

# 在线学习辅助的智能接收机设计与实现

孔凌劲, 梅锴, 刘潇然, 熊俊, 赵海涛, 魏急波

(国防科技大学电子科学学院, 湖南 长沙 410073)

**摘要:** 为了解决复杂场景下的可靠通信问题, 设计了一种在线学习辅助的正交频分复用 (OFDM) 智能接收机。该接收机能够判断信道环境是否发生改变, 并在线收集样本数据进行训练, 形成当前环境下最佳的接收参数。在 OFDM 系统的信道估计模块中, 设计了基于样本含噪均方误差 (MSE) 的性能比较器作为信道环境变化的判断依据, 并采用轻量化的神经网络结构以实现快速在线训练。最后, 通过通用软件无线电外设 (USRP) 进行了实现和验证。仿真和空口实验表明, 所提接收机能够有效感知并适应新的信道环境, 并且在导频数量受限的情况下, 接收性能和收敛速度均优于现有的机器学习方法。

**关键词:** 机器学习; 智能接收机; 在线训练; 正交频分复用

**中图分类号:** TN929.5

**文献标志码:** A

**DOI:** 10.11959/j.issn.1000-436x.2024012

## Design and implementation of online learning assisted intelligent receiver

KONG Lingjin, MEI Kai, LIU Xiaoran, XIONG Jun, ZHAO Haitao, WEI Jibo

College of Electronic Science and Technology, National University of Defense Technology, Changsha 410073, China

**Abstract:** To address the issue of reliable communication under complicated scenarios, an online learning-assisted intelligent OFDM receiver was proposed. The variations of the channel environment could be precepted by the receiver, and the optimal parameters of the receiver under the current scenario were obtained by collecting data and training online. In the channel estimation module of the OFDM system, a performance comparator based on the mean square error of noisy channel samples was designed as the indicator of channel environment variations. To accelerate the online training progress, a lightweight neural network structure was applied. The proposed method was further implemented and verified based on universal software radio peripherals. The numerical simulation and over-the-air experimental results demonstrate that the proposed receiver can perceive and adapt to new environments effectively, and outperforms existing machine learning methods in terms of receiving performance and convergence rate with a limited number of pilots.

**Keywords:** machine learning, intelligent receiver, online training, OFDM

### 0 引言

随着无人技术的快速发展, 无人系统被逐渐应用于各个领域, 如无人集群应急通信保障、空天地广域覆盖网络、空地协同要地防护等<sup>[1]</sup>。面对复杂且多样化的使用场景, 保证无人系统的可靠通信成为亟待解决的关键问题<sup>[2]</sup>。

针对该问题, 利用机器学习技术实现无线通信节点在不同环境下的智能适变成为重要的研究思路<sup>[3]</sup>。现有的基于机器学习的通信系统从结构上主要可以分为端到端系统和模块化接收机 2 种设计思路。其中, 端到端系统不再设置信道估计、均衡等信号处理模块, 只保留通信系统的输入-输出关系。文献[4]使用深度神经网络 (DNN, deep neural net-

收稿日期: 2023-07-24; 修回日期: 2023-11-09

通信作者: 刘潇然, liuxiaoran10@nudt.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61931020, No.62101569)

**Foundation Item:** The National Natural Science Foundation of China (No.61931020, No.62101569)

work) 代替正交频分复用 (OFDM, orthogonal frequency division multiplexing) 发射机和接收机, 通过训练最小化接收端 DNN 的输出符号与发送符号之间的差异, 能够有效地在接收端恢复出信息比特。文献[5]首次将复值神经网络应用于通信系统, 并提出使用多个级联的神经网络实现接收信号解调, 减小了训练难度。然而, 端到端系统为了学习输入-输出符号映射关系, 通常具有较深的神经网络结构, 训练过程仍相对困难。此外, 端到端系统也难以实现传统接收机中的同步定时等关键功能, 在实际信道环境下难以保证传输性能。

针对端到端系统存在的问题, 有学者提出保留传统接收机的模块化结构, 仅利用机器学习实现部分模块的功能。文献[6]首次提出用深度学习实现联合信道估计与均衡, 其在信号非线性失真、循环前缀 (CP, cyclic prefix) 缺失以及导频信号数量欠缺的情况下性能优于传统方法。文献[7]针对 5G 物理层设计了基于深度卷积神经网络的接收机, 实现了信道估计、均衡以及解映射。为进一步降低训练的难度, 也可在不改变传统接收机模块的情况下通过机器学习直接学习接收机的关键参数, 获得当前环境下更优的性能。该方面的研究包括同步<sup>[8-9]</sup>、信道估计<sup>[10-12]</sup>、均衡<sup>[13]</sup>、信道译码<sup>[14]</sup>等。

随着研究的深入, 基于机器学习的接收机通常采用深度网络实现复杂的信号处理功能, 其训练过程依赖于大量的训练数据和训练时间, 因此大多在预先制作的数据集上进行离线训练。然而, 由于离线数据集与实际通信数据分布存在差异, 离线训练的模型应用在真实通信环境下时往往会遭受性能损失<sup>[15]</sup>。以信道估计为例, 假设  $h_{\text{off}}$  和  $h_{\text{on}}$  分别代表离线和在线的信道响应真值,  $\hat{h}$  代表基于离线信道数据训练得到的估计器。该估计器在线应用时的均方误差满足

$$\mathbb{E}\left[|\hat{h} - h_{\text{on}}|^2\right] \geq \mathbb{E}\left[|\hat{h} - h_{\text{off}}|^2\right] + \mathbb{E}\left[|h_{\text{off}} - h_{\text{on}}|^2\right] \quad (1)$$

不等式(1)右侧第一项为离线训练时的损失函数, 可以通过设计合理的模型和训练过程尽可能减小; 第二项为离线数据集和在线信道环境的差异性引起的模型泛化误差, 是未知且难以预测的。为了学习到真实信道环境的特性, 减小离线模型泛化误差, 文献[16]采用了离线训练和在线微调结合的训练方式, 取得了比传统信道估计更好的效果。文献[17]提出了一种基于元学习的训练框架, 使模型基于较少的在线样本即可适应于通信任务。然而, 为完全

避免泛化误差带来的接收性能损失, 模型的训练数据应该全部通过实际的运行环境在线获取。此外, 由于无人系统部署场景的多样化和复杂性, 为了适应信道环境的变化, 还需要接收机能够自主判断信道环境的改变并实时在线收集训练数据, 快速完成训练。

针对以上问题, 本文提出了一种在线学习辅助的 OFDM 智能接收机, 在保留现有接收机模块化结构的同时, 使用轻量化的机器学习方法并行处理接收信号。针对信道环境变化造成接收机参数失配、性能下降的问题, 设计了基于样本含噪均方误差这一指标的性能比较器。在不引入额外通信开销的情况下, 接收机能够基于信道估计的实时性能准确感知信道环境变化, 自主控制学习算法的训练过程, 动态获取最佳的接收机参数, 因此能适应于快速变化的信道环境。针对信道估计和均衡模块开展了性能仿真, 测试了接收机对信道场景变化的识别能力; 进一步构建了基于 USRP 的智能接收机实物验证系统, 进行了空口传输测试, 验证了所提框架的有效性。

## 1 传统 OFDM 接收机设计

OFDM 技术被广泛应用于无线通信系统<sup>[18-20]</sup>, 其接收机结构框架如图 1 所示。其中, 信道估计和均衡的作用是估计无线信道的衰落, 并将估计结果用于数据符号的恢复与补偿。




图1 传统 OFDM 接收机结构框架

### 1.1 信道估计

考虑一个具有  $K$  个子载波的 OFDM 通信系统, 其频域信号模型可以表示为

$$\mathbf{Y} = \mathbf{X}\mathbf{h} + \mathbf{n} \quad (2)$$

其中,  $\mathbf{Y} \in \mathbb{C}^K$  为频域接收信号;  $\mathbf{X} \in \mathbb{C}^{K \times K}$  为频域发射信号, 是对角矩阵;  $\mathbf{h} \in \mathbb{C}^K$  和  $\mathbf{n} \in \mathbb{C}^K$  分别为频域信道响应和噪声, 两者均满足一定的随机过程。为了从接收信号中恢复出发射信息, 首先需要尽可能准确地估计出信道响应。在导频辅助的信道估计方法中,  $\mathbf{X}$  被视作已知的导频符号, 此时最小二乘 (LS, least square) 估计表示为

$$\hat{\mathbf{h}}_{\text{LS}} = \mathbf{X}^{-1}\mathbf{Y} \quad (3)$$

LS 估计的复杂度最低, 但估计误差受到噪声功率的影响较严重。最小均方误差 (MMSE, minimum mean

square error) 估计考虑了信道噪声, 是理论最优的估计器。大多数信道估计方法都是基于 LS 估计结果进一步处理, 以获得接近 MMSE 估计的性能。记  $\hat{\mathbf{h}}_{\text{LS}} = [\hat{h}_1, \hat{h}_2, \dots, \hat{h}_K]^T$ , 则第  $k$  个子载波的线性最小均方误差 (LMMSE, linear MMSE) 信道估计可以表示为

$$\hat{\mathbf{h}}_{\text{LMMSE}}^k = \mathbf{r}_{\mathbf{h}_k \mathbf{h}_k} \left( \mathbf{R}_{\mathbf{h}_k \mathbf{h}_k} + \frac{\sigma_n^2}{\sigma_x^2} \mathbf{I} \right)^{-1} \hat{\mathbf{h}}_k \quad (4)$$

其中,  $\hat{\mathbf{h}}_k \in \mathbb{C}^{K-1}$  是由  $\hat{\mathbf{h}}_{\text{LS}}$  中除  $\hat{h}_k$  以外的元素构成的向量,  $\mathbf{h}_k \in \mathbb{C}^{K-1}$  是对应于  $\hat{\mathbf{h}}_k$  的真实信道响应,  $\mathbf{r}_{\mathbf{h}_k \mathbf{h}_k} \in \mathbb{C}^{K-1}$  是  $\mathbf{h}_k$  与  $\mathbf{h}_k$  的互相关向量,  $\mathbf{R}_{\mathbf{h}_k \mathbf{h}_k} \in \mathbb{C}^{(K-1) \times (K-1)}$  是  $\mathbf{h}_k$  的自相关矩阵, 两者依赖于信道的统计模型<sup>[21]</sup>, 而在实际通信中难以直接获得。

鲁棒的线性 MMSE (RLMMSE, robust linear MMSE) 估计<sup>[22]</sup>不需要提前已知信道统计信息。该算法基于均匀的信道时延功率谱计算信道相关矩阵, 估计误差对信道的统计特性具有鲁棒性, 因此可适应不同的信道环境。算法假设信道功率时延谱具有以下形式

$$\Gamma(\tau) = \begin{cases} 1, & \tau \leq \tau_{\max} \\ \tau_{\max}, & \tau > \tau_{\max} \end{cases} \quad (5)$$

其中,  $\tau_{\max}$  表示信道可能的最大时延, 通常设置为 CP 长度。

RLMMSE 估计的互相关向量  $\mathbf{r}_{\mathbf{h}_k \mathbf{h}_k}$  和自相关矩阵  $\mathbf{R}_{\mathbf{h}_k \mathbf{h}_k}$  可以通过式(5)计算得到。对式(5)进行傅里叶反变换, 得到信道的频域相关函数为

$$r_f(\Delta f) = \int \Gamma(\tau) e^{j2\pi\Delta f\tau} d\tau \quad (6)$$

其中,  $\Delta f$  为频率差。假设  $\mathbf{R}_{hh} = \mathbb{E}[\mathbf{h}\mathbf{h}^H]$  为信道自相关矩阵, 则其第  $k$  行、第  $l$  列的元素为

$$\mathbf{R}_{hh}[k, l] = r_f[(k-l)f_0] \quad (7)$$

其中,  $f_0$  为子载波间隔,  $\mathbf{r}_{\mathbf{h}_k \mathbf{h}_k}$  为  $\mathbf{R}_{hh}$  的第  $k$  列除第  $k$  个以外的元素构成的向量,  $\mathbf{R}_{\mathbf{h}_k \mathbf{h}_k}$  为  $\mathbf{R}_{hh}$  除第  $k$  列、第  $k$  行

外的元素构成的矩阵,  $\sigma_x^2$  和  $\sigma_n^2$  分别代表发射信号平均功率和噪声功率, 本文假设  $\sigma_x^2$  和  $\sigma_n^2$  准确已知。

## 1.2 信道均衡

传统接收机通常采用单抽头均衡技术补偿信道衰落, 分别根据每个子载波上的接收信号恢复出发送信号。令  $\mathbf{x}_D = [x_1, \dots, x_d, \dots, x_{N_d}]^T$  表示发送的  $N_d$  个频域数据符号, 则 MMSE 均衡可以表示为

$$\hat{x}_{\text{MMSE}, d} = \frac{\hat{h}_d^*}{\hat{h}_d \hat{h}_d^* + \frac{\sigma_n^2}{\sigma_x^2}} y_d \quad (8)$$

其中,  $y_d$  为接收的数据信号,  $\hat{h}_d$  为数据符号的信道估计结果,  $\hat{x}_d$  为恢复的发送信号,  $\sigma_n^2$  为子载波上的噪声功率。

## 2 在线学习辅助的智能接收机设计

传统接收机设计依赖于信道的统计先验知识, 当信道发生改变时, 固定的接收参数无法保证较好的接收性能。针对这一问题, 本文设计了一种在线学习辅助的 OFDM 智能接收机框架, 如图 2 所示。该接收机保留了传统的接收信号处理模块, 并且增加了额外的机器学习模块, 两者同时并行运行。图 2 中 CEML 和 EqML 分别表示基于机器学习的信道估计模块和信道均衡模块。这些模块可以用于优化相应信号处理过程中的参数, 如信道估计中的最小均方误差插值系数、均衡器抽头系数等。

### 2.1 基于在线学习的信道估计

基于机器学习的信道估计模块可以采用多种学习方法, 包括 DNN<sup>[6]</sup>、复极限学习机<sup>[23]</sup>等。学习模块的信道估计结果可表示为

$$\bar{\mathbf{h}}_{\text{ML}} = f_{\text{CE}}(\hat{\mathbf{h}}_{\text{LS}}) \quad (9)$$

其中, 函数  $f_{\text{CE}}(\cdot)$  代表学习模块从输入到输出的映射关系。学习模块可以采用线性结构、深度卷积网络等, 其结构越复杂, 可学得映射关系的种类通常越多, 相应的估计器的性能潜力也越高。




图 2 在线学习辅助的 OFDM 智能接收机框架

为了使所提接收机方案适应快速变化的信道条件，考虑尽量减少在线训练所需的数据量。本文采用一种简单的网络结构<sup>[24]</sup>，输出通过一个单层线性网络直接与输入连接，可以表示为

$$\bar{\mathbf{h}}_{\text{ML}} = \mathbf{W}_{\text{ML-CE}} \hat{\mathbf{h}}_{\text{LS}} \quad (10)$$

其中， $\mathbf{W}_{\text{ML-CE}} \in \mathbb{C}^{K \times K}$  为信道估计网络的等效权值矩阵。给定训练集  $\mathcal{T} = \left\{ \left( \hat{\mathbf{h}}_{\text{LS}}^{(1)}, \mathbf{h}_{\text{L}}^{(1)} \right), \dots, \left( \hat{\mathbf{h}}_{\text{LS}}^T, \mathbf{h}_{\text{L}}^T \right) \right\}$ ， $\mathbf{W}_{\text{ML-CE}}$  在该训练集上具有最小的均方误差，即

$$\mathbf{W}_{\text{ML-CE}} = \arg \min_{\mathbf{W}} \sum_t \left\| \mathbf{W} \hat{\mathbf{h}}_{\text{LS}}^{(t)} - \mathbf{h}_{\text{L}}^{(t)} \right\|_2^2 \quad (11)$$

其中， $\mathbf{h}_{\text{L}}^{(t)} \in \mathbb{C}^K$  为第  $t$  对训练数据的标签。由于在线信道真值未知， $\mathbf{h}_{\text{L}}^{(t)}$  可以是其他子载波上的 LS 信道估计，也可以是基于信道估计值生成的<sup>[24]</sup>。在本文中，学习模块通过实时收集的信道数据  $\mathcal{T}$  训练网络参数  $\mathbf{W}_{\text{ML-CE}}$ ，是一种在线的学习过程。

## 2.2 基于在线学习的信道均衡

基于机器学习的信道均衡模块通常对 MMSE 均衡结果  $\hat{\mathbf{x}}_{\text{MMSE}}$  作进一步处理，以输出更高精度的恢复信号  $\bar{\mathbf{x}}_{\text{ML}}$ ，如式(12)所示。

$$\bar{\mathbf{x}}_{\text{ML}} = f_{\text{eq}}(\hat{\mathbf{x}}_{\text{MMSE}}) \quad (12)$$

与信道估计模块同理，信道均衡模块可以用简单的线性结构、极限学习机、深度神经网络等。本文同样采用单层线性网络直接处理  $\hat{\mathbf{x}}_{\text{MMSE}}$ ，则网络输出可以表示为

$$\bar{\mathbf{x}}_{\text{ML}} = \mathbf{W}_{\text{ML-EQ}} \hat{\mathbf{x}}_{\text{MMSE}} \quad (13)$$

其中， $\mathbf{W}_{\text{ML-EQ}} \in \mathbb{C}^{K \times K}$  为均衡网络的等效权值矩阵。给定训练集  $\mathcal{T} = \left\{ \left( \hat{\mathbf{x}}_{\text{MMSE}}^{(1)}, \mathbf{x}_{\text{L}}^{(1)} \right), \dots, \left( \hat{\mathbf{x}}_{\text{MMSE}}^{(T)}, \mathbf{x}_{\text{L}}^{(T)} \right) \right\}$ ，训练过程类似地表示为

$$\mathbf{W}_{\text{ML-EQ}} = \arg \min_{\mathbf{W}} \sum_t \left\| \mathbf{W} \hat{\mathbf{x}}_{\text{MMSE}}^{(t)} - \mathbf{x}_{\text{L}}^{(t)} \right\|_2^2 \quad (14)$$

当接收信号存在子载波间干扰 (ICI, inter-carrier interference) 时，仅通过式(8)所示的单抽头均衡技术无法取得理想的性能，通常需要对多个子载波进行联合处理以抑制失真。此时，通过神经网络对均衡后向量  $\hat{\mathbf{x}}_{\text{MMSE}}$  进行联合处理，有望提升均衡模块的性能。

## 2.3 性能比较器

当信道环境发生改变时，训练好的机器学习模块可能出现明显的性能下降。为了动态地获取最佳的接收参数，本文设计了如图3所示的基于信道估计结果的性能比较器，用于判断当前信道环境是否改变。由于无法在线获知信道真值，使用 LS 估计值代替信道真值评估估计器性能，该评价指标被称为样本含噪 MSE<sup>[25]</sup>。对于任一估计器  $\hat{\mathbf{h}}$ ，样本含噪 MSE 可以表示为

$$\xi = \frac{1}{K} \left\| \hat{\mathbf{h}} - \hat{\mathbf{h}}_{\text{LS}} \right\|_2^2 \quad (15)$$

将式(3)代入式(15)，则 RLMMSE 估计的性能评价指标表示为

$$\xi = \frac{1}{K} \left\| \mathbf{W}_{\text{RLMMSE}} \hat{\mathbf{h}}_{\text{LS}} - \hat{\mathbf{h}}_{\text{LS}} \right\|_2^2 \quad (16)$$

其中， $\mathbf{W}_{\text{RLMMSE}} \in \mathbb{C}^{K \times K}$  为 RLMMSE 插值矩阵，其对角线元素为 0，且第  $k$  行的其余元素与向量  $\mathbf{w}_k = \mathbf{r}_{h_k, h_k} \left( \mathbf{R}_{h_k, h_k} + \frac{\sigma_n^2}{\sigma_x^2} \mathbf{I} \right)^{-1}$  中的元素一一对应。基于机器学习的信道估计的性能评价指标表示为

$$\xi = \frac{1}{K} \left\| \mathbf{W}'_{\text{ML-CE}} \hat{\mathbf{h}}_{\text{LS}} - \hat{\mathbf{h}}_{\text{LS}} \right\|_2^2 \quad (17)$$

类似地，构成插值矩阵  $\mathbf{W}'_{\text{ML-CE}}$  的插值系数向量

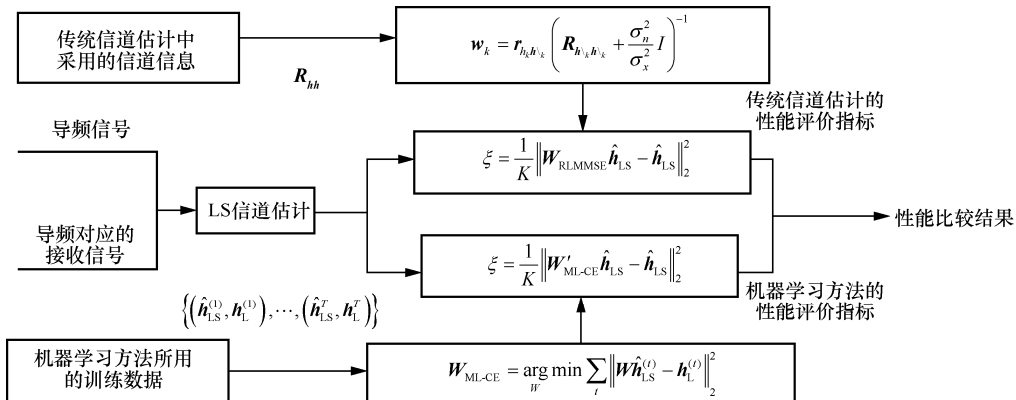


图3 基于信道估计结果的性能比较器

$w_k$  基于训练结果得到<sup>[24]</sup>。 $W'_{ML-CE}$  对角线元素也为 0，第  $k$  行的其余元素与  $w_k$  中的元素一一对应。当信道条件发生明显改变时，训练阶段与使用阶段的数据特征的失配可能造成估计器性能下降。此时，通过比较式(16)和式(17)，可以衡量机器学习方法的实时性能损失，进而使接收机感知到信道环境的改变。

### 2.4 智能接收机工作流程

智能接收机的工作流程如图 4 所示。为衡量信道环境变化带来的影响，将传统接收模块的性能作为基准。如果基于在线学习的接收模块的性能优于传统接收模块，则直接输出学习的结果；否则，判定信道环境发生改变，接收机开始在当前信道环境下收集训练数据并进行重新训练。在训练过程中，在线学习模块已经与当前信道环境不匹配，无法提供最佳的接收参数或有效的辅助信息。此时为了确保整个智能接收模块能够正常工作，使用传统接收模块完成接收信号的处理。在训练结束后，再次比较基于在线学习的接收模块的性能是否优于传统接收模块来判断训练是否成功。因此，所提接收机框架实现了对是否启用训练和训练结果可用性的自主判断，从而能够自主控制在线训练过程。

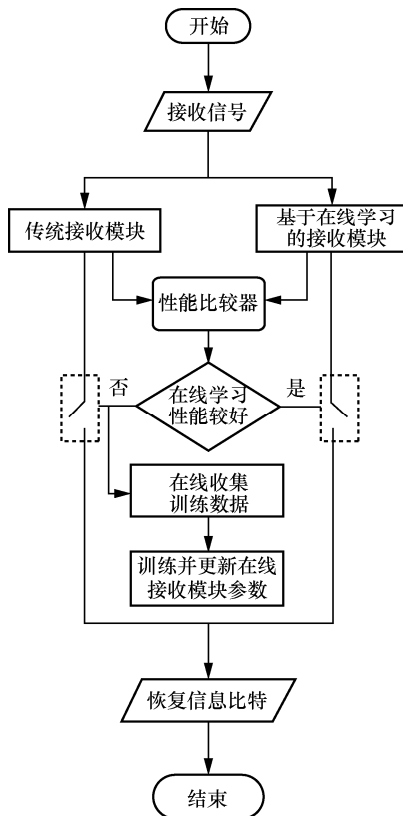


图 4 智能接收机的工作流程

### 2.5 性能分析

本节针对所提接收机采取的并行工作框架的接收性能、计算复杂度和时效性进行分析。假设在一段时间内，接收机可能经历两类信道环境，两类环境出现的概率分别为  $p$ 、 $1-p$ ，其中  $0 < p < 1$ 。针对信道估计问题，设在第一类信道环境下，在线学习方法的 MSE 为  $\theta_1^2$ ，传统方法的 MSE 为  $\rho_1^2$ ，且有  $\theta_1^2 > \rho_1^2$ ；设在第二类信道环境下，在线学习方法的 MSE 为  $\theta_2^2$ ，传统方法的 MSE 为  $\rho_2^2$ ，且有  $\theta_2^2 < \rho_2^2$ 。则在整个时间段内，如果单纯使用在线学习方法，则信道估计 MSE 为

$$\Delta_1 = p\theta_1^2 + (1-p)\theta_2^2 \quad (18)$$

如果单纯使用传统方法，则 MSE 为

$$\Delta_2 = p\rho_1^2 + (1-p)\rho_2^2 \quad (19)$$

假设性能比较器受到随机噪声影响，正确判断环境改变的概率为  $\varepsilon$ ， $0 < \varepsilon < 1$ ，则此时在所提接收机框架下，接收机的平均 MSE 为

$$\Delta_3 = p(\varepsilon\rho_1^2 + (1-\varepsilon)\theta_1^2) + (1-p)(\varepsilon\theta_2^2 + (1-\varepsilon)\rho_2^2) \quad (20)$$

相对于单纯使用在线学习方法，性能增益为

$$\Delta_1 - \Delta_3 = p\varepsilon(\theta_1^2 - \rho_1^2) + (1-p)(1-\varepsilon)(\theta_2^2 - \rho_2^2) \quad (21)$$

因此当  $\varepsilon > \frac{1}{1 + \frac{p}{1-p} \frac{\theta_1^2 - \rho_1^2}{\rho_2^2 - \theta_2^2}}$  时， $\Delta_1 - \Delta_3 > 0$ ，接

收机能够获得性能增益，增益大小由信道环境 ( $p$ )、估计器自身 MSE 性能 ( $\theta_1^2$ 、 $\rho_1^2$ 、 $\theta_2^2$ 、 $\rho_2^2$ ) 和正确判断概率 ( $\varepsilon$ ) 共同决定。同理，可以分析相对传统方法的性能增益。

正确判断概率  $\varepsilon$  取决于性能比较器的设计。如果信道真值已知，则可以直接计算 2 种估计方法的 MSE (记为  $\sigma_{MMSE}^2$ ) 作为判断依据。在数据量足够大的情况下，可以达到  $\varepsilon = 1$ ，即总能准确选择 MSE 性能最佳的方法，所提接收机框架性能增益达到最大化。考虑到实际接收过程中信道真值未知，本文性能比较的依据是信道估计的含噪 MSE，即式(15)中的  $\xi$ 。 $\xi$  是近似估计  $\sigma_{MMSE}^2$  的一个统计量，文献[25]证明了  $E[\xi] = \sigma_{MMSE}^2 + \sigma_n^2$ ，其中  $\sigma_n^2$  是噪声功率。因此，信道噪声功率越大，含噪 MSE 这一指标越不准确，则性能比较器的误判概率越大，框架的性能增益下降。当  $\varepsilon = 0.5$  时，性能比较器完全无法分辨信道是

否变化，只能随机地选择信道估计方法。此时，接收机信道估计的 MSE 性能达到下界

$$\Delta_4 = \frac{1}{2}p(\theta_1^2 + \rho_1^2) + \frac{1}{2}(1-p)(\theta_2^2 + \rho_2^2) \quad (22)$$

文献[24]基于复数乘法次数，对线性网络、DNN、复极限学习机和 RLMMSE 信道估计的计算复杂度进行了分析。在相同的输入维度  $N$  和输出维度  $S$  下，基于线性网络信道估计所需的复数乘法次数为  $NS$ ，RLMMSE 信道估计所需的复数乘法次数为  $C_{\text{inv}}(N^3) + N(N+S)$ ，其中  $C_{\text{inv}}(N^3)$  为计算  $N \times N$  维矩阵逆的复数乘法次数。由于两类算法同时在线运行，信道估计模块的复数乘法次数为  $C_{\text{inv}}(N^3) + N(N+2S)$ ，相比 RLMMSE 估计方法稍有增加。相对于 DNN、复极限学习机等方法，所提接收机具有合理的计算复杂度。

此外，文献[26]基于假设检验理论分析了线性神经网络的训练数据量和训练效果之间的关系，指出当网络输入维度（子载波数）为 240 时，使用 2 400 组数据进行训练，可以使信道估计网络的 MSE 与 MMSE 估计之间的相对性能差距小于 10%。假设 OFDM 系统信号带宽为 20 MHz，子载波数为 256，在不考虑循环前缀、前导序列的情况下，传输 2 400 个 OFDM 符号的耗时约为 30 ms。因此，所提接收机通过轻量化的网络结构，可以快速收集在线训练所需的数据，较好地适应复杂场景下快速变化的信道环境。

### 3 接收机性能仿真实验

为深入分析所设计的智能接收机性能，本节首先仿真评估在线学习方法在跨域情况下的信道估计误差，并对比不同信道估计和均衡算法下的接收机整体误码率。然后，通过信道场景变化识别测试，验证接收机感知信道环境变化的能力。

#### 3.1 基于在线学习的信道估计模块性能测试

通过不等式(1)可知，泛化能力是确保复杂环境下接收机性能的关键。本节对比了基于在线学习的信道估计方法（记为 Online CE）与离线学习+微调方法<sup>[16]</sup>（记为 SwitchNet）和迁移学习方法<sup>[27]</sup>（记为 TransferNet）在信道环境变化时的估计性能。SwitchNet 的思想是首先在 3 种离线信道环境下，训练 3 个信道估计子网络  $FC_1$ 、 $FC_2$ 、 $FC_3$ ，然后在线学习一个权重向量  $(\alpha_1, \alpha_2, \alpha_3)$ ，并对子网络的输出

加权求和，得到最终的信道估计结果。TransferNet 则首先基于离线数据训练得到网络模型，并在在线环境中重新训练输出层神经元参数，以获得新环境下的泛化能力。网络结构如表 1 所示，其中 Online CE 不含有隐藏层，SwitchNet 每个子网络含有一个 144 个神经元的全连接结构（FC, full connected）的隐藏层。TransferNet 网络结构与 SwitchNet 的子网络一致。

表 1 基于神经网络的信道估计方法的网络结构

方法	网络层	数据维度	激活函数
Online CE	输入 (LS 估计)	144	无
	输出	288	
SwitchNet	输入 (LS 估计)	144	无
	$FC_1$ 、 $FC_2$ 、 $FC_3$	288、288、288	
	输出 $\alpha_1 FC_1 + \alpha_2 FC_2 +$	288	
	$\alpha_3 FC_3$		
TransferNet	输入 (LS 估计)	144	无
	FC	288	
	输出	288	

信道估计实验采用的 OFDM 帧结构如图 5 所示，每个子帧包含一个导频符号 Pilot 和一个数据符号 Data，每个符号包含  $K = 72$  个子载波，子载波间隔设置为 15 kHz。为避免产生符号间干扰 (ISI, inter-symbol interference)，在每个符号前端附加  $\frac{1}{4}$  个符号长度的循环前缀。




图 5 信道估计实验采用的 OFDM 帧结构

离线训练阶段，本文实验基于 3GPP TS 36.101 标准<sup>[28]</sup>提出的 EPA、EVA、ETU 三类信道模型，在 5 dB、10 dB 和 15 dB 这 3 种信噪比条件下，共传输 225 000 个子帧，用于制作离线数据集。在线训练阶段则基于 3GPP TR 25.943 标准的 CDMA TUx 典型城区信道模型<sup>[29]</sup>进行估计性能测试。这四类信道模型具有不同的多径数量和时延功率谱参数，可以认为代表不同的信道环境。

离线训练时，将导频符号的 LS 信道估计作为

SwitchNet 和 TransferNet 的网络输入，以预测 2 个 OFDM 符号的信道响应。离线训练使用信道真值作为训练标签。由于在线学习与适变阶段无法获知信道真值，故使用整个子帧的  $\hat{\mathbf{h}}_{LS}$  代替  $\mathbf{h}$  作为训练标签。仿真过程训练参数如表 2 所示。由于上述网络均只能处理实值数据，本实验将频域信号的实部、虚部拆分并重排为一维实向量后，作为训练的输入和标签。

表 2 仿真过程训练参数

参数	参数值
SNR/dB	5~25
损失函数	MSE
初始化学学习率	$1 \times 10^{-4}$
优化器	Adam
训练轮次	100
训练数据量/组	15 000

对于 Online CE 方法，其输入与上述网络相同，网络具有式(10)的形式。采用文献[24]提出的基于导频的训练数据生成方案，首先对块状导频内部进行分组，本文实验选择每 4 个子载波为一组，记为  $\mathbf{h}_{P,k} = [\hat{h}_k, \hat{h}_{k+1}, \hat{h}_{k+2}, \hat{h}_{k+3}]^T$ ,  $k = 1, 2, \dots, K-3$ 。以  $\mathbf{h}_{in,k} = [\hat{h}_k, \hat{h}_{k+3}]^T$  为输入， $\mathbf{h}_{out,k} = [\hat{h}_{k+1}, \hat{h}_{k+2}]^T$  为标签，构成一组训练数据，记为  $\mathbf{H}_{in} = [\mathbf{h}_{in,1}, \dots, \mathbf{h}_{in,K-3}]$ ,  $\mathbf{H}_{out} = [\mathbf{h}_{out,1}, \dots, \mathbf{h}_{out,K-3}]$ ，可以训练插值器

$$\mathbf{W}_d = \mathbf{H}_{out} (\mathbf{H}_{in})^\dagger \quad (23)$$

记  $\mathbf{W}_d = \begin{bmatrix} w_{11} & w_{12} \\ w_{21} & w_{22} \end{bmatrix}$ ，则 Online CE 的等效权值

矩阵按照元素间映射关系表示为

$$\mathbf{W}_{ML-CE} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ w_{11} & 0 & 0 & w_{12} & \dots \\ w_{21} & 0 & 0 & w_{22} & \dots \\ 0 & 0 & 0 & 1 & \dots \\ \vdots & & & & \ddots \end{bmatrix} \quad (24)$$

基于一个块状导频，可生成  $K - (M - 1)D^f + 1$  个训练数据对<sup>[24]</sup>。其中， $M$  为一个分组内的导频子载波数， $D^f$  为导频子载波间隔，本文实验设置  $M = 2$ 、 $D^f = 4$ ，即 69 组训练数据。

图 6 为在线测试阶段信道估计方法的均方误

差，其中传统方法包括 LS 估计、LMMSE 估计和具有均匀 PDP 的 RLMMSE 估计。 $L$  为 SwitchNet 和 TransferNet 在线训练所使用的子帧数，即训练数据量大小。由图 6 可知，当在线训练数据充足 ( $L = 50$ ) 时，TransferNet 性能在高信噪比下最优，但随着训练数据量的减少 ( $L = 5$ )，TransferNet 性能在 3 种学习型方法中最差，这是因为训练不充分导致性能潜力难以完全发挥。SwitchNet 和所提的 Online CE 方法受到数据量  $L$  的影响，SwitchNet 仅需要在线学习 3 个权重参数，Online CE 不含有隐藏层，两者都不依赖于大量的训练数据。因此，在导频开销有限或信道场景快速变化的情况下，Online CE 方法估计误差优于 TransferNet 方法，在高信噪比下优于 SwitchNet 方法。

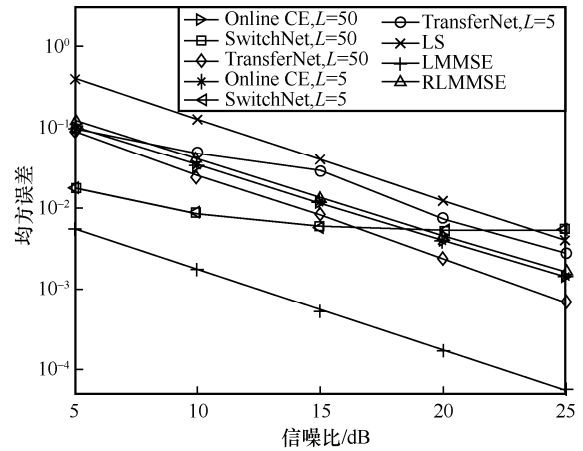


图 6 在线测试阶段信道估计方法的均方误差

图 7 为 3 种信道估计方法的实时估计误差，仿真设置每经过  $L = 5$  个子帧，网络重新训练一次，其中每经过 100 个子帧，改变当前的信道模型，以模拟信道环境的变化。仿真设置信噪比 SNR = 25 dB，蒙特卡罗仿真次数为 100。可以发现，当信道环境发生变化时，SwitchNet 和 TransferNet 需要大约 4 个子帧的时间收集训练数据并完成训练才能收敛，而 Online CE 方法根据单个子帧的数据即可完成训练，不存在信道与模型失配造成的性能跳变，即式(1)中的泛化误差。同时，由于训练数据较少，TransferNet 在每次训练都发生了明显的过拟合，估计误差随时间显著波动。而信道时变性使 Online CE 产生的性能波动最小。仿真结果表明，Online CE 方法具备导频开销小、适变速度快、估计性能稳定的特点，能够满足有人无人通信系统对复杂环境下传输鲁棒性的要求。

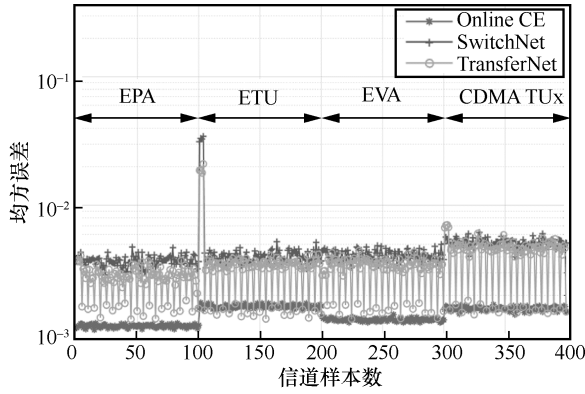


图 7 3 种信道估计方法的实时估计误差

### 3.2 基于在线学习的智能接收机误码率测试

本节考虑接收机整体，衡量所设计的在线学习模块对误码率性能带来的增益。实验基于 IEEE 802.11 ax 标准<sup>[30]</sup>设计传输过程，采用正交振幅调制（QAM, quadrature amplitude modulation）完成编码比特向星座图的映射。仿真设置载波频率为 5.25 GHz，OFDM 信号带宽为 20 MHz，子载波数  $K = 256$ ，CP 长度为 16，采用 IEEE 802.11 ax 室内信道模型<sup>[31]</sup>下的 Model B。为了突出信道估计和均衡算法的影响，本节针对未经过信道编码的误码率进行比较。实验训练阶段在信噪比为 40 dB 的条件下产生了约 100 万组数据；测试阶段根据误帧率情况，在不同的信噪比条件下传输 1 000~100 000 个数据帧。

首先评估 DNN<sup>[6]</sup>、线性网络、LS、RLMMSE 这 4 种信道估计方法对接收机的误码率影响。其中，DNN 采用全连接结构，包含一个隐藏层和一个输出层。隐藏层含有  $4N$  个神经元，使用双曲正切激活函数；输出层含有  $2N$  个神经元，使用线性激活函数。其中  $N$  代表网络输入维度，实验仿真了  $N = 8$  和  $N = 242$  这 2 种不同的设置。训练时，2 种学习模型均使用导频处的 LS 估计  $\hat{\mathbf{h}}_{\text{LS}}^{(t)}, t = 1, \dots, T$  作为输入数据，基于文献[24]提出的方法，使用判决反馈得到的数据符号的信道响应  $\hat{\mathbf{h}}_{\text{D}}^{(t)}, t = 1, \dots, T$  作为标签。则线性网络权值矩阵式(11)具有显式表达

$$\mathbf{W}_{\text{ML-CE}} = \hat{\mathbf{H}}_{\text{D}} (\hat{\mathbf{H}}_{\text{LS}})^{\dagger} \quad (25)$$

其中， $\hat{\mathbf{H}}_{\text{D}} = [\hat{\mathbf{h}}_{\text{D}}^{(1)}, \dots, \hat{\mathbf{h}}_{\text{D}}^{(T)}]$ ， $\hat{\mathbf{H}}_{\text{LS}} = [\hat{\mathbf{h}}_{\text{LS}}^{(1)}, \dots, \hat{\mathbf{h}}_{\text{LS}}^{(T)}]$ ， $(\cdot)^{\dagger}$  代表 Moore-Penrose 广义逆。仿真时，调制方式采取 16QAM，信道均衡模块固定使用 MMSE 均衡，RLMMSE 估计的  $\tau_{\text{max}}$  参数设置为 CP 长度。

信道估计模块采用不同机器学习方法时的误码率性能如图 8 所示。从图 8 可以看到，在经过训练后，机器学习类方法相比 LS 估计方法具有明显的误码率性能优势。并且，在相同的输入维度下，使用线性结构的网络能获得比 DNN 更好的接收效果，与 RLMMSE 估计性能较接近。一方面，DNN 难以发挥出其非线性拟合能力的优势；另一方面，DNN 的训练过程相对困难，在不经大量实验进行调参的情况下，DNN 难以获得最理想的性能，因此相比线性网络有性能损失。此外，由于线性网络的训练通过单步计算完成，即使输入维度很高，训练所需时间也很短，而对于 DNN 来说，则需要更多的训练时间。更小的训练难度使采用线性网络时，可以进一步通过增大输入维度来提升性能。




图 8 信道估计模块采用不同机器学习方法时的误码率性能

然后，评估 DNN、线性网络、MMSE 这 3 种均衡方法对接收机误码率的影响。DNN 采取与信道估计实验中同样的结构。训练时，使用数据符号的 MMSE 均衡值  $\hat{\mathbf{x}}_{\text{MMSE}}^{(t)}, t = 1, \dots, T$  作为输入，使用对应的发射符号  $\mathbf{x}^{(t)}, t = 1, \dots, T$  作为标签，则线性网络权值矩阵式(14)可以表示为

$$\mathbf{W}_{\text{ML-EQ}} = \hat{\mathbf{X}} (\hat{\mathbf{X}}_{\text{MMSE}})^{\dagger} \quad (26)$$

其中， $\mathbf{X} = [\mathbf{X}^{(1)}, \dots, \mathbf{X}^{(T)}]$ ， $\hat{\mathbf{X}}_{\text{MMSE}} = [\hat{\mathbf{x}}_{\text{MMSE}}^{(1)}, \dots, \hat{\mathbf{x}}_{\text{MMSE}}^{(T)}]$ 。仿真时，调制方式采取 64QAM，信道估计模块固定使用 LS 估计。

由于机器学习方法可以联合处理多个子载波上的接收信号，有望起到抑制 ICI 的效果，本实验去除了精频偏估计模块，以评估存在载波频率偏移 (CFO) 时的接收机性能。信道均衡模块采用不同

机器学习方法时的误码率性能如图 9 所示，其中线性网络输入维度分别设置为  $N=8$  和  $N=234$ 。可以看到，在有 CFO 的情况下，基于机器学习的均衡方法可以有效抑制 ICI，获得比 MMSE 均衡更好的性能。在相同输入维度下，采用 DNN 相比线性网络有微弱性能优势。这表明对于信道均衡，学习模块的非线性拟合能力带来了一定性能增益。此外，增加所提网络的输入维度可以带来显著的性能提升。




图 9 信道均衡模块采用不同机器学习方法时的误码率性能

### 3.3 智能接收机场景变化识别能力测试

性能比较器需要基于传统接收模块和在线学习接收模块信道估计模块的输出，判断当前环境是否需要重新训练。仿真实验中，首先保持信道模型不变，分别统计接收机在 IEEE 802.11 ax 标准定义的 Model A~Model F 这 6 种室内信道模型<sup>[31]</sup>下的虚警概率。然后，在传输过程中随机切换信道模型，每个模型保持的时长为 60 个帧时间，并统计接收机的检测概率。仿真设置信噪比为适中的值，即 25 dB，对  $6 \times 6 = 36$  种情况进行了测试，每种情况进行了 10 000 次蒙特卡罗仿真实验。

识别出信道模型切换的概率如表 3 所示，其中，横向表示切换前的场景，纵向表示切换后的场景，

主对角线的结果表示虚警概率，除主对角线元素之外的其余结果表示检测概率。从表 3 中可以看到，6 种信道模型下虚警概率均为 0，说明信道估计模块在信道环境不改变时，几乎不会重新训练，这表明所设计的接收机有良好的稳定性。观察发现，表 3 中上三角部分的检测概率都为 0，而下三角部分的检测概率大部分为 1。这表明在 6 种场景中，当多径分量丰富的场景切换为多径分量较少的场景时，所提方法难以识别出信道环境的改变，而在相反的情况下则能取得很好的识别性能。这说明在多径分量丰富的场景下训练得到的接收机具有一定鲁棒性，当多径分量减少时，没有遭受明显性能损失。为了验证该推断，对检测概率较低的场景进行了进一步的仿真实验。

图 10 给出了信道场景发生变化时不同信道估计方法的误码率性能。其中，机器学习方法与所提接收机使用一样的线性网络结构，但在新环境下不重新训练；横坐标描述了场景，例如， $B \rightarrow A$  表示信道模型从 Model B 切换为 Model A。从图 10 可以发现，在大多数情况下，传统方法和基于机器学习的方法性能较接近。当信道模型由多径分量丰富的场景切换到 Model C、Model D 和 Model E 时，基于机器学习的方法性能具有明显优势，说明环境的切换没有造成信道估计性能的显著下降，所提接收机的性能依然优于传统接收机，所以可以不重新进行训练。

仿真实验表明，通过在线学习方法的驱动，所设计的智能接收机可以在传统接收机的基础上显著提升数据恢复的精度。同时，智能接收机可以有效地识别出信道环境的改变，可以在变化的信道环境下自主地针对不同环境进行学习，优化接收机的参数配置。

## 4 系统评估

由于无线信道环境具有统计特性未知、传播场景复杂等特点，通信系统的实际性能往往与理论仿

表 3 识别出信道模型切换的概率

模型	Model A	Model B	Model C	Model D	Model E	Model F
Model A	0	0	0	0	0	0
Model B	1	0	0	0	0	0
Model C	1	0.994 5	0	0	0	0
Model D	1	1	0.634 2	0	0	0
Model E	1	1	1	1	0	0
Model F	1	1	1	1	0	0




图 10 信道场景发生变化时不同信道估计方法的误码率性能

真结果存在一定差异，因此空口实验对验证智能接收机的可行性十分重要。目前，已有部分研究测试了智能接收机在真实信道环境下的性能表现，这些原型样机通常需要在使用前进行预训练，在使用过程中不能进行重新训练<sup>[15]</sup>，或者只能修正少量参数<sup>[16]</sup>。本文对具备自主训练功能的接收机进行了空口测试，验证所提智能接收机的信道场景变化感知能力和自适应能力。

#### 4.1 系统实现

空口测试平台主要由 2 台 USRP X310 和 2 台计算机构成，如图 11 所示。其中，USRP X310 的功能是完成发射机和接收机的射频信号处理，包括将基带信号加载到载频上并发射射频信号，以及接收射频信号并解调出基带信号。计算机则通过 Labview 软件完成对 USRP 的控制、数据交互，以及对基带信号的处理，包括发射信号的生成与接收信号的解调、译码等，并实现通信系统的控制与实时信号的可视化。计算机通过 PCI 高速总线与 USRP 数据交互。

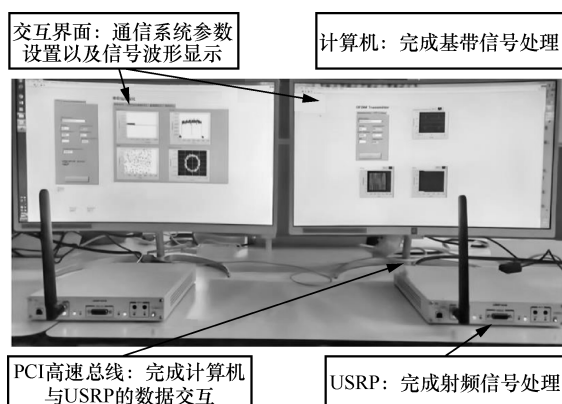


图 11 测试平台实验设备

所提出的智能接收机由计算机上的高级语言编程实现，包括 MATLAB、Python、Labview 的 G 语言等。其工作流程在图 4 中给出。本节主要介绍关键的软件实现过程，可以分为 2 条并行的工作流程，即接收信号的处理和在线学习模型的训练。其中，接收信号处理基于 Labview 联合 MATLAB 实现，在接收机工作过程中全程运行。训练过程基于 Python 实现，在接收机识别到信道环境发生改变时才执行。Python 程序和 Labview 程序的数据交互通过逗号分隔值 (CSV, comma-separated values) 文件实现。具体而言，在开始收集训练数据时，Labview 程序将接收信号保存为 CSV 文件，Python 程序从 CSV 文件中读取接收信号并生成训练数据。在收集到足够的数据后，Python 程序开始执行训练流程，并将训练结束后学习模块的参数保存到 CSV 文件。然后，Labview 程序读取 CSV 文件，更新信道估计和均衡模块中的参数，用于处理新环境下的接收信号。

#### 4.2 测试评估

空口测试平台基于计算机进行通信信号的调制解调，并通过 USRP 将基带信号搬移到 300 MHz 载频进行发射与接收。其中，OFDM 帧结构参考 IEEE 802.11 ax 标准<sup>[30]</sup>，采用正交相移键控 (QPSK, quadrature phase shift keying) 进行调制。在空口测试中，主要关注所提智能接收机相比传统接收机的性能优势，为了降低测试系统复杂度、提高测试效率，传输过程没有进行信道编译码。当神经网络模型需要训练时，接收机收集 10 000 个数据帧用于训练。通过接收信号显示界面，可以观察接收机的工作状态以及接收机的误码率性能。

为测试所提出的智能接收机在多种实际通信

场景中的误码率性能，构建了如图 12 所示的实验系统。发射机将射频信号输入 Prosim F8 信道模拟器，信道模拟器基于自定义的信道模型，模拟不同通信场景下的无线信号衰落过程，并将衰落后的信号输出到智能接收机。信道模拟器所加载的信道模型为欧洲电信标准化协会<sup>[32]</sup>提出的 Model C 和 Model E，两者均适用于无线局域网场景，平均均方根时延拓展分别为 150 ns 和 250 ns，可以用于测试接收机在不同频率选择性衰落情况下的性能。除此之外，实验还通过收发端直连衰减器的方式模拟了不同信噪比下的加性白高斯噪声信道，并进行了传输测试，作为误码率性能的参考。



图 12 基于信道模拟器的空口测试示意

实验比较了 3 种接收机的性能：1) 传统的接收机（记为 Traditional），其中信道估计模块和均衡模块分别采用 LS 估计和 MMSE 均衡；2) 处于训练阶段的所提智能接收机（记为 Training），即信道估计模块和均衡模块分别采用 RLMMSE 估计和 MMSE 均衡；3) 完成训练后的所提智能接收机（记为 Trained），即信道估计模块和均衡模块分别采用经过在线训练的线性网络。通过信道模拟器可以对信号施加功率衰减，从而测试接收机在不同信噪比下的性能，实验结果如图 13 所示。分析发现，由于 Model E 信道时延拓展大于 Model C 信道时延拓展，Model E 信道的频率选择性衰落更明显，因此系统的误码率性能相对较差。而在 AWGN 信道下，接收机具有最好的误码率性能。另一方面，在 3 种信道场景下，所提智能接收机在完成训练后的误码率均最低，这说明在训练结束后，基于机器学习的方法可以利用学习得到的当前信道特性获得较好的接收性能，完成对信道环境的智能适变。此外，从图 13 还可以看出，处于训练阶段的接收机优于传统接收机的性能，这表明所提接收机处于训练阶段时，可以使用 RLMMSE 估计获得相对于 LS 估计更好的接收性能。

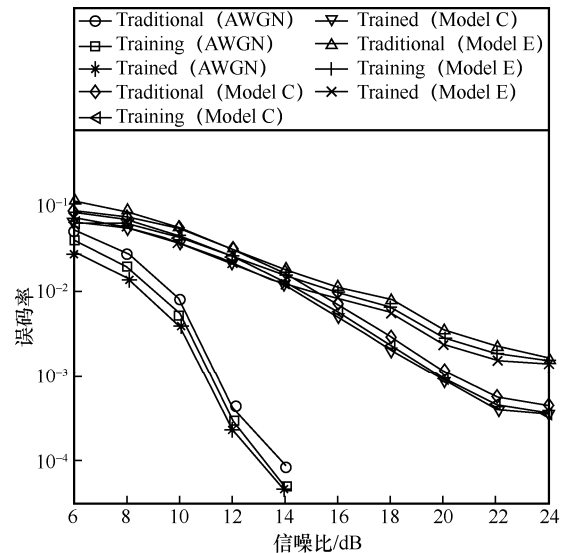


图 13 3 种信道场景下接收机的实测误码率性能

综合上述实验结果与讨论，可以得出以下结论：1) 在线学习是智能接收机实用化的关键，实验中，利用仿真数据预先进行离线训练，接收机在线上时通常会感知到性能损失并进行重新训练，表明离线训练得到的机器学习模型难以直接适用于实际信道；2) 受到在线训练方式的影响，线性结构的学习模块相较于 DNN 效果更好，在实验中采用的训练数据量下，即用 10 000 个数据帧产生的训练数据，通常不会出现过拟合；3) 当信道环境造成机器学习方法的性能下降并低于传统方法时，接收机可以自主地开始收集训练数据并通过训练改善接收机的性能。

### 5 结束语

本文提出了一种全新的可自主在线学习的 OFDM 智能接收机，其主要特点是能够感知信道变化并进行自主训练，训练过程与接收信号的处理过程并行进行。所提接收机可以基于简单的神经网络快速、实时地完成学习模块的训练，以适应高动态通信场景下的信道环境变化。基于实物验证系统完成的空口实验表明，所设计的智能接收机在真实信道环境中具备较好的有效性和可行性。本文的设计思想还可以推广到 OFDM 系统以外的多种无线通信体制中，为未来复杂环境下有人无人协同体系下的可靠通信链路构建提供可行的技术途径。

### 参考文献：

[1] 赵海涛, 高士顺, 王海军, 等. 无人机自主通信和组网能力评估方

- 法[J]. 通信学报, 2020, 41(8): 87-98.
- ZHAO H T, GAO S S, WANG H J, et al. Evaluation method for autonomous communication and networking capability of UAV[J]. *Journal on Communications*, 2020, 41(8): 87-98.
- [2] 王海军, 赵海涛, 任保全, 等. 一种面向无人机智能通信的信息物理融合框架[J]. 中国科学: 信息科学, 2022, 52(11): 2141-2154.
- WANG H J, ZHAO H T, REN B Q, et al. Cyber-physical framework for UAV intelligent communications[J]. *Scientia Sinica (Informationis)*, 2022, 52(11): 2141-2154.
- [3] 尹浩, 魏急波, 赵海涛, 等. 一种面向复杂场景的无线通信节点智能自适应架构[J]. 中国科学: 信息科学, 2021, 51(2): 294-304.
- YIN H, WEI J B, ZHAO H T, et al. An intelligent adaptive architecture for wireless communication in complex scenarios[J]. *Scientia Sinica (Informationis)*, 2021, 51(2): 294-304.
- [4] FELIX A, CAMMERER S, DÖRNER S, et al. OFDM-autoencoder for end-to-end learning of communications systems[C]//*Proceedings of the 2018 IEEE 19th International Workshop on Signal Processing Advances in Wireless Communications (SPAWC)*. Piscataway: IEEE Press, 2018: 1-5.
- [5] ZHAO Z Y, VURAN M C, GUO F J, et al. Deep-waveform: a learned OFDM receiver based on deep complex-valued convolutional networks[J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(8): 2407-2420.
- [6] YE H, LI G Y, JUANG 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.
- [7] HONKALA M, KORPI D, HUTTUNEN J M J. DeepRx: fully convolutional deep learning receiver[J]. *IEEE Transactions on Wireless Communications*, 2021, 20(6): 3925-3940.
- [8] LI A, ME Y, XUE S Y, et al. A carrier-frequency-offset resilient OFDMA receiver designed through machine deep learning[C]//*Proceedings of the 2018 IEEE 29th Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC)*. Piscataway: IEEE Press, 2018: 1-6.
- [9] DÖRNER S, CAMMERER S, HOYDIS J, et al. Deep learning based communication over the air[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2018, 12(1): 132-143.
- [10] YANG Y W, GAO F F, MA X L, et al. Deep learning-based channel estimation for doubly selective fading channels[J]. *IEEE Access*, 2019, 7: 36579-36589.
- [11] ZENG T Y, LI J Y, HU M S, et al. Toward higher performance for channel estimation with complex DnCNN[J]. *IEEE Communications Letters*, 2020, 24(1): 198-201.
- [12] 梅锴, 赵海涛, 刘潇然, 等. 高效的基于数据与模型的信道估计算法[J]. 通信学报, 2022, 43(1): 59-70.
- MEI K, ZHAO H T, LIU X R, et al. Efficient model-and-data based channel estimation algorithm[J]. *Journal on Communications*, 2022, 43(1): 59-70.
- [13] FARSAFAD N, GOLDSMITH A. Neural network detection of data sequences in communication systems[J]. *IEEE Transactions on Signal Processing*, 2018, 66(21): 5663-5678.
- [14] CAMMERER S, GRUBER T, HOYDIS J, et al. Scaling deep learning-based decoding of polar codes via partitioning[C]//*Proceedings of 2017 IEEE Global Communications Conference*. Piscataway: IEEE Press, 2017: 1-6.
- [15] ZHANG Y, DOSHI A, LISTON R, et al. DeepWiPHY: deep learning-based receiver design and dataset for IEEE 802.11ax systems[J]. *IEEE Transactions on Wireless Communications*, 2021, 20(3): 1596-1611.
- [16] JIANG P W, WANG T Q, HAN B, et al. AI-aided online adaptive OFDM receiver: design and experimental results[J]. *IEEE Transactions on Wireless Communications*, 2021, 20(11): 7655-7668.
- [17] XIONG K X, ZHAO Z Y, HONG W, et al. Few-shot learning in wireless networks: a meta-learning model-enabled scheme[C]//*Proceedings of the 2022 IEEE International Conference on Communications Workshops (ICC Workshops)*. Piscataway: IEEE Press, 2022: 415-420.
- [18] HWANG C H, LAI G L, CHEN S C. Spectrum sensing in wideband OFDM cognitive radios[J]. *IEEE Transactions on Signal Processing*, 2010, 58(2): 709-719.
- [19] AL-HABASHNA A, DOBRE O A, VENKATESAN R, et al. Second-order cyclostationarity of mobile WiMAX and LTE OFDM signals and application to spectrum awareness in cognitive radio systems[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2012, 6(1): 26-42.
- [20] LIEN S Y, SHIEH S L, HUANG Y, et al. 5G new radio: waveform, frame structure, multiple access, and initial access[J]. *IEEE Communications Magazine*, 2017, 55(6): 64-71.
- [21] NEUMANN D, WIESE T, UTSCHICK W. Learning the MMSE channel estimator[J]. *IEEE Transactions on Signal Processing*, 2018, 66(11): 2905-2917.
- [22] LI Y, CIMINI L J, SOLLENBERGER N R. Robust channel estimation for OFDM systems with rapid dispersive fading channels[J]. *IEEE Transactions on Communications*, 1998, 46(7): 902-915.
- [23] LIU J, MEI K, ZHANG X C, et al. Online extreme learning machine-based channel estimation and equalization for OFDM systems[J]. *IEEE Communications Letters*, 2019, 23(7): 1276-1279.
- [24] MEI K, LIU J, ZHANG X Y, et al. A low complexity learning-based channel estimation for OFDM systems with online training[J]. *IEEE Transactions on Communications*, 2021, 69(10): 6722-6733.
- [25] MEI K, LIU J, LIU X R, et al. LMMSE channel estimation for OFDM systems with channel correlation function selection[J]. *IET Communications*, 2021, 15(17): 2159-2175.
- [26] MEI K, LIU J, ZHANG X C, et al. Performance analysis on machine learning-based channel estimation[J]. *IEEE Transactions on Communications*, 2021, 69(8): 5183-5193.
- [27] LUAN D X, THOMPSON J S. Channelformer: attention based neural solution for wireless channel estimation and effective online training[J]. *IEEE Transactions on Wireless Communications*, 2023, 22(10):


6562-6577.

- [28] 3GPP. Evolved universal terrestrial radio access (E-UTRA); User equipment (UE) radio transmission and reception: TS 36.101[S]. 2011.
- [29] 3GPP. Universal mobile telecommunications system (UMTS); Deployment aspects: TR 25.943 V6.0.0[S]. 2004.
- [30] IEEE. IEEE draft standard for information technology – telecommunications and information exchange between systems local and metropolitan area networks – specific requirements part 11: wireless LAN medium access control (MAC) and physical layer (PHY) specifications amendment enhancements for high efficiency WLAN[S]. 2019.
- [31] JIANHAN L, RON P, NIHAR J, et al. TGax channel model[S]. 2014.
- [32] ETSI. Broadband radio access networks (BRAN); High performance radio logical area network (HIPERLAN) type 2; Requirements and architectures for wireless broadband access[S]. 1999.


[作者简介]



孔凌劲（1999-），男，湖北咸宁人，国防科技大学博士生，主要研究方向为机器学习、物理层传输技术等。




梅锴（1993-），男，四川仁寿人，国防科技大学博士生，主要研究方向为机器学习、物理层传输技术等。



刘潇然（1992-），男，河南洛阳人，博士，国防科技大学讲师，主要研究方向为无线通信信号处理技术、多载波波形设计和智能通信技术。



熊俊（1987-），男，江西丰城人，博士，国防科技大学副研究员，主要研究方向为协同通信、物理层安全和网络资源分配等。



赵海涛（1981-），男，山东昌乐人，博士，国防科技大学教授、博士生导师，主要研究方向为认知无线网络、自组织网络、协同通信等。



魏急波（1967-），男，湖北汉川人，博士，国防科技大学教授、博士生导师，主要研究方向为无线网络协议、通信信号处理、协同通信、认知无线网络等。