

基于深度学习的 OFDM 系统信号检测设计

高媛¹, 王慧¹, 孔菲菲², 耿仁轩¹, 刘源松¹, 王国涛^{1,3}

(1. 黑龙江大学 电子工程学院, 哈尔滨 150080;

2. 中国移动通信集团 黑龙江有限公司, 哈尔滨 150001;

3. 哈尔滨工业大学 电器与电子可靠性研究所, 哈尔滨 150001)

摘要: 传统信号检测技术在通信系统、雷达信号处理、生物医学信号处理等方面有着广泛的应用; 正交频分复用系统中传统信号检测技术存在信道失真、载波间干扰、码间干扰等问题; 为解决此问题, 提出一种基于深度学习的 OFDM 系统信号检测方法, 实验中根据信道统计仿真的结果数据离线训练深度学习模型, 利用该模型恢复在线传输的数据; 通过与传统算法之间的对比, 实验展示了在 OFDM 系统中使用深度学习方法进行信道估计和符号检测的成果; 仿真实验结果表明, 在训练导频较少、循环前缀省略和非线性削波噪声的条件下, 基于深度学习方法的信号检测比传统方法的鲁棒性更强; 该方法可以应用在大部分信道失真和干扰的无线通信系统中, 具有较强的实用价值。

关键词: 深度学习; 正交频分复用; 信道估计; 信号检测

Design of OFDM System Signal Detection Based on Deep Learning

GAO Yuan¹, WANG Hui¹, KONG Feifei², GENG Renxuan¹, LIU Yuansong¹, WANG Guotao^{1,3}

(1. School of Electronic Engineering, Heilongjiang University, Harbin 150080, China;

2. China Mobile Communications Group Heilongjiang Co., Ltd., Harbin 150001, China;

3. Reliability Institute for Electric Apparatus and Electronics, Harbin Institute of Technology, Harbin 150001, China)

Abstract: Traditional signal detection techniques are widely applied in communication systems, radar signal processing, biomedical signal processing, and so on. In orthogonal frequency division multiplexing (OFDM) systems, these techniques have problems such as channel distortion, inter-carrier interference, and inter-code interference. In order to solve this problem, a signal detection method for OFDM systems based on deep learning is proposed. Based on the channel statistical simulation data, a deep learning model is trained offline in the experiment, and the model is utilized to recover the online transmission data. Compared with traditional algorithms, experimental results show that the deep learning method is used for channel estimation and symbol detection in the OFDM systems. Simulation experiments show that under the conditions of fewer training guides, cyclic prefix omission and nonlinear clipping noise, the signal detection of the deep learning method is more robust than that of traditional methods. The proposed method can be applied in most wireless communication systems with channel distortion and interference, and has strong practical value.

Keywords: deep learning; orthogonal frequency division multiplexing; channel estimation; signal detection

0 引言

无线通信技术作为目前发展最迅速、最有希望的科研领域之一, 当某些接收的通信信号参数不够时, 就需

要使用调制识别技术来对信号进行研究与分析, 以获取信号的调制类型和进制数。由于调制识别技术一般使用在通信系统、无线定位、安全和军事应用等场合, 通常只能够识别信号的调制类型和一些基本调制参数, 在加

收稿日期:2024-01-22; 修回日期:2024-03-06。

基金项目:国家自然科学基金(51607059);黑龙江省自然科学基金(QC2017059);黑龙江省博士后基金(LBH-Z16169);黑龙江省重点研发计划项目(2022ZX03A06)。

作者简介:高媛(1978-),女,工学博士,教授。

通讯作者:王国涛(1982-),男,博士后,教授。

引用格式:高媛,王慧,孔菲菲,等.基于深度学习的 OFDM 系统信号检测设计[J].计算机测量与控制,2025,33(4):24-31.

密通信、多用户干扰、非标准调制等情况下可能无法获取完整的通信参数,因此在复杂的通信环境中,调制识别算法需要根据更多的未知通信参数(如天线数目)进行预测。但传统调制识别算法在准确预估通信参数时,频偏等干扰条件的存在会导致传统调制识别算法带来的误差偏大,特别是在依赖简单分类器(如支持向量机)进行判决的过程中^[1]。因此如何在其他通信方面的参数未知的情况下提高调制识别的准确性是目前需要解决的问题。正交频分复用(OFDM, orthogonal frequency division multiplexing)是一种广泛应用于无线宽带系统的多载波调制(MCM, multi-carrier modulation)技术^[2],它利用载波间的正交性,有效提高频谱利用率,并解决了无线信道中的频率选择性衰落问题。作为微电子部件中高密度和高可靠性的典型代表,OFDM技术具有很高的频带利用率,同时具备抗噪声能力强和高速数据传输等优势^[3]。

随着电子技术、半导体技术以及物理学等领域的快速发展,无线通信技术逐渐兴起,为人类社会带来巨大变革。1831年法拉第第一次发现了电产生磁效应,随后在1864年麦克斯韦做出了“电与磁的交替转化过程,是一种波的传播形式,是一种光波”^[3]的论断,该波被称为电磁波。1888年德国物理学家赫兹实验验证了麦克斯韦理论的正确性,正是这些实验打开了无线通信的新纪元^[4],促进了无线通信的发展。目前的信道估计算法主要有盲信道估计、半盲信道估计和导频辅助信道估计3种。这3种信道估计算法中,使用较为广泛的方法是导频辅助信道估计^[5]。Jiang等人^[6]提出了一种基于子空间结构的自适应信道检测设计,属于半盲信道估计方法,准确计算信道参数的初始值,最后通过功率方法和子空间追踪,对自适应信道进行检测估计。在无线通信系统传输过程中,衰落信道的存在对传输信号产生的不利影响,会引起码间干扰和载波间干扰的发生。鉴于OFDM技术的多种优点,其在无线通信系统中得到了广泛应用^[7]。根据当前的研究现状,无线信道的参数值表现出随位置和时间变化的特性,接收端为了能够准确及时地接收用户端数据,需要对信道的质量进行计算与分析,以抵消或减小信道特征对于传输过程的影响^[8]。由于在无线信道中,多普勒频移效应和多径衰落严重影响OFDM系统性能,近年来研究人员多是在OFDM系统的基础上进行关于信号检测设计的研究。深度学习模型相比于传统学习算法,其卓越的性能和出色的鲁棒性^[9],使其成为进行研究的理想选择。

综上所述,在复杂通信系统下研究调制识别技术是非常重要的。本文提出的基于深度学习的OFDM系统信号检测方法是利用深度学习和最小均方误差方法(MMSE, minimum mean-square error)来比较不同条件

对于两种方法误差率的影响,采取了理论分析与计算机程序仿真相结合的方法来验证所研究内容的正确性。结果表明,在训练导频较少、循环前缀省略、有非线性削波噪声的条件下,基于深度学习的方法比传统方法具有更强的鲁棒性。

1 信道估计算法基本理论

1.1 传统信道估计算法

传统常用的信道估计算法包括最小二乘(LS, least squares method)算法和MMSE算法,MMSE估计通过最小化均方误差来估计信道参数,因此在统计特性和先验概率信息已知的情况下,能够实现较高的估计精度。相比于其他估计方法,MMSE估计通常能够提供更接近真实信道的估计结果。由于考虑到噪声和先验信息,MMSE估计在面对噪声和干扰时表现出更强的鲁棒性。它能够通过对信道参数的合理假设和先验知识的利用,提高估计的准确性,并降低噪声和干扰的影响。另外,MMSE估计算法是基于统计模型和贝叶斯推断的方法,具有坚实的理论基础,其在通信系统中的信道估计、信号检测、自适应滤波等方面有广泛的应用,是一种被广泛研究和验证的估计方法。因此,本文采用的是MMSE算法来与深度学习算法进行对比研究。包含信道估计的OFDM系统流程如图1所示。输入的数据经数字调制系统(QAM, quadrature amplitude modulation或PSK, phase-shift keying)调制后进行串/并变换,随后依据一种规则插入导频信息以产生新的序列 $\{X(k)\}$ 。然后通过离散傅里叶逆变换对 $\{X(k)\}$ 进行执行,将发送的信号从频域转换为时域,转换公式如下:

$$x(n) = \text{IDFT}\{X(k)\} =$$

$$\sum_{k=0}^{N-1} X(k) e^{j(2\pi kn/N)}, n = 0, 1, 2, \dots, N-1 \quad (1)$$

其中: N 为IDFT的长度。

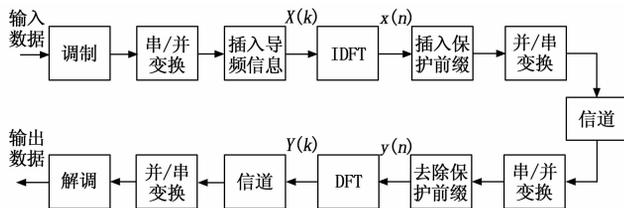


图1 包含信道估计的OFDM系统流程框图

在发送端输入数据通过离散傅里叶逆变换后,为避免码间干扰,须在信号中插入循环前缀(CP, cyclic prefix),该循环前缀的长度需要大于信道的最大时延。在通过CP处理和并/串变换后输入的信号 $x(n)$ 即可发送。接着信号经过有频率选择性的噪声信道,获取接收信号 $y(n)$, $y(n)$ 表示如下:

$$y(n) = x(n) + h(n) + w(n) \quad (2)$$

其中： $h(n)$ 是信道状态信息， $w(n)$ 是高斯白噪声。

接收端信号 $y(n)$ 的处理过程与发送端相对称，在进行串/并转换后，去除循环前缀，然后做离散傅里叶 (DFT, discrete fourier transformation) 变换，具体 DFT 变换表达式如下：

$$Y(k) = \text{DFT}\{y(n)\} = \frac{1}{N} \sum_{k=0}^{N-1} y(n)e^{-j(2\pi kn/N)}, k = 0, 1, 2, \dots, N-1 \quad (3)$$

经 DFT 处理后，能够获取数据中的导频信息，且根据信道预测能够得到剩余位置检测值，最终得到全部信道所有状态的信息 $H(k)$ 。发送消息估计式为：

$$X_e = \frac{Y(k)}{H(k)}, k = 0, 1, 2, \dots, N-1 \quad (4)$$

解调 X_e 即可获取发送端消息。

1.2 基于深度学习的信道估计算法

目前在信道估计领域已经出现多种基于深度学习的算法，包括卷积神经网络，反卷积神经网络和生成对抗网络等，其中深层神经网络 (DNN, deep neural network) 算法，近年来备受机器学习与大数据领域的关注。神经网络通过增加神经网络的隐藏层数量，提高了系统的表达和检测能力。该网络的每一层由大量的神经元构成，每个神经元通过对前一层神经元输出的加权和和应用非线性函数来产生输出。这种层级结构和非线性映射使得深度学习在各个领域实现了更多应用场景的机会。例如，在无人驾驶汽车领域，深度学习技术能够通过大量数据进行训练，实现对道路环境的感知和决策，从而使得车辆能够自主导航和避免事故。在生物医学领域，深度学习技术可以应用于预防性诊断和病理预测。此外，深度学习技术还可以应用于购物指南和电影导航等领域，以满足年轻人的需求。通过对用户行为和偏好数据的分析，深度学习可以为用户提供个性化的购物建议和电影推荐，提高用户体验和满意度^[10]。综上所述，深度学习技术极大地拓展了人工智能的领域范围。

近年来，有关监督学习、无监督学习和强化学习的理论和应用得到了显著的改进。Wu 等人^[9] 在研究中对深度学习方法和传统基于导频方法的信道估计进行比较，提出在通讯系统中加入频率偏移，以评估其对误码率的影响，引入频率偏移后的系统更加贴近实际无线通信系统特性。深度学习独具的端到端学习能力使得调制识别问题不再需要复杂的人工特征选取，而是能够自动学习最佳特征表示，从而保证了调制识别的高精度和高可靠性。深度学习模型具备卓越的特征提取能力和强大的拟合能力，使其在调制识别问题上表现出优异的性能，尤其是在考虑是否忽略循环前缀条件下。其出色的鲁棒性使其成为进行调制识别研究的理想选择。

能，尤其是在考虑是否忽略循环前缀条件下。其出色的鲁棒性使其成为进行调制识别研究的理想选择。

2 实验流程设计

2.1 深层神经网络算法

深层神经网络算法基于神经网络的层级结构和激活函数等组成要素，通过权重更新的方式实现模型的训练和优化^[11]。深层神经网络模型训练过程包括前向传播和反向传播的步骤，以及优化算法的应用。图 2 是一个典型的 5 层深度神经网络结构模型，它展示了拥有 3 个隐藏层的神经网络，该结构是本实验中所运用的深层神经网络模型，图中每层的神经元数目分别为 500、256、250、120、16 个。这种分布方式提供了逐渐减少神经元数目的结构，以逐层提取数据的抽象特征和高级表示。输入数字分别与包含导频和发送符号的 2 个 OFDM 块的实部和虚部的数目相匹配^[12]。

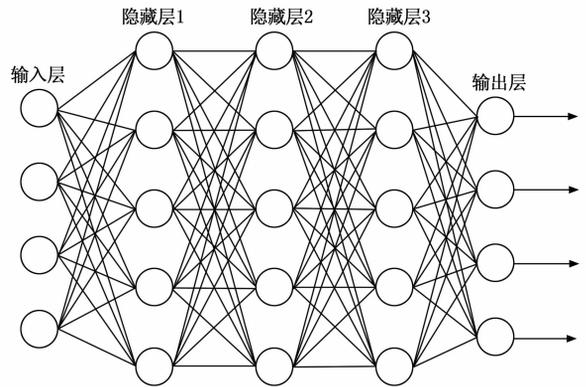


图 2 5 层深度神经网络结构

本文在基于文献 [13] 的基础上，进行了进一步的研究与探讨。DNN 算法流程主要分为以下步骤：

步骤 1：实验中的非线性函数可用 Sigmoid 函数或者 Relu 函数，它们的定义分别是 $f_s(a) = \frac{1}{1 + e^{-a}}$ 和 $f_R(a) = \max(0, a)$ 。网络 z 得到的结果是级联输入数据 I 经过非线性变换得到的^[14]，理论上其具体表达式如下：

$$z = f(I, \theta) = f^{(L-1)}\{f^{(L-2)}[\dots f^{(1)}(I)]\} \quad (5)$$

其中： L 为神经网络的层数， θ 为神经网络的权重。该模型的具体参数需要在在线部署之前进行神经元权重的改善。最佳权重通常是在实验数据集中确定出来的，具有人们了解的期望输出。

步骤 2：损失计算。常见的损失函数包括均方误差损失 (MSE, mean square error)，交叉熵损失 (CE, cross entropy) 函数等^[15]。在实验中，我们选择均方误差损失 L_2 损失函数：

$$L_2 = \frac{1}{N} \sum_k [\hat{X}(k) - X(k)]^2 \quad (6)$$

其中: $\hat{X}(k)$ 是预估消息预测值, $X(k)$ 是监视消息实际值, 它是在该条件下传输的信息。

步骤 3: 反向传播计算。反向过程是根据链式法则, 逐层计算出损失函数关于各层的梯度, 反向传播和权重梯度计算是反向过程的两条计算支路, 分别用于计算损失函数对于激活值的梯度。

步骤 4: 权重更新。最后, 根据反向过程中得到的权重梯度, 来对权重进行更新。

实验时为了与传统 MMSE 估计算法形成对比, 深度学习中也设置了与 MMSE 算法相同的 64 个子载波。为了在计算资源有限的情况下更快地训练模型并获得预测结果, 实验中采用分批次预测的方法, 在每次传输数据生成 128 位的传输数据时, 将预测过程分为 8 次进行预测, 每次预测 16 位, 该方法可以加快模型的收敛速度。传输数据的每 16 位以独立训练为基础的单个模型进行分组和估计, 接着将其串联来获取最终结果的输出。为了实现模型的非线性拟合能力, Relu 函数在大多数层中都被当成激活函数, 但在最后一层中需要使用 Sigmoid 函数将输出映射到区间 $[0, 1]$ 上, 以获得符合传输数据特性的预测结果。

2.2 OFDM 信道检测设计

图 3 和图 4 具体展现了具有基于深度学习的 OFDM 系统信号检测设计的体系结构。在基带正交频分复用系统中, 发射端的处理过程与传统系统相似。待发送的符号经过并行转换成数据流后, 经过离散傅里叶逆变换 (IDFT) 将信号从频域转换为时域。为降低码间干扰, 实验时在数据流中插入一个循环前缀, 其长度需要大于或等于通信信道的最大延迟扩展^[16]。本实验中, 无线信道遵循新无线电模型的无线世界倡议 (WINNER II), 使用 2.6 GHz 的载波频率以及具有 24 个路径和最大延迟为 16 个采样周期的典型城市信道^[17]。另外, 采用正交相移键控 (QPSK, quadrature phase shift keying) 作为调制方式^[18]。

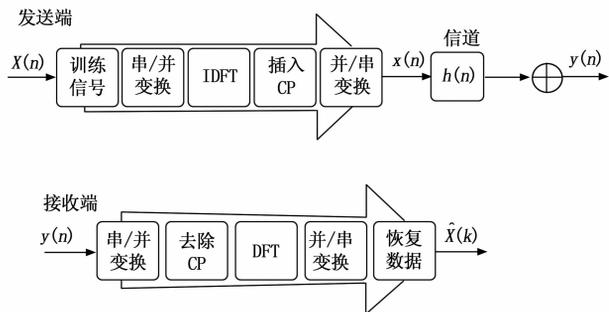


图 3 联机部署阶段 OFDM 系统模型

实验中, OFDM 系统信号检测设计的具体步骤如下:

步骤 1: 考虑到可以用复随机变量 $\{h(n)\}_{n=0}^{N-1}$ 来具体阐述样本数据间不同的多径信道, 接收信号具体表

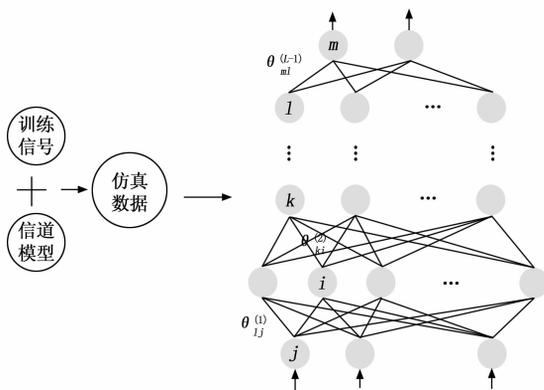


图 4 离线训练阶段 OFDM 系统模型

达式为:

$$y(n) = x(n) \otimes h(n) + w(n) \quad (7)$$

其中: \otimes 表示卷积, $x(n)$ 和 $w(n)$ 分别表示发送信号和信道中的加性高斯白噪声 (AWGN)。在移除循环前缀且经过傅里叶变换后, 可以得到的频域信号是:

$$Y(k) = X(k)H(k) + W(k) \quad (8)$$

其中: $Y(k)$ 、 $X(k)$ 、 $H(k)$ 和 $W(k)$ 分别是 $y(n)$ 、 $x(n)$ 、 $h(n)$ 和 $w(n)$ 的傅里叶变换。

步骤 2: 假设导频符号在第一个 OFDM 块中, 下面的 OFDM 块由传输的数据组成, 共同构成一个大的框架。整个框架中的信道可以被视为在导频块和数据块上保持不变的常数跨距。在初步实验中, 我们采用一种端到端的方法将一个数据块和一个导频块接收到的数据作为系统的输入, 以实现数据的准确发送。

步骤 3: 为了获得结合信道估计和符号检测的 DNN 模型, 图 3 展示了在联机部署阶段 DNN 模型所实现的过程。在发送端, 信息经过串并变换后, 进行离散傅里叶逆变换, 并插入循环前缀。接着进行并串变换, 通过传输信道传输到接收端。在接收端, 通过与发送端相反的操作, 即进行串并变换、去除循环前缀、离散傅里叶变换和并串变换, 恢复数据, 得到最终的信息输出。该过程主要用于恢复所需传输的数据输出, 而无需明确估计无线信道的特性。

步骤 4: 图 4 展示了在离线训练阶段 OFDM 系统模型中信息的传输过程。为了进行模型的训练, 实验中根据得到的 OFDM 样本信号进行仿真数据的采集, 这些样本是由具有差异的信息序列产生的, 并且在具有不同统计特征的信道环境下产生。通过在不同信道环境下生成的样本信号, 能够模拟实际通信中的多样性和复杂性。这样的数据采集过程能够获取更丰富的训练样本, 涵盖了各种可能的信道条件和信息序列变化。

实验中, 将 OFDM 调制和无线信道视为一个黑匣子, 并通过训练模型来获得实验数据。在该领域的历史

研究中，研究人员已经提出了许多不同的信道模型，这些模型可以利用信道统计数据来充分展现真实的信道信息。根据这些不同的信道模型，经过仿真能够获得实验所需的数据。在每一次的仿真实验中，都先生成一个随机数据序列当做发送符号，随后使用一组导频符号产生相应的 OFDM 帧。在离线训练和在线部署阶段，我们确保导频符号保持不变。本实验中通过对经过信道失真（包括信道噪声）的 OFDM 帧进行采样，获取实验中的接收信号，并将其与原始传输数据一起记录和收集，作为实验获得的信息数据。

3 结果分析

3.1 不同迭代次数的比较

实验中，首先对不同迭代次数下的 OFDM 信号输入信噪比 (SNR, signal noise ratio) 与识别误差之间的关系进行了比较。图 5 展示了在每帧使用 64 个导频进行信道估计，并进行 500 次迭代的情况下，OFDM 信号输入 SNR 与识别误差之间的关系。其中采集了从 1~30 的整数数据点，间隔为 2，以验证迭代次数对结果的影响。根据图 5 和图 6 的结果，可以观察到随着 SNR 的增大，当信噪比大于 15 dB 时，识别误差逐渐趋于饱和，表明无法有效地估计信道。图 6 显示的是在导频数量相同的情况下，仅改变迭代次数为 1 500 次时的结果，数据点的采集是从 1~30，间隔为 2 取得的整数。通过图像分析，可以发现该条件下检测到的数据更加精确，得到的数据点更加准确。实验结果表明，随着迭代次数的增加，实验所得到的识别误差更加精确，结果也更加准确。这意味着增加迭代次数有助于改善信道估计的性能，选择适当的迭代次数对于实现准确的信道估计至关重要。迭代次数的增加使模型能够更好地适应信道的变化和噪声干扰，从而提高了信道估计的准确性和鲁棒性。

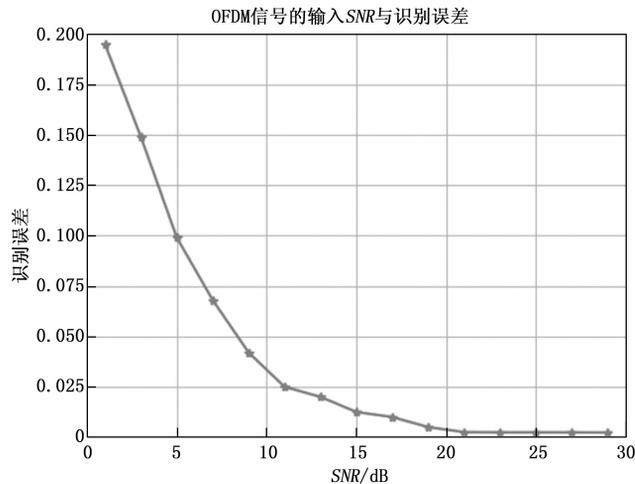


图 5 迭代 500 次 OFDM 信号的输入 SNR 与识别误差

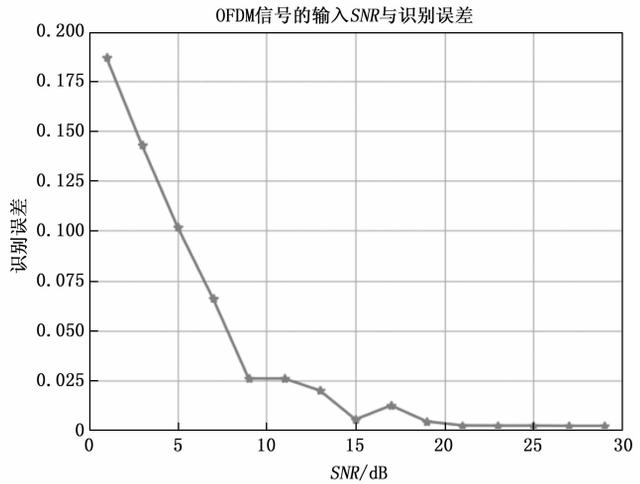


图 6 迭代 1 500 次 OFDM 信号的输入 SNR 与识别误差

3.2 不同导频数目的比较

接下来为了研究不同参数变化下深度学习方法和 MMSE 方法在信道估计问题上的差异性，我们首先验证了不同导频数目对两种方法性能的影响。实验中，首先每帧使用了 64 个导频进行信道估计，将信道估计和检测的 MMSE 方法与深度学习方法进行比较。如图 7 所示，结果表明，两种方法的表现性能相似，但是传统的 MMSE 方法在性能上优于深度学习方法，其识别误差更小。这是因为 MMSE 方法假设了信道的二阶统计量为已知，并将其用于符号检测。与基于深度学习的方法相比，我们可以明显地观察到 MMSE 方法的优势。

为了提高频谱利用率，在实验中我们考虑了信道模型的最大延迟为 16 个采样周期。因此，我们可以通过只使用较少的导频进行信道估计来实现更好的频谱利用率。在实验中，只使用 8 个导频进行信道估计，系统的第一个 OFDM 块由 8 个导频和传输的数据组成，深度学习方法的输入输出保持稳定不变。根据图 7 的结果显示，当只使用 8 个导频时，MMSE 方法的误码率识别误差在信噪比大于 10 dB 时趋于饱和。然而，基于深度学习的方法仍然能够随着信噪比的增加而降低误码率，这验证了深度学习方法在使用较少导频进行信道估计时具有很好的鲁棒性。深度学习方法的优越性表现在它能够利用不同模型训练产生的实验数据来研究无线信道的特点。通过深度学习，我们可以从大量数据中学习复杂的信道模式和非线性特征，从而改善信道估计的性能。

通过实验结果，我们可以得出结论：在信道估计问题中，传统的 MMSE 方法在某些情况下比深度学习方法更具优势。这是因为 MMSE 方法能够利用已知的信道统计信息，对信号进行更准确的估计和检测。然而，深度学习方法具有其自身的优势，它能够从大量的数据中学习复杂的信道模式和非线性特征，对于复杂的信

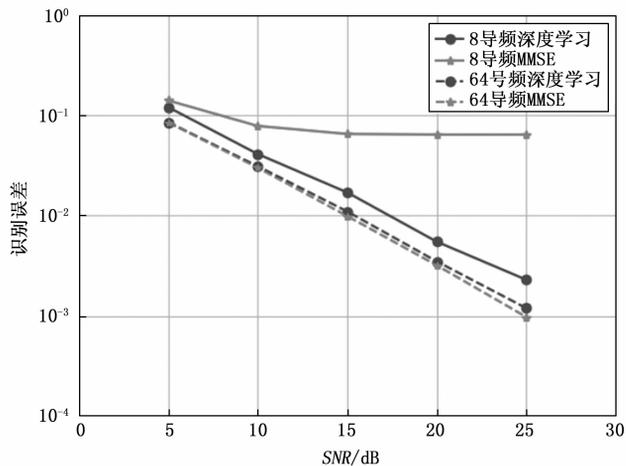


图 7 不同导频数目的误码率曲线

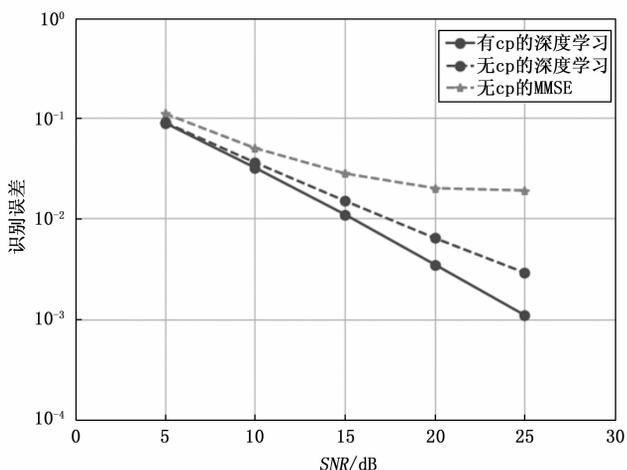


图 8 有无 CP 的误码率曲线

道环境和未知的统计特性可能更具有潜力。基于深度学习的方法在使用较少导频进行信道估计时表现出良好的性能,它能够通过学习大量实验数据来适应不同的信道条件,提高信道估计的鲁棒性和准确性,进而提高无线通信系统的性能。

因此,在选择信道估计方法时,需要考虑具体的应用场景和参数设置。如果已有关于信道统计的先验知识,并且信道条件较为稳定,那么传统的 MMSE 方法可能是一个更好的选择。而如果信道条件复杂、统计特性未知或变化频繁,深度学习方法可能具有更大的潜力。综合考虑实际需求和性能要求,选择适合的方法来解决信道估计问题是非常重要的。

3.3 有无循环前缀的比较

循环前缀可以将物理信道中的线性卷积转化为循环卷积,并降低码间干扰^[19]。然而,它需要大量的时间和能量来传输信息。在本实验中,我们研究了去除循环前缀后两种方法的性能变化,并比较它们之间的差异。

图 8 展示了没有循环前缀的 OFDM 系统的误码率曲线。根据图 8 的结果,可以观察到没有循环前缀的传统 MMSE 方法相比于深度学习无法有效地估计信道。当信噪比大于 15 dB 时,MMSE 方法的识别误差精度逐渐趋于平稳,不再发生变化。然而,深度学习方法在这种情况下仍然能够发挥作用,持续降低误码率。另外还发现,深度学习方法在具有循环前缀的情况下表现更好,即有 CP 的训练效果比没有 CP 的情况更好。这意味着深度学习方法能够发现无线信道的特性,并且在后续的训练阶段可以被深度神经网络学习。

综上所述,去除循环前缀后,传统的 MMSE 方法在信道估计上表现不佳,而深度学习方法仍然能够保持较好的性能。而添加循环前缀后,深度学习方法的训练效果进一步提升,能够更好地发现和学习无线信道的特性。这为优化 OFDM 系统设计和提高通信性能提供了

指导和依据。

3.4 有无限幅噪声的比较

OFDM 系统主要存在的一个明显缺点是峰值平均功率比 (PAPR, peak-to-average power ratio) 较高^[20]。为了降低峰值平均功率比,削波和滤波方法是一种非常简单有效的方法^[12],因此,实验中进一步研究了削波和滤波失真所带来的对系统的影响。然而在限幅之后,非线性噪声会降低检测和估计性能。截断信号变成如下情况:

$$\hat{x}(n) \begin{cases} x(n), & \text{if } |x(n)| \leq A \\ Ae^{j\Phi(n)}, & \text{otherwise} \end{cases} \quad (9)$$

其中: A 是阈值, $\Phi(n)$ 是 $x(n)$ 的相位。图 9 对比了在受到削波噪声干扰的情况下,传统的 MMSE 方法和深度学习方法的检测性能。从图 9 中可以看出,在理想情况下,传统 MMSE 方法的误码率误差略小于深度学习方法,然而当限幅比 ($CR=A/\sigma$, 其中 σ 为信号的均方根) 为 1 且信噪比大于 15 dB 时,深度学习方法的性能优于 MMSE 方法。

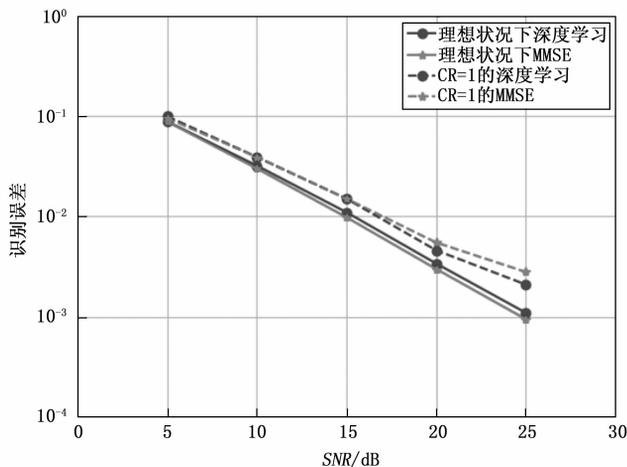


图 9 带限幅噪声的误码率曲线

因此,我们可以得出结论:与传统方法相比,深度学习方法在面对非线性限幅噪声时具有更强的鲁棒性。尽管在理想情况下传统 MMSE 方法略优于深度学习方法,但在实际应用中,当限幅比接近 1 且信噪比较高时,深度学习方法能够更好地适应和处理削波噪声引入的干扰,从而实现更可靠的检测性能。

3.5 合并上述 3 种条件下传统方法与深度学习方法的比较

如图 10 所示,在考虑了多个因素的综合情况下,我们对深度学习方法和传统 MMSE 方法进行了比较。具体而言,研究了在只使用 8 个导频、省略循环前缀以及存在削波噪声的情况下两种方法的性能。实验结果显示,随着信噪比的增加,理想情况下深度学习方法的识别误差呈现出逐渐下降的趋势;但是在考虑了前面 3 种条件的情况下,传统 MMSE 方法的识别误差趋于稳定,而深度学习方法的识别误差仍然呈现下降的趋势。因此,深度学习方法在识别误差方面表现优于传统的 MMSE 方法,其性能更好。与理想情况下的检测性能相比,实际情况下仍存在一定的差距。这表明还有进一步的研究需要进行,以更好地理解这些差异的具体原因和影响。尽管深度学习方法在综合条件下展现出较好的性能,但仍有改进的空间,例如进一步优化网络结构、增加训练样本等方面的探索。

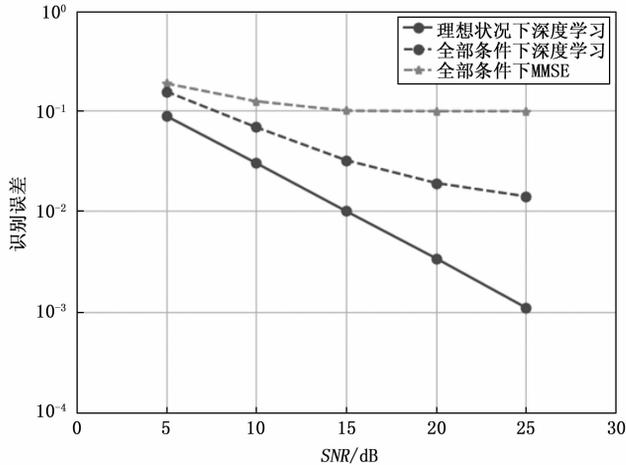


图 10 全部条件下的误码率曲线

综上所述,我们的研究通过对深度学习方法和 MMSE 方法在多种条件下的比较,展示了深度学习方法在识别误差方面的优势。然而,实际性能与理想情况之间存在差距,需要进一步的研究来揭示其中的细节,并提出改进策略。这些结果对于深度学习方法在通信系统中的应用和性能提升具有重要意义,也为未来的研究方向提供了启示。

4 结束语

本文在阐述传统的信道估计算法以及基于深度学习

的信道估计算法基础上,展示了在 OFDM 系统中使用传统方法与深度学习方法进行信号检测设计的比较方案。通过模拟数据,将 OFDM 和无线信道建模为黑匣子,并使用这些数据进行了模型的训练。通过对比分析不同算法之间的优点与缺点,本文初步展示了在 OFDM 系统中使用深度学习方法进行信道估计和符号检测的成果。实验结果表明,在条件相同的情况下,密集采集数据点和增加迭代次数可以提高实验结果的准确性,减少误差。在无线信道受到严重的失真和干扰的情况下,深度学习方法相较于传统的 MMSE 方法,表现出更小的识别误差,具有一定的优势。这证明了使用 DNN 模型来研究复杂无线信道特性的可行性。在实际应用中,DNN 模型需要具备准确的泛化能力,以便在在线部署阶段与离线训练阶段中所用到的信道模型有差别时,依旧能有效地工作。

因此,本文通过综合比较传统方法和深度学习方法,以及对实验结果的验证,展示了在 OFDM 系统中使用深度学习方法进行信号检测设计的潜力。这为今后进一步的研究提供了更为严谨的分析和更为全面的实验基础。这对于提升无线通信系统性能和探索深度学习在通信领域的应用具有重要意义,为未来进一步研究提供了启示和基础。

参考文献:

- [1] ANIS C. SVM based on LMMSE for high-speed coded OFDM channel with normal and extended cyclic prefix [J]. *Physical Communication*, 2018, 29: 288-295.
- [2] 姚成凤,葛万成. OFDM 在现代高速无线通信中的新应用 [J]. *信息安全与通信保密*, 2005 (4): 52-54.
- [3] 谢益溪. *无线电波传播:原理与应用* [M]. 北京:人民邮电出版社, 2008.
- [4] 何江. OFDM 系统的信道估计研究与实现 [D]. 成都:西南交通大学, 2017.
- [5] BAI W, HEC, JIANG L G, et al. Blind channel estimation in MIMO-OFDM systems [C] // *IEEE Transactions on Communications*, 2002: 317-321.
- [6] JIANG Y, KYEONG J K, REID T. Joint semi-blind channel estimation and data detection for MIMO-OFDM systems [C] // *IEEE Emerging Technologies: Frontiers of Mobile and Wireless Communication*, 2004: 709-712.
- [7] YONG S C, JAEKWON K, WON Y Y, et al. MIMO-OFDM wireless communications with Matlab [M]. 北京:电子工业出版社, 2013.
- [8] 王妮娜. OFDM 通信系统设计与分析 [J]. *科技风*, 2018 (23): 1671-7341.
- [9] WUJ X. A Comparison of channel estimation between deep learning-based method and traditional pilot-based method in OFDM systems [J]. *International Core Journal of Engi-*

neering, 2021, 7 (2): 349–361.

- [10] WU X, HUANG Z, JI Y. Deep neural network method for channel estimation in visible light communication [J]. Optics Communications, 2020, 125272.
- [11] ALTN G. Deep neural network-based detection of index modulated MIMO-OFDM [J]. Physical Communication, 2022, 52: 101669.
- [12] MUSTAPHA S, JEAN P D, PASCAL C. Third-order Volterra MMSE receivers for enhanced single and multiple antenna interference cancellation [J]. Digital Signal Processing, 2022, 120: 103246.
- [13] YE H, LI G Y, JIANG B H. Power of deep learning for channel estimation and signal detection in OFDM systems [J]. IEEE Wireless Communications Letters, 2018, 7 (1): 114–117.
- [14] YIN S, SEO J S. A 2.6 TOPS/W 16-bit fixed-point convolutional neural network learning processor in 65nm CMOS [J]. IEEE Solid-State Circuits Letters, 2020, 3: 13–16.
- [15] WANG C, SUN J, XU W, et al. Depth learning standard

deviation loss function [J]. Journal of Physics: Conference Series, 2019, 1176 (3): 32050–32057.

- [16] 廖 勇, 花远肖, 姚海梅. 基于深度学习的 OFDM 信道估计 [J]. 重庆邮电大学学报 (自然科学版), 2019, 31 (3): 348–353.
- [17] WANG J, HAO Y, YANG C. The current progress and future prospects of path loss model for terrestrial radio propagation [J]. Electronics, 2023, 12 (24): 4959.
- [18] SHIPPU S, MANOJ S, ROSEPREET K, et al. A 500 km long transmission with coherent optical OFDM using dual polarization quadrature phase shift keying (QPSK) and double sideband suppressed-enhanced carrier (DSS-EC) [J]. Macromolecular Symposia, 2023, 407 (1): 202200128.
- [19] ZHANG L, LI Y, SHI S, et al. Cyclic correlation-based blind SNR estimation for cyclic prefix-less OFDM system [J]. Radio Science, 2023, 58 (6): e2022RS007607.
- [20] LIU X Y, LIU B J, FAN W B, et al. Analysis of the channel estimate model in passive radar using OFDM waveforms [J]. Digital Signal Processing, 2024, 145: 104303.

(上接第 16 页)

器, 并将校准结果实时反馈至数据中心, 从而更加有效地保证雨量传感器始终处于正常工作状态, 提高观测数据的准确性和可靠性。

参考文献:

- [1] 陈志超, 迟庆红. DSC1 型称重式降水传感器典型问题及维护 [J]. 自动化与仪器仪表, 2022 (3): 222–224.
- [2] 陈龙福, 郑道淮, 蒋文欣, 等. SL3-1 翻斗式雨量传感器测量不确定度的评定 [J]. 海峡科学, 2020 (6): 23–25.
- [3] 袁 毅, 毛 倩, 施倩雯, 等. 两种翻斗式雨量测量仪器原理及常见故障分析 [J]. 中低纬山地气象, 2023, 47 (5): 102–106.
- [4] 甘志强, 高 涛, 匡昌武, 等. 区域自动气象站多传感器冗余观测技术设计与实现 [J]. 电子测量技术, 2022, 45 (5): 33–38.
- [5] 袁靖凯, 苏慧君, 郑礼灿. 区域自动气象站雨量传感器故障成因分析 [J]. 海峡科学, 2021 (9): 46–48.
- [6] 吴书成, 魏 爽, 王丽吉, 等. 自动气象站降水实时快速质控算法设计 [J]. 气象科技, 2016, 44 (6): 882–888.
- [7] 段培法, 张 璇, 赵 宇, 等. 基于 STM32 可在线监测传感器状态的翻斗雨量计 [J]. 湖北农业科学, 2021, 60 (5): 121–124.
- [8] 中国气象局气象探测中心. 降水多传感器标准系统建设技术方案 [Z]. 北京: 中国气象局, 2019.

- [9] 中国气象局. 中国气象局气象探测中心高质量发展实施方案 (2023—2025 年) [Z]. 北京: 中国气象局, 2023.
- [10] 深圳国芯人工智能有限公司. STC32G 系列单片机技术参考手册 [Z]. 深圳: 深圳国芯人工智能有限公司, 2023.
- [11] 刘汉臣. 面向孕妇居家健康的胎心胎动监测系统研究 [D]. 合肥: 合肥工业大学, 2022.
- [12] 闫 平. 多翻斗雨量传感器融合系统结构及故障排查 [J]. 农业灾害研究, 2022, 12 (11): 87–89.
- [13] 张 瑞, 蒲小兰, 周 宇. 浅谈多传感器融合技术在气象观测中的应用 [J]. 中低纬山地气象, 2022, 46 (2): 118–120.
- [14] 郎亚军, 行鸿彦. 基于全连接神经网络的红外漫反射光学自动雨量计设计 [J]. 传感技术学报, 2019, 32 (3): 476–480.
- [15] 深圳神兆电子科技有限公司. PL10 芯片资料 V1.0 [Z]. 深圳: 深圳神兆电子科技有限公司, 2022.
- [16] 刘师赫. 口腔医学教学服务机器人系统的设计与控制 [D]. 秦皇岛: 燕山大学, 2022.
- [17] 罗 倩, 邓成中, 王静梅, 等. 基于 STM8S 单片机的档案数字化 [J]. 西华大学学报 (自然科学版), 2019, 38 (5): 94–98.
- [18] 张远海, 翁佩纯. 基于北斗 GPS 双模定位的共享平衡车应用研究 [J]. 仪表技术, 2019 (10): 17–19.
- [19] 深圳市迈优科技有限公司. MY1680U-12P 语音模块使用说明书 [Z]. 深圳: 深圳市迈优科技有限公司, 2018.
- [20] 杭州佐格通信设备有限公司. 雨量自动检定系统使用手册 [Z]. 杭州: 杭州佐格通信设备有限公司, 2023.