



基于 1D-Concatenate 的信道估计 DNN 模型优化方法

卢敏¹, 秦泽豪^{1,2}, 陈志辉^{1,2}, 张敏^{1,2}, 乐光学^{2,3}

(1. 江西理工大学理学院, 江西 赣州 341000;

2. 嘉兴学院信息科学与工程学院, 浙江 嘉兴 314000;

3. 浙江省医学电子与数字健康重点实验室, 浙江 嘉兴 314000)

摘要: 为提高 DNN 模型在无线通信中信道估计精度, 提出一种基于 1D-Concatenate 的信道估计 DNN 模型优化方法。该方法将 Concatenate 进行一维 (1D) 数据转换, 以跳跃连接的方式引入 DNN 模型, 抑制梯度消失问题, 运用 1D-Concatenate 恢复网络训练过程中丢失的数据特征, 提高 DNN 信道估计精度。为验证优化方法的有效性, 选取较典型的基于 DNN 的无线通信信道估计模型进行对比仿真实验。实验结果表明, 本文提出的优化方法对已有 DNN 模型的估计增益提升可达 77.10%, 在高信噪比下信道增益提升可达 3 dB。该优化方法能有效提高 DNN 模型在无线通信中的信道估计精度, 特别是高信噪比下提升效果显著。

关键词: 信道估计; 深度神经网络; Concatenate 维度转换; 数据特征恢复

中图分类号: TN393

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2023097

1D-Concatenate based channel estimation DNN model optimization method

LU Min¹, QIN Zehao^{1,2}, CHEN Zhihui^{1,2}, ZHANG Min^{1,2}, YUE Guangxue^{2,3}

1. College of Science, Jiangxi University of Technology, Ganzhou 341000, China

2. College of Information Science and Engineering, Jiaxing University, Jiaxing 314000, China

3. Zhejiang Key Laboratory of Medical Electronics and Digital Health, Jiaxing 314000, China

Abstract: In order to improve the channel estimation accuracy of DNN model in wireless communication, a DNN model optimization method based on 1D-Concatenate was proposed. In this method, Concatenate performs one-dimensional data transformation, the DNN model was introduced by hopping connection, the gradient disappearance problem was suppressed, and 1D-Concatenate was used to restore the data features lost during network training to improve the accuracy of DNN channel estimation. In order to verify the effectiveness of the optimization method, a typical DNN-based wireless communication channel estimation model was selected for comparative simulation experiments. Experimental results show that the estimated gain of the existing DNN model can be increased by 77.10% by the proposed optimization method, and the channel gain can be increased by up to 3 dB under high sig-

收稿日期: 2022-08-24; 修回日期: 2023-04-12

通信作者: 乐光学, gxyue@zjxu.edu.cn

基金项目: 国家自然科学基金重点项目 (No.U19B2015)

Foundation Item: The National Natural Science Foundation Key Project of China (No.U19B2015)



nal-to-noise ratio. This optimization method can effectively improve the channel estimation accuracy of DNN model in wireless communication, especially the improvement effect is significant under high signal-to-noise ratio.

Key words: channel estimation, deep neural network, Concatenate dimension conversion, data feature recovery

0 引言

正交频分复用 (orthogonal frequency division multiplexing, OFDM) 技术无线通信系统信号质量受信道环境影响, 信号可靠性降低^[1]。为了在接收端获得准确可靠的信号, 需在接收端估计出信道状态信息 (channel state information, CSI), 基于导频的信道估计是获取 CSI 的有效方法之一^[2-4]。最小二乘 (least squares, LS) 法是 OFDM 系统中常用的信道估计方法, 其特点是计算简单, 但估计准确度不高^[3]。随着深度学习在数据处理^[5-8]领域取得巨大的成功, 深度神经网络 (deep neural network, DNN) 被引入无线通信系统, 构建基于 DNN 的信道估计模型已成为研究热点之一。为提高 OFDM 系统信道估计精度, 文献[9]构建了一种全连接深度神经网络 (full connection dense neural network, FC-DNN) 信道估计模型, 有效利用 DNN 的非线性拟合能力, 提高估计的精度, 证明了 DNN 模型可以用于信道估计, 但是 DNN 的信道估计精度并未达到最高值。

DNN 的网络深度与计算开销成正比, 且会导致梯度消失等问题^[10], 另外, IQ 输入数据特征在 DNN 中会出现“丢失”, 接收端难以准确恢复原始的 IQ 信号, 导致 DNN 模型的信道估计精度不高。为解决上述问题, 产业界对面向 DNN 的信道估计方法进行持续的研究和优化, 取得了大量的研究成果。为了减少单个网络的复杂度, Gao 等^[11]提出模型驱动方案, 该方案对信道估计和信道解码模块分别使用不同的子网进行替换, 提高信道估计精度。Bao 等^[12]提出一种简化的深度神经网络 (simplified deep neural network, SimNet), 降低网络复杂度。文献[13]结合离线与在线训练方式, 增强 DNN 的泛化能力, 提高

信道估计精度。Soltani 等^[14]提出 ChannelNet 模型, 使用导频位置的一些已知值进行信道估计, 提高估计精度。Soltani 等^[15]为了查找导频传输的信息量最大的位置, 提出 Concrete Autoencoder, 进一步提升了 ChannelNet 信道估计精度。文献[16]中, 信道估计采用功能链路神经模糊网络 (functional link neural fuzzy network, FLNFN) 算法, 取得优于传统信道估计的精度。Bai 等^[17]提出基于时延线性规划的估计器显示出其对不同导频密度的鲁棒性, 提高信道估计精度。目前, 已有一些提升信道估计精度的 DNN 模型被提出, 但是, DNN 仍然存在特征丢失、梯度消失等问题, 导致估计精度低。

为进一步提高 DNN 模型在无线通信中信道估计精度, 以估计误差为目标函数, 提出一种基于 1D-Concatenate 的信道估计 DNN 模型优化方法。DNN 网络层数多, 计算复杂度高, 训练过程中易出现特征丢失、梯度消失等问题, 导致估计精度低。本文所提出方法将 Concatenate 进行降维, 以跳跃连接的方式引入 DNN 模型缓解梯度消失和特征丢失问题, 提升信道估计精度。本文的主要贡献包含以下 3 个方面。

(1) 提出了一种用于信道估计 DNN 模型的优化方法, 适用于动态衰落信道、信道估计的场景和目前已有的 DNN 信道估计模型。该方法进一步降低了信道估计 DNN 模型的估计误差, 提高了估计精度。

(2) 提出一种 Concatenate 数据降维方式, 应用于所提优化方法, 获取网络训练中丢失的特征, 提高 DNN 全局优化能力。

(3) 为验证优化方法的有效性, 选取较典型基于 DNN 的无线通信信道估计模型进行对比仿真实验。仿真结果表明, 该优化方法能有效提高

DNN 模型在无线通信中信道估计精度,特别是在高信噪比情况下提升效果显著。

1 系统模型

信道估计消除码间串扰与信道干扰,是信号检测、解调和信道均衡的基础^[16],降低最终恢复比特流的误码率。基于深度神经网络的无线通信系统如图 1 所示,主要分为深度神经网络和 OFDM 系统两部分。




图 1 基于深度神经网络的无线通信系统

DNN 是一种多层感知机 (multi-layer perceptron, MLP), 内部网络层可分为输入层、隐藏层、输出层 3 类。各网络层之间紧密连接, 第 i 层的任一节点与第 $i+1$ 层的所有节点相连, DNN 计算式如式 (1) 所示:

$$x_{i+1} = \sum w_i x_i + b \quad (1)$$

其中, w_i 、 b 分别为网络节点之间的增益与偏置, x_i 和 x_{i+1} 分别第 i 层和第 $i+1$ 层的数据特征, 如此通过多层正向传播运算, 输出结果。

正交频分复用技术系统, 通过频分复用实现高速串行数据的并行传输, 具有抗多径衰落的能力, 能够支持多用户接入^[18]。OFDM 系统中的接收信号经过 FFT 处理表示^[13]为:

$$Y = S \cdot H + N \quad (2)$$

其中, S 为发射端发送信号, H 为实际导频和数据位置的 CSI, 以同向和正交分量表示, N 为高斯白噪声, Y 是接收信号。OFDM 系统发

射帧结构如图 2 所示, OFDM 系统频谱图如图 3 所示。




图 2 OFDM 系统发射帧结构




图 3 OFDM 系统频谱图

根据接收信号 Y 估计的导频和数据位置的 CSI 记为 $\hat{H}$, 并最小化 $\hat{H}$ 与 H 之间的误差, 估计过程表示为:

$$\hat{H} = \arg \min \|Y - [\hat{H} \cdot S + N]\|_2^2 \quad (3)$$

以传统信道估计算法 LS 为例, 该算法信道估计过程表示为^[15,19]:

$$\hat{H}_{LS} = \arg \min \|Y - \hat{H}_{LS} \cdot S\|_2^2 = Y \cdot S^{-1} \quad (4)$$

其中, $\hat{H}_{LS}$ 为 LS 算法根据接收信号 Y 估计得到的导频和数据位置的 CSI。信道估计问题中通常使用回归网络进行优化, 估计性能的优劣取决于 $\hat{H}$ 与 H 之间的估计误差大小。



2 1D-Concatenate 改进 DNN 设计

2.1 1D-Concatenate

DenseNets 通过 Concatenate 将任何层到所有后续层进行直接连接^[20], 抑制了 CNN 的数据特征丢失问题, DenseNets 结构如图 4 所示。




图 4 DenseNets 结构

假设网络由 L 层组成, 每层的非线性变化表示为 $g_i(\bullet)$, 第 i 层的输出为 x_i , 则第 L 层网络的输出为:

$$x_L = g_L(\hat{H}_{LS}, x_1, x_2, \dots, x_{L-1}) \quad (5)$$

其中, $\hat{H}_{LS}, x_1, x_2, \dots, x_{L-1}$ 分别为初始输入以及每层网络的输出。Concatenate 的作用是将各网络层的输出进行拼接, 加强了网络层之间特征的联系, 抑制了梯度消失和特征丢失问题。但 DenseNets 结构复杂, 反复的特征输入增加了其网络复杂度, 同时 Concatenate 使用的是二维数据, 难以直接应用于 DNN。

为使 Concatenate^[20] 适用于 DNN, 修改 Concatenate 的数据维度构建 1D-Concatenate, 由于数据维度改变, 1D-Concatenate 不再适用于

DenseNets 等 CNN。1D-Concatenate 将数据特征拼接形成一维向量, 通过拼接隐藏层 1 和隐藏层 $L-1$ 的数据特征, 找回网络丢失的数据特征。假设使用 1D-Concatenate 拼接隐藏层 1 和隐藏层 $L-1$ 的数据特征, 则 1D-Concatenate 运算过程如图 5 所示。




图 5 1D-Concatenate 运算过程

1D-Concatenate 运算步骤如下。

步骤 1 输入隐藏层 1 和隐藏层 $L-1$ 的数据特征 x_1, x_{L-1} 。

步骤 2 x_1, x_{L-1} 被送入 1D-Concatenate 进行拼接。

步骤 3 完成拼接, 输出 1 维拼接数据特征 $[x_1, x_{L-1}]$ 。

2.2 1D-Concatenate 改进 DNN 模型

无线通信中 DNN 模型信道估计的核心是, 以 DNN 模型的非线性拟合能力获取所有资源网格处的 CSI。该方法对传输信息量少、信道环境复杂度低的信道估计效果显著, 但不适合于信息量大、信道环境复杂的信道估计系统。为提高 DNN 模型的信道估计性能精度, 以跳跃连接将 1D-Concatenate 引入 DNN, 减少网络数据特征丢失, 缓解模型内部的梯度消失问题, 提升估计精度。基于 1D-Concatenate 的改进 DNN 方法结构如图 6 所示。




图 6 基于 1D-Concatenate 的改进 DNN 方法结构

其中, $\hat{H}_{LS} = \{(R, I) | R = (r_1, r_2, \dots, r_Q); I = (d_1, d_2, \dots, d_Q)\}$ 。
 R 、 I 分别为 $\hat{H}_{LS}$ 的同向和正交分量, Q 为每个符号插入导频个数, 网络层数为 L , 第 i 层的输出为 x_i , 假设每层的非线性变化表示为 $g_i(\cdot)$, 则第 L 层网络的输出为:

$$x_L = g_L(x_1, x_{L-1}) \quad (6)$$

DNN 用于提取导频序列特征值和信道估计, 由若干个全连接层组成, 这些全连接层通过权重参数相连, 如式 (1) 所示。1D-Concatenate 用于将隐藏层 1 和隐藏层 $L-1$ 的数据特征合并送入输出层, 通过数据特征合并获取丢失的数据特征, 提升信道估计精度。该方法是一种 DNN 模型泛用改进方式, 提升效果受被选取的基础模型影响, 区别于过去针对某一特定网络结构的模型改进方法, 故与针对单一特定网络的改进方法对比结果缺乏可信度。

基于 1D-Concatenate 的 DNN 模型优化方法流程如下:

步骤 1 输入传统 LS 算法估计出的信道状态信息 $\hat{H}_{LS}$;

步骤 2 经过 FC 层转换 $\hat{H}_{LS}$ 为数据特征 x ;

步骤 3 数据特征 x 在深度神经网络内部进行流通计算, 估计出信道状态信息 $\hat{H}$ 。

假设网络一共 L 层, 基于 1D-Concatenate 的 DNN 模型优化方法详细参数见表 1。

2.3 1D-Concatenate 改进 DNN 模型中的数据流

1D-Concatenate 改进 DNN 模型通过 LS 方法初始导频位置的 CSI, 再通过 DNN 获取所有资源网格位置的 CSI。下面分别详细描述了输入样本、特征矢量提取和信道估计。

(1) 输入样本

本文中 DNN 的输入样本为 1 000 个子帧大小的 CSI 矩阵 $\hat{H}_{LS} \in \mathbb{C}^{108 \times 1000}$, $\hat{H}_{LS}$ 为通过 LS 方法估计获取的导频处 CSI。DNN 需要一维数据作为输入, 因此将输入样本变为一维形式, 输入样本表达形式为:

$$\hat{H}_{LS} = [h_1, \dots, h_l, \dots, h_{4000}]^T \quad (7)$$

其中, $h_l \in \mathbb{C}^{27 \times 1}$ 表示第 l 个 OFDM 符号中导频处的 CSI。由于 CSI 是复数信号, 输入 DNN 之前要进行数据预处理, 把 CSI 的同向和正交分量提取出来, 结合成一个维度, 于是输入样本集变为 $H_{LS}^1 \in \mathbb{C}^{216 \times 1000}$, $h_l^1 \in \mathbb{C}^{54 \times 1}$, 即 DNN 的输入。OFDM 符号中导频处 CSI 提取和同向正交分量分离过程, 即数据预处理如图 7 所示, 其中 Q 为一个符号中的导频个数。

表 1 基于 1D-Concatenate 的 DNN 模型优化方法详细参数

网络层名称	网络类型	输出大小
Input	Feature Input	(54,1)
FC 1	Fully Connected	Size of baseline model
FC 2	Fully Connected	Size of baseline model
...	...	...
...	...	...
...	...	...
FC $L-1$	Fully Connected	Size of baseline model
1D-Concat	Concat[FC 2, FC $L-1$]	(Size of(FC 2+FC $L-1$),1)
FC L	Fully Connected	(108,1)
Output	Regression Output	Regression




图7 数据预处理

(2) 特征矢量提取和信道估计

输入样本经过数据预处理后送入DNN, 进行特征矢量提取和信道估计, 与传统人为提取特征的机器算法不同, DNN 可以自动从样本中进行特征值的提取, 获得输入样本中的代表性矢量。1D-Concatenate 优化方法旨在DNN的基础上, 利用初始时刻与最终时刻特征矢量进行拼接, 找回丢失特征, 提升信道估计精度, 因此本文采用DNN 预测CSI, 通过权重与偏置参数运算预测CSI, 充分利用导频信息, 基于式(1), 可以得到全连接层CSI 预测如下:

$$\hat{h}_l = \sum w_l h_l^1 + b_l \quad (8)$$

其中, w_l 和 b_l 分别代表每个全连接层的权重与偏置, 最终输出一个 $108 \times 4\ 000$ 大小的矩阵作为最终估计的同向和正交分量, 再将同向和正交分量组合得到最终输出:

$$\hat{H} = [\hat{h}_1, \dots, \hat{h}_l, \dots, \hat{h}_{4\ 000}] \quad (9)$$

2.4 模型训练

为了训练经1D-Concatenate改进的DNN, 本文使用端到端的训练方式获取网络中所有的权重和偏置参数。设整个网络的变换式和所有参数分别为 $f(\cdot)$ 和 θ , 因此网络估计得到的导频和数据位置的CSI 可表示为 $\hat{H} = f(\hat{H}_{LS}, \theta)$ 。本文使用附加动量随机梯度下降 (SGD with momentum, SGDM) 算法更新网络的参数集, SGDM 算法与

采取固定学习率的梯度下降算法不同, 它基于梯度的移动指数加权平均, 对网络的梯度进行平滑处理, 让梯度的摆动幅度变得更小, 算法伪代码如算法1所示。

算法1 SGDM

Require: 学习率 η , 动量参数 α , 初始参数 Θ , 和初始速度 v

Repeat

从训练集中选择 m 个样本 $\{x^{(1)}, \dots, x^{(m)}\}$,

其中, $x^{(i)}$ 所对应的目标为 $y^{(i)}$;

梯度计算: $g \leftarrow \nabla_{\theta} \sum_i L(f(x^{(i)}; \Theta), y^{(i)}) / m$;

速度更新: $v \leftarrow \alpha v - \eta g$;

参数更新: $\Theta \leftarrow \Theta + v$

Until 达到收敛条件

网络的损失函数设为均方误差 (mean square error, MSE), 因此模型的预测损失为:

$$L(\theta = \hat{\theta}) = \frac{1}{M} \sum_{i=1}^M (f(\hat{H}_{LS}, \theta) - H)^2 \quad (10)$$

其中, H 为监督数据, M 为训练样本集中总样本数, $\hat{\theta}$ 为DNN 模型参数在真实信道状态信息数据集上的最优估计。

3 仿真分析

3.1 实验设置

3.1.1 系统参数设置与仿真评价指标

(1) 实验参数

为验证基于1D-Concatenate的DNN模型优化方法的有效性, 实验采用文献[21]的OFDM 发射端和莱斯衰落信道进行测试。

发射端和衰落信道参数见表2。OFDM 发射端产生25万个输入样本集, 共1 000 帧, 包括15种不同的信噪比 (signal-to-noise ratio, SNR), 范围为0~15 dB, 步长为1 dB。每帧样本集由4个符号构成, 每个符号包含64个子载波, 发射端详细参数见表2。样本集中, 每个样本由54个采样点构

成, 输入样本为 1×54 的向量, 其中同向和正交分量分别代表 I 信号和 Q 信号。样本集标签由信噪比和真实信道状态信息组成。为模拟真实信道环境, 传输信道模块使用莱斯衰落信道, 该信道包含多普勒频移、路径时延、选择性衰落和高斯白噪声等干扰因素, 具体参数见表 2。

表 2 发射端和衰落信道参数

发射端参数		衰落信道参数	
名称	值	名称	值
子载波数	64	路径时延	$[0.0 \ 0.5 \ 1.2] \times 10^{-6}$
导频数	27	平均路径增益	$[0.1 \ 0.5 \ 0.2]$
符号数	4	直射路径多普勒偏移	5.0
发射帧数	1 000	直射路径初始相位	0.5
保护子载波数	4	最大多普勒频移	50
调制方式	BPSK	信道类型	Rice+AWGN

(2) 实验评价指标

为了评估信道估计性能, 本文使用 MSE 和估计增益 (estimate gain, EG) 作为仿真实验的评价标准。MSE 计算式如式 (11) 所示:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n |\hat{H} - H|^2 \quad (11)$$

其中, n 是发射端发射信号总样本数。MSE 是最经典的反映估计量与被估计量之间差异大小的度量之一。

估计增益 EG 计算式如式 (12) 所示:

$$\text{EG} = 10 \lg \frac{\hat{H}_{\text{LS}}}{\hat{H}} \quad (12)$$

3.1.2 信道估计对比模型

为了测试基于 1D-Concatenate 的信道估计 DNN 模型优化方法的优化性能, 对 6 个已有文献中的 DNN 模型进行 1D-Concatenate 改进测试分析, 并与改进前模型进行对比, 为与原有模型区分, 测试中改进后模型统一在原有模型基础上添加 Dense 前缀。已有 DNN 模型和改进模型见表 3。

表 3 已有 DNN 模型和改进模型

基准模型	优化方法	改进模型
FC-DNN	基于 1D-Concatenate 的	DenseFC-DNN
SimNet	信道估计 DNN 模型	DenseSimNet
DL-based	优化方法	DenseDL-based
LS_RefineNet		DenseLS_RefineNet
DNN-1		DenseDNN-1
DNN-2		DenseDNN-2

基准模型网络参数如下。

(1) LS: LS 是传统的信道估计模型, 表达式为式 (3), 采用线性拟合的方式估计 CSI^[19]。

(2) FC-DNN: 由 5 个全连接层组成, 每层神经元个数分别为 256、500、250、120、16, 除最后一层使用 Sigmoid 函数外, 其余层使用 ReLU 激活函数^[9]。

(3) SimNet: 由 5 个全连接层组成, 每层神经元个数分别为 128、150、150、150、128, 隐藏层使用 ReLU 激活函数, 输出层无激活函数^[12]。

(4) LS_RefineNet: 由一层全连接层组成, 神经元个数为 128, 无激活函数^[11]。

(5) DL-based: 由 5 个全连接层组成, 其中输入和输出层的神经元个数, 与输入和输出数据的长度相同, 隐藏层的神经元个数分别为 512、256、128, 除了输出层无激活函数, 其余层使用 ReLU 激活函数^[13]。

(6) DNN-1: 由 5 个全连接层组成, 每层神经元个数分别为 4、32、32、32、4, 隐藏层使用 tanh 激活函数, 输出层无激活函数^[22]。

(7) DNN-2: 由 5 个全连接层组成, 每层神经元个数分别为 16、64、64、64、16, 隐藏层使用 tanh 激活函数, 输出层无激活函数^[22]。

3.2 训练超参数调试

3.2.1 初始学习率取值分析

初始学习率是深度神经网络训练的超参数之一, 较高的初始学习率可以加速网络收敛, 但会



降低网络泛化能力, 较低的初始学习率会获得较好的训练效果, 但训练时间过长^[23]。本实验选择几种常见的初始学习率进行对比, 为神经网络选择最合适的初始学习率。理论上, 初始学习率确实可以影响网络收敛速度, 但实际上这种现象只有在层数深、复杂度高的深度神经网络中可以明显体现, 在本文实验过程中收敛速度几乎没有较大改变, 故本实验将估计精度作为最终评价指标。深度神经网络模型在不同学习下的平均 MSE 见表 4, 不同初始学习率下深度神经网络 MSE 曲线如图 8 所示。

仿真结果表明:

(1) 初始学习率是影响网络的训练泛化效果的重要参数;

(2) 综合分析表 4 和图 8, 本文选取对比模型的初始学习率, DenseSimNet、DenseDL-based 和 DenseLS_RefineNet 为 0.035, DenseFC-DNN 为 0.040, DenseDNN-1 为 0.025, DenseDNN-2 为 0.020。

3.2.2 训练环境 SNR 选定分析

对于深度神经网络, 训练时所选择的 SNR

环境会影响测试时网络的泛化能力。若训练 SNR 较低, 神经网络对低 SNR 区间拥有较强的泛化能力, 反之则对高 SNR 区间拥有较强的泛化能力。根据文献[12]选取最佳 SNR 的方法, 本实验选择几种常见的 SNR 进行训练对比, 为神经网络选择最合适的 SNR 进行训练。在不同训练 SNR 下深度神经网络的平均 MSE 见表 5, 不同训练 SNR 下深度神经网络 MSE 曲线如图 9 所示。

仿真结果表明:

(1) 训练环境 SNR 是影响网络的训练泛化效果的重要参数;

(2) 综合分析表 5 和图 9, 本文选取对比模型的训练 SNR, DenseSimNet 和 DenseDNN-2 为 7 dB, DenseFC-DNN, DenseDL-based 和 DenseLS_RefineNet 为 10 dB, DenseDNN-1 为 4 dB。

3.3 实验对比分析

3.3.1 对比模型与 LS 的 SNR 增益对比分析

通过估计误差对比, 分析改进模型相比于 LS 的信道估计性能, 神经网络与 LS 的 MSE 曲线如图 10 所示。LS 是目前较为常用的信道估计

表 4 深度神经网络在不同学习率下的平均 MSE

模型名称	数据名称	数值						
DenseSimNet	初始学习率	0.010	0.015	0.020	0.025	0.030	0.035	0.040
	平均 MSE $\times 10^2$	1.61	1.51	1.48	1.46	1.45	1.45	1.45
DenseFC-DNN	初始学习率	0.030	0.035	0.040	0.045	0.050	0.055	0.060
	平均 MSE $\times 10^2$	2.48	1.98	1.73	1.74	2.14	1.79	1.78
DenseDL-based	初始学习率	0.010	0.015	0.020	0.025	0.030	0.035	0.040
	平均 MSE $\times 10^2$	2.33	2.03	1.93	1.82	1.86	1.67	1.68
DenseLS_RefineNet	初始学习率	0.010	0.015	0.020	0.025	0.030	0.035	0.040
	平均 MSE $\times 10^2$	1.53	1.46	1.45	1.44	1.44	1.44	1.44
DenseDNN-1	初始学习率	0.005	0.010	0.015	0.020	0.025	0.030	0.035
	平均 MSE $\times 10^2$	3.30	3.00	3.11	3.09	2.67	2.87	2.69
DenseDNN-2	初始学习率	0.005	0.010	0.015	0.020	0.025	0.030	0.035
	平均 MSE $\times 10^2$	2.41	1.55	1.48	1.43	1.38	1.42	1.42




图8 不同初始学习率下深度神经网络的MSE曲线

表5 深度神经网络在不同训练SNR下的平均MSE

模型名称	SNR				
	1 dB	4 dB	7 dB	10 dB	13 dB
DenseSimNet	2.91	3.31	2.71	3.01	2.84
DenseFC-DNN	2.20	1.91	1.93	1.77	2.10
DenseDL-based	2.01	1.76	1.74	1.81	2.05
DenseLS_RefineNet	1.68	1.46	1.44	1.47	1.60
DenseDNN-1	3.00	3.01	3.16	3.02	3.09
DenseDNN-2	1.81	1.43	1.40	1.44	1.53




图9 不同训练 SNR 下深度神经网络的 MSE 曲线

方法,其优点为计算复杂度低,理论效果优异,但是其在复杂动态信道衰落环境下估计精度较差。该方法估计精度与插入导频数呈正相关。改进模型具有较强的非线性拟合能力,应具有更高的信道估计精度。

仿真结果表明:

(1) 改进模型在所有导频数下的性能优于 LS 模型;

(2) LS 模型的 MSE 性能较差的主要原因在于,莱斯衰落信道的 CSI 是一个可变参数,其变化不满足线性假设,LS 算法则采取线性拟合的方式估计导频位置的 CSI,并将其视为相邻数据位置的




图 10 深度神经网络与 LS 的 MSE 曲线



CSI, 导致导频和数据位置的 CSI 的 MSE 性能较差;

(3) 改进模型对莱斯衰落信道, 采取非线性拟合方式估计数据位置的 CSI, 并优化导频位置的 CSI, 有效提高了模型的估计精度;

(4) 上述原因导致在导频数为 27 时, 所有改进模型的 SNR 增益比 LS 模型高 15 dB 以上,

改进模型相较于 LS 模型可更好地适应信道变化。

3.3.2 深度神经网络 SNR 增益对比分析

为评价本文所提出方法对 DNN 模型的改进效果, 以 6 个基准模型与改进模型进行 MSE 测试对比, 深度学习信道估计模型 MSE 曲线如图 11 所示。基准模型和改进模型的差别仅在于是否使




图 11 深度学习信道估计模型 MSE 曲线

用本文所提出方法进行改进, 故该实验可有效证明所提出方法对 DNN 模型估计精度的提升效果。

仿真结果表明:

(1) DenseSimNet 的 SNR 增益比 SimNet 高 2.9 dB, DenseFC-DNN 的 SNR 增益比 FC-DNN 高 2.5 dB, DenseDL-based 的 SNR 增益比 DL-based 高 3.0 dB, DenseLS_RefineNet 的 SNR 增益比 LS_RefineNet 高约 0.1 dB, DenseDNN-1 的 SNR 增益比 DNN-1 高 2.4 dB, DenseDNN-2 的 SNR 增益比 DNN-2 高 1.5 dB;

(2) 造成该仿真结果的主要原因有两个, 一个原因是 DenseSimNet 中 Concatenate 跳跃连接层帮助一些数据特征跳过了部分梯度运算, 避免了梯度消失或爆炸问题对数据特征的影响; 另一个原因是 Concatenate 操作将一部分数据特征重复加入网络, 导致网络的数据特征数增加, 提高了预测的准确性;

(3) 从图 11 (c) 可以看出, 当 $\text{SNR} < 2$ dB 时, DenseLS_RefineNet 的信道估计性能低于 LS_RefineNet, 这是由于当 SNR 过低时, 1D-Concatenate 会保留一部分因干扰产生错误的特征, 导致信道估计性能下降, 但是从仿真结果可以看出该问题在测试的 6 组模型中只有一组明显出现, 且只有 $0 \sim 2$ dB, 所以影响较小;

(4) 图 11 表明高 SNR 下 SNR 增益提升效果显著, 这是由于高 SNR 环境下噪声较少, 正确数据较多, Concatenate 操作可以保留更多的正确数据信息, 故改进后深度神经网络的估计精度更高。

综上所述, 本文所提出的基于 1D-Concatenate 改进的 DNN 方法表现出较好的 MSE 性能, 表明该方法可以让 DNN 模型更好地学习到信道的变化特点, 并提高模型地信道估计估计精度。

3.3.3 深度神经网络估计增益对比分析

估计增益性能是衡量信道估计方法对 LS 估计精度影响的指标。通过对比基准模型和改进模型的估计增益, 评估本文提出方法对基准模型估计增益的提升效果, 深度神经网络估计增益对比

如图 12 所示。估计增益数值越大, 则该信道估计方法对 LS 估计精度的提升效果越强, 反之亦然。

仿真实验结果表明:

(1) 估计增益反映了深度神经网络模型对 LS 估计准确度的提升程度;

(2) 莱斯信道下, 所提出优化方法对深度神经网络的估计性能均为正增益, DenseSimNet 的 EG 比 SimNet 提升 77.10%, DenseFC-DNN 的 EG 比 FC-DNN 提升 38.53%, DenseDL-based 的 EG 比 DL-based 提升 45.66%, DenseLS_RefineNet 的 EG 比 LS-RefineNet 提升 0.26%, DenseDNN-1 的 EG 比 DNN-1 提升 16.38%, DenseDNN-2 的 EG 比 DNN-2 提升 9.52%;

(3) DL-based、DNN-2 分别在 2.20 dB 和 3.00 dB 之前, EG 低于改进前, 其原因为, 当 SNR 过低时传输数据受噪声影响较大, 错误信息较多, 1D-Concatenate 加强了数据连接使错误数据的影响变大;

(4) DenseSimNet、DenseDL-based、DenseLS_RefineNet、DenseDNN-2 的估计增益随着 SNR 的升高可进一步提升。

由以上仿真结果可知, 本文所提的信道估计方法能够使 DNN 模型获得较好的估计精度性能, 虽然 DL-based、DNN-2 在低信噪比下估计增益有所下降, 但总体而言, 本文所提出方法保持了较高的估计增益, 具有提升 DNN 信道估计精度的作用。

4 结束语

深度神经网络在提高无线通信信道估计精度方面展现了显著优势。本文提出了一种 DNN 模型优化方法, 该方法结合 1D-Concatenate 可以减少数据特征丢失, 跳跃连接能缓解梯度消失的特点, 充分利用了输入样本中的信道信息提升 DNN 信道估计精度。通过对 6 个当前先进的 DNN 改进仿真实验, 分析了所提出方法对提升




图 12 深度神经网络估计增益对比

信道估计精度的性能表现。仿真结果表明, 本文所提方法可使 DL-based 信道增益提升 3 dB, SimNet 估计增益提升 77.10%。该方法可以有效提高 DNN 模型的信道估计精度, 尤其是高信噪比环境下效果显著。虽然本文引入的

1D-Concatenate 给出了一种更精确的 DNN 优化方法, 但针对目前 OFDM 的信道估计算法大多忽略外网接入、接收机非同步接收、未授权频率接入等不利因素的影响, 并把信道间干扰近似为莱斯衰落或瑞利衰落来简化估计过程, 因此需

要提出更加精确的优化方法,以得到更高的估计精度。

参考文献:

- [1] ZHANG Z F, WANG C, GAN C Q, et al. Automatic modulation classification using convolutional neural network with features fusion of SPWVD and BJD[J]. *IEEE Transactions on Signal and Information Processing Over Networks*, 2019, 5(3): 469-478.
- [2] 廖勇, 花远肖, 姚海梅, 等. 高速移动环境下基于深度学习的信道估计方法[J]. *电子学报*, 2019, 47(8): 1701-1707.
LIAO Y, HUA Y X, YAO H M, et al. Channel estimation method based on deep learning in high-speed mobile environments[J]. *Acta Electronica Sinica*, 2019, 47(8): 1701-1707.
- [3] 张继东, 郑宝玉. 基于导频的OFDM信道估计及其研究进展[J]. *通信学报*, 2003, 24(11): 116-124.
ZHANG J D, ZHENG B Y. Overview of pilot-aided channel estimation in OFDM[J]. *Journal of China Institute of Communications*, 2003, 24(11): 116-124.
- [4] 华郁秀, 李荣鹏, 赵志峰, 等. 基于生成对抗网络的 MIMO 信道估计方法[J]. *电信科学*, 2021, 37(6): 14-22.
HUA Y X, LI R P, ZHAO Z F, et al. MIMO channel estimation method based on generating countermeasure network[J]. *Telecommunications Science*, 2021, 37(6): 14-22.
- [5] HUYNH-THE T, HUA C H, NGO T T, et al. Image representation of pose-transition feature for 3D skeleton-based action recognition[J]. *Information Sciences*, 2020(513): 112-126.
- [6] PURWINS H, LI B, VIRTANEN T, et al. Deep learning for audio signal processing[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2019, 13(2): 206-219.
- [7] IQBAL A, THAM M L, CHANG Y C. Double deep Q-network for power allocation in cloud radio access network[C]//*Proceedings of 2020 IEEE 3rd International Conference on Computer and Communication Engineering Technology (CCET)*. Piscataway: IEEE Press, 2020: 272-277.
- [8] IQBAL A, THAM M L, CHANG Y C. Double deep Q-network-based energy-efficient resource allocation in cloud radio access network[J]. *IEEE Access*, 2021(9): 20440-20449.
- [9] 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.
- [10] 陈建廷, 向阳. 深度神经网络训练中梯度不稳定现象研究综述[J]. *软件学报*, 2018, 29(7): 2071-2091.
CHEN J T, XIANG Y. Survey of unstable gradients in deep neural network training[J]. *Journal of Software*, 2018, 29(7): 2071-2091.
- [11] GAO X X, JIN S, WEN C K, et al. ComNet: combination of deep learning and expert knowledge in OFDM receivers[J]. *IEEE Communications Letters*, 2018, 22(12): 2627-2630.
- [12] BAO Y C, TAN Z Y, SUN H F, et al. SimNet: simplified deep neural networks for OFDM channel estimation[C]//*Proceedings of 2020 IEEE 3rd International Conference on Information Communication and Signal Processing (ICICSP)*. Piscataway: IEEE Press, 2020: 348-352.
- [13] 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.
- [14] SOLTANI M, POURAHMADI V, MIRZAEI A, et al. Deep learning-based channel estimation[J]. *IEEE Communications Letters*, 2019, 23(4): 652-655.
- [15] SOLTANI M, POURAHMADI V, SHEIKHZADEH H. Pilot pattern design for deep learning-based channel estimation in OFDM systems[J]. *IEEE Wireless Communications Letters*, 2020, 9(12): 2173-2176.
- [16] CHENG C H, HUANG Y F, CHEN H C, et al. Neural network-based estimation for OFDM channels[C]//*Proceedings of 2015 IEEE 29th International Conference on Advanced Information Networking and Applications*. Piscataway: IEEE Press, 2015: 600-604.
- [17] BAI Q B, WANG J T, ZHANG Y, et al. Deep learning-based channel estimation algorithm over time selective fading channels[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2020, 6(1): 125-134.
- [18] 唐昊, 韩东洪, 周蕊. 浅析 OFDM 技术及其应用[J]. *网络安全技术与应用*, 2019(5): 62-64.
TANG H, HAN D H, ZHOU R. Analysis of OFDM technology and its application[J]. *Network Security Technology & Application*, 2019(5): 62-64.
- [19] LI L J, CHEN H, CHANG H H, et al. Deep residual learning meets OFDM channel estimation[J]. *IEEE Wireless Communications Letters*, 2020, 9(5): 615-618.
- [20] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Piscataway: IEEE Press, 2017: 2261-2269.
- [21] 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.




- [22] JIANG R K, WANG X T, CAO S, et al. Deep neural networks for channel estimation in underwater acoustic OFDM systems[J]. IEEE Access, 2019(7): 23579-23594.
- [23] BASODI S, JI C Y, ZHANG H P, et al. Gradient amplification: an efficient way to train deep neural networks[J]. Big Data Mining and Analytics, 2020, 3(3): 196-207.

[作者简介]



卢敏（1964—），男，江西理工大学理学院教授，主要研究方向为电子材料与器件、智能通信。



陈志辉（1999—），男，江西理工大学理学院硕士生，嘉兴学院信息科学与工程学院联培研究生，主要研究方向为人工智能、深度学习。



张敏（1996—），女，江西理工大学理学院硕士生，嘉兴学院信息科学与工程学院联培研究生，主要研究方向为深度学习与智能通信。



秦泽豪（1998—），男，江西理工大学理学院硕士生，嘉兴学院信息科学与工程学院联培研究生，主要研究方向为智能通信、深度学习。



乐光学（1963—），男，博士，嘉兴学院信息科学与工程学院、浙江省医学电子与数字健康重点实验室教授，主要研究方向为多云融合与协同服务、边缘计算与一体化通信网络、深度学习与智能通信。