

# 基于深度多尺度一维卷积神经网络的雷达舰船目标识别

郭晨 简涛\* 徐从安 何友 孙顺  
(海军航空大学 烟台 264001)

**摘要:** 为满足雷达舰船目标识别的高实时性和高泛化性的需求, 该文提出了一种基于深度多尺度1维卷积神经网络的目标高分辨1维距离像(HRRP)识别方法。针对高分辨1维距离像特征提取难的问题, 所提方法通过共享卷积核的权值, 使用多尺度的卷积核提取不同精细度的特征, 并构造中心损失函数来提高特征的分辨能力。实验结果表明, 该模型可以显著提高目标在非理想条件下的识别正确率, 克服目标姿态角敏感性问题, 具有良好的鲁棒性和泛化性。

**关键词:** 雷达目标识别; 高分辨1维距离像; 多尺度; 卷积神经网络; 中心损失函数

中图分类号: TN957.51

文献标识码: A

文章编号: 1009-5896(2019)06-1302-08

DOI: 10.11999/JEIT180677

## Radar HRRP Target Recognition Based on Deep Multi-Scale 1D Convolutional Neural Network

GUO Chen JIAN Tao XU Congan HE You SUN Shun  
(Naval Aviation University, Yantai 264001, China)

**Abstract:** In order to meet the demand for high real-time and high generalization performance of radar recognition, a radar High Resolution Range Profile (HRRP) recognition method based on deep multi-scale one dimension convolutional neural network is proposed. The multi-scale convolutional layer that can represent the complex features of HRRP is designed based on two features of the convolution kernels which are weight sharing and extraction of different fineness features from different scales, respectively. At last, the center loss function is used to improve the separability of features. Experimental results show that the model can greatly improve the accuracy of the target recognition under non-ideal conditions and solve the problem of the target aspect sensitivity, which also has good robustness and generalization performance.

**Key words:** Radar target recognition; High Resolution Range Profile (HRRP); Multi-scale; Convolutional Neural Network (CNN); Center loss

### 1 引言

高分辨1维距离像(High Resolution Range Profile, HRRP)是利用宽带雷达得到的目标在雷达观测方向上的1维投影, 它反映了目标包含的丰富的散射体的信息, 如雷达散射面积(RCS)沿雷达视线方向的分布情况, 散射中心的结构和强弱大小等<sup>[1]</sup>。与2维距离像相比, 目标的1维HRRP更容易获取、处理和存储, 因此是雷达自动目标识别的研究热点

和难点。

如何提取目标的可分性特性是雷达目标识别的关键步骤, 现已有大量针对HRRP的特征提取方法, 如基于散射点匹配的1维距离像识别算法<sup>[2]</sup>, 基于超分辨算法的目标散射体信息提取方法<sup>[3]</sup>, 基于流形学习的特征降维方法<sup>[4]</sup>, 基于字典学习的噪声鲁棒性特征提取方法<sup>[5,6]</sup>, 基于核主分量相关判别的特征提取方法<sup>[7]</sup>, 基于特权信息的特征学习方法<sup>[8]</sup>等。这些方法均基于浅层线性结构, 不能提取完整表征目标信息的特征, 此外, 这些特征是人为设计的, 需要先验知识做支撑。因此, 如何自动提取目标的深层可分性特征是目标识别的重要研究方向。

基于深度学习的目标识别的本质是利用深度神经网络来进行目标的特征提取。目前, 基于深度学习的HRRP特征提取方法已经取得了一些研究成果。文献<sup>[9]</sup>提出了一种基于 $t$ 分布随机邻居嵌入

收稿日期: 2018-07-06; 改回日期: 2019-01-10; 网络出版: 2019-01-22

\*通信作者: 简涛 work\_jt@163.com

基金项目: 国家自然科学基金(61471379, 61790551, 61102166), 泰山学者工程专项

Foundation Items: The National Natural Science Foundation of China (61471379, 61790551, 61102166), The Taishan Scholar Project of Shandong Province

(*t*-SNE)和判别深度置信网络(Discriminant Deep Belief Network, DDBN)的新型识别框架, 该模型解决了不平衡数据集条件下的目标识别问题。文献[10]提出了一种判别式深度自编码(Discriminant Deep Auto Encoders, DDAE)模型, 该模型提高了数据量较小情况下的识别正确率。文献[11]提出的鲁棒变分自编码器(Robust Variational Auto-Encoder, RVAE)可以更好地提取目标的鲁棒特征。文献[12]提出了深度校正自编码(Stack Correction Auto Encoder, SCAE)模型, 该模型使用相邻角域的1维距离像的均值作为校正项, 并通过增加模型的深度, 提高了目标识别率。文献[13]提出了一种利用稀疏降噪自编码和多层感知器(Sparse Denoising Auto Encoder and Multi-Layer Perceptron, SDAE&MLP)相结合的HRRP识别模型, 先利用稀疏自编码进行无标签的网络参数训练, 在加入多层感知器进行有标签的网络参数训练, 由于训练过程中加入了噪声, 模型的抗噪性能较好。文献[14]提出了深度自编码和超限学习机(Stacked Auto Encoder and Extreme Learning Machine, SAE&ELM)相结合的模型, 利用超限学习机替代传统的BP网络, 大大减小了训练参数, 并提高了模型的学习速度和泛化性能。文献[15]提出了一种基于卷积神经网络(Convolutional Neural Network, CNN)的多雷达目标识别方法。该模型利用卷积神经网络输出单个雷达的类别概率, 取平均概率最大且大于所选阈值的结果判为目标类别。但上述方法都是针对较小角域的HRRP进行目标识别, 由于目标的1维距离像数据具有姿态敏感性, 姿态角相差较大的同一目标的HRRP差别非常大, 如果想进行目标的1维距离像的全角域目标识别, 需要构建更加复杂的模型, 自编码模型的复杂度可以通过增加模型深度和隐藏层神经元的个数来提高, 但会导致模型参数过多, 而用于训练的样本数量有限, 模型容易产生过拟合现象。因此基于自编码的方法不适合HRRP全角域目标识别。为了解决上述问题, 本文提出了一种基于深度多尺度1维卷积神经网络(Multi-Scale Convolutional 1D Neural Network, MSCNN)的目标HRRP识别方法。

本文首先对1维卷积神经网络的基本构成进行了描述和功能解释。介绍了卷积核的2个特点: 权值共享以及不同尺度卷积核提取不同精细度特征。在此基础上, 设计包含多尺度卷积层和多尺度下采样层的模型, 并采用中心损失函数来减小特征的内距离, 使得模型利用较少参数就可以提取HRRP的全角域复杂特征。最后通过仿真实验, 对该模型

在不同信噪比、不同模型深度的条件下的识别性能进行了分析, 并通过对比算法和特征可视化对该模型的泛化性能进行了分析, 证明了该模型可以有效提取HRRP的全角域特征。

## 2 1维卷积神经网络描述

深度卷积神经网络在计算机视觉领域取得了巨大成功。在目标识别领域, 深度卷积神经网络及其各种变体是目前各方面性能最好的方法<sup>[16]</sup>。本文提出的模型借鉴了传统卷积神经网络的结构特点, 其基础构成包括5个部分, 分别为输入层, 卷积层, 下采样层, 全连接层和输出层。下面主要介绍输入层, 卷积层, 下采样层的结构与功能:

(1) 输入层: 输入层要求输入的数据维度固定, 在输入层会对数据进行预处理, 预处理分为两步:

步骤1 幅度的归一化。设 $\mathbf{x}(n)$ 为第 $n$ 个1维距离像数据, 其幅度归一化表示为 $\bar{\mathbf{x}}(n) = \mathbf{x}(n) / \max(|\mathbf{x}(n)|)$ ;

步骤2 计算所有 $\bar{\mathbf{x}}(n)$ 的均值 $\bar{\mathbf{x}}_m = \frac{1}{N} \sum_{n=1}^N \bar{\mathbf{x}}(n)$ , 对所有的 $\bar{\mathbf{x}}(n)$ 执行减均值 $\bar{\mathbf{x}}_m$ 操作。

在输入层对数据进行预处理可以很好地减少幅值扰动对目标识别的影像, 提高模型的鲁棒性。

(2) 卷积层: 卷积层的功能是自动提取待识别目标的特征, 其特点在于权值共享, 可大大减少模型参数。卷积层的具体操作为, 输入与各通道的卷积核进行卷积, 通过激活函数, 得到输出特征向量。卷积核维度一般为 $(2n+1, 1)$ ,  $n = 0, 1, \dots, N$ , 卷积操作的数学表达式如式(1)

$$\left. \begin{aligned} \mathbf{x}_j^l &= f(\mathbf{u}_j^l) \\ \mathbf{u}_j^l &= \sum_{i \in M_j} \mathbf{x}_i^{l-1} \otimes \mathbf{k}_{ij}^l + \mathbf{b}_j^l \end{aligned} \right\} \quad (1)$$

式中,  $\otimes$ 代表卷积运算,  $\mathbf{u}_j^l$ 为卷积层 $l$ 的第 $j$ 个通道的净激活,  $\mathbf{x}_j^l$ 是卷积层 $l$ 的第 $j$ 个通道的输出,  $f(\cdot)$ 为激活函数, 采用Relu函数。 $\mathbf{k}_{ij}^l$ 是卷积层 $l$ 的第 $j$ 个通道对应第 $i$ 个输入特征向量的卷积核向量,  $\mathbf{b}_j^l$ 是卷积层 $l$ 的第 $j$ 个通道的偏置项。

(3) 下采样层: 通过卷积运算后, 相邻特征存在冗余, 通过下采样去除特征冗余, 下采样层可以解决HRRP的平移敏感性问题。下采样层的具体操作如式(2)

$$\mathbf{x}_j^l = \beta_j^l \text{down}(\mathbf{x}_j^{l-1}) \quad (2)$$

式中,  $\mathbf{x}_j^l$ 是下采样层 $l$ 的第 $j$ 个通道的输出,  $\beta_j^l$ 是下采样层 $l$ 的第 $j$ 个通道的权重系数, 一般设为1。

down(·)表示下采样函数，它通过对输入的特征向量划分为多个相连且不重叠的长度为 $n$ 的向量块，然后对每个向量块的值取平均或求最大值，输出的向量缩小为原来的 $1/n$ 。下采样函数一般采用最大值下采样函数。

### 3 深度多尺度1维卷积神经网络

#### 3.1 模型框架设计

该模型框图如图1所示，包含1个普通卷积层，3个多尺度卷积层，2个多尺度下采样层，其中多尺度卷积层和多尺度下采样层交替出现，多尺度卷积层3后接下采样层，由于多尺度卷积层3的输出特征通道数较多，故为了降低全连接层的输入数据维度，下采样的单元数设为4，其后接神经元个数分别为200, 2的全连接层，第2个全连接层的输出特征作为中心损失函数的输入。由于本文所使用数据集的待识别目标类别数为7，故所使用模型的输出层的神经元数为7。

#### 3.2 多尺度卷积层的设计

不同尺度的卷积核能提取不同精度的特征，卷积核的尺度越小，提取的特征越精细。单层如果只使用同一尺度的卷积核便容易忽略其他精度的特征，导致提取的特征表达的信息不够完整[17,18]。本节设计了3种多尺度卷积层，其结构如图2所示。

3种多尺度卷积层都包含4个分支，其中，(从左往右)分支1包含1个卷积层，卷积核尺度为 $1\times 1$ ， $1\times 1$ 的卷积核的主要功能是控制输出的通道数。分支2包含2个卷积层，(从上到下)卷积核尺度分别 $1\times 1$ 和 $3\times 3$ 。3种多尺度卷积层的差别主要体现在分支3和分支4。分支3包含3个卷积层，其中的最后1个卷积层的卷积核尺度分别为 $5\times 1$ ， $3\times 1$ 和 $1\times 1$ 。这符合普通卷积神经网络的设计思路，浅层使用尺度较大卷积核，主要负责提取目标的纹理轮廓等特征，深层使用尺度较小的卷积核，负责提取目标的

高层抽象特征。分支4都包含下采样操作，即剔除冗余信息，更好地保留特征的有效信息。最后的相加操作直接把每个分支的特征拼在一起，以多尺度卷积层1为例，假设输入为8通道的数据，经过多尺度卷积层后输出特征的通道数为 $16+16+16+8=56$ 。多尺度卷积层中的每个卷积层和下采样层的输出都进行补零操作，即多尺度卷积层的输出与输入维度相同。

#### 3.3 多尺度下采样层的设计

本节设计了2种多尺度下采样层，如图3(a)，图3(b)所示，多尺度采样层利用卷积操作实现了下采样。

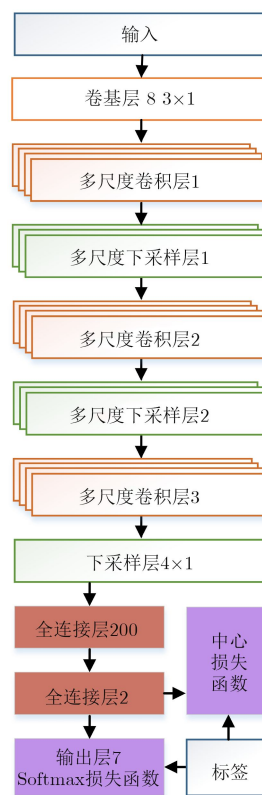


图1 本文所提模型示意图

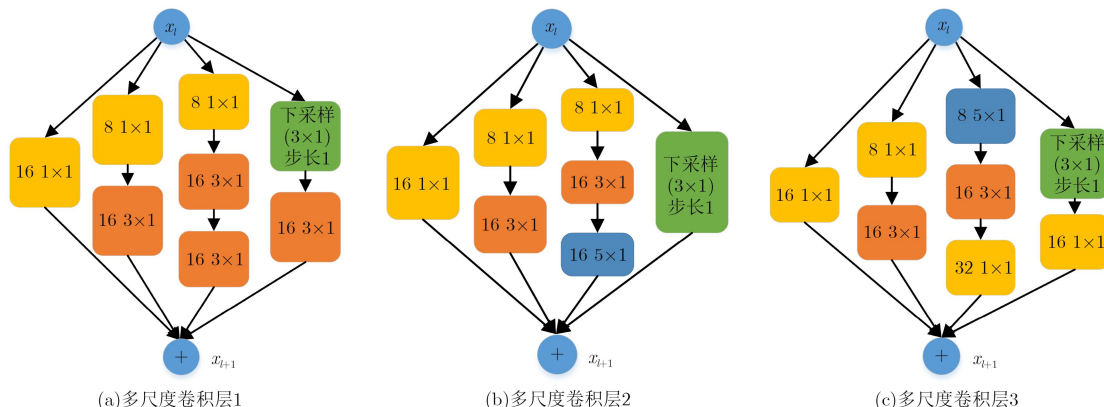


图2 多尺度卷积层示意图




图3 多尺度降采样层示意图

两种多尺度下采样层都包含3个分支，(从左往右)分支1和分支2由卷积层组成，需要注意的是，分支中最后1个卷积层的步长为2，这样可保证输出的维度为输入特征维度的1/2，分支3都由下采样层组成，每3个相邻值取最大，步长为2，输出特征维度为输入的1/2。多尺度下采样层的功能不只是减少数据维度，也提取了更深层次的特征。

### 3.4 损失函数的设计

考虑一般的卷积神经网络的目标识别对象都是粗分类的，例如，利用卷积神经网络进行猫、狗、花、鸟等不同类别的目标之间的识别，不同类别的目标特征的可分性较好，而不同型号的舰船目标属于同一类目标，相似性大，可分性较低，利用传统的软最大值损失(Softmax Loss, SL)函数，会导致特征的类内距离甚至大于类间距离，特征容易互相重叠，从而导致识别效果不够理想。损失函数设计借鉴了人脸识别方法的中心损失(Center Loss, CL)函数的思想<sup>[19]</sup>，考虑了特征的类内距离的约束，提出了一种基于特征中心的损失函数。该损失函数会对远离类中心的特征进行惩罚，通过训练，使得类内特征更加聚集。损失函数表达式如式(3)

$$L = L_s + \lambda L_c$$

$$= - \sum_{i=1}^m \lg \frac{e^{\mathbf{W}_{y_i}^T \mathbf{x}_i + b_{y_i}}}{\sum_{j=1}^m e^{\mathbf{W}_j^T \mathbf{x}_i + b_j}} + \frac{\lambda}{2} \sum_{i=1}^m \left\| \mathbf{x}_i - \mathbf{c}_{y_i} \right\|_2^2 \quad (3)$$

式中， $\mathbf{x}_i$ 表示第*i*个数据在输出层之前的全连接层的输出特征。 $\mathbf{W}_j \in \mathbb{R}^d$ 是全连接层的权值矩阵 $\mathbf{W} \in \mathbb{R}^{d \times n}$ 的第*j*列， $\mathbf{b} \in \mathbb{R}^n$ 是全连接层的偏置项，*m*是每个梯度更新过程中小批量数据的个数，*n*是

类别的个数， $\mathbf{c}_{y_i} \in \mathbb{R}^d$ 是第*y<sub>i</sub>*类的特征中心， $L_s$ 为软最大值损失函数， $L_c$ 为中心损失项， $\lambda$ 是中心损失项的权重， $\lambda$ 越大，类内特征越聚集。 $L_s$ 与 $L_c$ 组成的联合损失函数可以让类内特征更加聚拢，极大地提高特征的可分性。

在训练的过程中，利用式(4)对特征中心进行更新

$$\Delta \mathbf{c}_j = \frac{\sum_{i=1}^m \delta(y_i = j) \cdot (\mathbf{c}_j - \mathbf{x}_i)}{1 + \sum_{i=1}^m \delta(y_i = j)} \quad (4)$$

式中， $\delta(y_i = j)$ 表示当*y<sub>i</sub>*为第*j*类时， $\delta(\cdot)$ 等于1，否则 $\delta(\cdot)$ 等于0。

### 3.5 模型复杂度分析

本节从2个方面对模型的复杂度进行了分析，一是模型的结构复杂度，二是模型的计算复杂度。对比模型选择了自编码模型，又因为文中对比所用的自编码模型的参数数量级相同，故只对其中一种自编码模型进行了分析，所提模型、卷积神经网络及自编码模型的参数个数如表1-表3所示，其中，因为各层的偏置个数较少，在计算参数过程中将其忽略，且因下采样层不包含参数，故没有在表格中列出。

由表1-表3的数据可以看出，所提模型的参数个数小于普通卷积神经网络的参数个数，这二者都远远小于自编码模型的参数个数。而模型复杂度与参数个数成正比，故所提模型的结构复杂度小于普通卷积神经网络的结构复杂度，且二者都远远小于自编码模型的结构复杂度。

表1 所提模型中主要的特征提取层的参数个数

卷积层	多尺度卷积层1	多尺度下采样层1	多尺度卷积层2	多尺度下采样层2	多尺度卷积层3	全连接层	合计
24	1552	4480	6016	4480	5760	2560	24872

表2 CNN中主要的特征提取层的参数个数

卷积层32, 5×1	卷积层32, 5×1	卷积层64, 3×1	卷积层64, 3×1	卷积层128, 1×1	卷积层128, 1×1	全连接层2	合计
160	5120	6144	12288	8192	16384	2048	50336

表3 自编码模型中主要的特征提取层的参数个数

隐藏层1, 600	隐藏层2, 300	隐藏层3, 50	合计
307200	180000	15000	502200

由于模型的计算复杂度为各个层的计算复杂度的线性相加, 本节只分析单个层的计算复杂度, 假设训练样本总数为 $N$ , 单层的输入和输出特征维度分别为 $D$ 和 $T$ , 自编码模型的单层计算复杂度为 $O(NDT)$ , 假设卷积层中包含的卷积核的维度为 $k \times 1$ , 个数为 $k_n$ , 那么单个卷积层的计算复杂度为 $O(NDkk_n)$ 。一般情况下,  $kk_n > T$ , 且所提模型的层数多于自编码模型, 故所提模型的计算复杂度高于自编码模型。

## 4 实验仿真与分析

### 4.1 数据集构建

舰船目标多为非合作目标, 很难通过实测数据建立目标的HRRP数据库。本文利用Solidworks 3D软件建立7种1:1的舰船目标模型, 导入CST电磁仿真软件, 7种舰船目标的结构参数如表4所示。CST仿真参数设置如下: 方位角为 $-90^\circ \sim 90^\circ$ , 俯仰角为 $0^\circ$ , 角度步长为 $1^\circ$ ; 雷达的中心频率为10 GHz, 带宽为100 MHz, 极化方式为垂直极化, 频率采样点数为256, 采用软件默认的最优网格剖析尺寸, 选择射线追踪算法进行求解。最终, 仿真了7种舰船目标的181个方位角的HRRP数据。

训练样本匮乏会导致模型的过拟合, 用CST仿真的HRRP数量对所提模型来说远远不够, 需要对其进行扩充, 扩充分为两个步骤:

步骤1 通过加噪声对数据进行扩充。对原始数据分5次加入服从高斯分布的噪声 $n_i \sim N[0, \sigma_i]$ , 其中,  $i = 1, 2, \dots, 5$ , 将数据扩充5倍;

步骤2 对HRRP进行截取。CST输出的数据

表4 7种舰船目标的结构参数(m)

舰船编号	舰长	舰宽	吃水深度
1	182.8	24.1	8.1
2	172.8	16.8	6.5
3	153.8	20.4	6.3
4	135.0	16.8	4.5
5	121.0	17.6	4.3
6	102.2	16.5	4.2
7	89.3	12.1	4.0

维度为1024, 由于仿真过程中, 将模型中心放在坐标轴的原点, 因此仿真数据中反映模型特点的点基本以512为中心点对称分布, 所以进行截取时, 以512为中线, 以20为步长, 截取的长度为512(即截取后的数据长度为512), 左右各平移3次, 通过这个方法将数据扩充6倍。对HRRP进行裁剪, 也可模拟目标存在遮挡, 数据部分信息缺失的情况。利于验证模型的泛化性能。

为了验证模型表征目标HRRP完备角域的有效性, 本文选取数据集中每类目标的181个角度所对应的70%的HRRP数据构造为训练集, 将数据集中余下的数据构造为测试集来验证模型性能。用该方式构造的数据集称为数据集A。

为了验证模型在克服姿态敏感性问题的能力, 需要保证训练集和测试集的角度范围不完全重合, 且训练集的角度范围需小于测试数据的角度范围。本文选取了数据集中每类目标的1~160个角度所对应的70%的HRRP数据作为训练数据, 将数据集中余下的HRRP数据作为测试数据来验证模型性能。用该方式构造的数据集称为数据集B。

### 4.2 实验步骤

步骤1 按照3.4节的模型框图进行模型的构建, 并对模型进行初始化。即对待训练的参数进行初始化, 如卷积层的参数 $\theta_c = \{k_c, b_c\}$ , 全连接层的权值参数 $W$ , 各类别的特征中心 $\{c_j, j = 1, 2, \dots, k\}$ ;

步骤2 前向传播, 计算每个迭代过程中数据的损失函数;

步骤3 反向传播, 利用随机梯度下降法和链式法则来进行参数更新;

步骤4 重复步骤2, 步骤3, 直到损失函数收敛且不再下降, 结束训练过程, 使用测试数据进行模型有效性的验证。

### 4.3 算法性能分析

(1) 模型深度对识别正确率的影响: 本节采用数据集A研究了深度对模型的识别正确率的影响, 在所提模型的基础上, 仿真了3个不同深度的模型的识别正确率。其中, 模型a在本模型的基础上, 去除多尺度卷积层3, 模型b在模型a的基础上, 去除了多尺度下采样层2, 模型c在模型b的基础上, 去除了多尺度卷积层2。本节所有模型都使用SNR=5 dB的数据进行仿真实验, 仿真结果如表5所示。信噪比的表达式如式(5)

$$\text{SNR} = 10 \lg \left( \frac{P_s}{P_n} \right) \quad (5)$$

式中,  $P_s$ 和 $P_n$ 分别表示信号与噪声的平均功率, 信噪比的单位为dB。

由表5可以看出, 模型深度对目标的识别正确率影响较大, 模型的深度保证了模型的复杂度, 模型越复杂, 可以拟合更复杂的特征, 故当模型深度较小时, 其对目标的正确识别率会降低。

(2)不同信噪比条件下, 所提模型与对比模型的识别正确率: 本节选取了3种对比模型, 分别是卷积神经网络(CNN)<sup>[15]</sup>, 稀疏降噪自编码与多层感知器(SDAE&MLP)<sup>[13]</sup>, 栈式自编码+极限学习机(SAE&ELM)<sup>[14]</sup>, 后2种方法主要针对较小角域情况下的1维距离像目标识别的有效模型。本节的仿真采用数据集A, 仿真结果如表6所示。

从表6中结果可以看出, 本文模型与普通卷积神经网络的识别效果均好于基于自编码的模型, 其中所提模型的识别正确率更高一些。与自编码模型相比, 本文模型能够表征更加复杂的特征。由于本节所用数据集是通过初始HRRP数据进行裁剪得到的, 相当于模拟目标存在遮挡、原HRRP数据的部分信息丢失的情况, 所提模型在该情况下得到的目标识别率较高, 且所提模型在不同信噪比条件下均取得了较好的识别正确率, 可说明该模型在非理想条件下的鲁棒性能较好。

(3)不同模型对目标姿态角的泛化性能分析: 本节采用数据集B仿真了训练集与测试集包含目标姿态角不同且SNR=10 dB条件下的不同模型的识别正确率, 仿真结果如表7所示。

由表7结果所示, 本文模型和卷积神经网络的

表5 不同模型深度条件下的识别正确率(%)

模型	识别正确率
本文模型	97.67
模型a	89.23
模型b	82.41
模型c	75.25

表6 所提模型与对比模型在不同信噪比条件下的目标识别正确率(%)

模型名称	SNR (dB)		
	5	10	15
本文模型	95.12	97.67	98.90
CNN+CL	93.88	95.89	97.56
SDAE+MLP	90.58	92.15	93.22
SAE+ELM	90.94	92.63	94.05

表7 所提模型与对比模型在数据集B下的目标识别正确率(%)

本文模型	CNN+CL	SDAE+MLP	SAE+ELM
94.83	93.51	90.93	91.27

识别效果均好于基于自编码的模型。自编码模型由于参数数量较大、模型复杂度高而容易产生过拟合现象, 泛化性能相对较差。而本文所提模型由于卷积核的权值共享特性, 可以利用较少参数表征目标的有效特征, 在训练集数据量较少情况下, 模型不容易产生过拟合, 泛化性能较好。综上, 本文模型在姿态角不完备的情况下仍获得较高的目标识别结果, 具有良好的泛化性能, 在目标克服姿态敏感性问题上具有应用潜力。

#### 4.4 特征可视化

由于普通卷积神经网络(CNN)在目标全角域条件下的识别正确率好于其他几种方法, 故本节选取普通卷积神经网络作为对比模型, 对以下4种模型和损失函数的组合进行了特征可视化, 分别为: CNN+SL, CNN+CL, MSCNN+SL, MSCNN+CL。特征可视化结果如图4所示, 图中7种颜色的数据点分别表示7类目标的特征。

图4(a)中, CNN在仅使用SL函数的条件下, 提取的特征产生了重合, 可分性较差。图4(c)中, MSCNN在仅使用SL函数的条件下, 提取的特征可分性明显好于图4(a), 但特征的类内距离大于类间距离, 模型的泛化性能较差。图4(b)和图4(d)中CNN和MSCNN在使用CL函数的条件下, 都能够将不同类别的特征进行明显的区分, 图4(d)与图4(b)相比, 类内特征更加聚集, 不同类之间的特征区分度更好, 基本不存在重叠的情况, 故多尺度卷积神经网络的泛化性能更好。

当目标类别数较多时, 用于训练的样本数据量增加, 目标特征变得更加复杂。CNN由于同层的卷积核尺度单一, 对于复杂特征的表征能力略显不足, 其提取特征的可分性降低。MSCNN的多尺度卷积层和下采样层包含不同尺度的卷积核, 模型具有较高的复杂性, 故可以进行更加复杂的特征表征。

## 5 结束语

本文提出了一种基于深度多尺度1维卷积神经网络的舰船HRRP目标识别方法。所提模型利用了卷积核的权值共享特点, 在减少模型参数的同时提高了模型的表达能力, 显著提高了模型的训练效率。模型设计的多尺度卷积层对目标HRRP的不同精细度特征进行了提取, 多尺度下采样层有效减少特征的冗余信息, 在此基础上, 使用中心损失函数

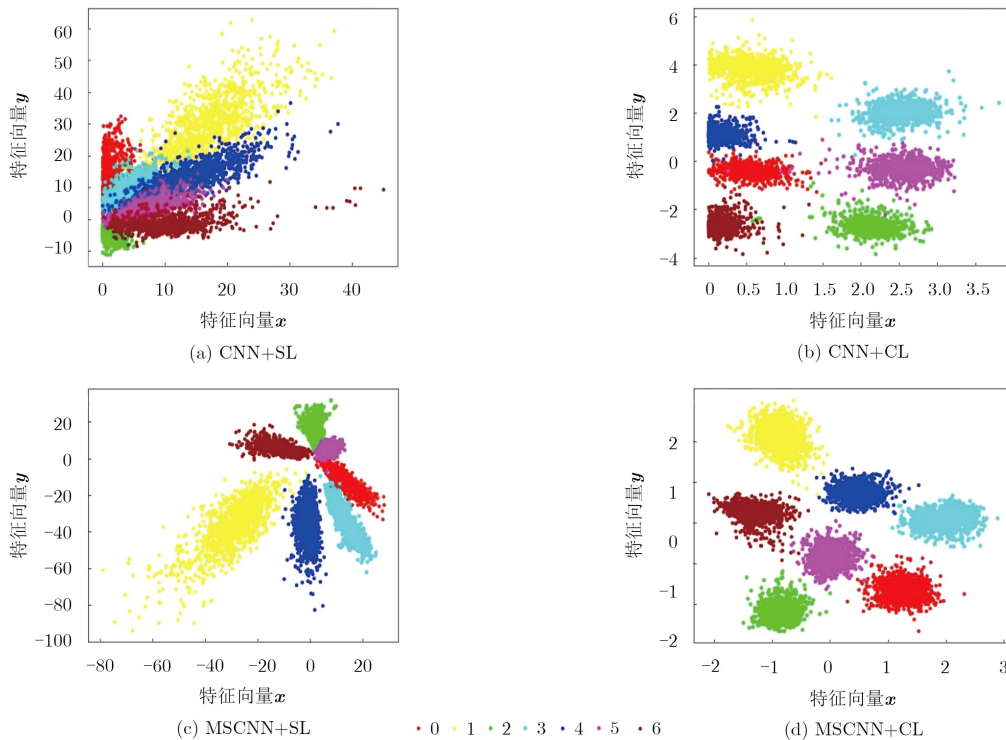


图4 CNN与MSCNN在不同损失函数条件下的特征可视化

对该模型提取的特征进行类内距离约束。通过仿真结果表明,所提模型提取的特征能够兼顾类间可分性和类内聚集性,模型在非理想条件下取得较好的目标识别结果,具有较好的鲁棒性和泛化性。为了更好的验证模型的有效性,下一步考虑利用实测数据进行实验。

### 参考文献

- [1] DU Lan, WANG Penghui, LIU Hongwei, *et al.* Bayesian spatiotemporal multitask learning for radar HRRP target recognition[J]. *IEEE Transactions on Signal Processing*, 2011, 59(7): 3182–3196. doi: [10.1109/TSP.2011.2141664](https://doi.org/10.1109/TSP.2011.2141664).
- [2] WANG Yu, ZHANG Liang, WANG Suixue, *et al.* Radar HRRP target recognition using scattering centers fuzzy matching[C]. Proceedings of 2016 CIE International Conference on Radar, Guangzhou, China, 2016: 1–5. doi: [10.1109/RADAR.2016.8059195](https://doi.org/10.1109/RADAR.2016.8059195).
- [3] PEI Bingnan and BAO Zheng. Multi-aspect radar target recognition method based on scattering centers and HMMs classifiers[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2005, 41(3): 1067–1074. doi: [10.1109/TAES.2005.1541451](https://doi.org/10.1109/TAES.2005.1541451).
- [4] JIANG Yue, HAN Yubing, and SHENG Weixing. Target recognition of radar HRRP using manifold learning with feature weighting[C]. Proceedings of 2016 IEEE International Workshop on Electromagnetics: Applications and Student Innovation Competition, Nanjing, China, 2016: 1–3. doi: [10.1109/iWEM.2016.7505053](https://doi.org/10.1109/iWEM.2016.7505053).
- [5] ZHOU Daiying. Radar target HRRP recognition based on reconstructive and discriminative dictionary learning[J]. *Signal Processing*, 2016, 126: 52–64. doi: [10.1016/j.sigpro.2015.12.006](https://doi.org/10.1016/j.sigpro.2015.12.006).
- [6] 冯博, 陈渤, 王鹏辉, 等. 利用稳健字典学习的雷达高分辨距离像目标识别算法[J]. 电子与信息学报, 2015, 37(6): 1457–1462. doi: [10.11999/JEIT141227](https://doi.org/10.11999/JEIT141227).  
FENG Bo, CHEN Bo, WANG Penghui, *et al.* Radar high resolution range profile target recognition algorithm via stable dictionary learning[J]. *Journal of Electronics & Information Technology*, 2015, 37(6): 1457–1462. doi: [10.11999/JEIT141227](https://doi.org/10.11999/JEIT141227).
- [7] 李龙, 刘峥. 基于核主分量相关判别分析特征提取方法的目标HRRP识别[J]. 电子与信息学报, 2018, 40(1): 173–180. doi: [10.11999/JEIT170329](https://doi.org/10.11999/JEIT170329).  
LI Long and LIU Zheng. Kernel principal component correlation and discrimination analysis feature extraction method for target HRRP recognition[J]. *Journal of Electronics & Information Technology*, 2018, 40(1): 173–180. doi: [10.11999/JEIT170329](https://doi.org/10.11999/JEIT170329).
- [8] GUO Yu, XIAO Huaitie, KAN Yingzhi, *et al.* Learning using privileged information for HRRP-based radar target recognition[J]. *IET Signal Processing*, 2018, 12(2): 188–197. doi: [10.1049/iet-spr.2016.0625](https://doi.org/10.1049/iet-spr.2016.0625).
- [9] PAN Mian, JIANG Jie, KONG Qingpeng, *et al.* Radar HRRP target recognition based on T-SNE segmentation and discriminant deep belief network[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(9): 1609–1613. doi: [10.1109/LGRS.2017.2726098](https://doi.org/10.1109/LGRS.2017.2726098).

- [10] PAN Mian, JIANG Jie, LI Zhu, *et al.* Radar HRRP recognition based on discriminant deep autoencoders with small training data size[J]. *Electronics Letters*, 2016, 52(20): 1725–1727. doi: [10.1049/el.2016.3060](https://doi.org/10.1049/el.2016.3060).
- [11] FENG Bo, CHEN Bo, and LIU Hongwei. Radar HRRP target recognition with deep networks[J]. *Pattern Recognition*, 2017, 61: 379–393. doi: [10.1016/j.patcog.2016.08.012](https://doi.org/10.1016/j.patcog.2016.08.012).
- [12] YAN Huaqing, ZHANG Zenghui, XIONG Gang, *et al.* Radar HRRP recognition based on sparse denoising autoencoder and multi-layer perceptron deep model[C]. Proceedings of the 4th International Conference on Ubiquitous Positioning, Indoor Navigation and Location Based Services, Shanghai, China, 2016: 283–288. doi: [10.1109/UPINLBS.2016.7809986](https://doi.org/10.1109/UPINLBS.2016.7809986).
- [13] ZHAI Ying, CHEN Bo, ZHANG Hao, *et al.* Robust variational auto-encoder for radar HRRP target recognition[C]. Proceedings of the 7th International Conference on Intelligent Science and Big Data Engineering, Dalian, China, 2017: 356–367. doi: [10.1007/978-3-319-67777-4\\_31](https://doi.org/10.1007/978-3-319-67777-4_31).
- [14] ZHAO Feixiang, LIU Yongxiang, HUO Kai, *et al.* Radar HRRP target recognition based on stacked autoencoder and extreme learning machine[J]. *Sensors*, 2018, 18(1): 173. doi: [10.3390/s18010173](https://doi.org/10.3390/s18010173).
- [15] LUNDÉN J and KOIVUNEN V. Deep learning for HRRP-based target recognition in multistatic radar systems[C]. Proceedings of 2016 IEEE Radar Conference, Philadelphia, USA, 2016: 1–6. doi: [10.1109/RADAR.2016.7485271](https://doi.org/10.1109/RADAR.2016.7485271).
- [16] BENGIO Y I, GOODFELLOW I, and COURVILLE A. Deep Learning[M]. Cambridge, USA: MIT Press, 2016: 276–324.
- [17] SZEGEDY C, LIU Wei, JIA Yangqing, *et al.* Going deeper with convolutions[C]. Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition, Boston, USA, 2015: 1–9. doi: [10.1109/CVPR.2015.7298594](https://doi.org/10.1109/CVPR.2015.7298594).
- [18] SZEGEDY C, IOFFE S, VANHOUCKE V, *et al.* Inception-v4, Inception-ResNet and the impact of residual connections on learning[C]. Proceedings of the 31st AAAI Conference on Artificial Intelligence, San Francisco, USA, 2017: 4278–4284.
- [19] WEN Yandong, ZHANG Kaipeng, LI Zhifeng, *et al.* A discriminative feature learning approach for deep face recognition[C]. Proceedings of the 14th European Conference on Computer Vision, Amsterdam, Netherlands, 2016: 499–515. doi: [10.1007/978-3-319-46478-7\\_31](https://doi.org/10.1007/978-3-319-46478-7_31).
- 郭晨: 女, 1990年生, 博士生, 研究方向为雷达目标识别、深度学习。
- 简涛: 男, 1980年生, 副教授, 研究方向为雷达信号处理、目标识别。
- 徐从安: 男, 1987年生, 讲师, 研究方向为多目标跟踪、信息融合、深度学习。
- 何友: 男, 1956年生, 教授, 研究方向为信息融合、军事大数据。
- 孙顺: 男, 1992年生, 博士生, 研究方向为信息融合、无源定位、协同控制。