

# 基于PID和深度卷积神经网络的辐射源识别方法

曹 阳<sup>1</sup>, 王金明<sup>1</sup>, 徐程骥<sup>2</sup>, 岳振军<sup>1</sup>, 狄恩彪<sup>1</sup>

(1. 陆军工程大学通信工程学院, 南京, 210007; 2. 南京国电南自电网自动化有限公司, 南京, 211153)

**摘 要:** 利用神经网络进行辐射源个体识别时, 训练样本的单一性会导致深度网络出现过拟合的现象, 继而影响辐射源个体识别的精确性。针对该问题, 本文提出一种基于PID算法的深度卷积网络结构, 该结构通过在传统卷积神经网络的输出层与输入层间构建一条反馈回路, 采用PID算法将网络输出错误率转化为划分训练集数据构成的概率, 通过优化训练集数据构成, 达到抑制过拟合的目的。将该方法应用于超短波电台识别, 平均识别率达到92.59%, 识别率方差约为传统算法的1/3, 训练用时减少约35 min, 上述指标均优于传统神经网络。实验结果表明, 该算法增强了深度网络的鲁棒性, 有效地抑制了过拟合现象。

**关键词:** 卷积神经网络; 辐射源识别; 过拟合

**中图分类号:** TP183      **文献标志码:** A

## Specific Emitter Identification Based on PID and Deep Convolutional Neural Network

CAO Yang<sup>1</sup>, WANG Jinming<sup>1</sup>, XU Chengji<sup>2</sup>, YUE Zhenjun<sup>1</sup>, DI Enbiao<sup>1</sup>

(1. College of Communications Engineering, Army Engineering University of PLA, Nanjing, 210007, China; 2. Guodian Nanjing Automation CO., LTD, Nanjing, 211153, China)

**Abstract:** With the singleness of the training sample, the phenomenon of overfitting occurs in the deep neural network when used for specific emitter identification (SEI), which in turn affects the accuracy. In this paper, a deep convolutional neural network (CNN) structure based on PID algorithm is proposed to alleviate the problem. The structure builds a feedback loop between the output layer and the input layer of the traditional CNN, transforms the error rate of output layer into the probability of dividing the training set data by using PID algorithm, and inhibits the overfitting by optimizing the composition of training set data. The average recognition rate of the network reaches 92.59% when the method is applied to the recognition of ultrashort wave radio. The variance of the recognition rate is about 1/3 of that of the traditional algorithm, and the training time is reduced by about 35 min, obviously the performance of this method is better than that of the traditional neural network. Experimental results show that the algorithm can enhance the robustness of the deep network and effectively suppress the overfitting phenomenon.

**Key words:** convolutional neural network (CNN); specific emitter identification; overfitting

## 引 言

辐射源个体识别(Specific emitter identification, SEI)是电子对抗的重要组成部分,常常通过提取信号的外部特征实现对发射机的分类,是一种非合作的识别手段。由信息传输过程可知,接收机采集到的信号并不是发射端发出的原始信号,还包含了信道、噪声等影响因素。在使用深度神经网络进行辐射源个体分类时,由于信号采集场景单一且样本数量少,网络容易学习到信道、噪声等特征,导致出现过拟合问题<sup>[1-2]</sup>。为了解决过拟合问题,研究人员提出将数据集按照一定比例随机划分为训练集、验证集和测试集3个部分,训练集和测试集的数据分别用于训练和测试,验证集用于观察训练过程、调整训练进度以及超参数。正则化<sup>[3]</sup>、Dropout<sup>[4]</sup>和 Earlystopping 等强化泛化能力的方法都会引入一定的超参数,需要一定量的验证集实现超参数优化。因此以上方法也无法完全解决过拟合问题。深度网络过拟合问题一直是研究热点和难点,基于小样本的学习算法已成为深度网络推广应用的一个核心瓶颈。

本文研究了采集场景单一情况下的辐射源信号分类识别方法。从理论上分析分类识别过程中,深度神经网络产生过拟合的原因,并探索通过在网络输出与输入间增加反馈回路,消除过拟合、提升网络泛化能力的方法。将该方法应用于超短波电台识别时,实验结果表明,该方法有效抑制了过拟合问题,增强了深度卷积神经网络的鲁棒性,提升了辐射源个体识别率,改善了识别效果。

## 1 卷积神经网络

卷积神经网络(Convolutional neural networks, CNN)是一类包含卷积计算且具有深度结构的前馈神经网络,是深度学习的代表算法之一<sup>[5-6]</sup>,目前已经在很多领域得到广泛的应用,尤其是在图像、语音处理等领域发挥着重要的作用。如图1所示,卷积神经网络一般包含输入层、卷积层、池化层、全连接层、softmax层和输出层等,输入数据通过一系列卷积和池化操作,经全连接层转为向量,由 softmax层归一化为概率分布。卷积计算公式为

$$Z^{l+1}(i, j) = [Z^l \otimes K^{l+1}](i, j) = \sum_k \sum_m \sum_n (Z^l_c(s_i + m, s_j + n) K^{l+1}_c(m, n)) \quad (1)$$

式中: $Z^l, K, C$ 分别为第 $l$ 层特征图(Feature map)、卷积核(Convolutional kernel)以及通道(Channel); $m, n, k$ 表示索引; $i, j$ 表示像素。




图1 典型的卷积神经网络结构

Fig.1 Typical convolutional neural network structure

## 2 基于PID和卷积神经网络的辐射源识别方法

### 2.1 卷积神经网络用于辐射源识别时网络过拟合问题分析

经信道传输后,信号接收机采集得到发射机发射的时域信号,并将其用于辐射源识别。那么接收

机采集的信号可表示为

$$x_i(t) = r_{x_i}(t) + C_i(t) + N_i(t) \quad (2)$$

式中:  $r_{x_i}(t)$  为发射机发出的发射端信号,  $x_i(t)$  为接收机采集到的信号,  $C_i(t)$ 、 $N_i(t)$  分别为信道特征和背景噪声特征,  $i$  为发射机序号。

在卷积神经网络训练过程中, 随着迭代次数的增加, 训练集的误差会越来越小。而过拟合现象的表现为: 训练集误差不断降低的同时, 测试集的正确率不仅没有提高, 甚至出现下降。

图2为接收机端信号的特征分布示意图, 其中方形区域表示背景噪声特征, 3个圆形区域表示3部发射机发射端信号特征, 椭圆形区域表示信道特征。如果没有信道和噪声的影响, 由于信号发射设备硬件上的细微差异, 深度神经网络能够学习到每类发射机的信号特征, 不同发射机的信号是完全可分的, 故图2中圆形特征区域相互不重叠。但是现实中, 传输信道的影响不可忽略, 网络还将学习到传输信道的特征。特别是当信号的采集环境较为单一(采集时间段相同、发射机空间位置相近等)时, 信道特征会高度相似, 进而严重影响深度网络的训练, 甚至会导致过拟合。神经网络出现过拟合时, 会将具有相似信道特征的输入信号判为一类, 从而表现出某一类的数据识别率较高, 其他数据识别率相对较低, 总体识别率下降。




图2 特征分布示意图

Fig.2 Feature distribution diagram

对于一个三分类的卷积神经网络, 当出现上述情况时, 3类电台的分类错误率随迭代次数的变化曲线会出现分层现象, 如图3所示。

对于一个以分类为目标的深度卷积神经网络, 毋庸置疑, 更高的分类正确率是第一位的。与此同时, 网络对每一类的识别能力应当尽可能相近, 也就是, 希望网络在出现错误分类时, 每一类的错误率应服从等概率分布, 即

$$P^i(i=k) = 1/m \quad (3)$$

$$P_0 = [P^1, P^2, \dots, P^i] \quad (4)$$

式中:  $P^i$  表示第  $i$  类发射机分类错误率,  $m$  表示分类数量,  $P_0$  表示目标分类错误率向量, 其服从等概率分布, 且维度的值与  $m$  相等。

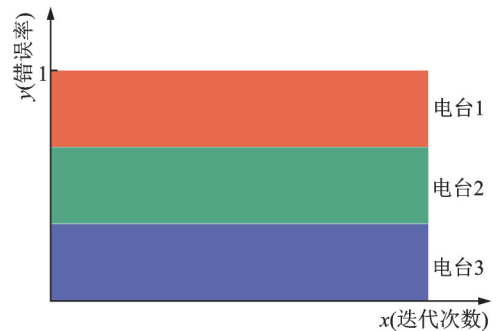


图3 错误率分层现象示意图

Fig.3 Diagram of error rate stratification

## 2.2 采用PID方法解决深度网络过拟合问题

图4为基于PID的深度卷积神经网络算法框图, 相较于传统的卷积神经网络, 在输出与输入间增加一条反馈回路, 即图4中的反馈2通道。采用PID算法将输出分类的错误率转化为控制数据分发器的概率, 让错误率高的数据以更高的概率参与训练, 进行“强化学习”, 以达到均衡错误率为目的, 进而抑制过拟合。

根据图4的系统框图, 设计了基于PID的深度卷积神经网络算法, 主要从训练过程、PID算法调控

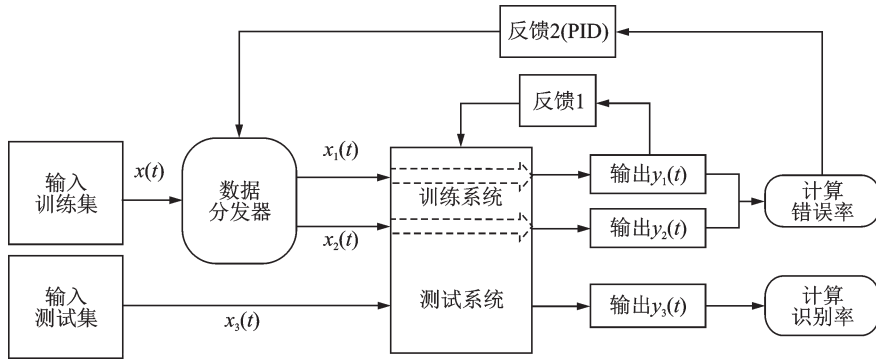


图4 基于PID的深度卷积神经网络结构图

Fig.4 Structure diagram of deep convolutional neural network system based on PID

原理和数据分发器3个方面实现。

(1)训练过程。从训练集中取出数据  $x(t)$ ,通过数据分发器,将数据集分成  $x_1(t)$ 和  $x_2(t)$ 。 $x_1(t)$ 通过训练系统,前向传播后由 softmax层转为概率向量  $y_1(t)$ ,计算损失函数并通过反馈1通道使用反向传播算法,对网络参数进行调整。同时,  $x_2(t)$ 通过训练系统后,输出为  $y_2(t)$ ,与  $y_1(t)$ 合并计算当前错误率为  $P(t)$ 。令当前样本标签二值化后为  $Q(t)$ ,则每个样本的交叉熵损失为

$$H(Q, y_1) = -\frac{1}{m} \sum_{i=1}^m Q^i(x_1) \log y_1^i(x_1) \quad (5)$$

式中  $m$ 表示分类数量。

(2)PID算法调控原理。当前错误率为  $P(t)$ ,目标错误率为  $P_0$ ,则偏差为

$$e(t) = P(t) - P_0 \quad (6)$$

控制量为

$$u(t) = P * e(t) + I * \int_0^t e(t) dt + D * \frac{de(t)}{dt} \quad (7)$$

式中  $P, I, D$ 分别表示比例项、积分项、微分项的系数。

为了便于设计数据分发器,对控制量  $u(t)$ 进行归一化处理。本文采用常用的 sigmoid函数实现控制量的归一化,该函数表达式为

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (8)$$

故而有

$$p(t) = \text{sigmoid}(u(t)) \quad (9)$$

(3)数据分发器。数据分发器决定训练集中正常参加训练的数据比例。图5为本文采用的数据分发器模型,主要由随机数发生器、偏移器、比较器和数据选择器构成。为了保证大部分数据能够参与训练,需要对  $p(t)$ 增加一个偏移量  $\delta$ 。将偏移后的概率与随机数发生器产生的数据比较,达到控制参加网络训练的数据比例的目的。

为了便于评价网络改进前后的分类效果,系统每迭代训练10次,计算1次测试集样本的正确识别

率。用  $N$  表示待测试样本总数,  $n$  表示正确分类的样本数, 则正确识别率可表示为

$$\text{accuracy} = \frac{n}{N} \times 100\% \quad (10)$$

### 2.3 PID 参数调节

PID 算法由于应用广泛, 因而其参数设定的方法也是众多学者的研究方向和重点<sup>[7]</sup>。使用卷积神经网络实现分类目的, 难免需要根据经验调整大量的超参数, 本文由于采用了 PID 算法, 增加了 4 个超参数, 分别为  $P, I, D$  以及偏移量  $\delta$ 。结合前人研究的调参方法, 通过多次实验得出了表 1 中的数据。

需注意的是, 参数设定应该遵循两个原则: (1) 逐个调整, 灵活搭配。本文先是调整了偏移量, 再调整  $P$ , 最后调整了  $I$ 。由于网络已取得较好的效果, 故  $D$  参数未参加调整。PID 参数可根据需要灵活组合使用。(2) 参数要适中。参数过大, 则表示控制强度过大, 调控进入饱和状态, 起不到调节作用; 参数过小, 则调控强度过小, 大量数据不能参与训练, 导致网络训练不充分, 收敛速度变缓。

### 3 实验仿真

在实验室环境下, 采集了 3 部超短波电台的辐射信号, 每部电台工作在 3 个不同的频率(频率间隔 2 MHz), 工作状态为有导频无语音。电台参数采用双谱特征, 双谱是信号高阶谱的一种, 由于双谱中包含了丰富的信号细微信息, 且受高斯噪声和杂波影响较小, 近年来得到了广泛的应用<sup>[8]</sup>。图 6 为一段电台信号提取的三维双谱图。将提取得到的双谱特征按照 9:1 打乱, 随机划分为训练集(1 085 个)和测试集(121 个)。

用来实验的卷积神经网络为 10 层网络(含 8 个卷积层和 2 个全连接层), 激活函数为线性整流函数(Rectified linear unit, ReLU), 池化方式为最大池化, 网络结构如图 7 所示。为了防止随着层数的增加导致梯度爆炸或消失, 文献<sup>[9]</sup>基于每一层输出值的方差相等推导出 Xavier 参数初始化方式。该初始化方式下的参数服从均匀分布, 若  $n_i$  表示第  $i$  层的输入个数, 则该分布可表示为




图 5 数据分发器构成

Fig.5 Data distributor composition

表 1 4 种超参数数值

Table 1 Four kinds of super parameter values

类别	$P$	$I$	$D$	$\delta$	识别率/%
参数值	1.0	0.07	0	0.4	92.59
参数值	1.0	0.007	0	0.4	92.04
参数值	1.0	0.007	0	0.1	90.72




图 6 一段电台信号三维双谱图

Fig.6 Three-dimensional bispectrum diagram of a radio signal




图 7 10 层卷积神经网络结构图

Fig.7 Ten-layer convolutional neural network structure diagram

$$W \sim U \left[ -\sqrt{\frac{6}{n_i + n_{i+1}}}, \sqrt{\frac{6}{n_i + n_{i+1}}} \right] \quad (11)$$

改进前与改进后的网络各训练3次,实验数据为3次实验的均值。训练平台为64位Win10系统,Python3.6,硬件为小米笔记本Pro,处理器为Intel Core i5-8250U,8 GB内存。

### 3.1 过拟合现象及分析

采用传统卷积神经网络进行辐射源个体识别时,识别率随着迭代次数的变化曲线如图8所示。可以发现:在3次实验中,识别率都是一开始随着训练迭代次数的增加快速增长,随后趋于稳定,在91%左右,但是最终识别率不仅没有进一步提升,反而出现了识别率曲线纵坐标数值的向下移动。尽管已经使用了Dropout方法抑制过拟合,但其效果并不理想,识别效果不佳。

### 3.2 错误率曲线分层现象

传统卷积神经网络训练过程中,识别错误率随着迭代次数的变化曲线如图9所示。从图9中可以看出第1部电台识别错误率较高,而第3部电台识别错误率较低。由于电台信号是在实验室环境下采集,信噪比较高,噪声带来的影响相对较低。但采集场景的单一,使得电台分类受信道传输影响较大,错误率曲线出现了明显的分层现象。

### 3.3 改进前后网络分类效果实验

分别得到了传统卷积网络和改进型网络识别错误率的均值和方差,如表2所示。可以发现通过改进型网络,1号电台的错误率相对于传统卷积网络的错误率,由0.513 5降为0.464 7;且3号电台的错误率由0.119 8提高到0.196 5,二者都在向着目标概率方向移动。同时,改进型网络的错误率方差明显小于传统卷积神经网络,仅为0.018 0。因此,可以得出结论:本文设计的反馈通道起到了调节作用,含有PID算法的卷积神经网络能够调整网络的输出分布。

图10是2种网络的识别率随迭代次数的变化曲线,传统卷积网络<sup>[10]</sup>随着迭代次数的增加,识别率在迭代次数为150左右时,开始出现下降。而改进型卷积网络由于增加了对输出错误率的约束,分类识别率没有因为迭代次数的增加而出现下降。因此可以得出结论:基于PID算法的卷积神经网络消除了




图8 传统卷积神经网络对电台的分类识别效果  
Fig.8 Classification and recognition effect of traditional convolutional neural networks on radio stations




图9 错误率曲线  
Fig.9 Error rate curve

表2 识别错误率和方差比较

Table 2 Identify error rates and variance comparisons

电台序号	1	2	3	方差
传统卷积网络	0.513 5	0.366 7	0.119 8	0.039 6
改进型网络	0.464 7	0.338 8	0.196 5	0.018 0

过拟合现象,增强了网络的泛化能力。表3是两种卷积神经网络的性能参数,从识别率来看,本文算法比传统算法的电台识别率更高,平均识别率为92.59%。从识别率方差来看,本文算法下的识别率方差更小,说明网络识别效果更为稳定。从训练用时来看,本文算法用时更少,较传统卷积网络算法整体用时少了35.3 min,说明算法复杂度较低。

综合来看,基于PID的卷积神经网络能够更好地完成辐射源个体的分类识别,该算法不仅实现了较高的识别率,还降低了算法复杂度,也提升了算法鲁棒性。




图10 正确识别率曲线

Fig.10 Curve of correct recognition rate

表3 两种网络性能比较

Table 3 Two kinds of network performance comparison

类别	测试平均识别率/%	识别率方差/ $10^{-4}$	训练平均用时/min
传统卷积网络	90.20	1.06	269.7
改进型网络	92.59	0.38	234.4

#### 4 结束语

本文对辐射源识别方法进行了研究,针对辐射源信号样本数据采集场景单一、数量较少,导致卷积神经网络出现过拟合问题,提出了基于PID和卷积神经网络的辐射源个体识别算法。将该算法用于通信电台的识别,实验结果表明,本文算法比传统算法识别率高,平均识别率为92.59%;识别率方差更小,该算法下的识别率方差约为传统算法的1/3,说明改进型网络识别效果更为稳定;训练用时较少,该算法训练速度比传统网络快,算法复杂度更低。总的来说,基于PID和深度卷积神经网络的识别算法能够完成辐射源个体的分类识别,该算法在保证较高的识别率的同时,抑制了过拟合,降低了算法复杂度,提高了深度网络的鲁棒性。同时,本文算法也为自适应调参提供了一种研究思路。

#### 参考文献:

- [1] YU S, JIA S, XU C, et al. Convolutional neural networks for hyperspectral image classification[J]. *Neurocomputing*, 2017, 219: 88-98.
- [2] CHEN Y, JIANG H, LI C, et al. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(10): 6232-6251.
- [3] GOLDBERG Y. Neural network methods for natural language processing[J]. *Synthesis Lectures on Human Language Technologies*, 2017, 10(1): 25-30.
- [4] TANG C S, SUN J D, ZHANG Y D, et al. Multiple sclerosis identification by convolutional neural network with dropout and parametric ReLU[J]. *Journal of Computational Science*, 2018, 28: 1-10.
- [5] GE Y, ZHANG R, WANG X, et al. DeepFashion2: A versatile benchmark for detection, pose estimation, segmentation and re-identification of clothing images[C]//*Proceedings of Computer Vision and Pattern Recognition*. Berlin: Springer, 2019: 5337-5345.

- [6] KUEN J, LIU T, GU J X, et al. Recent advances in convolutional neural networks[J]. Pattern Recognition: The Journal of the Pattern Recognition Society, 2018, 77: 354-377.
- [7] 张永振,苏寒松,刘高华,等.基于BP神经网络的PID控制器参数调整[J].南开大学学报:自然科学版,2018,51(3):26-30.  
ZHANG Yongzhen, SU Hansong, LIU Gaohua, et al. Parameter adjustment of PID controller based on BP neural network[J]. Nankai Journal (Acta Scientiarum Naturalium Universitatis Nankaiensis), 2018, 51(3): 26-30.
- [8] HAN J, ZHANG T, REN D, et al. Communication emitter identification based on distribution of bispectrum amplitude and phase[J]. IET Science, Measurement & Technology, 2017, 11(8): 1104-1112.
- [9] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks[J]. Journal of Machine Learning Research, 2010, 9: 249-256.
- [10] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]//Proceedings of Computer Vision and Pattern Recognition. Boston, USA: [s.n.], 2015: 1-9.

作者简介:



曹阳(1989-),男,硕士研究生,研究方向:深度学习、信号处理,E-mail:gma**bj**@126.com。



王金明(1972-),男,副教授,研究方向:信号与信息处理、机器学习。



徐程骥(1990-),男,硕士,研究方向:智能电网。



岳振军(1963-),男,教授,研究方向:多媒体信息处理。



狄恩彪(1993-),男,硕士研究生,研究方向:图像处理。

(编辑:陈璐)