基于深度学习的 OFDM 系统窄带干扰消除方法研究^{*}

马 涛^{1a},李 悦²,杨 峰^{1b},丁良辉^{1a}

(1. 上海交通大学 a. 图像通信与网络工程研究所; b. 无线通信技术研究所, 上海 200240; 2. 海军研究院, 北京 100161)

摘 要: 针对正交频分复用 (orthogonal frequency division multiplexing, OFDM) 系统中的窄带干扰 (narrowband interference, NBI) 引起的性能下降,提出了两种基于深度学习(deep learning, DL)的窄带干扰消除结构。在两种结构中,首先分别对接收信号进行预处理,然后利用卷积神经网络 (convolutional neural network, CNN) 从时域上对 经过预处理的数据进行特征提取并获得干扰估计。最后将干扰估计量从接收信号中消去。仿真结果显示,两种结构 可以有效学习出 OFDM 系统中的窄带干扰,并提升系统性能。

关键词:正交频分复用;窄带干扰消除;深度学习;卷积神经网络

中图分类号: TN973.3 doi: 10.19734/j.issn.1001-3695.2018.11.0834

Deep learning based nbi mitigation method in ofdm systems

Ma Tao^{1a}, Li Yue², Yang Feng^{1b}, Ding Lianghui^{1a}

(1. a. Institute of Image Communication & Network Engineering, b. Institute of Wireless Communication Technologies, Shanghai Jiao Tong University, Shanghai 200240, China; 2. Naval Research Institute, Beijing 100161, China)

Abstract: Considering the performance deterioration of orthogonal frequency division multiplexing communication (OFDM) system due to narrowband interference (NBI), this paper employed deep learning into NBI mitigation of OFDM systems and proposed two structures with convolutional neural network (CNN). These two structures firstly pre-processed the received data in receiver, then adopted CNN to exploit the interference estimation in time domain. Finally the impact of NBI was removed from received signal. The simulation results demonstrate that the two systems can learn the interference effectively and improve system performance.

Key words: OFDM; narrowband interference mitigation; deep learning; CNN.

0 引言

作为一种多载波传输技术,正交频分复用(OFDM)技 术利用载波之间的正交性来传输数据。OFDM系统具有频谱 利用率高,有效对抗多径延时和衰落等优点,已经被应用于 多种通信技术协议和标准中,如无线局域网(WLAN)、数字 媒体广播系^[1]。窄带干扰(NBI)是OFDM系统常见的一种 干扰,它占据系统的部分带宽,能量较高。由于窄带干扰破 坏了OFDM系统子载波间的正交性,因而会导致系统通信性 能下降。传统的窄带干扰消除手段主要包括:在时域上设计 陷波滤波器;频域阈值滤波,滤除疑似受干扰的子载波上的 数据;逐子载波估计干扰等方法^[1~3]。在2010年前后,压缩 感知(compressed sensing,CS)技术被引入NBI估计,通过 设计置零保护间隔、预编码矩阵等手段,构造模型重新估计 干扰^[4]。但使用压缩感知重构干扰计算复杂度高,并且不适 用于带有循环前缀(cyclic prefix, CP)的 OFDM系统。

近年来,深度学习已经被广泛应用于许多领域并取得了 巨大成就。作为一种机器学习方法,深度学习通过卷积神经 网络(CNN)等神经网络从低维输入数据中提取有用特征并找 出数据内部的相关性^[5]。深度学习被引入无线通信研究中,

并被证明是一项极有价值和希望的研究。传统通信系统面临 诸如复杂信道建模困难,存在大数据处理需求以传统块结构 系统存在限制等挑战,引入深度学习将有助于解决这些问题 ^[6]。深度学习和无线通信结合会有以下的优势: 首先深度网 络可以作为一种通用函数近似器对复杂信道建模;其次,深 度学习具有的分布式并行处理架构能够满足通信系统的大数 据处理需求; 第三, 基于深度学习的通信系统能够打破人工 的模块结构并实现系统整体性能最优。深度学习主要以两种 方式应用于无线通信领域。第一种是将通信系统看做一个端 到端的自编码器,用多组神经网络来模拟信号发送和接收; 文献[7]利用生成对抗网络(generative adversarial networks, GAN)实现了在未知信道先验知识下的通信系统,作者利用 GAN 在无监督模式下学习信道模型。另一种是在系统的某个 模块中用深度学习改进系统性能。文献[8]介绍了一种迭代的 解码 CNN 噪声估计结构。文献[9]利用多种神经网络结构识 别信号的调制模式。可以看到,在通信系统中引入深度学习 潜力巨大,是一项很有价值的研究。

本文基于卷积神经网络提出了两种 OFDM 通信系统,通 过不同的方式对接收信号做预处理并通过卷积神经网络学习 重构出窄带干扰估计量。最后将干扰估计量从接收信号中抹

收稿日期: 2018-11-23; 修回日期: 2019-01-27 基金项目: 国家自然科学基金资助项目(61771309, 61671301, 61420106008, 61521062);上海 市重点实验室基金资助项目(STCSM15DZ2270400);数据链技术重点实验室开放基金资助项目(CLDL-20162306);上海交通大学医工交叉基金资助项 目(YG2017QN47)

作者简介:马涛(1994-),男,宁夏吴忠人,硕士研究生,主要研究方向为无线通信(matao9403@163.com); 李悦(1977-),女,北京人,工程师, 博士,主要研究方向为无线通信、卫星通信;杨峰(1978-),男,北京人,副教授,博士,主要研究方向为无线通信、无线自组网;丁良辉(1981-), 男,江苏东台人,副教授,博士,主要研究方向为无线通信、无线自组网.

除,并递入接收机中估计出最终结果。

1 系统模型

假定在 OFDM 系统收发两端为理想同步,OFDM 符号子 载波数为 N,经过高斯白噪声 (additive white Gaussian noise, AWGN) 信道后的接收信号 y 可以表述为

(1)

其中: x为时域发送信号, n为时域噪声。当系统遇到窄带 干扰 d 时,式(1)变为

y = x + n

$$y = x + n + d$$

$$= x + n + \Lambda_{c} F^{*} D$$
(2)

其中: F^* 为反离散傅里叶变换(discrete Fourier transform, DFT)矩阵, D为频域上的窄带干扰向量, $\Lambda_f = \left[1, e^{\frac{i2\pi\beta}{N}}, ..., e^{\frac{i2\pi\beta(N-1)}{N}}\right]$ 为偏移向量, $\beta \in \left[\frac{-1}{2}, \frac{1}{2}\right]$ 指干扰和发送信号子载波的偏移比例。可以看到, D是一个稀疏向量, 非零元素即为在相应位置上的干扰分量。假定受干扰的子载 波连续,并用 B, f_c 代表受干扰的子载波数以及干扰中心频率, 则 D的第 j 个元素 D_j 为

$$D_{j} = \begin{cases} \sqrt{E_{l}} \cdot e^{2\pi j\omega}, |j - f_{c}| < \frac{B}{2} \\ 0, otherwise \end{cases}$$
(3)

其中: ω 是随机生成的相位,干扰能量 E_i 可以从信干比 (signal-to-interference ratio, SIR)中计算得到。

2 卷积神经网络

作为一种深度学习方式, CNN 用局部卷积操作从输入数 据中提取样本的线性特征。典型的 CNN 包括卷积层,激活 层,池化层以及全连接层。随着卷积核在输入向量或矩阵上 移动卷积,卷积层将输入数据中的线性特征提取出来并映射 到新的特征图中。卷积层后为激活层,激活函数给从卷积层 出来的特征图引入了非线性特征,常见的激活函数有 tanh 函 数,线性修正单元(rectified linear unit, ReLU)等。在池化 层,从前一级得到的特征图会被分组计算并输出平均值或者 最大值,经过池化,减小了前级特征图的尺寸,同时也保留 了数据的主要特征。最后,全连接层将会把所有的前级特征 图汇聚到一起并输出相应的判决。CNN 在训练时将会用到被 标签过的训练数据,网络训练旨在降低损失函数并获得最优 网络参数设定。总之, CNN 能够充分提取输入数据的局部特 征并能训练成为一个稳定的模型。本文中,考虑到 OFDM 符 号和干扰具有的频域特征,本文尝试用 CNN 估计和重构窄 带干扰信号,在 OFDM 系统中实现窄带干扰消除。

3 基于 CNN 的干扰消除架构

在本文中,两种基于深度学习的 OFDM 通信系统将被用 于消除窄带干扰:残余迭代和阈值滤除结构,如图 1 和 2 所 示。在这两种结构中,CNN 相当于干扰估计器,它将从时域 上估计干扰信息。

3.1 两种系统架构

在残余迭代结构中,式(2)中的接收信号 y 首先会被传递 到接收机中进行解调、解码。接收机的对应输出 ‰,将重新 经过发送机进行做编码调制,记对应的输出结果为 ‰。将 y 和 ‰ 的差值,记为 â 作为卷积神经网络的输入信息,即

$$\hat{d} = y - \hat{x}_0 \tag{4}$$





考虑到 ŝ₀ 中解码解调会存在错误, *â* 中不仅包括真实的 干扰信息 *a*, 还包括由于误码重传导致的错误信息。所以可 以将 *â* 重写为式(5)所示的形式,其中 *c* 为噪声和 NBI 向量中 的错误部分。

$$\hat{d} = d + \xi \tag{5}$$

上文提到,在该结构中神经网络相当于干扰估计器,它 从网络输入*à*中提取干扰的时域特征并输出相应的干扰估计 量,记为*à*。本文将会在后文单独讨论关于神经网络的架构 设计。

随后,干扰估计分量 *ã* 将会从接收信号 ^y 中抹除以达到 干扰消除的效果:

$$\tilde{y} = y - \tilde{d} = x + n + d - \tilde{d}$$

$$= x + n + r$$
(6)

式(6)中 ŷ 作为去除干扰后的接收信号,将会再次进入接 收机中进行解调解码,最终的输出结果为 ŝ,。

从残差迭代的系统结构可以看出,该结构中 CNN 作为 干扰估计器,其输入 *à* 来源于接收信号和重传结果的差值。

CNN-阈值滤波系统的结构如图 2 所示。和残差迭代结构不同,在阈值滤波系统中,接收信号 y 需要先进行频域滤波。 设 y 的频域信号为 Y ,滤波器的阈值为 T_F ,相应的经过频域 滤波器后的输出为 \hat{D} ,其计算如式(7)所示。



Fig. 2 The structure of CNN-threshold filtering

$$\hat{D}_{i} = \begin{cases} Y_{i}, |Y_{i}| > T_{F} \\ 0, otherwise \end{cases}$$
(7)

其中: Y_i 表示 Y 在第i 个子载波上的数据。滤波时,需要首 先计算出 Y 中所有的子载波能量;与此同时,取阈值 T_F 为 Y上各子载波的平均能量。设 $\Lambda = \{i | Y_i > T_F\}$ 为 Y 中超过阈值 T_F 的子载波的下标集合,则 \hat{D} 可以被看做 Λ 中的数据集合。最 后,将 \hat{D} 转到时域上,即 \hat{a} 。分析 \hat{a} 的成分,可以发现 \hat{a} 中 有实际的干扰, Λ 中的子载波上的信号和噪声。基于此,可 以将 \hat{a} 拆分为

$$\hat{d} = d + \lambda - d_r \tag{8}$$

chinaXiv:201904.00025v1

其中: λ.d, 分别表示 Λ 中受干扰的子载波上的信号和噪声, 以及不在 Λ 中的干扰量。所以 d-d, 代表实际落在 Λ 中子载波 上的干扰。

将 CNN 连接在阈值滤波器后,尝试从 *à* 中提取干扰的 特征并获得相应的估计量 *ā*。和残余迭代系统类似,本文将 *ā* 从 ^y 中消去即式(6)中所示。 ^y 将会进入接收机做均衡、解调 及解码操作,最后的估计结果为 *s*。从以上两种系统的描述 中可以看到,本文分别从时域和频域上生成 CNN 的输入数 据 *à*:时域迭代求差以及频域滤波操作。

3.2 基于 CNN 的干扰估计

在介绍 CNN 网络结构前,需要说明从时域上学习干扰 的必要性。从频域直接估计干扰的特征,输入数据内部存在 较多冗余,无法有效学习出干扰的频域信息。因为只有受到 干扰及其附近的子载波才是有用信息,用于学习和估计干扰。 时域接收信号,包括做完 IFFT 后的干扰分量。注意到干扰分 量在频域上具有稀疏性,IFFT 矩阵相当于压缩感知理论中的 测量矩阵。所以在本问题中,从时域估计干扰信息和解压缩 感知问题类似。然而接收信号中的数据分量给估计干扰带来 了难度,直接应用压缩感知技术求解频域干扰需要用到导频 等在接收端已知的先验知识,会减少系统的频谱效率。本文 提出用 CNN 作为盲估计器,在不需要导频信息的前提下, 找出干扰向量和接收信号之间的关系。鉴于 CNN 能够从网 络输入中提取出其内在的关系,本文选择 CNN 作为干扰估 计器。

表1 网络结构

Table 1	Network specification setting
网络结构	参数
输入数据维度	[2N,1]
输出数据维度	[2N,1]
结构组成	$\{l; f_1, \dots f_l; n_1 \dots n_l\}$

表1所示为网络结构的基本设置,可以看到网络的输入 输出大小保持不变,都为[2N,1],N为OFDM符号子载波数。 由于输入输出数据的维度没有减小,所以本文中,CNN 网络 将只包括卷积层和激活函数层。{l;f,...f,i,n_n}代表了系统的 网络结构,其中1为卷积层的层数,每层卷积层后都连接了 激活层。f,,n,分别表示第i层卷积层中的卷积核尺寸为[f,,1], 个数为ni。本文提出的网络结构模型和文献[8]中提出的结构 模型类似,关于网络模型的设计,有以下几点需要关注:首 先该网络并未引入池化层和全连接层。在之前的描述中已经 提到,在前向反馈过程中,数据的维度一直保持为 2N (将 数据的虚部和实部分离),未发生改变。在进行卷积时,会用 加零(zero padding)的方式来保证卷积操作不会带来数据尺 寸的减少。其次,在经过 IFFT 变换后,时域信号会存在负 数。所以在本网络中,将采用如式(10)所示 tanh 函数作为激 活层函数,因为Relu等激活函数不能有效映射出负数特征。 最后,提出的网络中没有引入池化层和全连接层。因为在前 向反馈过程中,输入数据尺寸未发生变化,所以没有必要采 用主要作用为减少数据维度的池化层。出于类似的原因,本 文也放弃使用全连接层。

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$
(9)

3.3 网络训练过程

神经网络通过训练成为稳定收敛的模型,然后被应用于 实际测试。本节将讨论上文提出的网络模型的训练和优化问题。本文将根据式(2)和(3)生成 OFDM 符号和相应的窄带干 扰。在生成窄带干扰时, *B*.*f*.*β*分别为窄带干扰的带宽,中 心频率,以及偏移系数,噪声和干扰的能量可以通过信噪比 (signal-to-noise ratio, SNR)及信干比(SIR)来计算。假定 *B*在生成训练数据时是固定的,即受干扰子载波数量保持不 变;中心子载波 f_c 从特定的几个位置中选取; β 服从平均分 布: $\beta \sim \left(-\frac{1}{2}, \frac{1}{2}\right)$ 。SNR 和 SIR 代表了信号传输条件,并将决 定系统的通信性能,在本文中, Γ_i 和 Γ_N 分别表示生成训练 集时的 SIR 与 SNR 取值集合。

本文将采用传统的最小批次下降法(mini-batch gradient descent)训练网络。考虑到网络模型为回归网络,将损失函数 Loss 设定为 L2 损失函数,其定义为

$$Loss = \frac{\|d - \tilde{d}\|^2}{N} = \frac{\|r\|^2}{N}$$
(10)

在训练进程中,本文采用 Adam 优化器用于降低训练损 耗并且更新优化网络参数设定。从训练集中选取一部分数据 作为验证集,网络参数在训练集上更新,同时在训练集上验 证网络训练效果。若验证集上的 Loss 持续多次迭代不再降低, 则训练提前终止。此外,在训练时会适当降低学习速率来减 缓网络的参数更新速度,使网络模型收敛,即

$$\alpha = \alpha_0 \cdot R_a^{R_r}$$
(11)
其中: $R_a \in (0,1)$ 是收敛速度, R_r 代表网络训练进程。是当前
训练次数 *step_c* 和总训练次数 *step_t* 的比值即 $R_r = \frac{step_c}{step_t}$ 。

由于训练数据数量较多,网络训练开销和复杂度将异常 巨大,此外经过训练的网络,其性能表现也和训练数据相关。 尽管如此,本文提出的系统在实际条件下仍具有相当高的应 用价值。本文会在线下训练网络,同时训练数据也将由线下 生成并存储。为使线下训练得到的网络模型更加稳定,适应 于更多场景,将在生成训练数据时尽可能多地包含多种情形。 在实际应用时,可以直接使用已经训练好的网络模型。

4 仿真结果

整个仿真中,除非特别声明,本文都将按照表 2 中的参数设置进行仿真。在发送端,使用二进制相移键控(binary phase shift keying, BPSK),'1/3'码率的 Turbo 编码作为符号 调制和信道编码方式;在每个(SIR,SNR)场景下,连续生成 500 个物理帧(选择其中 100 帧作为验证集),每帧包括 10 个长度为 194 的 turbo 编码块,也即每帧共 101 个 OFDM 符号。为了评价系统模型性能优劣,本文选择文献[3]中提出的"频域阈值滤除法"作为基准方法进行比较。首先计算出 OFDM 符号各子载波能量以及相应的能量阈值 *Tr*;然后抹除 能量超过 *tr* 的子载波上的数据。在仿真中由于会对比多种网络结构的效能,所以本文用'*CNNk_i*'表示第 *i* 个有 *k* 层卷积层的网络,比如'*CNN5_0*'。除了神经网络训练和测试进 程是在 TensorFlow 上完成,系统结构中的其他部分都是在 Matlab 上搭建并进行仿真。

4.1 网络结构选择

前文已经提到, CNN 作为干扰估计器,将从时域提取干扰的特征并输出相应的估计向量。因此,网络结构的效果对 系统具有较大的影响。本文在训练中使用了表 3 中所示的几 种网络结构,并比较了损失函数和相应的系统误码率。最终 本文确定 CNN5_5 网络在两种系统结构上的训练效果最稳 定,在测试集上也有较好的性能。

在对比各种模型时发现,当网络层数1>5 时,网络的学 习效果提升并不大。对此进行分析,认为这主要是因为输入 数据中低维特征较多,高维特征较少,因而增加网络深度并 不能帮助提升网络的学习效果。增加卷积核尺寸,其学习效 果反而会恶化,这可能是因为卷积核是对输入信号的局部信 息做处理,结合输入数据的维度考虑,较大的卷积核不能有 效提取数据的局部特征;扩大网络宽度,网络的学习效果会 更好。这说明输入数据仍具有较多的低维特征,供 CNN 提 取和学习。本文曾尝试将图 2 中的频域滤波器去掉,直接从 时域接收信号中估计干扰,发现 CNN 仍能从中有效学习出 干扰的特征,但相比于加上滤波预处理,该方法带来的系统 性能提升有限。经过分析后本文认为,不进行滤波的时域接 收信号中,存在较多未被干扰的有用信号。这些信号对 CNN 估计干扰有一定影响,不能很好地估计干扰。而阈值设置过 高,也会导致一些受干扰的信息被滤除,使得网络输入信息 不全,同样影响 CNN 的学习效果。

表 2 仿真参数设置

Table 2 Simulation parameters setting				
参数名利	际	取值		
子载波数日	N	64	ļ	
Turbo 编码块长	度和个数	(194,	10)	
每帧符号	个数	10	1	
每种场景下的	重复次数	30	0	
f. 集合	ĩ	[4,20,3	6,54]	
SIR 集合 Γ	$_{I}/\mathrm{dB}$	[-6:1	:-3]	
SNR 集合 I	$\int_{N}/d\mathbf{B}$	[3]]	
干扰带宽	B	[0.0]	5]	
初始学习速	率 α_0	0.00	01	
批(batch)	大小	101*8		
优化器	r F	Adam optimization		
初始器	l F	Xavier optimization		
表 3 用于训练的网络结构				
Table 3	Network structure for	or training		
网络标志	结构			
CNN4_1	{4;15,5,5,17;128	3,128,64,1}		
CNN5_1	{5;15,5,5,5,17;128	,128,64,32,1}		
CNN6_1 {	5;15,5,5,5,5,17;128,	128,64,32,16,	1}	
CNN5_2	{5;35,5,5,5,37;128	,128,64,32,1}		
CNN5_3	{5;55,5,5,5,57;128	,128,64,32,1}		
CNN5_4	{5;15,5,5,5,17;64	,64,32,16,1}		
CNN5_5	{5;15,5,5,5,17;256,	256,128,64,1]	}	

4.2 网络性能验证

在前面的仿真过程中,训练集和测试集都是在相同的条件下生成的(SNR, SIR, *B*, *f*_e, *β*)。然而,在实际场景下,以上五种条件可能是未知甚至和训练场景中不同的。所以,本文提出的系统需要具备一定的鲁棒性,即在与训练场景不同的条件下仍能有效学习出干扰并改进系统性能。

本文将训练好的网络应用在不同的场景下测试其鲁棒性。首先测试网络在不同 SIR 下的系统表现,选定 SIR 集为: $\Gamma_{I} = [-7:-2]$ SNR 集 $\Gamma_{R} = [3]$, CNN 网络模型为 CNN5_4,得到的系统性能曲线如图 3 所示。

如图 3 所示,本文提出的两种系统架构均可以降低受干扰 OFDM 系统的误码率,提升其性能。而和阈值滤波干扰消除技术相比,基于深度学习的频域滤波结构能够更有效地估计出干扰的特征,改进系统性能。而残余迭代结构只能给通信系统的性能带来的改进很有限。但是相比参与迭代结构,阈值滤波结构能够更准确地学习出干扰信息,并带来更多的性能增益。经过分析认为,由于存在较多的误码信息,残余迭代结构中的网络输入 *à* 含有较多的冗余信息,影响了网络

训练的质量。而在阈值滤波结构中,经过阈值滤波后转到时 域的 *à* 中干扰的特征将占更大的比重,在网络训练中的效果 会更好。所以在接下来的仿真中,本文将主要关注 CNN-阈 值滤波结构。



图 3 两种结构在不同 SIR 下的性能曲线

Fig. 3 Performance curve of two structures among various sirs

为了全面验证该网络性能,本文还仿真了系统在不同 SNR 下的性能,结果曲线如图 4 所示。其中 Γ_{R} =[1,2,3,4,5]。 从该曲线中可以看到,CNN-阈值滤波结构在不同的 SNR 下 具有很好的干扰消除效果,并且从图中"未加干扰消除手段" 曲线可以看出,在本文提出的系统模型中,窄带干扰是影响 系统通信性能的最主要因素。





with various snrs



图 5 CNN-阈值滤波结构在不同干扰数目下的性能曲线 Fig. 5 Performance of CNN-threshold filtering structure with various jammed subcarrier numbers

在生成训练集时,受干扰的子载波数目 B=7,接下来本 文将测试该系统在受干扰带宽不同时的性能。图5为系统 SIR 为-4时的仿真结果,可以看到随着受干扰的子载波数目增多, 系统的误码率也逐渐上升,而本文提出的 CNN-阈值滤波结 构仍能有效学出干扰特征,并降低系统的误码率。和阈值滤 波消除技术作对比,可以看到受干扰的子载波越多,本文提 出的基于 CNN 的阈值滤波结构性能提升更加明显。

此外,在生成训练集时,假定干扰的中心频点位置只有 有限几个选择,而在实际情况中,连续干扰的中心频点不一 定会落在相同的位置。故而,需要测试系统在这种情况下的 稳定性。正如表 2 中显示,本文隔 16 个子载波设定一个中心 频率选项。在本次仿真中,本文假设中心频率相对训练集中 的场景分别偏移了 4-8 个子载波,其他条件不变,仿真结果 如图 6 所示。可以看到,系统未加任何干扰消除手段和频域 滤波方法的效果,基本不会随着子载波的偏移出现变化,而 本文提出的结构,其性能会随着中心频率的偏移增大而恶化。 虽然随着 f.偏移量的增大,干扰覆盖的子载波和训练网络时 覆盖的子载波重合度会越来越小(偏移量为7、8 时,受干扰 的子载波将不会重合),但系统在相应场景下仍能较为准确地 估计并消除干扰。并且当偏移量不大于 5 个子载波时,本文 提出的模型架构性能仍将好于频域滤波手段。



图 6 CNN-阈值滤除结构在中心频率存在偏移时的性能曲线 Fig. 6 Performance of CNN-threshold filtering structure with various subcarrier offsets of center frequency

5 结束语

本文以 OFDM 系统和深度学习技术为背景,研究了 OFDM 系统窄带干扰消除问题。本文首先分析和评价了传统 的窄带干扰消除方法及其存在的优缺点。本文还介绍了深度 学习在物理层通信系统中的应用。本文提出了两种基于深度 学习的 OFDM 窄带干扰消除机制,利用卷积神经网络从时域 学习干扰信息并消除。结合模型中干扰的实际特点,本文设 计了一种 CNN 回归学习网络用于学习和估计干扰。学习到 的干扰将会在时域上从接收信号中抹除,去除干扰后的信号 将通过接收机得到最终结果。在仿真中,本文对影响神经网 络和系统性能的几种因素进行了仿真对比,实验结果表明, 本文提出的两种系统都能有效地学习出干扰特征并做准确的 估计,其中 CNN-阈值滤波结构比 CNN-残余迭代结构的干扰 估计效果更好。这是深度学习第一次被引入 OFDM 窄带干扰 消除问题研究中,基于深度学习的干扰消除结构既能准确估 计并消除窄带干扰,还因为其线下训练、线上测试的独特机 制,并未增加系统的复杂度,可以应用于多种场景。

参考文献:

- Coulson A J. Bit error rate performance of OFDM in narrowband interference with excision filtering [J]. IEEE Trans on Wireless Communications, 2006, 5(9): 2484-2492.
- [2] Darsena D. Successive narrowband interference cancellation for OFDM systems [J]. IEEE Communications Letters, 2007, 11 (1).
- [3] Shi Kai, Zhou Yi, Kelleci B, *et al.* Impacts of narrowband interference on OFDM-UWB receivers: analysis and mitigation [J]. IEEE Trans on Signal Processing, 2007, 55 (3): 1118-1128.
- [4] Gomaa A, Al-Dhahir N. A compressive sensing approach to NBI cancellation in mobile OFDM systems [C]//Proc of Global Telecommunications Conference. Piscataway,NJ:IEEE Press, 2010: 1-5.
- [5] Goodfellow I, Bengio Y, Courville A, et al. Deep learning [M]. Cambridge: MIT Press, 2016.
- [6] Wang Tianqi, Wen Chao-Kai, Wang Hanqing, et al. Deep learning for wireless physical layer: Opportunities and challenges [J]. China Communications, 2017, 14(11): 92-111.
- [7] Ye Hao, Li G Y, Juang B H F, et al. Channel agnostic end-to-end learning based communication systems with conditional GAN [J]. arXiv preprint arXiv: 1807.00447, 2018.
- [8] Liang Fei, Shen Cong, Wu Feng. An iterative BP-CNN architecture for channel decoding [J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(1): 144-159.
- [9] 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.