Tensorflow1.15.0;
20	Using CNN_Bi_LSTM to classification and recognition;
21	Statistical recognition rate and time

图 6 基于 CNN\_Bi\_LSTM 的极坐标 AFMR 切面识别算法

Fig. 6 Polar coordinate AFMR aspect recognition algorithm based on CNN\_Bi\_LSTM

其中, LFM 的带宽为 10 MHz, BPSK 和 BFSK 都采用 13 位 Barker 码, QPSK 采用 16 位 Frank 码, MSEQ 所用伪随机序列(1011100), 所有信号的 PW 均为 10  $\mu$ s, 采样频率为 60 MHz。此外, 除 BFSK 信号的两个频点分别取 10 MHz 和 2 MHz 外, 其余信号载频均为 10 MHz。在 -10 dB~12 dB 信噪比下, 每类信号每隔 2 dB 产生 20 个信号, 共 1440 个信号作为训练集, 每类信号在不同信噪比下各产生 100 个, 即每个测试集有 600 个信号。模型训练时使用 Python3.6 和 Tensorflow1.15.0。

#### 4.1 模型层数性能对比

模型当中两类神经网络的层数搭建对信号的分选识别有着至关重要的影响, 为探究出网络层数搭建的最优组合, 将模型当中的网络层数作为变量, 选取的评价标准为验证集的损失, 实验结果如表 1 所示。

表 1 不同网络结构下的实验结果

Table 1 Experimental results of different network structures

Number	Structure	Loss
1	3CNN+1Bi_LSTM	0.2743
2	4CNN+1Bi_LSTM	0.2026
3	5CNN+1Bi_LSTM	0.3030
4	3CNN+2Bi_LSTM	0.2865
5	4CNN+2Bi_LSTM	0.2633
6	5CNN+2Bi_LSTM	0.3255

由表 1 结果可得, 在 6 组对比实验中, 第 2 组的损失最低, 说明第 2 组的网络层数结构的识别能力更好。固定 Bi\_LSTM 为 1 层时, 通过对比第 1 组、第 2 组以及第 3 组实验, 结果说明卷积层层数不是越多越好。对

于小样本分类的神经网络来说, 当识别率在浅层网络达到最优时, 再增加网络层数容易造成梯度弥散或梯度爆炸并陷入局部最优, 而且随着网络层数的增加, 参数变多, 降低了模型计算速度。同时卷积层层数也不是越少越好, 提取抽象特征能力不够会造成识别率不高, 同理可解释在固定 Bi\_LSTM 为 2 层时验证集损失的变化情况。第 1 组与第 4 组、第 2 组与第 5 组、第 3 组与第 6 组的对比说明增加 Bi\_LSTM 层的数量并不能提升网络的识别能力, 增加 Bi\_LSTM 层后损失反而增加, 这是因为 Bi\_LSTM 层结构相对复杂, 其内部参数较多, 当网络深度增加时, 运算量变大, 导致训练效率降低。一般来说, Bi\_LSTM 设置为 1 层时就能较好地完成建模。

#### 4.2 与人工特征提取性能比较

与人工提取方法相比, 深度学习能够提取信号的隐藏特征。为对比深度学习方法与人工方法在不同信噪比(SNR)下的性能, 选取文献[15]、文献[16]和文献[17]中的方法和所提方法进行对比, 结果如图 7 所示。

从图 7 可知, 文献[15]中的方法在信噪比为 -2 dB 时的准确率仅为 72%, 因为双谱估计法在低信噪比下鲁棒性不高, 易受噪声的影响, 从而导致识别率较低。文献[17]中的方法通过投影 AF 三维图获得其等高线, 充分利用了一些海拔较高的 AF 地貌特征, 然而当信噪比较低时大部分 AF 地貌特征由于噪声干扰而消失, 因此其准确率在 0 dB 以下大幅度下滑。文献[16]中的方法的旋转角系数和对称 Holder 系数特征与其他两种方法的特征相比, 在低信噪比下识别率有所提升, -2 dB 时准确率为 79%, 但也不能达到理想




图 7 所提方法与人工方法的识别率对比

Fig. 7 Comparison of recognition rate between the proposed method and manual methods

的效果,而且该方法工程运算量大、时效性较低。三种人工方法在低信噪比情况下均表现不佳,这是因为人工方法不能提取到信号的深层次特征,只能提取表征信息,而信号的大部分信息在低信噪比下基本被噪声淹没。深度学习方法能更好地描述信号的内在信息,在低信噪比下的表现依旧良好,识别率在-2 dB时也远高于人工方法,所以从深度学习角度对雷达信号进行分类识别能大大提升在低信噪比下的信号准确率。

### 4.3 与其他深度学习方法对比

为探究所提方法在雷达辐射源信号识别领域的高效性,对所提方法与其他深度学习方法进行对比,结果如图 8 所示。

由图 8 可知,所提方法无论在何种信噪比下的识别率都远高于其他方法,这是因为所提方法充分提取了信号的时频域特征且经过极坐标转换后的 AFMR

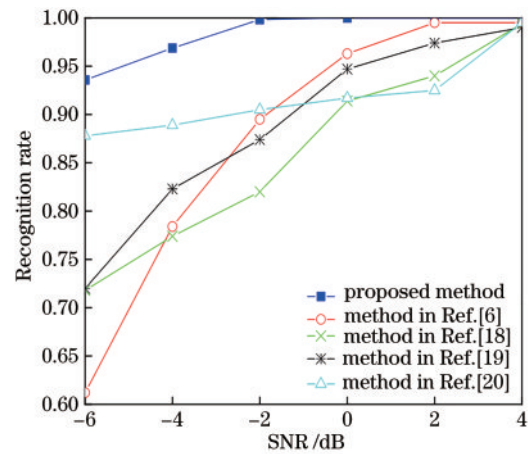


图 8 所提方法与其他深度学习方法的识别率对比

Fig. 8 Comparison of recognition rate between the proposed method and other deep learning methods

抗噪性能较强。文献[6]中的方法在-6 dB时的识别率仅为 61.2%,其模型输入为雷达原始信号,受噪声干扰较大,虽然该方法把损失函数替换为三元组损失函数,但只能增加模型的扩展性,并不能增强鲁棒性。文献[18]中的方法利用短时傅里叶变换对信号进行特征提取并对提取到的特征重新进行排列组合,然后利用广义回归神经网络进行分类识别,该方法易受噪声干扰且方法复杂度较大。文献[19]中的方法在对信号进行降维的同时损失了较多信息,导致识别率不高。文献[20]中的信号双谱图在低信噪比下混叠较为严重且 CNN 不能同时兼顾时频域信息。

### 4.4 不同方法性能对比

为了进一步探究所提方法的性能,从 AFMR 极坐标转换前后和不同神经网络两方面进行对比,结果如表 2 所示。

表 2 不同分类方法的识别率

Table 2 Recognition rate of different classification methods

Number	Method	Recognition rate / %					Time of an epoch / s
		-6 dB	-4 dB	-2 dB	0 dB	2 dB	
1	Proposed method	93.58	96.88	99.83	100	1	59
2	One-dimensional AFMR+LSTM	85.12	93.24	96.27	99.25	1	165
3	One-dimensional AFMR+SAE	82.33	96.83	98.83	99.55	1	96
4	One-dimensional AFMR+Bi_LSTM	86.12	94.57	95.63	99.42	1	462
5	Two-dimensional AFMR+CNN	93.17	96.33	99.50	100	1	85

从表 2 可以看出:在不考虑神经网络的情况下,二维 AFMR 在识别精度和平均用时上都高于一维 AFMR,这是因为 AFMR 在经过极坐标转换后放大了不同信号之间的差异,且信息没有受到损耗;第 1 组和第 5 组两者精度差别不大,但第 5 组在一次 epoch 所需时间上却是第 1 组的 1.5 倍左右,而深度学习又是需要进行多个 epoch 学习的过程,同时 CNN 的生物学基础支持不足,没有记忆功能,无法将前一时间信息和

当前时刻信息、未来时刻信息联系起来,由此可知所提方法大大加快了模型的计算速度;第 2 组、第 3 组及第 4 组在识别率和平均用时上均不如第 1 组,这是由于所提方法在经过 4 层 CNN 特征提取过后,特征维度大大降低,计算速度加快,并且 CNN 提取到的特征都是较高质量的特征,能够提升网络的识别率。虽然 SAE 也能降低特征维度,但是其降维幅度不如 CNN,对输入数据的平移不变性要求较高。LSTM 只注重



过去信息,无法从后往前对信息进行编码,因此不能利用输入的未来信息,又因其和 Bi\_LSTM 均具有特殊的门结构,从而参数繁杂、耗时长,且不同信号的一维 AFMR 在低信噪比下无明显差异,导致分类结果不理想。

综合所提方法和其余四种方法的对比结果可知,所提方法能够有效弥补其余算法精度低、训练难度大等不足,进而可以得到相对更为科学的实验结果。

#### 4.5 特征提取方法复杂度对比

从表 2 可以看出,各类方法所需的时间都不尽相同,从侧面反映了各类方法计算量的差异,这主要取决于信号重采样的点数  $N$ ,因此可根据采样长度  $N$  对所提方法、AFMR 极坐标转换前的所提方法、文献[15]中的方法、文献[17]中的方法以及文献[21]中的方法的计算量进行分析。

AFMR 的提取过程中,首先利用分数自相关计算任意角度对应的 AF 值,一次分数自相关运算包含一个  $1+P$  阶的分数傅里叶变换和一次傅里叶逆变换,其中快速分数傅里叶变换复杂度为  $O(9N \log N)$ ,傅里叶逆变换复杂度为  $O(N \log N)$ ;其次,在  $[-\pi/2, \pi/2]$  范围内对 AFMR 进行搜索,搜索精度为  $0.1^\circ$  时的搜索次数为 1800,因此 AFMR 极坐标转换前的复杂度为  $O(18000N \log N)$ 。在上述基础上对 AFMR 进行了极坐标变换,该环节复杂度为  $O(7N)$ ,故所提方法的复杂度为  $O(7N + 18000N \log N)$ 。

对于文献[15]双谱特征的复杂度,需计算双谱幅度谱和双谱幅度谱特征截面的分形维数。对于双谱幅度谱的计算,需要进行  $K$  (数据分段数) 次快速傅里叶变换计算,该环节的复杂度为  $O(KN \log N)$ ;而双谱幅度谱特征截面的分形维数包含盒维数与信息维数,复杂度为  $O(2N)$ ,因此文献[15]中的方法复杂度为  $O(2N + KN \log N)$ 。

文献[17]通过快速傅里叶变换直接计算网格采样的离散 AF 值,其次在高斯平滑环节中,先对 AF 逐行平滑,再对中间结果逐列平滑,该环节复杂度为  $O(2MN^2)$ ,  $M$  为高斯掩模的尺寸。而在等高线求解环节中考虑最坏情况,即所有相邻 AF 之间均存在等值点,该环节复杂度为  $O(3N^2)$ ,所以文献[17]中的方法复杂度为  $O(N \log N + (2M+3)N^2)$ 。

文献[21]采用 Choi-William 分布 (CWD) 作为分形维数的提取对象,其次采用复杂度为  $O(N^3)$  的奇异值分解进行矩阵相乘运算,频谱和 CWD 变换采用快速傅里叶变换实现,所以方法复杂度为  $O(N^3 + 2N + 2N \log N)$ 。

综上所述,从方法阶数分析,文献[21]中的方法的复杂度阶数最高,其次是文献[17]中的方法,所提

方法与 AFMR 极坐标转换前的所提方法、文献[15]中的方法的复杂度阶数最低,不过常数系数都不尽相同,所以方法复杂度主要取决于  $N$  的取值。因此,当采样长度  $N$  较长时,方法复杂度总计算量  $C$  的比较结果为  $C_{\text{method in Ref. [15]}} < C_{\text{before transformation}} < C_{\text{proposed method}} < C_{\text{method in Ref. [17]}} < C_{\text{method in Ref. [21]}}$ 。然而,当采样长度  $N$  较短时,方法复杂度总计算量  $C$  比较结果为  $C_{\text{method in Ref. [15]}} < C_{\text{method in Ref. [17]}} < C_{\text{method in Ref. [21]}} < C_{\text{before transformation}} < C_{\text{proposed method}}$ 。所提方法复杂度高的原因是为了确保 AFMR 的搜索精度,采用了穷举法进行搜索,因此复杂度虽然略高,但是能够保证高搜索精度和高识别率。

## 5 结 论

所提基于 AFMR 极坐标变换和 CNN\_Bi\_LSTM 的雷达辐射源识别方法不仅综合了两种神经网络的优势,而且放大了不同信号之间的差异,有效克服了人工提取特征方法耗时长,常规神经网络不能兼顾信号时频域信息等问题。实验结果表明,所提方法在  $-6$  dB 环境下的识别率仍能保持在 90% 以上,在与其他文献和不同分类算法的对比中,所提方法在识别率、训练难度和用时上均高于其他方法,而且具有更强的噪声稳健性,为雷达辐射源信号识别研究提供切实可行的研究思路,对电子对抗信号特征提取具有一定的指导意义。不过这里仅对 6 类信号进行实验分析,模型的普适性将是下一步的研究重点,同时考虑其他机器学习方法在雷达辐射源信号识别领域的应用。

## 参 考 文 献

- [1] 王利国,李亚清,巩蕾,等. 基于动态散斑时频特性的合作目标微动参数反演[J]. 光学学报, 2021, 41(2): 0228001.  
Wang L G, Li Y Q, Gong L, et al. Inversion algorithm for micro-motion parameters of a cooperative target based on time-frequency feature of dynamic speckle[J]. Acta Optica Sinica, 2021, 41(2): 0228001.
- [2] 王星,周一鹏,周东青,等. 基于深度置信网络和双谱对角切片的低截获概率雷达信号识别[J]. 电子与信息学报, 2016, 38(11): 2972-2976.  
Wang X, Zhou Y P, Zhou D Q, et al. Research on low probability of intercept radar signal recognition using deep belief network and bispectra diagonal slice[J]. Journal of Electronics & Information Technology, 2016, 38(11): 2972-2976.
- [3] 刘天元,鲍劲松,汪俊亮,等. 融合时序信息的激光焊接熔透状态识别方法[J]. 中国激光, 2021, 48(6): 0602119.  
Liu T Y, Bao J S, Wang J L, et al. Laser welding penetration state recognition method fused with timing information[J]. Chinese Journal of Lasers, 2021, 48(6): 0602119.
- [4] 方维,杨奎. 基于逆深度自适应加权的多视图三角化方法[J]. 中国激光, 2020, 47(12): 1204007.

- Fang W, Yang K. Inverse depth adaptive weighting based multi-view triangulation method[J]. Chinese Journal of Lasers, 2020, 47(12): 1204007.
- [5] 胡越, 罗东阳, 花奎, 等. 关于深度学习的综述与讨论[J]. 智能系统学报, 2019, 14(1): 1-19.
- Hu Y, Luo D Y, Hua K, et al. Overview on deep learning full text replacement[J]. CAAI Transactions on Intelligent Systems, 2019, 14(1): 1-19.
- [6] 石礼盟, 杨承志, 吴宏超. 基于深层残差网络和三元组损失的雷达信号识别方法[J]. 系统工程与电子技术, 2020, 42(11): 2506-2512.
- Shi L M, Yang C Z, Wu H C. Radar signal recognition method based on deep residual network and triplet loss[J]. Systems Engineering and Electronics, 2020, 42(11): 2506-2512.
- [7] Sun J, Xu G L, Ren W J, et al. Radar emitter classification based on unidimensional convolutional neural network[J]. IET Radar, Sonar & Navigation, 2018, 12(8): 862-867.
- [8] Cheng M W, Sori W J, Jiang F, et al. Recurrent neural network based classification of ECG signal features for obstruction of sleep apnea detection[C]//2017 IEEE International Conference on Computational Science and Engineering (CSE) and IEEE International Conference on Embedded and Ubiquitous Computing (EUC), July 21-24, 2017, Guangzhou, China. New York: IEEE Press, 2017: 199-202.
- [9] 柯丽, 王丹妮, 杜强, 等. 基于卷积长短时记忆网络的心律失常分类方法[J]. 电子与信息学报, 2020, 42(8): 1990-1998.
- Ke L, Wang D N, Du Q, et al. Arrhythmia classification based on convolutional long short term memory network[J]. Journal of Electronics & Information Technology, 2020, 42(8): 1990-1998.
- [10] 陈森森. 基于 RNN 的雷达辐射源分类识别算法研究[D]. 西安: 西安电子科技大学, 2019.
- Chen S S. Research on classification and recognition algorithm of radar signal based on RNN[D]. Xi'an: Xidian University, 2019.
- [11] 普运伟, 金炜东, 朱明, 等. 雷达辐射源信号模糊函数主脊切面特征提取方法[J]. 红外与毫米波学报, 2008, 27(2): 133-137.
- Pu Y W, Jin W D, Zhu M, et al. Extracting the main ridge slice characteristics of ambiguity function for radar emitter signals[J]. Journal of Infrared and Millimeter Waves, 2008, 27(2): 133-137.
- [12] 普运伟, 郭媛蒲, 侯文太, 等. 模糊函数主脊切面极坐标域形态特征提取方法[J]. 仪器仪表学报, 2018, 39(10): 1-9.
- Pu Y W, Guo Y P, Hou W T, et al. Morphological feature extraction based on the polar transformation of the slice of ambiguity function main ridge[J]. Chinese Journal of Scientific Instrument, 2018, 39(10): 1-9.
- [13] Akay O, Boudreaux-Bartels G F. Fractional convolution and correlation via operator methods and an application to detection of linear FM signals[J]. IEEE Transactions on Signal Processing, 2001, 49(5): 979-993.
- [14] LeCun Y, Boser B E, Denker J S, et al. Handwritten digit recognition with a back-propagation network[C]//Proceedings of the 2nd International Conference on Neural Information Processing Systems, November 27-30, 1989, Denver, Colorado, USA. San Francisco: Morgan Kaufmann, 1989: 396-404.
- [15] Chen C X, He M H, Xu J, et al. A new method for sorting unknown radar emitter signal[J]. Chinese Journal of Electronics, 2014, 23(3): 499-502.
- [16] Guo Q, Nan P L, Zhang X Y, et al. Recognition of radar emitter signals based on SVD and AF main ridge slice[J]. Journal of Communications and Networks, 2015, 17(5): 491-498.
- [17] 侯文太, 普运伟, 郭媛蒲, 等. 基于高斯平滑与模糊函数等高线的雷达辐射源信号分选[J]. 自动化学报, 2021, 47(10): 2484-2493.
- Hou W T, Pu Y W, Guo Y P, et al. Radar emitter signal sorting based on Gaussian smoothing and ambiguity function contours[J]. Acta Automatica Sinica, 2021, 47(10): 2484-2493.
- [18] 蒋兵, 茅玉龙, 曹俊纺. GRNN 神经网络在雷达信号调制类型识别中的应用[J]. 电子设计工程, 2018, 26(16): 111-115.
- Jiang B, Mao Y L, Cao J F. Application of GRNN neural network model in radar signal modulation type recognition[J]. Electronic Design Engineering, 2018, 26(16): 111-115.
- [19] 周志文, 黄高明, 高俊, 等. 一种深度学习的雷达辐射源识别算法[J]. 西安电子科技大学学报, 2017, 44(3): 77-82.
- Zhou Z W, Huang G M, Gao J, et al. Radar emitter identification algorithm based on deep learning[J]. Journal of Xidian University, 2017, 44(3): 77-82.
- [20] 刘赢, 田润澜, 王晓峰. 基于深层卷积神经网络和双谱特征的雷达信号识别方法[J]. 系统工程与电子技术, 2019, 41(9): 1998-2005.
- Liu Y, Tian R L, Wang X F. Radar signal recognition method based on deep convolutional neural network and bispectrum feature[J]. Systems Engineering and Electronics, 2019, 41(9): 1998-2005.
- [21] 曲志昱, 毛校洁, 侯长波. 基于奇异值熵和分形维数的雷达信号识别[J]. 系统工程与电子技术, 2018, 40(2): 303-307.
- Qu Z Y, Mao X J, Hou C B. Radar signal recognition based on singular value entropy and fractal dimension[J]. Systems Engineering and Electronics, 2018, 40(2): 303-307.