

基于信噪比分级的信号调制类型识别

陈晋音 蒋焘 郑海斌

浙江工业大学信息工程学院 杭州 310000

摘要 无线电调制类型识别广泛应用于军民的各个领域,相比人工识别和频谱分析法等传统方法,基于深度学习的信号调制类型识别方法取得了较好性能,但仍存在识别准确率低的问题。文中提出了一种基于长短时记忆网络(LSTM)模型的信号调制类型识别方法,将深度学习分类方法与信噪比分级相结合,设计了一种基于深度学习的信噪比分级调制类型识别框架。通过准确分类高低信噪比信号,并采用不同的降噪处理来提高低信噪比信号调制类型识别的准确率。通过机器学习方法对2016.4C信号数据集进行调制类型识别的准确率为21%,通过深度学习模型对2016.4C信号数据集进行不降噪、分级降噪、全部降噪3个调制类型识别对比实验,识别准确率分别为69.82%,70.50%,66.67%,有效验证了所提方法对提高低信噪比信号调制类型识别准确率的可行性与优越性。

关键词 信噪比分级;调制类型识别;深度学习;长短期记忆网络

中图法分类号 TP29

Radio Modulation Recognition Based on Signal-noise Ratio Classification

CHEN Jin-yin,JIANG Tao and ZHENG Hai-bin

College of Information Engineering,Zhejiang University of Technology, Hangzhou 310000,China

Abstract Radio modulation recognition has been widely used in various fields of military and civilian. Compared with the traditional methods such as artificial recognition and spectrum analysis, the modulation recognition method based on deep learning has better performance, but it still has the problem of low recognition accuracy. This paper proposed a modulation recognition method based on long-term and short-term memory network (LSTM) model. It combines deep learning classification method with SNR classification to design a SNR modulation recognition framework based on deep learning. By accurately classifying high and low SNR signals and using different denoising processing, the recognition accuracy of low SNR signal modulation is improved. The recognition accuracy of 2016.4c signal data set by machine learning method is 21%. Three modulation type identification comparison experiments, non-denoising, grading denoising and total denoising, are carried out on 2016.4C signal data set, the recognition accuracy is 69.82%, 70.56%, and 66.67% respectively, which effectively verifies the feasibility and superiority of the proposed method to improve the accuracy of low SNR signal recognition.

Keywords Signal-noise ratio classification, Modulation recognition, Deep learning, Long-short term memory networks

1 引言

无线电信号调制广泛应用于民用和军事领域,包括信号身份确认以及干扰确认、电子战和军用软件无线电技术等。目前,信号的调制类型识别存在信号调制类型种类繁多、信号受噪声影响大、数据量大、识别准确率低等问题,这给调制类型识别带来了挑战,也对信号调制识别方法提出了更高的要求。

现有较多的调制信号识别方法,早期的方法包括基于高阶累积量特征识别^[1]、基于循环累积量特征识别^[2]、基于小波变换特征的调制信号识别^[3]。基于机器学习的调制信号识别方法包括聚类算法^[4]、BP神经网络^[5]、支持向量机^[6]等。近

年来,得益于深度学习的快速发展,基于深度学习的调制类型识别方法取得了较好效果,如基于卷积神经网络的识别^[7]、基于循环神经网络的调制识别^[8]等。在已有的研究中发现,虽然现存调制识别方法众多,但依然存在以下问题:

(1)低信噪比(signal-to-noise ratio, SNR)信号的调制类型识别准确率较低,对信号的整体识别性能影响较大。

(2)对所有数据集进行滤波降噪处理(包含高SNR的信号数据样本和低SNR的信号数据样本),虽然对低SNR信号调制类型识别准确率有提升,但会干扰高SNR的信号调制类型识别,从而导致整体信号的调制类型识别准确率下降。

针对以上问题,本文提出了一种基于信噪比分级的信号调制类型识别方法,通过自适应确定最优SNR分类边界,根

基金项目:浙江省自然科学基金(LY19F020025);宁波市“科技创新2025”重大专项(2018B10063);基于GAN的信号识别项目;深度学习增强识别项目;浙江省认知医疗工程技术研究中心(2018KFJJ07)

This work was supported by the Zhejiang Provincial Natural Science Foundation of China (LY19F020025), Major Special Funding for “Science and Technology Innovation 2025” in Ningbo (2018B10063), Signal Recognition Based on GAN, Deep Learning for Enhancement Recognition Project, Engineering Research Center of Cognitive Healthcare of Zhejiang Province (2018KFJJ07).

通信作者:陈晋音(chenjinyin@zjut.edu.cn)

据信号样本 SNR 的差异性将样本分为 K 类。划分 K 类信号样本中 SNR 较低的类别为低 SNR 类,并对其进行滤波降噪后再识别;对于高 SNR 信号则跳过降噪直接识别。通过对高低信噪比类的差异化处理,既能提升低 SNR 信号的调制类型识别准确率,又不会降低高 SNR 信号样本调制类型的识别准确率,从而提升了整体的调制类型识别准确率。因此,本文方法的主要工作包括:

(1)提出了一种通用的信噪比分级调制类型识别框架,有效提高了包含多种信噪比的无线电信号调制类型识别准确率。采用无监督的聚类方法确定信噪比分类边界,将信噪比分为高、低信噪比两类。通过对低信噪比类进行滤波降噪处理,并采用调制类型识别的分级处理方法,提高了信号调制类型的识别准确率。

(2)提出了基于 K 均值聚类的信噪比分类边界自适应确定算法,通过提取信号的信噪比来表征特征并做无监督的聚类,利用最优的分类边界将无线电信号样本分为高信噪比类和低信噪比类两类。

(3)在实际数据集上展开实验,分别对比信噪比分级处理前后的调制信号识别准确率,验证了基于信噪比分级的调制类型识别方法的有效性。

本文第 2 节介绍了信噪比预测、信号降噪、调制识别、 K 均值聚类等相关工作;第 3 节介绍了本文提出的主要方法框架;第 4 节介绍了实验相关内容;最后总结全文。

2 相关工作

2.1 信噪比预测

信噪比预测是指预测信号平均功率与噪声平均功率的比值。预测方法包括:1)基于卡尔曼滤波的动态预测算法^[9],对某信道前 t 时刻的信噪比进行实时估算,利用卡尔曼滤波器,计算第 $t+1$ 时刻信号的信噪比值;2)基于自回归滑动平均模型的信噪比预测方法^[10],建立自回归滑动平均模型预测信道的传输系数,确定信道传输系数与信噪比之间的拟合多项式,并将预测的信道系数输入到拟合多项式中,以得到下一时刻信道的信噪比;3)基于反向传播神经网络的信噪比预测^[11-12],通过数据集的训练,利用反向传播算法,不断修正模型的权值和阈值,减小损失函数,逼近期望输出。基于神经网络的信噪比预测算法包括遗传算法优化^[11]与粒子群算法优化^[12]。

对于未知信噪比的信号,可先通过上述方法预测信噪比值,再根据信噪比进行分级降噪,调制识别。

2.2 信号降噪方法

信号降噪是指降低信号中的噪声成分,从而提高通信质量。常用降噪方法包括中值滤波、均值滤波、巴特沃斯滤波、小波变换滤波、降噪自编码器滤波^[13]等。中值滤波采用非线性性的方法,选择适当的点来替代受干扰信号点的值,对脉冲噪声有良好的滤除作用,且滤波方法简单易操作,因此本文采用中值滤波降噪方法。

中值滤波采用某种结构的二维滑动模板,将板内像素按照像素值的大小进行排序,生成单调上升(下降)的二维数据序列。二维中值滤波输出的定义为:

$$g_1(x, y) = \text{med}\{f_1(x-k, y-l), (k, l \in W_1)\} \quad (1)$$

其中, $f_1(x, y)$, $g_1(x, y)$ 分别为原始信号样本和处理后的信号样本。 W_1 为二维滤波模板,在信号的降噪滤波中,滤波模

板尺寸通常设为 1×3 或 1×5 。

2.3 调制类型识别方法

信号调制类型识别方法可分为两大类,即基于统计量的调制识别方法与基于决策论的调制识别方法。基于统计模式的方法根据信号频域特征的不同来区分各种调制方式,Desimio 等^[14]提出利用信号频谱特征来进行信号的调制类型分类;Chani 等^[15]利用 AM、QPSK 等信号平方谱谱峰数以及功率谱的差异来进行分类;Lopatka 等^[16]引用高阶矩的思想进行调制类型分类;Kim 等^[17]提出了准对数似然比规则,该规则以贝叶斯理论为核心,又称似然比检验法。提出了准对数似然比规则,以贝叶斯理论为核心的决策论调制类型识别方法,又称似然比检验法。基于机器学习的信号调制类型识别方法包括基于聚类算法的调制类型识别^[18]、基于 BP 神经网络的调制类型识别^[19]、基于支持向量机(SVM)的调制类型识别^[20]、基于 K 最近邻(KNN)的调制类型识别^[21]。机器学习调制类型识别方法的识别率较高,但对于数据量大、信噪比低的数据集识别困难。

随着深度学习在图像、语音、文本处理等领域取得巨大成功,2016 年,Shea 等^[22]提出将深度卷积神经网络应用于无线电信号调制识别,并显示出了卓越的性能改进,表明了使用深度卷积神经网络对密集编码的时间序列进行盲时间学习的可行性。同年,Shea 等^[23]提出了基于循环神经网络的信号调制类型识别,并达到了优异性能。2018 年,Tang 等^[24]提出利用生成式对抗网络进行数据增强的数字信号调制分类,解决了在深度学习训练时数据量不足的问题。

上述深度学习调制识别方法将深度神经网络与调制识别相结合,提高了调制类型的识别准确率,但难以改善低信噪比信号识别困难的问题。本文将深度学习分类方法与信噪比分级相结合,提出了新的调制识别框架,旨在提高低信噪比信号调制识别准确率。

2.4 K 均值聚类算法

K 均值聚类^[25]算法是基于样本间相似性度量的间接聚类方法,属于非监督学习方法。其以 K 为分类参数,将 N 个对象分为 K 个簇,以使簇内具有较高的相似度,而且簇间的相似度较低。随机选择 K 个对象作为初始聚类中心,对其余的每一个对象,根据该对象与各聚类质心之间的距离,把它分配到与之最相似的聚类中。距离计算公式的定义为:

$$D = \sum_{i=1}^k \sum_{x_j \in s_i} (x_j - \mu_i)^2 \quad (2)$$

其中, μ_i 为对应质心, x_j 表示第 j 个信号样本点, s_i 表示信号样本集, D 表示信号样本点 x_j 到质心 μ_i 的距离平方和,最优的聚类应使 D 达到最小值。

计算每个聚类的新质心,重复上述过程,直到无线信号样本的均方差 ϑ 收敛。均方差计算公式的定义为:

$$\vartheta = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (3)$$

其中, ϑ 表示均方误差, N 表示信号样本数, x_i 表示每个信号样本的坐标, μ 表示聚类中心。

3 基于信噪比分级的调制类型识别方法

3.1 方法介绍

基于信噪比分级的信号调制类型识别方法包括数据预处理及特征提取模块、 K 均值聚类确定最优信噪比分类边界模

块、信噪比分类模块、低信噪比信号样本降噪处理模块和调制类型识别模块。

图 1 为基于信噪比分级的调制类型识别框图,其中 K 均值聚类即为聚类确定最优分类边界模块,数据预处理即为数据预处理模块, $SNR > 0$ (假设 0 为最优信噪比分类边界) 与均值滤波为低信噪比信号样本降噪处理模块,无线信号调制类型识别模型即为调制类型识别模块,信噪比分类网络与信噪比分类模型即为信噪比分类模块。




图 1 基于信噪比分级的调制类型识别框图

Fig. 1 Modulation type identification block diagram based on SNR classification

3.1.1 数据预处理及特征提取

(1) 数据归一化

对获取的无线信号样本数据进行归一化处理,本文选取 min-max 归一化处理对无线信号样本进行归一化处理, min-max 归一化公式的定义为:

$$x_i^* = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (4)$$

其中, x_{\max} 为无线信号样本对应数据值的最大值, x_{\min} 为信号样本中对应数据值的最小值, x_i 为被归一化处理的数据, x_i^* 为经过归一化处理后的数据, $i=1, 2, \dots, N$ 。

(2) 基于 LSTM 的特征提取

本文使用的 LSTM 特征提取模块由一层输入层、两层 LSTM 特征提取层组成,其中输入层的形状为 $[bs, tp, 2]$, 第一层 LSTM 特征提取层的形状为 $[bs, tp, 128]$, 第二层 LSTM 特征提取层形状为 $[bs, tp, 32]$, 具体网络说明详见 3.2 节。

3.1.2 K 均值聚类确定信噪比最优分类边界

选取神经网络中提取出来的特征为数据样本进行聚类,具体过程如下:

(1) 以 LSTM 神经网络提取的信号特征作为聚类样本,通过 K 均值聚类得到信噪比聚类类标。

(2) 根据原始信号的信噪比值,人工设定原始信号的信噪比分类边界(如设定以 -12 dB 为分界线),获得原始样本信噪比分类类标。

(3) 将信噪比聚类类标与原始样本信噪比分类类标进行比较,得到该人工设定信噪比分类边界的分类准确率。

(4) 按步长为 2 dB 改变人工设定信噪比分类边界,获得各个信噪比分类边界的分类准确率,选取分类准确率最高的信噪比分类边界作为最优信噪比分类边界。

3.1.3 信噪比分类

针对所有无线信号样本构建一个信噪比分类网络,以无线信号样本及对应的信噪比标签为训练样本,对信噪比分类网络进行训练,获得信噪比分类模型,具体方法如下(以二分类为例):

(1) 根据最优信噪比分类边界,给信号样本标记信噪比类

标,信噪比值小于分类边界的标记为 1,大于分类边界的标记为 2。

(2) 搭建信噪比分类网络框架,网络由一层输入层、两层 LSTM 特征提取层、一层全连接层、一层输出层组成,具体框架请见 3.2 节。

(3) 以无线信号样本为训练集,以按最优分类边界进行分类获得的样本类标为分类类标,对模型进行训练。

信噪比分类网络的训练优化目标函数为:

$$L_{snr} = \sum_{i=1}^N \hat{y}_{snr}^{(i)} \log y_{snr}^{(i)} + (1 - \hat{y}_{snr}^{(i)}) \log (1 - \log y_{snr}^{(i)}) \quad (5)$$

其中, L_{snr} 为信噪比分类损失函数, N 为信号样本数量, $\hat{y}_{snr}^{(i)}$ 为无线信号样本的信噪比等级预测值, $y_{snr}^{(i)}$ 为无线信号样本的信噪比等级标签值。

3.1.4 降噪处理

对由最优分类边界找出的低 SNR 信号进行滤波降噪处理,从而提升低 SNR 样本的调制类型识别准确率。选取中值滤波方法,设置滤波窗口大小为 5×1 , 分别对低 SNR 类信号样本的 I/Q 路信号进行滤波降噪处理。

3.1.5 调制类型识别

构建基于 LSTM 的调制类型识别模型,由一层输入层、两层 LSTM 特征提取层、一层全连接层、一层输出层组成,具体框架设置请见 3.2 节。选取 'softmax' 激活函数,调制类型分类数为 c , 其中 c 的值与具体数据集相关联。

调制类型识别神经网络的训练优化目标函数为:

$$L_{mt} = \sum_{i=1}^N \hat{y}_{mt}^{(i)} \log y_{mt}^{(i)} + (1 - \hat{y}_{mt}^{(i)}) \log (1 - \log y_{mt}^{(i)}) \quad (6)$$

其中, L_{mt} 为调制类型识别损失函数, N 为信号样本数量, $\hat{y}_{mt}^{(i)}$ 为无线信号样本调制类型的预测值, $y_{mt}^{(i)}$ 为无线信号样本调制类型的标签值。

3.2 LSTM 神经网络框架介绍

LSTM^[26] 的核心是在算法中加入了一个判断信息有用与否的“处理器”(cell)。一个 cell 中有三扇门,分别为输入门、遗忘门和输出门。信息进入 LSTM 网络中,可以根据规则来判断是否有用,只有符合要求的信息才会留下,不符合要求的信息则通过遗忘门被遗忘。LSTM 是解决长序依赖问题的有效技术,无线电信号数据作为典型的时序性数据,适合用 LSTM 神经网络进行分类。

图 2 为循环神经网络前向计算展开图,其中 S_t 为 t 时刻的状态单元, X_t 为 t 时刻的输入数据, O_t 为 t 时刻的输出数据, W 为不同时刻间的记忆传递参数矩阵, U 为输入数据传递参数矩阵, V 为输出数据传递参数矩阵。




图 2 循环神经网络前向计算展开图

Fig. 2 Forward computational expansion diagram of cyclic neural network

图 3 为 LSTM 结构示意图,其中, $f(t)$ 为遗忘门, $i(t)$ 为输入门, O_t 为输出门, \tanh 与 σ 为激活函数, C_{t-1} 与 h_{t-1} 为上一单元的输出, C_t 与 h_t 为本单元的输出。

遗忘门 $f(t)$:遗忘门是以上一单元的输出 h_{t-1} 和本单元的输入 x_t 为输入的 sigmoid 函数,为 C_{t-1} 中的每一项产生一个在 $[0,1]$ 内的值,来控制上一单元状态被遗忘的程度。

输入门 $i(t)$:输入门由激活函数 \tanh 控制,产生一个新的候选向量 \tilde{C}_t ,输入门为 \tilde{C}_t 中的每一项生成一个 $[0,1]$ 以内的值,控制新信息被加入的程度。

输出门 O_t :输出门由激活函数 σ 控制,为当前状态的每一项产生一个在 $[0,1]$ 内的值,控制单元状态被过滤的程度。

激活函数:图 2 中的 \tanh 为激活函数‘ \tanh ’, σ 为激活函数‘ sigmoid ’。

$$\tanh x = \frac{\sinh x}{\cosh x} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (7)$$

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

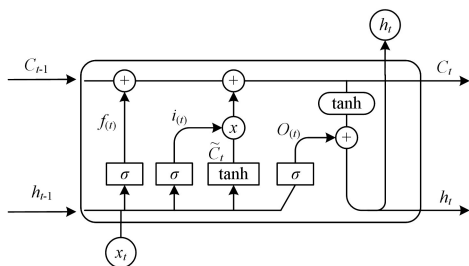


图 3 LSTM 结构示意图

Fig. 3 LSTM structural diagram

本文中的 LSTM 神经网络框架均为下文所述的结构框架。

本文中的 LSTM 特征提取神经网络、LSTM 信噪比识别神经网络、LSTM 信号调制类型识别神经网络均由一层输入层、两层 LSTM 特征提取层、一层全连接网络、一层输出层组成。输入层形状为 $[bs, tp, 2]$, 第一层 LSTM 特征提取层的形状为 $[bs, tp, 128]$, 第二层 LSTM 特征提取层的形状为 $[bs, tp, 32]$, 全连接层的形状为 $[bs, 512]$, 输出层的形状为 $[bs, c]$ 。两层 LSTM 特征提取层的 Dropout 均为 0.8, 全连接层 Dropout 为 0.5, 模型学习率为 0.0008, 输出层激活函数为‘softmax’。

图 4 为 LSTM 神经网络结构图,其中 bs 为数据集样本数, tp 为每个信号样本的时间节点数, 2 为每个时间节点下原始信号的特征维数, 128 与 32 分别为两层 LSTM 的神经元个数, 512 为全连接层节点数, c 为输出层节点数, 在信噪比分类模块中, c 的值为 2, 即高低信噪比两类, 分类结果为高信噪比类或者低信噪比类; 在调制类型识别模块中, c 的值为对应信号数据集调制类型数, 分类结果为信号样本对应的调制类型。




图 4 LSTM 神经网络结构图

Fig. 4 Structural chart of LSTM neural network

4 实验

4.1 数据集介绍

实验中一共用到 4 个数据集,均来自于 deepsig¹⁾ 的公开数据集,以下依次简称为:2016.4C,2016.10a,2016.10b,2016.data 数据集。

4.1.1 2016.4C 数据集

该数据集中共有 162060 个信号数据样本,信号样本的形式为 $[tp, 2]$,其中 $tp=128$ 为采样时间节点,2 为每个采样时间节点的特征维数。数据集共有 11 种调制类型,每一种调制类型的信号样本子集中均匀分布有从 -20 dB 到 18 dB(间隔 2 dB)一共 20 种信噪比值的信号样本。每种信噪比值的信号样本子集包含 6500 个样本。划分 80%(129648 个)为训练集,20%(32412 个)为测试集,随机选取测试集中的 10%(3241 个)作为验证集。图 5 为 2016.4C 数据集中 11 种调制类型信号的波形图。




图 5 2016.4C 数据集中 11 种调制类型信号的波形图(SNR=18 dB)

Fig. 5 Signal waveforms of 11 modulation types in 2016.4C dataset (SNR=18 dB)

4.1.2 2016.10a 数据集

该数据集中共有 220000 个信号数据样本,信号样本的形式为 $[tp, 2]$,其中 $tp=128$ 为采样时间节点,2 为每个采样时间节点的特征维数。本数据集共有 11 种调制类型,每一种调制类型的信号样本子集中均匀分布有从 -20 dB 到 18 dB(间隔 2 dB)一共 20 个信噪比值的信号样本。划分其中的 80%(176000 个)为训练集,20%(44000 个)为测试集,随机选取测试集中的 10%(4400)作为验证集。训练集中,每种调制类型的信号中的不同信噪比值子集包含 800 个信号样本,测试集中为 200 个。

4.1.3 2016.10b 数据集

该数据集中共有 1200000 个信号数据样本,信号样本的形式为 $[tp, 2]$,其中 $tp=128$ 为采样时间节点,2 为每个采样时间节点的特征维数。本数据集共有 10 种调制类型,每一种调制类型的信号样本子集中均匀分布有从 -20 dB 到 18 dB(间隔 2 dB)一共 20 个信噪比值的信号样本。在本文的实验中,划分 80%(960000 个)为训练集,20%(240000 个)为测试集,随机选取测试集中的 10%(24000)作为验证集。训练集中,每种调制类型的信号中的不同信噪比值子集包含 4800 个信号样本,测试集中为 1200 个。

4.1.4 2016.data 数据集

该数据集中共有 468000 个信号数据样本,信号样本的形式为 $[tp, 2]$,其中 $tp=512$ 为采样时间节点,2 为每个采样时

¹⁾ <https://www.deepsig.io/datasets/>

间节点的特征维数。本数据集共有 12 种调制类型,每一种调制类型的信号样本子集中均匀分布有从 -20 dB 到 30 dB(间隔 2 dB)一共 25 个信噪比值的信号样本。在本文的实验中,划分 66% (312000 个)为训练集, 33% (156000 个)为测试集,随机选取测试集中的 10% (15600)作为验证集。训练集中,每种调制类型的信号中的不同信噪比值子集包含 1000 个信号样本,测试集中为 500 个。

4.2 实验设置

4.2.1 信噪比分类模型训练实验

信噪比分类模型训练的神经网络结构由一层输入层、两层 LSTM 层、一层全连接层和一层输出层组成,第一层 LSTM 特征提取层的形状为 $[bs, tp, 128]$,第二层 LSTM 特征提取层的形状为 $[bs, tp, 32]$,LSTM 神经网络中 dropout 的比率(Dropout_lstm)为 0.8 ,设置输出层形状为 $[bs, 2]$,输出层激活函数为‘softmax’,采用 adam 优化器,设置模型学习率为 0.0008 。

4.2.2 降噪滤波实验

在对信号进行降噪处理时,我们选取了中值滤波的方式,并设置滤波窗口大小为 5×1 ,对低信噪比类信号的 I/Q 路信号分别进行降噪处理,获得对低信噪比类信号降噪后的训练集与测试集。

4.2.3 调制类型识别实验

信号调制模型训练的神经网络由一层输入层、两层 LSTM 层、一层全连接层、一层输出层组成,第一层 LSTM 特征提取层的形状为 $[bs, tp, 128]$,第二层 LSTM 特征提取层的形状为 $[bs, tp, 32]$,其中 tp 为采样节点个数。设置 LSTM 神经网络中随机删除节点的比例(Dropout_lstm)为 0.8 ,设置输出层形状为 $[bs, Cy1]$,其中 $Cy1$ 表示输出层节点个数,即信号调制类型类别数,对于 2016.4C 数据集, $Cy1$ 为 11 种;对于 2016.10a 数据集, $Cy1$ 为 11 种;对于 2016.10b 数据集, $Cy1$ 为 10 种;对于 2016.data 数据集, $Cy1$ 为 12 种。设置输出层激活函数为‘softmax’,采用 adam 优化器,设置模型的学习率为 0.0008 。

4.3 实验及分析

4.3.1 实验平台

本文实验均在下述实验平台上进行:i7-7700K 4.20GHzx8(CPU),TITAN Xp 12GiBx2(GPU),16GBx4 memory(DDR4),Ubuntu 16.04(OS),Python 3.5,Tensorflow-gpu-1.3,Tflearn-0.3.2。

4.3.2 自适应确定最优信噪比分类边界

下文仅以 2016.4C 为样例数据集,详细介绍最优信噪比分类边界的确定过程。

(1)以 2016.4C 数据集集中的训练集作为实验数据集,通过 LSTM 神经网络,提取信号特征样本,命名为 Feature_2016.4C。

(2)以 Feature_2016.4C 作为输入,设置聚类类别数为 2,通过 K 均值聚类获得信号特征样本的聚类类标,命名为 Feature_Label。

(3)人工设定 -20 dB 为信噪比分类边界,对原始信号的信噪比进行分类,小于等于 -20 dB 为第一类,设置类标为 1;大于 -20 dB 为第二类,设置类标为 2,获得原始数据类标,命名为 Original_Label。

(4)将原始类标 Original_Label 与聚类类标 Feature_Label 进行对比,计算得到以 -20 dB 为分类边界的分类准确率,获取分类边界准确率的方法为:2016.4C 训练集样本总数为 176000 个,设定 Sum 为准确分类的信号样本总数,并设 Sum 初始值为 0,按顺序逐一比对每一个信号样本的类标信息,若信号的聚类类标与原始分类类标一致,则准确分类的信号样本总数数值加 1($Sum = Sum + 1$);遍历类标矩阵,获得准确分类的信号样本总数 Sum,以 Accuray_SNR 表示信噪比分类准确率,以准确分类的信号样本总数除以总的信号样本个数($Accuray_SNR = Sum / 176000$),即为以 -20 dB 为分界线的信噪比分类准确率。

(5)选取不同的信噪比分类边界,重复步骤(3)、步骤(4),获得每一个信噪比分类边界的分类准确率,选取准确率最高的分类边界为最优信噪比分类边界。以信号样本的信噪比值为 X 轴,以各信噪比值对应的分类准确率为 Y 轴,绘制信噪比分类边界-准确率散点图,顶点所对应的信噪比分类边界即为最优分类边界。

图 6 为 2016.4C 数据集最优信噪比分类边界散点图,由图 6 易得最优信噪比分类边界为 -12 dB,Kmeans 聚类准确率为 99.25% 。




图 6 2016.4C 数据集最优信噪比分类边界散点图
Fig. 6 Optimal SNR classification boundary broken line diagram for 2016.4C Data Set

图 7 为 2016.4C 数据集以 -12 dB 信噪比为分类边界的分类效果散点图,可以明显看到,信号样本点被准确地分为红蓝两类。




图 7 2016.4C 数据集 -12 dB 分类边界下的分类效果散点图
(电子版为彩色)

Fig. 7 Classification effect scatter plot of 2016.4C data set classification boundary(SNR = -12 dB)

按照上述实验方法,依次寻找 2016.10a,2016.10b,2016.data 3 个数据集的最优信噪比分类边界,结果如 4.5.1 节中的表 2 所列。

4.3.3 基于 LSTM 的信噪比分类实验

准确地将信号样本根据高低信噪比分为两类是分级降噪的前提,以 K 均值聚类所确定的最优信噪比分类边界值为信噪比分类边界,给训练集信号样本设定信噪比分类类标。以训练集为输入数据,以信噪比分类类标为训练类标,对 LSTM

分类模型进行训练,获得基于 LSTM 的信噪比分类模型。实验结果如 4.5.1 节中的表 2 所列,其中 2016.4C 数据集的信噪比分类准确率为 100%。

4.3.4 调制类型识别实验

为了检验分级降噪对信号调制类型识别准确率有提升作用,此处做了 3 组对比实验,实验的条件设置如下。

(1)未降噪:所有信号样本均不做降噪处理,对进行调制类型识别,得到信号样本的调制类型识别准确率。

(2)全部降噪:所有信号样本均做滤波降噪处理,进行调制类型识别,得到信号样本的调制类型识别准确率。

(3)分级降噪:对低信噪比信号进行滤波降噪处理,高信噪比信号样本不做处理,再对所有信号样本进行调制类型识别,得到信号样本的调制类型识别准确率。

4.4 对比实验

选取 SVM、KNN、鉴别分析(DAC)、随机森林(RF)分类器在 2016.4C 与 2016.10a 两个数据集上进行实验。为验证分级降噪在机器学习调制类型识别中也有效,选取 SVM 分类器在上述所说的 3 个实验条件(不降噪、部分降噪、全降噪)下进行调制识别实验,实验结果如表 1 所列。实验结果表明,分级降噪对于机器学习识别方法也同样有效,在用 SVM 分类器对 2016.4C 数据集进行调制识别分类时,分级降噪处理过的数据集调制类型识别准确率比未降噪的高 0.08%,对 2016.10a 数据集进行调制识别分类时,分级降噪处理过的数据集调制类型识别准确率比未降噪的高 0.89%。

表 1 机器学习分类器对比实验数据表

Table 1 Comparison experiment data of SVM classifier
(单位:%)

数据集	分类器	Accuracy		
		未降噪	部分降噪	全部降噪
2016.4C	SVM	20.94	21.02	20.86
	KNN	45.65	45.90	44.40
	DAC	17.67	17.89	17.64
	RF	54.71	60.01	57.07
2016.10a	SVM	19.41	20.30	19.26
	KNN	28.04	28.72	27.36
	DAC	19.23	19.54	18.96
	RF	38.80	39.84	39.22

4.5 模型评价指标

4.5.1 信噪比分类实验评价指标

基于信噪比分级的调制类型识别方法,信噪比分类准确率对后续的调制类型识别有着极大的影响,此处选取了 4 个数据集,以最优分类边界作为信噪比分类边界训练信噪比分类模型,识别效果如表 2 所列。

表 2 信噪比分类准确率

Table 2 SNR classification accuracy

数据集	分类边界/dB	Accuracy/%
2016.data	-5	99.07
2016.10a	-5	89.95
2016.10b	-7	95.74
2016.4C	-12	100.00

4.5.2 调制类型识别实验评价指标

将未降噪、部分降噪、全部降噪的数据集分别通过 LSTM 深度神经网络进行调制类型识别,得到 LSTM 网络的调制类型识别准确率。参照 O'Shea 等^[27]于 2017 年发表的文章中

的 CNN 调制识别网络架构进行复现实验,具体结果如表 3 所列。

表 3 深度学习网络调制识别准确率

Table 3 Modulation recognition accuracy of deep learning network

分类器	数据集	最优信噪比 分类边界/dB	Accuracy/%		
			未降噪	部分降噪	全部降噪
LSTM	2016.4C	-12	69.82	70.50	66.67
	2016.10a	-5	57.23	58.02	57.53
	2016.10b	-7	62.17	62.44	62.10
CNN	2016.4C	-12	61.96	/	/
	2016.10a	-5	52.72	/	/
	2016.10b	-7	52.81	/	/

通过对比 3 个数据集在部分降噪、未降噪、全部降噪时的实验结果可以看出,不区分信噪比对整个数据集进行降噪处理会降低整体的调制类型识别准确率,进行分级降噪则可以有效提高整体的调制类型识别准确率,其中 2016.4C 数据集通过分级降噪,调制类型识别准确率提高了 0.74%,2016.10a 数据集调制类型识别准确率提高了 0.79%,2016.10b 数据集调制类型识别准确率提高了 0.27%。相比机器学习的调制类型识别方法(见表 1),本文提出的调制识别方法在识别准确率上有明显提高。相比 O'Shea 提出的 CNN 识别框架,文中的调制识别方法在 3 个数据集的识别准确率均显著提升,其中 2016.4C 数据集提升了 8.6%,2016.10a 数据集提升了 5.3%,2016.10b 数据集提升了 9.63%。

以 2016.4C 数据集为例,选取训练好的未降噪调制类型识别模型对未降噪的测试集进行测试,选取训练好的部分降噪调制类型识别模型对部分降噪的测试集进行测试,选取训练好的全部降噪调制类型识别模型对全部降噪的测试集进行测试,得到不同信噪比值下的调制类型识别准确率,以折线图的形式进行可视化,结果如图 8 所示。




图 8 2016.4C 数据集对比实验准确率图

Fig. 8 Accuracy diagram of comparison experiments on 2016.4C data set

从图 8 中可以看出,随着信号样本 SNR 的下降,信号调制类型识别准确率急剧下降,这也验证了信噪比对信号调制类型识别的巨大影响。在信噪比低于 -12 dB(最优信噪比分类边界)时,分级降噪后的样本识别准确率明显高于未降噪样本的识别准确率,其中信噪比为 -20 dB 的信号样本识别准确率提升了 1.46%,信噪比为 -16 dB 的样本提升了 2.12%,信噪比为 -14 dB 的样本提升了 0.81%,信噪比为 -12 dB 的样本提升了 6.79%。此外,在信噪比大于 -12 dB 并且小于 0 dB 时,全部降噪的信号样本调制类型识别准确率大幅度低于未降噪与分级降噪的信号样本调制类型识别准确率,证实了滤波降噪会损害高信噪比的部分信号,导致其调制类型识别准确率降低。因此,可得结论如下:部分降噪模型不仅对低信噪

比信号的识别准确率有显著的提升,并且不会降低高信噪比信号的识别准确率。

为了能够更明显地观察到低信噪比部分信号调制识别率的提升,特别地将低信噪比部分信号调制识别准确率图放大,如图9所示。

以2016.4C数据集为例,选取信噪比为18dB的不同调制类型信号样本,通过分级降噪的信号调制识别模型进行调制类型识别,获得调制类型识别准确率,并以混淆矩阵的形式进行可视化,具体如图10所示。




图9 2016.4C数据集对比实验准确率(低SNR)

Fig. 9 Accuracy diagram of comparison experiments on 2016.4C data set (Low SNR)




图10 2016.4C数据集调制类型识别结果混淆矩阵图 (SNR=18dB)

Fig. 10 Confusion matrix diagram of modulation type recognition results for 2016.4C data set (SNR=18dB)

结束语 将新兴的深度学习方法与传统的调制类型识别相结合,提升调制类型识别准确率是一个具有较高研究价值的问题。

本文提出的基于信噪比分级的调制类型识别,应用了基于LSTM神经网络与信噪比分级相结合的新型识别方法,有效改善了目前存在的低信噪比部分信号样本调制类型识别准确率低、识别困难的问题,并进行了充足的对比实验。结果表明,基于信噪比分级式调制类型识别模型确实能够有效地提高低信噪比信号样本的调制类型识别准确率,并且验证了对所有信号样本进行降噪反而会降低高信噪比信号样本的调制类型识别准确率。

基于本文方法的应用效果,对于未来调制类型识别的研究方向,将深度学习模型与不同的降噪方法相结合,将传统的识别方法与分级降噪相结合,都具有极大的理论和实践意义。

参考文献

[1] BAO H, WANG Y, CHEN L. Digital Signal Modulation Recognition Equipment Based on High-order Cumulants[C]// Proceedings of the 11th EAI International Conference on Mobile

Multimedia Communications. ICST (Institute for Computer Sciences, Social-Informatics and Telecommunications Engineering), 2018; 290-297.

- [2] MINGQUAN L, XIANCI X, LEMING L. Cyclic spectral features based modulation recognition[C]// Proceedings of International Conference on Communication Technology (ICCT'96). IEEE, 1996, 2: 792-795.
- [3] CAI T, WANG C, CUI G, et al. Constellation-wavelet transform automatic modulation identifier for M-ary QAM signals[C]// 2015 IEEE 26th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications (PIMRC). IEEE, 2015; 212-216.
- [4] YIN C, LI B, LI Y. Modulation classification of MQAM signals from their constellation using clustering[C]// 2010 Second International Conference on Communication Software and Networks. IEEE, 2010; 303-306.
- [5] JIA Y U, CHEN Y. Digital modulation recognition method based on BP neural network[J]. Transducer Microsyst, Technol, 2012, 5(7).
- [6] PETROVA M, MÄHÖNEN P, OSUNA A. Multi-class classification of analog and digital signals in cognitive radios using support vector machines[C]// 2010 7th International Symposium on Wireless Communication Systems. IEEE, 2010; 986-990.
- [7] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks[C]// International Conference on Engineering Applications of Neural Networks. Springer, Cham, 2016; 213-226.
- [8] WEST N E, O'SHEA T. Deep architectures for modulation recognition[C]// 2017 IEEE International Symposium on Dynamic Spectrum Access Networks (DySPAN). IEEE, 2017; 1-6.
- [9] ZHANG D W, DONG J, LIU K, et al. Quality Evaluation of Auto-adaptive Frequency-hopping Channel Based on Receiving Signal-to-noise Ratio Prediction[J]. Ship Electronic Engineering, 2008(4): 76-79.
- [10] CHANG L L, DAI X H, L Y, et al. Signal-to-Noise Ratio Prediction Method for High Speed Mobile Communication System[J]. Journal of Circuits and Systems, 2012, 17(1): 24-30.
- [11] CUI L F, CHENG Y C, YANG C, et al. Prediction of Signal-to-Noise Ratio Based on Genetic Optimized BP Neural Network [J]. China New Communications, 2016(7): 77-77.
- [12] FEI C L, CHENG Y C, YANG C, et al. Application of Particle Swarm Optimization BP Neural Network in Signal-to-Noise Ratio Prediction[J]. China New Communications, 2016(6): 44-44.
- [13] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders; Learning useful representations in a deep network with a local denoising criterion[J]. Journal of Machine Learning Research, 2010, 11: 3371-3408.
- [14] DESIMIO M P, PRESCOTT G E. Adaptive generation of decision functions for classification of digitally modulated signals [C]// Proceedings of the IEEE 1988 National Aerospace and Electronics Conference. IEEE, 1988; 1010-1014.
- [15] GHANI N, LAMONTAGNE R. Neural networks applied to the classification of spectral features for automatic modulation recognition[C]// Proceedings of MILCOM'93-IEEE Military Communications Conference. IEEE, 1993; 111-115.

- [16] LOPATKA J, PEDZISZ M. Automatic modulation classification using statistical moments and a fuzzy classifier[C]//WCC 2000-ICSP 2000, 2000 5th International Conference on Signal Processing Proceedings, 16th World Computer Congress 2000. IEEE, 2000; 1500-1506.
- [17] KIM K, POLYDOROS A. Digital modulation classification: the BPSK versus QPSK case[C]//MILCOM 88, 21st Century Military Communications—What's Possible?'. Conference record, Military Communications Conference. IEEE, 1988; 431-436.
- [18] GULDEMIR H, SENGUR A. Comparison of clustering algorithms for analog modulation classification[J]. Expert Systems with Applications, 2006, 30(4): 642-649.
- [19] WONG M L D, NANDI A K. Automatic digital modulation recognition using artificial neural network and genetic algorithm [J]. Signal Processing, 2004, 84(2): 351-365.
- [20] ZHANG X, GE T. Automatic Modulation Recognition of Communication Signals Based on Instantaneous Statistical Characteristics and SVM Classifier[C]//2018 IEEE Asia-Pacific Conference on Antennas and Propagation (APCAP). IEEE, 2018; 344-346.
- [21] ASLAM M W, ZHU Z, NANDI A K. Automatic modulation classification using combination of genetic programming and KNN [J]. IEEE Transactions on Wireless Communications, 2012, 11(8): 2742-2750.
- [22] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks[C]//International Conference on Engineering Applications of Neural Networks. Springer, Cham, 2016; 213-226.
- [23] O'SHEA T J, HITEFIELD S, CORGAN J. End-to-end radio traffic sequence recognition with recurrent neural networks [C]//2016 IEEE Global Conference on Signal and Information Processing (GlobalSIP). IEEE, 2016; 277-281.
- [24] TANG B, TU Y, ZHANG Z, et al. Digital signal modulation classification with data augmentation using generative adversarial nets in cognitive radio networks[J]. IEEE Access, 2018, 6: 15713-15722.
- [25] HARTIGAN J A, WONG M A. Algorithm AS 136: A k-means clustering algorithm[J]. Journal of the Royal Statistical Society, Series C (Applied Statistics), 1979, 28(1): 100-108.
- [26] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [27] O'SHEA T, HOYDIS J. An introduction to deep learning for the physical layer[J]. IEEE Transactions on Cognitive Communications and Networking, 2017, 3(4): 563-575.



CHEN Jin-yin, Ph.D, associate professor. Her main research interests include artificial intelligence security, graph data mining and evolutionary computing.

(上接第 309 页)

- [4] HU Y, XU Y, WANG X, et al. Cooperative Recovery of Distributed Storage Systems from Multiple Losses with Network Coding [J]. IEEE Journal on Selected Areas in Communications, 2010, 28; 268-276.
- [5] SHUM K W. Cooperative Regenerating Codes for Distributed Storage System [C]//Proceeding of IEEE International Conference on Communications (ICC). 2011.
- [6] KERMARREC A, STRAUB G, SCOUARNEC L. Repairing Multiple Failures with Coordinated and Adaptive Regenerating Codes [C]//Proceeding of International Symposium on Network Coding (NetCod), 2011.
- [7] ZHONG F Y, WANG Y, LI N S. Node Selection Scheme for Data Repair in Heterogeneous Distributed Storage Systems [J]. Computer Science, 2019(8): 35-41.
- [8] WANG L S, TANG X H. Regenerating Codes for New Multi-node Repair Model [J]. Application Research of Computers, 2018(2): 527-531.
- [9] ZHANG H Y, LI H, ZHU B, et al. Minimum Storage Regenerating Codes for Scalable Distributed Storage [J]. IEEE Access, 2017, 5: 7149-7155.
- [10] NETANEL R. Asymptotically Optimal Regenerating Codes over Any Field [J]. IEEE Transactions on Information Theory, 2018, 64(11): 7178-7187.
- [11] MARWEN Z, ZHIYING W. Centralized Multi-node Repair Regenerating Codes [J]. IEEE Transactions on Information Theory, 2019, 65(7): 4180-4206.
- [12] ZHANG G, ZHENG W, SHU J. ALV: A New Data Redistribution Approach to RAID-5 Scaling [J]. IEEE Transactions on Computers, 2010, 59; 345-357.
- [13] ZHANG G, LI K, WANG J, et al. Accelerate RDP RAID-6 Scaling by Reducing Disk I/Os and XOR Operations [J]. IEEE Transactions on Computers, 2015, 64; 32-44.
- [14] RAI B K, DHOORJATI V, SAINI L, et al. On Adaptive Distributed Storage Systems [C]//IEEE International Symposium on Information Theory (ISIT). 2015.
- [15] RAI B K. Adaptive Erasure Code Based Distributed Storage Systems [C]//IEEE 14th Canadian Workshop on Information Theory. 2015.



WANG Xue-bing, born in 1974, associate professor. His main research interests include network communication, information security, intelligent material association and artificial intelligence.