

DOI:10.3969/j.issn.1672-2337.2020.01.005

# 基于 CNN 的舰船高分辨距离像目标识别

张 奇<sup>1</sup>, 卢建斌<sup>1</sup>, 刘 涛<sup>1</sup>, 刘齐悦<sup>2</sup>

(1. 海军工程大学电子工程学院, 湖北武汉 430033; 2. 中国人民解放军 91245 部队, 辽宁葫芦岛 125000)

**摘要:** 针对传统目标识别方法人工提取特征难以挖掘到数据深层次特征的问题, 提出了将卷积神经网络(CNN)应用于高分辨距离像(HRRP)的目标识别方法, 实现了对数据深层次特征的自动提取。首先构造 CNN 模型, 设置网络参数; 然后针对 HRRP 数据是一维的问题, 将 HRRP 数据重新排列使一维数据变为二维数据; 其次用训练数据对 CNN 模型进行训练得到网络参数; 最后用训练好的网络模型对测试数据进行目标识别。通过对数据的减半并且添加噪声, 验证了 CNN 的泛化性能。通过对学习率的优化, 可以进一步提高 CNN 的识别率。实测数据的实验结果表明, CNN 具有较好的识别性能。

**关键词:** 雷达目标识别; 高分辨距离像; 卷积神经网络; 深度学习

中图分类号: TN957.51; TP183 文献标志码: A 文章编号: 1672-2337(2020)01-0027-07

## High Resolution Range Profile Ship Target Recognition Based on CNN

ZHANG Qi<sup>1</sup>, LU Jianbin<sup>1</sup>, LIU Tao<sup>1</sup>, LIU Qiyue<sup>2</sup>

(1. School of Electronic Engineering, Naval University of Engineering, Wuhan 430033, China;  
2. Unit 91245 of PLA, Huludao 125000, China)

**Abstract:** For the problem that traditional target recognition method is difficult to mine the deep feature of data, the application of convolutional neural network (CNN) to high resolution range profile (HRRP) target recognition method is proposed in this paper. It realizes the automatic extraction of deep features of data. Firstly, the CNN model is constructed and the network parameters are set. Secondly, for the problem that HRRP data are one-dimensional, HRRP data are reordered to transform one-dimensional data into two-dimensional data. Then, the CNN model is trained with training data to obtain network parameters. Last, the target recognition of test data is carried out with trained network model. The generalization performance of CNN is verified by halving the data and adding noise. The target recognition rate of CNN can be further improved by optimizing the learning rate. Experimental results of measured data show that CNN achieves better recognition performance.

**Key words:** radar target recognition; high resolution range profile(HRRP); convolutional neural network (CNN); deep learning

## 0 引言

高分辨距离像(HRRP)在雷达自动目标识别(RATR)领域具有重要的军事意义, 其图像的尖峰和起伏代表了目标的精细结构信息, 反映了目标散射特性沿雷达视线方向(RLOS)的分布, 同时具有易获取、易处理的特点, 因此在目标识别领域具有广阔的应用前景<sup>[1-5]</sup>。目前国内学者对基于

HRRP 的目标识别进行了大量的研究, 模板匹配法<sup>[3]</sup>、SVM<sup>[4]</sup>和 PCA<sup>[5]</sup>是比较常见的目标识别方法, 但以上对于 HRRP 的目标识别方法均基于特征提取这一关键步骤, 很难挖掘目标数据中的深层特征, 且泛化性能不强<sup>[6-11]</sup>。

近年来深度学习(DL)发展迅速, 成为各个领域的研究热点, 同样在雷达领域也可以通过深度学习算法实现信号与信息处理<sup>[12]</sup>。目前已有国内外学者将深度学习应用于 HRRP-RATR 领域中,

文献[8]分别将 SVM、NN(Neural Network)与 SAE 方法进行区分,通过比对实验发现 SAE 的识别率最高。西安电子科技大学雷达信号处理国家重点实验室的冯博团队在文献[13]中提出 SCAE(stacked corrective autoencoder)方法,对 SAE 进行了改进,提升了 HRRP 的识别效果。文献[14]应用 SAE 和极限学习机相结合的方法进行分类,识别速度快。文献[15]采用 RNN 中长短时记忆循环神经网络(LSTM)对 HRRP 进行分类。文献[16]应用了深度置信网络(DBN)进行 HRRP 目标识别,该文献提出对样本进行  $t$  分布随机邻域插入处理,扩充了相应类型样本量。文献[17]利用 CNN 进行 HRRP 的目标识别,该文献对比了 CNN 和 DBN 对不同目标的识别准确率,CNN 的准确率大于 10%。

CNN 作为一种端对端的识别方式,无需人工特征提取且不需要角度的先验信息,一般用于对图像数据的处理,其鲁棒性和抗干扰性较强。针对传统目标识别方法人工提取特征难以挖掘到数据深层次特征,且易丢失数据信息的问题,本文提出了将 CNN 应用于 HRRP 的目标识别方法;针对 HRRP 数据是一维的问题,本文提出了将 HRRP 序列重新排列,将一维数据变为二维数据进行输入,其具体方法为:将一维 HRRP 向量分为若干列向量形成“伪二值图像”,即二维矩阵,作为网络的输入数据。由于 CNN 网络对平移、扭曲、缩放具有不变性<sup>[18]</sup>,因此将一维数据转化为二维数据并不会增加或减少数据所包含的信息量,并且基于此优越特性,解决了 HRRP 的平移敏感性。并在各层将数据可视化,可以更加直观地看出网络的训练过程;针对网络中参数的选择问题,本文详细讨论了网络中的参数对识别性能的影响并进行了优化。另外本文通过对数据集减半和添加噪声的方式验证了 CNN 具有较高的鲁棒性和较高的识别率。

## 1 基于卷积神经网络的高分辨距离像目标识别

### 1.1 高分辨距离像(HRRP)

HRRP 是目标散射点子回波沿雷达视线方向的投影向量和,其生成示意图如图 1 所示。早期的

雷达目标识别主要是通过窄带雷达对目标的有效散射截面积(RCS)进行研究的,随着带宽的增大,雷达的分辨能力增强,当雷达的带宽大到使雷达的距离分辨率远小于目标的尺寸时,目标的各等效散射中心在雷达视线上被分开,目标回波占据了多个距离单元,形成 HRRP,它包含了目标的结构、大小、形状等重要信息<sup>[19]</sup>,因此如何有效地获取并利用这些信息在目标识别领域中显得尤为重要。

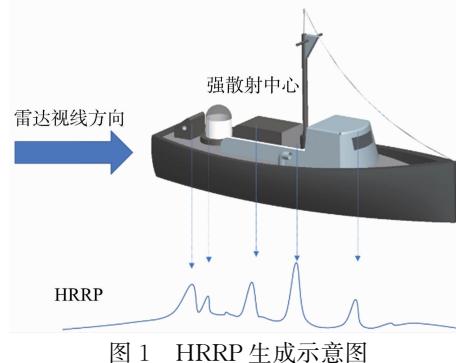


图 1 HRRP 生成示意图

### 1.2 CNN 模型结构

CNN 是一类特殊的前馈神经网络,最早始于 20 世纪 60 年代 Hubel 和 Wiesel 等人通过对猫和猴的视觉皮层细胞研究,发现其独特的网络结构可以有效地降低反馈神经网络的复杂性,提出了感受野(receptive field)的概念,继而提出了 CNN<sup>[20]</sup>。近年来,CNN 被广泛应用于各个领域,在语音识别、人脸识别、通用物体识别、运动分析、自然语言处理等方面均有突破,它的基本结构如图 2 所示。

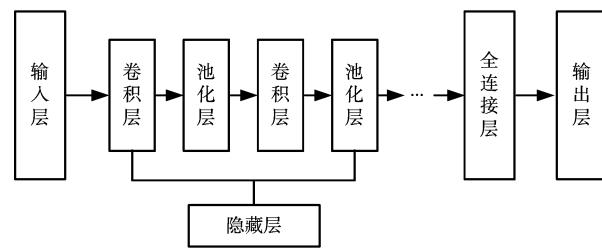


图 2 CNN 基本结构图

从图 2 可以看出,CNN 与普通的人工神经网络相比在结构上多了卷积层和池化层,即“特征抽取器”,通过数据训练出的卷积核对于特定的特征才会有较大的激活值。卷积操作是利用卷积核对输入图片或者上一隐层的数据进行处理,更深层次的卷积层可以学习到更深层次的特征,其核心

是可以减少不必要的权值连接,权值共享可以大大减少网络的参数量并且提高计算速度,每一个卷积层包含了若干个特征映射图(feature map),其表达式如下:

$$h_j^i = f^i \left( \sum_{k \in I_j} C_{jk} \cdot (h_k^{(i-1)} \otimes w_{kj}^{(i-1)}) + b_j^{(i-1)} \right) \quad (1)$$

式中: $f(\cdot)$ 为激活函数; $i$ 为隐层数, $j$ 为第 $i$ 隐层的特征图数; $C_{jk}$ 为连接池化层(或输入层)与卷积层的指示集,连接时其值为1,未连接时值为0; $\otimes$ 代表卷积运算; $w_{kj}^{i-1}$ 为第 $i$ 隐层第 $j$ 个特征图与第 $i-1$ 隐层第 $k$ 个特征图(或输入层)之间的卷积核; $b$ 为偏置项。如 $h_1^2$ 代表第二隐层第一张特征图, $h^0$ 为输入图片。池化层即子抽样层,池化操作是在特征图的一个小区域内选取一个特定的值作为输出值,可以减少计算量,有效控制过拟合风险。即

$$h^i = \text{pooling}(h^{i-1}) \quad (2)$$

池化操作包括最大池化、平均池化等,本文采用最大池化。在全连接层输出的每个神经元都和上一层每一个神经元连接。在输出层一般用 softmax 分类器进行分类,损失函数为

$$J = -\frac{1}{N} \sum_N \log(Y) + \lambda \|w\| \quad (3)$$

式中, $Y$ 为网络的输出,后一项为正则项,目的是为了防止过拟合,权重衰减系数 $\lambda$ 可以控制过拟合程度, $\lambda$ 值过小可能会导致过拟合,反之可能会导致欠拟合。

### 1.3 步骤方法

由于 HRRP 是一维数据,因此本文考虑将 HRRP 数据重新排列转化为二维数据再进行输入。实验步骤分为数据预处理、训练网络、测试网络。

**数据预处理:**一般情况下初始 HRRP 都是复值数据,首先对复值数据进行取模运算,然后进行能量归一化,最后将一维数据重新排列转化为二维数据。

**训练网络:**在网络进行训练之前搭建 CNN 网络,初始化网络参数,本文采用标准初始化(normalized initialization)方法初始超参数,即

$$w_{ij} \sim U \left( -\sqrt{\frac{6}{m+n}}, \sqrt{\frac{6}{m+n}} \right) \quad (4)$$

式中, $U$ 代表均匀分布, $m$ 为类别数, $n$ 为输出的全

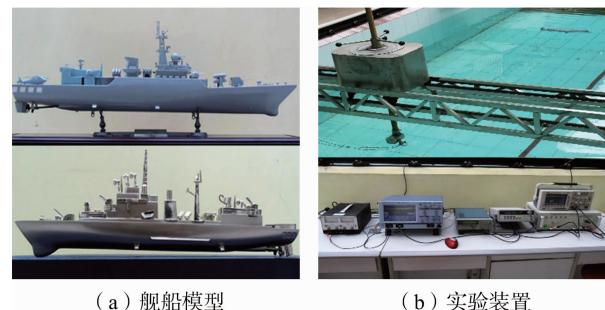
连接维度。将处理后的二维数据作为网络的输入,利用式(1)、式(2)进行前向传播计算,获得网络各卷积层和池化层的特征图 $h^1, h^2, \dots$ ,根据得到的损失函数式(3)利用反向传播算法(BP)来实现网络中参数的更新学习,最终得到每一类样本的网络参数 $w$ 和 $b$ 并保存。

**测试网络:**将测试数据输入到训练好的网络模型中并与实际标签进行对比,计算网络的准确率。

## 2 实验结果与讨论

### 2.1 数据集

本文采用的数据是某实验室通过水声试验测量的舰船模型 HRRP 数据<sup>[21]</sup>,舰船模型与实验装置如图 3 所示,实验示意图如图 4 所示。



(a) 舰船模型 (b) 实验装置

图 3 舰船模型与实验装置

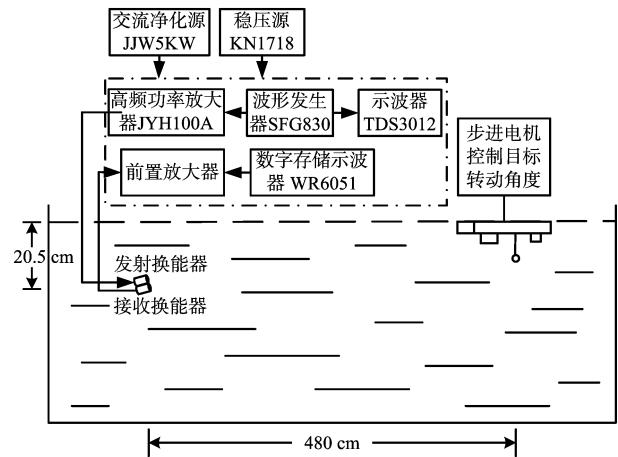


图 4 实验示意图

实验共测得 5 类舰船在不同角度下的 HRRP 数据,5 类舰船目标编号为目标 A~E,其中 A~C 为军用舰船,D 为渔政船,E 为巴拿马型货船。每一类包含 2 400 个样本,平均覆盖 180°姿态角,图 5 给出了 5 类目标在姿态角为 0°时的归一化 HRRP。

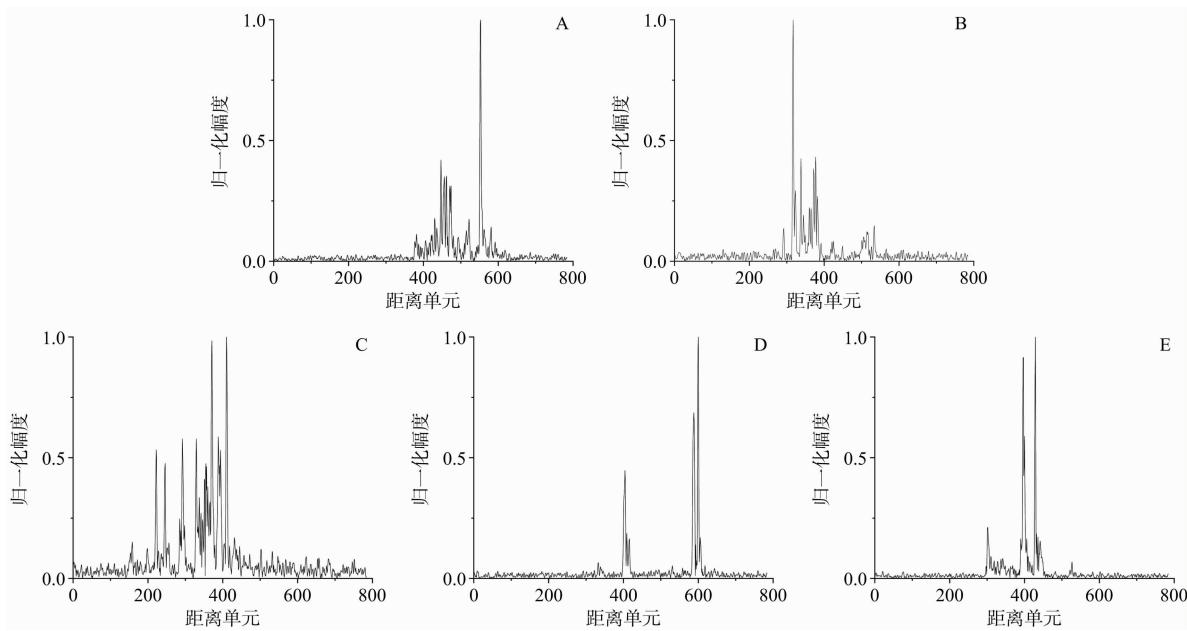


图 5 5 类舰船实测数据的 HRRP

本文所采用的网络模型如图 6 所示。

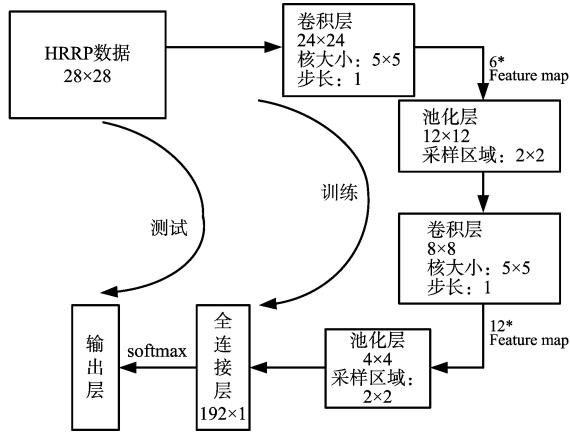


图 6 卷积神经网络模型

实验随机抽取 80% 的数据进行训练网络, 剩余数据测试网络。设测试数据为  $P_{\text{test}}$ , 这里  $P_{\text{test}} = 2400$ , 测试数据中预测正确的样本数量为  $N$ , 由于 5 类舰船数据量相同, 具有对称性, 因此本文定义目标识别率为

$$\eta = \frac{N}{P_{\text{test}}} \quad (5)$$

## 2.2 实验结果

实验基于 MATLAB 中的 DeepLearn Toolbox, 具体运行环境为 Intel (R) Core(TM) i5-7500 CPU @ 3.4 GHz(8 G 内存)。为了更加清楚直观地观察网络训练的过程, 图 7 给出了可视化训练结果。

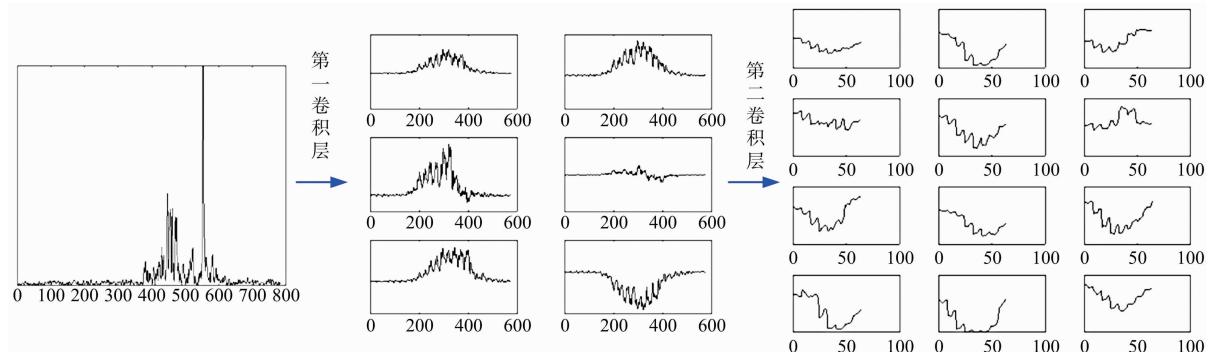


图 7 HRRP 数据与不同卷积层的特征图

图 7 为某类样本在一次训练过程中的特征图, 其中包括第一个卷积层的 6 张特征图和第二个卷积层的 12 张特征图(图中特征图的纵轴均为归一化幅度), 网络层数越高代表了学习到更深层次的特征。

由于 sigmoid 函数在信号的空间映射上有良好的效果, 因此实验选取 sigmoid 作为激活函

数,对应的公式为

$$\text{sigmoid}(x) = \frac{1}{1+e^{-x}} \quad (6)$$

在实验中,取学习率  $\alpha=1$ , $batches=50$ ,采用批量随机梯度下降法训练网络,在不同的迭代次数下目标识别率如图 8 所示。

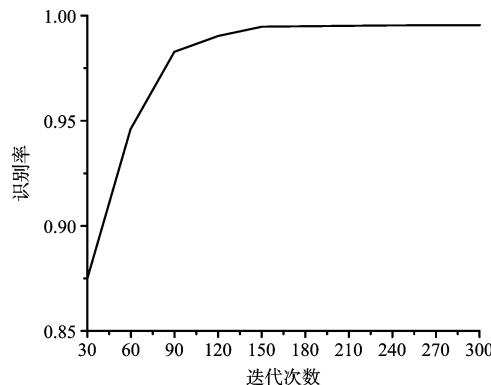


图 8 CNN 在不同迭代次数下的识别率

由图 8 可以看出,在迭代次数超过 150 时网络基本可以学到数据的全部特征,训练损失曲线如图 9 所示。同时为了验证 CNN 方法对稳健特征提取与目标识别的有效性,文章将 CNN 与 SVM 进行比较,在 SVM 实验中,核函数取径向基函数(RBF),通过网格搜索算法对惩罚系数 C 和  $\sigma$  进行寻优,训练数据与测试数据完全相同,CNN 迭代次数为 300,识别率与识别时间如表 1 所示。

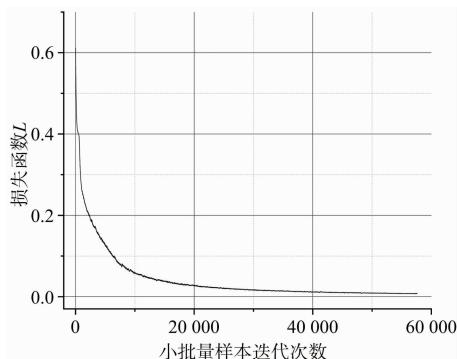


图 9 训练损失曲线

表 1 CNN 与 SVM 的目标识别结果

方法	识别率	识别时间/ms
SVM	0.985 0	21.48
CNN	0.995 4	0.23

从表 1 可知,CNN 的识别性能在准确率与识别时间上都优于 SVM,识别率可达到 99.54%,并且识别速度较快,无需人工特征提取且无需了解姿态角的先验信息。

### 3 泛化性能

由上一节可知,在数据量充足的情况下 CNN 可达到较高的识别率,但由于舰船非合作目标的缺陷,往往会造成数据库角度数据的不足,数据集缺失,回波数据被噪声干扰等情况,本节将进一步探讨在训练数据不足且添加噪声的情况下 CNN 的识别性能。

取数据集中姿态角度为  $30^\circ \sim 60^\circ$ , $90^\circ \sim 120^\circ$ , $150^\circ \sim 180^\circ$  扇形区间内的数据,训练集从中随机选取 80%,即将数据集与训练集减少一半,测试集不变,仍从全数据集中随机选取 20%,这样测试集中会有大约 50% 的数据没有在训练数据的扇形区间内。在此基础上,对数据加入高斯白噪声,使得处理后数据信噪比范围为  $-5 \sim 10$  dB,CNN 在不同的信噪比、学习率、迭代次数下识别结果如表 2 所示,与此同时将实验测得 SVM 在相同数据集与信噪比环境下的识别率如表 3 所示,两种方法的识别结果如图 10 所示。

表 2 CNN 在不同条件下的识别结果

学习率	迭代次数	信噪比/dB			
		-5	0	5	10
0.5	150	0.600 4	0.688 8	0.740 8	0.756 3
	300	0.680 4	0.750 8	0.776 3	0.809 6
1.0	150	0.658 3	0.723 8	0.777 5	0.793 8
	300	0.717 9	0.770 0	0.777 5	0.805 8
1.5	150	0.692 1	0.715 4	0.768 8	0.794 2
	300	0.705 0	0.758 3	0.782 5	0.798 3
2.0	150	0.680 4	0.749 6	0.770 4	0.802 5
	300	0.692 9	0.737 9	0.786 3	0.807 5
2.5	150	0.677 1	0.750 8	0.772 1	0.789 6
	300	0.716 7	0.781 3	0.796 7	0.818 3
3.0	150	0.690 4	0.723 8	0.753 8	0.791 3
	300	0.705 8	0.742 5	0.787 1	0.806 3
3.5	150	0.680 0	0.728 8	0.776 7	0.798 3
	300	0.697 9	0.726 7	0.788 8	0.795 8
4.0	150	0.695 8	0.726 3	0.752 5	0.781 7
	300	0.720 8	0.740 8	0.775 8	0.817 5
4.5	150	0.695 4	0.725 4	0.789 6	0.767 9
	300	0.705 0	0.729 2	0.776 3	0.797 5
5.0	150	0.672 1	0.728 8	0.741 3	0.790 4
	300	0.692 5	0.735 0	0.758 3	0.781 7

表 3 SVM 在不同信噪比情况下的识别结果

信噪比/dB	识别率
-5	0.5117
0	0.6954
5	0.7233
10	0.7342

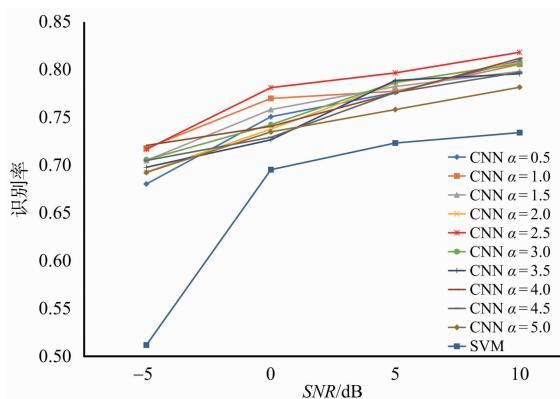


图 10 CNN 与 SVM 在不同信噪比情况下的识别率

从图 10 可以看出,在添加噪声并且测试集中有一半的数据集没有经过训练的情况下 CNN 仍有较高的识别率,信噪比为 10 dB,训练数据减半时最高识别率可达到 81.83%。学习率是深度学习中重要的参数,其取值对于梯度下降法有重要的影响,值过大可能会导致陷入局部极值甚至无法收敛,值过小可能导致收敛过程十分缓慢,因此学习率是决定目标函数是否能够收敛与何时收敛的重要因素。往往在训练深度网络的过程中学习率的取值多数凭经验选取,比如 1 等值,而适当的学习率的选择会提高目标识别的准确率,在图 10 中当信噪比大于 0 时, $\alpha=2.5$  时识别率最高,平均识别率可提高 1.0 个百分点。当学习率分别为 1 和 2.5 时网络的训练损失如图 11 所示。从图 11 可以看出,当  $\alpha=2.5$  比  $\alpha=1$  时网络会更加快速的收敛。

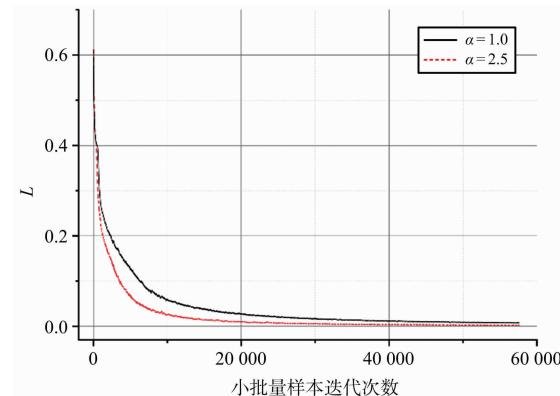


图 11 不同学习率下的训练损失曲线

## 4 结束语

本文将卷积神经网络应用于高分辨距离像的目标识别中,将一维数据转化为二维数据,解决了在传统目标识别的过程中人工提取特征很难挖掘到数据深层次特征的问题。在数据量充足的情况下可以达到近百分之百的识别率,然后对网络的泛化性能进行了讨论,并与 SVM 进行了对比,验证了 CNN 的鲁棒性较强,最后对不同的学习率进行了对比,以往由于深度网络训练时间较长等原因,学习率的选择往往是易被忽视的一点,而本文提出的合适学习率的选择可以提高识别率,对雷达自动目标识别具有重要的意义。

## 参考文献:

- [1] DU Lan, WANG Penghui, LIU Hongwei, et al. Bayesian Spatiotemporal Multitask Learning for Radar HRRP Target Recognition[J]. IEEE Trans on Signal Processing, 2011, 59(7):3182-3196.
- [2] FENG Bo , DU Lan , LIU Hongwei, et al. Radar HRRP Target Recognition Based on K-SVD Algorithm [C] // Proceedings of 2011 IEEE CIE International Conference on Radar, Chengdu:IEEE, 2011:642-645.
- [3] 张军英,白向辉.雷达自动目标识别中的 HRRP 特征提取研究[J].系统工程与电子技术, 2007, 29(12): 2047-2051.
- [4] 翟夕阳,王晓丹,李睿,等.基于二叉树直觉模糊 SVM 的弹道目标 HRRP 识别[J].火力与指挥控制, 2017, 42(10):64-68.
- [5] DU L , LIU H , BAN Z , et al. Radar Automatic Target Recognition Using Complex High-Resolution Range Profiles[J]. IET Radar, Sonar & Navigation, 2007, 1(1):18-26.
- [6] 赵飞翔,刘永祥,霍凯.基于栈式降噪稀疏自动编码器的雷达目标识别方法[J].雷达学报, 2017, 6(2): 149-156.
- [7] 曲长文,刘晨,周强,等.基于分块 CNN 的多尺度 SAR 图像目标分类算法[J].雷达科学与技术, 2018, 16(2):169-173.
- [8] 张欢.基于射频隐身的机载雷达系统软件实现及 HRRP 目标识别研究[D].南京:南京航空航天大学, 2016.
- [9] 徐彬,陈渤,刘宏伟,等.基于注意循环神经网络模型

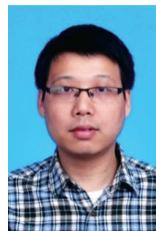
- 的雷达高分辨率距离像目标识别[J]. 电子与信息学报, 2016, 38(12):2988-2995.
- [10] 朱同宇. 基于深度学习的合成孔径雷达地面目标识别技术研究[D]. 哈尔滨:哈尔滨工业大学, 2017.
- [11] 徐丰, 王海鹏, 金亚秋. 深度学习在 SAR 目标识别与地物分类中的应用[J]. 雷达学报, 2017, 6(2): 136-148.
- [12] 王俊, 郑彤, 雷鹏, 等. 深度学习在雷达中的研究综述[J]. 雷达学报, 2018, 7(4):395-411.
- [13] FENG Bo, CHEN Bo, LIU Hongwei. Radar HRRP Target Recognition with Deep Networks[J]. Pattern Recognition, 2017, 61(1):379-393.
- [14] ZHAO Feixiang , LIU Yongxian, HUO Kai, et al. Radar HRRP Target Recognition Based on Stacked Autoencoder and Extreme Learning Machine [J]. Sensors, 2018, 18(1):173.
- [15] JITHESH V, SAGAYARAJ M J, SRINIVASA K G. LSTM Recurrent Neural Networks for High Resolution Range Profile Based Radar Target Classification[C] // International Conference on Computational Intelligence & Communication Technology, Ghaziabad, India: IEEE, 2017:1-6.
- [16] XIA J Y, LI X, LIU Y X. Application of a New Restricted Boltzmann Machine to Radar Target Recognition [C] // Progress in Electromagnetic Research Symposium, Shanghai: IEEE, 2016:2195-2201.
- [17] LUNDÉN J, KOIVUNEN V. Deep Learning for HRRP-Based Target Recognition in Multistatic Radar Systems[C] // 2016 IEEE Radar Conference, Philadelphia, PA, USA: IEEE, 2016:1-6.
- [18] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6):1229-1251.
- [19] 姜卫东. 光学区雷达目标结构成像的理论及其在雷达目标识别中的应用[D]. 长沙: 国防科学技术大学, 2000.
- [20] GU Jiuxiang, WANG Zhenhua , KUEN J, et al. Recent Advances in Convolutional Neural Networks[J]. Pattern Recognition, 2018, 77:354-377.
- [21] 张明敏, 卢建斌, 程广利. 近距离水声模拟测量舰船目标雷达一维距离像[J]. 哈尔滨工程大学学报, 2016, 37(6):855-859.

### 作者简介:



**张奇** 男,1994 年生,吉林敦化人,硕士研究生,主要研究方向为雷达信号处理、深度学习。

E-mail:zhangqi890@outlook.com



**卢建斌** 男,1980 年生,河南信阳人,副教授、硕士生导师,主要研究方向为雷达信号处理。



**刘涛** 男,1978 年生,山东泰安人,教授、博士生导师,主要研究方向为雷达极化信息处理。



**刘齐悦** 男,1995 年生,辽宁葫芦岛人,助理工程师,主要研究方向为相控阵雷达。

(上接第 26 页)



**夏翔** 男,1994 年生,江苏镇江人,硕士研究生,主要研究方向为阵列信号处理。

**俞传富** 男,1995 年生,江苏扬州人,硕士研究生,主要研究方向为水下声学成像。

**宋逸君** 男,1994 年生,江苏南京人,硕士研究生,主要研究方向为水下信号处理。