

# 基于卷积神经网络的低分辨雷达目标一步识别技术

朱克凡, 王杰贵

(国防科技大学电子对抗学院, 合肥, 230037)

**摘要** 现有低分辨雷达目标识别通常采用先特征提取、再进行目标分类的两步识别算法, 存在识别率难以提高和方法泛化性不足的问题, 因此提出了一种基于卷积神经网络(CNN)的低分辨雷达目标一步识别算法。该算法直接将采样数据作为输入, 利用设计的一维 CNN, 通过卷积池化等操作自动获取数据深层本质特征, 无需特征提取, 实现对目标的一步识别。仿真实验结果表明: 基于 CNN 的低分辨雷达目标一步识别方法的识别率较传统基于提取特征的两步识别方法提高了 10.31%, 识别时间较传统两步识别方法减少了 0.142 s, 充分证明了一步识别方法的有效性, 为低分辨雷达目标识别问题提供了新的解决途径。

**关键词** 低分辨雷达目标识别; 一步识别算法; 卷积神经网络

**DOI** 10.3969/j.issn.1009-3516.2019.05.014

**中图分类号** TN957.52 **文献标志码** A **文章编号** 1009-3516(2019)05-0083-07

## Low-Resolution Radar Target One-Step Recognition Technology Based on Convolutional Neural Network

ZHU Kefan, WANG Jiegui

(Electronic Countermeasure Institute of National University of Defense Technology, Hefei 230037, China)

**Abstract:** In view of the problem of the existing methods of low-resolution radar target recognition, usually the two-step recognition algorithm is adopted to make feature extraction and target classification, which is not conducive to the improvement of recognition accuracy and the generalization of recognition methods, for the reason mentioned above, an one-step recognition algorithm based on Convolution Neural Network (CNN) for low-resolution radar target is proposed. This algorithm takes the sampled data as input directly, and uses the designed one-dimensional CNN to automatically obtain the deep essential features of the data without feature extraction through convolution pooling and other operations, realizing the one-step recognition of the target. The simulation results show that the recognition rate of the one-step recognition method is 10.31% higher than that of traditional two-step recognition method based on artificial feature extraction, and the recognition time of one-step recognition method is 0.142s less than that of two-step recognition method, which proves the effectiveness of one-step recognition method. The one-step recognition method provides a new solution for radar target recognition.

**Key words:** low-resolution radar target recognition; one-step recognition algorithm; Convolution Neural Network

收稿日期: 2019-05-14

基金项目: 预研基金项目(9140C100404120C1003)

作者简介: 朱克凡(1994—), 男, 山东青岛人, 硕士生, 主要从事深度学习, 智能信息处理研究。E-mail: 13865993110@163.com

**引用格式:** 朱克凡, 王杰贵. 基于卷积神经网络的低分辨雷达目标一步识别技术[J]. 空军工程大学学报(自然科学版), 2019, 20(5): 83-89.  
ZHU Kefan, WANG Jiegui. Low-Resolution Radar Target One-Step Recognition Technology Based on Convolutional Neural Network[J]. Journal of Air Force Engineering University (Natural Science Edition), 2019, 20(5): 83-89.

基于低分辨雷达的目标识别技术研究仍然是雷达研究的一个重要热点。传统低分辨雷达目标识别采用先特征提取后分类识别的两步识别方法,即首先基于回波起伏、极点分布以及调制谱特性等特征,对目标进行特征提取,然后采用贝叶斯、支持向量机(Support Vector Machine, SVM)、最近邻分类等方法对目标进行分类识别。文献[1]利用雷达目标一维距离像的时频特征对目标进行识别。文献[2]利用隐马尔科夫模型表征目标 RCS 变化规律,实现目标识别。文献[3]提取雷达目标多个特征构成多特征向量,基于 SVM 方法进行识别。文献[4]基于时频分布的倒双谱特征,提出了多种有效的特征提取方法。文献[5]提出了多重分形谱特征对目标进行分类。文献[6]基于窄带分形和相位调制特征对地面运动目标进行了有效识别。通过提取目标特征可以凸显目标间局部差异,实现对目标的分类识别,然而作为关键步骤的特征提取过程往往需要花费大量时间精力,且特征多为人工设计,对目标提取特征的同时也丢失了其他特征,不利于目标识别率的进一步提高,方法的泛化性也存在不足。

自 Hinton 等人提出深度学习理论后,深度学习学习方法被应用于各个领域<sup>[7-10]</sup>,卷积神经网络(Convolutional Neural Networks, CNN)作为该领域里的重要模型,由于能够自学习数据深层本质特征,应用在目标分类识别领域,识别准确度可以获得较大提升,较传统方法有明显优势,逐渐开始被应用于对辐射源信号<sup>[11]</sup>、语音信号<sup>[12]</sup>、水下目标<sup>[13]</sup>、SAR 图像<sup>[14]</sup>和 HRRP<sup>[15]</sup>等的分类识别中。

为解决传统的两步识别方法损失数据信息问题,提高识别精度,本文基于 CNN,提出了一种对低分辨雷达目标的一步识别算法。该算法直接将回波采样数据作为输入,通过设计的一维 CNN 来自动学习数据深层本质特征,并与 softmax 分类器结合,最终实现对雷达目标的一步识别。

## 1 基于卷积神经网络的低分辨雷达目标一步识别方法

CNN 是深度学习领域的一个重要模型,能够自动提取数据的深层特征,同时将特征提取、特征选择和特征分类融入到一个模型中,通过端到端的训练,从整体上进行功能优化,增强了自主学习到的特征的可分性,且 CNN 由于卷积层采用局部连接和权值共享等方式,具有平移不变性,特征的平移不影响其对目标的识别。应用于低分辨雷达目标识别领域,对于因目标运动存在特征平移的回波采样数据,

CNN 仍然可以自动提取其深层本质特征,且与传统的频谱熵值、RCS 等整体特征相比,CNN 还能够获取采样数据的局部特征。所以,将 CNN 应用于低分辨雷达目标识别领域是可行且有效的。

CNN 最初是针对图像数据而设计,更适合于处理二维图像。由于低分辨雷达目标信号是一维时序信号,无法直接将目标回波的采样数据输入 CNN,常见方式是对数据进行时频变换,将时序信号转换为时频图像,文献[16]提取信号全双谱特征输入 CNN,文献[17]提取信号时频特性作为 CNN 的输入。由于进行时频变换会损失数据信息,为保留目标全部差异信息,尽可能提高目标识别率,本文采取调整 CNN 结构的方式,设计了一维 CNN。

### 1.1 一维卷积神经网络设计

CNN 是一种深度前馈人工神经网络,包括卷积层、池化层及全连接层,基本结构见图 1。卷积层和池化层通过卷积和池化运算在隐式提取数据特征的同时大大降低了网络参数的数量,而全连接层将特征进行综合,并可与 softmax 分类器结合,在模式识别领域具有明显优势。

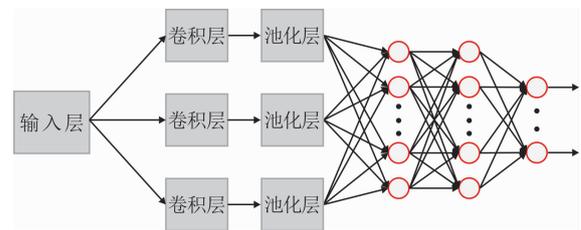


图1 卷积神经网络基本结构

低分辨雷达目标回波信号是一维时序信号,需要调整 CNN 的输入层、卷积核和池化层结构,设计出一维 CNN 与目标采样数据相匹配。

#### 1.1.1 卷积层

卷积层通过不同的卷积核与输入数据进行卷积操作实现特征提取。给定一个输入信号矩阵  $x \in m \times n$ , 和滤波器  $w \in i \times j$ , 滤波器依次对上一层的输入特征进行局部卷积操作。卷积的输出为:

$$y(u, v) = \sum_{k=1}^{\infty} \sum_{g=1}^{\infty} w(k, g) x(u-k, v-g) \quad (1)$$

卷积层采用局部连接的方式,通过一个激活函数实现对数据的非线性特征映射,本文选用 ReLU 激活函数:

$$f(x) = \max(0, x) \quad (2)$$

则第  $l$  层第  $i$  个神经元的输入为:

$$a_i^l = f(w^l \otimes a^{l-1} + b) \quad (3)$$

式中:  $w \in i \times j$  为  $i \times j$  维的滤波器;  $a \in m \times n$  为该层  $m \times n$  维的输入,  $b$  是偏置参数。

常用的二维卷积核大小为  $3 \times 3, 5 \times 5, 7 \times 7$ , 由

于一维采样数据维度远远大于常规二维图像的某一维度,若直接使用 $1 \times 3, 1 \times 5, 1 \times 7$ 的卷积核,一次卷积运算所处理的采样数据较少,不利于数据的降维和特征的学习。通过多次实验,选用了 $1 \times 13, 1 \times 11, 1 \times 5$ 作为各层卷积核维度。

### 1.1.2 池化层

池化层是通过下采样实现数据的压缩,避免过拟合。常见的池化方法包括最大池化和平均池化,本文采用最大池化的方法,即取区域内神经元的最大值。池化层将输入的特征映射 $x^l$ 划分为很多不重叠的区域 $P_k, k=1, 2, \dots, K$ 。

$$\text{pool}_{\max}(P_k) = \max_{i \in P_k, j \in P_k} a_{i,j} \quad (4)$$

为适应一维时序信号,池化层也相应调整为通过一维窗口对卷积层特征进行下采样处理。

### 1.1.3 全连接层

全连接层将池化层输出的局部特征依次连接成一维特征向量实现特征的整合,起到将“分布式特征表示”映射到样本标记空间的作用。本文结合连接层与 softmax 分类器,实现对目标的识别,全连接层的输出为 $1 \times k$ 的特征向量并输入 softmax 分类器,其中 $k$ 为目标类别数。

### 1.1.4 softmax 分类器

softmax 分类器用于解决多分类问题,分类器输入经过 softmax 函数获得目标后验概率向量,实现目标分类。类别标签 $y$ 可以取 $k$ 类不同的值,给定训练集 $\{(x(1), y(1)), \dots, (x(m), y(m))\}$ , $y(i) \in \{1, 2, \dots, k\}$ ,对于输入 $x$ ,通过 softmax 分类器估算属于类别 $j$ 的概率值 $p(y=j|x), j=1, 2, \dots, k$ 。假设 softmax 函数的输入数据是 $k$ 维度的向量 $z$ ,那么其输出数据也是一个 $k$ 维度的向量 $s$ 。softmax 函数是一个归一化的指数函数,定义如下:

$$h_{\theta}(x^{(i)}) = \begin{bmatrix} p(y^{(i)}=1|x^{(i)};\theta) \\ p(y^{(i)}=2|x^{(i)};\theta) \\ \vdots \\ p(y^{(i)}=k|x^{(i)};\theta) \end{bmatrix} = \frac{1}{\sum_{j=1}^k e^{\theta_j^T x^{(i)}}} \begin{bmatrix} e^{\theta_1^T x^{(i)}} \\ e^{\theta_2^T x^{(i)}} \\ \vdots \\ e^{\theta_k^T x^{(i)}} \end{bmatrix} \quad (5)$$

式中: $\theta_j^T$ 为网络权值,经过训练实现最小化代价函数的目的。代价函数采用交叉熵损失函数,定义如下:

$$J(\theta) = -\frac{1}{m} \sum_{i=1}^m \log h_{\theta_y^{(i)}}(x^{(i)}) \quad (6)$$

式中: $h_{\theta_y^{(i)}}(x^{(i)})$ 表示第 $i$ 个样本被预测为真实类别 $y^{(i)}$ 的概率。

将 $x^{(i)}$ 输入训练好的网络中,softmax 分类层将输出 $k$ 个概率值,其中值最大的类别作为目标的估计类。

### 1.1.5 一维 CNN 结构

为了进一步提高设计的一维 CNN 的识别性能,本文在网络中加入了归一化层和 Dropout 层,归一化层通过将输入参数做归一化处理,有效减少了初始化参数对网络的影响,提高了网络收敛速度;而 Dropout 层通过将输入参数随机置零来缓解网络过拟合现象。

一步识别算法中使用的一维 CNN 结构见表 1,共含有 3 个卷积层、3 个池化层、3 个归一化层、2 个 Dropout 层、1 个全连接层及 softmax 分类器。各卷积层包含 6 个 $1 \times 13$ 的卷积核,12 个 $1 \times 11$ 的卷积核和 30 个 $1 \times 5$ 的卷积核;各池化层采用 $1 \times 4, 1 \times 4$ 及 $1 \times 2$ 的小窗口对卷积后的特征进行不重叠的下采样;Dropout 层以 0.2 的概率随机将输入参数置零;通过计算可知,第 3 池化层的输出为 30 个 $1 \times 12$ 的特征向量,全连接层将输入特征依次连接成一维特征向量作为输入,本文识别目标为 3 类,则全连接层的结构为 $(360, 3)$ ,softmax 分类器输出 $1 \times 3$ 的目标识别后验概率向量。

表 1 一维卷积神经网络结构

输入层: $1 \times 500$ 时序信号
第 1 卷积层: $1 \times 13, 6, \text{ReLU}$
归一化层: 6
第 1 池化层: $1 \times 4$
Dropout = 0.2
第 2 卷积层: $1 \times 11, 12, \text{ReLU}$
归一化层: 12
第 2 池化层: $1 \times 4$
Dropout = 0.2
第 3 卷积层: $1 \times 5, 30, \text{ReLU}$
归一化层: 30
第 3 池化层: $1 \times 2$
全连接: $(360, 3)$
softmax 分类器
输出层: $1 \times 3$ 预测概率向量

## 1.2 一步识别算法

一步识别算法采用一维 CNN 结构,实现步骤如下:

**步骤 1** 取大量雷达目标信号采样数据作为训练样本输入卷积层,使用多个初始权值不同的卷积核对输入数据进行卷积,获得数据的特征映射向量并输入归一化层;

**步骤 2** 归一化层将输入参数做归一化处理后,输入池化层;

**步骤 3** 池化层通过一维窗口,采用不重叠的步进方式,对特征向量进行下采样处理,降低数据维度;

步骤4 Dropout层将池化后的参数随机置零;

步骤5 根据网络结构和各层数量,重复步骤1~4,并将第3次池化后的数据输入到全连接层;

步骤6 全连接层将输入的多个特征整合成一维特征向量,并通过softmax函数,输出各类识别概率组成向量,取概率向量中值最大的作为本次识别结果,将识别结果与训练样本标签对比来获取识别误差,利用误差反向传递来训练网络;

步骤7 取部分采样数据作为测试样本输入训练完毕的一维CNN,测试网络识别效果。

## 2 实验结果与分析

### 2.1 实验数据集

#### 2.1.1 低分辨雷达目标回波建模

现代雷达辐射源信号常采用脉冲压缩信号,如相位编码信号、线性调频(Linear Frequency Modulation, LFM)信号等,使用脉冲压缩技术可使雷达具有很高的径向分辨力,当雷达目标的尺寸大于径向分辨力时,运动目标占据多个距离单元,此时可以使用多散射点模型来模拟目标回波信号。

当雷达发射信号是LFM信号时,将与发射信号斜率相同的LFM参考信号作为本振信号,对接收到的回波信号进行变频、采样和幅度归一化处理,获得的回波采样数据为:

$$S(n) = \sum_i a\left(\frac{n}{f_s} - t_i\right) a\left(\frac{n}{f_s} - t_0\right) \exp\{j2\pi[f_m \frac{n}{f_s} + \phi]\} \tag{7}$$

式中: $i$ 表示目标多散射点模型中第 $i$ 个散射点;

$$a(t) = \begin{cases} 1, & |t| \leq \frac{T}{2} \\ 0, & \text{其他} \end{cases}, T \text{ 为调频周期}; f_s \text{ 是采样频率}; t_i = \frac{2R_i}{c}, R_i \text{ 为散射点 } i \text{ 的距离}, c \text{ 为光速}; t_0 = \frac{2R_0}{c}, R_0 \text{ 为目标参考距离}; f_m \text{ 是混频后信号频率},$$

$$f_m = \frac{2k(R_i - R_0)}{c}, k \text{ 为调频斜率}; \phi = f_0(t_i - t_0) + \frac{1}{2}(t_0^2 - t_i^2), f_0 \text{ 是中心频率}。$$

2.1.2 数据集参数设置

实验数据集由python语言编程软件生成,仿真参数设置:LFM信号载频为3GHz,调频周期0.1ms,调频带宽100MHz,采样频率5MHz。数值仿真实验对3类目标进行目标识别,分别为人、摩托车、卡车。人的速度是0~6km/h,摩托车是0~40km/h,卡车是0~80km/h,取1个调频周期内的

采样数据作为1个样本,通过计算可知样本大小为 $1 \times 500$ ,3种类别标签分别用(0,1,2)表示。训练样本集与测试样本集分别独立产生,其中训练集每类目标各1920个样本,共5760个样本;测试集每类目标各200个样本,共600个样本。

### 2.2 本文方法识别性能

为了验证一步识别方法的可行性,对3类目标进行识别实验。用添加高斯白噪声的方法对数据进行加噪处理,实验采用SNR=-4dB的仿真目标回波采样数据作为网络输入,使用设计的一维CNN结构作为识别网络。图2是3类目标的识别混淆矩阵,混淆矩阵中每一列表示目标所属的真实类别,每一行表示一维CNN的识别结果,标签从上至下,从左至右依次为卡车、摩托车和人。

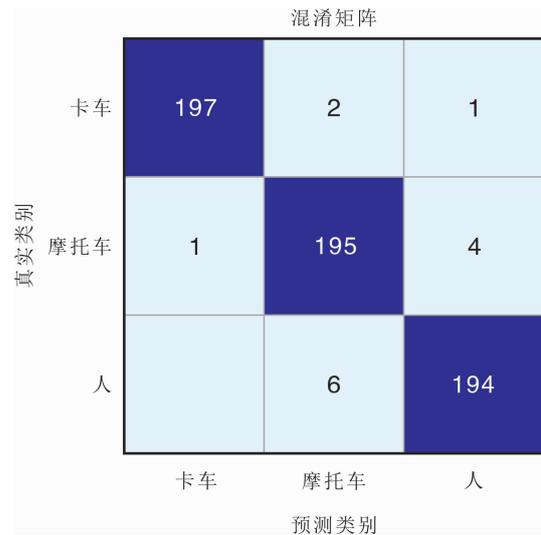


图2 识别混淆矩阵

图3是一步识别方法的接收者操作特征曲线(Receiver Operating Characteristic Curve, ROC)曲线和ROC曲线下方的面积(Area Under the Curve of ROC, AUC)。

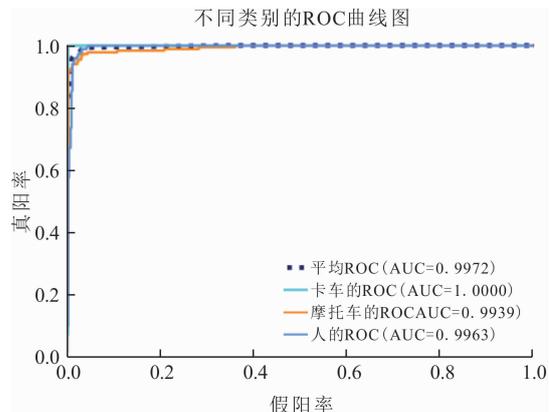


图3 ROC曲线和AUC值

图中AUC值通过计算ROC曲线与横坐标所围成的面积获得,能够很好地描述分类器整体性能

的高低。从图 2 和图 3 可以看出,虽然一步识别方法识别 3 类目标的效果有差异,但在 SNR = -4 dB 的条件下,3 类目标的最低识别率仍达到了 97.00%,最低 AUC 值依然达到了 0.993 9,说明基于一维 CNN 的低分辨雷达目标一步识别方法对人、摩托车和卡车 3 类目标都能进行有效识别。

CNN 中卷积层负责特征学习,输出特征表示为特征图。卷积核与输入的若干特征图作卷积,对应结果求和并加上偏置后,传递给 ReLU 激活函数,获得该卷积核对应的特征图,从而实现特征提取。将 3 类目标采样数据输入训练好的一维 CNN,各卷积层通过卷积运算得到的目标特征见图 4。

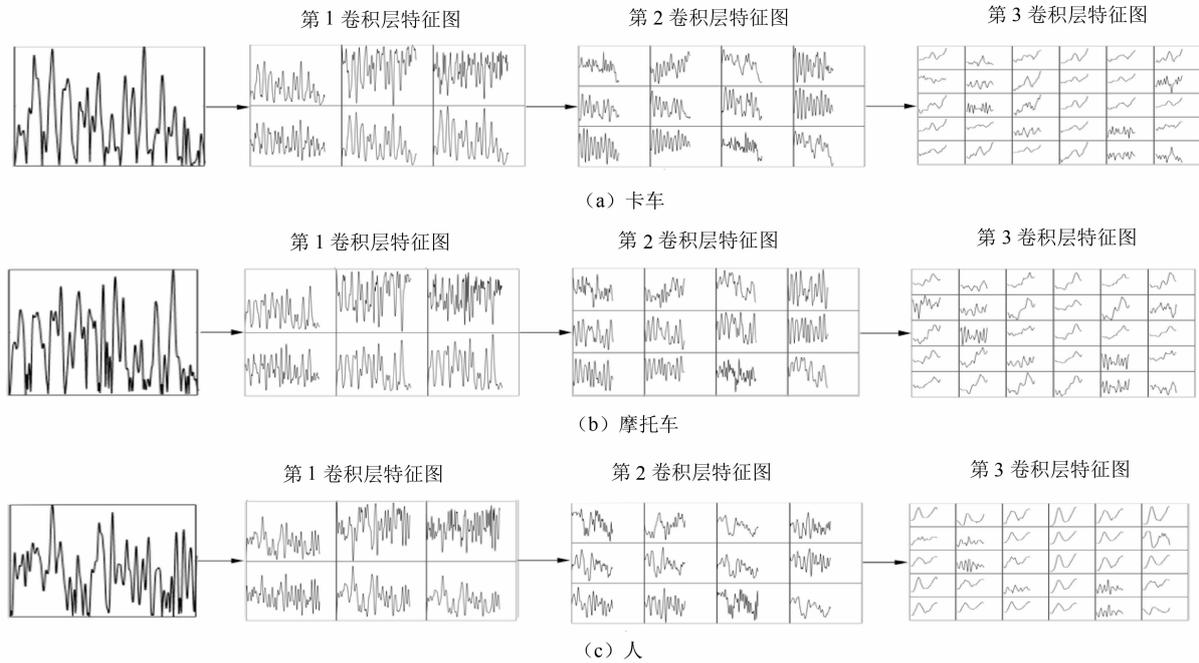


图 4 各卷积层特征图

从图 4 可以看出,由于卷积和池化运算,各卷积层获取的特征维度减小,高阶特征抽象化程度高。不同输入在相同卷积核的处理下的高阶特征差异明显,充分说明了一维 CNN 能够自动学习数据特征,且层数越多,CNN 自学习能力越强,能获取数据更深层特征。当然,盲目增加卷积层数量是不可取的,一是随着数量增多,目标识别率上升缓慢甚至不再增长,二是太多的卷积层会在训练阶段占用大量的计算资源和训练时间,且网络结构越复杂,为了防止过拟合,需要的训练样本数越多。所以应经过多次调试,确定最适合的网络结构。

2.3 与采用二维 CNN 识别方法的性能对比

对一维时序信号使用 CNN,常见的方法是提取信号的时频特征,将一维时序信号转换为二维时频图像输入 CNN,实现目标分类,但由于时频变换会损失数据信息,不利于识别精度的提高。

为了说明本文设计的一维 CNN 结构应用于低分辨雷达目标识别领域的有效性,与采用时频变换的二维 CNN 识别方法进行对比<sup>[17]</sup>。在不同信噪比条件下,进行 20 次蒙特卡洛实验,2 种方法的平均识别率如表 2 所示,其中文献[17]提取信号时频特征作为 CNN 的输入进行目标识别。

表 2 不同信噪比下的识别率

识别方法	SNR/dB					
	-10	-8	-6	-4	-2	0
文献 [17]	84.88	93.16	97.57	96.92	98.02	99.34
本文算法	92.56	95.71	97.99	98.48	98.51	99.72

从表 2 可以看出,本文所提算法在不同信噪比条件下,平均识别率均高于文献[17]所提算法。因为文献[17]算法在时频变换过程中损失了数据信息,特别是在低信噪比条件下,识别率下降明显,在 SNR = -10 dB 时,本文算法识别率比文献[17]提高了 7.68%,充分说明了本文设计的一维 CNN 结构应用于低分辨雷达目标识别领域是可行且有效的。

2.4 与传统两步识别方法的性能对比

为了进一步说明一步识别算法的有效性和优越性,将一步识别算法与传统基于人工提取特征的两步识别方法进行对比评估,提取目标回波采样数据的雷达散射截面(Radar Cross Section, RCS)特征、一维距离像特征的归一化中心矩和频谱熵值特征,对单一特征和多个特征融合使用  $k$  类最近邻分

类器(k-Nearest Neighbor, kNN)<sup>[18]</sup>和SVM<sup>[19]</sup>进行目标分类识别。同时为了验证一步识别算法的鲁棒性,在不同信噪比条件下进行识别实验。用添加高斯白噪声的方法对数据进行加噪处理,信噪比分别是-10 dB,-8 dB,-6 dB,-4 dB,-2dB,0 dB,进行20次蒙特卡洛实验,各方法平均识别效果见图5。其中特征1是频谱熵值特征,特征2是RCS特征,特征3是一维距离像特征的归一化中心矩。

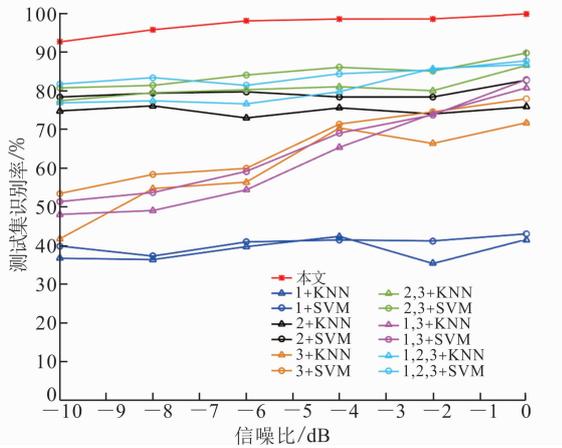


图5 各方法识别率

从图5可知,在传统两步识别方法中,使用不同的识别特征和分类器会对识别效果产生影响,其中基于频谱熵值特征的识别方法无法正确区分3类目标,而文献[20]利用频谱熵值特征实现了对飞机目标的分类识别,说明基于人工提取特征的识别方法存在泛化性不足的问题;传统方法中识别效果最好的是基于二维距离像特征的归一化中心矩和RCS特征采用SVM的识别方法,说明盲目增加所提取特征的数量不利于识别率的提高,而针对目标设计合适的识别方法需要花费大量时间精力。一步识别算法无需特征提取,能够自适应学习数据深层本质特征,无信息损失,识别率明显高于传统方法,且对3类目标都能进行有效识别,方法的泛化性好。

不同方法对测试集的平均识别时间见图6。

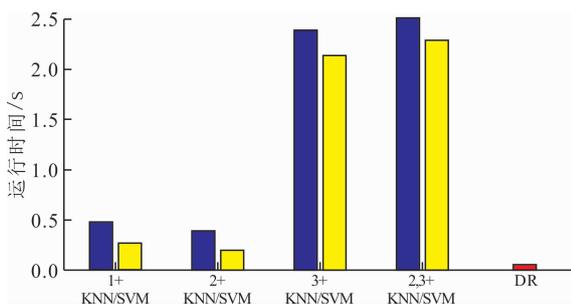


图6 各方法平均识别时间

从图6可以看出,一步识别算法由于在识别过程中省去了人工特征提取步骤,对测试集的识别时间

明显少于传统方法,证明使用训练好的网络对低分辨率雷达目标进行一步识别能够有效节省识别时间。

### 3 结语

本文提出了基于卷积神经网络的低分辨率雷达目标一步识别算法,采用设计的一维CNN结构,将采样数据直接作为网络输入,保留了采样数据的全部信息,通过优化卷积核的参数从数据中自动获取其深层本质特征,实现对雷达目标的一步识别。仿真实验结果表明,一步识别方法与传统两步识别方法相比,在识别率、泛化性和识别时间上都有明显优势,充分说明了本文方法的有效性和较传统两步识别方法的优越性。

#### 参考文献(References):

[1] 谢德光,张贤达. 基于分数阶 Fourier 变换的雷达目标识别[J]. 清华大学学报(自然科学版), 2010, 50(4): 485-488.  
XIE D G, ZHANG X D. Radar Target Recognition Based on Fractional Fourier Transform[J]. Journal of Tsinghua University(Science and Technology), 2010, 50(4):485-488. (in Chinese)

[2] 郭武,朱明明,杨红兵. 基于隐马尔科夫模型的 RCS 识别方法研究[J]. 现代雷达, 2013, 35(3): 37-40.  
GUO W, ZHU M M, YANG H B. A Study on RCS Recognition Method of Radar Targets Based on Hidden Markov Model[J] Modern Radar, 2013, 35(3): 37-40. (in Chinese)

[3] 杨磊,王晓丹,张玉玺. 一种基于多特征提取的雷达目标识别方法研究[J]. 电光与控制, 2011, 18(12): 35-38.  
YANG L, WANG X D, ZHANG Y X. A Radar Target Recognition Approach Based on Multi-Feature Extraction[J] Electronics Optics & Control, 2011, 18(12): 35-38. (in Chinese)

[4] TOTSKIY A V, MOLCHANOY P A, KHLOPOV G I, et al. Bispectrum Based Time-Frequency Distributions Used for Moving Target Recognition in Ground Doppler Surveillance Radar Systems [J]. Telecommunications and Radio Engineering, 2011, 70(20): 1797-1812.

[5] CHEN F, LIU H W, DU L, et al. Target Classification with Low-Resolution Radar Based on Dispersion Situations of Eigenvalue Spectra[J]. Science China(Information Sciences), 2010, 53(7):1446-1460.

[6] 王福友,罗钉,刘宏伟. 低分辨率机载雷达空地运动目标的分类识别算法[J]. 雷达学报, 2014, 3(5):497-504.  
WANG F Y, LUO D, LIU H W. Low-Resolution Airborne Radar Air/ground Moving Target Classifica-

- tion and Recognition[J]. Journal of Radars, 2014, 3(5):497-504. (in Chinese)
- [7] 李旭冬,叶茂,李涛. 基于卷积神经网络的目标检测研究综述[J]. 计算机应用研究, 2017, 34(10):2881-2886+2891.  
LI X D, YE M, LI T. Review of Object Detection Based on Convolutional Neural Networks[J]. Application Research of Computers, 2017, 34(10):2881-2886, 2891. (in Chinese)
- [8] 郭立民,寇韵涵,陈涛,等. 基于栈式稀疏自编码器的低信噪比下低截获概率雷达信号调制类型识别[J]. 电子与信息学报, 2018, 40(4):875-881.  
GUO L M, KOU Y H, CHEN T, et al. Low Probability of Intercept Radar Signal Recognition Based on Stacked Sparse Auto-Encoder[J]. Journal of Electronics & Information Technology, 2018, 40(4):875-881. (in Chinese)
- [9] CHEN L C, SCHWING A G, YUILLE A L, et al. Learning Deep Structured Models[C]//The 32th Conference on Machine Learning, 2014: 1785-1794.
- [10] ELHEWY A H, MESBAHI E, PU Y. Reliability Analysis of Structure Using Neural Network method [J]. Probabilistic Engineering Mechanics, 2006, 21(1):44-53.
- [11] 袁延鑫,孙莉,张群,等. 基于堆栈稀疏自编码器和微动特征的身份认证技术[J]. 空军工程大学学报(自然科学版), 2018, 19(4):48-53.  
YUAN Y X, SUN L, SUN Q. et al. Authentication Technology via Stack Sparse Autoencoder and Micro-Motion Feature [J]. Journal of Air Force Engineering University (Natural Science Edition), 2018, 19(4):48-53. (in Chinese)
- [12] SHAO L, CCAI Z, LU K, et al. Performance Evaluation of Deep Feature Learning for RGB-D Image/Video Classification[J]. Information Sciences, 2017, 385(C):266-283.
- [13] ZHANG Q Q, LIU Y, PAN J L, et al. Continuous Speech Recognition Based on Convolutional Neural Network[C]// International Conference on Digital Image Processing. Los Angeles:[s. n.], 2015.
- [14] HU G, WANG K J, PENG Y, et al. Deep Learning Methods for Underwater Target Feature Extraction and Recognition[J]. Computational Intelligence and Neuroscience, 2018(3):1-10.
- [15] 王思雨,高鑫,孙皓,等. 基于卷积神经网络的高分辨率SAR图像飞机目标检测方法[J]. 雷达学报, 2017, 6(2):195-203.  
WANG S Y, GAO X, SUN H, et al. An Aircraft Detection Method Based on Convolutional Neural Networks in High-Resolution SAR Images[J]. Journal of Radars, 2017, 6(2):195-203. (in Chinese)
- [16] 方成,薛质. 基于全双谱和卷积神经网络的信号分类方法[J]. 计算机应用研究, 2018, 35(12):3766-3769.  
FANG C, XUE Z. Signal Classification Method Based on Complete Bispectrum and Convolutional Neural Network [J]. Application Research of Computers, 2018, 35(12):3766-3769. (in Chinese)
- [17] 王念滨,何鸣,王红滨,等. 基于卷积神经网络的水下目标特征提取方法[J]. 系统工程与电子技术, 2018, 40(6):1197-1203.  
WANG N B, HE M, WANG H B, et al. Underwater Target Feature Extraction Method Based on Convolutional Neural Network. [J]. Systems Engineering and Electronics, 2018, 40(6):1197-1203. (in Chinese)
- [18] ROSENBAACH KH, SCHILLER J. Identification of Aircraft on the Basis of 2-d Radar Images[C]//Record of the IEEE 1995 International. [s. l.]: IEEE, 1995: 405-409.
- [19] QUN Z, JOSE C P, VICTOR L B, et al. Synthetic Aperture Radar Automatic Target Recognition with Three Strategies of Learning and Representation[J]. Optical Engineering, 39(5):1230-1244, 2000.
- [20] 辛玉林,许人灿. 低分辨雷达目标识别方法研究[J]. 现代电子技术, 2005, 28(19):17-19.  
XIN Y L, XU R C. Methods of Target Recognition Based on Low-Resolution Radar[J]. Modern Electronic Technique, 2005, 28(19):17-19. (in Chinese)

(编辑:徐敏)