



研究与开发

基于时序深度残差收缩网络的混叠信号调制识别方法

刘京华¹, 魏祥麟², 范建华², 胡永扬², 王晓波², 于兵¹

(1. 南京信息工程大学电子与信息工程学院, 江苏 南京 210044;

2. 国防科技大学第六十三研究所, 江苏 南京 210007)

摘要: 基于深度学习进行信号自动调制识别在分类精度、可迁移性等方面普遍优于传统方法, 引起广泛关注。但是, 当前方法多数针对单信号样本进行识别, 无法适用于混叠信号识别场景。针对该问题, 对混叠信号调制识别方法进行了研究, 结合长短期记忆 (long short term memory, LSTM) 网络和深度残差收缩网络 (deep residual shrinkage network, DRSN), 设计了时序深度残差收缩网络模型, 其中包含残差模块、收缩模块和 LSTM 模块。残差模块和收缩模块负责提取混叠信号中的显著信息并自适应生成决策阈值, LSTM 模块用于提取混叠信号中的时序隐含特征。三者结合可以有效提高混叠信号的识别精度。公开和实测数据集测试结果表明, 所提方法识别精度优于 5 种典型方法, 在高信噪比下的平均识别分类准确率可以达到 92.7%; 21 种混叠信号中有 12 种识别准确率接近 100%。

关键词: 调制识别; 混叠信号; 深度残差收缩网络; 深度学习

中图分类号: TN929.5

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2024207

Mixed signal modulation recognition method based on temporal depth residual shrinkage network

LIU Jinghua¹, WEI Xianglin², FAN Jianhua², HU Yongyang², WANG Xiaobo², YU Bing¹

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

2. The 63rd Research Institute, National University of Defense Technology, Nanjing 210007, China

Abstract: Deep learning-based automatic signal modulation recognition has generally outperformed traditional methods in terms of classification accuracy and transferability, garnering widespread attention. However, most existing methods are designed to recognize single signal samples and are not applicable to recognize scenarios involving overlapping signals. To address this limitation, a modulation recognition method for aliased signals was investigated and a temporal deep residual shrinkage network model by integrating LSTM and DRSN was developed. There were three key modules in the model: a residual module, a shrinkage module, and a LSTM module. Salient information from overlapping signals was extracted by the residual module and the shrinkage module and decision thresholds were

收稿日期: 2024-04-24; 修回日期: 2024-06-14

通信作者: 魏祥麟, wei_xianglin@163.com



adaptively generated, while the LSTM module is tasked with extracting temporal hidden signals within the aliased data. The recognition accuracy of aliased signals was enhanced by the combination of these modules significantly. Testing on both public and private datasets demonstrates that the proposed method outperforms five state-of-the-art approaches, achieving an average recognition and classification accuracy of 92.7% under high signal-to-noise ratio conditions. Notably, the recognition accuracy for 12 out of 21 types of aliased signals approaches 100%.

Key words: modulation recognition, mixed signal, deep residual fast shrinking network, deep learning

0 引言

信号调制方式识别是感知和理解复杂电磁环境的重要前提和基础。当前,面向单个调制信号的识别方法可以分为3类。第一类是基于判决理论的调制识别方法,该方法对先验信息要求较高,需要人为设置门限^[1];第二类是基于统计模式的调制识别方法,首先采用瞬时统计特征^[2]、高阶累积量^[3]、循环平稳特征^[4]和小波变换等方法提取信号特征,然后基于决策树、支持向量机等技术设计分类器,对调制信号进行分类识别^[5];第三类是基于深度学习进行调制方式识别。这类方法将分类问题转化为多层非线性问题,利用深度神经网络结构自动提取信号特征,显著降低了人工参与程度,在识别精度和可迁移性方面优于前两类方法^[6-8]。

然而,在日益复杂和拥挤的电磁环境下,同一信道中出现两个或更多信号日益普遍。尤其是带有调制信息的干扰信号,会对原有通信信号进行干扰和覆盖,使接收端接收到的信号为时频混叠信号。在此场景下,传统针对单信号的调制识别方法无法适用。为了从混叠接收信号中获取目标信号携带的调制信息,有两种可行的思路。一种是分离识别方法,该方法首先从接收信号中分离目标信号,然后进行识别。但是该方法计算复杂度高,并且信号分离的效果对识别结果有直接影响,适用信号解析场景。第二种是直接识别方法,该方法直接判别接收信号中的信号成分,无须显式进行信号分离,复杂度较低,适用于信号感知场景,也是本文关注的重点。

混叠信号识别的挑战主要包括两个方面。一方面,基于深度学习的单信号调制识别是一种单标签学习,阈值设置相对简单,然而混叠信号通常建模为多标签学习问题,传统阈值确定方法难以适用;另一方面,混叠信号调制方式存在相互干扰和重叠,现有的单信号调制识别模型特征提取能力不足,需要设计新的识别模型来提取混叠信号的有效特征。

为此,本文设计了一种时序深度残差收缩网络模型,并根据该模型提出了一种混叠信号自动调制识别方法。本文主要工作和贡献包括如下两个方面。

(1) 本文设计了一种时序深度残差收缩网络模型,并提出了基于该模型的混叠信号调制识别方法。模型主要包括残差模块、收缩模块和LSTM模块。残差模块通过残差连接和恒等映射,有效缓解了深度神经网络在训练过程中的梯度消失和模型退化问题,使模型能更好地处理复杂的非线性关系,提高混叠信号识别的准确率;收缩模块通过引入软阈值化作为非线性层,自适应生成决策阈值,增强对关键特征的提取能力和降噪能力;LSTM模块用于增强模型对时序数据的特征提取能力,从而提升识别准确率。

(2) 为了验证模型的性能,本文采用RadioML2018.01a公开数据集和基于软件无线电收集的实测数据集进行对比实验。结果显示,在公开数据集上,所设计方法在信噪比16 dB时的识别准确率可以达到92.7%,显著优于5种现有方法,并且21种混叠信号中有12种的识别准确率可以达到或接近100%。实测数据集上在信噪比15 dB时的识别率高达95.53%。

1 相关工作

针对混叠信号识别, 文献[9]提出了一种预分类式网络, 引入自编码器 (Auto-encoder) 和注意力机制 (Attention), 改进了传统的稠密连接网络 (DenseNet), 实现了对分量信号两两混合的 21 种混叠信号调制方式的识别, 并验证了预分类结构对识别信号的促进作用。文献[10]提出了一种用于多个混叠源的调制分类框架, 然后通过最大化提取的累积量的似然函数, 利用多累积量分类方法进行识别分类。文献[11]提出了一种基于循环谱截面和深度学习相结合的智能识别方法。利用提出的非线性分段映射和指向性伪聚类新方法对截面图进行预处理特征增强, 提高了截面特征的适应性和一致性。并将预处理后的特征图与经典残差网络相结合, 利用深度学习网络对特征图中调制信息的深层次细节挖掘分析能力, 实现了混合信号的有效识别。

现有基于卷积神经网络 (convolutional neural network, CNN) 的单信号调制分类模型, 文献[12]对其进行了改进, 并应用于混叠信号分类。文献[13]提出了一种结合复值卷积神经网络和干扰类别表示的端到端多标签分类框架, 用于自动识别复合干扰信号中的干扰信号分量。文献[14]基于卷积神经网络对 5 种调制类型混叠的 31 种信号进行识别分类, 具有较强的鲁棒性, 预处理仅需要采样和量化, 但是混叠信号必须是不同调制类型的信号。文献[15]提出了一种基于 MIML-DCNN (multi-instance multi-label deep convolutional neural network) 算法的新型多实例多标签学习框架, 框架以端到端的方式处理信号, 证明了混叠信号情况下可以准确识别信号调制类型。文献[16]改进了重叠低截获波形识别任务处理框架, 将注意力机制添加到分类器中, 结合强大的表示能力和多样化的实例表示提高识别性能。针对 MIML 的重叠信号波形识别问题, 文献[17]使

用对抗学习近似训练数据的分布, 并通过自适应阈值校准从 MIML 鉴别器上进行类别预测。文献[18]对现有混叠信号识别方法适应性差的问题, 提出了一种基于循环频谱投影和深度神经网络的混叠信号识别方法, 采用了一种新的非线性分段映射和有向伪聚类方法对灰度图像进行增强, 降低了能量比和符号速率对信号识别的影响。

总体来看, 当前工业界已经针对混叠信号识别进行了一些探索, 但仍然存在两个问题: 一是模型特征提取能力不足, 识别精度有待提升; 二是模型大多在生成数据集上测试, 缺乏公开数据集验证。

2 问题描述

在复杂的电磁环境中, 发射机发出的不同调制类型的信号在时频域上可能会发生混叠。对于线性混叠情况, 在接收机内, 有 k 个独立的窄带信号进入接收机的带宽范围, 这些信号彼此独立, 每个信号在一段时间内可以被完全接收。此外, 噪声对接收信号也存在一定影响。时频混叠信号表示如式 (1) 所示。

$$s(t) = \sum_{i=1}^k s_i(t) + n(t), i = 1, 2, \dots, k \quad (1)$$

其中, $s_i(t)$ 为调制信号, $n(t)$ 为平稳的加性高斯白噪声, 并且调制信号与噪声相互统计独立。 $s_i(t)$ 表示为:

$$s_i(t) = \sum_{n=1}^N \sqrt{E_i} a_i(n) q_i(t - nT_i) e^{(j2\pi f_i + \phi_i)} \quad (2)$$

其中, N 为码元个数, E_i 为独立调制信号的功率, $a_i(n)$ 为信息码元序列, $q_i(t - nT_i)$ 为成形脉冲, T_i 为码元周期, f_i 为各个调制信号的载波频率, ϕ_i 为载波初相。

本文主要研究双信号混叠时的调制识别, 因此相加混叠的信号模型表示为:

$$s(t) = s_1(t) + s_2(t) + n(t) \quad (3)$$



基于深度学习的混叠信号自动调制识别是从大量混叠信号样本中,通过CNN、LSTM等网络提取多层次多方面的混叠信号特征。然后,提取的特征被进一步输入全连接层,用于特征融合,进而完成分类。特征提取或者特征学习本质上是

$$f: s_i \in S^{N \times 2} \rightarrow \hat{x}_i \in S^L \quad (4)$$

$$I = I_a + I_b \quad (5)$$

期望模型H可以将给定混叠信号的输入正确映射到混叠信号标签I, I_a 和 I_b 分别表示单信号的标签。那么H的设计目标为:最小化模型预测 $\hat{y} = f(x)$ (具体预测过程如式(4)所示)与真实标签y之间的损失 $J(X, Y, W)$ (计算过程如式(6)),获得最终模型权重W。优化过程如式(7)所示。


$$J(X, Y, W) = \frac{1}{N} L(x_i, y_i, W) \quad (6)$$

$$\arg \min J(X, Y, W) \quad (7)$$

其中, $L(x_i, y_i, W)$ 表示计算每一个样本与预测样本的损失。

3 模型与方法设计

本文设计的时序深度残差收缩网络(LSTM deep residual shrinkage network, LDRSN)模型结构如图1所示,主要包含3个模块:残差模块、收缩模块、LSTM模块。残差模块设计了一层二维卷积,输入大小为 $1024 \times 2 \times 1$,然后经过两个残差网络提取混叠信号特征,每个残差网络设计两层二维卷积,卷积核大小设为(8, 2),数量为40个,通过残差模块后的输出为 $1024 \times 2 \times 40$ 。混叠信号通过残差模块处理后进入收缩模块进一步提升对混叠信号的特征学习,对提取的混叠信号特征进行特征选择,保留关键特征,剔除冗余信息。本






图2 残差块结构

文分别设计5个残差模块和收缩模块，多个残差模块和收缩模块的组合可以使网络更深，能在避免梯度爆炸的同时加强对混叠信号的空间特征提取能力。本文LSTM模块包含两个级联的LSTM网络，将两个LSTM网络分别称为LSTM1和LSTM2。二者通过堆叠的方式连接，LSTM1的隐状态输出作为输入传递给LSTM2，LSTM2按时间步处理输入序列，每个时间步更新其细胞状态和隐状态。LSTM2最后一个时间步的隐状态输出作为输入传递给后面的全连接层。这种两层LSTM结构能够捕捉时间序列数据中更复杂的时间依赖关系，能提高模型的表达能力和处理复杂序列的能力，提升混叠信号的识别准确率。最后通过两层神经元分别为128和64全连接层得出21种混叠信号分类结果 $[p_1, p_2, \dots, p_{21}]$ 。

3.1 残差模块

残差模块由两个残差块和一层二维卷积构成，残差块结构如图2所示。一共分为两条支路，一条支路中，输入 x 先进入一层二维卷积提取混叠信号局部特征，然后通过归一化层和激活函数，第二个卷积层有助于网络提取更深层次的特征。为了避免在过多的变换中丢失信息，另一条支路采用跳跃连接，跳过卷积层直接与其结果相加并激活，避免在过多的变换中丢失信息，能有效解决网络梯度爆炸和梯度消失问题。

3.2 收缩模块

残差模块提取完混叠信号特征后进入收缩模块，收缩模块包含一个阈值学习子网络，在这个子网络中实现了注意力机制的效果和自适应阈值

选择，是一个软阈值化过程。收缩模块子网络结构如图3所示。混叠信号经过残差网络的两次卷积后，对提取的特征取绝对值，通过全局平均池化（global average pooling, GAP）层获得一个特征值记为 A 。在另一条路径中，全局平均池化之后的特征输入一个全连接（fully connected, FC）网络中，这个全连接网络以Sigmoid函数作为最后一层，将输出归一化到0和1之间，获得一个系数记为 β ，最终获得混叠信号样本的阈值 $A\beta$ ，此方法保证了阈值为正并且不会太大。通过以上过程，收缩模块就可以根据混叠信号样本的特性动态地调整阈值大小，可以理解为一种特殊的注意力机制。




图3 收缩模块子网络结构

3.3 长短期记忆网络模块

所设计的长短期记忆（long short term memory, LSTM）网络共两层结构，两层LSTM结构能够很好地处理时序数据并进一步提取混叠信号的时序特征。为了避免梯度爆炸和过拟合，在两层LSTM后加入Dropout层，丢弃率设置为0.5。

LSTM共有3种门结构，分别是输入门、遗



忘门和输出门，通过门结构选择性让信息通过，有助于更新和遗忘数据。LSTM内结构如图4所示， σ 代表激活函数 Sigmoid， C_{t-1} 代表上一时刻的单元记忆状态， h_{t-1} 表示上一时刻隐层状态， X_t 表示输入单元的向量， C_t 和 h_t 表示当前的时刻 t 的单元记忆状态和隐层状态。




图4 LSTM内结构

输入门决定了当前时刻网络的输入 X_t 有多少保存到单元状态 C_t ，根据上一次的输出和本次的输入来计算当前输入的单元状态，输入门的计算式如式(8)所示。

$$i(t) = \sigma(W_i h(t-1) + U_i x(t) + b_i) \quad (8)$$

其中， W_i 表示输入门权重矩阵， b_i 表示输入门偏置向量。

遗忘门决定了上一时刻的单元状态 C_{t-1} 有多少保留到当前时刻 C_t ，它可以保存之前的信息，又可以避免无用的信息，计算式如式(9)所示。

$$f(t) = \sigma(W_f h(t-1) + U_f x(t) + b_f) \quad (9)$$

其中， W_f 表示遗忘门权重矩阵， b_f 表示遗忘门偏置向量。

记忆单元的状态更新主要由两个部分组成，计算过程如式(10)所示。前半部分由上一时刻单元状态 $C(t-1)$ 与遗忘门的输出 $f(t)$ 相乘得到，后半部分由输入门 $i(t)$ 和候选单元状态 $\tilde{C}(t)$ 相乘得到。

$$\tilde{C}(t) = \tanh(W_c h(t-1) + U_c x(t) + b_c) \quad (10)$$

$$C(t) = C(t-1) \times f(t) + i(t) \times \tilde{C}(t) \quad (11)$$

输出门控制单元状态 C_t 有多少输出到 LSTM 的当前输出值 h_t ，控制有多少状态信息可以作为隐藏状态的输出，计算式如式(12)所示。

$$O(t) = \sigma(W_o h(t-1) + U_o x(t) + b_o) \quad (12)$$

其中， W_o 表示输出门权重矩阵， b_o 示输出门偏置向量。

3.4 基于时序深度残差收缩网络的自动调制识别方法

方法1描述了基于时序深度残差收缩网络的自动调制识别方法，该方法以混叠信号作为输入，通过训练输出最佳训练模型和识别结果。方法1包含2个部分，即步骤(1)到步骤(9)所示的模型训练过程；步骤(10)到步骤(13)所示为模型测试过程。

方法1 时序深度残差收缩网络的自动调制识别方法

第1部分：模型训练

- (1) 初始化模型权重 w 和偏置 b
- (2) 将训练数据分批加载到模型中
- (3) 生成模型的预测输出
- (4) 比较模型预测输出与实际标签，计算损失值
- (5) 从输出层开始逐层计算损失函数相对于各层权重和偏置的梯度
- (6) 更新模型权重和偏置
- (7) 调整超参数，优化模型性能
- (8) 保存最终的模型权重
- (9) 结束

第2部分：模型测试

- (10) 测试数据输入训练好的模型中
- (11) 模型的预测结果和实际标签进行比较，评估模型性能
- (12) 返回测试结果

(13) 结束

4 实验设置与分析

本节首先介绍了仿真实验需要的两类数据集和与实验相关的参数设置。然后,通过对比实验分析了在不同信噪比下所提模型的性能。最后,进行了消融实验,验证 LDRSN 模型有无 LSTM 模块和收缩模块的识别效果。

4.1 实验设定

4.1.1 信号数据集

公开数据集。本文采用的是 O'shea 等^[19]利用软件无线电平台 GNU Radio 信道模型生成的 RadioML2018.01a 公开数据集。数据集中的数据是从真实场景中抽样而来射频数据。数据集中共包含 2 555 904 个样本,分为 24 种调制方式,每种调制方式下有 -20 dB 至 30 dB、步进 2 dB 信噪比范围共 26 个信噪比,每个信噪比都有 4 096 个样本。每个样本具有 1 个标签,由于有 24 种调制类别,故标签采用 24 位的独热编码组成。由于 MASK 和 MPSK 类间信号的混叠会产生幅度和相位信息的干扰,以及 MASK 和 MPSK 类内信号具有相似的特征,信号混叠后较难识别。于是本文在 RadioML2018.01a 公开数据集中选取了 7 种调制信号 {OOK、4ASK、8ASK、BPSK、QPSK、8PSK、16APSK} 进行两两线性相加混叠,共混叠成 21 种混叠信号进行实验,每种类型的混叠信号共有 65 536 个样本。

实测数据集。实测数据采集软件环境如图 5 所示。本文实测数据场景中采用了 1 个发射端和 1 个接收端,二者配合完成实测信号采集。首先,射频发送端的 MATLAB 程序 1 读取生成信号数据的 .mat 文件。然后,数据经过 AD9361 射频子板 1 的 DAC 转换后经由射频天线 1 发送出去。射频接收端接收信号后,利用 AD9361 射频子板 2 进行 ADC 转换,接着通过 ZedBoard 开发板 2 传输数据到上位机,上位机的 MATLAB 程序 2 将数据保存

为新的 .mat 文件,从而完成实测数据集的采集,然后将采集完成的实测数据通过两两混叠的方式制作成混叠信号数据集。




图5 实测数据采集软件环境

实测数据采集软硬件环境如图 6 所示。数据集的制作分为发送数据制作、通过 SDR 接收数据、接收数据制作。随机生成 1 024 000 个随机数,通过升余弦滤波后,保存为 .mat 格式文件。由于 16QAM 和 64QAM 信号混叠较难识别,QAM 信号和 MPSK 信号易混淆,不同的类间信号之间会存在干扰,本文采集 {BPSK、QPSK、8PSK、16QAM、64QAM、PAM4、GFSK} 7 种实测信号混叠成 21 种混叠信号。




图6 实测数据采集软硬件环境

4.1.2 参数设置及模型训练

RadioML2018.01a 由 2 555 904 个样本组成,实测数据集每种类别有 44 000 个样本。利用公开数据集和实测数据集进行训练和测试,并将数据集按 7:3 的比例划分成训练集和测试集,以对比不同方法的识别性能。



本文采用的损失函数是交叉熵损失 (cross-entropy loss) 函数, 优化方法为Adam动态优化。学习率根据训练批次epoch值动态调整, epoch大小设为100, 训练10个epoch后每过5个epoch学习率将会衰减。其中, 参数设置为衰减因子0.1, 初始学习率0.001, 最低学习率0.000 001, 学习率更新相关参数 $\beta_1=0.9$, $\beta_2=0.999$ 。训练停止条件是迭代次数达到100 epoch或损失值连续10个epoch不减少, 并选择交叉验证集损失值最小的epoch对应的权重作为最终保存的网络权重。

4.1.3 损失函数设置

本文损失函数采用的是交叉熵损失函数, 给定两个概率分布 p 和 q , 通过 q 来表示 p 的交叉熵如式(13)所示。

$$H(p, q) = -\sum p(x) \log q(x) \quad (13)$$

其中, p 是真实结果的概率分布, q 是预测结果的概率分布。

交叉熵损失函数是一种衡量预测结果和真实结果的之间差异的衡量指标, 能够为每个预测结果提供平滑且有效的梯度信号, 有助于模型参数的优化, 在分类问题中发挥重要作用, 可以提高分类模型的准确性。相比较其他损失函数, 交叉熵损失在训练模型时更容易获得稳定的收敛如式(14)所示。

$$\text{Loss} = -\sum_{i=1}^n y_i \log y'_i \quad (14)$$

其中, y_i 是标签值, y'_i 是预测值, 损失函数的值越小, 表示模型的预测结果与真实结果之间的差异越小, 模型性能更好。

4.2 实验结果与分析

4.2.1 识别精度

在RadioML2018.01a数据集上对混叠信号进行分类识别, RadioML2018.01a数据集上不同模型的识别精度如图7所示。由图7可以看出, 随着信噪比逐渐增加, 混叠信号的识别准确率呈逐渐增加的趋势。Capsnet^[20]、Hybrid network^[21]、MLCNN、LSTM^[22]、CLDNN^[23]几种神经网络都

被用于混叠信号的自动调制识别, 现有方法性能最佳的是Hybrid network, 是一种混合ConvNeXt和atrous自注意力的网络, 在公开数据集上信噪比16 dB时准确率仅达到87.3%, 本文所提方法在信噪比16 dB时准确率可以达到92.7%。




图7 RadioML2018.01a数据集上不同模型的识别精度

RadioML2018.01a数据集上混叠信号在不同信噪比下的识别率曲线如图8所示。由图可知, 在信噪比为10 dB时, 21种混叠信号中有16种达到了90%以上, 12种接近100%。改进后的深度残差收缩网络模型在信噪比16 dB时的识别率可以达到92.7%,




图8 RadioML2018.01a数据集上混叠信号在不同信噪比下的识别率曲线

LDRSN模型在16 dB时的混淆矩阵如图9所示。

LDRSN模型的损失函数收敛曲线如图10所示，初始阶段损失函数数值较高，随着训练轮次的增加，损失值逐渐下降，从第20轮开始损失函数表现出明显的收敛趋势，这一阶段的损失值下降速度减缓，趋于平稳。在第80轮时，损失值变化幅度较小，表明模型已在训练数据上达到较优的拟合。

4.2.2 实测数据集实验

实测数据集上LDRSN模型的混淆矩阵如图11所示。在信噪比15 dB实测数据集上，本文提出的LDRSN模型在实测数据集上的识别准确率达95.53%。表明该模型在实际场景下具有较好的混叠信号识别能力。

4.2.3 复杂度对比分析

本文通过对比参数量来对比分析模型的复杂度。模型复杂度对比分析见表1。可以看出，本文设计的时序深度残差收缩网络算法模型参

数量较大，共1 056万，比Capsnet模型小80万，对比另外4种模型的参数量大。主要原因是本文设计的网络较深，共有5个残差模块和收缩模块，残差模块由两个残差块和一层二维卷积构成，残差块又包含两层卷积，共包含25层卷积。

4.2.4 LSTM结构影响分析

LSTM通过其记忆单元和门控单元能够有效捕捉混叠调制信号中长期依赖信息，对于混叠调制信号中的长期依赖特征特别有效。其中，门控单元中的遗忘门和输入门能有效过滤混叠信号中的冗余信息和噪声。并且，LSTM结构在复杂的混叠环境中通过多层递归和非线性处理，可以有效提取混叠调制信号的关键特征。

为了验证LSTM结构对混叠调制信号分类识别效果的影响，在公开数据集RadioML2018.01a上，本文分别对LDRSN模型有LSTM结构和无




图9 LDRSN模型在16 dB下的混淆矩阵




图10 LDRSN模型的损失函数收敛曲线

LSTM结构进行实验, 有无LSTM模块时LDRSN模型的识别精度如图12所示。无LSTM结构时模型的识别精度仅有83.3%, 加入LSTM结构后识别精度提升了9.4个百分点, 达到92.7%。可以看出, 加入LSTM结构能很好地对深度残差收缩网络提取的混叠信号特征进行建模和处理, 有效提

表1 模型复杂度对比分析

模型	参数量/ $\times 10^6$
LDRSN	10.56
Hybrid network	3.95
Capsnet	11.36
CLDNN	7.8
LSTM	4.67
MLCNN	5.31

高混叠信号的识别精度。

4.2.5 收缩模块影响分析

收缩模块的核心是通过特征选择和特征收缩机制减少不重要的特征对混叠信号识别的影响, 混叠信号通过残差模块提取完特征后输入收缩模块中, 收缩模块中的软阈值对特征进行收缩, 使得小于阈值的特征被抑制。

为了验证深度残差收缩网络中的收缩结构对识别结果的影响, 在公开数据集RadioML2018.01a




图11 实测数据集上LDRSN模型的混淆矩阵




图12 有无LSTM模块时LDRSN模型的识别精度

上, 本文将LDRSN模型和剔除收缩结构之后得到的LDRSN模型进行对比实验, 有无收缩模块时的识别精度如图13所示。可以看出, 收缩结构对低信噪比环境下和整体的识别率均有一定影响, 剔除掉收缩结构后的模型在12 dB时准确率最高为87.1%, 下降了5.6个百分点。由此可知, 加入收缩模块后模型性能更优, 混叠信号识别准确率有明显提升。




图13 有无收缩模块时的识别精度

5 结束语

针对目前单信号调制识别方法难以适用于混叠信号, 对识别混叠信号识别精度较低的问题, 本文设计了一种时序深度残差收缩网络模型, 称

为LDRSN, 其包含残差模块、收缩模块和LSTM模块, 并基于该模型设计了混叠信号识别方法。实验表明, 本文所提模型在公开数据集RadioML2018.01a上对混叠信号的识别性能明显优于5种现有网络模型, 其中21种混叠信号有16种达到了90%以上, 12种接近100%。在16 dB信噪比时, LDRSN的整体识别率可以达到92.7%。在实测数据集上的识别准确率高达95.53%。下一步, 将进一步完善模型结构, 重点提升在低信噪比条件下的混叠信号识别精度。

参考文献:

- [1] LI X, DONG W, ZHANG S, et al. A survey on deep learning techniques in wireless signal recognition[J]. Wireless Communications and Mobile Computing, 2019: 1-12.
- [2] ZHANG X, GE T, CHEN Z. Automatic modulation recognition of communication signals based on instantaneous statistical characteristics and SVM classifier[C]//proceedings of the IEEE Asia-Pacific Conference on Antennas and Propagation (APCAP). Piscataway: IEEE Press, 2018: 344-346.
- [3] 杨洪娟, 时统志, 李博, 等. 基于联合特征参数的卫星单-混信号调制识别研究[J]. 电子与信息学报, 2022, 44(10): 3499-3506.
- [4] YANG H J, SHI T Z, LI B, et al. Research on satellite single-mixed signal modulation recognition based on joint feature parameters[J]. Journal of Electronics & Information Technology, 2022, 44(10): 3499-3506.
- [5] ZUO J, MIAO Y, ZHANG B, et al. Cyclostationary feature mode decomposition and its application in fault diagnosis of planetary gearboxes via built-in information[J]. IEEE Sensors Journal, 2024, 24(2): 1129-1139.
- [6] 谢智东, 谭信, 袁昕旺, 等. 基于生成对抗数据增强支持向量机的小样本信号调制识别算法[J]. 电子与信息学报, 2023, 45(6): 2071-2080.
- [7] XIE Z D, TAN X, YUAN X W, et al. Small sample signal modulation recognition algorithm based on support vector machine enhanced by generative adversarial networks generated data[J]. Journal of Electronics & Information Technology, 2023, 45(6): 2071-2080.
- [8] XIE C, LI C, ZHANG C, et al. Hierarchical residual stochastic networks for time series recognition[J]. Information Sciences, 2019, 471: 52-63.



- [7] YAN H, WANG G, GAO F, et al. Dynamic convolutional neural network for wireless interference identification[J]. IEEE Communications Letters, 2024, 28(1): 83-87.
- [8] XU S, LIU L, ZHAO Z. DTFTNet: radar modulation recognition with deep time-frequency transformation[J]. IEEE Transactions on Cognitive Communications and Networking, 2023, 9(5): 1200-1210.
- [9] 曾泓然, 高勇. 一种采用预分类式神经网络的混叠信号识别方法[J]. 无线电工程, 2023, 53(5): 1138-1144.
- ZENG H R, GAO Y. An overlapped signal recognition method used pre-classification neural network[J]. Radio Engineering, 2023, 53(5): 1138-1144.
- [10] HUANG S, YAO Y, WEI Z, et al. Automatic modulation classification of overlapped sources using multiple cumulants[J]. IEEE Transactions on Vehicular Technology, 2017, 66(7): 6089-6101.
- [11] DU Y, YANG X, ZHANG J, et al. Modulation recognition method of mixed signal based on intelligent analysis of cyclic spectrum section[J]. Journal of System Simulation, 2023, 35(1): 146-157.
- [12] XU W, GAN L, HUANG C. A robust deep learning-based beamforming design for RIS-Assisted multiuser MISO communications with practical constraints[J]. IEEE Transactions on Cognitive Communications and Networking, 2022, 8(2): 694-706.
- [13] MENG Y, YU L, WEI Y. Multi-label radar compound jamming signal recognition using complex-valued CNN with jamming class representation fusion[J]. Remote Sensing, 2023, 15(21): 5180.
- [14] YIN Z, ZHANG R, WU Z, et al. Co-channel multi-signal modulation classification based on convolution neural network[J]. IEEE 89th Vehicular Technology Conference (VTC2019-Spring), 2019: 1-5.
- [15] PAN Z, WANG S, ZHU M, et al. Automatic waveform recognition of overlapping LPI radar signals based on multi-instance multi-label learning[J]. IEEE Signal Processing Letters, 2020, 27: 1275-1279.
- [16] PAN Z, WANG S, LI Y. Residual attention-aided U-Net GAN and multi-instance multilabel classifier for automatic waveform recognition of overlapping LPI radar signals[J]. IEEE Transactions on Aerospace and Electronic Systems, 2022, 58(5): 4377-4395.
- [17] PAN Z, WANG B, ZHANG R, et al. MIML-GAN: a GAN-based algorithm for multi-instance multi-label learning on overlapping signal waveform recognition[J]. IEEE Transactions on Signal Processing, 2023, 71: 859-872.
- [18] YANG W C, REN K, DU Y, et al. Modulation recognition method of mixed signals based on cyclic spectrum projection[J]. Scientific Reports, 2023, 13: 21459.
- [19] O'SHEA T J, ROY T, CLANCY T C. Over-the-air deep learning based radio signal classification[J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(1): 168-179.
- [20] ZHOU S, WU Z, YIN Z, et al. Blind modulation classification for overlapped co-channel signals using capsule networks[J]. IEEE Communications Letters, 2019, 23(10): 1849-1852.
- [21] ZHANG R, ZHAO Y, YIN Z, et al. A reference signal-aided deep learning approach for overlapped signals automatic modulation classification[J]. IEEE Communications Letters, 2023, 27(4): 1135-1139.
- [22] LI J, QI L, LIN Y. Research on modulation identification of digital signals based on deep learning[C]//proceedings of the IEEE International Conference on Electronic Information and Communication Technology (ICEICT). Piscataway: IEEE Press, 2016, 402-405.
- [23] XU J, LIN Z. Modulation and classification of mixed signals based on deep learning[J]. arXiv: 2205.09916, 2022.

[作者简介]



刘京华 (1997-), 男, 南京信息工程大学硕士生, 主要研究方向为深度学习和移动计算。

魏祥麟 (1985-), 男, 博士, 现就职于国防科技大学第六十三研究所, 主要研究方向为边缘计算、深度学习和无线网络安全。

范建华 (1971-), 男, 博士, 现就职于国防科技大学第六十三研究所, 主要研究方向为软件无线电和频谱智能计算。

胡永扬 (1977-), 男, 博士, 国防科技大学第六十三研究所高级工程师, 主要研究方向为软件无线电和频谱智能计算。

王晓波 (1982-), 男, 博士, 国防科技大学第六十三研究所工程师, 主要研究方向为移动智能计算。

于兵 (1981-), 男, 博士, 南京信息工程大学副教授, 主要研究方向为微波技术、射频感知和电磁超材料。