

## 基于 Res-DNN 的端到端 MIMO 系统信号检测算法

李国权<sup>1,2</sup>, 徐永海<sup>1,2</sup>, 林金朝<sup>1,2</sup>, 黄正文<sup>3</sup>

(1. 重庆邮电大学通信与信息工程学院, 重庆 400065; 2. 光电信息感测与传输技术重庆市重点实验室, 重庆 400065;  
3. 伦敦布鲁内尔大学电子与计算机工程系, 英国 伦敦 UB8 3PH)

**摘要:** 深度学习可通过提取无线通信数据的内在特征提升信号检测效果。针对 MIMO 系统信号检测存在的性能与复杂度的折中问题, 提出一种基于深度学习的端到端 MIMO 系统信号检测方案。基于残差深度神经网络的编码器和解码器分别替代无线通信系统的发送端和接收端, 将它们看作一个整体通过端到端的方式进行训练。编码器首先对输入数据进行特征提取, 进而建立通信模型并传入迫零检测器进行初步检测, 最终通过解码器重构得出检测信号。仿真结果表明, 所提检测方案优于同类型算法, 并且在牺牲一定时间复杂度的情况下, 检测性能明显优于 MMSE 检测算法。

**关键词:** 深度学习; MIMO 系统; 信号检测; 残差深度神经网络; 端到端

中图分类号: TN92

文献标志码: A

doi:10.11959/j.issn.2096-3750.2022.00256

## Res-DNN based signal detection algorithm for end-to-end MIMO systems

LI Guoquan<sup>1,2</sup>, XU Yonghai<sup>1,2</sup>, LIN Jinzhao<sup>1,2</sup>, HUANG Zhengwen<sup>3</sup>

1. School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China  
2. Chongqing Key Lab of Photoelectronic Information Sensing and Transmitting Technology, Chongqing 400065, China  
3. Department of Electronic and Computer Engineering, Brunel University London, London UB8 3PH, UK

**Abstract:** Deep learning can improve the effect of signal detection by extracting the inherent characteristics of wireless communication data. To solve the tradeoff between the performance and complexity of MIMO system signal detection, an end-to-end MIMO system signal detection scheme based on deep learning was proposed. The encoder and the decoder based on residual deep neural network replace the transmitter and the receiver of the wireless communication system respectively, and they were trained in an end-to-end manner as a whole. Firstly, the features of the input data were extracted by encoder, then the communication model was established and was sent to the zero forcing detector for preliminary detection. Finally, the detection signal was reconstructed through the decoder. Simulation results show that the proposed detection scheme is superior to the same type of algorithm, and the detection performance is significantly better than that of the MMSE detection algorithm at the expense of a certain time complexity.

**Key words:** deep learning, MIMO system, signal detection, Res-DNN, end-to-end

### 0 引言

多输入多输出 (MIMO, multiple input multiple

output) 技术可通过多天线实现更好的复用增益, 从而提升无线通信系统的容量及可靠性<sup>[1]</sup>。MIMO 系统的复杂度与天线的数目息息相关, 尤其是

收稿日期: 2021-10-27; 修回日期: 2022-01-03

通信作者: 李国权, ligq@cqupt.edu.cn

基金项目: 国家重点研发计划 (No.2019YFC1511300); 重庆市自然科学基金资助项目 (No.cstc2019jcyj-msxmX0666, No.cstc2019jcyj-xfkxX0002)

**Foundation Items:** The National Key Research and Development Program of China (No.2019YFC1511300), The Natural Science Foundation of Chongqing (No.cstc2019jcyj-msxmX0666, No.cstc2019jcyj-xfkxX0002)

MIMO 系统信号检测算法的复杂度会随着天线数目的增多呈指数级增长。目前,信号检测算法多为传统算法的改进,所以如何在保证一定系统信号检测性能的基础上降低算法复杂度,依然是该领域的研究热点。

MIMO 系统的信号检测即在接收端设计得到合理的数据恢复算法,从而提高通信系统的检测性能。传统的信号检测算法主要分为线性检测算法和非线性检测算法。非线性检测算法中最大似然估计(MLE, maximum likelihood estimate)是最优的检测算法,复杂度较高,因此一些非线性算法皆以降低 MLE 算法复杂度为目标,如球形译码算法<sup>[2]</sup>、半定松弛算法<sup>[3-4]</sup>、近似消息传递<sup>[5]</sup>等。此类非线性检测算法应用于 MIMO 系统时复杂度仍较高,因此复杂度较低的线性检测算法应用较广,如迫零(ZF, zero forcing)检测算法和最小均方误差(MMSE, minimum mean square error)检测算法等。ZF 检测算法作为一种比较简单的信号接收器,主要原理是将信道矩阵引起的干扰强制成零。ZF 检测算法以增加噪声为代价抵消不同天线间的干扰,而 MMSE 检测算法则是以最小均方误差为准则最小化发送信号和估计结果之间的误差。为了进一步降低算法复杂度,一些研究致力于改进 MMSE 检测算法,衍生得到线性 MMSE 检测算法<sup>[6-7]</sup>以平衡 MMSE 检测算法复杂度与性能之间的矛盾。上述算法在不同的通信场景下有着不同的优势,选择合适的信号检测算法对通信系统性能的提升具有重要的意义。总体上讲,传统信号检测算法存在一些性能较低或复杂度较高等问题,因此,需要提出一种新的检测方法对未来更加复杂的通信场景。

目前,深度学习作为人工智能领域的一项重要技术,在计算机视觉<sup>[8]</sup>、自然语言处理<sup>[9-10]</sup>等方面得到了广泛应用。此外,无线通信中难以为复杂信道建立准确数学模型的问题可通过深度学习解决,深度学习如今已被广泛应用于无线通信领域且表现良好。并且传统的通信系统多由多个模块组成,而单个模块的优化并不意味着整个系统的性能的优化,目前深度学习为实现系统端到端整体优化提供了强力工具<sup>[11-12]</sup>。目前,有关深度学习和通信的研究多着眼于信道状态信息(CSI, channel state information)反馈<sup>[13-14]</sup>、信号检测<sup>[15]</sup>以及预编码<sup>[16-17]</sup>等方面。在无线通信的信号检测方面,文献[18]提出了一种应用在 MIMO 信号检测上的深度神经网络

(DNN, deep neural network) OAMP-Net, 对传统正交近似消息传递算法<sup>[19]</sup>进行了改进。文献[20]通过深度神经网络学习并恢复多级 MIMO 符号,以此探究神经网络在学习高级波形的同时生成新波形的可能性。文献[21]提出了一种并行检测网络(PDN, parallel detection network),该网络由多个基于深度学习的检测网络并行组成,通过设计特定的损失函数降低了检测网络之间的相似性,提升了系统性能。在时变的 MIMO 信道中,随着 PDN 并行数量的增加,系统的检测性能得到显著的提升。文献[22]将循环结构引入神经网络,提出一种低复杂度的 MIMO 系统检测网络。该检测方案既可从零开始训练,具有循环结构的网络,也可由其他深层的神经网络模型转换而来。仿真结果表明,该算法在性能下降很小的情况下降低了模型空间复杂度。文献[23]提出了检测网络(DetNet, detect network),该网络在最大似然估计算法的基础上引入梯度下降算法,分别在两种信道类型中验证了该算法的检测性能,仿真结果显示该方案优于传统的近似消息传递检测算法。然而该文献的数据仿真仅考虑了 MIMO 系统接收端天线数目大于发送端的情况,并且由于其在 MLE 基础上改进而来,网络模型仍具有较高的复杂度。

为了解决 MIMO 系统信号检测存在的性能与复杂度的权衡问题,提出一种基于深度学习的 MIMO 系统信号检测方案,采用残差深度神经网络(Res-DNN, residual deep neural network)以端到端的方式进行信号检测。基于 Res-DNN 的自动编码器中的编码器和解码器网络分别代表通信系统的发送端和接收端,编码器首先对输入数据的内部特征进行学习,之后将编码器的输出作为发射信号通过无线信道进行传输,接下来将接收到的数据传入一个迫零检测器中进行初步的检测,最终解码器网络根据检测结果重构得出发送信号。

## 1 系统模型

考虑一个收发双方同时配备多根天线的 MIMO 无线通信系统,发送端的天线数目为  $N_t$ ,接收端天线数目为  $N_r$ 。MIMO 系统架构如图 1 所示,数据流经过发送端之后再通过发射天线传入信道,接收天线接收数据后在接收端进行信号的检测与恢复。天线间的数据传输共用一个频段,节省了带宽资源。

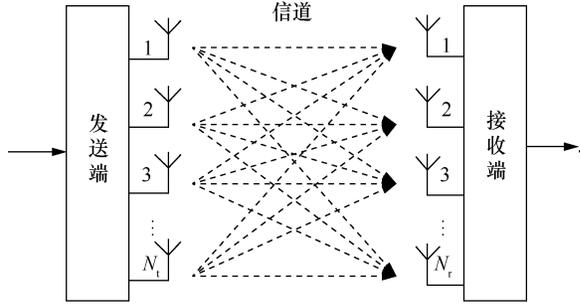


图 1 MIMO 系统架构

MIMO 系统发送长度为  $\tau$  的信号，发送信号为  $\mathbf{X} \in \mathbb{C}^{N_t \times \tau}$ ，接收信号为  $\mathbf{Y} \in \mathbb{C}^{N_r \times \tau}$ 。MIMO 系统的信号检测模型可表示为

$$\mathbf{Y} = \mathbf{H}\mathbf{X} + \mathbf{N} \quad (1)$$

其中， $\mathbf{H} \in \mathbb{C}^{N_r \times N_t}$  为发射天线和接收天线之间的信道矩阵，服从瑞利分布。 $\mathbf{N} \in \mathbb{C}^{N_r \times \tau}$  为加性高斯白噪声，服从均值为 0、方差为  $\sigma^2$  的高斯分布。

MIMO 系统信号检测即在信道信息已知或者未知的前提下，通过一些算法检测或恢复发送信号  $\mathbf{X}$ ，本文考虑信道信息完全已知的情况。传统算法中的 ZF 检测算法和 MMSE 检测算法，因其较低的复杂度可有效地恢复得到信号而在实际中较为常用。线性检测一般指接收信号乘以一个加权矩阵后得到估计值，之后进行判决得到结果。

首先对线性检测算法进行探讨，对于 ZF 检测算法，其加权矩阵为

$$\mathbf{W}_{\text{ZF}} = (\mathbf{H}^H \mathbf{H})^{-1} \mathbf{H}^H \quad (2)$$

该矩阵为信道矩阵  $\mathbf{H}$  的伪逆矩阵，它起到了逆转信道的作用。ZF 检测算法的结果为

$$\begin{aligned} \tilde{\mathbf{X}}_{\text{ZF}} &= \mathbf{W}_{\text{ZF}} \mathbf{Y} = (\mathbf{H}^H \mathbf{H})^{-1} \mathbf{H}^H \mathbf{Y} = \\ &= \mathbf{X} + (\mathbf{H}^H \mathbf{H})^{-1} \mathbf{H}^H \mathbf{N} \end{aligned} \quad (3)$$

其中， $(\mathbf{H}^H \mathbf{H})^{-1} \mathbf{H}^H \mathbf{N}$  表示真实信号与检测结果之间的误差。

对于 MMSE 检测算法，其加权矩阵为

$$\mathbf{W}_{\text{MMSE}} = (\mathbf{H}^H \mathbf{H} + \sigma^2 \mathbf{I})^{-1} \mathbf{H}^H \quad (4)$$

其中， $\sigma^2$  为噪声的统计信息， $\mathbf{I}$  为单位矩阵。MMSE 算法的检测结果为

$$\begin{aligned} \tilde{\mathbf{X}}_{\text{MMSE}} &= \mathbf{W}_{\text{MMSE}} \mathbf{Y} = (\mathbf{H}^H \mathbf{H} + \sigma^2 \mathbf{I})^{-1} \mathbf{H}^H \mathbf{Y} = \\ &= \mathbf{X} + (\mathbf{H}^H \mathbf{H} + \sigma^2 \mathbf{I})^{-1} \mathbf{H}^H \mathbf{N} \end{aligned} \quad (5)$$

对于非线性检测算法中的 MLE 检测算法，其以

计算所有可能的  $\mathbf{X}$  与信道矩阵  $\mathbf{H}$  的乘积和接收信号  $\mathbf{Y}$  间的最小欧氏距离为准则。该算法的检测结果为

$$\tilde{\mathbf{X}}_{\text{ML}} = \underset{\mathbf{X} \in M^{N_t}}{\operatorname{argmin}} \|\mathbf{Y} - \mathbf{H}\mathbf{X}\|^2 \quad (6)$$

其中， $M$  表示信号的星座集， $N_t$  表示发射天线的数目。MLE 检测算法可达到最大后验概率检测的最优性能，然而其计算复杂度随着调制阶数及天线数目的增多呈指数增长。因此，MLE 检测多作为参考基准算法。

上述的检测算法中 ZF 检测算法比较简单，因为放大了噪声，所以检测性能较差，而 MMSE 检测算法考虑了噪声的因素，性能较于 ZF 算法得到了不小的提升，但性能仍然较低。一些非线性检测算法的性能虽然达到了次优，但因其复杂度较高而在实际中应用较少。

## 2 基于 Res-DNN 的端到端信号检测方案

深度学习通过多层神经网络及每层的神经元对输入的海量标签数据特征进行学习，实现对目标的准确预测或分类。每一层的神经元通过提取数据样本中不同的特征，得到比较全面的数据特征信息。基于端到端的深度学习方案则是将需要多模块处理的问题通过训练单个模型使其得以解决。当采用多个模型解决一个较为复杂的问题时，由于各个模块的目标函数不同，某一模块的损失函数指标可能与总体的目标存在偏差，最终导致训练完成的模型很难达到最优的性能，采用端到端的训练方式即可解决该问题，通过对整体进行优化以提升系统检测性能。

### 2.1 所提方案的网络结构

一般情况下，深层神经网络层数的增加意味着学习数据特征能力的增强，但实际情况并非如此。当网络层数增加到一定程度时，网络模型的性能会出现下降的现象，从而导致网络模型的能力退化。这种情况主要是由于深层网络中较易出现梯度爆炸或者梯度消失。针对此问题，采用基于深度残差网络<sup>[24]</sup>的 Res-DNN<sup>[25]</sup>。本文提出的信号检测算法主要对通信数据进行处理，深度神经网络可满足本文场景；而卷积神经网络主要适用于图像领域，所需算力更高，因此本文将原本残差网络中的卷积神经网络替换为满足信号检测需求的深度神经网络，在此基础上设计构建基于 Res-DNN 的端到端的 MIMO 系统信号检测网络模型。

Res-DNN 由多个残差块组成，旨在解决深层网

络模型中随网络层数增加模型性能退化的问题。每个残差块由 3 层网络组成，第一层网络经过激活函数后的输出与第 3 层网络激活函数之前的数据流相加，共同作为下一层网络的输入。随着网络层数加深，网络对数据特征的处理得以有所保留地进行。残差块结构如图 2 所示，在保证深层神经网络本身所具有前向计算输出、反向传播更新参数能力的同时，第 L1 层整流线性单元 (ReLU, rectified linear unit) 激活函数后的数据流加到了第 L3 层激活前的输出上，可有效解决网络层数增大造成的提取特征能力的降低。Res-DNN 则是由不同的残差块级联组成。

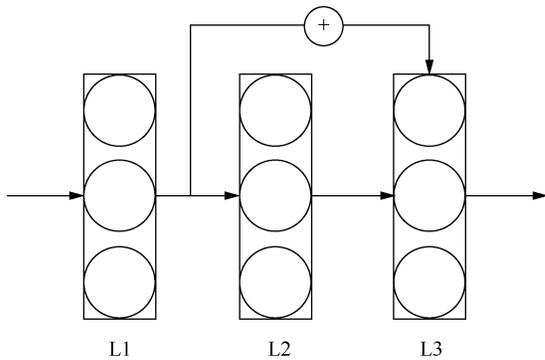


图 2 残差块结构

对于 MIMO 系统信号检测，提出一种采用 Res-DNN 端到端地进行 MIMO 信号检测的神经网络模型。如上所述，Res-DNN 可解决由于网络加深导致的模型能力退化问题。MIMO 通信系统的发送端和接收端分别由基于 Res-DNN 的编码器和解码器替代。类似于自动编码器的方式，将整个系统当作一个整体进行训练。自编码器模型一般由两部分能组成：第一部分是编码器的映射，可学习并提取输入数据的内在特征；第二部分是解码器的映射，

利用编码器学习到的数据特征重构输入数据。采用端到端的训练方式，可以避免不同模块之间原本的缺陷，在一定程度上实现了全局优化，提升了系统的检测效率。

基于 Res-DNN 的端到端信号检测方案框架如图 3 所示，MIMO 系统的发送端和接收端分别由 Res-DNN 所替代。首先，发送信号  $X$  作为输入数据传入第一个 Res-DNN 进行特征提取得到  $\tilde{X}$ ，接下来将其发送到一个无线信道中进行传输。为了更好地提升系统的检测性能，将神经网络与传统的 ZF 检测算法相结合，在接收端网络重构数据之前对传入的数据进行 ZF 检测。之后将经过初步检测后的信号传入到第二个 Res-DNN 进行原始数据的重构，最终得到网络输出的检测结果  $\tilde{X}_{AE}$ 。

对于编码器网络，其输入为发送信号。从输入到该网络输出的映射  $F_E$  可表示为

$$F_E(X, \theta_E) = f(f(X \times W_1 + b_1) \times W_2 + b_2) \cdots \times W_L + b_L \quad (7)$$

其中， $\theta_E$  为此部分的参数集合， $W_k \in \mathbb{R}^{N \times N}$  和  $b_k \in \mathbb{R}^N$  分别为编码器第  $k$  层网络的权值矩阵和偏置值矩阵， $1 < k < L$ ， $L$  为编码器的网络层数， $N$  为每层神经元的神经元个数， $f(\cdot)$  为激活函数。

对于解码器网络，其输入为由编码器输出，再由无线信道和 ZF 检测处理后的信号。该部分的映射  $F_D$  可表示为

$$F_D(\tilde{X}, \theta_D) = f(f(\tilde{X} \times U_1 + v_1) \times U_2 + v_2) \cdots \times U_K + v_K \quad (8)$$

其中， $\theta_D$  为解码器的参数集， $U_i \in \mathbb{R}^{N \times N}$  和  $v_i \in \mathbb{R}^N$  为解码器第  $i$  层的权值和偏置值，其中， $1 < i < K$ ， $K$  为解码器网络层数。除末层神经网络外，其余每

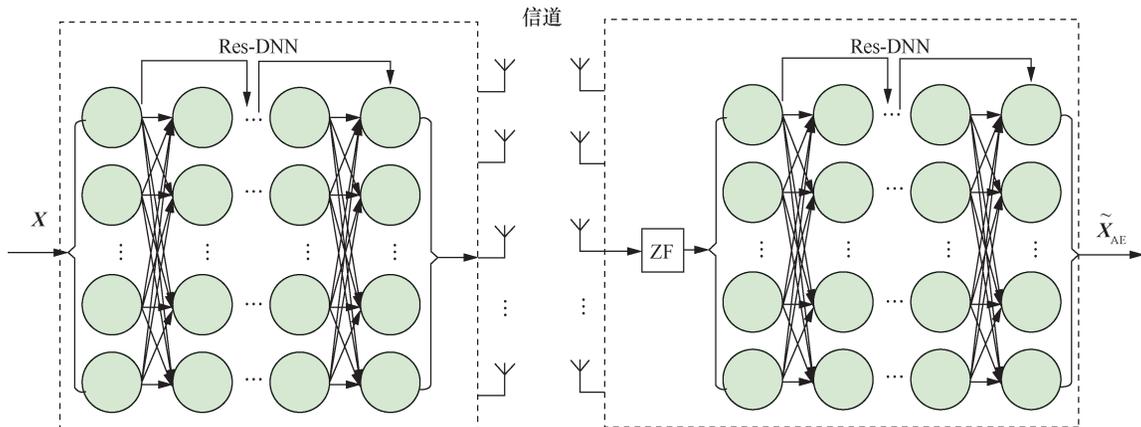


图 3 基于 Res-DNN 的端到端信号检测方案框架

层均采用 ReLU 激活函数。ReLU 可在提高计算效率的同时对梯度消失进行补偿。每层网络的神经节点在传入下一层网络之前经过一个非线性函数，可达到去线性化的目的，从而更适合解决实际应用中的非线性问题。

自编码器中的编码器和解码器网络根据一个损失函数进行参数的迭代更新，损失函数指网络预测值与输入数据之间的均方误差，本文采用适用于高斯分布的二次代价函数作为损失函数。网络的输入首先与第一层网络的权值相乘后与偏置值相加，再经过激活函数处理后作为下层神经网络的输入，其中权值和偏置值均已知。由神经网络前向传播得到从输入数据中学习的特征，之后以最小化输出与数据标签间的误差为目标进行反向传播迭代更新每一层的权值和偏置值，如此循环直至收敛。损失函数 Loss 可表示为

$$\text{Loss} = \frac{1}{R} \sum_{j=1}^R \|\tilde{\mathbf{X}}_{\text{AE}} - \mathbf{X}\|_2^2 \quad (9)$$

其中， $\tilde{\mathbf{X}}_{\text{AE}}$  为网络输出的信号检测结果， $R$  为每次训练时训练样本的大小。

学习率指参数更新调整的幅度大小。学习率过大将导致模型不易收敛，过小将造成收敛效率过低。本文采用可自动调整学习率的 Adam 优化器，Adam 可使学习率呈指数级衰减。训练前期采用较大的学习率得到次优的结果，其次随着迭代次数的增加学习率会逐渐减小，可使训练后期的损失函数值更加稳定并得到更加健壮的网络模型。

此外，所提方案网络中的一些地方需要进行矩阵维度的修整。在输入无线信道前需要对编码器输出的数据进行维度的调整以进行系统模型的建立；在经过 ZF 检测之后需调整传入解码器网络的数据维度；网络最终输出结果的维度为发送信号的矩阵维度，利于直接进行判决得出误码率。

## 2.2 数据预处理

目前神经网络输入的数据多为实数类型，尚不能对复数数据进行处理，因此在整个研究工作中避免直接处理复数，将复数形式的数据等效为实数形式。输入的数据遵循式 (10)

$$\begin{bmatrix} \Re(\mathbf{Y}) \\ \Im(\mathbf{Y}) \end{bmatrix} = \begin{bmatrix} \Re(\mathbf{H}) & -\Im(\mathbf{H}) \\ \Im(\mathbf{H}) & \Re(\mathbf{H}) \end{bmatrix} \begin{bmatrix} \Re(\mathbf{X}) \\ \Im(\mathbf{X}) \end{bmatrix} + \begin{bmatrix} \Re(\mathbf{N}) \\ \Im(\mathbf{N}) \end{bmatrix} \quad (10)$$

其中， $\Re(\cdot)$  和  $\Im(\cdot)$  分别表示实部和虚部。合并之后的数据维度发生了变化，接收信号为  $\mathbf{Y} \in \mathbb{R}^{2N_r \times r}$ ，

发送信号为  $\mathbf{X} \in \mathbb{R}^{2N_t \times r}$ ，信道矩阵为  $\mathbf{H} \in \mathbb{R}^{2N_r \times 2N_t}$ ，高斯白噪声为  $\mathbf{N} \in \mathbb{R}^{2N_r \times r}$ 。

## 3 仿真结果

### 3.1 参数配置

针对 MIMO 无线通信系统的信号检测，将进行所提方案相关参数配置的介绍以及仿真结果展示，并对其性能进行分析，参数配置见表 1。

表 1 参数配置

类型	参数配置
天线数目	8×8/16×16
信道类型	瑞利信道
调制方式	BPSK/QPSK
训练数据的信噪比	15 dB
神经网络层数	11 层
训练次数	20 000 次
神经元数目	128 个
激活函数	ReLU
初始学习率	0.000 3
损失函数	二次代价函数
优化器	Adam

发射端和接收端的天线数目分别考虑 8×8 和 16×16 两种情况，无线信道类型为瑞利信道，调制方式包括 BPSK 和 QPSK。网络所需要的训练数据通过仿真产生，每次迭代的数据皆根据给定的分布随机生成，网络的输入作为模型学习的标签。训练数据为仿真产生的 15 dB 信噪比下的数据，训练次数为 20 000，两种天线配置下的训练次数及训练信噪比相同。非线性激活函数采用 ReLU 激活函数，损失函数和优化器分别采用二次代价函数和 Adam 优化器，学习率的初始值设为 0.000 3，随着迭代次数的增加学习率会逐渐减小直至收敛。

通过测试发现，网络层数及神经元数目过小会导致学习能力较低，过大则会造成模型易出现过拟合现象。因此，通过仿真测试将神经网络层数设为 11，每层网络中神经元的数目设为 128，矩阵维度调整处的神经元数目会适当增减。仿真时将 DetNet 的网络层数设置为 40，此时在所提方案的场景下 DetNet 算法的性能趋于饱和。训练阶段主要训练的是固定单个信噪比下的数据。发送信号经过一个编码器网络后进行无线通信系统模型的建立，接下来进行 ZF 检测后传入解码器网络重构发送信号，最

终输出估计值。测试阶段分别测试从 0~20 dB 下的数据得到对应的误码率。

### 3.2 仿真结果

天线数目为 8×8、BPSK 调制下不同信号检测方案的误码率对比如图 4 所示, 主要包括 ZF 检测、MMSE 检测、ML 检测、DetNet 检测以及基于 Res-DNN 的检测算法。各个检测算法的仿真均在相同的条件下进行。仿真结果表明, MMSE 检测算法优于 ZF 检测和 DetNet 算法, 然而性能远低于 ML 检测。仿真时 DetNet 检测中网络的层数设置为 20 层, 此时 DetNet 检测具有与所提方案相当的复杂度。此外, DetNet 的研究仅考虑了接收端天线数目大于发送端的情况, 在该情况下其性能较好, 而本文测试对比的是收发天线数目相同条件下的 DetNet 算法。所提检测方案性能优于列举出的传统线性检测算法以及基于深度学习的 DetNet 检测算法。同时, 在 0~4 dB 处所提方案略优于 ML 检测, 随着信噪比的增加, 所提方案性能逐渐低于 ML 检测, 但皆优于除最优检测算法 ML 之外的其他检测算法。所提方案通过自身较强的重构输入数据的能力, 在 MIMO 系统信号检测方面表现出较好的误码率。

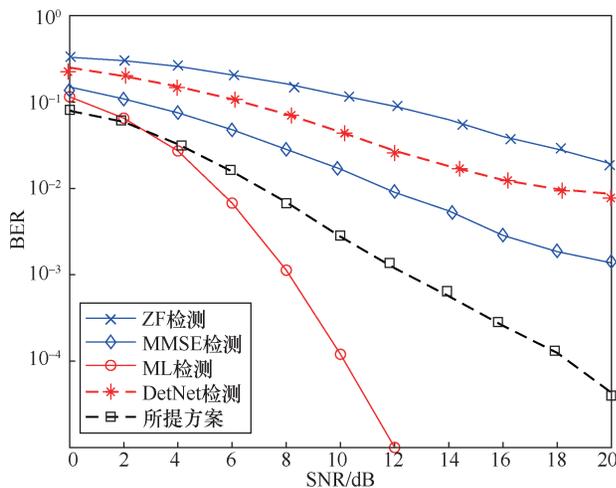


图 4 天线数目为 8×8、BPSK 调制下不同信号检测方案的误码率对比

为了探究本文提出的方案在天线数目增加后的误码率情况, 天线数目为 16×16、BPSK 调制下不同信号检测方案的误码率对比如图 5 所示。仿真结果表明, 所提方案与 ZF 检测、MMSE 检测以及 DetNet 检测 3 种算法相比仍具有较大优势。此外, 结合图 4、图 5 可以看出, 所提方案的误码率曲线与其他算法相比平滑度有所欠缺, 初步推断这是由于模型在训练时输入只包含了单个信噪比下的数据, 而测试时的输入

则为所有信噪比下的数据, 但从总体误码率可以看出所提方案仍能表现出较好的检测性能, 深度学习在无线路通信系统信号检测上表现出了不俗的能力。

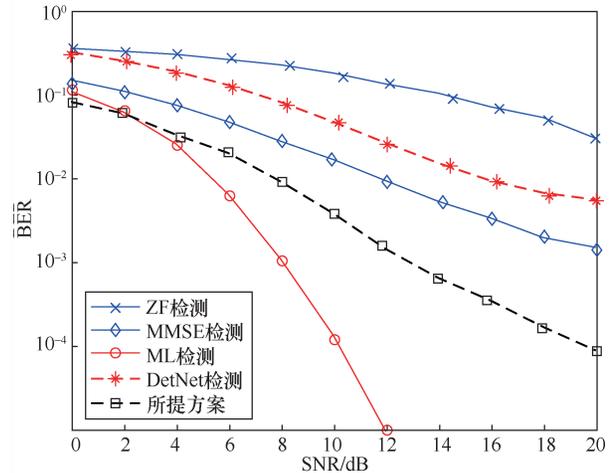


图 5 天线数目为 16×16、BPSK 调制下不同信号检测方案的误码率对比

为了进一步验证所提方案的性能, 天线数目为 8×8、QPSK 调制下不同信号检测方案的误码率对比如图 6 所示, 天线数目为 16×16、QPSK 调制下不同信号检测方案的误码率对比如图 7 所示。仿真结果表明, QPSK 调制下随着天线数目的增多, DetNet 算法误码率性能逐渐上升, 其余检测方案误码率曲线变化较小。QPSK 调制下与 BPSK 调制下相比, 误码率曲线略微上升。但总体上看, 误码率性能波动较小。所提方案在 QPSK 调制下仍能表现出良好的信号检测性能, 依旧优于同等条件下的 ZF 检测、MMSE 检测以及 DetNet 检测算法。这足以证明所提出的方案在 MIMO 通信信号检测方面的可行性, 更印证了深度学习与传统算法结合的可能。

天线数目为 8×8、BPSK 调制下 Res-DNN 与 DNN 的误码率对比如图 8 所示, 其中未采用端到端方式下, 输入 DNN 的数据为经过信道到达接收端的接收信号, 输出的是恢复的发送信号。此时, DNN 主要承担接收端解调、判决等操作, 发送端仍保留了原来的调制等通信模块。仿真结果表明, 采用 Res-DNN 作为编码器及解码器网络, 其误码率性能与另外两种方案相比具有明显的提升, 表现出基于 Res-DNN 的端到端检测方案在 MIMO 通信系统中所发挥的重要作用。综上所述, 所提出的基于 Res-DNN 的端到端 MIMO 系统信号检测方案, 在同等条件下与一些传统检测算法及深度学习检测算法相比, 在检测性能上具有较明显的优势。

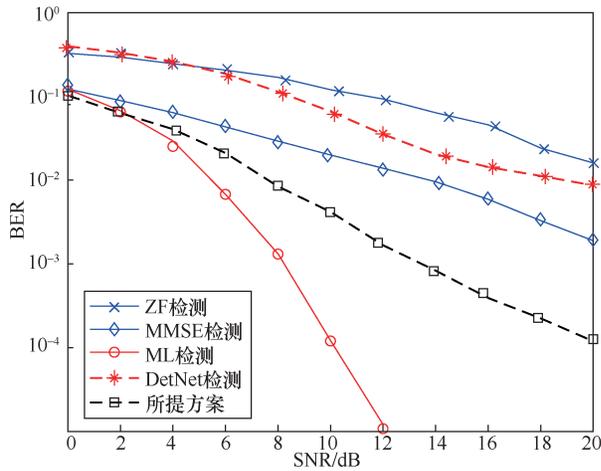


图 6 天线数目为 8×8、QPSK 调制下不同信号检测方案的误码率对比

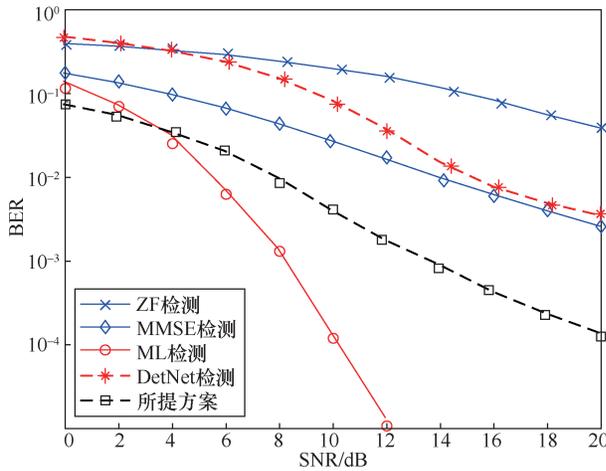


图 7 天线数目为 16×16、QPSK 调制下不同信号检测方案的误码率对比

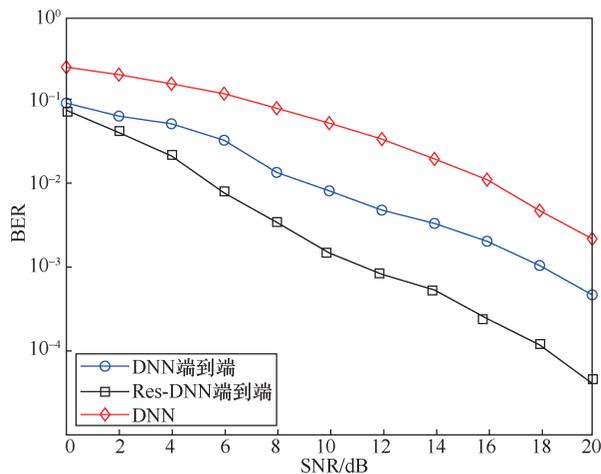


图 8 天线数目为 8×8、BPSK 调制下 Res-DNN 与 DNN 的误码率对比

### 3.3 复杂度分析

深度学习中网络模型的复杂度多用神经网络中的参数量衡量，这不同于传统的通信算法复杂度的衡量标准，因此为了便于统一对比分析，本文采

用平均计算时间作为复杂度的衡量标准。8×8 MIMO 系统 QPSK 调制下各检测算法的平均计算时间对比见表 2。线性检测算法 ZF 检测以及 MMSE 检测的计算时间较短，最优检测算法 ML 的计算时间最长。而所提检测方案的计算时间比 DetNet 算法的计算时间略长，但性能具有较明显的提升。二者的计算时间皆位于线性检测和最优化检测算法之间，表明在复杂度增加可接受范围内，所提方案的检测性能可达到较好的结果。

表 2 8×8 MIMO 系统 QPSK 调制下各检测算法的平均计算时间对比

检测算法	计算时间/s
ZF 检测	0.000 025 1
MMSE 检测	0.000 049 8
ML 检测	0.525 025 8
DetNet 检测	0.000 281 7
所提方案	0.000 451 4

## 4 结束语

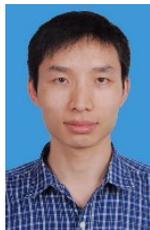
目前，在上层应用中得到广泛发展的深度学习正在向无线通信物理层推进。为了解决无线通信中存在的传统信号检测问题，本文提出了一种基于 Res-DNN 的端到端的 MIMO 系统信号检测方案，结合深度学习与传统通信算法提升系统的检测性能。采用端到端的方式将整个无线通信系统看作一个模型进行训练，避免不同模块间相互影响，使得总的目标函数更加明确，在一定程度上提高了系统的效率。仿真结果表明，在可接受的计算开销内，所提方案在多种调制方式下均优于 MMSE 检测算法。此外，传统的多个模块级联处理问题的方式可以比较清晰地分析单个模块的贡献程度，而端到端的训练方式则不具备这种优势，即端到端模型内部机制的可解释性仍存在欠缺，有必要在该方面投入更多的研究。

### 参考文献：

- [1] ABID W, HAJAJ M, MEJRI A, et al. Weighted Kalman based detection for uplink MIMO systems[C]//Proceedings of 2020 International Conference on Software, Telecommunications and Computer Networks (SoftCOM). Piscataway: IEEE Press, 2020: 1-6.
- [2] CHAN A M, LEE I. A new reduced-complexity sphere decoder for multiple antenna systems[C]//Proceedings of 2002 IEEE International Conference on Communications. Conference Proceedings. Piscataway: IEEE Press, 2002: 460-464.

- [3] LUO Z Q, MA W K, SO A M C, et al. Semidefinite relaxation of quadratic optimization problems[J]. IEEE Signal Processing Magazine, 2010, 27(3): 20-34.
- [4] JALDEN J, OTTERSTEN B. The diversity order of the semidefinite relaxation detector[J]. IEEE Transactions on Information Theory, 2008, 54(4): 1406-1422.
- [5] JEON C, GHODS R, MALEKI A, et al. Optimality of large MIMO detection via approximate message passing[C]//Proceedings of 2015 IEEE International Symposium on Information Theory (ISIT). Piscataway: IEEE Press, 2015: 1227-1231.
- [6] WALUYO C B, ISKANDAR. Performance analysis with LMMSE for MIMO LTE on the high altitude platform station[C]//Proceedings of 2015 International Conference on Electrical Engineering and Informatics (ICEEI). Piscataway: IEEE Press, 2015: 308-313.
- [7] XIONG Y Z, WEI N, ZHANG Z P. An LMMSE-based receiver for uplink massive MIMO systems with randomized IQ imbalance[J]. IEEE Communications Letters, 2018, 22(8): 1624-1627.
- [8] DEEP S, ZHENG X. Leveraging CNN and transfer learning for vision-based human activity recognition[C]//Proceedings of 2019 29th International Telecommunication Networks and Applications Conference (ITNAC). Piscataway: IEEE Press, 2019: 1-4.
- [9] HASSAN S, IRFAN A, MIRZA A, et al. Cursive handwritten text recognition using Bi-directional LSTMs: a case study on Urdu handwriting[C]//Proceedings of 2019 International Conference on Deep Learning and Machine Learning in Emerging Applications (Deep-ML). Piscataway: IEEE Press, 2019: 67-72.
- [10] ALWEHAIBI A, ROY K. Comparison of pre-trained word vectors for Arabic text classification using deep learning approach[C]//Proceedings of 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA). Piscataway: IEEE Press, 2018: 1471-1474.
- [11] 桂冠, 王禹, 黄浩. 基于深度学习的物理层无线通信技术: 机遇与挑战[J]. 通信学报, 2019, 40(2): 19-23.
- GUI G, WANG Y, HUANG H. Deep learning based physical layer wireless communication techniques: opportunities and challenges[J]. Journal on Communications, 2019, 40(2): 19-23.
- [12] 李国权, 杨鹏, 林金朝, 等. 基于深度学习的 MIMO 系统联合优化[J]. 重庆邮电大学学报(自然科学版), 2019, 31(3): 293-298.
- LI G Q, YANG P, LIN J Z, et al. Deep learning-based joint optimization for MIMO systems[J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition), 2019, 31(3): 293-298.
- [13] ZHANG Y B, WANG J, SUN J L, et al. CV-3DCNN: complex-valued deep learning for CSI prediction in FDD massive MIMO systems[J]. IEEE Wireless Communications Letters, 2021, 10(2): 266-270.
- [14] WANG J, GUI G, OHTSUKI T, et al. Compressive sampled CSI feedback method based on deep learning for FDD massive MIMO systems[J]. IEEE Transactions on Communications, 2021, 69(9): 5873-5885.
- [15] XIA J J, DENG D, FAN D. A note on implementation methodologies of deep learning-based signal detection for conventional MIMO transmitters[J]. IEEE Transactions on Broadcasting, 2020, 66(3): 744-745.
- [16] HUANG H J, SONG Y W, YANG J, et al. Deep-learning-based millimeter-wave massive MIMO for hybrid precoding[J]. IEEE Transactions on Vehicular Technology, 2019, 68(3): 3027-3032.
- [17] MA W Y, QI C H, ZHANG Z C, et al. Sparse channel estimation and hybrid precoding using deep learning for millimeter wave massive MIMO[J]. IEEE Transactions on Communications, 2020, 68(5): 2838-2849.
- [18] HE H T, WEN C K, JIN S, et al. A model-driven deep learning network for MIMO detection[C]//Proceedings of 2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP). Piscataway: IEEE Press, 2018: 584-588.
- [19] MA J J, LIU L, YUAN X J, et al. On orthogonal AMP in coded linear vector systems[J]. IEEE Transactions on Wireless Communications, 2019, 18(12): 5658-5672.
- [20] CORLAY V, BOUTROS J J, CIBLAT P, et al. Multilevel MIMO detection with deep learning[C]//Proceedings of 2018 52nd Asilomar Conference on Signals, Systems, and Computers. Piscataway: IEEE Press, 2018: 1805-1809.
- [21] JIN X L, KIM H N. Parallel deep learning detection network in the MIMO channel[J]. IEEE Communications Letters, 2020, 24(1): 126-130.
- [22] LIAO S Y, DENG C H, LIU L J, et al. Structured neural network with low complexity for MIMO detection[C]//Proceedings of 2019 IEEE International Workshop on Signal Processing Systems (SiPS). Piscataway: IEEE Press, 2019: 290-295.
- [23] SAMUEL N, DISKIN T, WIESEL A. Learning to detect[J]. IEEE Transactions on Signal Processing, 2019, 67(10): 2554-2564.
- [24] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Piscataway: IEEE Press, 2016: 770-778.
- [25] CHENG X, LIU D J, ZHU Z Y, et al. A ResNet-DNN based channel estimation and equalization scheme in FBMC/OQAM systems[C]// Proceedings of 2018 10th International Conference on Wireless Communications and Signal Processing (WCSP) Piscataway: IEEE Press, 2018: 1-5.

## [作者简介]



李国权 (1980- ), 男, 博士, 重庆邮电大学通信与信息工程学院教授, 主要研究方向为 MIMO 无线通信传输技术、异构无线网络传输技术、机器学习等。



徐永海 (1995- ), 男, 重庆邮电大学通信与信息工程学院硕士生, 主要研究方向为 MIMO 无线通信传输技术、机器学习等。



林金朝 (1966- ), 男, 博士, 重庆邮电大学通信与信息工程学院教授, 主要研究方向为无线通信传输技术、BAN 与信息处理技术等。



黄正文 (1981- ), 男, 博士, 伦敦布鲁内尔大学讲师、高级研究员, 主要研究方向为人工智能、复杂系统优化、数据分析等。