

9-23-2022

## Modulation Recognition Algorithm Based on Truncated Migration and Parallel ResNet

Yecai Guo

*1.School of Electronic and Information Engineering, Nanjing University of Information Science & Technology, Nanjing 210044, China;2.Jiangsu Collaborative Innovation Center on Atmospheric Environment and Equipment, Nanjing University of Information Science & Technology, Nanjing 210044, China,; guo-yecai@163.com*

Qingwei Wang

*1.School of Electronic and Information Engineering, Nanjing University of Information Science & Technology, Nanjing 210044, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# Modulation Recognition Algorithm Based on Truncated Migration and Parallel ResNet

## Abstract

**Abstract:** *A truncated migration data preprocessing algorithm is proposed for the problem of limited time series characteristics of the signal extracted by convolutional neural network. The distance unit at one end of the sampling matrix is truncated, migrated to the other end to form a new matrix, allowing the convolutional neural network to extract more sampling points and compare more symbolic information. An improved parallel ResNet is proposed, which focuses on features in both horizontal and vertical directions simultaneously by two parallel branches. The results show that the algorithm has an accuracy rate of about 10% higher than that of ordinary convolutional networks. When the signal-to-noise ratio is 14 dB, the improved network has an accuracy rate of 93.78% and when the signal-to-noise ratio is greater than 0 dB, the accuracy rate is above 91%.*

## Keywords

convolutional neural network, truncated migration, data preprocessing, parallel ResNet

## Recommended Citation

Yecai Guo, Qingwei Wang. Modulation Recognition Algorithm Based on Truncated Migration and Parallel ResNet[J]. Journal of System Simulation, 2022, 34(09): 2009-2018.

## 基于截断迁移与并行残差网络的调制识别算法

郭业才<sup>1,2</sup>, 王庆伟<sup>1</sup>(1. 南京信息工程大学 电子与信息工程学院, 江苏 南京 210044;  
2. 南京信息工程大学 江苏省大气环境与装备技术协同创新中心, 江苏 南京 210044)

**摘要:** 针对卷积神经网络提取的信号时序特征受限问题, 提出一种截断迁移的数据预处理算法, 将采样矩阵一端的距离单位截断, 迁移到另一端, 依次合并成新的矩阵, 使卷积神经网络提取到更多的采样点, 比较更多的符号信息。同时提出一种改进的并行残差神经网络, 通过两路并行的支路同时关注水平和垂直 2 个方向的特征。结果表明, 该算法比普通卷积网络提高约 10% 的准确率, 改进的网络在信噪比为 14 dB 时, 准确率为 93.78%, 信噪比大于 0 dB 时, 准确率均在 91% 以上。

**关键词:** 卷积神经网络; 截断迁移; 数据预处理; 并行残差神经网络

中图分类号: TP183; TP391      文献标志码: A      文章编号: 1004-731X (2022) 09-2009-10  
DOI: 10.16182/j.issn1004731x.joss.21-0282

## Modulation Recognition Algorithm Based on Truncated Migration and Parallel ResNet

Guo Yecai<sup>1,2</sup>, Wang Qingwei<sup>1</sup>(1. School of Electronic and Information Engineering, Nanjing University of Information Science & Technology, Nanjing 210044, China;  
2. Jiangsu Collaborative Innovation Center on Atmospheric Environment and Equipment, Nanjing University of Information Science & Technology, Nanjing 210044, China)

**Abstract:** A truncated migration data preprocessing algorithm is proposed for the problem of limited time series characteristics of the signal extracted by convolutional neural network. The distance unit at one end of the sampling matrix is truncated, migrated to the other end to form a new matrix, allowing the convolutional neural network to extract more sampling points and compare more symbolic information. An improved parallel ResNet is proposed, which focuses on features in both horizontal and vertical directions simultaneously by two parallel branches. The results show that the algorithm has an accuracy rate of about 10% higher than that of ordinary convolutional networks. When the signal-to-noise ratio is 14 dB, the improved network has an accuracy rate of 93.78% and when the signal-to-noise ratio is greater than 0 dB, the accuracy rate is above 91%.

**Keywords:** convolutional neural network; truncated migration; data preprocessing; parallel ResNet

## 引言

无线通信系统在信号处理领域的实际运行过程中, 调制识别是一项必不可少的关键技术。无线信号有多种调制类型, 自动调制识别(automatic modulation recognition, AMR)是指先验知识不充分或信号数据不多时, 通过对接收信号的处理和分

析, 最终判断出接收信号的调制类型, 从而为信号处理更好地提供信息。

调制识别在近几十年来引起人们广泛关注, 不少学者提出多种优秀的方法, 大致可以分为 3 类: ①基于似然(likelihood-based, LB)<sup>[1-3]</sup>的方法; ②基于特征(feature-based, FB)<sup>[4-6]</sup>的方法; ③基于深度学习(deep learning, DL)的方法。理论上, LB 方法对

收稿日期: 2021-04-02      修回日期: 2021-05-17

基金项目: 国家自然科学基金(61673222, 61371131); 江苏省高校自然科学研究重大项目(13KJA510001); 江苏高校品牌专业建设项目(PPZY2015B134)

第一作者: 郭业才(1962-), 男, 博士, 教授, 研究方向为通信信号处理、自适应盲均衡技术。E-mail: guo-yecai@163.com

算法的分析是完备的,但需要知道更多的先验知识。与 LB 方法相比,FB 方法在设计充分的情况下可以获得次优的性能和广泛的适用性,然而该方法很大程度上取决于信号特征的选择。随着大数据时代和计算机的强大功能的出现,DL 研究热潮随之而来,目前已广泛应用于调制识别。

文献[7]使用深度神经网络(deep neural network, DNN)和卷积神经网络(convolutional neural network, CNN)对原始同相正交信号进行训练,模型简单,但是难以区分高阶调制信号。文献[8]研究了神经网络结构的变化对识别精度的影响,在传统 CNN 层后引入一种新的神经网络,称为长短期记忆(long short term memory, LSTM)网络,记为卷积长短期深度神经网络(CLDNN),捕获信号的长期依赖性,取得较好的结果。文献[9]利用多个相关学习任务间的有用信息来提高性能,有效减少了相似分类之间的混淆,但由于只使用了 CNN 模型,总体识别精度并未大幅度提高。

上述研究证实 DL 已被广泛应用于 AMR,与传统的基于高度解释的特征算法不同,基于 DL 的分类器在端到端的方式上提供了模块化类别,作为“黑盒子”运行。文献[10]通过引入类激活向量,对不同的基于 DL 的调制分类器进行了可视化处理,结果表明,基于 DL 的分类器很大程度上取决于无线电信号携带的内容,短的无线电样本更可能导致分类错误。因此对数据进行适当的预处理有助于提高识别率。文献[11]通过自动编码器对信号去噪。文献[12]提出旋转、翻转和高斯噪声三种数据增强方法。文献[13]将信号转化成图像进行识别。文献[14]选用星座图输入 VGGNet 网络识别。文献[15]选用彩色星座图分别输入 ResNet50 和 Inception-ResNet-V2 网络识别信号。然而以上预处理的数据生成和存储的高成本增加了实际应用中的难度。

本文提出一种信号截断迁移算法,通过将采样矩阵一端的距离单位截断然后迁移到矩阵的另一端,依次类推,最后合并组成新的采样矩阵。另外,针对预处理后的采样矩阵的形状,设计了一种专门

的并行残差神经网络,通过两路并行支路同时提取水平和垂直 2 个方向的特征。最后对混淆信号进行了可视化分析。仿真实验表明,本文算法识别准确率优于普通 CNN 模型,改进的并行残差网络进一步提高了识别准确率。

## 1 信号模型

为了便于分析 AMR 任务,假设接收信号为

$$\mathbf{Y}(t) = \mathbf{H}(t) \otimes \mathbf{X}(t) + \mathbf{N}(t) \quad (1)$$

式中:  $\otimes$  为卷积运算;  $\mathbf{Y}(t)$  为接收信号;  $\mathbf{X}(t)$  为分类的目标(被调制的信号);  $\mathbf{H}(t)$  为信道脉冲效应;  $\mathbf{N}(t)$  为加性高斯白噪声。自动调制识别可以被解释为:仅通过接收信号  $\mathbf{Y}(t)$  来识别  $\mathbf{X}(t)$  的调制类型的方案。

信号采样矩阵  $\mathbf{Y}$  由接收信号  $\mathbf{Y}(t)$  的离散时间采样生成,表示为

$$\mathbf{Y} = [\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_l] \quad (2)$$

式中:  $l$  为采样点的个数;  $\mathbf{s}_l$  为采样矩阵  $\mathbf{Y}$  的第  $l$  个采样点。因为无线电信号样本由同相(in-phase, I)信号和正交(quadrature, Q)信号组成,所以  $\mathbf{s}_l$  可以表示为

$$\mathbf{s}_l = [I_l, Q_l]^T \quad (3)$$

式中:  $I_l$  和  $Q_l$  分别为样本点  $\mathbf{s}_l$  的实数值和虚数值,即采样点的 I/Q 分量。所以,采样矩阵  $\mathbf{Y}$  的形状为  $(2, l)$ 。在文献[7-8]中,通常把  $\mathbf{Y}$ (信号的 I/Q 分量组成的采样矩阵)作为基于 DL 的分类器的输入。

## 2 算法与网络设计

### 2.1 数据截断迁移算法

神经网络分类器利用采样点,即采样信号携带的内容进行分类。一般而言,信号的特征分布在信号的整个序列上。CNN 在 AMR 中应用最广泛,因此以 CNN 为例说明提出的数据截断迁移算法。

CNN 致力于提取输入信号的局部特征,这和感受野有关。一个神经元感受野之外的特征图,不会对神经元的值产生影响。文献[16]表明,尽管通过堆叠更多的卷积层和池化层可以增加感受野,但

并不是所有在感受野中的特征图对神经元具有相同贡献。换句话说, 感受野中间的特征图对输出有更大的影响。CNN 的本质是卷积算子, 它可以将局部感受野内的空间信息和通道信息融合在一起, 产生信息特征。卷积计算公式为

$$F = X \otimes K \quad (4)$$

式中:  $\otimes$  为卷积运算;  $X$  为输入;  $F$  为特征;  $K$  为卷积核,  $K \in \mathbb{R}^{k \times k}$ ,  $k$  表示卷积核的尺寸大小。特征单元  $F$  的感受野受卷积核  $K$  和  $X$  的限制。

由于 CNN 难以捕获长期的依赖关系(例如样本的 2 个端点), 只能将符号  $s_l$  与位于信号采样矩阵  $Y$  的少量  $s_l$  附近的符号进行比较, 浪费了大量  $s_l$  可以通过与其他符号进行比较来提取的特征。所以, 本文提出一种数据截断迁移算法, 让 CNN 比较更多的符号信息, 图 1 为本文提出的数据截断迁移算法过程。

数据截断迁移算法过程可描述为以下步骤:

步骤 1: 将采样矩阵  $Y$  形状重塑为  $(2, l, 1)$ , 2 为宽度,  $l$  为长度, 1 为通道维度。

步骤 2: 设置超参数  $S$ ,  $S$  为正整数, 代表一次截断要移动的距离单位。设置移动的次数为  $T$ 。

步骤 3: 将原采样矩阵  $Y_0$  的右端  $1 \times S$  的距离截断迁移到矩阵最左端, 其余不变, 组成采样矩阵  $Y_1$ ; 为了特征的多样性, 第二次将  $Y_1$  的右端  $2 \times S$  的距离截断迁移到它的最左端, 其余不变, 组成采样矩阵  $Y_2$ ; 如图 2 所示, 依次类推, 移动  $T$  次, 组成采样矩阵  $Y_T$ 。

步骤 4: 移动  $T$  次, 若满足式(5), 则返回步骤 3。若不满足, 则执行步骤 5。

$$\frac{T \times (T+1) \times S}{2} < l \quad (5)$$

步骤 5: 将采样矩阵  $Y_0$  到  $Y_T$  通过“Concatenate”合并组成新的采样矩阵  $Y_{IQ}$ 。“Concatenate”为特征相连的方式, 在表达式中用  $\oplus$  表示, 如式(6)所示:

$$X \oplus Y = \sum_{i=1}^c X_i \otimes K_i + \sum_{i=1}^c Y_i \otimes K_{i+c} \quad (6)$$

式中:  $X$  和  $Y$  分别为 2 个不同的特征;  $c$  为特征的

通道数, 且  $i \in c$ ;  $K_i, K_{i+c}$  为卷积核;  $\otimes$  为卷积。




图 1 数据截断迁移算法过程

Fig. 1 Process of data truncated migration algorithm




图 2  $Y_0, Y_1$  和  $Y_2$  的截断迁移算法过程

Fig. 2 Truncated migration algorithm process of  $Y_0, Y_1$  and  $Y_2$

$Y_0$  到  $Y_T$  在宽度维度上合并, 此时,  $Y_{IQ}$  形状大小为  $(2T+2, l, 1)$ ,  $Y_{IQ}$  可以表示为

$$Y_{IQ} = Y_0 \oplus Y_1 \oplus \dots \oplus Y_T \quad (7)$$

根据图2可知,  $Y_0$  和  $Y_1$  合并使  $\{s_l\}, l \in [1, S]$  在水平方向上接近  $\{s_l\}, l \in [l-S+1, l]$ , 在垂直方向上更接近  $\{s_l\}, l \in [S, 2S]$ , 如红色椭圆所在的区域所示;  $Y_1$  和  $Y_2$  合并使  $\{s_l\}, l \in [S, 3S]$  在水平方向上接近  $\{s_l\}, l \in [1, S]$  和  $\{s_l\}, l \in [l-S-1, l]$ , 在垂直方向上更接近  $\{s_l\}, l \in [3S, 5S]$ , 如绿色椭圆所在的区域所示。依次类推, 根据式(7)合并成新的采样矩阵  $Y_{IQ}$ 。

步骤6: 将所有采样矩阵  $Y_{IQ}$  的 I/Q 分量按照式(8)转换成由幅度(amplitude, A)相位(phase, P)分量组成的采样矩阵  $Y_{AP}$ 。

$$A = \sqrt{I^2 + Q^2} \quad (8)$$

$$P = \arctan(I/Q)$$

步骤7: 将  $Y_{IQ}$  与  $Y_{AP}$  通过“Concatenate”在通道维度上合并组成新的矩阵  $Y'$ , 作为分类器的输入, 可以表示为

$$Y' = Y_{IQ} \oplus Y_{AP} \quad (9)$$

为了进一步增强提取的特征, 步骤6和步骤7将转换结果以极坐标的形式添加到信号采样矩阵中。虽然 I/Q 分量间接代表了极坐标, 通过将 I/Q 分量转换为 A/P 分量, 能够表示角度和距离, DL 可以直接访问它们的角度和距离值。最终经过数据截断迁移算法的采样矩阵  $Y'$  形状为  $(2T+2, l, 2)$ 。

文献[17]表明, 对于调制识别来说, 识别准确率最高的 CNN 模型有4层卷积层, 卷积滤波器的个数依次为 256, 256, 80, 80, 滤波器的大小分别为 (1, 3), (2, 3), (1, 3), (1, 3), 除最后一层采用 Softmax 激活函数外, 其余层采用 ReLU 函数, 如图3所示。它的输入是没有经过预处理的采样矩阵  $Y$ , 卷积层步长全部设置为(1, 1), 本文把此 CNN 模型作为对比实验的基线模型, 记为 CNN4。

为了适应经过数据截断迁移算法之后的采样矩阵, 对 CNN4 模型进行了调整, 记为 CNN4-1, 如图4所示。在第2个和第4个卷积层后面添加了 MaxPooling 层, 保留主要特征的同时减少参数和

计算量。同时调整了卷积层滤波器的尺寸, 设置为: (4, 4), (3, 3), (3, 3), (3, 3)。除了卷积层1的步长设置为(2, 1), 其他卷积层步长全部设置为(1, 1)。另外, 最重要的是, 将经过预处理后的采样矩阵  $Y'$  作为 CNN4-1 模型的输入。




图3 CNN4 的结构  
Fig. 3 Structure of CNN4




图4 CNN4-1 的结构  
Fig. 4 Structure of CNN4-1

为了验证正确率的提高不是因为模型的微调, 而是数据的预处理, 所以构造模型 CNN4-2 和 CNN4 进行对比, 2 个模型都输入没有经过预处理的采样矩阵  $Y$ 。由于输入形状的尺寸问题, 导致 CNN4-2 与 CNN4-1 并不能完全一样, 第一层卷积层滤波器的大小为(1, 4), 其余层与 CNN4-1 的设置相同, 卷积层的步长全部设置为(1, 1)。CNN4-2 与 CNN4-1 的结构客观来说是一致的, 只是输入矩阵不同。

## 2.2 改进的并行残差神经网络

在深层网络中存在梯度消失或梯度爆炸问题, 归一化在很大程度上解决了这一问题, 然而, 训练深层网络时也会出现退化, 残差神经网络引入“捷径连接”解决了这一问题。根据经过预处理的采样矩阵的形状, 本文提出一种具有并行结构的残差网络, 图5为提出的网络结构, 因为经过预处理后的

采样点的排列不再是连续的, 而是在空间矩阵上, 不仅在水平方向上有关而且在垂直上也有关。因

此, 设计并行的卷积层, 同时关注水平和垂直 2 个方向的特征。




图 5 并行残差网络结构  
Fig. 5 Structure of parallel ResNet

卷积层的滤波器分别设置为较宽的形状(2, 8)提取水平方向特征和较窄的形状(4, 4)提取垂直方向的特征。另外对残差块进行了改进, 普通残差块结构只有单层卷积层连接, 而改进的残差块如图 6 所示, 采用两支路并行输入的卷积层连接, 借鉴了 Inception 网络, 将网络做的更宽。同样将卷积层滤波器的形状设置为(2, 8)和(4, 4)。本文改进的并行残差神经网络(Parallel ResNet), 记为 PResNet。

集下载链接: <https://www.deepsig.ai/datasets>。考虑了频率、相位和采样率偏移, 多径衰减, 加性高斯白噪声等多种信道效应。具体来说, 此数据集共有 22 万个已调制的信号, 属于 11 种不同的调制类型, 包括 8 个数字调制类别(BPSK, QPSK, 8PSK, QAM16, QAM64, CPFSK, GFSK, 4PAM)和 3 个模拟调制类别(AM-DSB, AM-SSB, WBFM)。共有 20 个不同的信噪比(SNR), 范围为-20~18 dB, 步长为 2 dB。即单种调制方式的一种 SNR 下有 1 000 个信号样本。每个信号样本均由 128 个同相(I)信号和正交(Q)信号组成, 所以信号样本的尺寸为(2, 128)。

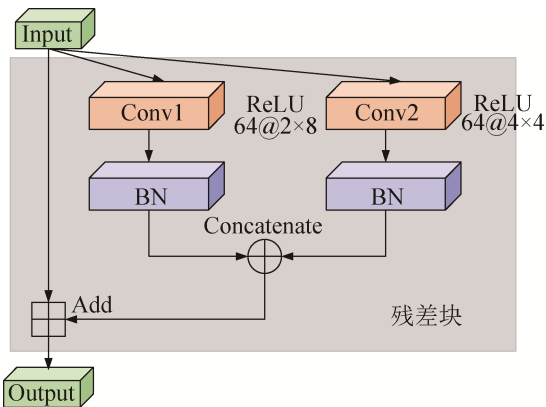


图 6 改进的残差块结构  
Fig. 6 Improved residual block structure

### 3.1.2 训练参数

网络训练参数包括训练集大小、优化器选择、学习率大小、早停机制设置等。在前人工作经验基础上, 首先分配不同数量的训练集来评估模型, 表 1 为不同训练数量下的识别性能。

## 3 实验与结果分析

### 3.1 实验设置

#### 3.1.1 数据集

本文采用的数据集为 RadioML2016.10A。数据

表 1 不同训练数量下的识别性能

Table 1 Recognition performance under different training numbers

训练集: 测试集	平均 准确率/%	验证损失值	迭代一次 所需时间/s
5: 5	61.81	1.08	177
6: 4	62.40	1.06	205
7: 3	63.48	1.03	228
8: 2	63.67	1.02	236



表 1 表明,使用的训练数量越多,训练的性能越好,但训练数据数量增加到一定程度后,对模型的识别性能的提升效果会减小。因此从性能保证和复杂度的角度考虑,选取 7:3 的比例划分数据集。

其次,对于迭代次数、批尺寸大小、学习率和丢弃率的参数选择采用随机搜索的自动选择方法。迭代次数为 100 次,批尺寸大小为 512,优化器为自适应矩估计,学习率默认 0.001;采用了随机失活理论,丢弃率为 0.5。

最后,在训练网络时,为防止过拟合还加入了早停机制,不同耐心值的结果如表 2 所示。

表 2 不同耐心值下的识别性能  
Table 2 Recognition performance under different patience values

耐心值	平均识别率/%	最终损失值	最终验证损失值	迭代次数
5	62.19	1.04	1.07	36
10	63.08	1.01	1.05	58
15	63.48	1.00	1.03	64
20	63.14	0.98	1.07	93

表 2 表明,当监测值验证损失的误差超过耐心值时停止训练,耐心值为 15 时,平均识别率最高,共训练 64 次,并且没有过拟合;当耐心值为 20 时,会出现过拟合现象。因此选择耐心值为 15。

所有实验都使用 Tensorflow 作为后端, Keras 库搭建神经网络训练,性能在配备 3.79 GHz CPU, 32 GB RAM 和单个 NVIDIA GeForce RTX 2070 SUPER GPU 的系统上测得。

表 3 不同超参数  $S$  在 CNN4-1 模型下的结果  
Table 3 Results of different hyperparameters  $S$  in CNN4-1 model

超参数	最大识别准确率/%	平均识别准确率/%	输入形状	一次迭代时间/s
$S=1$	91.78	61.50	(32,128,2)	116
$S=2$	91.69	61.46	(22,128,2)	86
$S=3$	<b>91.91</b>	<b>61.53</b>	(18,128,2)	60
$S=4$	91.35	61.03	(16,128,2)	55
$S=5$	90.12	60.22	(14,128,2)	53
$S=6$	88.67	58.60	(12,128,2)	50

## 3.2 结果分析

### 3.2.1 数据截断迁移算法的结果

本节将 CNN4、CNN4-1 和 CNN4-2 的结果进行比较,找到最合适的超参数  $S$ 。表 3 展示了在 CNN4-1 模型下不同超参数的结果。表 3 表明,  $S=3$  时,平均识别率和最大识别率都最高。因此选择  $S=3$ 。  $l=128$ ,根据式(5),得  $T=8$ ,因此输入形状为  $(2T+2, l, 2)$ ,即(18, 128, 2)。  $S$  值越小,样本量越大,则每个样本一次迭代计算时间也变长。  $S=3$  时,一次迭代时间大概 60 s,在接受范围之内。

图 7 为 CNN4 系列的识别准确率,其中, CNN4-1 是在  $S=3$  下的结果。图 7 表明,经过数据截断迁移算法后,准确率得到了显著提高,尤其在  $SNR > -6$  dB 以后,最高识别准确率为 91.91%。比较 CNN4 和 CNN4-2,可以看出准确率几乎相同。因此, CNN4-1 准确率的提高不是由于模型结构微调造成的,而是数据预处理的结果。这也验证了本文提出的数据截断迁移算法的有效性。

### 3.2.2 改进的并行残差网络的结果

本文将 PResNet 与 5 个最新模型(ResNet<sup>[8]</sup>、CLDNN<sup>[8]</sup>、Inception<sup>[18]</sup>、LSTM<sup>[19]</sup>、MCLDNN<sup>[20]</sup>)进行识别准确率比较。为了有统一的标准,所有模型都按照 3.1 节介绍的实验设置进行仿真。由于电脑硬件配置和超参数设置的不同等原因,可能本文的结果和原作者的结果有差异。图 8 为 6 种模型在每个信噪比下的准确率。表 4 详细记录了不同模型的仿真结果, PResNet 模型识别率最高。



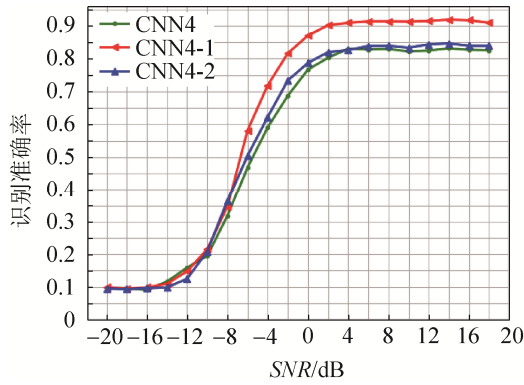


图 7 CNN4、CNN4-1 和 CNN4-2 的识别准确率  
Fig. 7 Recognition accuracy of CNN4, CNN4-1 and CNN4-2

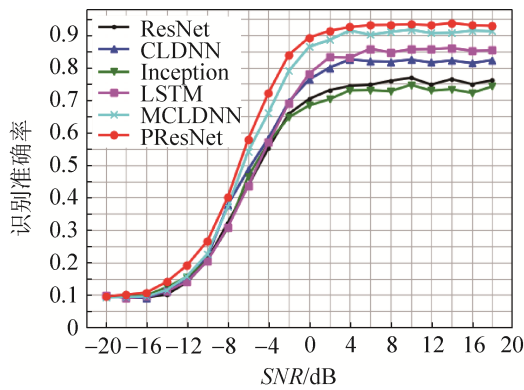


图 8 不同模型的识别准确率  
Fig. 8 Recognition accuracy of different models

表 4 不同模型的具体仿真结果

Table 4 Specific simulation results of different models %

模型	最高准确率	平均准确率
ResNet	76.87	50.86
CLDNN	82.44	55.12
Inception	74.70	50.06
LSTM	86.07	55.87
MCLDNN	91.64	60.88
PResNet	<b>93.78</b>	<b>63.48</b>

图 8 表明, 6 种模型的识别性能都随着信噪比的增加而提高。LSTM 输入为信号的 A/P 分量, 提取到更多的时序特征, 但空间特征提取不充分, 最高准确率为 86.07%。CLDNN 是 CNN、LSTM 和 DNN 的结合, 能够提取空间和时序特征, 但是中间的 LSTM 层没有充分挖掘相邻时域信号之间的连接, 因为之前卷积层的局部连接可能会破坏信号的依赖性, 最高准确率为 82.44%。MCLDNN 对

CLDNN 做了改进, 通过 I 通道、Q 通道和 I/Q 通道使用卷积层分别提取信号的特征。另外, 采用 CuDNNLSTM 代替 LSTM 层, 在提取时序特征同时利用 GPU 加速, 最高准确率为 91.64%。相比简单的 ResNet 和 Inception 结构, 本文改进的 PResNet 输入为预处理后的矩阵  $Y_D'$ , 最高准确率为 93.78%。

通过 FLOPs(floating-point operations per second) 和参数个数进一步评价本文模型。FLOPs 衡量算法复杂度, 描述所需计算力; 参数个数描述所需内存。表 4 表明经过预处理之后, 大大提高了识别准确率。将 PResNet 与经过预处理之后的文献进行比较 FLOPs 和参数个数, 结果如表 5 所示。表 5 表明, 与其他预处理方法相比, PResNet 的所需计算力最小, 参数个数也仅次于 ResNet50 模型, 易于实现。

表 5 不同模型的 FLOPs 和参数个数比较

Table 5 Comparison of FLOPs and the number of parameters of different models

模型	FLOPs	参数个数
PResNet	1.71G	31 719 179
ResNet152 <sup>[13]</sup>	22.6G	60 419 944
VGGNet <sup>[14]</sup>	18.2G	93 337 594
ResNet50 <sup>[15]</sup>	7.76G	25 636 712
Inception-ResNet-V2 <sup>[15]</sup>	26.4G	55 873 736

图 9 为 SNR=14 dB 时, PResNet 模型的混淆矩阵, 每一列代表预测类型, 每一行代表真实类型。对角线上颜色越深则代表识别准确率越高。




图 9 PResNet 模型在 SNR=14 dB 时的混淆矩阵  
Fig. 9 Confusion matrix of PResNet model at SNR=14 dB

图9表明,16正交幅相调制(QAM16)和64正交幅相调制(QAM64)信号之间存在混淆现象,这是因为QAM16的星座点包含在QAM64中。本文在很大程度上提高了这两者之间的准确率。宽带频率调制(WBFM)和双边带调幅(AM-DSB)信号之间也存在混淆现象,这是因为数据集是根据真实的语音信号提取的,人的声音在说话时有静默期,只留下载波,导致信号不存在,因此,WBFM信号很容易被误分类为AM-DSB信号。除了这两组易混淆的信号以外,由混淆矩阵可以看出,其他信号的颜色很深,识别准确率很高。

### 3.2.3 混淆信号可视化的结果

图10为SNR分别为-20、-10、0、18 dB时信号星座图。

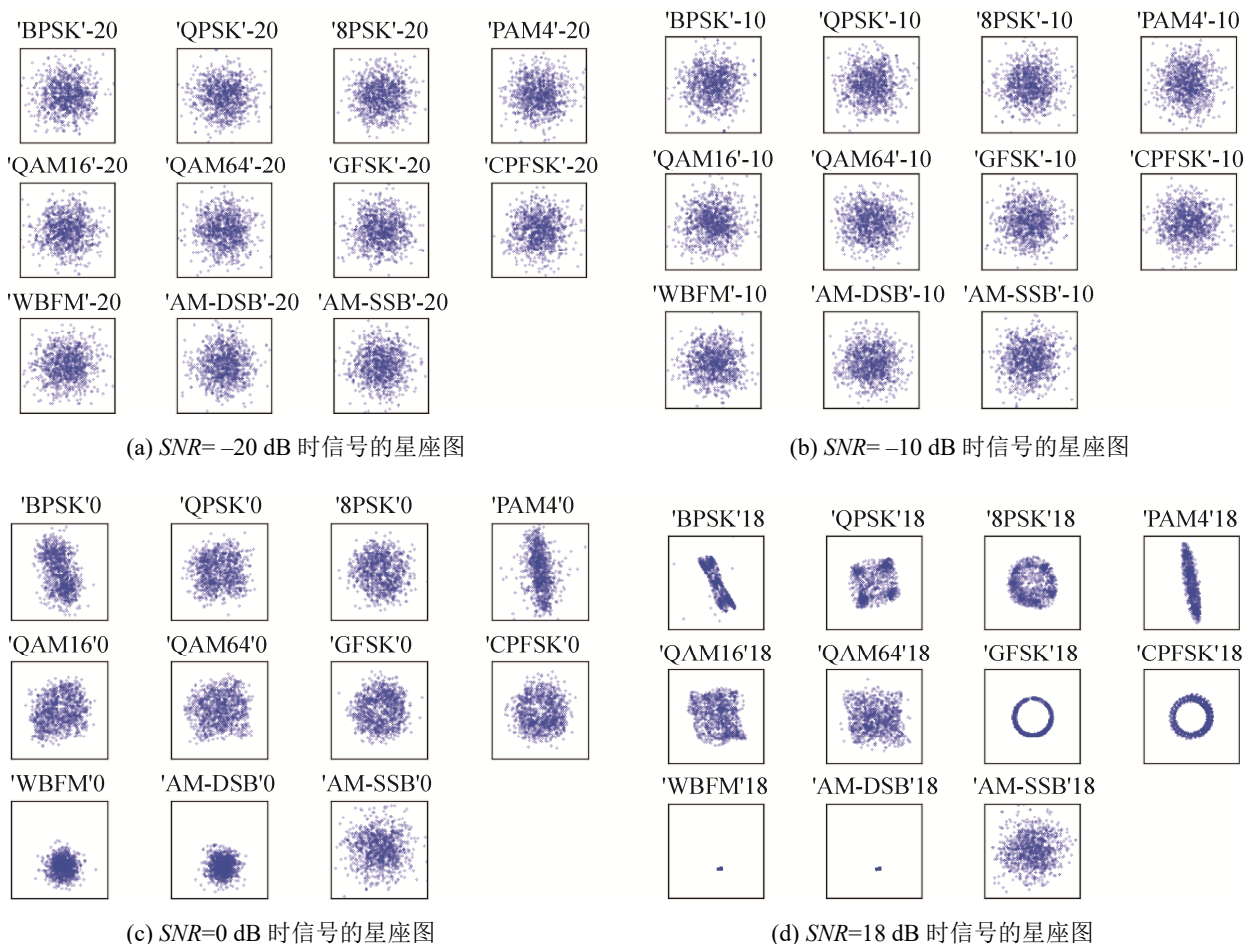


图10 信号的星座图

Fig. 10 Constellation diagram of signals

图10(a)、10(b)表明,当SNR<0 dB时,星座图无法用肉眼分辨,那么用深度学习在低信噪比下的识别率也会降低。图10(c)、10(d)表明,高SNR下的星座图区分度更高,则识别率也更好。这和图8的结论是一致的。另外观察到QAM16和QAM64的星座图很相似,即使在高信噪比(SNR=18 dB)下,相似度也很高,确实很难分辨。最后观察WBFM和AM-DSB两种信号,SNR=18 dB时,在星座图中似乎是错误的,因为它们看起来只是点。这也和数据集中有简短的无声周期,信号不存在的结论是一致的。因此,在使用RadioML2016.10A的数据集的论文中经常会遇到这两组信号的混淆问题,并且随着信噪比的降低,两组信号之间的混淆会更加明显。

## 4 结论

深度学习在无线通信领域为调制识别做出了巨大贡献, 本文提出一种数据截断迁移算法, 通过将采样矩阵一端的距离截断然后迁移到另一端, 依次类推, 合并成新的采样矩阵, 让分类器比较更多的符号信息, 进一步探索无线信号的特征。该算法识别准确率比普通 CNN 模型提高约 10%。本文还提出一种改进的并行残差网络结构, 利用两路并行卷积层构造残差块, 同时关注水平和垂直 2 个方向的特征。仿真结果表明, PResNet 模型进一步提高了识别准确率。具体来说, 最高识别准确率达到 93.78%, 对比 ResNet、CLDNN、Inception、LSTM、MCLDNN 模型, 分别提高 18.03%、12.09%、20.35%、8.22%、2.28%, 平均识别准确率为 63.48%, 当  $SNR > 0$  dB 时, 识别准确率均在 91% 以上。该算法的提出可为后续开展 CNN 提取特征信号受限问题的研究提供帮助。

### 参考文献:

- [1] Zhu D, Mathews V J, Detienne D H. A Likelihood-Based Algorithm for Blind Identification of QAM and PSK Signals[J]. IEEE Transactions on Wireless Communications (S1536-1276), 2018, 17(5): 3417-3430.
- [2] Chen W, Xie Z, Ma L, et al. A Faster Maximum Likelihood Modulation Classification in Flat Fading Non-gaussian Channels[J]. IEEE Communications Letters (S1089-7798), 2019, 23(3): 454-457.
- [3] Ramezani-Kebrya A, Kim I M, Kim D I, et al. Likelihood-Based Modulation Classification for Multiple-antenna Receiver[J]. IEEE Transactions on Communications (S0090-6778), 2013, 61(9): 3816-3829.
- [4] Teng C F, Liao C C, Chen C H, et al. Polar Feature Based Deep Architectures for Automatic Modulation Classification Considering Channel Fading[C]// 2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP). Anaheim, California, USA: IEEE, 2018: 554-558.
- [5] Zhang Z, Zhong H, Liu Y. Modulation Classification in Multipath Fading Channels Using Sixth-order Cumulants and Stacked Convolutional Auto-encoders[J]. Iet Communications (S1751-8628), 2017, 11(6): 910-915.
- [6] Wang Y, Liu M, Yang J, et al. Data-driven Deep Learning for Automatic Modulation Recognition in Cognitive Radios[J]. IEEE Transactions on Vehicular Technology (S0018-9545), 2019, 68(4): 4074-4077.
- [7] O'Shea T J, Corgan J, Clancy T C. Convolutional Radio Modulation Recognition Networks[C]// International Conference on Engineering Applications of Neural Networks. Aberdeen, Scotland, UK: Springer, 2016: 213-226.
- [8] Liu X, Yang D, Gamal A E. Deep Neural Network Architectures for Modulation Classification[C]// 2017 51st Asilomar Conference on Signals, Systems, and Computers. Pacific Grove, California, USA: IEEE, 2017: 915-919.
- [9] Mossad S, ElNainay M, Toriki M. Deep Convolutional Neural Network with Multi-task Learning Scheme for Modulations Recognition[C]// 2019 15th International Wireless Communications & Mobile Computing Conference (IWCMC). Tangier, Morocco: IEEE, 2019: 1644-1649.
- [10] Huang L, Zhang Y, Pan W, et al. Visualizing Deep Learning-based Radio Modulation Classifier[J]. IEEE Transactions on Cognitive Communications and Networking (S2332-7731), 2020, 7(1): 47-58.
- [11] Wang J, Wang W, Luo F, et al. Modulation Classification Based on Denoising Autoencoder and Convolutional Neural Network with GNU Radio[J]. The Journal of Engineering (S2051-3305), 2019(19): 6188-6191.
- [12] Huang L, Pan W, Zhang Y, et al. Data Augmentation for Deep Learning-based Radio Modulation Classification[J]. IEEE Access (S2169-3536), 2019, 8: 1498-1506.
- [13] Zhang Z, Wang C, Gan C, et al. Automatic Modulation Classification Using Convolutional Neural Network with Features Fusion of SPWVD and BJD[J]. IEEE Transactions on Signal & Information Processing Over Networks (S2373-776X), 2019, 5(3): 469-478.
- [14] 张清. 机器学习在通信信号调制识别中的应用研究[D]. 南京: 南京邮电大学, 2020.
- [15] Zhang Qing. Research on Applications of Machine Learning in Modulation Recognition of Communication Signals[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2020.
- [16] Kumar Y, Sheoran M, Jajoo G, et al. Automatic Modulation Classification Based on Constellation Density using Deep Learning[J]. IEEE Communications Letters (S1558-2558), 2020, 24(6): 1275-1278.
- [17] Luo W, Li Y, Urtasun R, et al. Understanding the

- Effective Receptive Field in Deep Convolutional Neural Networks[C]// 30th International Conference on Neural Information Processing Systems (NIPS'16). Barcelona: Curran Associates Inc, 2017: 4905-4913.
- [17] Emam A, Shalaby M, Aboelazm M A, et al. A Comparative Study between CNN, LSTM, and CLDNN Models in The Context of Radio Modulation Classification[C]// 2020 12th International Conference on Electrical Engineering (ICEENG). Cairo, Egypt: IEEE, 2020: 190-195.
- [18] West N E, O'Shea T J. Deep Architectures for Modulation Recognition[C]// 2017 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN). Baltimore, Maryland, USA: IEEE, 2017: 1-6.
- [19] Rajendran S, Meert W, Giustiniano D, et al. Deep Learning Models for Wireless Signal Classification with Distributed Low-cost Spectrum Sensors[J]. IEEE Transactions on Cognitive Communications and Networking (S2332-7731), 2018, 4(3): 433-445.
- [20] Xu J, Luo C, Parr G, et al. A Spatiotemporal Multi-channel Learning Framework for Automatic Modulation Recognition[J]. IEEE Wireless Communication Letters (S2162-2337), 2020, 9(10): 1629-1632.