

低信噪比下基于深度学习的调制模式识别方法

陈晋音 成凯回 郑海斌

浙江工业大学信息工程学院 杭州 310000

摘要 无线电信号的调制类型识别是信号检测与解调的中间步骤,已有的研究表明利用深度学习技术能高效地识别无线电信号调制类型。但对于低信噪比区间内识别准确率骤降的问题,仍没有一种较好的解决方案。受到深度学习在图像降噪中的启发,本文提出了低信噪比下基于深度学习的调制模式识别方法,实现了对低信噪比信号的降噪处理,解决了低信噪比区间信号识别准确率过低的问题。通过在开源数据集下的大量实验,验证了本方法的有效性,低信噪比信号调制类型识别的准确率由10%上升至15%。最后,文章对于本方法存在的问题进行分析,并对未来的研究进行了展望。

关键词:深度学习;调制类型自动识别;降噪模型;低信噪比

中图法分类号 TP29

Deep Learning Based Modulation Recognition Method in Low SNR

CHEN Jin-yin, CHENG Kai-hui and ZHENG Hai-bin

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

Abstract Modulation recognition of radio signals is the intermediate step of signal detection and demodulation. The existing research shows that deep learning technology can effectively identify the modulation types of radio signals. As for the low signal-to-noise ratio, there is still no good solution to the problem of the sharp drop in recognition accuracy. Inspired by the noise reduction in image fields, a modulation recognition method based on deep learning in Low SNR was proposed in this paper. It realizes the denoising of the low signal-to-noise ratio signals and solves the problem of the sharp drop. Through a large number of experiments in the open source datasets, the effectiveness of the proposed method was verified. The recognition accuracy of the low signal-to-noise ratio signals increased from 10% to 15%. Finally, we analyze the problems existing in the method and look forward to future research.

Keywords Deep learning, Automatic recognition of modulation type, Denoising model, Low signal-to-noise ratio

1 引言

无线电信号的调制类型识别技术是一项介于信号检测与信号解调之间的技术^[1],通过快速准确的自动识别,可以实现无线电信号的智能接收与处理。在未来的电子对抗战中,实施电子对抗、电子反对抗、威胁侦测、目标搜索与检测等任务,都需要高效的调制类型自动识别技术来分析相关信号参数与性质。但是,无论是传统的调制类型识别方法,还是最近提出的基于深度学习的信号调制类型识别方法,在低信噪比区间内的识别准确率都非常低。针对以上问题,本文提出一种新的低信噪比下基于深度学习的调制模式识别方法,最终目的是提高信号的调制类型识别准确率。

传统的信号降噪方法包括小波降噪法、模极大值降噪法等,这些方法泛化能力低而且需要一定的先验知识。例如,小波变换阈值的确定、小波的选择。基于对数据表征的学习,深度学习可以较好地提取出数据中所隐藏的关键特征量,自动

滤除干扰噪声的影响。凭借其高效的数据处理能力,深度学习在计算机视觉^[2]、自然语言处理^[3]等领域得到了广泛应用。在图像降噪中, Vincent 等^[3]提出了基于卷积神经网络结构的降噪自编码器(denoising autoencoder, DAE),通过对噪声图片的特征映射实现图像的降噪。Tian 等^[4]全面回顾和总结近年来提出的基于深度学习的图像降噪技术。此外,研究人员也将深度学习技术运用到无线电信号调制类型的识别领域中,提出了基于卷积神经网络结构的调制类型识别方法^[5-6]。虽然深度学习技术在无线电信号调制类型识别领域中取得了优良的效果,但其在低信噪比区间的识别效果仍然较差。受到深度学习技术在图像降噪中的启发和无线电信号的时序特性,本文以长短时记忆网络^[7](Long-Short Time Memory, LSTM)为基础结构,提出了低信噪比下基于深度学习的调制模式识别方法,其最终目的是提高信号的调制类型识别准确率。实验结果表明,无线电信号经过该降噪方法处理后,能够更精确地被无线电信号调制类型识别模型分类,能

基金项目:浙江省自然科学基金(LY19F020025);宁波市“科技创新 2025”重大专项资助(2018B10063);基于 GAN 的信号识别项目资助;深度学习增强识别项目资助;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 under Grant (LY19F020025), the Major Special Funding for “Science and Technology Innovation 2025” in Ningbo under Grant (2018B10063) and Signal Recognition Based on GAN, Deep Learning for Enhancement Recognition Project, and Engineering Research Center of Cognitive Healthcare of Zhejiang Province under Grant (2018KFJJ07).

通信作者:陈晋音(chenjinyin@zjut.edu.cn)

够更全面地利用有限的无线电信号的信息资源。

本文的主要贡献如下:

(1)提出了一种低信噪比下基于深度学习的调制模式识别框架,自动识别高低信噪比的信号,并对低信噪比信号进行降噪处理,来提高信号调制类型的整体识别准确率。

(2)设计了基于 LSTM 的无线电信号降噪方法,实现了对低信噪比区间的无线电信号的降噪重构处理,进一步提高了该区间内调制类型识别模型的准确率和稳定性。

(3)本文通过大量的实验证明了低信噪比下基于深度学习的调制模式识别方法对提高调制类型识别准确率的有效性。

本文第 2 节总结了目前的信号调制类型识别方法以及降噪方法;第 3 节介绍了提出的基于深度学习的信号降噪方法;第 4 节阐述了实验的设计和结果分析;最后总结全文并展望未来。

2 相关工作

2.1 无线电信号调制类型识别方法

无线电信号的调制类型识别,是信号检测和解调之间的关键步骤,其目的是在没有先验知识的情况下通过对信号数据的分析,来识别信号的调制类型。传统的无线电信号调制类型识别方法种类较多,基于无线电信号的不同特征属性主要分为:基于瞬时信息的数字调制识别^[8]、基于谱相关特征的调制信号识别^[9-10]、基于高阶累积量特征的调制信号识别^[11]、基于循环累积量特征的调制信号识别^[12]、基于小波变换特征的调制信号识别^[13]、基于复杂度特征的调制信号识别^[14]。

基于瞬时信息的数字调制识别方法^[8],从信号的瞬时幅值、瞬时相位、瞬时频率等方面估计信号参数,实现调制类型识别,并且具有计算简单、适用范围广等优势,但其抗衰弱能力较弱。基于高阶累积量特征的识别方法^[11]具有良好的抗衰弱能力以及抑制高斯噪声的优点,但其计算复杂度较高。谱相关特征的识别方法^[10]通过不同频带之间的相关性,利用信号的时间周期性,能够实现信号的调制类型识别。基于循环累积量特征的调制信号识别方法^[12]利用基带信号的循环平稳特性,构造基于循环累积量的分类特征量并将其推广至循环平稳域,从而实现调制类型的识别。小波变换具有时域局部化和频域局部化的性质以及多分辨分析的特点,能将信号进行不同尺度的分解,利用不同的特征信息,可以实现调制类型的识别。虽然上述传统方法能够较好地实现调制类型的识别,但这些传统的调制类型方法需要先验知识,适用范围受到算法本身的限制,而且计算成本较高。

还有一些基于机器学习的调制类型识别方法:基于聚类算法的调制信号识别^[15-16]、基于 BP 神经网络的调制信号识别^[15]、基于 SVM 的调制信号识别^[9]、基于 KNN 的调制信号识别^[17]、基于随机森林的调制信号识别^[18]。

此外,研究人员们将深度学习技术应用于无线电信号调制类型识别领域,提出了一些基于深度学习的调制类型识别方法,如基于栈式自编码器的自动调制分类技术^[5]、基于深度学习的调制类型快速自动识别方法,实现了对大批量无线电信号数据的调制类型识别。但是,其中使用的卷积神经网络,更擅长处理空间结构的数据,如图像数据。而无线电信号中

更多存在的是时间序列信息,因此本文使用 LSTM 网络作为基础。

2.2 无线电信号的信噪比识别方法

信噪比(signal-to-noise ratio, SNR),是信号中信号与噪声的比例,信号是指外部接收设备所需要的信号,而噪声是指无规律、不随信号改变而改变的额外信号,即加性噪声。信噪比的定义如式(1)所示:

$$SNR = 10 \times \log_{10} \left(\frac{\text{Signal power}}{\text{Noise power}} \right) \quad (1)$$

其中,Signal power 和 Noise power 分别代表信号和噪声的有效功率。

但是,在真实情况下不能获得有效信号和噪声信号的有效功率。对于实测信号的信噪比,通过估计噪声的方差来计算实测信号的信噪比。使用估计方法计算实测信号的信噪比,计算量大,泛化能力低。

因此,本文在低信噪比下基于深度学习的调制模式识别方法框架中,使用了基于 LSTM 的无线电信号分类器识别样本中的低信噪比信号。

2.3 长短时记忆神经网络

在深度学习技术中,典型的神经网络包括卷积神经网络、循环神经网络、全连接神经网络等。循环神经网络^[19]是一种节点定向连接成循环的神经网络,能较好地展示动态时序行为,利用内部的记忆单元可以处理任意时序的输入序列,处理一些时序问题,例如自然语言处理、语音识别等任务。

长短时记忆网络^[7]是一种特殊的循环神经网络。在循环神经网络的基础上,增加输入门限、遗忘门限和输出门限,使权重在自循环过程中变化,而且不同时间节点上的积分尺度可以动态地变化,巧妙地避免了循环过程中产生的梯度消失或者梯度膨胀的问题。因此,利用长短时记忆网络为基础可以构建庞大的循环神经网络,解决复杂的时序问题。

长短时记忆网络(LSTM)解决了循环神经网络中存在的梯度爆炸和梯度消失问题,极大地提高了循环神经网络处理时序问题的能力。

长短时记忆网络的结构如图 1 所示,其核心思想是使用存储单元(细胞)代替神经元。细胞的整个状态如图 1 中的灰色部分所示,细胞在传送带上有序进行信息的传递。单个细胞由 3 个门组成,包括遗忘门、输入门和输出门。

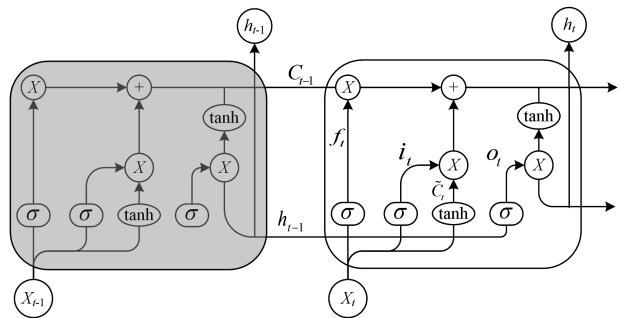


图 1 长短时记忆网络(LSTM)结构示意图

Fig. 1 Architecture of long-short time memory network (LSTM)

遗忘门通过 sigmoid 层来决定细胞中哪些信息需要被丢弃。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

其中, h_{i-1} 表示上一个细胞的输出, x_i 表示当前细胞的输入, f_i 为区间 $[0,1]$ 的数值, 1 表示完全保留, 0 表示完全舍弃, σ 表示 sigmoid 函数:

$$\sigma(x) = \frac{1}{1+e^x} \quad (3)$$

输入门决定信息的更新, 而 tanh 层用来生成备选信息 \tilde{C}_i :

$$i_i = \sigma(W \cdot [h_{i-1}, x_i] + b_i) \quad (4)$$

$$\tilde{C}_i = \tanh(W_C \cdot [h_{i-1}, x_i] + b_C) \quad (5)$$

$$C_i = f_i * C_{i-1} + i_i * \tilde{C}_i \quad (6)$$

上式中, C_i 表示当前细胞状态; i_i 为区间 $[0,1]$ 的数值, 用于决定哪些信息需要更新, 1 表示完全保留, 0 表示完全舍弃, tanh 层的具体计算如下:

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

基于当前细胞的状态, 细胞的输出门输出相应的内容:

$$o_i = \sigma(W_o [h_{i-1}, x_i] + b_o) \quad (8)$$

$$h_i = o_i * \tanh(C_i) \quad (9)$$

2.4 无线电信号存在的干扰噪声

无线电信号的噪声是信号中的无用信息部分, 噪声干扰会造成信号的失真, 影响调制类型识别器的分类准确性。按照噪声与信号的关系可以分为加性噪声 s_1 和乘性噪声 s_2 , 公式如下:

$$s_1 = s(t) + n(t) \quad (10)$$

$$s_2 = s(t)[1 + n(t)] \quad (11)$$

其中, $s(t)$ 表示信号信息, $n(t)$ 表示噪声。加性噪声独立于信号并且始终存在, 乘性噪声随信号的存在而存在。

在无线信号传输过程中很容易产生干扰信号(噪声), 影响无线电信号调制类型识别的准确性。因此, 提出一种有效的无线电信号降噪方法十分必要。

2.5 基于小波变换的信号降噪

小波变换是一种无线电信号的频率分析方法^[20]。与传统的傅里叶变换分析相比, 小波变换具有时域局部化和频域局部化等优点, 可以实现信号在不同尺度下的分解, 保留不同调制类型下信号的特征。连续的小波变换函数的定义如下:

$$F(a, b) = \int x(t) \psi_{(a,b)}^*(t) dt \\ = \frac{1}{\sqrt{a}} \int x(t) \psi^*\left(\frac{t-b}{a}\right) dt \quad (12)$$

其中, a 为尺度因子, b 为平移因子, $*$ 表示复共轭, $\psi(t)$ 表示小波函数且满足容许性条件:

$$W_\psi = \int_{-\infty}^{+\infty} \frac{|\psi(\omega)|}{|\omega|} d\omega < \infty \quad (13)$$

其中, $\psi(\omega)$ 表示函数 $\psi(t)$ 的傅里叶变换, $\psi_{(a,b)}(t)$ 表示小波函数 $\psi(t)$ 经过伸缩平移后得到的基波函数:

$$\psi_{(a,b)}(t) = a^{-1/2} \psi\left(\frac{t-b}{a}\right) \quad (14)$$

信号在空间或时间上具有一定的连续性, 其有效信号在小波域的小波系数较大, 而噪声信号在空间或时间上一般呈现离散状态, 其在小波域内的小波系数较小。利用这一性质, 可以通过小波变换的方法来实现对信号的降噪处理。小波阈值降噪法的具体流程如图 2 所示。



图 2 小波阈值降噪法框图

Fig. 2 Block diagram of wavelet threshold denoising method

对输入的原始信号进行小波分解处理, 计算得到不同的小波系数, 假设噪声信号服从高斯分布, 那么绝大部分的噪声系数都会位于 $[-3\sigma, 3\sigma]$ 区间内, 将该区间内的系数置零, 以实现噪声信号最大程度的抑制。利用阈值处理后的小波系数, 实现无线电信号重构, 得到降噪后的信号。

2.6 基于卷积神经网络的自编码器

自编码器(Auto-encoder, AE)一般由三层网络构成, 包括输入层、隐藏层和输出层, 其中输入层与输出层的神经元数量相等。在训练过程中, 对于每一个输入样本, 自编码器都会产生一个相同尺寸的输出样本, 自编码器训练的优化目标就是使输出样本与输入样本尽可能接近, 损失函数可以设计为:

$$L(x, z) = \|x - z\|^2 \quad (15)$$

其中, x 表示输入样本, z 表示输出样本。

在自编码器的基础上, 研究人员提出降噪自编码器(Denoising Auto-encoder, DAE)^[7], 在输入数据中加入噪声信号, 使训练得到的自编码器具有降噪功能, 同时更具鲁棒性, 提高了模型的泛化能力。

3 低信噪比下基于深度学习的调制模式识别方法

3.1 主要思想

现有的基于深度学习的无线电信号调制类型识别方法, 对大批无线电信号数据的调制类型识别具有良好的识别效果, 但在低信噪比区域, 这些调制类型识别方法的识别准确率仍然较低。针对上述问题, 本文提出了一种基于深度学习的无线电信号降噪重构方法。

本文设计了低信噪比下基于深度学习的调制模式识别方法, 如图 3 所示, 主要包括低信噪比分类器、降噪自编码器以及调制类型识别网络。其中低信噪比分类器的本质是一个二分类器, 通过设置不同的信噪比阈值, 能够识别信噪比中的高信噪比信号与低信噪比信号。降噪自编码器能够实现对低信噪比无线电信号的降噪处理。调制类型识别网络由 LSTM 网络构成, 能够识别所输入无线电信号的调制类型。

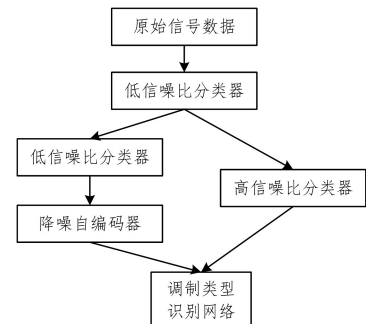


图 3 低信噪比下基于深度学习的调制模式识别方法结构框图

Fig. 3 Architecture of deep learning based modulation recognition method in low SNR

3.2 基于 LSTM 的无线电信号调制类型识别模型

受长短时记忆神经网络的启发, 本文设计了基于长短时

记忆网络的无线电信号调制类型识别模型,具体结构如图4所示。图4中,输入的原始信号尺寸为 $len * 2$,其中 len 表示采样节点数,2表示某一采样节点的时间维度。LSTM(128)表示将输入数据的时间维度映射到尺寸为 $len * 128$ 的特征空间中。FC(11)表示全连接网络,将输入数据映射到11个分布区域,其中11是由训练数据集调制类型种类所确定的。LSTM层采用 \tanh 作为激活函数,dropout为0.8。全连接层使用 softmax 作为激活函数,训练采用交叉熵作为损失函数,选择学习率为0.001的Adam作为优化器,batch size为64,epoch为20。选择 top_one 作为模型的评价指标,即仅当最高置信度所对应的类标为正确类标时,模型识别正确。




图4 基于长短时记忆网络的无线电信号调制类型识别模型
Fig. 4 Radio signal modulation recognition model by LSTM

利用长短时记忆网络从无线电信号数据中提取数据的特征信息,根据该特征信息实现对于不同调制类型信号的分类。根据基于长短时记忆网络的无线电信号调制类型识别模型对无线电信号降噪前后的调制类型识别准确率的对比,来判断该降噪重构模型的降噪效果。

3.3 低信噪比分类器

在高信噪比区域内,调制类型识别模型已具备良好的分类效果,但在低信噪比区间内的识别准确率极低。因此,需要对低信噪比区间内的无线电信号进行降噪处理,以提高调制类型识别模型的识别区间的准确率。

对低信噪比信号进行降噪处理,首先需要从信号数据中提取低信噪比信号。为了更加准确地筛选出低信噪比信号,本文设计了基于LSTM的无线电信号分类器,用以低信噪比信号的降噪处理,具体结构如图5所示。




图5 基于LSTM的无线电信号分类器
Fig. 5 Radio signal classifier with LSTM

图5中,输入的信号尺寸为 $len * 2$,其中 len 表示采样节点数,2表示某一采样节点的时间维度。LSTM(32)表示将输入数据的时间维度映射到尺寸为 $len * 32$ 的特征空间中。LSTM层采用 \tanh 作为激活函数,dropout为0.8。FC层即为全连接层,采用 softmax 作为激活函数。训练采用交叉熵

作为损失函数,选择学习率为0.008的Adam作为优化器,batch size为64,epoch为20。

利用低信噪比分类网络可以将无线电信号映射到高信噪比与低信噪比两个区间,实现基于LSTM的无线电信号二分类任务。

3.4 基于自编码技术的无线电信号降噪方法

在无线电信号调制类型识别中,信号的信噪比越大,噪声对信号的影响越小,无线电信号调制类型的识别准确率就越高。现有的一些基于深度学习的无线电信号调制类型识别方法^[4-5],实现了对高信噪比无线电信号数据的调制类型的准确识别,但低信噪比区域的低准确率仍然是个难以解决的问题。针对上述问题,本文提出了一种基于自编码技术的无线电信号降噪方法,具体结构如图6所示。图6中,输入的信号尺寸为 $len * 2$,其中 len 表示采样节点数,2表示某一采样节点的时间维度。LSTM(32)表示将输入数据的时间维度映射到尺寸为 $len * 32$ 的特征空间中。LSTM层采用 \tanh 作为激活函数,dropout为0.8。通过样本时间维度的伸缩变换实现对低信噪比信号的降噪处理。

训练过程中,在高信噪比信号中加入高斯白噪声得到所需的低信噪比信号,将原始信号及加噪信号同时输入到图6所示的模型中。训练采用均方误差作为损失函数,选择学习率为0.001的Adam作为优化器,batch size为64,epoch为20。




图6 基于自编码技术的无线电信号降噪模型
Fig. 6 Radio signal denoising model based on AE

4 实验结果及分析

4.1 实验设置与评价指标

实验平台环境为:i7-7700K 4.20GHzx8 (CPU),TITAN Xp 12 GiBx2 (GPU),16 GB×4 内存 (DDR4),Ubuntu 16.04 (操作系统),Python 3.5, Tensorflow-gpu-1.3 (深度学习框架),Tflearn-0.3.2。

为了证明基于深度学习的无线电信号降噪重构方法的有效性,我们分别测试了低信噪比无线电信号在降噪前后的调制类型识别准确率。

实验中,以识别准确率为生成的降噪自编码器的评价标准,识别准确率 ACC 为:

$$ACC = \frac{N}{N_c} \quad (16)$$

其中, N 表示准确识别的样本数量, N_c 表示测试样本的总数量。以扰动的2-范数作为降噪前后噪声的评价标准:

$$\|x\|_2 = \sqrt{\sum_{i=1}^N x_i^2} \quad (17)$$

其中, N 表示样本尺寸, i 表示每个采样点。

4.2 数据集和对比方法

本文使用了 Deep-Sig 团队的 04C 数据集¹⁾,该数据集包括了 11 种广泛应用的无线电信号调制类型: BPSK, QPSK, 8PSK, 16QAM, 64QAM, BFSK, CPFSK, PAM4, WB-FM, AM-SSB, AM-DSB。该数据集被划分为两个子集: 训练集和测试集。训练集有 132000 个训练样本, 测试集有 33000 个测试样本, 每个样本的尺寸为 [128, 2]。每类调制类型的样本数量相同, 每类样本中含有 20 种不同的信噪比无线电信号数据 (SNR = -20 + 2n)。我们对上述的数据集进行了预处理操作, 对数据集进行了归一化:

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (18)$$

4.3 低信噪比分类器

利用图 5 所示的低信噪比分类网络, 将无线电信号数据映射到低信噪比与高信噪比两个区域中, 实现低信噪比无线电信号的提取。我们选取了不同的信噪比作为区分高低信噪比信号的标准并进行测试, 统计结果如表 1 所列。

表 1 低信噪比分类器的分类结果

Table 1 Accuracy of radio signal classifier with LSTM

高低信噪比 分类边界	ACC	
	训练集	测试集
-15DB	0.877	0.850
-10DB	0.865	0.860
-5DB	0.913	0.905
0DB	0.904	0.897

根据实验结果可知, 所设计的低信噪比分类器能够准确地提取出数据集中的低信噪比信号, 并且具有一定的泛化能力。

4.4 无线电信号调制类型识别

为了更好地证明该基于深度学习的无线电信号降噪模型的通用性, 本文使用 4.2 节中所描述的数据集进行验证。利用训练集对图 4 所示的基于 LSTM 的无线电信号调制类型识别模型进行训练。在训练过程中, 采用交叉熵作为损失函数, 学习率为 0.001, 选择 Adam 作为优化器, batch size 为 64, epoch 为 20。训练结束之后, 我们将测试集输入到模型中, 得到不同信噪比 (SNR) 下的调制类型识别结果。由于数据集中的信噪比变化范围较大, 本文将其划分为 4 个区间, 统计不同信噪比下无线电信号调制类型识别模型的准确率。识别效果如表 2 所列, 从总体数据来看, 该无线电信号调制类型识别模型在高信噪比区域能够达到 90% 的识别准确率, 识别准确率较高, 基本可以准确识别高信噪比信号的调制类型。

表 2 基于 LSTM 的无线电信号调制类型识别模型的识别结果

Table 2 Result of radio signal modulation recognition model

SNR	ACC	
	训练集	测试集
10DB~18DB	0.891	0.883
0DB~8DB	0.881	0.862
-10DB~-2DB	0.573	0.542
-20DB~-10DB	0.133	0.122

图 7 与表 1 显示了基于 LSTM 的无线电信号调制类型识别模型对于 33000 个测试样本进行调制类型识别的统计结果。




图 7 基于 LSTM 的无线电信号调制类型识别模型的识别结果


Fig. 7 Accuracy of radio signal modulation recognition model by LSTM

由实验结果可知, 基于 LSTM 的无线电信号调制类型识别模型能够准确识别 SNR ≥ 0 dB 的无线电信号的调制类型。但当 SNR < 0 dB 时该无线电调制类型识别模型的识别准确率会骤降, 尤其是当 SNR < -14 dB 模型时的识别准确率仅为 10%。

4.5 基于自编码技术的无线电信号降噪重构模型

针对低信噪比区域内的识别准确率较低的问题, 本文提出了基于自编码技术的无线电信号降噪模型, 具体结构如图 6 所示。本文利用了 4.1 节中所介绍的数据集对模型进行训练, 并通过调制类型识别模型测试了该模型的降噪重构效果。

在高信噪比信号中加入服从高斯分布的白噪声, 将这些含有加性噪声的信号和原始高信噪比信号输入到降噪模型进行训练。使用训练完毕的降噪模型, 实现对低信噪比信号的降噪重构处理。



(a) 降噪前

(b) 降噪后

图 8 基于自编码技术的无线电信号降噪模型的实验结果

Fig. 8 Example of radio signal denoising model based on AE

我们以 SNR = -12 dB 为高低信噪比信号的分类标准, 将低于该信噪比的无线电信号进行降噪重构处理。利用重构后的信号对调制类型识别模型进行重训练, 并与图 2 所示的小波阈值降噪方法进行比较。具体结果如表 3、表 4 所列。实验中采用 Donoho 与 Johnstone 提出的基于噪声数据分布以及最佳基的自适应方法^[21-23] 计算每一个通道的小波降噪的阈值系数并保留近似系数, 利用计算所得小波阈值系数实现对信号的小波降噪处理。

表 3 无线电信号降噪模型前后调制类型识别准确率的实验结果

Table 3 Recognition accuracy before and after the radio signal

SNR	denoising		
	原始信号	自编码器 降噪重构后	小波阈值 降噪后
-12DB	0.169	0.155	0.167
-14DB	0.124	0.154	0.115
-16DB	0.125	0.154	0.120
-18DB	0.095	0.152	0.102
-20DB	0.099	0.154	0.099

¹⁾ <https://www.deepsig.io/datasets/>

表4 无线电信号降噪模型降噪的实验结果

Table 4 Result of radio signal denoising model based on AE

	噪声的 2-范数	
	训练集	测试集
降噪前	119.10	119.37
降噪后	8.30	8.33

根据实验结果可知,本文提出的基于自编码技术的无线电信号降噪重构方法能够更加充分地利用有限的信号资源,并一定程度地提升无线电信号调制类型识别模型在低信噪比区间内的识别准确率。

结束语 无线电信号技术,是经济持续发展的基础保障,无线电信号识别技术的自动化与智能化,能够为我国社会发展注入强大的动力。本文针对深度学习模型在低信噪比区域内识别精度较低的问题,结合自编码器技术,提出了一种自编码技术的无线电信号降噪重构模型方法,一定程度上能够提高基于深度学习的调制类型识别模型在低信噪比区间内的识别精度,能更充分地利用有限的信号资源。

本文首先通过 LSTM 构建无线电信号调制类型识别模型对不同信噪比的无线电信号进行调制类型识别,通过低信噪比分类器实现基于 LSTM 的无线电信号二分类任务,随后基于自编码技术构建无线电信号降噪重构模型,实现对低信噪比无线电信号的降噪重构工作,最后使用降噪重构后的数据对调制类型识别模型进行重训练,并进行测试。

由实验结果可知,本文提出的基于自编码技术的无线电信号降噪重构模型在公开数据集上取得了较好的效果,能够提高基于深度学习的调制类型识别模型在低信噪比区间内的识别准确率。在本文方法的研究过程中也发现了许多不足之处,如降噪效果还有待提高、低信噪比分类器的分类准确率欠佳等,都有待进一步的改进。

但基于本文的实验结果,对于未来将自编码技术应用于无线电信号降噪领域是具有极大理论与实践意义的。

参 考 文 献

- [1] TENG W L, ZHAO M S, HU M. A Novel Method for Classification of MPSK Signals[J]. Telecommunication Engineering, 2004, 44(2): 47-49.
- [2] GIRSHICK R B. Fast R-CNN[C]//International Conference on Computer Vision. 2015:1440-1448.
- [3] VINCENT P, LAROCHELLE H, BENGIO Y, et al. Extracting and composing robust features with denoising autoencoders [C]// International Conference on Machine Learning. 2008: 1096-1103.
- [4] TIAN C, XU Y, FEI L, et al. Deep learning for image denoising: a survey[C]//International Conference on Genetic and Evolutionary Computing. Springer, Singapore, 2018: 563-572.
- [5] ALI A, YANGYU F, LIU S, et al. Automatic modulation classification of digital modulation signals with stacked autoencoders [J]. Digital Signal Processing, 2017: 108-116.
- [6] RAMJEE S, JU S, YANG D, et al. Fast Deep Learning for Automatic Modulation Classification [J]. arXiv <https://arxiv.org/abs/1901.05850>.
- [7] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [8] HU Y Q, LIU J, TAN X H. Digital modulation recognition based on instantaneous information[J]. The Journal of China Universities of Posts and Telecommunications, 2010, 17(3): 52-90.
- [9] TENG X, TIAN P, YU H. Modulation classification based on

spectral correlation and SVM[C]//2008 4th International Conference on Wireless Communications, Networking and Mobile Computing. IEEE, 2008: 1-4.

- [10] FEHSKE A, GAEDDERT J, REED J H. A new approach to signal classification using spectral correlation and neural networks [C]//First IEEE International Symposium on New Frontiers in Dynamic Spectrum Access Networks, 2005. DySPAN 2005. IEEE, 2005: 144-150.
- [11] WU H, SAQUIB M, YUN Z, et al. Novel Automatic Modulation Classification Using Cumulant Features for Communications via Multipath Channels [J]. IEEE Transactions on Wireless Communications, 2008, 7(8): 3098-3105.
- [12] DOBRE O A, BAR-NESS Y, SU W. Higher-order cyclic cumulants for high order modulation classification[C]//IEEE Military Communications Conference, 2003. MILCOM 2003. IEEE, 2003, 1: 112-117.
- [13] AVCI E, HANBAY D, VAROL A. An expert Discrete Wavelet Adaptive Network Based Fuzzy Inference System for digital modulation recognition [J]. Expert Systems with Applications, 2007, 33(3): 582-589.
- [14] ZENG D, XIONG H, WANG J, et al. An Approach to Intra-Pulse Modulation Recognition Based on the Ambiguity Function [J]. Circuits, Systems, and Signal Processing, 2010, 29(6): 1103-1122.
- [15] LIU A S, ZHU Q. Automatic modulation classification based on the combination of clustering and neural network [J]. The Journal of China Universities of Posts and Telecommunications, 2011, 18(4): 13-38.
- [16] GULDEM R H, SENGUR A. Comparison of clustering algorithms for analog modulation classification [J]. Expert Systems with Applications, 2006, 30(4): 642-649.
- [17] 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.
- [18] WANG X, GAO Z, FANG Y, et al. A Signal Modulation Type Recognition Method Based on Kernel PCA and Random Forest in Cognitive Network [C]//International Conference on Intelligent Computing, 2014: 522-528.
- [19] PHAM V, BLUCHE T, KERMORVANT C, et al. Dropout Improves Recurrent Neural Networks for Handwriting Recognition [C]//International Conference on Frontiers in Handwriting Recognition, 2014: 285-290.
- [20] LIU Q J, CHEN G M, LIU X F, et al. Application of FFT and Wavelet in Signal Denoising [J]. Journal of Data Acquisition & Processing, 2009, 24(S1): 58-60.
- [21] DONOHO D L. De-noising by soft-thresholding [M]. IEEE, Trans. on Inf. Theory, 1995, 41(3): 613-627.
- [22] DONOHO D L, JOHNSTONE I M. Ideal spatial adaptation by wavelet shrinkage [J]. Biometrika, 1994, 81: 425-455.
- [23] DONOHO D L, JOHNSTONE I M. Ideal de-noising in an orthonormal basis chosen from a library of bases [J]. Comptes Rendus de l'Académie des Sciences-Series I-mathematics, 1994, 319: 1317-1322.



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