

DOI: 10.13382/j.jemi.B2003019

基于波形优化的深度调制识别方法*

杨小洪¹ 余春泉²

(1. 江西科技学院 信息工程学院 南昌 330098; 2. 江西应用科技学院 实训中心 南昌 330100)

摘要:自动调制识别技术,可在接收信号在样式未知、内容未知的前提条件下,自动对其调制方式进行估计。提出一种基于深度学习的调制识别方法,该方法通过波形优化的方法迭代更新滤波器参数,对接收信号样本进行滤波,再通过深度识别网络进行识别。该方法在处理流程中存在识别结果对滤波器参数的反馈回路,能够减轻信道对调制识别结果的不利影响。通过开源数据集进行验证,证明了该方法相比于几种利用经典深度学习网络的方法,识别率均有所提高。特别是相比于传统的 CNN 方法,识别率提高了约 7%。

关键词:调制识别;深度学习;波形优化

中图分类号: TP391; TN98 **文献标识码:** A **国家标准学科分类代码:** 510.51040

Waveform optimization based automatic modulation recognition

Yang Xiaohong¹ Yu Chunquan²

(1. College of Information Engineering, Jiangxi University of Technology, Nanchang 330098, China;

2. Experimental Training Center, Jiangxi College of Application Science and Technology, Nanchang 330100, China)

Abstract: Automatic modulation recognition (AMR) can automatically estimate the modulation type under the condition that the signal is unknown at all. A deep learning based AMR is proposed. The proposed method can update the filter taps through waveform optimization, which can filter the signal samples in order to overcome the unfavorable effects of the transmission channels. In the proposed method, a feedback path exists between the recognition network and the inverse-channel filter. According to the experiments from an open-source dataset, the proposed feedback-structured method can increase the recognition rate compared with the traditional deep learning methods. Specially, compared with the CNN based method, the recognition rate has increased by about 7%.

Keywords: modulation recognition; deep learning; waveform optimization

0 引言

自动调制识别技术,在接收信号未样式未知、内容未知的前提条件下,可自动对其调制方式进行识别。在当前物联网应用处于铺开阶段,频谱资源紧缺的条件下,频谱感知是动态频谱接入(dynamic spectrum access, DSA)的基础条件。而自动调制识别是频谱感知技术中重要的一环,是当前研究的热点。虽然调制识别的研究历史较长,但是随着信号调制种类的增加,宽带的调制识别需求,对识别率更高的需求,当前仍然是研究的热点与

难点。

整体来说,调制识别技术分为两种,基于似然函数的识别方法与基于特征的识别方法。其中,基于似然函数的方法出现较早,通过寻找接收信号在不同调制方式假设下的似然函数的最大值,进行调制识别。该识别方式中,由于需要计算似然函数,通常要估计出信号的一些先验信息,如载频、码率等。由于对不同的假设条件下,都需要进行不同的参数估计,计算似然比,因此,该方法的复杂度较高,不适合多调制方式集合的识别。

当前较为普遍的方法是基于特征的方法,该方法有着明确清晰的过程。即先提取接收信号的特定特征,形



成特征向量,再根据一定的分类器对该特征向量进行分类。该类方法基于机器学习的理论,可以通过数据的积累改进调制识别的效果。传统的特征分类方法中,所提取的特征通常是信号理论中有明显意义的物理量,如高阶谱特征、瞬时特征、星座图特征等,而提高识别率的主要途径是寻找更好地分类器,如决策树(decision tree)分类器、支撑向量机(support vector machine, SVM)分类器等。随着深度学习在图像处理、自然语言处理(natural language processing, NLP)领域的成功应用,也逐渐拓展至信号处理领域。然而,当前深度学习在信号领域的应用较为有限,主要集中在信号识别领域,如文献[1]的(orthogonal frequency division multiplexing, OFDM)信号的识别;文献[2-3]的对信号指纹(设备指纹)的识别;文献[4-6]的调制识别等。

当前基于深度学习的调制识别主要存在如下几种方法。文献[6]利用通信信号中的基带时域信号作为信号样本,研究了不同种类的、不同层数的深度学习网络对调制识别的影响。如经典的残差网络(residual networks, ResNet),卷积长短时网络(convolutional long short-term deep neural networks, CLDNN),普通的卷积神经网络(convolutional neural network, CNN)等经典网络。文献研究了如何将经典的神经网络用于调制识别,并且研究了网络中一些超参数,如层数等对识别率的影响。文献[7]提出一种新的(radio transformer network, RTN)结构,借鉴了图像处理中的变换网络结构,引入了注意力机制,提高了识别率。文献[8]同样利用了基带信号的时域采样点作为样本进行调制识别,同样对传统的神经网络结构进行了改进。将3个通道的输入(分别是I、Q路与IQ联合)到3个不同的特征提取网络中,再通过全联接层进行调制识别。由于该结构能够更充分地利用不同通路的特点,因此文献[8]的调制识别结果相比于文献[4-6]准确率更高。文献[9]利用了信号的星座图作为输入,利用卷积神经网络进行调制识别。由于直接利用星座图,相当于在原始的信号上进行了一定的特征提取,存在一定的信息损失,因此该方法应用受限,文献[9]仅描述了其对4QAM, 16QAM和64QAM三种信号的调制识别。文献[10]提出将深度学习的方法与普通的特征分类的方法结合,结合深度网络的所提取的特征与普通的循环谱变换或小波变换特征,使得识别率比单一依赖深度学习或变换特征的方法,识别率有所提高。

以上方法通过改变深度学习的网络结构,或者改变训练样本的输入情况,从而达到更好提取调制类型中的有效特征,从而提高识别率。然而,在实际情况中,相同的调制信号在经过射频发射,通过信道,再接收的过程中,由于受到信道的影响(如衰落等),使得调制信号的某些特征被淹没,从而降低了调制识别的准确率。由信

道带来的识别率的降低问题,可通过提高不同信道条件下的样本数量解决。然而,由于信道的情况较为复杂,无法通过提高样本数据量的方式对信道的情况进行学习。另一种解决方案是,利用新信道条件下采集的样本进行重新训练。然而由于信道随时间变化,重新训练的代价较高,所需的时间较长,不利于实际的应用。

受到信号指纹识别方法^[2,11-12]的启发,本文提出一种基于波形优化的调制识别方法,该不需要对神经网络进行重新训练。该方法依赖基于反馈的深度学习调制识别模型,通过波形优化的方法得到信道滤波逆波器,在信号输入调制识别网络前,通过滤波器后,减少信道对调制识别的影响,从而提高识别率。该方法的最大特点是,在不同的信道传播实际情况中,不需要对已经得到的神经网络进行重新训练,也能使识别结果较少受到信道的影响,从而提高整体识别率。通过开源的数据集(根据本文的需求进行了重新生成)进行网络的训练与测试后,证明了本文提出的基于波形优化的方法相比于 SCC-CNN, CLDNN, CNN, ResNet 这几种直接用深度学习网络进行识别的方法,识别率分别提高了约4%、6%、7%和15%。

1 方法

为了减少不同的信道带来的对识别率的影响,本文提出在将信号样本送入神经网络之前,先通过一个有限长冲激响应(finite impulse response, FIR)滤波器。该滤波器能够对信号样本进行滤波,从而在一定程度上抵消信道带来的衰落等不利影响。考虑到信道是时变的,因此该滤波器的参数应当产生相应的变化。本文提出的方法的整体结构如图1所示,在信号样本与深度调制识别网络之间加入了一个FIR滤波器,用 $h[n]$ 表示。此处所用到的信号样本是原始信号经过信道后得到。

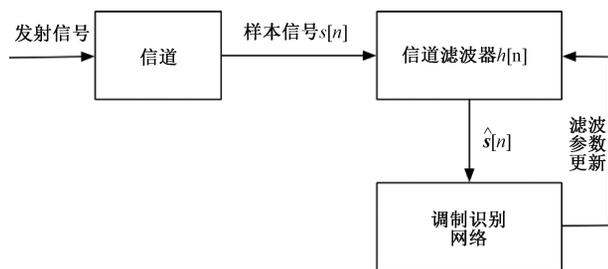


图1 方法整体结构

Fig. 1 The overall structure of the proposed modulation recognition model

其中 $s[n]$ 表示信号样本,而 $h[n]$ 表示信道滤波器。信号样本经过设计的滤波器 $h[n]$ 后,目标是抵消掉信道的不利影响,得到滤波后的样本信号 $\hat{s}[n]$,再通过深度神经网络进行调制识别。为了对FIR滤波器的参数进行调



整,在调制识别的结果与设计的 FIR 滤波器中形成反馈。通过波形优化的方法对设计的 FIR 滤波器参数进行调整,从而尽量抵消掉信道带来的不利影响。调制识别后,若仍需要对信号进行后续的解调等操作,需要对设计的滤波器进行逆滤波,从而保证解调出的码元受到滤波的影响较小。

该方法的优点是,可以根据识别网络的反馈结果对滤波器的参数进行调整,从而减轻信道衰落等因素带来的对识别的不利影响。并且,由于能够根据反馈对信道影响进行逆滤波,使得在实际情况信道变化时,不需要对识别网络进行重新训练,利于快速识别。该方法的关键是,如何通过识别网络的反馈对信道逆滤波器参数进行调整,即如何进行波形优化。

1.1 波形优化方法

波形优化的流程如图 2 所示,识别网络将识别的输出 $g(\hat{s})$ 与计算得到的输出相对于波形参数的偏导数 $\nabla_h g(\hat{s})$ 作为输入,送入到波形优化模块。波形优化模块根据 $g(\hat{s})$ 与 $\nabla_h g(\hat{s})$ 对波形参数进行迭代调整,从而对本信号进行 FIR 滤波。图 2 用不同的序号标出了波形优化过程中最主要的几个过程。

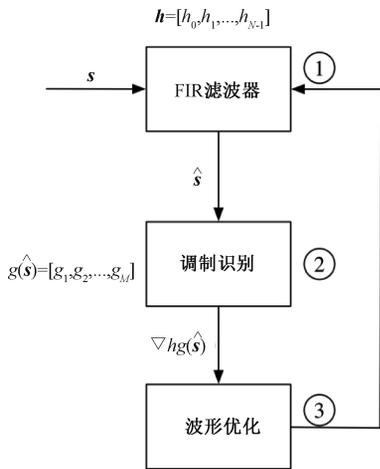


图 2 波形优化或滤波器参数更新流程

Fig. 2 Waveform optimization or filter taps update process

1) FIR 滤波

普通的 FIR 滤波过程可以用如下方式进行表示:

$$\hat{s}[n] = \sum_{i=0}^{N-1} h_i s[n-i] \quad (1)$$

式中: $\mathbf{h} = [h_0, h_1, \dots, h_{N-1}]$ 为滤波器的参数; $s[n]$ 为原始的样本信号; N 为滤波器的阶数。然而,由于本文的样本信号是利用 IQ 路表示的时域信号(本质上是复数表示),因此对该信号进行 FIR 滤波,要求 FIR 滤波器的参数也是复数。假设滤波器参数仍然用 $\mathbf{h} = [h_0, h_1, \dots, h_{N-1}]$ 表示,但是 h_i 用复数表示,式(1)可以改写为:

$$\hat{s}[n] = \sum_{k=0}^{N-1} (h_k^R + j h_k^I) (s^R[n-k] + j s^I[n-k]) = \hat{s}^R[n] + j \hat{s}^I[n] \quad (2)$$

式中: $s^R[n]$ 和 $s^I[n]$ 分别表示滤波后信号的实部与虚部; h_k^R 和 h_k^I 分别表示滤波器参数的实部与虚部。式(2)给出了,当输入样本为 IQ 两路的复数时,仍然可以通过 FIR 滤波器的复数参数对其进行滤波。

2) 信号调制方式识别

经过 FIR 滤波的样本信号 $\hat{s}[n]$, 需要经过调制识别神经网络进行调制识别。该调制识别网络的输出可以表示为一个向量:

$$g(\hat{s}) = [g_1, g_2, \dots, g_M] \quad (3)$$

式中: $g(\cdot)$ 表示识别网络正向识别过程,可以用函数表示,该向量的长度 M 为样本信号的不同调制方式的种类数目;向量 g_i 表示识别网络的识别结果中调制方式 i 所对应的概率。

滤波器参数的更新原则如下:

$$\underset{\mathbf{h}}{\text{maximize}} = \frac{1}{L} g_i(\hat{s}, \mathbf{h}) \quad (4)$$

根据最大化对应的调制方式的识别率的均值作为目的对滤波器的参数进行更新。其中 L 表示一个批次(batch)的调制方式为 i 的样本数目,由于单个样本的识别率的变化较为随机,因此利用多个样本的平均值,对滤波器的参数进行更新。除了避免对滤波器参数的错误更新,该方式的另一个优点是,可以避免对滤波器参数过快地更新,从而减少了计算量,使得本方法适用性更强。

3) 滤波器参数更新

目标函数确定后,可以根据迭代优化的方法对滤波器参数进行更新。更新时,需要获取识别网络的识别精度对滤波器参数的偏导数:

$$\nabla_h g(\hat{s}) = J_g(\mathbf{h})^T \nabla_s g(\hat{s}) \quad (5)$$

根据求导的链式法则,偏导数 $\nabla_h g(\hat{s})$ 可以表示为雅可比矩阵 $J_g(\mathbf{h})^T$ 与导数 $\nabla_s g(\hat{s})$ (表示识别率对信号样本的导数)的乘积。将该式进行展开后,结合复数滤波的公式(式(2)),可以得到:

$$\frac{\partial g(\mathbf{s}, \mathbf{h})}{\partial h_n^P} = \sum_{k=1}^K \left(\frac{\partial g(\mathbf{s}, \mathbf{h})}{\partial s^R[k]} \frac{\partial s^R[k]}{\partial h_n^P} + \frac{\partial g(\mathbf{s}, \mathbf{h})}{\partial s^I[k]} \frac{\partial s^I[k]}{\partial h_n^P} \right) \quad (6)$$

式中:上标 P 表示取实部 R 或虚部 I; K 表示输入样本序列的长度;并且 $n = 0, 1, \dots, N-1$ 表示对滤波器参数序号的变化。根据式(6),可以求对滤波器的每个参数的导数,其中 $\frac{\partial s^R[k]}{\partial h_n^R}$ 和 $\frac{\partial s^I[k]}{\partial h_n^I}$ 可以通过下面的公式进行计算,表示滤波后的序列的实部和虚部对滤波器参数的偏导:

$$\frac{\partial s^R[k]}{\partial h_n^R} = \frac{\partial s^I[k]}{\partial h_n^I} = s_R[N-1+k-n] \quad (7)$$



$$\frac{\partial \hat{s}^l[k]}{\partial h_n^R} = -\frac{\partial \hat{s}^R[k]}{\partial h_n^l} = s_l[N-1+k-n] \quad (8)$$

通过上面的推导过程,可以求出识别网络的结果对滤波器参数的偏导,与所有数值优化框架相同,该偏导是参数优化的重要依据。

受到文献[2,13]的启发,本文中采用共轭梯度法对滤波器参数进行优化。在共轭梯度法中,每一次迭代的参数的前进方向与前一次的方向共轭正交,相比于常用到的最速下降法,通常来说可以加快其收敛速度。共轭梯度法迭代更新公式可以表示为:

$$\mathbf{h}^i = \mathbf{h}^{i-1} + \mathbf{v}^i \mathbf{d}^i \quad (9)$$

式中:上标 i 表示迭代更新的次数的变化; \mathbf{v}^i 表示更新的方向; \mathbf{d}^i 表示更新的步长。根据共轭梯度法,迭代方向的更新可以表示为:

$$\mathbf{v}^i = \beta^i \mathbf{v}^{i-1} + \sum_{l=1}^L \nabla_{\mathbf{h}} g(s_l, \mathbf{h}^{i-1}) \quad (10)$$

迭代更新的步长可以表示为:

$$\mathbf{d}^i = \underset{\mathbf{d}}{\operatorname{argmax}} \sum_{l=1}^L g(s_l, \mathbf{h}^{i-1} + \mathbf{d} \mathbf{v}^i) \quad (11)$$

式中: L 是前文描述的优化目标函数中的一个批次中的样本的数目。参数 β^i 可以根据标准的共轭梯度法得到,在本文不再赘述。

上述的滤波器更新过程,在每个批次识别完毕后,对滤波器参数进行迭代更新。然而在实际操作过程中,也可以根据信道变化的实际情况,通过固定周期触发对滤波器参数的迭代更新。

1.2 深度识别网络

1.1 节介绍了通过识别网络的识别结果如何对滤波器参数进行更新,现介绍调制识别网络的核心,即深度识别网络的结构。由于文献[2,13]已经对不同的网络进行了描述并且对比,本文基于前人的研究成果,设计了调制识别的网络。

由于本文的框架中创新之处主要在滤波器参数优化或波形优化上,因此在该节中仅对调制识别网络进行简单描述。为了对比单纯的调制识别网络和本文的带滤波器参数反馈的框架,本文对框架中不同的调制识别网络进行了试验,所用到的网络包含较为传统的 CNN 网络,也包含了一些较新的网络框架,如残差网络 ResNet^[14]、卷积长短时记忆网络 CLDNN^[15]、分离通道卷积神经网络 SCC-CNN 网络等。此处仅挑选其中的典型的 CNN 网络和 CLDNN 网络进行描述。

其中 CNN 调制识别网络的结构如图 3 所示,其包含 2 层卷积层,2 层全联接层,每一层的参数情况如图所示。其中第 1 层卷积层的卷积核大小为 1×8 ,主要用于分别提取 I 路或 Q 路的特征,第 2 层的卷积核大小为 2×8 ,主要用于提取 IQ 路的联合特征。第 3 层全联接层的输出

单元数目为 256,第 4 层全联接层的输出单元的数目为 11,该数目与本文所用到的调制识别数据集中的调制种类相同。

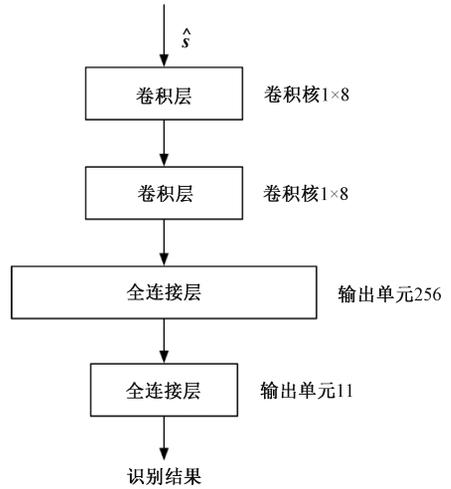


图 3 卷积网络用于调制识别

Fig. 3 CNN for modulation recognition

CLDNN 网络的结构如图 4 所示,存在 3 层卷积层,每一层的卷积核的维度都是 1×8 ,并且每层卷积层的通道数或滤波器数都为 50。将数据通过第 1 层卷积层后的输出向量,与数据通过第 3 层的输出向量合并后,得到新的特征向量。将该向量作为输入,输入到长短时记忆单元(long short time memory, LSTM)中进行处理。然后通过上述的 CNN 网络相同的两层全联接层中(同样第一层输出单元数目为 256,第 2 层为 80),得到最终的分类结果。

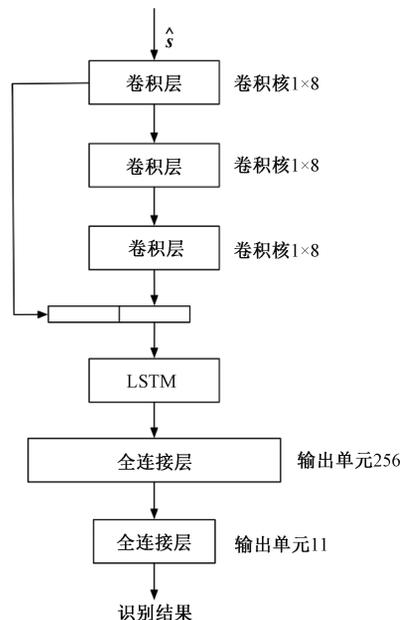


图 4 CLDNN 网络用于调制识别

Fig. 4 CLDNN for modulation recognition



上述的两种网络中,最佳超参数是通过文献[7]的研究得到,因此可以直接在本文中应用。并且所有提到的调制识别网络在输出前都通过了 softmax 层进行了归一化处理,并且在网络训练过程中所用的代价函数都是典型的交叉熵代价函数,在此处不再赘述。

2 实验

2.1 数据集生成

本文的方法相比于普通的深度学习方法中,通过学习结果对滤波器优化产生反馈,从而可以不断更新滤波器的参数,从而减少信道的影响,提高整体识别率。为了能够验证本文提出的方法,需要满足如下要求的数据集。

1) 数据集中需要加入信道的影响,如衰落、采样点偏移、频偏等影响,使得接收端带识别的信号包含了信道的影响。

2) 为了能够对本文的方法进行训练与测试,需要保证每个批次(batch)的数据含有相同或相似的信道参数,从而使得识别网络的反馈能够对固定的信道进行滤波优化。本文利用到了这样的前提条件假设,即信道都是缓慢变化的,在接收信号数据积累,并进行调制识别时,信道是恒定的。

3) 数据集中应当包含多种不同的调制识别方式,使得网络具有多种调制识别的能力。

4) 生成的数据集中的信号样本应当具有相同的格式,使之能够被应用于深度学习网络。并且其格式应当无损地表示信号,如用 IQ 两路时域信号表示,用复数进行表示等,不能用瀑布图进行表示(丢失了相位信息)。

综上所述,利用开源的软件无线电框架 GUNRADIO^[16]对数据集进行生成,并且借鉴了已有的射频信号开源数据集 RadioML^[17]的产生方式。该软件包含了许多成熟的通信过程中的模块,如调制、信道等,能够很好地对经过信道的已调信号进行仿真。该软件的另一个优点是,能够将仿真的通信系统与实际硬件连接,利于后续的实际通信信号的调制识别研究。

原始的 RadioML 开源数据集中,包含了多种调制方式,如数字调制的 QPSK,模拟调制的 AM 信号等。并且在信道的模拟过程中,充分考虑了信道的多样性,加入了衰落、载频偏移、采样点偏移等。然而,由于该数据集中的通信信号样本没有通过信道进行组织,因此不适合于本文中的应用。本文的数据集中,信道中同样考虑了衰落、载频偏移、采样点偏移、高斯噪声等,并且根据相同的信道对数据进行了组织,使得相同信道的样本成为一个 batch,适用于本文的训练和测试。在本文的数据集中,包含了 11 种调制方式,信噪比从 $-10 \sim 20$ dB 变化,并且在每种信噪比中,按照不同的信道参数将信号分为了 100 个 batch,每个 batch 包含了 220 个信号样本,每种调

制方式 10 个样本,该 batch 也是本文中的测试和训练的 batch。该数据集中的单个信号样本的维度与开源的 RadioML 数据集中的单个样本相同,都为 2×128 的矩阵。其中 2 表示 IQ 两路,128 表示时域采样点的数目。该数据集中总共包含 220 000 个样本,1 000 个批次,随机取 500 个批次的作为训练数据,剩下的 500 个批次为测试数据。取自该数据集中的同一批次的不同调制方式的样本如图 5 所示。

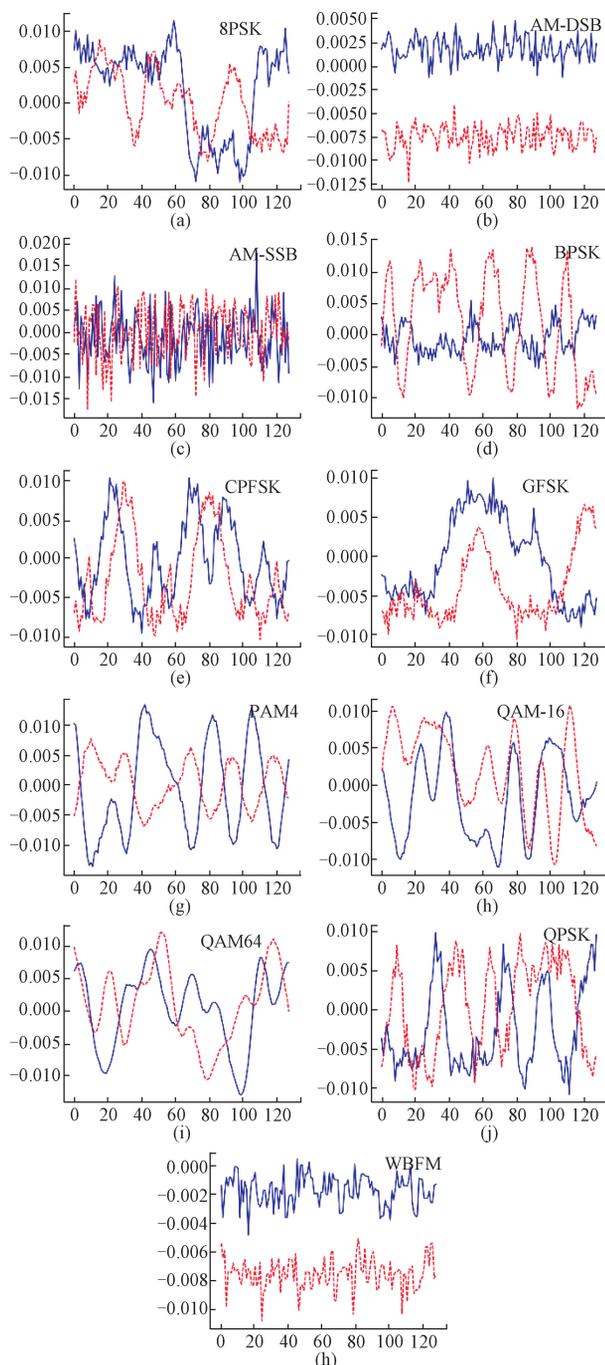


图 5 不同调制方式的样本

Fig. 5 Signal samples for different modulation types in the training dataset



2.2 识别精度对比

本文通过 Pytorch 深度学习框架对数据进行训练与测试。注意,在本文提出的方法的训练过程中,需要根据第 1 节的方法,根据反向传播的梯度对滤波器参数进行更新。训练的过程用到的是经典的交叉熵代价函数和 Adam 优化器,在此处不再赘述。训练完成后,本文的测试结果与其它方法的识别率对比结果如图 6 所示。不同方法在不同信噪比下的平均识别率如表 1 所示。可以看出,本文提出的方法相比于文献[4, 7-8]提出的 SCC-CNN、CLDNN、CNN 和 ResNet 网络识别率有所提高,平均识别率分别提高了约 4%、6%、7% 和 15%。该识别率的提高,说明了本文提出方法的有效性,在识别网络前加入的滤波器,能够减轻信道对调制识别的不利影响。

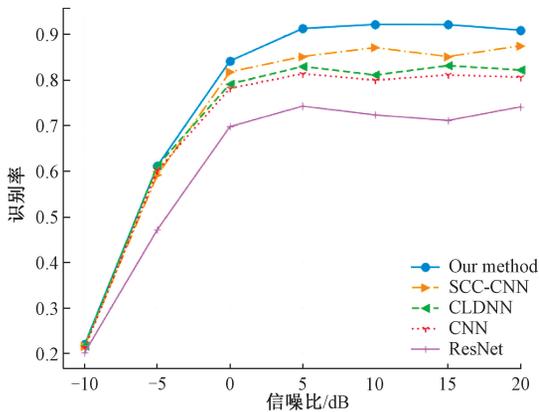


图 6 不同方法识别率对比

Fig. 6 Recognition rate comparisons between different methods

表 1 平均识别率对比

Table 1 Recognition rate comparisons between different methods

	识别率/%
本文方法	76.4
SCC-CNN	72.6
CLDNN	70.3
CNN	69.1
ResNet	61.4

识别率是在滤波器的阶数为 9 的条件下得到。图 7 所示为不同的滤波器阶数(从 3 变到 15)对最终的平均识别率的影响。可以看出,随着滤波器的阶数变高,整体来说,识别率有所提高,阶数为 15 时识别率达到约 78%,比阶数为 3 时,识别率提高了约 6%。然而,随着滤波器阶数的变高,滤波器优化的自由度更高,对滤波器阶数的更新需要相同批次的更多数据,使得方法的实用性下降。因此,在本文中,取滤波器阶数为 9 的结果。

2.3 训练时间对比

本文提出的方法通过滤波器优化的反馈过程,使得

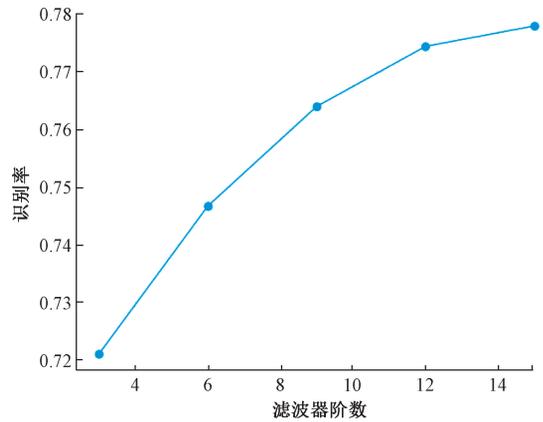


图 7 不同阶数的滤波器对应的识别率

Fig. 7 Recognition rate over different number of filter taps

识别率上有所提高。然而由于存在反馈过程中对滤波器参数的迭代更新,因此在调制识别网络结构相同的条件下,计算复杂度更高。为了说明本文中的方法相对于其他方法的优越性,此处对网络的训练时间进行了对比。不同的方法训练时间如表 2 所示,可以看出,本文提出的方法虽然相对于传统的 CNN 网络的训练时间有所提高,但是识别的提高是较为明显的(提高了 7%)。并且,相比于 CLDNN 网络等存在长短时记忆单元的训练时间更小,然而其识别率却更高(提高了 6%)。通过表 2 的网络所需训练时间的对比,可以看出,相比于 CLDNN 方法,在类似的识别率,甚至略高的识别率条件下,本文提出的方法所需的训练时间更少;相比于 CNN 网络,虽然训练时间更长,但是识别率有明显的提高。

表 2 训练时间对比

Table 2 Training time comparison

	时间/h
本文方法	1.56
SCC-CNN	1.93
CLDNN	1.82
CNN	0.26
ResNet	0.42

3 结论

基于深度学习的调制识别方法,由于能够根据训练数据提取更高阶、更抽象的特征用于识别,相比于传统的方法有更高的识别率。然而,通常来说,接收的通信信号中存在信道的影响,如噪声、衰落、采样点偏移等,可能降低识别率。本文提出一种基于深度学习的调制识别方法,与传统的方法不同的是,该方法能够根据识别结果的反馈对识别网络前的滤波器参数进行优化,使得信道对信号的影响降低,从而提高调制识别率。本文通过开源



的软件无线电软件 *gunradio* 生成了训练和测试数据集,对本文提出的方法进行测试。结果表明,本文提出的方法相比于传统的方法,如 SCC-CNN、CLDNN、CNN 和 ResNet 网络,分别提高了约 4%、6%、7% 和 15%。虽然在识别网络相同的条件下(都为 CNN),存在更高的计算复杂度,训练时间增加了 1.6 h,但是网络识别率的提高较为明显,为 6%。并且相比于 CLDNN 方法(含长短时记忆门控单元),训练时间减小了约 0.3 h,但是识别率提高了 6%。

参考文献

- [1] YE H, LI G Y, JUANG B, et al. Power of deep learning for channel estimation and signal detection in OFDM systems [J]. IEEE Wireless Communications Letters, 2018, 7(1): 114-117.
- [2] RESTUCCIA F, DORO S, ALSHAWABKA A, et al. DeepRadioID: Real-time channel-resilient optimization of deep learning-based radio fingerprinting algorithms [C]. Twentieth Acm International Symposium, ACM, 2019(4): 129-139.
- [3] MERCHANT K, REVAY S, STANTCHEV G, et al. Deep learning for RF device fingerprinting in cognitive communication networks [J]. IEEE Journal of Selected Topics in Signal Processing, 2018(5): 1-14.
- [4] O'SHEA T J, CORGAN J, CLANCY T C. Convolutional radio modulation recognition networks [C]. International Conference on Engineering Applications of Neural Networks. 2016: 101-120.
- [5] O'SHEA T J, PEMULA L, BATRA D, et al. Radio transformer networks: Attention models for learning to synchronize in wireless systems [C]. Asilomar Conference on Signals, Systems and Computers, IEEE. 2016: 130-142.
- [6] 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.
- [7] WEST N, OSHEA T J. Deep architectures for modulation recognition [C]. IEEE International Symposium on Dynamic Spectrum Access Networks, 2017: 1-6.
- [8] 郭有为, 蒋鸿宇, 周劼, 等. 分离通道联合卷积神经网络的自动调制识别 [J]. 电讯技术, 2018, 58(6): 86-91.
- [9] GUO Y W, JIANG H Y, ZHOU J, et al. Automatic modulation recognition based on separate channel combined convolutional neural networks [J]. Telecommunication Engineering, 2018, 58(6): 86-91.
- [9] 彭超然, 刁伟鹤, 杜振宇. 基于深度卷积神经网络的数字调制方式识别 [J]. 计算机测量与控制, 2018, 26(8): 228-232.
- [10] PENG CH R, DIAO W H, DU ZH Y. Digital modulation recognition based on deep convolutional neural network [J]. Computer Measurement and Control, 2018, 26(8): 228-232.
- [10] 张民谣, 高云鹏, 吴聪, 等. 基于改进平方检测和新型 K-N 互卷积窗的闪变参数检测 [J]. 仪器仪表学报, 2019, 40(8): 222-229.
- [10] ZHANG M Y, GAO Y P, WU C, et al. Flicker parameters detection based on the improved square demodulation method and new K-N mutual convolution window [J]. Chinese Journal of Scientific Instrument, 2019, 40(8): 222-229.
- [11] 曾德国, 熊辉, 龙柯宇, 等. 基于相位差分的脉内调制信号类型识别 [J]. 电子测量与仪器学报, 2009, 23(10): 85-90.
- [11] ZENG D G, XIONG H, LONG K Y, et al. Recognition of intra-pulse modulation signal types based on phase difference [J]. Journal of Electronic Measurement and Instrument, 2009, 23(10): 85-90.
- [12] 郭坚, 漆轩. 基于残差网络的自动调制识别 [J]. 计算机工程与设计, 2019, 40(9): 2406-2410.
- [12] GUO J, QI X. Automatic modulation classification based on residual network [J]. Computer Engineering and Design, 2019, 40(9): 2406-2410.
- [13] 李凌, 尹航. 基于序列判决和相位排序的 GLRT 最优序列检测算法 [J]. 电子测量与仪器学报, 2019, 33(1): 77-83.
- [13] LI L, YIN H. Sequence decision and phase sorting based GLRT optimal sequence detection algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(1): 77-83.
- [14] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, Inception-ResNet and the impact of residual connections on learning [J]. Computer Vision and Pattern Recognition, 2016, arXiv:1602.07261.
- [15] TARA N S, ORIOL V, ANDREW S. Convolutional, long short-term memory, fully connected deep neural networks [C]. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2015: 392-404.
- [16] CHENG S M, HUANG W R, CHENG R G, et al. Experimental emergency communication systems using USRP and GNU radio platform [C]. 11th EAI International Conference on Heterogeneous Networking for Quality, Reliability, Security and Robustness, 2015.
- [17] O'SHEA T J, WEST N. Radio machine learning dataset



generation with gnu radio[C]. Proceedings of the GNU Radio Conference, 2016(1): 100-117.

作者简介



杨小洪, 2009 年于江西科技师范大学获得学士学位, 现为江西科技学院专职教师、讲师, 主要研究方向为单片机控制工程, 电子信息工程, 物联网工程。

E-mail: searivery@163.com

Yang Xiaohong received his B. Sc. degree from Jiangxi Normal University in 2009. Now he is a full-time teacher, lecturer at Jiangxi University of Technology. His main research interest includes single chip microcomputer control engineering, electronic information engineering and internet of

things engineering.



余春泉, 南昌航空大学本科, 现为江西应用科技学院实验实训中心主任, 实验师、高级技师、健康管理师二级, 主要研究方向为电子与通信工程, 物联网工程。

E-mail: yuchunq_work@163.com

Yu Chunquan with a bachelor's degree from Nanchang Hangkong university, is currently the director of the experimental training center of Jiangxi institute of applied science and technology. He is a laboratory engineer, a senior technician and a second-level health manager. His main research interests include electronic and communication engineering and Internet of things engineering.